

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЧЕРКАСЬКИЙ ДЕРЖАВНИЙ ТЕХНОЛОГІЧНИЙ УНІВЕРСИТЕТ

**Кваліфікаційна наукова
праця на правах рукопису**

БОЙКО НАТАЛІЯ ІВАНІВНА

УДК 004.04: 004.02: 004.6: 004.9

ДИСЕРТАЦІЯ

**МЕТОДОЛОГІЯ БАГАТОВИМІРНОГО АНАЛІЗУ
МУЛЬТИМОДАЛЬНИХ ДАНИХ**

05.13.06 – інформаційні технології

Подається на здобуття наукового ступеня доктора технічних наук.

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело


_____ Н. І. Бойко

Черкаси – 2025

АНОТАЦІЯ

Бойко Н. І. Методологія багатовимірної аналізу мультимодальних даних
– Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора технічних наук за спеціальністю 05.13.06 – інформаційні технології. – Черкаський державний технологічний університет Міністерства освіти і науки України, Черкаси, 2025.

Сучасні технології розвиваються дуже швидко, і разом із цим зростають обсяги та різнотиповість даних. У медицині це особливо відчутно, адже доводиться працювати з великою кількістю інформації: від сенсорів і приладів до знімків, записів лікарів та числових показників. Такі різноманітні дані називають мультимодальними, і для їх якісної обробки потрібні нові рішення.

Мультимодальні дані часто різняться за форматом, точністю чи часом отримання, можуть бути неповними або надлишковими. Це створює труднощі при їх поєднанні й аналізі. Крім того, в реальних завданнях важливо враховувати одразу кілька вимог – швидкість, точність, стійкість до шуму та обчислювальну ефективність. Класичні методи, які орієнтуються лише на один критерій, у таких випадках виявляються малоефективними.

Перспективним напрямом є пошук балансу між кількома вимогами. Модель можна налаштувати так, щоб вона зберігала достатню точність навіть при відсутніх даних, або ж працювала швидше без помітної втрати якості.

У цьому дослідженні запропоновано підходи для побудови ознакових просторів для різних типів даних, узгодження інформації з різноманітних джерел та адаптації моделей до неповних чи зашумлених даних.

Відсутність комплексних моделей, методів і засобів підтримки прийняття медичних рішень на основі багатовимірної аналізу мультимодальних даних, які б одночасно враховували різноманітність джерел інформації, часову синхронізацію модальностей і багатокритеріальний характер клінічних рішень, а також методологічна фрагментарність існуючих підходів і неможливість їх інтеграції в єдину ефективну систему створюють *актуальну науково-прикладну проблему*.

Особливу увагу приділено медичній галузі, де точність і своєчасність рішень відіграють критичну роль. Виявлено, що наразі бракує універсальних інформаційних технологій підтримки прийняття рішень, які б могли ефективно об'єднувати дані різної модальності – наприклад, електрокардіограми (ЕКГ), електроенцефалограми (ЕЕГ), магнітно-резонансні томограми (МРТ) та враховувати як структурну різноманітність, так і часову неузгодженість цих даних.

Розроблена в роботі інформаційна технологія вирішує цю проблему шляхом формалізованого подання медичних даних, що враховує їхню складність і багатоманітність. Вона дозволяє інтегрувати інформацію з кількох джерел, забезпечує її часову синхронізацію, зберігає аналітичну точність навіть за умови нестачі або надлишку інформації та підвищує якість і швидкість клінічних рішень. Такий підхід відкриває нові можливості для побудови сучасних інтелектуальних медичних систем і підвищення їх ефективності у реальній практиці.

Наукова новизна результатів дисертаційної роботи полягає у вирішенні важливої науково-прикладної проблеми розроблення методології багатовимірного аналізу мультимодальних даних, що дало змогу розробити інформаційну технологію для автоматизованої обробки, інтеграції та інтерпретації різноманітної інформації й забезпечило подальший розвиток цього наукового напрямку. Отримано такі нові наукові результати:

вперше:

- запропонована концепція аналізу мультимодальних даних, яка полягає у виділенні ознак для кожної модальності та їх об'єднанні в єдиний багатовимірний простір ознак, яка, на відміну від існуючих, забезпечує формування окремих множин ознак із різних модальностей для розробки методів класифікації станів пацієнта, що дозволяє підвищити інформативність масивів вхідних даних та збільшити кількість правильно класифікованих станів;
- сформульовано принципи багатовимірного аналізу мультимодальних даних, які полягають в інтеграції різноманітних ознак та модальних моделей

у єдиній інформаційній технології, що забезпечує підвищення точності, надійності та адаптивності класифікаційних систем в умовах гетерогенності та неповноти медичних даних.

- розроблено метод інтеграції модальних даних, який полягає у поєднанні цих даних за певними ознаками, що, на відміну від існуючих, будує точки спостереження шляхом адаптивного, погодженого та поетапного об'єднання даних із різних модальностей в єдиний вектор та поєднання цих векторів, що дозволяє створити із окремих точок спостереження за пацієнтом спільний масив вхідних даних та формувати модель-класифікатор;
- розроблено метод побудови мультимодальної моделі, який полягає у побудові моделей окремих модальностей та використанні результатів моделювання для класифікації станів пацієнта, який на відміну від існуючих, інтегрує результати моделювання в єдину ієрархічну структуру, що дозволяє підвищити кількість правильно класифікованих станів пацієнта.

Одержав подальший розвиток:

- метод вибору інформативних ознак, адаптований до гетерогенності джерел мультимодальних даних, завдяки формуванню багатовимірного ознакового простору з урахуванням їх кореляційної узгодженості, що дозволяє підвищити стійкість моделей машинного навчання.

Удосконалено:

- метод оцінювання ефективності аналізу мультимодальних даних, шляхом порівняння результатів експериментів за точністю, повнотою, F1-метрикою, часом обробки та стабільністю роботи моделей, що дає змогу об'єктивно визначати переваги запропонованої технології, збільшувати кількість правильно класифікованих станів та забезпечувати адаптацію системи до клінічних умов.

Практична значимість виконаного дослідження полягає у створенні інформаційної технології багатовимірного аналізу мультимодальних даних, яка

забезпечує автоматизовану обробку, інтеграцію та інтерпретацію різномірної інформації. Застосування розробленої технології підвищує ефективність функціонування інформаційних систем і сприяє достовірності отриманих результатів для вирішення прикладних завдань, що дало змогу сформулювати такі прикладні результати дослідження:

- Запропонована концепція аналізу мультимодальних даних дозволяє реалізувати ефективні методи класифікації шляхом формування окремих наборів ознак для кожної модальності та їх об'єднання у єдиний багатовимірний простір. Сформовано узгоджений простір ознак розмірністю $X \in R^{1000 \times 24}$ для 1000 пацієнтів, який забезпечив загальну точність класифікації на рівні 85 %. Такий підхід підвищує інформативність вхідних даних, зменшує втрати релевантної інформації при інтеграції, та дозволяє покращити точність класифікації станів пацієнтів.
- Сформульовано принципи багатовимірного аналізу мультимодальних даних, зокрема інтеграції ознак різних модальностей та об'єднання моделей, побудованих за окремими модальностями. Застосування цих принципів забезпечує надійність функціонування інформаційної технології в умовах неповних чи надлишкових даних, а також адаптацію системи до змін у структурі вхідної інформації. Розроблена технологія зберігає стабільність результатів навіть за наявності пропусків та варіацій у наборі ознак, що підтверджує її прикладну цінність для прикладних задач обробки даних.
- Розроблено метод інтеграції модальних даних, що забезпечує адаптивне поетапне об'єднання інформації з різних джерел у єдиний ознаковий простір. Це дозволило досягти 96 % загальної точності класифікації та значення макро- та зважених середніх метрик також дорівнюють 0,96, забезпечивши збалансоване розпізнавання всіх класів, включно зі складними клінічними станами, та підтвердивши ефективність методу для системи підтримки клінічних рішень.

- Розроблено мультимодальну модель з інтеграцією результатів, яка досягла 71,5 % загальної точності класифікації. Найкращі результати отримано для класів Healthy (0,73) та Other (0,76), що показує здатність моделі добре розпізнавати стани з чіткими ознаками. Водночас для класу Ischemic показник виявився низьким ($F1 = 0,31$), що свідчить про складність у відмежуванні схожих клінічних станів і вказує на потребу вдосконалення простору ознак для підвищення точності розпізнавання подібних патологій.
- Проаналізовано дані та відібрано найбільш інформативні й слабо корельовані між собою ознаки, що зменшило ризик сильних залежностей та підвищило стабільність моделі. Вибрані ознаки (наприклад, Alpha_power, GM_WM_contrast, Spectral_entropy) продемонстрували низьку міжмодальну кореляцію та високу класифікаційну значущість. Це забезпечило зменшення надмірності, підвищення стійкості до шуму та точність на рівні 85% на тестовій вибірці.
- Удосконалено метод оцінювання ефективності аналізу мультимодальних даних, який показав суттєву перевагу моделі інтеграції ознак (Feature-level fusion) над інтеграцією модальних моделей (Model-level fusion) у багатокласовій класифікації клінічних станів. Модель Feature-level fusion досягла 96 % точності та F1-метрику на рівні 0,962, демонструючи високу точність класифікації розпізнаючи складні класи (Ischemic, Poststroke). Для порівняння, Model-level fusion забезпечила лише 71,5 % точності з $F1 = 0,31$ для класу Ischemic. Високі результати Feature-level fusion пояснюються тим, що на етапі попередньої обробки формується узгоджений набір ознак, що зменшує втрати інформації та підвищує здатність моделі узагальнювати дані. Крім того, використання Використання Apache Spark прискорило обробку в 1,35–1,6 рази порівняно з Hadoop, забезпечивши середній виграш понад 100 секунд на задачу. Отримані результати свідчать про ефективність розробленої технології для масштабованого медичного аналізу.

Результати дисертаційної роботи впроваджено у навчальному процесі Львівського національного університету ветеринарної медицини та біотехнологій імені С. З. Гжицького, Львівського державного університету безпеки життєдіяльності. Розроблену методологію створення та застосування інформаційних технологій підтримки прийняття рішень на основі багатовимірного аналізу мультимодальних даних було впроваджено у практичну діяльність низки підприємств: ПП «Квадро-Альянс», ТОВ «ХВАК ЮНІТ», ДП «Бумеранг-Комфорт», ТОВ «ЗБАРАЖ АГРО-ТРЕЙД», ТОВ «ІНТЕЛДІМ».

Ключові слова: інформація, методологія, інформаційна технологія, мультимодальні дані, багатовимірний простір, інформаційна система, прогнозування, моделювання, класифікація, модель, метод, підхід, аналіз даних, дослідження, обробка інформації.

ANNOTATION

Boyko N. I. Methodology of multidimensional analysis of multimodal data – Qualifying scientific work on the right of the manuscript.

Dissertation for the degree of Doctor of technical sciences for specialty 05.13.06 - information technology. – Cherkasy state technological university Ministry of Education and Science of Ukraine, Cherkasy, 2025.

Modern technologies are developing very rapidly, accompanied by a constant increase in the volume and heterogeneity of data. This is especially evident in medicine, where it is necessary to process vast amounts of information: from sensors and medical devices to imaging, physicians' notes, and numerical measurements. Such heterogeneous data are referred to as multimodal, and their effective processing requires new solutions.

Multimodal data often differ in format, accuracy, or acquisition time and may be incomplete or redundant. This creates difficulties in their integration and analysis. Moreover, real-world tasks demand the simultaneous consideration of multiple requirements – speed, accuracy, noise robustness, and computational efficiency. Classical methods that focus on a single criterion are ineffective in such cases.

A promising direction is to find a balance between these requirements. Models can be configured to maintain sufficient accuracy even in the presence of missing data or to operate faster without a significant loss of quality.

This study proposes approaches for constructing feature spaces for different data types, aligning information from heterogeneous sources, and adapting models to incomplete or noisy datasets.

The lack of comprehensive models, methods, and tools for medical decision support based on multidimensional analysis of multimodal data – capable of simultaneously accounting for data heterogeneity, temporal synchronization of modalities, and the multi-criteria nature of clinical decisions – along with the methodological fragmentation of existing approaches and their inability to be integrated into a unified system, form an urgent scientific and applied problem.

Special attention is devoted to the medical field, where accuracy and timeliness of decisions are critical. It was revealed that there is currently a lack of universal information technologies for decision support that can effectively combine data of various modalities – for instance, electrocardiograms (ECG), electroencephalograms (EEG), magnetic resonance imaging (MRI) – while considering both structural heterogeneity and temporal inconsistency of such data.

The information technology developed in this work addresses this problem through a formalized representation of medical data that accounts for their complexity and multilayered nature. It enables integration of information from multiple sources, ensures temporal synchronization, maintains analytical accuracy even in the presence of missing or redundant data, and improves both the quality and speed of clinical decision-making. This approach opens new opportunities for building advanced medical systems and enhancing their effectiveness in real practice.

The scientific novelty of this dissertation lies in solving a significant scientific and applied problem – the development of a methodology for multidimensional analysis of multimodal data. This has made it possible to design an information technology for automated processing, integration, and interpretation of heterogeneous information, thereby advancing this research area. The following new scientific results have been obtained:

For the first time:

- A concept for multimodal data analysis has been proposed, which involves extracting features for each modality and combining them into a unified multidimensional feature space. Unlike existing approaches, it ensures the creation of distinct feature sets from different modalities for developing classification methods of patient states, thereby increasing the informativeness of input data and the number of correctly classified cases.
- Principles of multidimensional analysis of multimodal data have been formulated, which lie in integrating heterogeneous features and modality-specific models within a single information technology. This enhances the

accuracy, reliability, and adaptability of classification systems under conditions of heterogeneity and incompleteness of medical data.

- A method for integrating modality data has been developed, based on combining data by specific features. Unlike existing methods, it builds observation points through adaptive, coordinated, and stepwise merging of data from different modalities into a single vector, followed by integration into a joint dataset for classifier model construction.
- A method for building a multimodal model has been proposed, which constructs modality-specific models and then integrates their outputs into a unified hierarchical structure for patient state classification. This improves the number of correctly classified cases compared to existing methods.

Further developed:

- A feature selection method adapted to the heterogeneity of multimodal data sources by forming a multidimensional feature space that accounts for correlation consistency, thereby enhancing the robustness of machine learning models.

Improved:

- A method for evaluating the effectiveness of multimodal data analysis through comparative experiments on accuracy, recall, F1-score, processing time, and model stability. This enables objective assessment of the advantages of the proposed technology, increases the number of correctly classified states, and ensures system adaptability to clinical conditions.

The *practical significance* of this study lies in the creation of an information technology for multidimensional analysis of multimodal data, which provides automated processing, integration, and interpretation of heterogeneous information. The application of the proposed technology improves the effectiveness of information systems and ensures reliability of results for applied tasks. The following applied results were obtained:

- The proposed concept of multimodal data analysis enables effective classification methods by constructing separate feature sets for each modality

and merging them into a unified multidimensional space. A harmonized feature space of dimension $X \in R^{1000 \times 24}$ was formed for 1000 patients, achieving an overall classification accuracy of 85%. This approach increases the informativeness of input data, reduces information loss during integration, and enhances the accuracy of patient state classification.

- The formulated principles of multidimensional analysis—integrating features of different modalities and combining modality-specific models—ensure system reliability under incomplete or redundant data and adaptability to structural variations in input information. The technology maintains stable results even with missing or variable features, confirming its applied value.
- The developed method of modality data integration enables adaptive, stepwise merging of information from different sources into a single feature space. This achieved 96% overall classification accuracy, with both macro- and weighted-average F1-scores of 0,96, ensuring balanced recognition of all classes, including complex clinical states, and demonstrating the method's effectiveness for clinical decision support systems.
- The developed multimodal model with integrated outputs achieved 71,5% overall accuracy. The best results were obtained for the Healthy (0,73) and Other (0,76) classes, showing strong recognition of states with distinct features. However, for the Ischemic class the F1-score was low (0,31), indicating difficulties in distinguishing similar clinical states and highlighting the need for improved feature space construction for better recognition of such pathologies.
- Data analysis identified the most informative and weakly correlated features, reducing redundancy and enhancing model stability. Selected features (e.g., Alpha_power, GM_WM_contrast, Spectral_entropy) demonstrated low intermodal correlation and high classification significance, resulting in reduced noise sensitivity and 85 % accuracy on the test set.
- The improved evaluation method of multimodal data analysis showed clear superiority of feature-level fusion over model-level fusion in multiclass

classification of clinical states. Feature-level fusion achieved 96 % accuracy with F1-scores of 0,962, ensuring high recognition even of complex classes (Ischemic, Poststroke). By contrast, model-level fusion yielded only 71,5 % accuracy with an F1-score of 0,31 for the Ischemic class. The high performance of feature-level fusion is explained by the construction of a harmonized feature set at the preprocessing stage, which minimizes information loss and improves generalization. Moreover, the use of Apache Spark accelerated processing by 1,35–1,6 times compared to Hadoop, saving over 100 seconds per task on average. These results demonstrate the effectiveness of the developed technology for scalable medical data analysis.

The results of the dissertation were implemented in the educational process of Stepan Gzhytskyi Lviv National University of Veterinary Medicine and Biotechnologies, and Lviv State University of Life Safety. The developed methodology was also implemented in the activities of enterprises: PE "Kvadro-Alliance", LLC "HVAC Unit", SE "Boomerang-Comfort", LLC "Zbarazh Agro-Trade", LLC "Inteldim".

Keywords: information, methodology, information technology, multimodal data, multidimensional space, information system, prediction, modelling, classification, model, method, approach, data analysis, research, information processing.

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у періодичних виданнях, включених до категорії «А» Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних *Web of Science Core Collection* та/або *Scopus*:

1. Boyko N. Application of mathematical models for improvement of “cloud” data processes organization. *Mathematical Modeling and Computing*. 2016. Vol. 3 No. 2. P. 111–119. (0,36 д.а.). DOI: <https://doi.org/10.23939/mmc2016.02.111>. ISSN 2312-9794 (індексована в наукометричній базі *Scopus*).
2. Boyko N. Advanced technologies of big data research in distributed information systems. *Radio Electronics, Computer Science, Control*. 2018. No. 4. P. 66–77. (0,45 д.а.). DOI: <https://doi.org/10.15588/1607-3274-2017-4-8>. ISSN 1607-3274 (індексована в наукометричній базі *Web of Science* (Q4 by Journal Citation Report)).
3. Boyko N. Models and algorithms for multimodal data processing. *WSEAS Transactions on Information Science and Applications*. 2023. Vol. 20. Art. No. 11. P. 87–97. (0,45 д.а.). DOI: <https://doi.org/10.37394/23209.2023.20.11>. ISSN 1790-0832 (індексована в наукометричній базі *Scopus* (Q4 by Scimago Journal & Country Rank)).
4. Boyko N. Data interpretation algorithm for adaptive methods of modeling and forecasting time series. *WSEAS Transactions on Mathematics*. 2023. Vol. 22. Art. No. 43. P. 359–372. (0,6 д.а.). DOI: <https://doi.org/10.37394/23206.2023.22.43>. ISSN 1109-2769 (індексована в наукометричній базі *Scopus* (Q2 by Scimago Journal & Country Rank)).
5. Boyko N. Application of adaptive and multiplicative models for analysis and forecasting of time series. *International Journal of Computing*. 2023. Vol. 22(2). P. 202–211. (0,4 д.а.). DOI: <https://doi.org/10.47839/ijc.22.2.3089>. ISSN 1727-6209 (індексована в наукометричній базі *Scopus* (Q4 by Scimago Journal & Country Rank)).
6. Vykylyuk Ya., Nevinskyi D., Boyko N. GeoCity – a new dynamic-spatial model of urban ecosystem. *J. Geogr. Inst. Cvijic*. 2023. Vol. 73(2). P. 187–203. (0,72 д.а.).

DOI: <https://doi.org/10.2298/IJGI2302187V>. ISSN 2683-3867 (індексована в наукометричній базі Scopus (Q3 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробленні алгоритмів обробки геопросторових даних з використанням методів просторової кластеризації, інтерполяції та часової сегментації та становить 0,35 д.а.

7. Boyko N., Lukash O. Methodology for estimating the cost of construction equipment based on the analysis of important characteristics using machine learning methods. *Journal of Engineering*. 2023. Vol. 2023. Art. No. 8833753. P. 27. (1,2 д.а.). DOI: <https://doi.org/10.1155/2023/8833753>. ISSN 2314-4904 (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає в аналізі значущості ознак (feature importance) з метою виявлення важливих ознак; створенні програмного прототипу для вводу технічних характеристик обладнання для їх автоматичної оцінки та становить 0,85 д.а.

8. Boyko N. I., Mykhailyshyn V. Yu. K-NN's nearest neighbors method for classifying text documents by their topics. *Radio Electronics, Computer Science, Control*. 2023. No. 3. P. 83–97. (0,63 д.а.). DOI: <https://doi.org/10.15588/1607-3274-2023-3-9>. ISSN 1607-3274 (індексована в наукометричній базі Web of Science (Q4 by Journal Citation Report)).

Особистий внесок автора полягає в адаптації методу найближчих сусідів (k-NN) для задач класифікації текстових документів за тематикою з урахуванням особливостей української та англійської мов та становить 0,5 д.а.

9. Boyko N. Models of binary classification of the semantic colouring of texts. *Innovaciencia*. 2023. Vol. 11(1). P. 1–23. (1 д.а.). DOI: <https://doi.org/10.15649/2346075X.3553>. E- ISSN 2346-075X (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).

10. Boyko N. The model of backpropagation algorithm realization in parallel mode for big data solutions. *Journal of the Balkan Tribological Association*. 2023. Vol. 29. Issue 5. P. 689–704. (0,68 д.а.). ISSN 1310-4772.

URL: <https://scibulcom.net/en/article/>

gfGV3mMkYgTAEk60Qczd (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).

11. Boyko N. Evaluating binary classification algorithms on data lakes using machine learning. *Revue d'Intelligence Artificielle*. 2023. Vol. 37(6). P. 1423–1434. (0,5 д.а.). DOI: <https://doi.org/10.18280/ria.370606>. ISSN 0992-499X (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
12. Vyklyuk Y., Semianiv I., Nevinskyi D., Todoriko L., Boyko N. Applying geospatial multi-agent system to model various aspects of tuberculosis transmission. *New Microbes and New Infections*. 2024. Vol. 59. P. 101417. DOI: <https://doi.org/10.1016/j.nmni.2024.101417>. (0,31 д.а.). ISSN 2052-2975 (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробленні інтеграції алгоритмів агентного моделювання з медико-статистичними даними, що дозволило врахувати поведінкові характеристики населення, мобільність і регіональні особливості, та становить 0,12 д.а.

13. Boyko N. Overview of multimodal data and its application to fake-news detection. *Jordanian Journal of Computers and Information Technology (JJCIT)*. 2024. Vol. 10. No. 03. P. 281–293. (0,54 д.а.). DOI: <https://doi.org/10.5455/jjcit.71-1709201313>. ISSN 2415-1076 (індексована в наукометричній базі Scopus (Q3 by Scimago Journal & Country Rank)).
14. Boyko N., Kovalchuk R. Detection of anomalies and Data Drift in a time-series dismissal prediction system. *Iraqi Journal for Computer Science and Mathematics*. 2024. Vol. 5. No. 3. P. 229–251. (1 д.а.). DOI: <https://doi.org/10.30880/ijcsm.2024.05.03.12>. ISSN 2788-7421. URL: <https://ijcsm.researchcommons.org/ijcsm/vol5/iss3/20> (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробці комбінованої аналітичної моделі, яка поєднує методи контролю стабільності розподілу з інструментами автоматичного виявлення аномалій, зокрема *Isolation Forest* і *Autoencoder*; визначенні критеріїв деградації моделей прогнозування при змінах у розподілах даних, та становить 0,65 д.а.

15. Boyko N., Kachmaryk V. Forecasting stochastic time series using reinforcement learning. *International Journal of Artificial Intelligence*. 2024. Vol. 22(2). P. 1–28. (1,23 д.а.). ISSN 0974-0635. URL: <http://www.ceser.in/ceserp/index.php/ijai/article/view/6991> (індексована в наукометричній базі *Scopus* (Q3 by *Scimago Journal & Country Rank*)).

Особистий внесок автора полягає у розробці методології прогнозування стохастичних часових рядів із використанням алгоритмів навчання з підкріпленням, з акцентом на адаптивність до нестабільних і непередбачуваних даних, та становить 0,8 д.а.

16. Boyko N. Study of multimodal identification algorithms using modern methods and tools of multivariate analysis. *Journal of Ecohumanism*. 2024. Vol. 3(5). P. 99–114. (0,68 д.а.). DOI: <https://doi.org/10.62754/joe.v3i5.3877>. ISSN 2752-6798 (індексована в наукометричній базі *Scopus*).
17. Boyko N. Data processing and optimization in the development of machine learning systems: Detailed requirements analysis, model architecture, and anti-data drift strategies. *Journal of Applied Data Sciences*. 2024. Vol. 5(3). P. 1110–1122. (0,54 д.а.). DOI: <https://doi.org/10.47738/jads.v5i3.278>. ISSN 2723-6471 (індексована в наукометричній базі *Scopus* (Q3 by *Scimago Journal & Country Rank*)).
18. Boyko N. The comprehensive model of using in-depth consolidated multimodal learning to study trading strategies in the securities market. *Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. ISDMCI 2022. Lecture Notes on Data Engineering and Communications Technologies*. 2023. Vol. 149. P. 126–147. (0,95 д.а.). Springer, Cham. DOI: https://doi.org/10.1007/978-3-031-16203-9_8. ISSN 2367-4512, 2367-4520

(індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).

19. Boyko N. I., Rabotiahov D. S. Modeling of the spread of tuberculosis by regions in Ukraine. *Radio Electronics, Computer Science, Control*. 2024. Vol. 4. P. 41–55. (0,63 д.а.). DOI: <https://doi.org/10.15588/1607-3274-2024-4-4>. ISSN 1607-3274 (індексована в наукометричній базі Web of Science (Q4 by Journal Citation Report)).

Особистий внесок автора полягає у розробці математичної моделі просторово-часового поширення туберкульозу, яка враховує регіональні особливості епідеміологічної ситуації в Україні, та становить 0,4 д.а.

Статті у наукових виданнях, включених до Переліку наукових фахових видань України:

20. Бойко Н. І. Методи та інструменти моделювання інформаційних процесів. *Вісник Національного університету “Львівська політехніка”. Інформаційні системи та мережі*. 2014. № 805. С. 361–368. (0,31 д.а.). ISSN: 2524-065X. URL: <https://science.lpnu.ua/uk/sisn/vsi-vypusky/vypusk-805-2014/metody-ta-instrumenty-modelyuvannya-informaciyh-procesiv>. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
21. Бойко Н. І. Багатовимірне подання даних для управління ІТ-проектами. *Вісник Національного університету “Львівська політехніка”. Інформаційні системи та мережі*. 2015. № 814. С. 387–395. (0,36 д.а.). ISSN: 2524-065X. URL: <https://ena.lpnu.ua/items/196e3ab0-679e-47b8-9900-5d36131482dd>. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
22. Бойко Н. І. Еволюція побудови архітектур інформаційних систем. Перспективи розвитку “хмарної” архітектури. *Вісник Національного університету “Львівська політехніка”. Інформаційні системи та мережі*. 2015. № 832. С. 348–368. (0,9 д.а.). ISSN: 2524-065X. URL: <chrome-extension://efaidnbmnnnibpcajpcgclcfndmkaj/>

- <https://science.lpnu.ua/sites/default/files/journal-paper/2018/jun/12945/24-348-367.pdf>. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
23. Бойко Н. І. Аналіз парадигми Semi-supervised learning для класифікації мультимодальних даних. *Науковий вісник Ужгородського університету. Серія: Математика і інформатика*. 2021. № 39(2). С. 125–144. (0,86 д.а.). DOI: [https://doi.org/10.24144/2616-7700.2021.39\(2\).125-144](https://doi.org/10.24144/2616-7700.2021.39(2).125-144). ISSN 2616-7700. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
 24. Бойко Н. І., Шаховська Н. Б., Михайлишин В. Ю. Розроблення методу класифікації користувачів за рівнем стресостійкості з використанням модифікованої автоасоціативної нейронної мережі. *Вісник Хмельницького національного університету*. 2021. № 6(303). С. 64–68. (0,18 д.а.). DOI: <https://doi.org/10.31891/2307-5732-2021-303-6-64-68>. ISSN 2307-5732. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
Особистий внесок автора полягає у розробці методу автоматичної класифікації користувачів за рівнем стресостійкості та становить 0,1 д.а.
 25. Boyko N. Research into machine learning algorithms for the construction of mathematical models of multimodal data classification problems. *Computational Problems of Electrical Engineering*. 2021. Vol. 11. No. 2. P. 1–11. (0,45 д.а.). DOI: <https://doi.org/10.23939/jcpee2021.02.001>. ISSN: 2224-0977. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
 26. Бойко Н. І., Качмарик В. Побудова моделей для прогнозування часових рядів застосовуючи мережі довгострокової пам'яті. *Науковий вісник Ужгородського університету. Серія: Математика і інформатика*. 2022. Т. 40. № 1. С. 131–147. (0,72 д.а.). DOI: [https://doi.org/10.24144/2616-7700.2022.40\(1\).109-125](https://doi.org/10.24144/2616-7700.2022.40(1).109-125). ISSN 2616-7700. *Фахове видання категорії Б*

(включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробленні моделей прогнозування часових рядів на основі архітектур LSTM (Long Short-Term Memory), орієнтованих на роботу з нестабільними та нелінійними даними, та становить 0,5 д.а.

27. Boyko N., Muzyka M. Methods of analysis of multimodal data to increase the accuracy of classification. *Applied Aspects of Information Technology*. 2022. Vol. 5. No. 2. P. 147–160. (0,59 д.а.). DOI: <https://doi.org/10.15276/aait.05.2022.11>. ISSN 2617-4316. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробленні підходів до інтегрованого аналізу мультимодальних даних (текстових, числових, візуальних, сенсорних) з метою підвищення точності класифікації в складних умовах та становить 0,4 д.а.

28. Бойко Н. І., Блажевський С. Г. Методика визначення структури моделі оптимальної складності. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2022. № 2(307). С. 7–13. (0,27 д.а.). DOI: <https://www.doi.org/10.31891/2307-5732-2022-307-2-7-13>. ISSN 2307-5732. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробленні методики формування моделей із балансом між складністю та точністю, орієнтованої на задачі машинного навчання та моделювання систем, та становить 0,17 д.а.

29. Boyko N., Petrovskiy O. Methods of classification of machine learning for construction of mathematical models on multimodal DATA. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2022. № 2(307). С. 25–32. (0,32 д.а.). DOI: <https://doi.org/10.31891/2307-5732-2022-307-2-25-32>. ISSN 2307-5732. *Фахове видання категорії Б* (включене до Index

Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у систематизації методів машинного навчання, що застосовуються для побудови математичних моделей на основі мультимодальних даних (текстових, числових, зображень, сенсорних сигналів), та становить 0,2 д.а.

30. Бойко Н. І., Газдюк К. П. Порівняння регресійних моделей за наявності викидів у наборі різнотипових даних. *Науковий вісник НЛТУ України*. 2023. Т. 33. № 2. С. 84–91. (0,32 д.а.). DOI: <https://doi.org/10.36930/40330212>. ISSN 5-7763-2435-1. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає в аналізі впливу викидів (аномальних значень) на точність різних регресійних моделей, побудованих на даних зі змішаними типами ознак (числові, категоріальні, порядкові), та становить 0,2 д.а.

31. Бойко Н., Левицький Б. Алгоритми тренування та оцінки моделей машинного навчання для структурованого набору даних. *Information Technology: Computer Science, Software Engineering and Cyber Security*. 2023. Вип. 3. С. 3–12. (0,4 д.а.). DOI: <https://doi.org/10.32782/IT/2023-3-1>. ISSN 2786-507X. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці та апробуванні алгоритмів навчання моделей машинного навчання на структурованих наборах даних із табличною формою представлення та становить 0,25 д.а.

32. Boyko N. I., Kurylo V. Medical data classification algorithm for oncology prediction. *Systems and Technologies*. 2023. Vol. 66(2). P. 21–31. (0,45 д.а.). DOI: <https://doi.org/10.32782/2521-6643-2023.2-66.3>. ISSN 2521-6643. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці підбору релевантних медичних ознак, включаючи біохімічні показники, історію хвороби, спадковість, демографічні дані та результати скринінгу, та становить 0,2 д.а.

33. Boyko N., Kovalchuk R. Data update algorithms in the Machine Learning System. *Computer Systems and Information Technologies*. 2023. Vol. 1. P. 6–13. (0,32 д.а.). DOI: <https://doi.org/10.31891/csit-2023-1-1>. ISSN 2710-0766. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці алгоритму оновлення навчальної вибірки без втрати продуктивності моделі з використанням механізмів буферизації, відбору важливих зразків і контролю якості та становить 0,2 д.а.

Статті у закордонних наукових виданнях:

34. Boyko N., Slobodian P. Application of machine learning methods for enhancing the quality of medical audio recordings: Comparative analysis of classical and modern approaches. *International Journal of Computer Applications*. 2025. Vol. 186, No. 69. P. 31–43. (0,55 д.а.). DOI: <https://doi.org/10.5120/ijca2025924502>. ISSN 0975-8887 (включене до Google Scholar).

Особистий внесок автора полягає у формалізації задачі підвищення якості медичних аудіозаписів шляхом застосування методів машинного навчання, виборі та обґрунтуванні критеріїв для порівняння класичних (спектральних фільтрів) та сучасних (нейромережевих автоенкодерів) підходів, а також у розробці методики оцінювання результатів за метриками SNR, PESQ та інтерпретованості для клінічного середовища, та становить 0,35 д.а.

Монографії (розділи у колективних монографіях):

35. Boyko N. Machine learning on data lake : Monograph. Beau Bassin. Mauritius : LAP Lambert Academic Publishing, 2018. 178 p. (8,09 д.а.). ISBN 13 978-613-9-83668-0.

36. Boyko N., Mochurad L. I. Modeling of discrete mathematics' problems : Monograph. Beau Bassin, Mauritius : LAP Lambert Academic Publishing, 2019. 195 p. (8,86 д.а.). ISBN 13 978-620-0-08172-8.

Особистий внесок автора полягає у дослідженні та моделюванні прикладних задач дискретної математики з акцентом на алгоритмічну реалізацію і практичне застосування в інформаційних технологіях та становить 7,5 д.а.

37. Mochurad L. I., Boyko N. I. Practical numerical methods: Algorithms and programs : Monograph. Lviv : Publishing House "Bona", 2019. 204 p. (9,27 д.а.). ISBN 978-617-7815-08-1.

Особистий внесок автора полягає у розробленні та описі чисельних методів, алгоритмів і програмних реалізацій для розв'язання прикладних задач у технічних та природничих науках та становить 7,5 д.а.

38. Mochurad L. I., Boyko N. I. Technologies of distributed systems and parallel computation : Monograph. Lviv : Publishing House "Bona", 2020. 261 p. (11,86 д.а.). ISBN 978-617-7815-25-8.

Особистий внесок автора полягає у дослідженні теоретичних засад, архітектурних рішень та практичних аспектів реалізації розподілених систем і технологій паралельних обчислень та становить 8 д.а.

39. Boyko N. Software approach to creating a layout with dynamic interfaces. *Theoretical aspects of modern engineering* : Collective monograph. International Science Group. Boston : Primedia eLaunch, 2020. P. 77–81. (0,23 д.а.). DOI: <https://doi.org/10.46299/ISG.2020.MONO.TECH.III>). ISBN 979-8-88722-619-4.

40. Boyko N. The use of cloud technologies at the open information systems. *На шляху до індустрії 4.0: Інформаційні технології, моделювання, штучний інтелект, автоматизація* : Колективна монографія. Одеса : Астропринт, 2021. С. 300–317. (0,77 д.а.). ISBN 978-966-927-702-2.

41. Boyko N. Creation of information systems using power algorithms. *Technical research and development* : Collective monograph. International Science Group. Boston : Primedia eLaunch, 2021. P. 80–85. (0,23 д.а.). DOI: <https://doi.org/10.46299/ISG.2021.MONO.TECH.I>). ISBN 978-1-63732-136-2.

42. Бойко Н. Застосування задачі багаторукового бандита для максимізації пропускної здатності мережі. *Scientific foundations of solving engineering tasks and problems* : Collective monograph. International Science Group. Boston : Primedia eLaunch, 2021. P. 292–300. (0,36 д.а.). DOI: <https://doi.org/10.46299/ISG.2021.MONO.TECH.II>). ISBN: 978-1-63848-664-0.
43. Бойко Н. І. Порівняльний аналіз моделей прогнозування часових рядів для мультимодальних даних. *Moderní aspekty vědy* : X. Díl mezinárodní kolektivní monografie. Česká republika : Mezinárodní Ekonomický Institut s.r.o., 2021. S. 187–205. (0,81 д.а.). URL: chrome-extension://efaidnbmnnnibpcajpcgclfindmkaj/http://expertise.odessa.ua/wp-content/uploads/2025/02/%D0%A5%D0%BE%D0%BC%D1%83%D1%82%D0%B5%D0%BD%D0%BA%D0%BE_%D0%9C%D0%BE%D1%82%D0%B8%D0%B3%D1%96%D0%BD_2021.pdf

Публікації, які засвідчують апробацію матеріалів дисертації:

44. Бойко Н. І. Технології обробки інформації у динамічних системах. *Сучасні проблеми прикладної математики та інформатики* : зб. наук. праць. Львів : Львів. нац. ун-т ім. І. Франка, 2016. С. 37–40. (0,14 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcgclfindmkaj/http://apamcs.lnu.edu.ua/tmp/APAMCS-2016.pdf>
45. Boyko N. A look trough methods of intellectual data analysis and their applying in informational systems. *IEEE 11th International Scientific and Technical Conference on Computer Science and Information Technologies (CSIT)*. 2016. P. 183–185). (0,09 д.а.). DOI: <https://doi.org/10.1109/STC-CSIT.2016.7589901>. URL: <https://ieeexplore.ieee.org/document/7589901> (індексована в наукометричній базі Scopus).
46. Boyko N., Kryvenchuk Yu. Application of cloud services for processing of information flows. *Problems of Infocommunications. Science and Technology: International Scientific-Practical Conference (PIC S&T`2018)*, (Kharkiv, Ukraine, October 9–12). 2018. P. 243–247. (0,18 д.а.). ISBN: CFP18PIA-POD 978-1-5386-

6612-8. URL: <https://easychair.org/publications/preprint/vSDr> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у розробленні методичного підходу до застосування хмарних сервісів для обробки інформаційних потоків у розподілених системах та становить 0,08 д.а.

47. Boyko N., Shakhovska N. Prospects for using cloud data warehouses in information systems. *IEEE 13th International Scientific and Technical Conference on Computer Science and Information Technologies (CSIT)*, (September). 2018. Vol. 2. P. 136–139. (0,18 д.а.). DOI: <https://doi.org/10.1109/STC-CSIT.2018.8526745>.

URL: <https://www.sciencedirect.com/science/article/pii/S1877050919317478?via%3Dihub> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні можливостей використання технологій обробки Big Data в розподілених інформаційних системах з урахуванням специфіки хмарних сховищ даних та становить 0,08 д.а.

48. Kunanets N., Vasiuta O., Boiko N. Advanced technologies of Big Data research in distributed information systems. *IEEE 14th International Scientific and Technical Conference on Computer Science and Information Technologies (CSIT)*, (Lviv, Ukraine, September 17–20). 2019. P. 71–76. (0,23 д.а.). DOI: <https://doi.org/10.1109/STC-CSIT.2019.8929756>. URL: <https://ieeexplore.ieee.org/document/8929756> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні та узагальненні сучасних технологій обробки Big Data в умовах розподілених інформаційних систем та становить 0,11 д.а.

49. Shakhovska N., Boyko N., Zasoba Y., Benova E. Big data processing technologies in distributed information systems. *Procedia Computer Science: 10th International conference on emerging ubiquitous systems and pervasive networks (EUSPN-2019)*, 2019. P. 561–566. (0,23 д.а.).

DOI: <https://doi.org/10.1016/j.procs.2019.11.047>. URL: <https://dl.acm.org/doi/10.1016/j.procs.2019.11.047> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні принципів організації розподіленої обробки великих даних (Big Data) та адаптації сучасних технологій до потреб інформаційних систем з високими вимогами до продуктивності та масштабованості та становить 0,18 д.а.

50. Boyko N., Tkachuk N. Processing of medical different types of data using Hadoop and Java MapReduce. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)*, (Växjö, Sweden, November 19–21). 2020. P. 405–414. (0,41 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcgclfindmkaj/https://ceur-ws.org/Vol-2753/short15.pdf> (індексована в наукометричній базі Scopus)

Особистий внесок автора полягає у дослідженні та реалізації підходів до обробки різномірних медичних даних із використанням технологій Hadoop та моделі програмування MapReduce на мові Java та становить 0,35 д.а.

51. Boyko N., Dosiak I. Analysis of machine learning algorithms for classification and prediction of heart disease. *The 4th International Conference on Informatics & Data-Driven Medicine (IDDM 2021)*, (Valencia, Spain, November 19–21). 2021. P. 233–249. (0,72 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcgclfindmkaj/https://ceur-ws.org/Vol-3038/paper15.pdf> (індексована в наукометричній базі Scopus)

Особистий внесок автора полягає у проведенні порівняльного аналізу алгоритмів машинного навчання для задач класифікації та прогнозування серцево-судинних захворювань та становить 0,55 д.а.

52. Boyko N., Hrynyshyn A. Using recurrent neural network to noise absorption from audio files. *Proceedings of the 2nd International Workshop on Computational & Information Technologies for Risk-Informed Systems (CITRisk 2021) co-located with XXI International Conference on Information Technologies in Education and Management (ITEM 2021)*, (Kherson, Ukraine, September 16–17). 2021. P. 227–240. (0,59 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcgclfindmkaj/https://ceur-ws.org/Vol-3038/paper15.pdf>

extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-ws.org/Vol-3101/Paper15.pdf (індексована в наукометричній базі Scopus)

Особистий внесок автора полягає у дослідженні можливостей використання рекурентних нейронних мереж (RNN) для приглушення шумів в аудіофайлах у задачах попередньої обробки звукових сигналів та становить 0,4 д.а. Автор провела аналіз джерел і типів шумів, характерних для акустичних даних, зокрема у сфері телекомунікацій та медичної акустики, та обґрунтувала доцільність застосування RNN для моделювання тимчасових залежностей у звукових сигналах.

53. Boyko N., Muzyka M. Analysis of multimodal data for classification problems by using methods of machine learning. *IEEE 8th International Conference on Problems of Infocommunications, Science and Technology (PIC S&T)*. 2021. P. 525–534. (0,41 д.а.). DOI: <https://doi.org/10.1109/PICST54195.2021.9772203>. URL: <https://ieeexplore.ieee.org/document/9772203> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні методів машинного навчання для аналізу мультимодальних даних у задачах класифікації та становить 0,2 д.а.

54. Boyko N., Mykhailyshyn V. Model of finding associative rules in inhomogeneous data of semantic networks. *Proceedings of The Fifth International Workshop on Computer Modeling and Intelligent Systems (CMIS-2022)*, (Zaporizhzhia, Ukraine, May 12). 2022. P. 58–67. (0,41 д.а.). DOI: <https://doi.org/10.32782/cmisi/3137-5>. URL: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-ws.org/Vol-3137/paper11.pdf> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у розробленні моделі виявлення асоціативних правил у неоднорідних даних, що представлені у вигляді семантичних мереж, та становить 0,2 д.а.

55. Boyko N., Mykhailyshyn V. Methods of searching for associative rules for inhomogeneous data in semantic networks. *Proceedings of the 3rd International Workshop on Intelligent Information Technologies & Systems of Information*

Security, (Khmelnyskyi, Ukraine, March 23–25). 2022. P. 54–71. (0,77 д. а.).
 URL: [chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-
 ws.org/Vol-3156/paper1.pdf](chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-

 ws.org/Vol-3156/paper1.pdf) (індексована в наукометричній базі *Scopus*).

Особистий внесок автора полягає у дослідженні та вдосконаленні методів пошуку асоціативних правил у неоднорідних даних, що представлені у формі семантичних мереж, та становить 0,6 д.а.

Публікації, які додатково відображають наукові результати дисертації:

56. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Твій персональний помічник» / Бойко Н. І., Гетьман С. Л. 2022. № 112320. URL: <https://sis.ukrpatent.org/uk/search/detail/1695539/>
57. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Image Translate» / Бойко Н. І., Куба М. О. 2022. № 112319. URL: <https://sis.ukrpatent.org/uk/search/detail/1695540/>
58. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Інтелектуальна система виявлення стресу на основі машинного навчання в режимі реального часу» / Бойко Н. І., Яцків М. В. 2022. № 111792. URL: <https://sis.ukrpatent.org/uk/search/detail/1695561/>
59. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Система прийняття рішень для навігації в середовищах з неповною інформацією» / Бойко Н. І. 2023. № 117954. URL: <https://sis.ukrpatent.org/uk/search/detail/1708480/>
60. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Алгоритм оптимізації гіперпараметрів при тренуванні моделей машинного навчання для покращення продуктивності їх застосування на невідомих даних» / Бойко Н. І. 2024. № 126272. URL: <https://sis.nipo.gov.ua/uk/search/detail/1810806/>

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ ТА СКОРОЧЕНЬ.....	31
ВСТУП.....	32
РОЗДІЛ 1. СУЧАСНИЙ СТАН РОЗВИТКУ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ БАГАТОВИМІРНОГО АНАЛІЗУ МУЛЬТИМОДАЛЬНИХ ДАНИХ	43
1.1. Визначення базових понять концептуального та багатовимірного аналізу даних. Нормативно-правова основа	44
1.2. Наукові дослідження сучасних підходів до оптимізації методів концептуального та багатовимірного аналізу даних	56
1.3. Система концептуального аналізу даних на основі багатовимірних формальних контекстів. Основні поняття	63
1.4. Мультиmodalність як методологічна перспектива дослідження інтерації в інформаційній технології	67
1.5. Порівняльна характеристика багатовимірних і мультиmodalних даних у контексті інформаційної структури	73
1.6. Аналіз програмного забезпечення для обробки мультиmodalних даних	78
1.7. Аналіз існуючих підходів та інформаційних технологій обробки мультиmodalних медичних даних	82
1.8. Формулювання науково-прикладної проблеми дослідження.....	95
Висновки до розділу 1.....	97
РОЗДІЛ 2. ТЕОРЕТИЧНІ ОСНОВИ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ БАГАТОВИМІРНОГО АНАЛІЗУ МУЛЬТИМОДАЛЬНИХ МЕДИЧНИХ ДАНИХ.....	100
2.1. Формалізація інформаційної технології багатовимірного аналізу мультиmodalних медичних даних.....	100
2.2. Формування дослідницької гіпотези як основи методології багатовимірного аналізу мультиmodalних медичних даних	108

2.3. Концепція багатовимірного аналізу мультимодальних медичних даних	122
2.4. Принципи інформаційної технології багатовимірного аналізу мультимодальних медичних даних	134
2.5. Методологія інформаційної технології багатовимірного аналізу мультимодальних медичних даних	135
Висновки до розділу 2.....	145
РОЗДІЛ 3. ПОБУДОВА УНІФІКОВАНОГО ОЗНАКОВОГО ПРОСТОРУ ДЛЯ МУЛЬТИМОДАЛЬНИХ МЕДИЧНИХ ДАНИХ	147
3.1. Виділення ознак із сигналів на основі мел-частотних кепстральних коефіцієнтів	147
3.2. Виділення ознак із сигналів прихованими марковськими моделями	152
3.3. Підходи до класифікації сигналів у мультимодальних системах.....	155
3.4. Виділення ознак із цифрових зображень	158
3.5. Формування табличного представлення ознак із мультимодальних медичних даних.....	164
Висновки до розділу 3.....	172
РОЗДІЛ 4. МОДЕЛІ РЕПРЕЗЕНТАЦІЇ ТА ЗЛИТТЯ МУЛЬТИМОДАЛЬНИХ ДАНИХ	175
4.1. Концептуальний аналіз даних для багатовимірної обробки мультимодальної медичної інформації	176
4.2. Застосування багатовимірного концептуального аналізу до обробки мультимодальних медичних даних	186
4.3. Багатокритеріальний підхід до формування простору ознак мультимодальних даних	194
Висновки до розділу 4.....	204
РОЗДІЛ 5. МЕТОДИ УНІФІКАЦІЇ ТА ІНТЕГРАЦІЇ МУЛЬТИМОДАЛЬНИХ МЕДИЧНИХ ДАНИХ У ВЕКТОРАХ ОЗНАК ТА РІШЕНЬ	206

5.1. Методи виявлення структурних відповідностей мультимодальних даних у багатовимірному просторі	207
5.2. Методи інтеграції модальностей та побудова уніфікованого простору ознак мультимодальних медичних даних	222
5.3. Методи побудови уніфікованих просторів ознак для комплексного представлення мультимодальних медичних даних	235
5.4. Формалізація та трансформація простору мультимодальних медичних даних у динамічних і статичних інформаційних системах	258
Висновки до розділу 5.....	267
РОЗДІЛ 6. РОЗРОБЛЕННЯ АРХІТЕКТУРИ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ТА АПРОБАЦІЯ СФОРМУЛЬОВАНИХ ГІПОТЕЗ	269
6.1. Розроблення архітектурного вирішення системи	270
6.2. Методика побудови класифікаційних моделей на основі уніфікованого простору ознак.....	286
6.3. Методика побудови класифікаційних моделей на основі метарішень у мультимодальних медичних системах	305
6.4. Застосування розподілених обчислень та оптимізаційних алгоритмів у роботі з великими медичними даними.....	322
Висновки до розділу 6.....	333
ВИСНОВКИ.....	336
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	339
ДОДАТОК А. АКТИ ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЙНОЇ РОБОТИ	378
ДОДАТОК Б. СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ.....	385
ДОДАТОК В. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ	394

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ ТА СКОРОЧЕНЬ

IT	Інформаційні технології (англ. Information technology)
IS	Інформаційна система (англ. Information system)
CDA	Концептуальний аналіз даних (англ. Concept Data Analysis)
PCA	Головні компоненти (англ. principal component analysis)
ReLU	Передавальна функція (англ. rectified linear unit)
MFCA	Система концептуального аналізу даних на основі багатомірних формальних контекстів (англ. Multidimensional Formal Context Analysis)
FCA	Формальна теорія концептів (англ. Formal Concept Analysis)
MCO	Багатокритеріальне покращення (англ. Multi-Criteria Optimization)
ZSL	Здатність системи виконувати все з нуля (англ. Zero shot learning)
DDBS	Розподілена база даних (англ. Distributed database)
HDFS	Розподілена файлова система (англ. Hadoop Distributed File System)
МН	Машинне навчання (англ. Machine learning)
MFCC	Мел-частотні кепстральні коефіцієнти (англ. Mel-frequency cepstral coefficients)
HMM	Прихована марковська модель (англ. Hidden Markov Model)
LDA	Лінійний дискримінаційний аналіз (англ. Linear discrimination analysis)
SVM	Опорні векторні машини (англ. Support Vector Machine)
IDWT	Зворотне дискретне вейвлет-перетворення (англ. Inverse Discrete Wavelet Transform)
CCA	Канонічний кореляційний аналіз (англ. Canonical Correlation Analysis)
CNN	Згортова нейронна мережа (англ. Convolutional Neural Network)
RNN	Рекурентна нейронна мережа (англ. Recurrent Neural Network)
LSTM	Довга короткочасна пам'ять (англ. Long short-term memory)

ВСТУП

Актуальність теми. Стрімкий розвиток технологій та експоненційне зростання обсягів даних створюють нові виклики для їх ефективної обробки, аналізу та підтримки прийняття рішень. Сучасні інформаційні системи працюють із різноманітними типами даних – сенсорними сигналами, медичними зображеннями, текстовими описами, числовими масивами та потоковою інформацією в режимі реального часу. Така різноманітність джерел визначає об'єкт дослідження в багатьох галузях, зокрема в медицині, де особливо важливими є точність і швидкість обробки. Це зумовлює потребу в інтеграції різноманітних джерел у єдине аналітичне середовище. У цьому контексті ключового значення набуває концепція мультимодальних даних, що передбачає їх комплексну обробку для формування цілісної та достовірної картини об'єкта дослідження.

Мультимодальні дані створюють нові можливості для підвищення якості аналітичних висновків, що є критично важливим для ефективного функціонування медичних інформаційних систем та виконання міждисциплінарних досліджень. Це зумовлює необхідність розробки інформаційних технологій, здатних забезпечувати повноцінний багатовимірний аналіз таких даних. Використання комплексного підходу дозволяє досягати високої точності, адаптивності та відповідності результатів під час обробки інформації з різноманітних джерел.

Ефективний аналіз мультимодальних даних вимагає не тільки потужних технічних засобів, а й методологічно обґрунтованих підходів. Саме тут багатокритеріальне вдосконалення можна розглядати як формування теоретичної основи, на основі якої інноваційні інформаційні технології можуть бути побудовані для відповіді на сучасні виклики шляхом розробки нових моделей та інструментів, здатних працювати з високим навантаженням, забезпечуючи при цьому надійність і гнучкість рішень. Це відкриває шлях до реалізації нового покоління інформаційних систем, які ефективно працюють у складних умовах, що вимагає не лише технічної модернізації, але, що ще

важливіше, науково обґрунтованого перегляду підходів до обробки та аналізу даних. У цьому відношенні вдосконалення за багатьма критеріями займає місце стратегічно важливого напрямку, який пропонує компроміси продуктивності як з точністю аналізу, так і з адаптивністю системи.

У контексті реалізації такого підходу особливої актуальності набуває проблема масштабованості інформаційних технологій, яка у процесі обробки мультимодальних наборів даних вважається одним із основних викликів сучасної науки про дані. З огляду на наявні складнощі, актуальним є використання методів багатовимірного аналізу з урахуванням вдосконалення методів обробки даних. Такий підхід дозволяє зосередитися на найважливіших аспектах обробки даних, знижуючи надмірне навантаження на систему й підвищуючи загальну ефективність.

У свою чергу, міждисциплінарний характер цього дослідження відкриває нові можливості для інтеграції сучасних інформаційних технологій, включаючи штучний інтелект, машинне навчання та обробку великих даних. Зокрема, методи глибинного навчання, які використовуються у візуальній діагностиці, мовному аналізі медичних записів чи сенсорному моніторингу, потребують значних обчислювальних потужностей. Принципи багатокритеріального вдосконалення сприяють досягненню балансу між точністю прогнозування, швидкістю обробки інформації та економією ресурсів, що є критично важливим для систем, що забезпечують безперервний моніторинг стану пацієнтів.

Таким чином, подальший розвиток інформаційних технологій, орієнтованих на мультимодальну обробку даних у медичній галузі, фактично обумовлює **протиріччя** між зростаючими вимогами до точності, швидкості та гнучкості систем, що виконують такі аналізи, з обмеженими можливостями традиційних засобів їх реалізації. Це потребує нових методологічних підходів, які б не лише забезпечили інтеграцію з різних джерел, але й запропонували цілісну підтримку на різних рівнях прийняття рішень у сферах медичних послуг

У результаті виникає необхідність розроблення нових методологічних засад, які дозволять інтегрувати різноманітні дані та забезпечувати комплексну,

масштабовану підтримку прийняття рішень у сфері охорони здоров'я. Отже, актуальною **науково-прикладною проблемою** є протиріччя між обмеженими можливостями традиційних моделей і методів аналізу, з одного боку, та зростаючими вимогами клінічної практики, дослідників і медичних установ до точності, оперативності й гнучкості сучасних інформаційних технологій – з іншого.

Зв'язок роботи з науковими програмами, планами та темами. Наведені в дисертації дослідження проводились в рамках держбюджетних науково-дослідних робіт Національного університету «Львівська політехніка»: «Інформаційні технології формування психофізичного портрета в умовах стресових ситуацій» (номер державної реєстрації № 0120U102194); «Технології та системи оброблення і зберігання персоналізованих військових медичних даних» (номер державної реєстрації № 0121U107809); «Розроблення інформаційної технології оцінювання та прогнозування надійності програмного забезпечення методами машинного навчання» (номер державної реєстрації № 0121U109527); «Методи та засоби штучного інтелекту для запобігання поширенню туберкульозу у військовий час» (номер державної реєстрації №0124U000660) та гопдоговірних тем «Машинне навчання для вивчення біомаркерів старіння людини для збільшення тривалості життя» (№ 896-2022); «Розроблення методу визначення важливих характеристик з існуючих баз даних» (№ 896-2022); Проєкт Національного фонду досліджень України «Методи та засоби дослідження маркерів старіння та їх впливу на постковідні ефекти для подовження працездатного періоду» (номер державної реєстрації № 2021.01/0103). У процесі виконання наведених науково-дослідних робіт автором були розроблені методи комплексного аналізу мультимодальних даних з використанням принципів багатовимірної аналізу та машинного навчання. Зокрема, були створені методологічні підходи до побудови психофізичних портретів в умовах стресу, моделі персоналізованої обробки медичних даних, а також моделі оцінювання надійності програмного забезпечення з урахуванням динамічних змін його параметрів. У межах досліджень, присвячених вивченню

процесів старіння, автором були реалізовані методи виявлення біомаркерів на основі навчання моделей на великих обсягах медичних даних, що дозволяє здійснювати прогнозування постковідних ефектів і розробляти підходи до продовження працездатного віку людини.

Мета дисертаційної роботи – підвищення якості аналізу мультимодальних даних шляхом розроблення та впровадження інформаційної технології, заснованої на новій методології багатовимірного аналізу.

Для досягнення цієї мети поставлено такі **завдання**:

1. Запропонувати концепцію аналізу мультимодальних даних, що передбачає інтеграцію, узгодження та спільну обробку інформації з різнорідних джерел.
2. Сформулювати принципи багатовимірного аналізу мультимодальних даних, які забезпечують поєднання різних ознак та модальних моделей з метою підвищення точності, надійності й гнучкості класифікаційних систем у випадку неповних чи неоднорідних медичних даних.
3. Розробити метод інтеграції даних з різних модальностей, що дозволяє узгоджувати та поєднувати інформацію в єдиному аналітичному просторі.
4. Запропонувати метод побудови мультимодальної моделі, яка забезпечує узгоджену інтеграцію гетерогенних даних у єдиний вектор ознак.
5. Розвинути метод вибору інформативних ознак, адаптований до умов гетерогенності джерел мультимодальних даних.
6. Удосконалити метод оцінювання ефективності аналізу мультимодальних даних, орієнтований на комплексне врахування точності, продуктивності та стійкості результатів.

Об'єктом дослідження є процеси аналізу мультимодальних даних.

Предметом дослідження є моделі, методи та засоби багатовимірного аналізу мультимодальних даних.

Методи дослідження. Методологічна база дисертаційної роботи ґрунтується на положеннях загальної теорії систем та системного аналізу,

зокрема принципах ієрархічності, декомпозиції та структурного моделювання. У процесі розроблення інформаційної технології було використано моделі зберігання й передачі мультимодальних даних, а також методи машинного навчання для обробки інформації різних модальностей. Для узгодження та синхронізації даних застосовано інструменти математичної статистики та теорії множин.

Крім того, робота спирається на принципи побудови баз знань, методи логічного висновку та семантичного представлення даних. У програмній реалізації інформаційної технології використано моделі згорткових і рекурентних нейронних мереж, методи аналізу часових і потокових даних, а також технології обробки мультимодальних структур у розподілених обчислювальних середовищах.

Наукова новизна полягає у вирішенні важливої науково-прикладної проблеми розроблення методології багатовимірного аналізу мультимодальних даних, що дало змогу розробити інформаційну технологію для автоматизованої обробки, інтеграції та інтерпретації різнорідної інформації й забезпечило подальший розвиток цього наукового напрямку. Отримано такі нові наукові результати:

вперше:

- запропонована концепція аналізу мультимодальних даних, яка полягає у виділенні ознак для кожної модальності та їх об'єднанні в єдиний багатовимірний простір ознак, яка, на відміну від існуючих, забезпечує формування окремих множин ознак із різних модальностей для розробки методів класифікації станів пацієнта, що дозволяє підвищити інформативність масивів вхідних даних та збільшити кількість правильно класифікованих станів;
- сформульовано принципи багатовимірного аналізу мультимодальних даних, які полягають в інтеграції різнорідних ознак та модальних моделей у єдиній інформаційній технології, що забезпечує підвищення

точності, надійності та адаптивності класифікаційних систем в умовах гетерогенності та неповноти медичних даних.

- розроблено метод інтеграції модальних даних, який полягає у поєднанні цих даних за певними ознаками, що, на відміну від існуючих методів, будує точки спостереження шляхом адаптивного, погодженого та поетапного об'єднання даних із різних модальностей в єдиний вектор та поєднання цих векторів, дозволяє створити із окремих точок спостереження за пацієнтом спільний масив вхідних даних та формувати модель-класифікатор;
- розроблено метод побудови мультимодальної моделі, який полягає у побудові моделей окремих модальностей та використанні результатів моделювання для класифікації станів пацієнта, який, на відміну від існуючих, інтегрує результати моделювання в єдину ієрархічну структуру, що дозволяє підвищити кількість правильно класифікованих станів пацієнта.

Одержали подальший розвиток:

- метод вибору інформативних ознак, адаптований до гетерогенності джерел мультимодальних даних, завдяки формуванню багатовимірного ознакового простору з урахуванням їх кореляційної узгодженості, що дозволяє підвищити стійкість моделей машинного навчання.

Удосконалено:

- метод оцінювання ефективності аналізу мультимодальних даних, який базується на комплексному порівнянні результатів експериментів за точністю, повнотою, F1-метрикою, часом обробки та стабільністю роботи моделей, що дає змогу об'єктивно визначати переваги запропонованої технології, збільшувати кількість правильно класифікованих станів та забезпечувати адаптацію системи до клінічних умов.

Практична значущість дослідження одержаних результатів полягає у створенні інформаційної технології багатовимірного аналізу мультимодальних

даних, яка забезпечує автоматизовану обробку, інтеграцію та інтерпретацію різномірної інформації. Застосування розробленої технології підвищує ефективність функціонування інформаційних систем і сприяє достовірності отриманих результатів для вирішення прикладних завдань, що дало змогу сформулювати такі прикладні результати дослідження:

- Запропонована концепція аналізу мультимодальних даних дозволяє реалізувати ефективні методи класифікації шляхом формування окремих наборів ознак для кожної модальності та їх об'єднання у єдиний багатовимірний простір. Сформовано узгоджений простір ознак розмірністю $X \in R^{1000 \times 24}$ для 1000 пацієнтів, який забезпечив загальну точність класифікації на рівні 85 %. Такий підхід підвищує інформативність вхідних даних, зменшує втрати релевантної інформації при інтеграції, та дозволяє покращити точність класифікації станів пацієнтів.
- Сформульовано принципи багатовимірного аналізу мультимодальних даних, зокрема інтеграції ознак різних модальностей та об'єднання моделей, побудованих за окремими модальностями. Застосування цих принципів забезпечує надійність функціонування інформаційної технології в умовах неповних чи надлишкових даних, а також адаптацію системи до змін у структурі вхідної інформації. Розроблена технологія зберігає стабільність результатів навіть за наявності пропусків та варіацій у наборі ознак, що підтверджує її прикладну цінність для прикладних задач обробки даних.
- Розроблено метод інтеграції модальних даних, що забезпечує адаптивне поетапне об'єднання інформації з різних джерел у єдиний ознаковий простір. Це дозволило досягти 96 % загальної точності класифікації; значення макро- та зважених середніх метрик дорівнюють 0,96, забезпечивши збалансоване розпізнавання всіх класів, включно зі складними клінічними станами, підтвердивши ефективність методу для системи підтримки клінічних рішень.

- Розроблено мультимодальну модель з інтеграцією результатів, яка досягла 71,5 % загальної точності класифікації. Найкращі результати отримано для класів Healthy (0,73) та Other (0,76), що показує здатність моделі добре розпізнавати стани з чіткими ознаками. Водночас для класу Ischemic показник виявився низьким ($F1 = 0,31$), що свідчить про складність у відмежуванні схожих клінічних станів і вказує на потребу вдосконалення простору ознак для підвищення точності розпізнавання подібних патологій.
- Проаналізовано дані та відібрано найбільш інформативні й слабо корельовані між собою ознаки, що зменшило ризик сильних залежностей та підвищило стабільність моделі. Вибрані ознаки (наприклад, Alpha_power, GM_WM_contrast, Spectral_entropy) продемонстрували низьку міжмодальну кореляцію та високу класифікаційну значущість. Це забезпечило зменшення надмірності, підвищення стійкості до шуму та точність на рівні 85 % на тестовій вибірці.
- Удосконалено метод оцінювання ефективності аналізу мультимодальних даних, який показав суттєву перевагу моделі інтеграції ознак (Feature-level fusion) над інтеграцією модальних моделей (Model-level fusion) у багатокласовій класифікації клінічних станів. Модель Feature-level fusion досягла 96 % точності та F1-метрику на рівні 0,962, демонструючи високу точність класифікації при розпізнаванні складних класів (Ischemic, Poststroke). Для порівняння, Model-level fusion забезпечила лише 71,5 % точності з $F1 = 0,31$ для класу Ischemic. Високі результати Feature-level fusion пояснюються тим, що на етапі попередньої обробки формується узгоджений набір ознак, що зменшує втрати інформації та підвищує здатність моделі узагальнювати дані. Крім того, використання Apache Spark прискорило обробку в 1,35–1,6 разу порівняно з Hadoop, забезпечивши середній виграш понад 100 секунд на задачу. Отримані результати свідчать про ефективність розробленої технології для масштабованого медичного аналізу.

Використання результатів дослідження. Результати дисертаційної роботи впроваджено у навчальний процес Львівського національного університету ветеринарної медицини та біотехнологій імені С. З. Ґжицького (акт впровадження від 30.04.2025), Львівського державного університету безпеки життєдіяльності (акт впровадження від 01.05.2025). Розроблену методологію створення та застосування інформаційних технологій підтримки прийняття рішень на основі багатовимірної аналізи мультимодальних даних було впроваджено у практичну діяльність низки підприємств (додаток А): ПП «Квадро-Альянс» (акт впровадження від 29.04.2025), ТОВ «ХВАК ЮНІТ» (акт впровадження від 29.04.2025), ДП «Бумеранг-Комфорт» (акт впровадження від 01.05.2025), ТОВ «ЗБАРАЖ АГРО-ТРЕЙД» (акт впровадження від 28.04.2025), ТОВ «ІНТЕЛДІМ» (акт впровадження від 29.04.2025).

Особистий внесок здобувача. Усі наукові результати, подані в дисертації, є особистим досягненням здобувача. У спільних публікаціях автору належать такі результати: розроблено алгоритми обробки геопросторових та різнорідних медичних даних із застосуванням методів просторової кластеризації, інтерполяції, часової сегментації, а також технологій Hadoop і MapReduce [6, 50]; адаптовано метод k-NN для класифікації текстових документів з урахуванням особливостей української та англійської мов [8]; проведено аналіз значущості ознак та підбір релевантних медичних характеристик [32]; розроблено комбіновані аналітичні моделі та моделі прогнозування часових рядів на основі LSTM і алгоритмів навчання з підкріпленням, з урахуванням впливу аномальних значень [15, 26, 30]; створено математичну модель просторово-часового поширення туберкульозу [19] та метод автоматичної класифікації користувачів за рівнем стресостійкості [24]; запропоновано підходи до інтегрованого аналізу мультимодальних даних для підвищення точності класифікації в складних умовах [27], а також методики формування моделей із балансом між складністю та точністю [28]; систематизовано методи машинного навчання для роботи з мультимодальними даними різних типів [29]; проведено порівняльний аналіз алгоритмів для прогнозування серцево-судинних захворювань [51]; розроблено

та апробовано алгоритми оновлення навчальних вибірок і навчання моделей на табличних даних [31, 33]; запропоновано концепцію використання хмарних сервісів у складних інформаційних системах та проведено огляд технологій Big Data у розподілених середовищах [44, 46, 47, 48, 49]; розроблено моделі та вдосконалено методи пошуку асоціативних правил у неоднорідних даних, представлених у вигляді семантичних мереж [54, 55]; досліджено застосування рекурентних нейронних мереж (RNN) для приглушення шумів в аудіофайлах, зокрема для медичної акустики [52].

Апробація результатів дисертації. Основні теоретичні та практичні результати дисертаційної роботи були представлені та обговорені на науково-практичних конференціях та семінарах: International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT), Lviv, Ukraine, 2016, 2018, 2019; International Scientific-Practical Conference Problems of Infocommunications, Science and Technology (PIC S&T), Kharkiv, Ukraine, 2018; 10th International Conference on Emerging Ubiquitous Systems and Pervasive Networks (EUSPN), 2019; International Conference on Informatics & Data-Driven Medicine (IDDM), Växjö, Sweden, 2020, 2021; International Workshop on Computational & Information Technologies for Risk-Informed Systems (CITRisk 2021), co-located with XXI International Conference on Information Technologies in Education and Management (ITEM 2021), Kherson, Ukraine, 2021; International Scientific-Practical Conference Problems of Infocommunications, Science and Technology (PIC S&T), Kyiv, Ukraine, 2021; International Workshop on Computer Modeling and Intelligent Systems (CMIS), Zaporizhzhia, Ukraine, 2022; International Workshop on Intelligent Information Technologies & Systems of Information Security (IIT&IS), Khmelnytskyi, Ukraine, 2022.

Публікації. Основні результати дисертаційного дослідження опубліковано у 60 наукових публікаціях (Додаток Б), із них: 16 статей опубліковано у виданнях, що входять до міжнародної наукометричної бази даних SCOPUS, з них: 4 статті опубліковано в журналах з Q1-Q2, 10 статей – в журналах з Q3-Q4, 3 статті – опубліковано у виданнях, що входять до міжнародної наукометричної бази

даних Web of Science Core Collection, 14 публікацій – в наукових фахових виданнях України; 1 публікація у закордонному науковому виданні; 12 публікацій – матеріали конференцій, 11 з яких – у виданнях, що індексуються в наукометричній базі даних SCOPUS. Також опубліковано 9 монографій, 1 з яких – одноосібна, а також 3 навчальних посібники та 5 авторських свідоцтв на твір.

Структура та обсяг роботи. Дисертація складається з анотації, вступу, шести розділів, висновків, списку використаних джерел з 345 найменувань та 3 додатків. Робота викладена на 308 сторінках основного тексту, включає 55 рисунків та 50 таблиць.

РОЗДІЛ 1

СУЧАСНИЙ СТАН РОЗВИТКУ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ БАГАТОВИМІРНОГО АНАЛІЗУ МУЛЬТИМОДАЛЬНИХ ДАНИХ

Стрімкий розвиток сучасної медицини супроводжується зростанням обсягів, складності та різноманітності даних, що генеруються під час діагностичних, лабораторних, візуалізаційних та клінічних процедур. Це зумовлює потребу у створенні та вдосконаленні інформаційних технологій, здатних інтегрувати, аналізувати та інтерпретувати мультимодальні дані у багатовимірному аналітичному середовищі.

Разом з тим, наявні підходи до їх обробки обмежені в аспектах адаптивності, масштабованості та інтерпретованості результатів. Особливо це проявляється в умовах неповноти даних та неузгодженості між окремими модальностями. Тому актуальним завданням є пошук нових методів, які поєднували б теоретичну обґрунтованість із практичною реалізованістю, забезпечуючи точність, надійність та високу обчислювальну ефективність.

Однією з перспективних методологічних основ для вирішення цієї проблеми є концептуальний аналіз даних (Conceptual Data Analysis, CDA) – формальний підхід, що дозволяє виявляти структурні залежності між об'єктами та їх ознаками, будувати ієрархії знань і зменшувати розмірність без втрати інформативності. У сфері медичної інформатики використання CDA відкриває можливості для побудови аналітичних моделей підтримки клінічних рішень, орієнтованих на багатокритеріальну оцінку та інтерпретованість результатів.

Метою цього розділу є аналіз сучасного стану інформаційних технологій для обробки мультимодальних медичних даних, окреслення ключових викликів та обґрунтування доцільності застосування концептуального аналізу даних як теоретичної та методологічної основи для побудови ефективної інформаційної технології багатовимірного аналізу.

1.1. Визначення базових понять концептуального та багатовимірного аналізу даних. Нормативно-правова основа

Сучасна медична практика ґрунтується на обробці великої кількості різнорідних даних, що надходять із різних джерел – електронних медичних карток, результатів інструментальних досліджень (ЕЕГ, МРТ, ЕКГ), лабораторних показників, клінічних спостережень тощо. Така складність інформаційного середовища вимагає пошуку нових підходів до аналізу, інтеграції та інтерпретації даних, які забезпечують достовірну, масштабовану та адаптивну підтримку прийняття медичних рішень [6, 11].

У цьому контексті концептуальний аналіз даних (Conceptual Data Analysis, CDA) постає ефективною теоретичною основою для моделювання структур знань, виявлення закономірностей і формування узагальнень на основі логіко-алгебраїчного підходу. Його застосування дає змогу виявляти формальні структури у множинах об'єктів і ознак, розкривати приховані зв'язки між модальностями та знижувати складність представлення даних без втрати інформативності [236, 240, 242].

З огляду на те, що джерела медичних даних стають дедалі різноманітнішими як за природою, так і за структурою, особливого значення набувають методи, здатні інтегрувати інформацію різних типів у єдине аналітичне середовище. Поняття мультимодальних даних у цьому випадку охоплює числові параметри, текстові звіти, медичні зображення, сигнали (ЕЕГ, ЕКГ), звукові записи тощо [42, 44].

Таким чином, застосування CDA у сфері медичної інформатики забезпечує формалізоване подання різнорідної інформації, незалежно від її модальності, та розкриває внутрішні взаємозв'язки між об'єктами і їх характеристиками. Це створює підґрунтя для побудови узагальнених моделей знань, здатних враховувати специфіку кожного типу даних і поглиблювати аналітичне розуміння складних медичних явищ.

Разом із цим, для повноцінного відображення структурної складності медичних даних та ефективного опрацювання їх великого обсягу необхідне

також застосування багатовимірного аналізу, що забезпечує чисельне представлення інформації у вигляді векторних моделей, матриць та тензорів. На відміну від CDA, що акцентує увагу на концептуальних зв'язках та логічних структурах, багатовимірний аналіз зосереджується на кількісній оцінці даних, виявленні закономірностей за допомогою математичних і статистичних методів, а також на зменшенні розмірності з метою спрощення обчислень і візуалізації результатів [236, 242].

Для повного відображення структурної складності медичних даних та ефективної обробки їх великих обсягів необхідним є застосування багатовимірного аналізу, який забезпечує чисельне представлення інформації у вигляді векторних моделей, матриць і тензорів. Якщо CDA зосереджується на виявленні концептуальних зв'язків і формуванні логічних структур, то багатовимірний аналіз орієнтований на кількісне опрацювання даних: виявлення закономірностей за допомогою математичних і статистичних методів, а також на зменшення розмірності для спрощення обчислень та підвищення ефективності візуалізації результатів [14, 23].

Поєднання цих двох підходів – концептуального та багатовимірного – формує методологічну основу розроблення інформаційних технологій, здатних інтегрувати й інтерпретувати мультимодальні медичні дані з урахуванням як семантичної, так і кількісної складових (Табл. 1.1). Різниця між концептуальним аналізом даних та багатовимірним аналізом полягає у різному підході до дослідження. CDA зосереджується на виявленні концептуальних зв'язків, структури знань та залежностей між об'єктами та їх властивостей, використовуючи формальні контексти й логіко-алгебраїчні моделі. Натомість багатовимірний аналіз орієнтується на числове опрацювання даних у багатовимірному просторі, застосовуючи методи математичної статистики та машинного навчання для виявлення закономірностей, кластерів, головних компонент та інших узагальнених характеристик.

Таблиця 1.1

Основні підходи до інтерпретації інформації CDA та багатовимірною
аналізу

Критерій порівняння	Концептуальний аналіз даних (CDA)	Багатовимірний аналіз
Основна мета	Виявлення концептуальних зв'язків між об'єктами та їх ознаками	Аналіз та управління даними в багатовимірному числовому просторі
Тип вхідних даних	Формалізовані ознаки, бінарні відношення, якісні характеристики	Числові дані, вектори ознак, метричні змінні
Підхід до аналізу	Логіко-алгебраїчний підхід, побудова формальних контекстів	Статистичний підхід, застосування PCA, класифікації
Результат аналізу	Решітки концептів, ієрархії понять, концептуальні структури	Класи, головні компоненти, проекції, діаграми
Спрямованість	Інтерпретація знань і структурування семантики даних	Узагальнення та зменшення розмірності числових даних
Методологічна основа	Формальна концептуальна теорія, FCA (Formal Concept Analysis)	Математична статистика, лінійна алгебра, машинне навчання
Застосування до мультимодальних даних	Застосовується для виявлення структур у якісних або семантичних даних	Ефективний для структурованих кількісних даних і великомасштабних вимірювань

Мультимодальні дані застосовуються в обох підходах, оскільки поєднують різноманітні типи інформації – текстову, числову, візуальну, сигнальну та інші. Ця різноманітність дозволяє створювати багатовимірні представлення об'єктів, та вивчати глибинні семантичні зв'язки між модальностями для підвищення інформативності аналітичних висновків [15, 17, 18].

Для результативного використання CDA у задачах аналізу мультимодальних медичних даних необхідним є чітке розуміння його базових понять і принципів, що визначають логіку побудови та інтерпретації концептуальних структур [13, 20, 23].

1. Об'єкт – це сутність, яка підлягає вивченню в межах концептуального аналізу даних. Об'єкти можуть представляти людей, продукти, документи, компанії або будь-які інші елементи досліджуваної предметної області.

2. Атрибут – це характеристика об’єкта, що описує його властивості. Наприклад, для об’єкта «пацієнт» атрибутами можуть виступати: вік, стать, діагноз, результати аналізів тощо.
3. Концепт – це формалізована одиниця знань, яка описує множину об’єктів, що мають спільний набір атрибутів. Концепти дозволяють узагальнювати інформацію та будувати ієрархії ознак у формі решіток.
4. Асоціація – це зв’язок між об’єктами та атрибутами, що відображає, які атрибути притаманні яким об’єктам. Асоціації дозволяють виявляти закономірності та залежності в даних.
5. Контекст – це набір об’єктів, що формують інформаційне середовище аналізу. Контекст визначає область дослідження та включає релевантні атрибути.
6. Формальний контекст – це трійка, яка складається з множини об’єктів, множини атрибутів і відношення між ними, що формально описується у вигляді бінарної матриці. Такий контекст дозволяє математично опрацьовувати асоціації.
7. Галузь – це сукупність концептів, що охоплює певну предметну область знань. Дослідження галузі може здійснюватися з різних поглядів залежно від обраного набору об’єктів та атрибутів.
8. Категорія – це частковий концепт, який класифікує групу об’єктів із загальними атрибутами. Категорії допомагають організувати інформацію для подальшої інтерпретації.
9. Формальний контекст з атрибутами – це варіант формального контексту, який акцентує увагу на взаємозв’язках між самими атрибутами. Він дозволяє аналізувати співзалежності та співвживаність ознак.
10. Аналіз концептів – це процес побудови та дослідження ієрархії концептів. Дозволяє ідентифікувати структурні закономірності та формалізувати знання в досліджуваній галузі.

11. Концептуальне схематичне моделювання – це побудова графічного представлення концептів, об’єктів та атрибутів для кращого розуміння структури даних. Візуалізація у формі схем полегшує інтерпретацію результатів.
12. Діаграма класів – графічне подання класів об’єктів, їх атрибутів і методів. Широко використовується в об’єктно-орієнтованому аналізі для візуалізації структури системи.
13. ER-діаграма (Entity-Relationship) – схема, що описує сутності, їх атрибути та зв’язки між ними. Є одним з основних інструментів моделювання баз даних.
14. Схема бази даних – структурований опис елементів бази даних, включаючи таблиці, поля, зв’язки, ключі та індекси. Визначає логіку організації та зберігання даних.
15. Опис процесу бізнесу – формалізований опис дій, подій, ресурсів та ролей у межах певного бізнес-процесу. Дозволяє встановити логіку й послідовність операцій у межах функціонування організації або інформаційної системи.

В результаті проведеного аналізу існуючих визначень концептуального аналізу даних (CDA), що представлені в роботах [13, 15, 17, 20, 23], автором було запропоновано власне визначення, яке узагальнює сучасні тенденції розвитку CDA та орієнтоване на прикладне застосування в медичній інформатиці, зокрема при обробці мультимодальних медичних даних.

Визначення 1.1. Концептуальний аналіз даних мультимодальних медичних джерел – це формалізований підхід до структурування знань, який базується на побудові формальних контекстів і концептів для виявлення логічних зв’язків між об’єктами й атрибутами з різних модальностей. Такий аналіз дозволяє здійснювати узагальнення гетерогенних даних, формувати ієрархії понять та виявляти приховані закономірності, що є основою для підтримки прийняття клінічних рішень в умовах невизначеності, неповноти або надлишковості інформації.

Подане визначення показує, що концептуальний аналіз дає змогу об'єднувати різні типи медичних даних у єдину систему знань та пояснювати смислові зв'язки між ознаками і джерелами даних. Це дозволяє створювати гнучкі й обґрунтовані моделі, які підвищують ефективність медичної аналітики.

Застосування концептуального аналізу даних до мультимодальних джерел інформації відкриває нові можливості для глибшого, узагальненого і структурованого представлення знань, що є особливо актуальним в умовах зростання обсягів і складності даних у різних галузях. Наукова новизна такого підходу полягає в наступних аспектах [22, 25].

1. Доповнення інформаційного простору, де мультимодальні дані забезпечують розширене уявлення про об'єкти дослідження за рахунок поєднання різних типів інформації – текстів, зображень, сигналів, числових параметрів тощо. Це дозволяє у межах CDA формувати повніші формальні контексти, що враховують різноманітні властивості об'єктів, а отже – сприяє точнішому виявленню концептуальних структур.

2. Глибше розуміння складних систем, що дозволяє інтегрувати мультимодальні дані та створювати можливість для аналізу складних об'єктів і явищ, які неможливо повністю охопити за допомогою одного джерела інформації. Зокрема, в медичному контексті це дозволяє поєднувати симптоматику, результати діагностики, зображення та лабораторні показники для виявлення причинно-наслідкових зв'язків і моделей перебігу захворювань.

3. Підвищення обґрунтованості прийняття рішень, що створює можливість для одночасного врахування кількох типів даних у межах концептуального моделювання забезпечує більш об'єктивну підтримку прийняття рішень.

4. Універсальність і широке міжгалузеве застосування, що дозволяє виявляти закономірності та структури в гетерогенних даних, що зростають у кількості та складності в умовах цифрової трансформації.

Так, аналогічно до CDA, багатовимірний аналіз також базується на низці ключових понять і принципів, без розуміння яких його ефективне застосування

неможливе – особливо у сфері обробки складних мультимодальних медичних даних.

Ось основні поняття та принципи багатовимірного аналізу, які варто відзначити [2, 5, 23]:

1. Вектор ознак (Feature Vector) – математичне представлення об'єкта у вигляді набору числових значень, де кожна координата відповідає певному атрибуту або вимірюванню.
2. Простір ознак (Feature Space) – багатовимірний простір, у якому об'єкти представлені точками відповідно до їхніх векторів ознак.
3. Розмірність (Dimensionality) – кількість атрибутів (ознак), які описують об'єкт. Висока розмірність часто потребує зменшення (наприклад, через PCA) через «прокляття розмірності».
4. Метрики відстані – способи вимірювання подібності чи відмінності між об'єктами (наприклад, евклідова, косинусна, мангеттенська відстань).
5. Коваріація та кореляція – оцінка зв'язків між ознаками; важливі для виявлення залежностей та надлишковості в даних.
6. Зменшення розмірності (Dimensionality Reduction) – техніки (наприклад, PCA), що дозволяють зменшити кількість ознак при збереженні основної інформації.
7. Класифікація – процес автоматичного віднесення об'єктів до одного з наперед визначених класів або категорій на основі їхніх ознак (атрибутів), представлених у вигляді векторів у багатовимірному просторі.
8. Факторний аналіз – виявлення прихованих факторів, які пояснюють спостережувані варіації між змінними.
9. Нормалізація та стандартизація – приведення значень ознак до єдиного масштабу для коректного аналізу (особливо важливо при різномірних типах медичних даних).
10. Візуалізація високовимірних даних – методи (наприклад, PCA-проекції), що дозволяють відображати багатовимірні об'єкти у 2D/3D для інтерпретації результатів.

Розуміння вищезазначених понять є необхідною умовою для ефективного застосування багатовимірного аналізу, особливо у сфері обробки мультимодальних медичних даних, де висока розмірність, складна структура та різноманітність джерел вимагають не лише математичної строгості, а й глибокого усвідомлення етичних, соціальних та правових аспектів використання інформації [12, 11].

В результаті систематизації наявних підходів до багатовимірного аналізу даних [2, 5, 11, 12, 23], а також з урахуванням обробки мультимодальної медичної інформації, автором було запропоновано власне визначення, яке узагальнює ключові методологічні принципи та відображає сучасні прикладні потреби медичних інформаційних систем.

Визначення 1.2. Багатовимірний аналіз мультимодальних медичних даних – це сукупність методів та підходів до опрацювання складних структурованих і неструктурованих даних, представлених у вигляді векторів ознак у багатовимірному просторі, які забезпечують виявлення закономірностей, класифікацію, узагальнення та візуалізацію інформації з урахуванням кореляцій, високої розмірності, різноманітності модальностей і необхідності адаптації до невизначеності та неповноти даних.

Наведене визначення підкреслює методологічну інтеграцію статистичних і машинних підходів до аналізу даних високої розмірності та їх здатність до адаптації у медичному контексті, де важливими є точність, швидкодія та інтерпретованість рішень уніфікованих ознак, що дозволяє сформулювати модель стану пацієнта.

У медичному середовищі це питання набуває особливої ваги, оскільки йдеться про персоналізовані дані пацієнтів, які містять конфіденційну, чутливу або критично важливу інформацію – результати лабораторних досліджень, історії хвороб, електронні медичні картки, зображення МРТ чи ЕКГ-записи. Їх некоректне використання або витік можуть призвести до серйозних правових і моральних наслідків.

У роботі з медичними даними важливо враховувати вимоги законодавства, яке регламентує їх збір, обробку, зберігання та використання. Національні та міжнародні норми у сфері захисту персональних даних встановлюють чіткі правила щодо конфіденційності, обов'язкової згоди пацієнта, контролю доступу та гарантій інформаційної безпеки.

Тому перед початком будь-яких досліджень чи клінічних проєктів, що передбачають збір і аналіз медичних даних, необхідно ознайомитися з відповідною правовою базою. Вона визначає межі використання персональної інформації та забезпечує захист прав пацієнтів. В Україні основним документом є Закон «Про захист персональних даних», у якому закріплено принципи законності, пропорційності, обмеження мети обробки, а також вимоги щодо згоди, прав суб'єкта, термінів зберігання та заходів безпеки [65].

Крім цього закону, у галузі охорони здоров'я діють також інші нормативні акти – зокрема, Наказ МОЗ України № 587 від 28.02.2020, яким затверджено Порядок ведення електронної системи охорони здоров'я, а також підзаконні акти щодо зберігання медичних документів, передачі інформації між медичними закладами, використання телемедицини тощо [66].

Важливе значення для захисту персональних даних у сфері інформаційних технологій, зокрема у медицині, мають також міжнародні нормативно-правові документи. Одним із ключових є Конвенція Ради Європи про захист осіб у зв'язку з автоматизованою обробкою персональних даних (1981 р.), яка встановлює мінімальні стандарти захисту приватної інформації, включаючи обмеження на автоматизоване прийняття рішень, вимоги до конфіденційності та контроль над подальшим використанням персональних відомостей. Цей документ заклав основу для розбудови законодавства про інформаційну безпеку в країнах-членах Ради Європи, включно з Україною [91].

Доповненням до цих норм є Загальний регламент про захист даних (GDPR), який з 2018 року став обов'язковим для усіх країн-членів Європейського Союзу та дедалі частіше виступає орієнтиром і для країн-кандидатів, зокрема України, в умовах євроінтеграційного курсу. GDPR чітко формулює принципи обробки

персональних даних: законність, прозорість, цілеспрямованість, мінімізація даних, точність, обмеження зберігання, цілісність і конфіденційність, а також вимагає запровадження відповідальності з боку обробників даних. У сфері медичних IT-систем це означає, що всі процедури збору та аналізу даних мають бути не лише технологічно ефективними, а й юридично обґрунтованими та безпечними [8, 15].

У такому правовому контексті особливої актуальності набуває концептуальний аналіз даних (CDA), адже він забезпечує структуровану роботу з інформацією, зберігаючи контроль над джерелами та зв'язками. У мультимодальному середовищі CDA сприяє створенню прозорих і керованих моделей, що відповідають принципам етичного та безпечного використання даних.

Водночас багатовимірний аналіз надає інструменти для числової обробки великих масивів інформації у високовимірному просторі. Методи PCA, класифікації та візуалізації допомагають виявляти закономірності, знижувати розмірність без втрати суттєвих характеристик, формувати прогнозні моделі та аналізувати клінічні або поведінкові профілі пацієнтів.

Ефективне використання CDA у системах аналізу мультимодальних медичних даних потребує засвоєння базових понять і інструментів, що становлять його методологічну основу. Вони дають змогу будувати концептуальні моделі, виявляти зв'язки між об'єктами та атрибутами, а також забезпечувати зрозуміле й якісне опрацювання даних у складних і різномірних інформаційних середовищах [13, 18].

Натомість багатовимірний аналіз забезпечує числове подання та обробку даних у високовимірному просторі, застосовуючи методи PCA, класифікації та візуалізації. Це дозволяє знаходити приховані закономірності, зменшувати розмірність без втрати важливої інформації, будувати прогнозні моделі й аналізувати клінічні чи поведінкові профілі пацієнтів.

Поєднання CDA та багатовимірного аналізу дає можливість об'єднати семантичне представлення знань із числовою обробкою даних, що особливо

важливо при роботі з мультимодальними джерелами – такими як ЕЕГ, МРТ, клінічні описи чи лабораторні показники.

Для ефективного використання цих підходів важливо розуміти основні поняття. Нижче наведено ключові терміни, визначені автором на основі проведеного аналізу, які допомагають краще зрозуміти принципи концептуального та багатовимірного аналізу даних.

1. Дані – будь-яка зафіксована інформація, яка може бути представлена в цифровій формі (числа, текст, зображення, аудіо/відео, сигнали) та слугує об'єктом зберігання, обробки й аналізу.
2. Концептуальна модель – абстрактна структура, яка описує сутності, їх атрибути та взаємозв'язки між ними в певній предметній області. Використовується для представлення знань у логічній формі.
3. Метадані – «дані про дані», тобто описова інформація, яка характеризує основні дані: формат, джерело, час створення, структура, правила доступу, тип атрибутів тощо.
4. Класифікація – процес віднесення об'єктів до наперед визначених категорій або класів на основі їхніх ознак. У медичних ІТ системах використовується для діагностики, прогнозування ризиків, автоматичного прийняття рішень.
5. Атрибут – характеристика або ознака об'єкта, яка має певне значення. Наприклад: вік, артеріальний тиск, тип патології.
6. Ієрархія – система впорядкування об'єктів або концептів за рівнями узагальнення або підпорядкування. У CDA формується через решітки концептів.
7. Розмірність – кількість незалежних ознак, які описують об'єкт у багатовимірному просторі. Наприклад, 512 ознак МРТ або 256 параметрів ЕЕГ.
8. PCA (Principal Component Analysis) – метод зменшення розмірності, який дозволяє зберегти максимум інформації при трансформації даних у новий простір головних компонент.

9. Вектор ознак (Feature Vector) – числове представлення об'єкта у вигляді впорядкованої множини значень його атрибутів. Наприклад, вектор пацієнта з параметрами ЕКГ, ЕЕГ, віком, діагнозом.
10. Простір ознак (Feature Space) – математичний простір, в якому кожен об'єкт подається точкою відповідно до його вектора ознак. Відстані між точками відображають подібність об'єктів.
11. Метрика відстані – правило обчислення відстані між об'єктами у просторі ознак. Найпоширеніші: евклідова, косинусна, мангеттенська. Вибір метрики впливає на якість класифікації та кластеризації.
12. Нормалізація – процес приведення ознак до спільного масштабу (наприклад, у діапазон $[0;1]$ або зі стандартним відхиленням 1) для коректної обробки й порівняння.
13. Моделювання даних – створення формальних (математичних або логічних) моделей, що описують взаємозв'язки між ознаками, об'єктами, результатами та поведінковими характеристиками системи.
14. Схема бази даних / діаграма сутність-зв'язок / DFD – візуальні та структурні форми подання моделей, які допомагають зберігати, пов'язувати та передавати дані між системами.

Хоча перелік термінів не є повним, наведені поняття формують методологічну основу концептуального аналізу даних та пов'язані з принципами багатовимірної аналізу. У поєднанні вони є базою для побудови ефективних інформаційних моделей, здатних не лише структурувати знання, а й обробляти великі масиви даних, інтегрувати та інтерпретувати інформацію з різних медичних джерел – ЕКГ, ЕЕГ, МРТ, клінічних протоколів, лабораторних показників тощо.

Багатовимірний аналіз забезпечує числове перетворення та інтерпретацію даних у високовимірних просторах із використанням методів головних компонент (PCA), класифікації, векторного подання ознак, метрик подібності та візуалізації. Це дає змогу виявляти приховані залежності, групи ризику та

ключові фактори впливу, які складно або неможливо отримати традиційними статистичними методами.

Отже, у підрозділі доведено доцільність одночасного застосування концептуального та багатовимірного аналізу для створення інформаційної технології обробки мультимодальних медичних даних. Такий підхід поєднує логічну інтерпретацію знань із числовим та статистичним аналізом, що є критично важливим для роботи з різномірними та великомасштабними медичними інформаційними потоками.

1.2. Наукові дослідження сучасних підходів до оптимізації методів концептуального та багатовимірного аналізу даних

У сучасних умовах стрімкого зростання даних, зокрема в медицині та біоінформатиці, особливої актуальності набуває ефективний аналіз структурованої й неструктурованої інформації. У цьому контексті вдосконалення методів концептуального аналізу даних (CDA) є одним із ключових напрямів досліджень, спрямованих на побудову змістовних і логічно пов'язаних знань на основі великих та різномірних інформаційних потоків.

CDA дає змогу виявляти структурні закономірності, логічні залежності між об'єктами та їх ознаками, а також формувати формалізовані контексти знань. Його застосування забезпечує семантичну інтерпретацію даних, що є особливо важливим у мультимодальному середовищі. Водночас робота з великими, складними й високовимірними наборами потребує оптимізації алгоритмів побудови концептів, застосування ефективних обчислювальних моделей і засобів візуалізації результатів.

Багатовимірний аналіз є важливим доповненням до CDA, оскільки дозволяє чисельно оцінювати характеристики об'єктів, зменшувати розмірність без втрати суттєвої інформації, здійснювати класифікацію та виявляти приховані закономірності. Поєднання концептуального й багатовимірного аналізу створює синергію: логічна інтерпретація знань поєднується з обчислювальною потужністю сучасних математичних методів. Це робить їх інтегроване

застосування особливо доцільним для інтелектуальних інформаційних технологій у медицині.

За останні десятиліття CDA, що ґрунтується на формальній концептуальній теорії (FCA), істотно розвинувся – від теоретичних моделей до прикладних рішень для обробки мультимодальних, нечітких і масивних даних. На початкових етапах увага зосереджувалась на математичному формалізмі. Праця Ganter & Wille (1999) [23] заклала основу FCA, визначивши ключові структури: формальний контекст, формальний концепт і решітку концептів. У центрі досліджень була побудова концептуальних решіток, моделювання бінарних відношень між об'єктами та атрибутами і формалізація понять у логічній структурі знань.

Зі зростанням обсягів даних і кількості їх атрибутів традиційні алгоритми побудови решіток виявилися малоефективними для масштабних та динамічних контекстів. Це стимулювало розробку нових підходів, спрямованих на пришвидшення обчислень і зменшення складності побудови концептуальних структур. Зокрема, Vychodil (2013) [18] запропонував алгоритми компактного подання контекстів, що знижують надмірність без втрати інформативності. Obiedkov & Roth (2002) [13] розробили методи відсікання зайвих концептів шляхом використання сітчастих фільтрів і аналізу залежностей атрибутів. Kuznetsov (2007) [20] зосередився на стабільності концептів, що стало особливо актуальним для роботи із зашумленими чи неповними даними, зокрема у медичній сфері.

Паралельно розвивався напрям семантичного розширення CDA. Priss (2006) [2] показала можливість інтеграції CDA з онтологіями, що дозволило моделювати знання у складних термінологічних системах, зокрема медичних. Belohlávek (2004) [3] розробив нечітке розширення FCA, яке враховує часткову належність об'єктів до концептів, що важливо для роботи з неповними або нечіткими даними, наприклад у психіатрії чи поведінкових дослідженнях.

Важливим етапом у розвитку CDA стала візуалізація та взаємодія з користувачем. Одним із перших програмних рішень став ConExp [236], що

забезпечив базову побудову та перевірку концептуальних структур. Подальші розробки, зокрема Kaytoue et al. (2011) [11], розширили ці можливості, додавши інтерактивні решітки, теплові карти, графові моделі та аналітичні інструменти, що поєднують візуальність із логічною структурою – критично важливу для медичних інформаційних систем.

Перспективним напрямом є інтеграція CDA з багатовимірним аналізом і машинним навчанням. Методи зменшення розмірності, як-от PCA, та тензорні представлення дозволяють ефективно працювати з високорозмірними даними. Нео et al. (2018) [25] показали, що поєднання FCA з тензорними моделями відкриває нові можливості для аналізу медичних сигналів (наприклад, ЕКГ, ЕЕГ), де важлива як семантична структура, так і кількісна обробка.

Прикладні дослідження підтверджують ефективність CDA у практичних завданнях. Poelmans et al. (2013) [21] продемонстрували його успішне використання в психіатрії, криміналістиці та медичній інформатиці. У психіатрії CDA застосовувався для моделювання поведінкових профілів і виявлення критичних патернів, у медицині – для формалізації знань про патології, структурування діагностичної інформації, аналізу симптомів та побудови систем підтримки рішень.

Таким чином, сучасні дослідження зосереджені на чотирьох напрямках: підвищення обчислювальної ефективності, поглиблення семантичних моделей, удосконалення візуалізації та інтеграція CDA з багатовимірними підходами й машинним навчанням [242]. Аналіз тенденцій показує, що ці напрями стають основою подальшого розвитку методів концептуального аналізу даних (Табл. 1.2).

Сучасний розвиток концептуального аналізу даних орієнтований на створення комплексних аналітичних платформ, що поєднують структурну глибину, семантичну інтерпретацію та обчислювальну ефективність. В умовах цифровізації медицини, використання мультимодальних даних і зростання потреби в персоналізованих підходах таке поєднання стає методологічною основою нових інформаційних технологій підтримки клінічних рішень. Це

відкриває можливості для впровадження інтелектуальних моделей, здатних поєднувати логічний і кількісний аналіз медичної інформації [236].

Таблиця 1.2

Аналіз досліджень з оптимізації концептуального аналізу

Напрямок	Результати
Алгоритмічна оптимізація	Зниження складності побудови решіток, прискорення обчислень
Семантичне розширення	Інтеграція онтологічних структур, запровадження нечітких концептів і гібридних моделей, що підвищує здатність CDA працювати з неповними, нечіткими або гетерогенними даними
Інтерактивність	Розвиток інструментів візуального аналізу знань (наприклад, ConExp, теплові карти, адаптивні графі рішень), що забезпечує кращу інтерпретацію результатів та зручність користування для кінцевого користувача, зокрема в медичних інформаційних системах
Багатовимірна інтеграція	Поєднання CDA з методами багатовимірного аналізу, що дозволяє обробляти мультимодальні дані (наприклад, ЕЕГ, ЕКГ, клінічні протоколи) шляхом зменшення розмірності, класифікації та семантичного узагальнення
Прикладне застосування	Створення адаптивних інформаційних технологій у галузях охорони здоров'я, соціальних наук, діагностики, безпеки, цифрового профілювання та прогностичної аналітики

Проведений аналіз джерел і практичних реалізацій підтвердив, що інтеграція CDA з багатовимірними методами створює умови для побудови ефективних аналітичних систем. У межах дисертації це дозволяє вирішити теоретичні та прикладні завдання, пов'язані з інтеграцією, обробкою й інтерпретацією мультимодальних медичних даних.

Перший напрям – розробка методів обробки даних із урахуванням семантики та структури. Поєднання CDA та багатовимірних моделей дає змогу подати медичну інформацію у вигляді формалізованих ієрархій, де відображаються зв'язки між симптомами, синдромами, діагнозами та іншими характеристиками. Це не лише структурує знання, але й дозволяє виявляти типові патерни, тоді як оптимізація контекстів зменшує надмірність ознак і скорочує час обробки.

Другий напрям – інтеграція з методами багатовимірного аналізу, насамперед PCA. Це дозволяє зменшити розмірність векторів ознак і водночас зберегти інформативність. Метрики подібності забезпечують групування

близьких концептів і виявлення аномалій, що особливо корисно для рідкісних або складних клінічних випадків. У результаті підвищується ефективність і масштабованість інформаційної технології.

Третій напрям – створення адаптивної платформи для підтримки медичних рішень. Гібридний підхід поєднує числові методи багатовимірного аналізу з логічною інтерпретацією CDA. Це дозволяє інтегрувати різні модальності (тексти, зображення, сигнали, числові параметри) в єдиному середовищі, будувати кластери пацієнтів, концептуальні ієрархії та формувати прозорі пояснення для медичних висновків.

Важливим аспектом є дотримання етичних і правових норм у роботі з персональними даними. На відміну від «чорних скриньок» у машинному навчанні, CDA дозволяє відстежити логіку формування результатів, що забезпечує прозорість, підзвітність і відповідність законодавству (GDPR, Закон України «Про захист персональних даних»).

Завдяки цим підходам у дисертаційному дослідженні формуються основні групи завдань (Табл. 1.3).

Таблиця 1.3

Очікувані результати, що вирішуються в межах дисертації

Напрямок	Завдання, яке вирішується в дисертаційній роботі
Методологічний	Формування основи для аналізу медичних даних, що поєднує CDA та багатовимірний підхід
Алгоритмічний	Ефективність побудови концептуальних решіток, використання PCA для зменшення розмірності, зменшення часу обробки
Прикладний	Виявлення закономірностей і шаблонів у мультимодальних медичних даних пацієнтів; побудова формалізованих структур знань
Функціональний	Створення інформаційної технології для інтерпретованого, масштабованого та адаптивного аналізу медичних даних
Правовий	Забезпечення відповідності технології вимогам безпеки, прозорості та правового регулювання персональних даних

Узагальнюючи, можна зазначити, що поєднання концептуального аналізу з багатовимірними методами створює надійну основу для розробки інтелектуальних технологій, здатних забезпечити точну, масштабовану й інтерпретовану підтримку прийняття рішень у медицині. Розв’язання цієї актуальної науково-прикладної проблеми охоплює як теоретичні моделі знань, так і практичні аспекти роботи зі складними даними.

Концептуальний аналіз даних за останні роки суттєво розвинувся завдяки новим алгоритмам, сучасним обчислювальним технологіям та інтеграції з іншими підходами. Сьогодні активно впроваджуються інструменти, що значно підвищують ефективність роботи з великими обсягами різномірної інформації [27].

Один із перспективних напрямів – інтерактивний аналіз даних (IAD) [58], який дає змогу користувачеві взаємодіяти з візуалізаціями результатів у режимі реального часу. Це не лише пришвидшує отримання висновків, а й дозволяє адаптувати аналіз під конкретні потреби дослідження. Візуальний зворотний зв'язок і можливість налаштовувати параметри під час обробки роблять результати зрозумілішими [75].

Інший ключовий напрям – інтеграція CDA з машинним навчанням та штучним інтелектом. Такі алгоритми допомагають автоматично знаходити приховані закономірності, виконувати класифікацію, прогнозування та скорочують витрати часу при роботі з великими наборами даних. Це відкриває шлях до створення адаптивних систем, що поєднують семантичну інтерпретацію з високою обчислювальною ефективністю. У результаті CDA, збагачений сучасними технологіями, стає гнучким, масштабованим і особливо корисним у цифровій медицині [26, 35, 56].

Ефективність CDA має не лише технічне, а й стратегічне значення. Він знижує витрати на обробку інформації, підвищує точність, адаптивність і якість результатів. Це актуально для сфер, де аналіз великих обсягів даних є критичним.

Завдання концептуального аналізу полягає у глибокому розумінні зв'язків між поняттями, об'єктами й атрибутами. Це дає змогу не лише структурувати знання, а й відкривати нові напрями досліджень. Використання сучасних підходів – інтерактивного аналізу, алгоритмів ІІІ, хмарних технологій та методів багатовимірного представлення даних – робить CDA ефективним, масштабованим і практично корисним інструментом у цифровому середовищі (Табл. 1.4).

Таблиця 1.4

Аналіз методів концептуального аналізу даних

Метод концептуального аналізу даних	Опис
Формальне поняття	Метод, що дозволяє знайти спільні ознаки між різними об'єктами та згрупувати їх в одне поняття.
Формальний контекст	Метод, що дозволяє представити дані у вигляді таблиці, в якій стовпці – поняття, а рядки – об'єкти.
Теорія графів	Метод, що дозволяє візуалізувати зв'язки між різними поняттями та концептами у вигляді графа.
Мультиаспектний аналіз	Метод, що дозволяє аналізувати дані з різних сторін та враховувати взаємозв'язки між ними.
Формальний концептуальний аналіз	Метод, що поєднує у собі формальне поняття та формальний контекст, дозволяючи аналізувати дані на основі спільних ознак.
Інтерактивний аналіз даних	Підхід, що забезпечує взаємодію користувача з моделлю та результатами аналізу в режимі реального часу.
Алгоритми машинного навчання	Автоматизований підхід до виявлення шаблонів, класифікації та прогнозування на основі великих наборів даних.
Хмарні технології	Інфраструктура для обробки великих обсягів даних з використанням розподілених обчислювальних ресурсів.
Багатовимірне представлення (РСА, тензори)	Методи для числового подання даних у багатовимірному просторі для виявлення закономірностей та зменшення розмірності.

У межах дисертаційного дослідження ефективність методів концептуального аналізу даних (CDA) реалізована з урахуванням особливостей обробки мультимодальних медичних даних. Зокрема, у роботі запропоновано:

- використання формального контексту для побудови структур знань, що відображають взаємозв'язки між клінічними ознаками, результатами обстежень (ЕЕГ, ЕКГ, МРТ) та діагнозами;
- інтеграцію CDA з методами багатовимірного аналізу (зокрема РСА) для зменшення розмірності ознак і зниження обчислювального навантаження при формуванні концептуальних решіток;
- застосування адаптивних алгоритмів побудови решіток для роботи з великими та гетерогенними наборами медичних даних у режимі реального часу;
- розробку методів семантичного представлення результатів, що дозволяє створювати допоміжні аналітичні моделі для підтримки клінічних рішень.

Таким чином, концептуальний аналіз даних виступає методологічною основою інформаційної технології, яка забезпечує ефективну, інтерпретовану та масштабовану обробку мультимодальних медичних даних. Кожен із методів має власні переваги й застосовується залежно від характеру завдання та обсягів інформації.

1.3. Система концептуального аналізу даних на основі багатовимірних формальних контекстів. Основні поняття

Система концептуального аналізу даних на основі багатовимірних формальних контекстів (англ. Multidimensional Formal Context Analysis, MFCA) є сучасним підходом до інтегрованого аналізу складних, різнорідних і мультимодальних даних. Вона ґрунтується на формальній теорії концептів (Formal Concept Analysis, FCA) – методології для виявлення закономірностей та структур знань через аналіз відношень між об'єктами й атрибутами [11, 21].

FCA передбачає побудову формальних контекстів, концептів і решіток концептів, що дає змогу моделювати знання у вигляді ієрархій понять. У медицині це використовується для виявлення клінічних патернів та взаємозв'язків між симптомами, діагнозами й результатами обстежень [23].

FCA як теоретична основа концептуального аналізу даних широко використовується в таких галузях, як комп'ютерні науки, штучний інтелект, інформаційні системи, біоінформатика та медицина. Її основними поняттями є [23, 25]:

- Формальний контекст – трійка, що складається з множини об'єктів, множини атрибутів та бінарного відношення між ними.
- Формальний концепт – пара, яка описує множину об'єктів (екстент) і відповідну множину спільних для них атрибутів (інтент), що формують логічно завершену одиницю знання.
- Решітка концептів – ієрархічна структура, в якій концепти впорядковані за ступенем узагальнення.

Багатовимірне розширення FCA (MFCA) дозволяє аналізувати дані одразу за кількома вимірами, наприклад за модальністю (ЕЕГ, ЕКГ, МРТ), часом, джерелом або типом клінічного випадку. Це забезпечує не лише формалізацію знань у межах одного виміру, а й інтеграцію інформації з різних джерел у єдину концептуальну модель.

У межах багатовимірного розширення FCA вводяться додаткові елементи, що дають змогу працювати з даними, які мають кілька вимірів або модальностей. Серед основних понять Multidimensional FCA можна виділити [25, 235]:

- Багатовимірні формальні контексти – розширення класичних формальних контекстів, що дозволяють пов'язувати об'єкти, атрибути й відношення в межах кількох вимірів (наприклад, час, модальність, джерело). Це забезпечує можливість аналізу даних у різних площинах, наприклад, ЕЕГ, МРТ, клінічні параметри.
- Багатовимірні концепти – узагальнені концепти, що формуються з урахуванням кількох контекстів одночасно. Вони описують множину об'єктів, які мають спільні властивості в різних вимірах, і дозволяють виявляти глибші структурні закономірності.
- Багатовимірні атрибути – атрибути, що варіюються залежно від контексту чи виміру (наприклад, «рівень глюкози у крові» в різний час або при різних клінічних умовах). Такі атрибути уможливають побудову складніших формальних моделей.

Практична цінність системи концептуального аналізу даних на основі багатовимірних формальних контекстів (MFCA) особливо проявляється під час обробки мультимодальних медичних даних, де необхідна інтеграція інформації з різних джерел і модальностей (ЕЕГ, ЕКГ, МРТ, клінічні записи) з урахуванням часових зрізів. У таких умовах MFCA забезпечує не лише підвищення точності класифікації, а й прозорість та інтерпретованість рішень, що є ключовою вимогою сучасної доказової медицини.

Основне завдання MFCA полягає у виявленні концептів у багатовимірному середовищі, тобто груп об'єктів, що мають спільні властивості за кількома

вимірами даних. Для цього застосовуються алгоритми побудови багатовимірних решіток концептів, які системно відображають логічні зв'язки між елементами інформації. Додатково сучасні реалізації MFCA включають засоби візуалізації (графові моделі, решітки, проекції), що полегшують інтерпретацію результатів та експертну оцінку [235, 237].

До основних переваг MFCA можна віднести:

- Високу ефективність та масштабованість при роботі з великими обсягами даних.
- Можливість виявлення складних, багатовимірних закономірностей у структурно неоднорідних наборах.
- Гнучкість і адаптивність до різних типів медичних задач, включно з неповними, шумовими або нечіткими даними.
- Підтримку візуалізації ієрархічних та кластерних структур, що сприяє кращому розумінню моделі як з боку дослідника, так і з боку практикуючих фахівців.

Разом з тим, слід визнати певні обмеження MFCA, зокрема:

- Складність реалізації багатовимірних моделей, що вимагає високого рівня алгоритмічної підготовки.
- Високі вимоги до попередньої підготовки даних і до коректності формалізації атрибутів.
- Необхідність візуальної інтерпретації великої кількості концептів, що потребує ефективних засобів візуальної аналітики.

Попри існуючі виклики, система концептуального аналізу на основі MFCA має високу цінність у науці та практиці, особливо там, де дані є складними, а точність і прозорість рішень мають критичне значення. У цій дисертації MFCA розглядається як основа інформаційної технології інтерпретованого аналізу мультимодальних медичних даних. Вона поєднує логічне структурування знань із числовим моделюванням, створюючи підґрунтя для розвитку інтелектуальних систем медичної підтримки.

Суть MFSA полягає в розширенні традиційного формального контексту до багатовимірного. Кожна модальність подається як окремий контекст: пацієнти виступають об'єктами, а стовпці містять властивості чи ознаки конкретної модальності. Інтеграція контекстів відбувається через об'єднання концептів, що дає змогу знаходити зв'язки між різними типами даних.

Особливо корисним цей підхід є для медичних даних, які включають часові сигнали (ЕЕГ, ЕКГ), зображення (МРТ), текстові записи (протоколи, виписки) та числові лабораторні показники. Кожен тип можна формалізувати як окремий контекст, а MFSA забезпечує побудову узгоджених концептів, що об'єднують знання з різних джерел у єдине структуроване представлення [235, 237].

У межах запропонованої інформаційної технології система MFSA дозволяє:

- виявляти концептуальні патерни, спільні для різних модальностей;
- інтегрувати інформацію в єдину аналітичну модель, зберігаючи зв'язки між її елементами;
- забезпечувати інтерпретованість рішень, що особливо важливо у сфері клінічної підтримки.

До переваг системи MFSA належать:

- можливість структурування гетерогенних даних з різних джерел;
- гнучкість моделювання, що дає змогу розширювати або змінювати кількість вимірів;
- візуалізація концептів у вигляді решіток, графів та матриць;
- підтримка аналізу залежностей, кластеризації, класифікації і навіть виявлення аномалій.

Однак, MFSA має і низку обмежень, насамперед пов'язаних із:

- обчислювальною складністю при великій кількості ознак або модальностей;
- необхідністю попередньої нормалізації та уніфікації форматів даних;
- чутливістю до наявності шуму або пропусків у вхідних матрицях.

У дисертаційному дослідженні система MFCA виконує роль ядра концептуального представлення мультимодальної медичної інформації. Реалізовані підходи дозволяють:

- поєднати багатовимірний аналіз (через використання PCA, тензорних моделей, метричних методів) з формальними контекстами;
- забезпечити інтерпретовану класифікацію пацієнтів;
- побудувати адаптивну технологію аналізу, яка узгоджується з нормативно-правовими та етичними вимогами.

Отже, система концептуального аналізу даних на основі багатовимірних формальних контекстів є не лише теоретично обґрунтованим, а й практично дієвим інструментом для обробки різномірних медичних даних. Вона відкриває нові можливості для точного, масштабованого та зрозумілого аналізу в цифровій медицині.

1.4. Мультимодальність як методологічна перспектива дослідження інтеракції в інформаційній технології

Мультимодальність розглядається як підхід, що визначає інтеграцію та взаємодію різномірних інформаційних потоків в ІТ-системах. Він особливо важливий для сучасних технологій, оскільки дозволяє комплексно аналізувати багатоканальні процеси з урахуванням різних типів даних – текстових, візуальних, аудіальних і сенсорних [41, 51, 53].

У медичних інформаційних системах мультимодальність має ключове значення, адже дані надходять із різних джерел: електронних карток, лабораторних результатів, МРТ-зображень, сигналів ЕКГ та ЕЕГ, клінічних спостережень тощо. Інтеграція цих даних дає змогу формувати цілісне уявлення про стан пацієнта та підвищувати обґрунтованість діагностики [43, 56].

Застосування концептуального аналізу в такому середовищі відкриває нові можливості для моделювання взаємозв'язків між медичними ознаками різної природи. Поєднання CDA з багатовимірними методами дозволяє не лише структурувати знання, а й оцінювати кількісні залежності між модальностями,

що формує основу для адаптивних і масштабованих моделей підтримки клінічних рішень.

Мультимодальний підхід є важливим інструментом у межах концептуального аналізу, оскільки забезпечує комплексне дослідження інтеграції різних джерел даних та їх впливу на процеси сприйняття й обробки інформації. Методологічно він спирається на інтегративний підхід, що поєднує різні методи для більш глибокого розуміння складних явищ [46, 48].

Загалом мультимодальність виступає основою аналітичних моделей, здатних забезпечувати точність, гнучкість та надійність у процесах підтримки медичних рішень. Аналіз прикладів сучасних мультимодальних ІТ-систем підтверджує її значущість і практичну цінність:

1. Розпізнавання мовлення через мультимодальні інформаційні системи обробляють вербальну комунікацію користувача, забезпечуючи взаємодію через голосові команди або текстове введення голосом. Це значно підвищує доступність і зручність роботи з інформаційними технологіями.
2. Візуальне сприйняття через системи розпізнавання обличчя дає змогу фіксувати емоційні стани користувача, що може бути використано для динамічної адаптації системної відповіді в медичних та соціальних ІТ-додатках.
3. Гестурний інтерфейс у мультимодальних платформах дозволяє використовувати рухи тіла або жести як форму введення даних, що особливо актуально для систем реабілітації або розширеної реальності.
4. Синтез мовлення та графічне відображення дає змогу поєднати вербальні та невербальні канали комунікації дозволяє створювати більш природні й інтуїтивно зрозумілі інтерфейси для кінцевих користувачів.

Отже, мультимодальність виступає перспективним напрямом досліджень, що допомагає зрозуміти взаємодію різних потоків інформації та створювати ефективні багатовимірні технології для медицини й інших критично важливих сфер. Для узагальнення уявлень про сутність мультимодальності в таблиці 1.5 наведено порівняльний огляд визначень, запропонованих провідними

науковцями в галузі ІТ, когнітивних наук і медичної інформатики. Це формує теоретичне підґрунтя для подальшого розвитку моделей інтеграції даних у межах концептуального й багатовимірного аналізу.

Таблиця 1.5

Визначення поняття «мультимодальність»

Автор	Визначення	Галузь застосування
Kress and van Leeuwen [46]	Мультимодальність відноситься до використання різних знакових систем, таких як мова, образ, звук тощо, для передачі інформації та створення значення.	Освіта, візуальна комунікація, дизайн навчальних матеріалів
Jewitt [285]	Мультимодальність відноситься до використання різних знакових систем в рамках одного тексту або комунікативної події для передачі інформації та вираження значення.	Лінгвістика, педагогіка, цифрові освітні ресурси
O'Halloran [53]	Мультимодальність відноситься до використання різних знакових систем, які мають різні способи вираження та взаємодіють між собою для передачі інформації та створення значення.	Системний функціональний аналіз, математична освіта, семіотика
Bezemer and Kress [41]	Мультимодальність відноситься до використання різних знакових систем, які працюють разом, щоб виразити повніше інформацію та збільшити ефективність комунікації.	Здоров'я, медицина, аналіз клінічної взаємодії, освітній дизайн
Norris and Jones [72]	Мультимодальність відноситься до використання різних знакових систем, щоб виразити більш повну та детальну інформацію про комунікаційну подію або текст.	Соціальна комунікація, аналіз відеозаписів, поведінкові дослідження
Oviatt [152]	Мультимодальність – це здатність системи приймати та обробляти інформацію з кількох сенсорних каналів одночасно.	Людино-комп'ютерна взаємодія, мультимодальні інтерфейси
Jaimes & Sebe [145]	Комбінування кількох модальностей (текст, аудіо, відео) для підвищення точності інтерпретації контексту	Обробка мультимедійної інформації

Продовження Табл. 1.5

Автор	Визначення	Галузь застосування
Calhoun et al. [178]	Інтеграція гетерогенних даних для створення уніфікованого інформаційного середовища.	Нейронаука, обробка функціональних даних мозку
Srivastava & Salakhutdinov [99]	Об'єднання глибоких ознак з різних джерел даних у спільному просторовому представленні.	Глибоке навчання, багатовимірні представлення
Узагальнене визначення (авторське) [6]	Мультиmodalність – це інтегративний підхід до обробки різнорідних даних, що дозволяє виявити структурні зв'язки між модальностями для прийняття обґрунтованих рішень	Медична аналітика, концептуальний аналіз даних

Автори, що їх наведено у таблиці 1.5, трактують мультиmodalність у різних площинах – від класичної людино-комп'ютерної взаємодії до сучасних методів глибинного навчання та клінічної аналітики. Попри відмінності у підходах, усі визначення підкреслюють здатність систем працювати з даними з різних каналів і поєднувати їх у єдину смислову або функціональну структуру.

Ключовим у більшості підходів є інтеграція гетерогенних даних, що підвищує якість інтерпретації, підтримує прийняття рішень та створює нові форми представлення знань. Наприклад, Srivastava & Salakhutdinov [99] розглядають мультиmodalність через глибинні нейромережі, які формують спільний простір ознак, тоді як Jaimes & Sebe [145] акцентують на міжmodalних зв'язках у медичних системах підтримки рішень.

На основі проведеного аналізу автором запропоновано власне визначення мультиmodalності, яке узагальнює сучасні підходи та орієнтоване на практичне застосування у медицині.

Визначення 1.3. Мультиmodalність – це інтегративний підхід до обробки різнорідних даних, що дозволяє знаходити зв'язки між ними для прийняття обґрунтованих рішень.

Таке визначення підкреслює інтегративну природу мультиmodalного підходу та його здатність виявляти залежності між клінічними, візуальними та сигнальними даними. Тому мультиmodalність є не лише теоретичним поняттям, а й практичним інструментом для створення аналітичних технологій, зокрема в

межах інформаційної технології багатовимірного аналізу медичних даних, розробленої у дисертаційному дослідженні.

Застосування цього підходу відкриває можливості для виявлення складних взаємозв'язків між модальностями та формування моделей, що забезпечують зрозумілу й достовірну обробку інформації. Це підвищує точність і прозорість аналітичних висновків, що особливо важливо у медицині, де поєднання різних діагностичних джерел дозволяє приймати більш зважені рішення.

Аналіз сучасних робіт [32–33, 50, 319] підтверджує, що мультимодальний підхід ефективний для вивчення взаємодії людини й інформаційних систем. Дослідження включають аналіз зорових, мовних, акустичних і моторних каналів, що поглиблює розуміння процесів взаємодії та допомагає адаптувати системи до потреб користувачів. Це є особливо цінним для створення медичних інтерфейсів, телемедичних платформ, систем реабілітації та інших застосувань, де потрібна точність і персоналізація.

Таким чином, мультимодальність зміцнює методологічні основи багатовимірного аналізу й виступає ключовим компонентом дослідження, спрямованого на побудову адаптивних і зрозумілих інформаційних технологій у складних середовищах. Це дозволяє моделювати процеси обробки даних у ситуаціях із великою різноманітністю джерел і форматів.

Мультимодальний підхід забезпечує отримання повнішої інформації про процеси взаємодії та використання різних методів для їх аналізу. Це створює основу для нових поколінь інформаційних технологій, здатних ефективно працювати з різноманітними даними та підтримувати персоналізовану взаємодію в цифрових системах.

Разом із перевагами мультимодальний підхід має й певні обмеження (див. Табл. 1.6). Інтеграція різних типів даних потребує значних технічних і семантичних зусиль. Високі вимоги до ресурсів, синхронізації, попередньої обробки та єдиного трактування результатів можуть знижувати якість і достовірність аналізу. Крім того, на результати можуть впливати зовнішні чинники, не пов'язані безпосередньо з природою модальностей.

Таблиця 1.6

Недоліки використання мультимодальності у дослідженні інтеракції

Обмеження при використанні мультимодальності	Недоліки використання мультимодальності у дослідженні інтеракції
Складність обробки даних	Інтеграція декількох модальностей вимагає врахування специфіки кожної окремої модальності та потребує їх окремого аналізу
Передача та синхронізація даних різних модальностей	Може призводити до часових затримок, що негативно впливає на точність взаємодії та сприйняття користувачем
Нерівнозначність значущості модальностей	У деяких випадках надмірна увага до окремих модальностей може викликати плутанину або знизити ефективність експерименту
Використання багатьох модальностей одночасно	Може призводити до перевантаження інформаційної системи та ускладнювати її реалізацію
Необхідність спеціального обладнання	Застосування мультимодального підходу часто вимагає використання специфічних апаратних або програмних засобів для кожної модальності, що ускладнює впровадження

Попри це, мультимодальність посідає ключове місце у сучасних методологіях багатовимірного аналізу даних. Її застосування в межах дисертаційного дослідження дозволяє підвищити ефективність обробки різномірної інформації та створювати інтерпретовані, масштабовані й адаптивні аналітичні системи. У медицині такі системи сприяють підвищенню достовірності, обґрунтованості й прозорості клінічних рішень.

Дослідження інтеракцій у мультимодальному середовищі відкриває перспективи для створення гнучких моделей, що поєднують текстові, числові, сигнальні та візуальні дані. Це особливо важливо для медичних інформаційних систем, де мультимодальні підходи забезпечують вищу точність аналізу, краще розуміння інформаційних процесів і розширюють можливості роботи з великими масивами даних.

Отже, мультимодальність є не лише концептуальною основою аналізу, а й дієвим методологічним інструментом для підтримки прийняття рішень.

1.5. Порівняльна характеристика багатовимірних і мультимодальних даних у контексті інформаційної структури

У добу цифрової трансформації багатовимірні та мультимодальні дані дедалі активніше використовуються в різних сферах, зокрема в медицині. Це зумовлено зростанням кількості джерел інформації, різноманітністю форматів і потребою в інтегрованому поданні складних даних [45, 160]. Адже, багатовимірні дані характеризуються великою кількістю ознак чи атрибутів, що описують об'єкт, та зазвичай подаються у вигляді таблиць, матриць, векторів або тензорів. Вони застосовуються для числового аналізу, статистичної обробки, класифікації та візуалізації високорозмірних структур.

Мультимодальні дані поєднують інформацію з різних джерел і каналів – текстів, зображень, аудіо, відео, сигналів, біомедичних параметрів тощо. Їхня основна особливість полягає в інтеграції змісту з різних модальностей у єдине аналітичне середовище [146, 225].

Інформаційні системи, що працюють із такими даними, мають бути масштабованими, адаптивними та здатними поєднувати числове багатовимірне подання з семантичною інтеграцією різнорідних джерел. Це потребує гібридних рішень – поєднання матричних і графових структур, формальних контекстів, онтологій і обчислювально ефективних алгоритмів. Аналіз ролі та особливостей багатовимірних і мультимодальних даних є важливим кроком у розробці методології інтегрованих ІТ, насамперед у медицині, де точність і швидкість рішень критично важливі [223].

Отже, у сучасних умовах необхідно чітко розуміти як спільні, так і відмінні риси цих типів даних. Багатовимірні зазвичай подаються як числові вектори або матриці, тоді як мультимодальні поєднують інформацію з неоднорідних джерел – текстових, візуальних, сигнальних. Відповідно, методи їх аналізу різняться: для багатовимірних застосовують числову обробку, а для мультимодальних – інтегративні моделі, що враховують семантику та синхронізацію [23, 56].

Для узагальнення характеристик, методів обробки, сфер застосування й обмежень обох категорій у таблиці 1.7 наведено їх порівняльний огляд.

Таблиця 1.7

Схожість та відмінність між багатовимірними та мультимодальними даними

Критерій	Багатовимірні дані	Мультимодальні дані
Джерело даних	Зазвичай один тип джерела (наприклад, сенсори, анкети)	Кілька різних джерел (текст, зображення, аудіо, відео, сигнали)
Структура	Впорядкована таблиця або матриця з великою кількістю ознак	Набір різнорідних структур, що включають різні типи представлення
Представлення	Вектори ознак, тензори, багатовимірні матриці	Поєднання векторів, графів тощо
Методи обробки	РСА, класифікація, аналіз головних компонент	Алгоритми злиття ознак, нейронні мережі для різних модальностей
Інтеграція інформації	Необов'язкова, оскільки ознаки вже представлені в єдиному форматі	Необхідна, вимагає вирівнювання та уніфікації форматів
Застосування	Зменшення розмірності, виявлення закономірностей	Виявлення взаємозв'язків між модальностями, побудова комплексних моделей
Сфери використання	Біоінформатика, економіка, фізика, машинне навчання	Медицина, мультимедійні системи, телемедицина, соціальні медіа
Обмеження	«Прокляття розмірності», надлишковість ознак	Висока складність синхронізації та обробки різнорідних даних

Проведений аналіз показує, що багатовимірні та мультимодальні дані є важливими для прийняття обґрунтованих рішень, але вимагають різних підходів до обробки. Тому сучасні інформаційні технології мають забезпечувати не лише ефективність роботи з високорозмірними структурами, а й здатність інтегрувати та інтерпретувати дані з різних джерел.

У дисертації ця інтеграція реалізується через поєднання концептуального аналізу даних (CDA) з методами багатовимірного моделювання. Це дає змогу працювати як із числовими ознаками, так і з потоками клінічної інформації різних типів, формуючи адаптивну й прозору аналітичну систему для цифрової медицини [165].

Багатовимірні дані – це числові атрибути об'єктів, подані у вигляді таблиць, матриць, векторів чи тензорів. Їх аналіз дозволяє виявляти залежності, закономірності, формувати кластери й прогнознi моделі. Для цього широко застосовуються інструменти Python (NumPy, pandas, scikit-learn), R (tidyverse, caret), MATLAB, SPSS із методами на кшталт PCA чи класифікації [154, 187].

Мультимодальні дані поєднують інформацію з різних джерел: тексти, зображення, звук, відео, сигнали датчиків, біомедичні параметри тощо. Їх аналіз вимагає інтеграційних підходів, що об'єднують семантику й структуру у спільну модель. У медицині це може бути паралельний розгляд клінічних записів, результатів МРТ, ЕКГ та мовних характеристик пацієнта [78, 164].

Для ефективного аналізу таких даних використовуються спеціалізовані програмні засоби та бібліотеки, зокрема [212]:

- TensorFlow та PyTorch – для побудови мультимодальних моделей глибокого навчання.
- OpenCV, NLTK, Transformers – для обробки зображень, тексту та мовлення.
- Orange, RapidMiner – інтерактивні середовища для мультимодальних наборів.
- FCA Tools, ConExp, Galicia – для концептуального аналізу даних.

Одним із основних викликів при роботі з мультимодальними даними є необхідність синхронізації та узгодження різних форматів, одиниць виміру та термінологічних відмінностей. Для цього застосовують нормалізацію, уніфікацію ознак, семантичне тегування та онтології. Лише за таких умов результати аналізу будуть інтерпретованими та практично цінними [138, 158].

Мультимодальний підхід дозволяє поєднати сильні сторони кожного джерела, підвищуючи точність, повноту й узгодженість висновків. Це особливо важливо в медицині, де рішення спираються на комплексне врахування візуалізацій, лабораторних тестів, історії хвороби та мовної поведінки пацієнтів.

Таким чином, багатовимірні й мультимодальні дані мають ключове значення в сучасних ІТ-системах, а їх ефективна обробка потребує поєднання числових методів із концептуальними та інтеграційними технологіями. Це створює основу для адаптивних рішень у складних інформаційних середовищах [168].

Багатовимірні дані зазвичай мають фіксовану кількість числових параметрів, тоді як мультимодальні охоплюють різноманітні інформаційні потоки, що потребують інтеграції у спільний простір аналізу. Для систематизації їх

спільних і відмінних рис у таблиці 1.8 наведено порівняльний огляд структур, методів обробки, сфер застосування та обмежень [154].

Таблиця 1.8

Порівняння багатовимірних та мультимодальних даних

Критерій	Багатовимірні дані	Мультимодальні дані
Тип параметрів	Числові, структуровані	Числові, текстові, графічні, аудіовізуальні тощо
Представлення	Матриці, таблиці, вектори	Комбінація зображень, текстів, аудіо, відео, сигналів
Джерела даних	Єдиний тип джерела (наприклад, сенсори, опитування)	Різнорідні джерела та пристрої
Аналіз	Статистичний, факторний, регресійний, РСА	Машинне навчання, глибоке навчання, онтологічний аналіз
Обмеження	Висока розмірність, мультиколінеарність	Інтеграція форматів, синхронізація, семантична узгодженість
Приклади застосування	Класифікація пацієнтів за симптомами, математичне моделювання	Виявлення емоцій у відео, медичні системи підтримки рішень

У сучасних інформаційних технологіях багатовимірні та мультимодальні дані відіграють важливу роль у створенні аналітичних систем, особливо в медицині, де важливі точність, масштабованість і прозорість рішень. Для роботи з такими даними потрібен інтегративний підхід, що поєднує різні форми подання інформації в єдиному аналітичному середовищі [149].

Багатовимірні дані відображають числові чи категоріальні характеристики об'єктів у вигляді векторів у багатовимірному просторі та застосовуються для класифікації, прогнозування й пошуку залежностей. Мультимодальні дані охоплюють різнорідні джерела – тексти, зображення, сигнали – і потребують використання методів машинного навчання, NLP та комп'ютерного зору [225, 302].

Як показано в таблиці 1.8, при аналізі ці типи даних мають суттєві відмінності, але в сучасних ІТ-рішеннях вони успішно поєднуються. Зокрема, багатовимірний аналіз використовується для числової підготовки перед інтеграцією з текстовими чи візуальними ознаками.

У дисертації запропонована технологія, що поєднує ці підходи, синхронізуючи багатовимірні параметри з семантичними описами з протоколів

чи візуальних даних. Це формує єдиний простір даних, підвищує інтерпретованість результатів і точність клінічних рішень.

У зв'язку з цим автор пропонує методологію, що поєднує концептуальну інтеграцію та багатовимірне структурування даних. Основні положення підходу такі:

- формування багатовимірних формальних контекстів, де кожна модальність (тип даних) виступає підконтекстом і синхронізується з іншими у спільному просторі;
- використання концептуального аналізу даних (CDA) як логічної основи для побудови ієрархії понять і прозорі структури знань;
- застосування методів зниження розмірності, зокрема PCA, для збереження релевантної інформації при мінімальних обчислювальних витратах;
- інтеграція інтерпретованої аналітики, що дозволяє пояснювати результати аналізу – кластеризацію пацієнтів, діагностичні шаблони чи нетипові випадки.

Такий підхід дає змогу створити інформаційну технологію, яка поєднує строгість концептуального аналізу з гнучкістю роботи з мультимодальними даними. У підсумку формується адаптивна система підтримки рішень, особливо актуальна для медичної інформатики. З огляду на різноманітність даних, автор пропонує уточнене трактування базових понять:

- Мультимодальні дані – це сукупність інформації з різних джерел (тексти, зображення, аудіо, сигнали, сенсори), які відрізняються природою, структурою та частотою оновлення. У межах запропонованої технології вони синхронізуються та консоліднуються в єдиному просторі.
- Багатовимірні дані – це структуровані множини вимірювань, де об'єкти описуються векторами ознак у високовимірному просторі. Вони формують основу для побудови формальних контекстів та концептуального структурування знань.

Таким чином, у дисертаційній роботі пропонується інтегрована модель, яка поєднує мультимодальність і багатовимірність, забезпечуючи ефективність,

прозорість та адаптивність аналізу в клінічних умовах. Синтез концептуальної строгості та гнучкості модальностей становить основу авторського підходу до розв'язання актуальних задач медичної інформатики.

1.6. Аналіз програмного забезпечення для обробки мультимодальних даних

Аналіз мультимодальних даних є складним та водночас надзвичайно актуальним напрямом у сучасній аналітиці, особливо в умовах зростання обсягів різнорідної інформації, що надходить із численних джерел. Мультимодальні дані охоплюють різні типи вхідної інформації, що потребують не лише уніфікованого представлення, але й гнучких засобів обробки. У сфері медичної інформатики це особливо важливо, оскільки об'єднання інформації з клінічних записів, результатів діагностичних тестів, біосигналів та зображень дозволяє досягти більшої точності діагностики й адаптивності клінічних рішень [205, 216].

Один із головних викликів мультимодального аналізу полягає в інтеграції даних, які відрізняються за структурою, форматом і семантикою. Для цього використовуються спеціалізовані програмні платформи, що забезпечують підготовку даних, побудову моделей і візуалізацію результатів.

Зокрема, RapidMiner є популярною платформою для побудови й валідації моделей машинного навчання, яка підтримує мультимодальний підхід. Вона пропонує інструменти для інтеграції текстових, числових і візуальних даних, а також засоби візуалізації результатів [201].

Інша платформа KNIME має велику бібліотеку модулів, що дозволяє виконувати повний цикл обробки даних: від збору й попередньої обробки до моделювання та візуалізації. KNIME підтримує інтеграцію з Python, R та бібліотеками глибокого навчання, що розширює її функціональність у роботі з мультимодальними структурами [201].

Ще одним зручним інструментом є Orange, який надає можливість створення графічних моделей і має простий візуальний інтерфейс для аналізу

даних. Orange підтримує модулі для текстової аналітики, обробки зображень і сигналів, що робить його корисним для інтерактивного аналізу та навчання.

Окремо варто відзначити методи глибинного аналізу, які орієнтовані на виявлення прихованих залежностей між різними модальностями. Такі підходи вимагають великих обсягів даних і складних алгоритмів, але відкривають нові можливості для інтерпретації комплексних зв'язків [154, 189].

Для якісного аналізу мультимодальних даних також застосовують QDA Miner – програмне забезпечення, що дозволяє обробляти тексти, графіку та аудіо в реальному часі. Його перевага – широкі можливості для інтерпретації та візуалізації, що робить його корисним у вивченні людської взаємодії та сприйняття [45, 69, 111].

Узагальнено, мультимодальний аналіз потребує поєднання методології та сучасних програмних засобів. Це забезпечує якісну інтеграцію різних типів даних і створює підґрунтя для ефективного вивчення складних процесів, зокрема в медицині.

Іншим поширеним інструментом для аналізу мультимодальних даних є NVivo, що підтримує якісний, кількісний та комбінований аналіз текстів, зображень і відео. Програма має широкий набір інструментів для обробки та візуалізації, дозволяє відстежувати теми, підтеми й коди, а також автоматично чи напівавтоматично кодувати великі обсяги даних [78, 125].

Ще одним важливим програмним засобом є Atlas.ti, орієнтований на якісний і кількісний аналіз мультимодальних даних. Він надає розширені можливості для візуалізації, вивчення зв'язків між різними елементами та інтерпретації складних структур даних [125].

Іншими корисними програмами для аналізу мультимодальних даних є Transana, TAMS Analyzer і ELAN. Transana дозволяє користувачам аналізувати звукові, відео- та текстові файли одночасно, забезпечуючи зручний інтерфейс для відстеження різних елементів даних. TAMS Analyzer надає користувачам можливість позначати сегменти даних різними кодами та тегами, що дозволяє аналізувати взаємодію між різними елементами мультимодальних даних. ELAN

спеціалізується на аналізі лінгвістичних даних, таких як мовлення, і надає користувачам можливість відстежувати відносини між мовними та немовними елементами даних [146, 167].

У контексті дисертаційного дослідження ці інструменти можуть бути адаптовані до побудови інформаційної технології, що об'єднує методи концептуального аналізу зі засобами мультимодальної обробки даних. Такий підхід відкриває нові можливості для створення адаптивних, інтерпретованих і масштабованих аналітичних систем, орієнтованих на медичні дані та підтримку прийняття клінічних рішень.

Для забезпечення ефективного аналізу даних у межах концептуального підходу важливо мати доступ до інструментів, які дозволяють працювати з формальними контекстами, будувати концептуальні решітки та візуалізувати структуру знань. З розвитком формального концептуального аналізу (FCA) було створено низку спеціалізованих програмних рішень, які підтримують як базові операції з формальними контекстами, так і складніші функції – аналіз імплікацій, багатомірне подання, роботу з нечіткими даними та інші [65, 72].

Нижче в таблиці 1.9 наведено огляд ключових характеристик програмних засобів, які активно використовуються в дослідницьких та прикладних задачах концептуального аналізу даних. Усі перелічені програми мають спільну функціональність у базовому наборі інструментів для роботи з формальними контекстами, також мають можливості, які роблять їх більш придатними до певних дослідницьких завдань. Наприклад, Galicia краще підходить для аналізу нечітких даних, тоді як ConExp є ідеальним варіантом для навчальних цілей. У рамках дисертаційного дослідження доцільним є застосування таких програм для побудови формалізованих структур знань, аналізу багатомодальних контекстів і створення інтерпретованих моделей підтримки прийняття рішень у медичних ІТ-системах.

З огляду на швидке зростання обсягів і складності інформаційних потоків, аналіз мультимодальних даних стає одним із ключових напрямів сучасних інтелектуальних технологій. Поєднання методів глибинного навчання,

концептуального структурування та візуалізації формує надійну основу для створення систем, у яких важливими є точність, прозорість та швидкість прийняття рішень [111, 129].

Таблиця 1.9

Програми концептуального аналізу даних

Назва програми	Характеристики
ToscanaJ [285]	Інструмент для аналізу та візуалізації формальних контекстів і їхніх залежностей. Підтримує побудову лінійних ієрархій, фільтрацію та моделювання концептуальних структур
Formal Concept Analysis Research Toolbox (FCART) [236]	Програма з відкритим кодом, що забезпечує повний набір інструментів для аналізу формальних контекстів, включаючи побудову імплікацій, решіток концептів та інтеграцію з мовами програмування
ConExp [242]	Зручний інструмент з графічним інтерфейсом для побудови решіток концептів, візуалізації контекстів і експорту графічних структур. Часто використовується в навчанні та наукових дослідженнях
Galicia [234]	Система, яка підтримує аналіз множинних контекстів, роботу з нечіткими концептами, розширене візуальне подання та інтерфейс редагування.
Concept Explorer [2, 11]	Інструмент з можливістю створення, редагування та аналізу формальних контекстів, побудови решіток і перевірки імплікацій. Має зручний редактор і підтримує експорт даних
Lattice Miner [13]	Сучасне програмне забезпечення для маніпуляцій з решітками концептів, аналізу імплікаційних баз і підтримки асоціативного аналізу
FcaStone [20]	Освітній та дослідницький інструмент із підтримкою збереження контекстів, аналізу атрибутів та побудови концептуальних структур

У цьому контексті значну роль відіграє аналіз підходів різних авторів до трактування мультимодальності. У таблиці 1.10 охарактеризовано методи обробки й аналізу мультимодальних даних, запропоновані провідними дослідниками, які відображають різні шляхи інтеграції та інтерпретації цього типу інформації.

Автори, що їх наведено в таблиці 1.10, представляють основні наукові підходи до побудови та аналізу мультимодальних даних. Кожен із них акцентує увагу на власному способі інтеграції: від поєднання ознак у спільному просторі до розробки спеціалізованих моделей для задач класифікації чи розпізнавання.

Таблиця 1.10

Аналіз методів обробки та аналізу мультимодальних даних

Автори	Аналіз методів обробки
Li, X., Ge, Y., Yi, K., Hu, Z., Shan, Y., Duan, L.-Y. [208]	Метод глибинного навчання мультимодальних даних, який поєднує різні види даних, такі як зображення, текст та звукові дані, у єдине просторово-часове представлення
Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., Ng, A. Y. [245]	Автори розробили модель Deep Multi-modal Neural Networks для класифікації зображень та звукових даних, яка може працювати з багатьма видами вхідних даних
Wang, Yu., Huang, R., Song, Sh., Huang, Z., Huang, G. [220]	Розроблено методику побудови мультимодальної архітектури для вирішення задач розпізнавання образів та відео за допомогою комбінації різних видів даних, таких як відео, текст та звук

Отже, огляд сучасних визначень і методів роботи з мультимодальними даними показує динамічний розвиток цього напрямку та підтверджує його важливість для створення ефективних, зрозумілих і адаптивних аналітичних технологій. У межах дисертаційного дослідження саме ці підходи стають підґрунтям для побудови інтегрованої системи аналізу складних медичних даних.

1.7. Аналіз існуючих підходів та інформаційних технологій обробки мультимодальних медичних даних

Стрімкий розвиток медичних інформаційних систем супроводжується зростанням обсягів даних різних модальностей, що створює нові виклики для їх інтеграції, обробки та аналізу. Ефективне вирішення завдань підтримки клінічних рішень потребує створення інформаційних технологій, здатних об'єднувати текстову, візуальну, аудіальну та сенсорну інформацію в єдиному аналітичному середовищі. Особливої актуальності ці питання набули у зв'язку зі швидким розвитком електронних медичних систем, біомедичних сенсорів та алгоритмів штучного інтелекту. Сучасні наукові дослідження дедалі більше зосереджуються на розробленні інформаційних технологій, які забезпечують комплексний багатовимірний аналіз мультимодальних даних, спрямований на підвищення точності, обґрунтованості та своєчасності прийняття медичних рішень [129, 137].

Аналіз існуючих підходів до обробки мультимодальних медичних даних демонструє широку міждисциплінарну базу досліджень, яка охоплює як

формальні методи структурування знань, так і сучасні технології штучного інтелекту. Ці підходи суттєво відрізняються за своєю природою від логічно-інтерпретованих моделей до високопродуктивних, проте менш пояснюваних глибинних архітектур. Водночас вони не виключають одне одного, а радше доповнюють, формуючи сучасну парадигму обробки складних, різномірних і великомасштабних медичних даних.

Одним із класичних і водночас інтерпретованих підходів є концептуальний аналіз даних (CDA), який ґрунтується на формальній теорії концептів, започаткованій Ganter і Wille [235]. CDA дозволяє побудувати ієрархію понять на основі формальних контекстів, що забезпечує прозорість логіки класифікації даних. У медичній сфері, де критично важливою є інтерпретованість рішень, цей підхід має особливу цінність. Наприклад, Priss запропонувала поєднувати CDA з онтологіями для узгодження термінології між різними джерелами медичних даних, що дозволяє будувати семантично цілісні системи [2].

У свою чергу, інтеграційно-семантичні підходи, представлені у працях Kress [12], Jewitt [22], Bezemer [24], O'Halloran [53], зосереджуються на взаємодії різних модальностей як носіїв значення. Такі підходи використовуються для формування єдиного семантичного простору на основі тексту, зображень, звуку, сенсорної інформації. У медичному контексті це дозволяє, наприклад, зіставляти МРТ-знімки з текстовими описами лікарів або поєднувати симптоматичні шкали з аудіозаписами консультацій.

Для подолання масштабності та складності даних, що характерно для медицини, активно використовуються методи багатовимірного статистичного аналізу, зокрема аналіз головних компонент (PCA) (Jolliffe) [29]. Ці методи дають змогу зменшити розмірність вхідних даних (наприклад, ЕЕГ або ЕКГ), зберігаючи водночас ключову інформацію для подальшого аналізу або класифікації.

На цьому фоні особливо активно розвиваються архітектури на основі глибинного навчання. Так, Ngiam (2011) [245] запропонували мультимодальні нейромережі, які дозволяють інтегрувати текст, аудіо та зображення для

створення єдиного представлення. Wang і колеги [40, 44] розширили ці підходи на відеодані та сигнали. В медицині такі нейромережі ефективно використовуються для автоматичної інтерпретації зображень (МРТ, КТ), аналізу електрофізіологічних сигналів і навіть емоційного стану пацієнта на основі мови.

Однак глибинні нейромережі часто розглядаються як «чорні скриньки», що ускладнює їхнє застосування в критичних сферах, де потрібна повна прозорість обґрунтувань. Це породжує потребу в гібридних моделях, які поєднують інтерпретованість концептуального аналізу з обчислювальною потужністю глибинного навчання. Саме до таких моделей належать ті, що базуються на багатовимірних формальних контекстах (Multidimensional FCA), де кожна модальність структурується окремо, але аналізується синхронно [2, 23].

Важливо також згадати практичні реалізації, такі як роботи Poelmans et al. [21], які впровадили CDA у криміналістиці, психіатрії та медичній інформатиці для виявлення патернів у поведінкових і діагностичних даних. Їх досвід доводить, що концептуальний підхід має не лише теоретичне, а й практичне значення у виявленні структурних залежностей у гетерогенних джерелах.

Не менш важливу роль відіграють інструменти візуалізації, зокрема ConExp, Galicia, FCART, які дають змогу досліднику не лише будувати концептуальні решітки, а й інтерактивно працювати з ними: переглядати логіку побудови понять, досліджувати їх включення, фільтрувати ознаки. У клінічній практиці це дозволяє візуалізувати типові профілі пацієнтів, виявляти відхилення, формувати гіпотези щодо нових діагностичних категорій [145].

Проведений огляд сучасних підходів до обробки мультимодальних медичних даних виявляє чотири основні напрями, що застосовуються в аналітичних системах: концептуальний аналіз даних (CDA), багатовимірний аналіз, глибинне навчання та гібридні підходи. Кожен із них має свої переваги та обмеження, які визначають його придатність у конкретних аналітичних сценаріях – від роботи з чітко структурованими числовими наборами до інтеграції складних, різнорідних медіаданих. У таблиці 1.11 представлено

порівняльну характеристику цих підходів з акцентом на ключові технічні та методологічні аспекти.

Таблиця 1.11

Аналіз підходів обробки мультимодальних даних

Підходи	Переваги	Недоліки
Концептуальний аналіз даних (CDA)	– Забезпечує високу інтерпретованість результатів; – Дозволяє виявляти ієрархічні концепти та логічні залежності між об'єктами та ознаками; – Підтримує семантичне узгодження інформації, що є критично важливим у медичній сфері.	– Обмежена масштабованість при роботі з великими обсягами даних; – Потребує попередньої нормалізації та структурування інформації.
Багатовимірний аналіз	– Добре працює з структурованими числовими даними (наприклад, показники здоров'я, біомаркери); – Дозволяє зменшити розмірність даних без значної втрати інформації; – Сприяє побудові прогнозних моделей.	– Погано працює з неструктурованими даними (зображення, текст, аудіо); – Інтерпретація результатів часто потребує додаткових аналітичних кроків.
Глибинне навчання та мультимодальні нейромережі	– Забезпечують високу точність класифікації та прогнозування; – Можуть обробляти гетерогенні дані одночасно (текст, зображення, звук, сигнали); – Добре масштабується на великі обсяги даних.	– Низька інтерпретованість (ефект “чорної скриньки”); – Високі вимоги до обчислювальних ресурсів; – Необхідність великого обсягу розмічених даних для навчання.
Гібридні підходи (Multidimensional FCA + AI)	– Поєднують точність глибинного навчання із пояснюваністю концептуальних моделей; – Підходять для синхронізації модальностей з різною структурою; – Дають змогу інтегрувати логіку, числові та семантичні структури в єдину аналітичну систему.	– Вимагають складного проєктування архітектури; – Складність у розробці та налаштуванні компонентів такої системи.

Проведений аналіз існуючих підходів до обробки мультимодальних медичних даних показав, що жоден з них не є універсальним або достатнім для повноцінної підтримки прийняття клінічних рішень в умовах складних інформаційних середовищ. Кожен підхід має свої сильні сторони, але також супроводжується суттєвими обмеженнями. Тому в межах дисертаційного

дослідження акцент зроблено на пошуку інтегративної технології, яка б об'єднала переваги різних методів і компенсувала їх недоліки [3, 20].

Зокрема, багатовимірний аналіз забезпечує ефективну обробку числових медичних показників, таких як результати лабораторних тестів, сигнали ЕКГ або ЕЕГ, біомаркери тощо. Ці методи дозволяють зменшити розмірність простору ознак, зберігаючи при цьому значущу інформацію, що є критичним для подальшого аналізу. Проте обмеження багатовимірного аналізу проявляються в роботі з неструктурованими даними, які є типовими для медичних інформаційних систем (наприклад, медичні зображення або текстові висновки – т.зв. заключення).

Натомість глибинне навчання дозволяє ефективно працювати з великими масивами гетерогенних даних, зокрема із зображеннями, текстами, аудіо- та сенсорними сигналами. Використання згорткових нейронних мереж, рекурентних моделей та трансформерів дозволяє виявляти складні нелінійні залежності та закономірності між модальностями. Однак ключовим недоліком цього підходу залишається низька інтерпретованість результатів. У клінічному контексті, де кожне рішення має бути обґрунтованим, це обмежує застосування виключно нейромережових рішень [220, 225].

Саме тут свою важливу роль відіграє концептуальний аналіз даних (CDA). Завдяки використанню формальних контекстів, ієрархій понять та логічних зв'язків між атрибутами, CDA дозволяє представити структуру знань у прозорий і зрозумілий спосіб. Це особливо важливо для клінічних фахівців, які потребують не лише результату, але й логічного пояснення того, як і чому він був отриманий. Однак CDA, як правило, не масштабуються на великі обсяги даних без попередньої трансформації та структуризації [20].

Виходячи з цього, найбільш перспективним напрямом є розроблення методології з комплексної обробки та аналізу мультимодальних даних, що поєднує в собі всі вищезазначені підходи:

- багатовимірну обробку числових показників для зменшення розмірності та підвищення якості входу для моделювання;

- глибинне навчання для виявлення складних патернів і обробки неструктурованих даних (зображення, текст, звук);
- концептуальний аналіз для структурування знань, інтерпретації результатів та побудови логічно обґрунтованих рішень.

Така синхронізація різних аналітичних стратегій дозволяє подолати основні обмеження традиційних методів і забезпечити високу точність, масштабованість та пояснюваність у процесі прийняття медичних рішень. Особливо актуальним це стає у випадках, коли йдеться про інтеграцію даних із різних джерел: біосигналів, зображень МРТ, текстових карт пацієнтів та голосових скарг. Усі ці дані, об'єднані в єдиному концептуальному просторі, дають змогу створити інтелектуальну аналітичну систему, яка не лише обробляє дані, а й формує висновки [124, 129].

Таким чином, авторське бачення полягає у формуванні гнучкої, адаптивної та інтерпретованої інформаційної технології, здатної працювати в умовах гетерогенності, неповноти та високої динамічності даних. Розроблена система є відповіддю на сучасні виклики медичної інформатики та створює основу для впровадження персоналізованих підходів до діагностики, лікування і моніторингу пацієнтів.

Однією з ключових складових цієї системи є обробка текстових медичних даних, які традиційно займають значний обсяг у структурі електронної медичної документації та відіграють важливу роль у процесах клінічного прийняття рішень. З огляду на критичну роль саме цієї модальності, особливу увагу в межах дисертаційного дослідження приділено аналізу методів її обробки. Застосування підходів обробки природної мови (NLP) дозволяє трансформувати неструктуровану текстову інформацію у формалізовані знання, які можуть бути безпосередньо використані в аналітичних модулях системи підтримки прийняття рішень. Водночас, проведений аналіз свідчить про низку викликів, пов'язаних із лексичною варіативністю, контекстною залежністю термінів і необхідністю точного кодування медичних понять [131].

У цьому контексті було систематизовано типові завдання, які розв’язуються в межах NLP у медицині, відповідні підходи до їх вирішення, а також ключові виклики, з якими стикаються дослідники та розробники при роботі з клінічними текстами.

Для узагальнення ключових особливостей аналізу текстових медичних даних у сфері NLP в таблиці 1.12 наведено основні завдання, методи та обмеження, притаманні цьому напрямку.

Таблиця 1.12

Завдання, методи та обмеження в аналізі текстових медичних даних (NLP)

Завдання	Методи	Обмеження
Витягування медичних концептів	Named Entity Recognition (NER), BioBERT, SciSpacy	Полісемія, синонімія, неповні або неоднозначні формулювання
Класифікація клінічних записів	Fine-tuning моделей BERT, LSTM-класифікатори	Дисбаланс класів, відсутність розмічених даних
Виявлення відношень між медичними поняттями	Relation Extraction, Knowledge Graph Embeddings	Контекстна залежність термінів, складність семантичного узгодження
Анонімізація даних	Rule-based підходи, ML-моделі для детекції персональних даних	Збереження значущих даних при видаленні конфіденційної інформації
Кодування за міжнародними класифікаціями	Mapping до ICD-10/ICD-11, SNOMED CT, використання медичних онтологій	Висока складність мапування, лексичне розмаїття

Таким чином, аналіз NLP у контексті медичних даних підтверджує необхідність розробки спеціалізованих моделей, орієнтованих на доменну специфіку галузі охорони здоров’я. Інтеграція таких моделей у загальну архітектуру мультимодального аналізу є наступним кроком у напрямі створення цілісної інтелектуальної інформаційної системи підтримки медичних рішень.

Разом із розвитком технологій обробки текстових даних значного поширення набули дослідження у сфері обробки візуальної медичної інформації, яка включає дані комп’ютерної томографії (КТ), магнітно-резонансної томографії (МРТ), ультразвукової діагностики (УЗД) та інших джерел візуалізації. Технології комп’ютерного зору та методи глибинного навчання, зокрема згорткові нейронні мережі (англ. Convolutional neural network, CNN)

[141], активно застосовуються для автоматичного виявлення патологій, сегментації анатомічних структур і побудови тривимірних моделей. При цьому виникають певні виклики, пов'язані з варіативністю якості отриманих зображень і потребою у великих анованих наборах даних для навчання моделей. Узагальнену характеристику підходів і викликів у цьому напрямку наведено в таблиці 1.13.

Таблиця 1.13

Аналіз підходів, методів і обмежень обробки візуальних медичних даних	
Категорія	Опис
Основні завдання обробки візуальних медичних даних	– Сегментація органів і патологічних утворень на медичних зображеннях – Автоматичне виявлення ознак захворювань, таких як пухлини, запальні процеси та ураження судин – Класифікація медичних знімків за типами патологій – Побудова тривимірних реконструкцій на основі серій двовимірних зображень
Основні технології	– Згорткові нейронні мережі (CNN) для розпізнавання зображень – Моделі сегментації (U-Net, Mask R-CNN) – Алгоритми глибинного навчання для мультикласової класифікації
Основні виклики	– Потреба у великих обсягах анованих даних для навчання – Варіативність якості зображень залежно від обладнання – Необхідність стандартизації форматів зображень (DICOM та інші)

Обробка візуальних медичних даних сприяє підвищенню точності діагностики та дозволяє зменшити навантаження на лікарів за рахунок автоматизації аналізу візуальної інформації.

Поряд із візуальними даними, важливим джерелом медичної інформації є аудіальні сигнали, що містять відомості про функціонування серцево-судинної та дихальної систем пацієнтів, а також про особливості їхнього мовлення. Аналіз аудіальних даних ґрунтується на спектральних методах та нейронних мережах Recurrent neural network (RNN) та Long short-term memory (LSTM) [132], проте має низку викликів, зокрема чутливість до шумів і варіативність умов запису.

Узагальнений огляд основних підходів і викликів обробки аудіальних медичних даних наведено в таблиці 1.14.

Обробка аудіальних даних у медицині відкриває нові можливості для неінвазивної діагностики, підвищення доступності медичних послуг, а також розвитку систем дистанційного моніторингу пацієнтів на основі аналізу звукової інформації.

Таблиця 1.14

Аналіз підходів, методів і викликів обробки аудіальних медичних даних

Категорія	Опис
Основні завдання обробки аудіальних медичних даних	– Діагностика серцево-судинних захворювань на основі аналізу фонокардіограм – Виявлення патологій дихальної системи через обробку легеневих шумів – Скринінг неврологічних та психічних розладів шляхом аналізу мовлення пацієнтів
Основні методи обробки аудіо	– Спектральний аналіз сигналів (застосування перетворення Фур'є, мел-частотних кепстральних коефіцієнтів – MFCC) – Використання рекурентних нейронних мереж (RNN, LSTM) для обробки послідовностей аудіосигналів – Методи класифікації аудіальних даних на основі технологій глибокого навчання
Основні виклики	– Підвищена чутливість до фонових шумів і перешкод – Варіативність акустичних характеристик залежно від умов та якості запису – Необхідність створення високоякісних анотованих наборів даних для навчання моделей

Поряд з обробкою аудіосигналів активно розвивається напрям інтеграції та аналізу сенсорних і фізіологічних даних, що надходять від пульсометрів, глюкометрів та моніторів фізичної активності [133, 135]. Їх обробка передбачає використання методів аналізу часових рядів, виявлення аномалій та побудови прогнозних моделей стану пацієнтів. Водночас робота з сенсорними потоками даних супроводжується низкою викликів, серед яких особливе місце займають проблеми синхронізації інформації з різних джерел, обробки великих обсягів даних у режимі реального часу та забезпечення конфіденційності персональної медичної інформації.

Основні підходи до інтеграції сенсорних даних у медичних інформаційних системах, а також супутні проблеми й виклики узагальнено у таблиці 1.15.

Таким чином, інтеграція сенсорних та фізіологічних даних є стратегічним напрямом розвитку сучасних інформаційних технологій у медицині, оскільки

вона сприяє підвищенню точності діагностики, персоналізації лікувальних підходів та своєчасності прийняття клінічних рішень.

Таблиця 1.15

Аналіз підходів, методів і викликів інтеграції сенсорних даних
у медичних системах

Категорія	Опис
Основні завдання інтеграції сенсорних даних	– Безперервний моніторинг життєво важливих параметрів пацієнтів у режимі 24/7 – Раннє виявлення змін у фізіологічному стані, що можуть сигналізувати про розвиток критичних ситуацій – Прогнозування ризиків виникнення захворювань на основі аналізу часових рядів фізіологічних даних
Основні методи обробки сенсорних даних	– Аналіз часових рядів і фільтрація сигналів для виявлення трендів і аномальних змін – Використання алгоритмів машинного навчання для класифікації станів пацієнтів – Побудова прогнозних моделей на основі історичних фізіологічних записів
Основні виклики інтеграції сенсорних даних	– Необхідність синхронізації потоків даних, що надходять із різною частотою та затримкою – Обробка великих обсягів даних у режимі реального часу – Забезпечення безпеки та конфіденційності персональної фізіологічної інформації

Особливо складним завданням залишається об'єднання даних різних модальностей в єдине аналітичне середовище. Для розв'язання цієї проблеми застосовуються різноманітні стратегії інтеграції: об'єднання ознак шляхом конкатенації векторних представлень, інтеграція на рівні прийняття рішень за допомогою агрегування результатів окремих моделей, а також побудова спільного простору ознак методом спільної репрезентації (joint embedding). Для забезпечення комплексної обробки мультимодальної інформації активно розробляються багатовхідні нейронні мережі, мультимодальні трансформерні архітектури та ансамблеві методи. Водночас процес інтеграції ускладнюється через відмінності у форматах даних, їх структурі та відсутність уніфікованих стандартів синхронізації. Основні методи та виклики інтеграції мультимодальних даних у медичних інформаційних системах наведено в таблиці 1.16.

Ефективна інтеграція мультимодальних медичних даних є важливою умовою створення комплексних аналітичних систем, які сприяють підвищенню

точності діагностики, покращенню прогнозування перебігу захворювань і підвищенню якості прийняття клінічних рішень. Проведений аналіз літературних джерел засвідчив, що інформаційні технології обробки мультимодальних медичних даних активно розвиваються і охоплюють широкий спектр методів роботи з текстовими, візуальними, аудіальними та сенсорними даними. Використання сучасних алгоритмів машинного навчання, технологій комп'ютерного зору, обробки природної мови та глибоких нейронних мереж дозволяє суттєво підвищити ефективність діагностики, прогнозування і підтримки прийняття медичних рішень [145, 163].

Таблиця 1.16

Аналіз методів і викликів інтеграції мультимодальних даних у медичних інформаційних системах

Категорія	Опис
Основні методи інтеграції мультимодальних даних	– Інтеграція на рівні ознак шляхом конкатенації векторних представлень даних різних модальностей – Об'єднання результатів через незалежну обробку даних кожної модальності з подальшою агрегацією результатів на рівні прийняття рішень – Створення спільного простору ознак (joint embedding) для полегшення комплексного аналізу мультимодальної інформації
Основні підходи до інтеграції	– Застосування багатовхідних нейронних мереж із подальшим об'єднанням ознак на прихованих шарах – Розробка мультимодальних трансформерних архітектур (наприклад, Multimodal Transformers) – Використання ансамблевих методів для комбінування результатів моделей, побудованих для різних типів даних-Багатовхідні нейронні мережі з об'єднанням на прихованих шарах – Мультимодальні трансформери (ММТ, Multimodal Transformers) – Ансамблеві методи для об'єднання результатів моделей
Основні виклики виклики інтеграції мультимодальної інформації	– Різниця у структурі, обсягах та якості даних залежно від типу модальності – Труднощі синхронізації інформації, отриманої у різні часові моменти або за різних умов – Необхідність стандартизації форматів і протоколів даних для забезпечення сумісності систем

Водночас аналіз показав, що існуючі підходи мають низку обмежень, серед яких слід відзначити такі: складність інтеграції різнорідних даних через відмінності у їхній структурі та форматах; високі вимоги до обчислювальних

ресурсів для обробки великих обсягів мультимодальної інформації; потреба у стандартизації протоколів збору та обробки даних; необхідність забезпечення конфіденційності персональної медичної інформації.

Інтеграція мультимодальних даних у медичних інформаційних системах є предметом досліджень вже протягом кількох десятиліть. Проте більшість існуючих рішень залишаються обмеженими вузькою спеціалізацією (наприклад, тільки обробка МРТ або ЕКГ) або застосовують уніфіковані статистичні методи без врахування специфіки багатовимірності та необхідності синхронізації потоків даних [146, 220].

Аналіз сучасних підходів до інтеграції медичних даних, наведених в таблиці 1.17, демонструє, що, незважаючи на успіхи окремих систем, таких як IBM Watson Health, DeepMind Health чи TensorFlow Healthcare, більшість із них мають істотні обмеження щодо глибини мультимодальної інтеграції, гнучкості, масштабованості та адаптивності до клінічних умов.

Виконаний аналіз сучасних підходів засвідчив, що, попри суттєві досягнення у розвитку методів обробки окремих типів медичних даних, залишаються актуальними такі проблеми:

- складність повної інтеграції даних різної природи;
- недостатня адаптивність до неповних або зашумлених даних;
- висока обчислювальна складність обробки великих масивів мультимодальної інформації;
- складність синхронізації часових потоків даних.

Таким чином, подальший розвиток інформаційних технологій обробки мультимодальних медичних даних має бути спрямований на створення гнучких, адаптивних і масштабованих систем, здатних забезпечити комплексний багатовимірний аналіз різномірної медичної інформації з високою точністю підтримки клінічних рішень.

Таблиця 1.17

Порівняльний аналіз сучасних підходів до інтеграції медичних даних

Назва платформи	Основні характеристики	Переваги	Обмеження
IBM Watson Health	Комплексний аналіз структурованих і неструктурованих даних, підтримка прийняття клінічних рішень	Потужні можливості аналізу текстової та візуальної інформації, інтеграція з електронними медичними записами (EHR)	Висока вартість впровадження, закритість вихідного коду, обмежена адаптація до місцевих стандартів
DeepMind Health (Google)	Застосування глибокого навчання для обробки медичних зображень (зокрема МРТ, офтальмологія)	Висока точність результатів у спеціалізованих галузях, активна співпраця з медичними установами	Орієнтованість виключно на візуальні дані, обмежена мультимодальність
HealthNet AI	Інтеграція біомедичних сигналів (ЕКГ, пульс), використання нейронних мереж	Підтримка моніторингу в реальному часі, висока масштабованість	Відсутність повної інтеграції з іншими типами медичних даних (наприклад, ЕЕГ, МРТ)
TensorFlow Healthcare (Google)	Платформа для розробки моделей машинного навчання для медичних даних	Відкрите програмне забезпечення, підтримка роботи з великими наборами даних, активна спільнота розробників	Високі вимоги до кваліфікації користувачів, відсутність вбудованої інфраструктури
Philips HealthSuite	Хмарна платформа для збору даних з медичних пристроїв і аналітики в реальному часі	Ефективна підтримка носимих пристроїв, обробка даних у режимі реального часу	Обмежені можливості для глибокої багатомодальної обробки складних даних
BioMind	Інтеграція МРТ-сканів, історії хвороб і лабораторних даних для діагностики	Висока точність у нейрологічних дослідженнях, ефективне об'єднання різномірних джерел	Обмежена гнучкість у роботі з нестандартними даними, закритість алгоритмів

Це зумовлює потребу у створенні нових підходів, що поєднують переваги існуючих технологій із сучасними вимогами медицини. Насамперед ідеться про гнучкість, масштабованість, інтерпретованість рішень і можливість працювати з неповними або зашумленими даними.

У межах цього дисертаційного дослідження запропоновано інформаційну технологію багатовимірної аналізи мультимодальних даних, яка базується на принципах синхронізованої обробки, концептуального структурування знань і інтеграції різномірних джерел інформації в єдиний логічно-обґрунтований

простір. Такий підхід дозволяє сформувати нову якість аналітичної підтримки у клінічних системах, підвищити достовірність діагностичних висновків і адаптуватися до складних та динамічних медичних сценаріїв.

1.8. Формулювання науково-прикладної проблеми дослідження

У сучасних умовах інтенсивного розвитку інформаційних технологій та зростання обсягів даних виникає необхідність обробки великої кількості різнорідної інформації, зокрема у сфері медицини, де критично важливою є точність, швидкість та адаптивність прийняття рішень. Медичні інформаційні системи працюють в умовах інтеграції даних із різних джерел: текстових записів, зображень, аудіо- та відеосигналів, сенсорних потоків тощо. Наявні технології та алгоритми часто не враховують особливості різнотипових даних і не забезпечують комплексного багатовимірного аналізу. Це призводить до втрати важливої інформації, зниження точності прогнозування та недостатньої гнучкості при прийнятті медичних рішень.

Окрім цього, сучасні аналітичні моделі, як правило, не враховують можливості багатокритеріального вдосконалення, що дозволяє встановити баланс між точністю, швидкістю, обчислювальними ресурсами та адаптивністю. Таким чином, існує потреба у розробленні нової інформаційної технології, яка поєднуватиме методи багатовимірного аналізу та принципи багатокритеріальної ефективності з урахуванням особливостей мультимодальних медичних даних.

Важливим чинником є гетерогенність джерел – інформація має різну природу, структуру, частоту оновлення, рівень достовірності, що ускладнює її узгодження та інтеграцію. У зв'язку з цим виникає необхідність розроблення нових моделей, які враховують взаємозв'язки між модальностями та забезпечують цілісне уявлення про об'єкт дослідження.

Потреба в забезпеченні високої точності та адаптивності рішень є особливо актуальною для медицини, де ціна помилки може бути критичною. Традиційні алгоритми не завжди справляються з високим рівнем невизначеності, тому

застосування принципів багатокритеріального вдосконалення дає змогу оптимізувати співвідношення між точністю, швидкістю та ефективністю.

Ще одним важливим аспектом є обмеження обчислювальних ресурсів у реальних умовах експлуатації інформаційних систем. Це зумовлює необхідність використання технологій паралельної та розподіленої обробки даних, зокрема в середовищах, подібних до Apache Spark, що дає змогу зменшити затримки при обробці великих масивів медичної інформації.

Розв'язання означених проблем можливе за умови створення інтегрованої інформаційної технології, яка об'єднує методи синхронізації, класифікації, прогнозування та підтримки прийняття рішень у єдиній системі. Також важливим чинником успішного розвитку обраного напрямку дослідження є його міждисциплінарність – поєднання знань із галузей медицини, штучного інтелекту, комп'ютерних наук, аналізу даних і прикладної математики, що дозволяє формувати нові ефективні методологічні та технологічні рішення.

Актуальність проблеми полягає у необхідності розроблення інформаційної технології багатовимірному аналізу мультимодальних медичних даних, яка б відповідала сучасним вимогам до точності, швидкодії, адаптивності, масштабованості та ефективного використання обмежених обчислювальних ресурсів. В умовах стрімкого зростання обсягів і різноманітності медичної інформації, а також відсутності комплексних моделей і методів, здатних інтегрувати дані з різних джерел у єдиному аналітичному середовищі, створення такої технології є необхідною передумовою для забезпечення високої якості підтримки прийняття клінічних рішень.

Відтак, подальший розвиток інформаційних технологій, орієнтованих на обробку мультимодальних даних у медичній сфері, обумовлює протиріччя між зростаючими вимогами до точності, швидкості та адаптивності систем аналізу даних і обмеженими можливостями традиційних підходів до їх реалізації. Це створює необхідність у формуванні нових методологічних підходів, що дозволяють не лише інтегрувати дані з різних джерел, але й забезпечувати комплексну, масштабовану підтримку прийняття рішень у сфері медичних

послуг. Тобто, наявна важлива науково-прикладна проблема – протиріччя між обмеженнями традиційних методів аналізу мультимодальних даних та необхідністю відповідати сучасним вимогам до точності, швидкості й адаптивності інформаційних технологій.

Таким чином, сформульоване нами протиріччя між обмеженими можливостями традиційних моделей та методів аналізу медичних даних, з одного боку, і необхідністю задоволення зростаючих вимог клінічних практиків, дослідників та організацій охорони здоров'я – з іншого, можливо подолати через вирішення актуальної **науково-прикладної проблеми** – розроблення методології, на основі якої можливо створити інформаційну технологію для інтеграції, обробки та аналізу мультимодальних медичних даних.

Гіпотеза дослідження полягає у припущенні, що об'єднання результатів обробки кількох модальностей із різною природою в межах єдиної інформаційної технології, яка реалізує взаємне доповнення даних за допомогою багатовимірного аналізу, дає змогу збільшити кількість правильно класифікованих станів пацієнта.

Висновки до розділу 1

У розділі 1 дисертаційної роботи проведено комплексний огляд теоретичних засад, практичних підходів і проблемних аспектів, пов'язаних із обробкою мультимодальних медичних даних. Аналіз охоплює як особливості самих даних, так і наявні технології, методи інтеграції, вимоги до точності, адаптивності та інтерпретованості, а також теоретичні підходи до моделювання знань. За результатами аналізу сформульовано наступні висновки:

1. Досліджено, що мультимодальні медичні дані характеризуються високим ступенем структурної та семантичної неоднорідності, різним форматом подання, а також різною частотою надходження й точністю. Джерела таких даних включають текстову інформацію (медичні протоколи, анамнези), числові вимірювання (результати аналізів), сигнали (ЕЕГ, ЕКГ) і зображення (МРТ, КТ). Через таку різноманітність особливої актуальності набуває розробка адаптивних

аналітичних систем, здатних забезпечити інтеграцію, повноту, узгодженість і збереження клінічного контексту даних. Визначено, що ефективна обробка потребує високого рівня автоматизації, точності, адаптивності до змін у даних, а також здатності до інтерпретації результатів медичними фахівцями.

2. Проаналізовано існуючі підходи до обробки мультимодальних даних, які поділяються на методи ранньої, пізньої інтеграції, гібридні глибокі архітектури (CNN, LSTM, трансформери) та статистично-логічні підходи. Розглянуто їхні можливості в забезпеченні узгодженості ознак і підтримки семантичних зв'язків між модальностями. Встановлено, що хоча сучасні глибокі моделі демонструють високу точність, вони часто є «чорними скриньками», що ускладнює їхнє впровадження в медичну практику через низьку інтерпретованість. Підкреслено необхідність розробки комбінованих моделей, які забезпечують баланс між точністю, гнучкістю й прозорістю.

3. Виявлено, що сучасні інформаційні технології, застосовувані в медицині (клінічні інформаційні системи, хмарні сервіси, програмні фреймворки), здебільшого орієнтовані на обробку окремих типів даних і рідко забезпечують повноцінну мультимодальну інтеграцію. Встановлено потребу в інформаційних системах нового покоління, які будуть здатні до семантичного аналізу, інтерпретації та візуалізації структурованих і неструктурованих мультимодальних даних у єдиному середовищі.

4. В роботі досліджувалось питання забезпечення узгодженості, синхронності та логічної цілісності при об'єднанні даних з різних джерел. Встановлено, що проблема інтеграції виникає через різну частоту вимірювання, формати, структуру й відсутність єдиного часово-просторового каркасу. Розглянуто типові техніки вирівнювання даних: ресемплінг, нормалізація, крос-кореляційний аналіз. Однак зазначено, що ці методи не враховують семантичних аспектів, що є критичним у клінічному аналізі. Підкреслено доцільність впровадження формальних моделей, здатних інтегрувати структурну та семантичну інформацію в уніфіковану модель даних.

5. Проаналізовано три базові вимоги до сучасних моделей: адаптивність (здатність моделі змінювати поведінку без повного перенавчання), точність (особливо важлива для клінічного застосування) та інтерпретованість. Показано, що традиційні підходи не здатні одночасно забезпечити всі ці вимоги. Розглянуто приклади інтерпретованих моделей, що поєднують правила, онтології, attention-механізми та дерева рішень. Наголошено на перспективності комбінованих підходів, які дозволяють досягти балансу між гнучкістю глибокого навчання та прозорістю формального моделювання.

6. Систематизовано понятійний апарат концептуального аналізу даних (CDA): об'єкти, атрибути, формальні контексти, концепти, решітки та асоціації. Показано, як ці інструменти дозволяють формалізувати знання, структурувати дані та виявляти закономірності. Представлено багатовимірне розширення – Multidimensional Formal Context Analysis (MFCA), яке дозволяє одночасно враховувати кілька вимірів даних (модальність, час, джерело, клінічний сценарій). У поєднанні з методами багатовимірного аналізу MFCA забезпечує гнучке, інтерпретоване й масштабоване представлення знань.

7. На підставі порівняльного аналізу зроблено висновок, що більшість сучасних технологій не забезпечує глибокої інтеграції між модальностями, а також не дає достатньої інтерпретованості результатів. Багато рішень є вузькоспеціалізованими, слабо адаптованими до зміни даних та клінічного середовища. Обґрунтовано потребу в створенні нової інформаційної технології, яка б поєднувала концептуальне моделювання, багатовимірне представлення знань та гнучку обробку структурно неоднорідних даних.

Результати досліджень за першим розділом опубліковано в роботах автора [11, 14, 19, 20, 21, 27, 31] (Додаток Б).

РОЗДІЛ 2

ТЕОРЕТИЧНІ ОСНОВИ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ БАГАТОВИМІРНОГО АНАЛІЗУ МУЛЬТИМОДАЛЬНИХ ДАНИХ

У розділі сформовано теоретичну й методологічну основу для створення інформаційної технології багатовимірного аналізу мультимодальних медичних даних. Запропоновано формалізоване подання ключових компонентів системи – векторів ознак, функцій моделювання, механізмів інтеграції та пояснюваності, що дає цілісне уявлення про її архітектуру.

На основі гіпотези про підвищення точності класифікації станів пацієнтів завдяки інтеграції даних різних типів сформовано концепцію багатовимірного аналізу. Вона базується на об'єднанні часових, просторових, семантичних і статистичних ознак у єдиний узгоджений простір, що підвищує інформативність і надійність моделей.

Визначено основні принципи роботи технології: узгодженість даних, багатокритеріальність оцінки, стійкість до неповноти, адаптивність до змін структури, масштабованість для великих обсягів медичної інформації та інтерпретованість результатів.

Узагальнено методологію побудови системи, яка охоплює вибір моделей машинного навчання, методів об'єднання прогнозів, засобів пояснюваності та критеріїв ефективності. Таким чином, розділ формує наукове підґрунтя для створення інформаційної технології, здатної працювати з великими, різнорідними й складними медичними даними.

2.1. Формалізація інформаційної технології багатовимірного аналізу мультимодальних медичних даних

У сучасних умовах функціонування медичних інформаційних систем зростає потреба в обробці великих обсягів різнорідних даних, що надходять з різних джерел: електронних медичних карток, лабораторних систем, систем візуалізації, біосенсорів тощо. Такі дані мають різну природу та утворюють

мультимодальний інформаційний простір, в якому клінічні характеристики пацієнта представлені у розподіленому вигляді.

Аналіз мультимодальних даних ускладнюється гетерогенністю форматів, відсутністю синхронізації, відмінністю масштабів і часових інтервалів, що створює методологічні та технологічні виклики для створення єдиної аналітичної системи. У зв'язку з цим виникає необхідність у побудові формалізованої основи для представлення, обробки та класифікації мультимодальних даних у межах єдиного ознакового та семантичного простору.

Завдання багатовимірної аналізу мультимодальних медичних даних полягає у побудові інформаційної технології, здатної забезпечити узгоджену інтеграцію, обробку та інтерпретацію даних з різномірних модальностей для прийняття рішень.

У контексті математичної постановки ця задача формалізується як модель класифікації, що ґрунтується на об'єднаному ознаковому представленні мультимодального об'єкта.

Нехай:

- $M = \{M_1, M_2, \dots, M_k\}$ – множина модальностей (наприклад, текст, сигнал, зображення, числові параметри);
- $X_i = \{x_{i1}, x_{i2}, \dots, x_{in_i}\}$ – множина ознак, отриманих з модальності M_i , $i = 1, \dots, k$;
- $X = \bigcup_{i=1}^k X_i$ – узагальнений ознаковий простір, що включає всі ознаки з усіх модальностей після попередньої обробки, вирівнювання та уніфікації.

Таким чином, кожен об'єкт (пацієнт) описується вектором:

$$x = [x_1, x_2, \dots, x_n] \in R^n, \quad (2.1)$$

де $n = \sum_{i=1}^k n_i$ – загальна кількість ознак після уніфікації та нормалізації.

- $Y = \{y_1, y_2, \dots, y_c\}$ – множина класів клінічного стану пацієнта.

Формально, завдання полягає у побудові відображення:

$$f: X \rightarrow Y, \quad (2.2)$$

де:

- f – функція класифікації, яка встановлює відповідність між вектором ознак $x \in X$ та відповідним класом $y \in Y$.
- $f(x) = \hat{y}$, де $\hat{y}$ – передбачуваний клінічний стан пацієнта.

Функція f реалізується у вигляді моделі машинного навчання, яка навчається на множині навчальних прикладів $\{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\}$, де кожен об'єкт має повне мультимодальне подання.

З огляду на те, що кожна модальність $M_i \in M$ відображає лише часткову проекцію клінічного стану пацієнта, жодна з них окремо не забезпечує достатньої повноти та достовірності для прийняття обґрунтованого рішення. Це обумовлює необхідність інтеграції інформації з різнорідних джерел з метою формування цілісного ознакового опису.

У запропонованій інформаційній технології така інтеграція здійснюється за допомогою стратегій об'єднання мультимодальних даних, які визначають спосіб формування єдиного представлення на основі ознак чи моделей, отриманих із різних модальностей. Вибір стратегії об'єднання істотно впливає на:

- здатність системи працювати за умов неповних або втрачених даних;
- прозорість та інтерпретованість рішень;
- стійкість до конфліктної чи надлишкової інформації;
- адаптивність до різних клінічних ситуацій.

У цьому дослідженні розглянуто три підходи до поєднання модальних даних: ознакове поєднання (early fusion) – інтеграція на рівні ознак; модельне поєднання (late fusion) – інтеграція на рівні рішень моделей; адаптивне поєднання (adaptive fusion) – гібридна стратегія з динамічним вибором підходу залежно від умов задачі.

1. Ознакове поєднання, або раннє злиття (early fusion), передбачає інтеграцію різнорідних модальностей $M_1, M_2, \dots, M_k$ ще на етапі входу в модель, до виконання основної аналітичної обробки. Це означає, що об'єднання даних

відбувається до процесів навчання, класифікації – на рівні ознак, отриманих після первинної векторизації.

Для кожної модальності M_i формується множина ознак:

$$X_i = \{x_{i1}, x_{i2}, \dots, x_{in_i}\}, x_{ij} \in R, i = 1, \dots, k. \quad (2.3)$$

З метою забезпечення узгодженості та однакової шкали впливу ознак виконуються попередня обробка (preprocessing):

- Нормалізація:

$$x'_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j}, \quad (2.4)$$

де μ_j, σ_j – середнє та стандартне відхилення по вибірці.

- Масштабування до єдиного діапазону (наприклад, $[0;1]$):

$$x''_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)}. \quad (2.5)$$

- Синхронізація: прив'язка до уніфікованої часової шкали у разі сигналів та динамічних ознак.

Наступним етапом є формування об'єднаного вектора ознак. В процесі виконується конкатенація всіх ознак у єдиний вектор:

$$x = [x_{11}, x_{12}, \dots, x_{1n_1}, \dots, x_{k1}, \dots, x_{kn_k}]^T \in R^n, n = \sum_{i=1}^k n_i. \quad (2.6)$$

На основі вибірки з m об'єктів будується класифікаційна модель:

$$D = \{(x^{(j)}, y^{(j)}) \mid x^{(j)} \in R^n, y^{(j)} \in Y, j = 1, \dots, m\}, \quad (2.7)$$

та здійснюється навчання моделі $f: R^n \rightarrow Y$ методом мінімізації функції втрат:

$$f^* = \arg \min_{f \in F} L(f(x^{(j)}), y^{(j)}) + \lambda \cdot \Omega(f), \quad (2.8)$$

де:

- L – функція втрат (наприклад, крос-ентропія для класифікації),
- $\Omega(f)$ – регуляризатор для уникнення перенавчання,
- $\lambda \in R_+$ – коефіцієнт регуляризації.

Для нового пацієнта з вхідними даними з модальностей $\{M_1, \dots, M_k\}$, відбуваються ті самі кроки: ознакове представлення x та прогноз: $\hat{y} = f(x)$.

При злитті на рівні входу всі модальності об'єднуються перед подальшою обробкою моделі (Рис. 2.1). Цей підхід об'єднує різні типи даних на ранньому етапі, тобто ще до їх обробки. Наприклад, властивості текстових та візуальних даних можна з'єднати в один вектор, який потім передається в модель для подальшого навчання. Припустимо, M_1 – це текстові дані, а M_2 – це зображення. Текстова модальність обробляється через текстовий векторизатор наприклад, TF-IDF або Word2Vec, а зображення перетворюються у вектори ознак за допомогою CNN (англ. Convolutional Neural Network). Після векторизації обох модальностей отримано вектори: $Z_1 = f_1(M_1)$, $Z_2 = f_2(M_2)$.

Наступним етапом є об'єднання модальностей $x = [x_1; x_2]$ у вектор та передавання його у модель: $\hat{y} = f(x)$, наприклад, повнозв'язну нейронну мережу або іншу модель машинного навчання, яка обробляє текст та зображення одночасно.




Рис. 2.1. Формальне представлення ознакового поєднання модальних даних

2. Модельне поєднання або пізнє злиття (late fusion) – це стратегія, при якій кожна модальність M_i обробляється незалежно, із застосуванням окремої моделі f_i , а об'єднання результатів виконується на фінальному етапі прийняття

рішення. Такий підхід дозволяє зберегти специфіку кожної модальності та адаптувати аналітичні методи під її особливості [254, 259, 263].

Нехай:

- $X_i \in R^{n_i}$ – простір ознак, отриманих з модальності M_i , де $i = 1, \dots, k$;
- $f_i: X_i \rightarrow R^c$ – модель (класифікатор) для i -тої модальності, яка повертає вектор оцінок (наприклад, ймовірностей приналежності до кожного з класів);
- $f_i(X_i) = p_i = [p_{i1}, p_{i2}, \dots, p_{ic}] \in R^c$, де p_{ij} – оцінка того, що об'єкт належить до класу $y_j \in Y$.

Після отримання прогнозів від кожної модальності застосовується функція агрегації Φ , яка комбінує ці результати в остаточне передбачення:

$$f(X_1, X_2, \dots, X_k) = \Phi(f_1(X_1), f_2(X_2), \dots, f_k(X_k)) = \hat{y}, \hat{y} \in Y. \quad (2.9)$$

Визначення агрегуючої функції Φ може бути реалізоване як:

- зважене голосування: $\hat{y} = \arg \max_{y_j \in Y} \sum_{i=1}^k w_i \cdot p_{ij}$, де w_i – ваговий коефіцієнт довіри до модальності i ;
- мета-класифікатор (stacking): вектори прогнозів $p_1, \dots, p_k$ подаються на вхід мета-моделі: $\hat{y} = f_{meta}([p_1 \parallel p_2 \parallel \dots \parallel p_k])$.

Для кожної модальності отримуємо вектор ймовірностей $p_1, p_2, p_3 \in R^c$, які подаються у функцію Φ для отримання остаточного класу $\hat{y}$.

Пізнє злиття (late fusion) обробляє кожну модальність окремо та комбінує прогнози на кінцевому етапі (Рис. 2.2).



Рис. 2.2. Формальне представлення модельного поєднання мультимодальних даних

Отже, технологія раннього злиття підходить для завдань, де модальності мають багато спільних ознак та можуть представлятись в одній векторній формі. Проте технологія пізнього злиття частіше використовується, коли модальності сильно відрізняються одна від одної (наприклад, зображення та звук), а їхня окрема обробка дає кращі результати.

3. Адаптивне поєднання (adaptive fusion) – це стратегія, за якої динамічно обирається найдоцільніший спосіб інтеграції мультимодальних даних (ознаковий, модельний) залежно від поточного контексту задачі, характеристик даних і доступних ресурсів. Такий підхід реалізує функцію адаптивного керування стратегією злиття: $\psi: C \rightarrow \{\text{ознакове, модельне}\}$, де: C – множина умов і контекстних факторів, ψ – адаптивний механізм вибору стратегії злиття.

Приклади умов C :

- повнота даних: наявність або відсутність окремих модальностей (наприклад, відсутній сигнал ЕКГ);
- якість даних: рівень шуму, неповнота, точність вимірювань;
- тип клінічного завдання: класифікація, прогнозування;
- часові обмеження: потреба у швидкому або точному рішенні;
- обчислювальні ресурси: доступність GPU, можливість розпаралелювання.

Формально, представлення адаптації:

Нехай:

- $D = \{X_1, X_2, \dots, X_k\}$ – множина доступних модальностей,
- Θ – тип задачі (наприклад, раннє виявлення хвороби, моніторинг),
- R – обмеження на ресурси.

Тоді адаптивна стратегія може бути формалізована як:

$$\psi(D, \Theta, R) = \text{вибір}\{EF, LF\}, \quad (2.10)$$

де:

EF – Early Fusion (ознакове поєднання),

LF – Late Fusion (модельне поєднання).

Адаптивне поєднання модальностей є гнучкою та ефективною стратегією, що дозволяє автоматично обирати оптимальний спосіб інтеграції даних залежно

від повноти, якості та контексту клінічного завдання. У випадках, коли всі модальності доступні, перевага надається ознаковому поєднанню завдяки високій інформативності. Натомість за умови відсутності або обмеженої якості частини даних доцільним є використання модельного підходу. Таким чином, адаптивна стратегія забезпечує баланс між точністю, стійкістю та обчислювальною ефективністю, що є критично важливим у реальних клінічних сценаріях із високим рівнем невизначеності та змінності даних.

Запропоновані стратегії інтеграції мультимодальних даних – ознакове, модельне та адаптивне поєднання – формують концептуальну та функціональну основу побудови інтелектуальної інформаційної технології. Проте для практичної реалізації цієї технології необхідно формалізувати процес навчання класифікаційної моделі, що дозволяє ефективно обробляти об'єднані ознаки та здійснювати точне прийняття рішень.

У цьому контексті виникає потреба в оптимізаційному поданні задачі, що забезпечує системне навчання моделі на основі доступних мультимодальних даних з урахуванням регуляризації, контролю складності та балансу між точністю та узагальненістю. Такий підхід дозволяє не лише досягти високої якості класифікації, а й забезпечити інтерпретованість і стійкість системи до варіативності вхідної інформації.

Ефективність роботи інформаційної технології визначається якістю класифікації:

- *Accuracy* (точність класифікації загалом) – це базовий показник, що визначає частку правильно класифікованих об'єктів серед усіх:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}, \quad (2.11)$$

де:

- *TP* – True Positives (правильно передбачені позитивні приклади);
- *TN* – True Negatives (правильно передбачені негативні приклади);
- *FP* – False Positives (помилково передбачені як позитивні);
- *FN* – False Negatives (помилково передбачені як негативні).

- *Precision* (точність позитивних прогнозів) показує, яка частина передбачених як «позитивних» справді належать до цього класу.

$$Precision = \frac{TP}{TP + FP}. \quad (2.12)$$

- *Recall* (повнота, чутливість) показує, яка частка об'єктів певного класу була правильно знайдена моделлю.

$$Recall = \frac{TP}{TP + FN}. \quad (2.13)$$

- *F1-score* (гармонійне середнє між точністю та повнотою) є корисним, коли важлива як точність, так і повнота, наприклад, у задачах діагностики.

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}. \quad (2.14)$$

Застосування та аналіз наведених метрик забезпечує комплексну оцінку ефективності розробленої інформаційної технології. Окрім показників точності, важливими критеріями виступають інтерпретованість рішень, адаптивність системи до змінних умов та відповідність клінічним вимогам, що є визначальними для її впровадження у практичну медичну діяльність.

Узагальнене формалізоване представлення, що охоплює математичну постановку задачі, стратегії поєднання модальностей, підходи до оптимізації та критерії оцінювання якості класифікації, є методологічною основою запропонованої концепції. Воно забезпечує не лише цілісне бачення процесу побудови системи, а й дає змогу послідовно реалізовувати інформаційну технологію багатовимірного аналізу мультимодальних даних, орієнтовану на клінічно релевантні результати, масштабованість, надійність та практичну застосовність у сучасному медичному середовищі.

2.2. Формування дослідницької гіпотези як основи методології багатовимірного аналізу мультимодальних медичних даних

Формування дослідницької гіпотези виступає відправною точкою для побудови методології багатовимірного аналізу мультимодальних медичних даних, оскільки саме вона визначає напрями, логіку та структуру подальшого

наукового дослідження. Методологія, в межах цього підходу, розглядається не лише як сукупність технічних методів, а як цілісна система філософських і наукових принципів, що забезпечують обґрунтованість і послідовність пізнання.

У цьому контексті ключовими елементами виступають чітко визначені концептуальні засади та категоріальні конструкції, які відображають бачення структури проблеми, підходів до її вирішення та шляхів досягнення поставленої мети. Формулювання гіпотези ґрунтується на загальнонаукових принципах, таких як системність, об'єктивність, логічність та внутрішня узгодженість, що є базисом для розробки ефективної інформаційної технології.

Методологія та концепція в цьому дослідженні відіграють системотвірну роль, формуючи інтелектуальну рамку для аналізу та інтерпретації складної структури мультимодальних медичних даних і забезпечуючи наукову цілісність усіх подальших етапів роботи.

- Методологія – це система принципів, методів, прийомів і процедур, що застосовуються в науковому дослідженні для досягнення поставленої мети. Вона визначає не лише технічні інструменти дослідження, але й логіку побудови дослідницького процесу, правила перевірки гіпотез, критерії істинності результатів [27].
- Методологія – це система загальнонаукових і спеціальних принципів, методів та засобів організації та проведення дослідження, яка визначає підхід до вирішення наукової проблеми [28].
- Концепція – це система поглядів на об'єкт дослідження, яка визначає основні ідеї, вихідні припущення та стратегічні орієнтири розвитку теорії або практики в певній галузі. У межах дослідження концепція є інтелектуальною рамкою, що формує бачення проблеми, її структурування та напрями розв'язання [33].
- Концепція – це система базових положень, теоретичних припущень і стратегічних орієнтирів, що відображають бачення дослідником структури проблеми, об'єкта і предмета дослідження та напрямів її вирішення [30].

У процесі наукових досліджень проблеми побудови інформаційної технології багатовимірного аналізу мультимодальних даних використані наступні підходи [27, 29]:

- Системний підхід – забезпечує цілісне бачення процесу обробки даних як взаємопов’язаної системи, що включає збір, синхронізацію, інтерпретацію та прийняття рішень на основі даних з різних джерел.
- Мультимодальний підхід – передбачає інтеграцію інформації з різних модальностей, що дозволяє сформувати узгоджене представлення пацієнта чи клінічного випадку.
- Багатовимірний підхід – реалізований через побудову високовимірних векторних описів об’єктів, що дозволяє враховувати складну структуру і взаємозалежності між параметрами.
- Концептуально-онтологічний підхід – використано для формального подання знань і виявлення латентних структур у даних за допомогою концептуального аналізу, що забезпечує інтерпретованість моделей.
- Багатокритеріальний підхід – дозволив одночасно оптимізувати точність, продуктивність, адаптивність та ресурсну ефективність інформаційної технології в умовах реальних обмежень.
- Інтелектуальний підхід – полягав у використанні сучасних методів машинного та глибинного навчання для автоматичної класифікації, прогнозування та виявлення закономірностей у складних даних.
- Паралельно-розподілений підхід – застосовано для обробки великих обсягів медичних даних із використанням високопродуктивних обчислювальних платформ, що дозволяє масштабувати запропоновану технологію.
- Адаптивно-евристичний підхід – реалізовано через гнучкі алгоритми, здатні підлаштовуватися під змінні характеристики вхідних даних та специфіку клінічних завдань.

Одним із фундаментальних підходів, що забезпечують цілісність наукового дослідження та побудову ефективної інформаційної технології, є

системний підхід. У контексті обробки мультимодальних медичних даних він дозволяє не лише узгоджено об'єднувати різноманітні джерела інформації, а й взаємодіяти зі зв'язками з урахуванням змін, що відбуваються у підсистемах [27]. Цей підхід спрямований на розгляд усієї сукупності медичних даних як єдиної ієрархічної системи з численними елементами та зв'язками між ними. Він дозволяє виявляти структурні залежності між джерелами інформації, враховувати взаємозв'язки між модальностями та оцінювати вплив змін у підсистемах на загальний результат. Такий підхід є основою для цілісного управління інформаційними потоками в медичному середовищі [29].

До основних завдань системного підходу слід віднести [29]:

- Встановлення взаємозв'язків між модальностями.
- Забезпечення узгодженого злиття та синхронізації даних.
- Оцінка впливу локальних змін на глобальний діагностичний висновок.
- Створення основи для адаптивної обробки у випадках неповноти або нестабільності даних.

Суть підходу полягає в тому, що мультимодальні медичні дані зводяться в єдину ієрархічну систему, де кожен тип даних (модальність) – це окрема підсистема, яка взаємодіє з іншими. Наприклад: ЕКГ → відображає електричну активність серця, ЕЕГ → реєструє мозкову активність, МРТ → забезпечує структурну візуалізацію тканин, клінічні дані → включають історію хвороби, симптоми, лабораторні результати. Ці компоненти не функціонують ізольовано, вони впливають один на одного, і лише їх узгоджене трактування дозволяє здійснити моніторинг стану пацієнта. На рисунку. 2.3 представлено візуальну модель, яка демонструє логіку реалізації системного підходу.

Системний підхід створює підґрунтя для реалізації інших, зокрема, мультимодального, багатовимірного, багатокритеріального та інтелектуального в єдиній концепції аналітичної платформи [6, 8].




Рис. 2.3. Схематичне представлення системного підходу

Після визначення загальної архітектури та взаємозв'язків елементів інформаційної системи в межах системного підходу наступним кроком є деталізація способів обробки даних з урахуванням їх джерел та природи. У медичній сфері інформація надходить із різних типів джерел, кожне з яких має власні характеристики, формат подання та частоту оновлення. Це зумовлює потребу у застосуванні мультимодального підходу, який дозволяє інтегрувати ці дані в єдине аналітичне середовище.

Мультимодальний підхід не лише забезпечує об'єднання гетерогенних даних, але й дозволяє врахувати взаємодоповнюючу природу модальностей, що суттєво підвищує точність, повноту та інтерпретованість діагностичних рішень. У цьому контексті мультимодальність стає природним продовженням системного бачення структури медичних даних, де фокус зміщується від загальної організації до змістовної інтеграції інформації з урахуванням її джерел [27].

На рисунку 2.4. схематично поданий мультимодальний підхід, який забезпечує більш повне й точне представлення об'єкта дослідження – пацієнта, що є основою для побудови ефективних моделей діагностики, прогнозування й прийняття клінічних рішень.

Запропонований підхід (Рис. 2.4) забезпечує цілісне уявлення про стан пацієнта завдяки інтеграції даних із різних каналів.




Рис. 2.4. Схематичне представлення мультимодального підходу

Однак при поєднанні інформації з різнорідних джерел у межах мультимодального підходу виникає завдання коректного подання цих даних для подальшої обробки, аналізу та підтримки рішень. Кожен тип даних має власну структуру, масштаб вимірювання та клінічну значущість, тому просте злиття інформації є недостатнім. Потрібно формувати уніфіковану багатовимірну модель, яка описує об'єкт (пацієнта, випадок, стан) через систему взаємопов'язаних ознак [27, 33]. Це реалізується в рамках багатовимірного підходу, який дозволяє відобразити медичні об'єкти як вектори високої розмірності або багатовимірні тензори. Завдяки цьому можна аналізувати складні структури, виявляти закономірності на різних рівнях деталізації, застосовувати методи зменшення розмірності (PCA, t-SNE) та формального концептуального аналізу (FCA, CDA). Такий підхід є основою для побудови інтерпретованих і математично строгих моделей в умовах високої складності медичних даних [33].

На рисунку 2.5 представлено багатовимірний підхід, який дозволяє здійснювати єдину інтерпретацію гетерогенних даних, що є критично важливим

для точного й ефективного прийняття клінічних рішень на основі комплексного аналізу інформації про стан пацієнта.




Рис. 2.5. Схематичне представлення багатовимірного підходу

На схемі показано, як у рамках багатовимірного підходу дані з різних модальностей проходять процес векторизації, уніфікуються й перетворюються у спільний багатовимірний простір ознак. Це дозволяє ефективно аналізувати структуру даних, будувати інтерпретовані моделі та знаходити закономірності між різними аспектами медичної інформації.

Побудова багатовимірних моделей дозволяє глибше аналізувати структурні особливості медичних даних, однак ефективність таких моделей значною мірою залежить від здатності враховувати різноманітні вимоги до якості, швидкодії та адаптивності системи. У практичних медичних задачах часто важливо не лише отримати точний результат, а й забезпечити його своєчасність, стабільність при неповноті даних, економне використання ресурсів обчислювальної інфраструктури [28].

У цьому контексті набуває особливої ваги багатокритеріальний підхід, який дає змогу одночасно оцінювати ефективність технології за кількома показниками, такими як [30]:

- точність діагностування;
- швидкість обробки;
- стійкість до зашумлення та пропусків;
- адаптивність до нових даних;
- масштабованість у великих системах;
- обчислювальна ефективність.

Застосування багатокритеріального підходу забезпечує оптимальний баланс між конкуруючими вимогами, що дозволяє приймати зважені рішення з урахуванням потреб реального клінічного середовища. На рисунку 2.6 схематично відображено ключові складові багатокритеріального підходу [30].



Рис. 2.6. Схематичне представлення багатокритеріального підходу

Такий підхід дозволяє проводити збалансоване оптимізаційне налаштування інформаційної системи, орієнтуючись не лише на максимальну точність, але й на інші критично важливі аспекти, що мають значення в умовах реального застосування в медицині. Наприклад, у деяких випадках доцільніше обрати більш швидку або менш ресурсоємну модель при незначному зниженні точності, якщо це забезпечить оперативність прийняття клінічних рішень.

У поєднанні з іншими підходами (мультимодальним, багатовимірним, адаптивно-евристичним) багатокритеріальність формує методологічну основу для побудови надійних і гнучких медичних інформаційних технологій [28, 29].

Оптимізація медичних рішень на основі множини критеріїв ставить нові вимоги до гнучкості та адаптивності аналітичних моделей. У такому середовищі особливої актуальності набуває інтелектуальний підхід, що передбачає використання машинного навчання для автоматичної обробки даних, виявлення прихованих закономірностей і формування прогностичних висновків [27]. Цей підхід дозволяє:

- здійснювати класифікацію станів пацієнта на основі історичних і поточних даних;
- навчати моделі на великих обсягах мультимодальної інформації;

- інтерпретувати результати за допомогою концептуальних моделей;
- створювати адаптивні системи, здатні підлаштовуватись під нові дані без потреби повного перенавчання.

Інтелектуальний підхід слугує ядром для побудови сучасних клінічних систем, у яких високий рівень автоматизації поєднується з пояснюваністю та гнучкістю.

На рисунку 2.7 наведено схематичне представлення інтелектуального підходу, який реалізує логіку трансформації структурно складних мультимодальних медичних даних у клінічно значущі рішення з використанням методів машинного навчання. Завдяки своїй адаптивності, інтерпретованості та здатності працювати з неповними або гетерогенними даними, інтелектуальний підхід є основою для створення новітніх медичних інформаційних систем, що забезпечують підвищену точність і довіру до автоматизованих рішень [27].



Рис. 2.7. Схематичне представлення інтелектуального підходу

Інтелектуальні моделі, зокрема ті, що ґрунтуються на глибинному навчанні та багатовимірній обробці даних, вимагають значних обчислювальних ресурсів, особливо при роботі з великими обсягами мультимодальної інформації. Це обумовлює потребу у використанні паралельно-розподіленого підходу, який дозволяє масштабувати обчислення, зменшити затримки обробки та забезпечити

продуктивну роботу інформаційної технології в реальних умовах [28, 29]. Такий підхід передбачає:

- розподіл даних і задач між вузлами в обчислювальному кластері або хмарному середовищі (наприклад, Apache Spark, Hadoop);
- паралельну обробку сигналів, зображень і текстів у рамках єдиного конвеєра;
- підтримку масштабованості та відмовостійкості, що є критичними для медичних систем, які працюють у режимі 24/7;
- можливість експлуатації на різних рівнях інфраструктури – від локальних серверів до хмарних платформ.

Застосування паралельно-розподіленого підходу забезпечує ефективне функціонування інтелектуальної технології в умовах реального часу, коли швидкість прийняття рішення може бути вирішальною [28].




Рис. 2.8. Схематичне представлення паралельно-розподіленого підходу до обробки мультимодальних медичних даних

Наведений схематично на рисунку 2.8 підхід є надзвичайно ефективним для роботи в умовах реального часу та високого навантаження, а також забезпечує масштабованість системи за рахунок можливості додавання нових обчислювальних вузлів у разі зростання обсягів даних або розширення функціональності.

Незважаючи на переваги паралельно-розподілених архітектур, для медичних систем важливо не лише обробляти великі обсяги даних швидко, але й гнучко адаптуватися до нових, непередбачуваних ситуацій, неповних даних або змін у середовищі. Саме тому у межах проєкту застосовується адаптивно-евристичний підхід, що поєднує механізми автоматичної адаптації з інтуїтивно зрозумілими компонентами [30, 33]. Цей підхід забезпечує:

- адаптацію до нових сценаріїв без повного перенавчання моделі (наприклад, зміна структури даних);
- використання евристик, що враховують експертні знання лікарів і клінічні протоколи;
- обробку неповних, зашумлених даних, функції належності або вагові коефіцієнти;
- поєднання машинного інтелекту з людською інтуїцією, що критично важливо в медичному середовищі, де остаточне рішення приймає лікар.

Таким чином, адаптивно-евристичний підхід завершує методологічну рамку дослідження, забезпечуючи гнучкість, надійність і пояснюваність функціонування створеної інформаційної технології в умовах реальної клінічної практики [33].




Рис. 2.9. Схематичне представлення адаптивно-евристичного підходу до обробки мультимодальних медичних даних

На рисунку 2.9 представлено архітектуру адаптивно-евристичного підходу, що забезпечує гнучке налаштування алгоритмів і процесів обробки медичних даних відповідно до специфіки задачі, якості вхідної інформації та клінічного контексту.

Такий підхід особливо ефективний в умовах неповних, зашумлених або змінних даних, оскільки дозволяє інтелектуальній системі гнучко адаптуватися до нових вхідних умов і зберігати високу якість результатів.

Визначення наукової методології потребує не лише формалізації технічних засобів дослідження, а й глибокого розуміння загальнонаукових і філософських засад, які формують підґрунтя для побудови узгодженої, ефективною та адаптивної інформаційної технології. З огляду на міждисциплінарний характер теми дослідження, що поєднує медицину, комп'ютерні науки, штучний інтелект і теорію даних, методологія повинна враховувати комплекс фундаментальних принципів, які визначають її цілісність і логічну послідовність [6, 8].

У межах дисертаційного дослідження сформульовано методологію, яка ґрунтується на таких філософських і загальнонаукових принципах: системності, цілісності, багатовимірності, інтерпретованості, адаптивності та багатокритеріальності. Розглянемо їх зміст детальніше.

1. Принцип системності передбачає розгляд мультимодальних медичних даних як частин єдиної, складної, ієрархічної системи, в якій існують як вертикальні (між рівнями даних) так і горизонтальні (між модальностями) зв'язки. Мультимодальні дані – це не ізольовані фрагменти інформації, а елементи взаємопов'язаного середовища, де зміна однієї модальності може впливати на інші. Системність дозволяє виявляти закономірності, що проявляються лише при комплексному аналізі структури взаємозв'язків між даними різних типів, що критично важливо для точного клінічного прогнозування та діагностики.
2. Принцип цілісності передбачає поєднання різномірних інформаційних джерел (текстових описів, зображень, електрофізіологічних сигналів,

структурованих клінічних записів тощо) в єдиному аналітичному середовищі. Це дозволяє створити уніфіковану модель пацієнта або клінічної ситуації, мінімізувати втрату інформативних ознак і забезпечити максимально повне уявлення про об'єкт аналізу, що, в свою чергу, покращує обґрунтованість прийнятих рішень.

3. Принцип багатовимірності обґрунтовує використання аналітичних моделей, здатних одночасно обробляти численні ознаки з різних джерел, враховуючи як їх кількісні, так і якісні параметри. Це дає змогу виявити складні нелінійні залежності, приховані патерни, крос-модальні кореляції, що неможливо досягти при розгляді кожної модальності окремо. У результаті формується узагальнене багатовимірне представлення об'єкта, придатне до машинного навчання та класифікації.
4. Принцип інтерпретованості має важливе значення в медичних інформаційних системах, оскільки результати аналізу повинні бути зрозумілими та логічно обґрунтованими для лікаря. Принцип передбачає застосування моделей та методів, які дозволяють не лише рішення про стан пацієнта, але й пояснити, які саме ознаки (модальності, характеристики, часові ділянки тощо) були критичними для його формування. Це підвищує рівень довіри до технології з боку медичних фахівців і сприяє її впровадженню в практику.
5. Принцип адаптивності визначає здатність технології змінювати свою поведінку відповідно до змін вхідних даних, структури записів, нових клінічних випадків або варіабельності у вимірюваннях. Адаптивні алгоритми забезпечують високу чутливість до змін середовища, що важливо в умовах реального клінічного застосування, де часто маємо справу з неповними, зашумленими або неструктурованими даними.
6. Принцип багатокритеріальності дозволяє одночасно враховувати декілька параметрів ефективності при оцінюванні роботи інформаційної системи: точність діагнозу, час обробки, споживання обчислювальних ресурсів, стійкість до помилок, масштабованість, інтерпретованість

результатів. Це забезпечує збалансованість між якістю прогнозів і практичними обмеженнями (наприклад, вартістю обчислень або доступністю даних), що є важливим критерієм при впровадженні системи в медичну практику.

У контексті наведених принципів формується цілісна методологічна основа, яка визначає підхід до побудови інформаційної технології багатовимірної аналізу мультимодальних медичних даних. Розуміння усіх принципів уможливорює не лише визначення архітектури системи, а й обґрунтування вибору аналітичних моделей, механізмів інтеграції та інтерпретації даних.

Виходячи з цих положень, наступним логічним етапом є конкретизація дослідницьких підходів, які дозволяють забезпечити реалізацію зазначених принципів на практиці. Саме тому в дисертаційній роботі особливу увагу зосереджено на визначенні та використанні ефективних методологічних підходів, здатних обробляти структурно складну, гетерогенну інформацію з урахуванням вимог до адаптивності, багатокритеріальності та пояснюваності результатів [29].

У філософському вимірі дослідження відображає діалектику розвитку інформаційних технологій як відповіді на еволюцію соціальних та медичних викликів. Якщо традиційні медичні ІТ-системи зазвичай орієнтовані на обробку окремих типів даних або вирішення ізольованих задач, то сучасні підходи повинні забезпечити гнучку, масштабовану й прозору інтеграцію даних з різних модальностей у єдине інтелектуальне середовище [28].

Таким чином, сформована у роботі методологія, що ґрунтується на аналогії між пацієнтом у клінічному середовищі та інформаційним об'єктом в аналітичній системі, дозволила переосмислити процес побудови інформаційної технології як відповідник медичної діагностики та лікування. Це надало змогу вивести дослідницьку гіпотезу як узагальнене припущення щодо принципів обробки та аналізу мультимодальних медичних даних, що забезпечують правильну класифікацію стану пацієнта.

У межах цієї парадигми логічно сформульовано такі наукові гіпотези:

1. **Гіпотеза 1.** Підвищення інформативності результатів дослідження можливе за рахунок інтегрованого аналізу мультимодальних даних, що поєднують різні типи інформації (сигналові, візуальні, текстові, числові) в єдиному аналітичному середовищі.
2. **Гіпотеза 2.** У процесі формування мультимодальних моделей чисельні ознаки, отримані з окремих модальностей, взаємно доповнюють одна одну, що дозволяє більш повно репрезентувати стан пацієнта та його зміни у динаміці.
3. **Гіпотеза 3.** Ефективне поєднання інформації від окремих модальностей створює ефект емерджентності, тобто якісно новий рівень інформативності, який забезпечує збільшення кількості правильно класифікованих клінічних станів.

Таким чином, сформульовані гіпотези стали основою для подальшого обґрунтування методологічних рішень та вибору інструментарію багатовимірного аналізу, а також для розроблення архітектури інформаційної технології, адаптованої до умов структурної різноманітності, часової асинхронності та неповноти медичних даних.

2.3. Концепція багатовимірного аналізу мультимодальних медичних даних

Виходячи зі сформованої дослідницької гіпотези та методологічних засад, що визначають принципи обробки мультимодальної інформації, наступним кроком є побудова концепції, яка інтегрує ці положення в єдину системну структуру. Концепція багатовимірного аналізу мультимодальних медичних даних слугує логічним і структурним каркасом для формалізації інформаційної технології, забезпечуючи узгоджене функціонування її компонентів, а також цілеспрямовану обробку складних, гетерогенних і часово неузгоджених даних.

Концепція багатовимірного аналізу мультимодальних медичних даних ґрунтується на системному баченні ролі інформаційних технологій у забезпеченні точного, адаптивного та інтерпретованого клінічного аналізу, який

охоплює обробку гетерогенних джерел медичної інформації. Вона передбачає об'єднання знань із суміжних галузей – медицини, штучного інтелекту, обробки сигналів, глибинного навчання, концептуального аналізу та паралельних обчислень – у єдину аналітичну парадигму [6, 306, 338].

Згідно з цією концепцією, процес обробки мультимодальних даних розглядається як поетапна ієрархічна взаємодія між різними рівнями обробки, які забезпечують поступовий перехід від сирих даних до прийняття клінічних рішень. Основними елементами концепції, які формують її методологічну та прикладну цілісність, є:

1. Рівень збору та попередньої обробки даних

На цьому етапі здійснюється акумуляція вхідних даних з різних модальностей, серед яких:

- Текстові дані: електронні медичні картки, анамнез, діагностичні звіти.
- Сигнальні дані: біомедичні часові ряди (ЕКГ, ЕЕГ).
- Графічні зображення: результати візуалізаційних досліджень (МРТ)
- Числові/структуровані: лабораторні показники, персоналізовані дані.

Дані проходять фільтрацію, нормалізацію, синхронізацію часових міток та первинну трансформацію (векторизацію, виділення ознак), що забезпечує їхню придатність для подальшої інтеграції.

2. Рівень уніфікації та інтеграції даних реалізує:

- Вирівнювання модальностей за масштабами та форматами.
- Семантична інтеграція (встановлення відповідностей між значеннями різних джерел).
- Побудова узагальненого векторного представлення об'єкта дослідження.
- Використання концептуального аналізу даних (CDA, FCA) для створення концептуальних решіток, що відображають внутрішні зв'язки між модальностями.

3. Аналітико-діагностичний рівень виконує основну аналітичну обробку даних із використанням:

- Методів глибинного навчання (LSTM, CNN, трансформери) для вилучення складних шаблонів і прогнозування.
- Методів багатовимірної аналізу для виявлення латентних залежностей.
- Багатокритеріальних моделей оцінювання, які враховують точність, час обробки, ресурсоємність, адаптивність і інтерпретованість.

4. Рівень інтерпретації результатів здійснює:

- Забезпечення візуалізації важливих ознак та причинно-наслідкових зв'язків між модальностями.
- Використовуються засоби концептуальної аналітики для формалізації логічних висновків.

5. Рівень прийняття рішень

Результатом функціонування інформаційної технології є:

- Формування діагностичних висновків.
- Генерація рекомендацій щодо подальшого клінічного супроводу.
- Підтримка прийняття рішень в умовах неповних, суперечливих або багатозначних даних.

6. Інфраструктурно-обчислювальний рівень, який передбачає використання:

- Паралельно-розподіленого середовища обробки (Apache Spark, Hadoop).
- Адаптивної конфігурації ресурсів під навантаження.
- Масштабованості до великих потоків даних у реальному часі.

Таким чином, концепція багатовимірної аналізу мультимодальних медичних даних відображає не лише структурну та функціональну організацію інформаційної системи, а й визначає основні методологічні інновації, що забезпечують її цілісність, гнучкість і клінічну ефективність [306].

Для забезпечення реалізації такої інтеграції необхідно виокремити основні елементи концепції, які визначають логіку поєднання модальностей, способи їх обробки та адаптацію до конкретних клінічних умов. Наступним кроком є деталізація методологічних принципів, які забезпечують поєднання даних з різних джерел, з урахуванням їх гетерогенності, семантичної несумісності та

різної інформативної ваги. Ці положення формують основу для побудови стратегій об'єднання ознак і моделей багатовимірного аналізу мультимодальних медичних даних.

Підвищення інформативності результатів аналізу пацієнтів за рахунок взаємного доповнення модальностей є перевагою мультимодального підходу в медичній аналітиці. Цей підхід базується на припущенні, що жодна окрема модальність – чи то ЕКГ, результат МРТ, текстовий звіт лікаря чи лабораторні показники – не може в повній мірі охопити усі аспекти стану пацієнта. Лише їхнє системне об'єднання дозволяє сформувати всебічну та клінічно релевантну картину. На рисунку 2.10 представлено схему інформаційної системи багатовимірного аналізу мультимодальних медичних даних. Зазначена схема ілюструє процеси інформаційної системи, що забезпечують обробку, інтеграцію та аналіз мультимодальних медичних даних для підтримки клінічних рішень. Структура системи відображає основні логічно пов'язані компоненти, починаючи з етапу збору даних і закінчуючи формуванням клінічних рішень.




Рис. 2.10. Схематичне представлення інформаційної системи багатовимірного аналізу мультимодальних медичних даних

Першим етапом, представленим на рисунку 2.10, є збір даних з різномірних джерел, серед яких текстові записи (анамнези, діагнози, протоколи), сигналові ряди (ЕКГ, ЕЕГ), візуальні обстеження (МРТ) та числові показники (результати лабораторних досліджень, біомаркери). Ці дані мають різну структуру, одиниці вимірювання та формат подання, що обумовлює необхідність їх попередньої обробки.

У модулі попередньої обробки відбувається фільтрація, нормалізація, уніфікація частоти дискретизації, векторизація та синхронізація даних у часовому вимірі. Це забезпечує їхню сумісність і готує до інтеграції [338].

Далі процес переходить до етапу інтеграції, де дані з різних модальностей об'єднуються у спільний простір ознак. Тут застосовуються методи формалізації, такі як концептуальний аналіз даних (CDA) або формальний концептуальний аналіз (FCA), що дозволяє виявити міжмодальні залежності та узгодити багатовимірні структури.

У аналітичному блоці реалізуються алгоритми глибинного навчання (зокрема, CNN, LSTM, Transformer), а також методи багатовимірного аналізу для класифікації. Особливістю системи є врахування багатьох критеріїв – точності, швидкодії, стійкості до шуму, адаптивності до нових даних, інтерпретованості тощо.

На наступному етапі – інтерпретація результатів, де відбувається логічне обґрунтування отриманих висновків, пояснення механізмів прийняття рішень, а також візуалізація ключових індикаторів, що вплинули на результат.

Завершальним є блок формування клінічного рішення, у межах якого система видає діагностичний висновок про стан пацієнта.

Уся система функціонує в паралельно-розподіленому обчислювальному середовищі, що забезпечує масштабованість, гнучкість і стійкість до великих обсягів даних, що особливо актуально для реальних клінічних інформаційних систем [306].

Таким чином, схема відображає концепцію побудови інтелектуальної медичної технології, яка інтегрує структурно неоднорідні дані в єдину

аналітичну платформу, забезпечуючи високу якість підтримки клінічних рішень на основі сучасних методів аналізу даних [338].

Оскільки на схемі (Рис. 2.10) візуально представлені основні компоненти концепції інформаційної технології, то наступним кроком є її формалізація, з метою чіткого окреслення інформаційних потоків, логіки обробки даних і механізмів прийняття рішень. Така формалізація дозволяє не лише краще зрозуміти внутрішню архітектуру системи, але й забезпечити можливість її аналітичного опису, моделювання та подальшої реалізації. Вона базується на визначенні множин вхідних модальностей, перетворень, інтеграційних процедур, критеріїв оцінки та логіки виводу результату.

Нижче подано формальний опис концепції, що деталізує її елементи та відображає функціональні залежності між ними [6].

1 етап. Вхідні дані (мультимодальні джерела).

Нехай:

- $D = \{d_1, d_2, \dots, d_n\}$ – множина джерел медичних даних;
- $M = \{M_{text}, M_{img}, M_{sig}, M_{num}\}$ – типи модальностей: M_{text} – текстові дані (анамнез); M_{img} – зображення (МРТ); M_{sig} – сигнали (ЕКГ, ЕЕГ); M_{num} – числові дані (аналізи).

Кожен об'єкт $o \in O$ представлений вектором модальностей: $o = \{x_{text}, x_{img}, x_{sig}, x_{num}\}$.

2 етап. Модуль попередньої обробки виконує функції:

- нормалізація: $f_{norm}: M_i \rightarrow M_i'$
- синхронізація часових рядів: $f_{sync}(M_{sig}) \rightarrow M_{sig}'$
- зниження розмірності: $f_{pca}: R^n \rightarrow R^k, k \ll n$.

3 етап. Модуль інтеграції модальностей

Інтеграція даних у спільний простір ознак: $F_{int}: \{M_1', \dots, M_n'\} \rightarrow Z \subset R^k$, де Z – об'єднане векторне подання об'єкта у високовимірному просторі.

4 етап. Аналітичний модуль, де застосовуються:

- алгоритм глибинного навчання: $f_{DL}: Z \rightarrow Y, Y \in \{\text{класи, оцінки}\}$

- концептуальний аналіз (CDA): побудова решітки понять $L = (G, M, I)$, де G =об'єкти, M =ознаки, $I \subseteq G \times M$.

5 етап. Модуль багатокритеріальної оцінки ефективності, де визначається:

- Множина критеріїв: $C = \{c_1, c_2, \dots, c_m\}, c_i \in \{\text{точність, швидкість, інтерпретованість, ресурси}\}$.
- Функція оцінки: $E_{val}: Y \times C \rightarrow [0,1]^m$.

6 етап. Модуль інтерпретації, де формується пояснення:

$E_{explain}(Y)$ = множина значущих ознак $\subseteq Z$, що обґрунтовує вибір рішення $y \in Y$.

7 етап. Вихідні результати.

Результат подається як:

$$R = \{\text{діагноз}\}, R = f_{output}(Y, E_{explain}(Y)).$$

Така структура описує взаємозалежні процеси в інформаційній технології, що забезпечує інтеграцію, аналіз, оцінку та пояснення результатів, ґрунтуючись на сучасних методах штучного інтелекту та концептуального аналізу. Формальний опис концепції інформаційної технології багатовимірного аналізу мультимодальних медичних даних включає визначення основних множин, функцій та відображень, які описують структуру, інформаційні потоки та функціональні взаємозв'язки системи [6].

У наведеному описі концепції інформаційної технології багатовимірного аналізу мультимодальних медичних даних (Рис. 2.10) чітко простежується архітектурна цілісність і логіка послідовної обробки медичних даних від збору до прийняття рішення. Водночас, попри структурну завершеність, ця концепція стикається з рядом важливих практичних і теоретичних обмежень (Табл. 2.1), які дозволяють сформулювати наукову проблему. Обмеження, представлені в таблиці, формують підґрунтя для постановки наукової проблеми щодо створення адаптивної, інтерпретованої та ефективною ІТ-системи для мультимодального аналізу медичних даних.

Наукова проблема в контексті концептуальної моделі інформаційної технології багатовимірного аналізу мультимодальних медичних даних полягає в протиріччі між зростаючою складністю медичних даних та обмеженими можливостями існуючих підходів до їхньої інтеграції, обробки й інтерпретації [6, 338].

Таблиця 2.1

Виявленні проблеми концепції

Проблеми	Пояснення проблеми
Неповнота міжмодального узгодження	Не враховано динамічні та контекстно-залежні зв'язки між даними з різних джерел
Обмежена інтерпретованість глибинних моделей	Складність пояснення рішень моделей глибинного навчання обмежує прозорість і довіру лікарів
Слабка адаптація до неповних або зашумлених даних	Відсутність механізмів компенсації або реконструкції даних у разі їх дефіциту
Обмежена підтримка оновлення знань	Модель не враховує механізми постійного навчання на нових даних
Брак семантичної підтримки	Відсутність медичних онтологій обмежує інтерпретацію та ускладнює обробку текстової інформації.
Відсутність єдиного критеріального балансу	Не реалізовано узгоджену систему зважування параметрів ефективності з урахуванням клінічного контексту.

Для вирішення окресленої наукової проблеми необхідно розробити нову інформаційну технологію, яка враховує структурні, семантичні та динамічні особливості мультимодальних медичних даних і реалізує такі ключові функціональні компоненти (Табл. 2.2).

Таким чином, вирішення наукової проблеми полягає у створенні інтерпретованої, адаптивної та багатокритеріально оптимізованої інформаційної технології, здатної ефективно обробляти структурно складні та гетерогенні медичні дані в умовах реального клінічного застосування. Запропонована технологія має забезпечувати не лише точність та продуктивність аналізу, але й прозорість прийняття рішень, стійкість до неповноти даних та можливість масштабування у розподіленому середовищі [338].

Вирішення поставлених задач реалізується у межах логічно послідовної структури дослідження, представленої в наступних розділах дисертаційної

роботи. У сукупності вони формують методологію побудови інформаційної технології багатовимірного аналізу мультимодальних медичних даних

Таблиця 2.2

Структура наукової проблеми інформаційної технології багатовимірного аналізу мультимодальних медичних даних, показана через невирішені задачі

Невирішені завдання	Пояснення до виконання
Інтеграція контекстно-залежних міжмодальних зв'язків	Розробка методів, які дозволяють враховувати часові, семантичні та клінічні залежності між модальностями (наприклад, ЕКГ ↔ анамнез ↔ МРТ), з урахуванням їхньої динаміки у часі та значущості в клінічному сценарії
Інтерпретовані гібридні моделі	Поєднання алгоритмів глибинного навчання з методами концептуального аналізу даних (CDA) та онтологічними підходами для пояснення рішень, формування прозорих
Обробка неповних та зашумлених даних	Розроблення адаптивних механізмів заповнення пропущених даних, реконструкції зашумлених сигналів, а також виявлення аномалій з мінімізацією втрати інформативності
Постійне навчання (continual learning)	Запровадження механізмів доадаптації моделей на нових даних без втрати попередньо набутого досвіду, що забезпечить довготривалу ефективність системи в умовах змін у медичній практиці
Онтологічна підтримка та семантичне узгодження	Використання медичних онтологій (SNOMED CT, ICD, UMLS тощо) для забезпечення узгодженого представлення термінів, понять та зв'язків у текстових і структурованих даних
Багатокритеріальне управління якістю	Реалізація системи адаптивного зважування критеріїв ефективності (точність, швидкодія, інтерпретованість, стійкість, ресурсна ефективність) відповідно до типу клінічного завдання або контексту

На рисунку 2.11 представлено оновлену концепцію інформаційної технології багатовимірного аналізу мультимодальних медичних даних, розроблену з урахуванням виявлених наукових проблем. Схема ілюструє логічно впорядковану систему взаємодії функціональних компонентів, що забезпечують цілісний цикл обробки, аналізу, адаптації та інтерпретації медичних даних різних модальностей.

Формально концепція інформаційної технології багатовимірного аналізу мультимодальних медичних даних після врахування виявлених проблем змінюється в таких аспектах:

1. Розширення множин і функцій

У базовому формальному представленні множина описувалась як: $IT = (D, M, F, R)$, де: D – множина вхідних даних (модальностей); M – множина модулів (обробки, інтеграції, аналізу); F – функції перетворення; R – результати (вихідна інформація для прийняття рішення).




Рис. 2.11. Схематичне представлення інформаційної системи багатовимірного аналізу мультимодальних даних з урахуванням наукових проблем (сформовано автором)

Оновлена формальне представлення: $IT^* = (D, M^*, F^*, R, \Omega)$, де:

- $M^* \supset M$ – множина модулів, доповнена новими підсистемами:
 - M_{sem} – семантична узгоджувальна підсистема (з онтологічною підтримкою);
 - M_{exp} – модуль інтерпретації;
 - M_{cont} – модуль безперервного навчання;
 - M_{rob} – механізми реконструкції та компенсації;
 - M_{multi} – багатокритеріальний модуль оцінки.
- F^* -функції перетворення включають:
 - $f_{sem}: D \rightarrow \hat{D}$ – семантичне узгодження;
 - $f_{int}: \hat{D} \rightarrow V$ – уніфікація та векторизація;
 - $f_{anal}: V \rightarrow A$ – аналітична обробка;
 - $f_{exp}: A \rightarrow E$ – пояснення результатів;
 - $f_{eval}: (A, E) \rightarrow Q$ – багатокритеріальна оцінка якості.
- Ω – онтологічна база знань, яка використовується при f_{sem} та f_{exp} .

2. Зміна логіки обробки

У попередній моделі функції були лінійно зв'язані: $f = f_{eval} \circ f_{anal} \circ f_{int} \circ f_{pre} \circ f_{col}$.

У новій моделі з'являються розгалуження та інтерактивні петлі: $f^* = f_{eval} \circ (f_{anal} \circ f_{int} \circ f_{sem} \circ f_{pre}) \oplus f_{exp}$, де $\oplus$ означає паралельну обробку результатів аналітики й пояснень.

3. Введення багатокритеріального простору якості

Оцінка вихідних рішень тепер визначається не одним показником, а вектором: $Q = \{q_{acc}, q_{time}, q_{rob}, q_{interp}, q_{scal}\}$, де q_{acc} – точність, q_{time} – час обробки; q_{rob} – стійкість до шуму/неповноти; q_{interp} – пояснюваність; q_{scal} – масштабованість.

4. Інтелектуальне управління

Система доповнюється функціоналом адаптивного контролю: $U: Q \rightarrow A$, де A – множина дій: перенавчання, заміна моделі, уточнення даних тощо.

Формальне представлення інформаційної технології багатовимірного аналізу мультимодальних даних після змін має вигляд: $IT^* = (D, M^*, F^*, R, \Omega, Q, U)$ і представлена в наступних роботах автора [338, 343]. Модель визначає інтегровану, адаптивну, інтерпретовану інформаційну систему, що може:

- семантично узгоджувати дані;
- обробляти та пояснювати рішення;
- адаптуватися до нових умов;
- динамічно оцінювати якість аналізу.

Такий підхід забезпечує не лише наукову новизну, але й прикладну цінність дослідження в умовах цифрової трансформації медичної галузі.

У цьому контексті формалізована модель системи задає підґрунтя для подальшого розкриття концептуальних основ багатовимірного аналізу мультимодальних медичних даних. Саме вони визначають інноваційність розробленої технології, а також закладають принципи її побудови. Серед основних ідей, що формують концептуальний каркас, можна виокремити:

1. Підвищення інформативності результатів аналізу пацієнтів за рахунок взаємного доповнення модальностей, що забезпечує цілісне уявлення про клінічний стан завдяки комплексному використанню різномірних джерел (тексту, сигналів, зображень, числових показників).
2. Побудову методів обробки мультимодальних даних на основі поєднання моделей модальностей, де кожна модальність аналізується власною моделлю, а результати агрегуються задля підвищення точності та стійкості.
3. Побудову методів на основі поєднання ознак модальностей, що передбачає інтеграцію уніфікованого ознакового простору для формування єдиного представлення об'єкта пацієнта та подальшої класифікації.
4. Адаптивне застосування вищенаведених підходів залежно від клінічного контексту, повноти даних і доступності модальностей.

5. Інтеграцію в інформаційну технологію гібридного механізму, що забезпечує вибір між ознаковим і модельним підходами або їх комбінацією відповідно до ситуаційних потреб.

Таким чином, запропонована концепція відображає не лише методичну цілісність, а й стратегічну орієнтацію на побудову адаптивної та ефективної системи багатовимірного аналізу мультимодальних медичних даних.

2.4. Принципи інформаційної технології багатовимірного аналізу мультимодальних медичних даних

У сучасних умовах цифрової трансформації медицини основним завданням стає створення інтелектуальних систем, здатних забезпечити точний, адаптивний і комплексний аналіз клінічного стану пацієнта на основі різноманітної інформації. Різноманіття форматів медичних даних зумовлює необхідність мультимодального підходу до їх обробки. В основі побудови такої інформаційної технології мають бути покладені фундаментальні методологічні принципи, які відображають логіку сучасного клінічного мислення.

Серед ключових принципів, що визначають архітектуру і функціонування інформаційної технології, можна виокремити:

1. **Принцип інтеграції мультимодальних ознак**, згідно з яким ознаки, що походять з різних модальностей (сигналів, зображень, числових даних), уніфікуються й поєднуються у єдиний ознаковий простір. Це дозволяє отримати цілісне векторне представлення об'єкта (пацієнта), яке потім подається на вхід універсальним моделям класифікації чи прогнозування. Такий підхід підвищує інформативність і точність результатів, оскільки дозволяє враховувати міжмодальні зв'язки вже на етапі формування вхідних даних.
2. **Принцип інтеграції модальних моделей**, який передбачає побудову окремих спеціалізованих моделей для кожної модальності, CNN для зображень, LSTM для сигналів. Кожна з моделей формує власний прогноз, а кінцеве рішення формується шляхом агрегування. Такий підхід є стійким

до втрати частини модальностей, дозволяє краще адаптуватися до властивостей кожного типу даних та зберігає гнучкість у розширенні системи.

Ці принципи не є ізольованими, а навпаки, вони відтворюють логіку клінічного мислення лікаря, у процесі якого здійснюється:

- збір даних із різних джерел (анамнез, тести, зображення);
- попередня оцінка якості й достовірності кожного джерела;
- узгодження інформації у єдину картину клінічного стану;
- формування проміжних гіпотез на основі часткових висновків;
- інтеграція висновків у фінальне клінічне рішення.

Таким чином, обидва принципи – ознакова та модельна інтеграція – концептуально та функціонально наслідують етапи медичного діагностування, що надає запропонованій інформаційній технології високу ступінь методологічної обґрунтованості. Це створює реальні передумови для її застосування в умовах сучасної клінічної практики, де потрібна не лише точність, але й адаптивність системи підтримки прийняття рішень.

2.5. Методологія інформаційної технології багатовимірного аналізу мультимодальних медичних даних

Методологія побудови інформаційної технології багатовимірного аналізу мультимодальних медичних даних базується на застосуванні методу прямої аналогії між процесами клінічного мислення та ключовими етапами обробки даних. Це забезпечує формування зрозумілої, узгодженої та інтерпретованої структури інформаційної системи, адаптованої до практичних потреб медичної галузі.

Методологія включає наступні етапи:

Етап 1. Аналіз задачі та формування вимог

На цьому етапі визначаються основні проблеми, пов'язані з обробкою мультимодальних медичних даних, включаючи гетерогенність форматів, часову неузгодженість, відсутність частини даних та потребу в клінічній інтерпретації.

Формулюються вимоги до інформаційної технології, зокрема: висока точність класифікації (A), швидкодія обробки даних у режимі, наближеному до реального часу (S), адаптивність до зміни вхідних даних і умов функціонування (R), масштабованість результатів.

Формалізовано множину модальностей представлено як: $M = \{M_1, M_2, \dots, M_k\}$, де M_i – i -та модальність. Кожна модальність представлена вхідними даними у своєму форматі $X_i \in M_i$. Відповідно множина записів пацієнта представлена як $D = \{d_1, d_2, \dots, d_n\}$, а $X_i = (x_i^{(num)}, x_i^{(img)}, x_i^{(sig)})$ – мультимодальний вектор ознак, відповідно $Y = \{y_1, \dots, y_n\} \in \{0,1\}^n$ – мітки класів.

Задача полягає в тому, щоб розробити інформаційну технологію T , яка забезпечить ефективну обробку мультимодальних даних для підтримки прийняття клінічних рішень. Формально задача полягає у знаходженні такої технології T^* , що максимізує узагальнений функціонал якості:

$$T^* = \arg \max_T Q(T) = f(A, S, R), \quad (2.15)$$

де:

- A – точність класифікації (Accuracy),
- S – швидкість обробки – швидкодія або час очікування (Latency),
- R – адаптивність до змін у даних, конфігураціях та умовах експлуатації (Robustness).

Функція якості $Q(T)$ є багатокритеріальною, тобто враховує одночасно кілька метрик. У деяких випадках можна застосовувати зважене середнє, що дозволяє балансувати між пріоритетами в залежності від сценарію застосування (наприклад, критичні стани $\rightarrow$ ваги на точність; моніторинг $\rightarrow$ ваги на швидкість):

$$Q(T) = \alpha_1 A + \alpha_2 S + \alpha_3 R, \text{ де } \alpha_i \in [0,1], \sum \alpha_i = 1. \quad (2.16)$$

Обмеження постановки задачі:

- $\exists i: M_i = \emptyset$ – можливість відсутності однієї модальності;
- $\exists t_j \neq t_i$ – часові зсуви між вимірюваннями;

– Обмежені обчислювальні ресурси.

Таблиця 2.3

Схема переходу від проблем до критеріїв оптимізації

Проблема	Вимога до ІТ-системи	Формалізація	Критерій оптимізації
Гетерогенність форматів даних (сигнали, зображення, число)	Уніфікація подання та інтеграція модальностей	$M = \{M_1, M_2, \dots, M_k\}, X_i \in M_i$. Побудова єдиного векторного простору ознак: $x_i = \phi(x_i^{(1)}, \dots, x_i^{(k)})$	Інформаційна повнота інтегрованого представлення
Часова неузгодженість між модальностями	Синхронізація даних за часовими мітками	$\exists t_j = t_i \Rightarrow$ тимчасові зсуви. Вирівнювання часових рядів, агрегування	Узгодженість часових вимірів
Неповнота даних (відсутні модальності або частини вимірювань)	Адаптація до пропусків у даних	$\exists i: M_i = \emptyset$ Застосування автоенкодерів, евристик	Стійкість до втрат
Необхідність точних медичних висновків	Висока точність класифікації	Побудова моделі f , що мінімізує $L(f(X), Y)$	$A = Accuracy(f)$
Повільна обробка в системах з обмеженими ресурсами	Мінімізація часу відповіді	Обмеження на latency: $T_{resp} \leq T_{max}$	$S = Speed(T)$
Вимога інтерпретованості результатів у клінічній практиці	Пояснюваність прогнозів	Використання решітки концептів	$I = Explainability$
Варіативність у конфігураціях пристроїв, умовах, джерелах	Адаптивність до змін середовища	Динамічне оновлення моделі	$R = Robustness$

Цільова функція системи класифікації, що працює над злитим простором ознак X , має вигляд: $f: R^d \rightarrow \{0,1\}$. Тоді оптимальне налаштування моделі досягається через мінімізацію втрат:

$$\min_f L(f(X), Y), \quad (2.17)$$

де L – функція втрат (крос-ентропія), яка вимірює розбіжність між прогнозами моделі та реальними мітками пацієнтів.

Цей етап закладає основу для вибору моделей, побудови ознак, побудови алгоритмів компенсації пропусків і синхронізації, які реалізуються в наступних частинах методології.

Етап 2. Формування ознак і простору подання

На цьому етапі здійснюється побудова узагальненого представлення мультимодальних вхідних даних, що є необхідною передумовою для подальшої класифікації та прийняття клінічних рішень. Завданням є сформувати інтегроване векторне представлення записів пацієнтів на основі гетерогенних модальностей з урахуванням часових, логічних та структурних зв'язків між ними. Для цього слід використати методи формального концептуального аналізу (для виявлення значущих категорій та концептів), методи злиття представлень (multimodal fusion), латентне кодування (autoencoders), семантичне нормування термінів та узгодження з клінічним мисленням (через метод прямої аналогії).

Формалізація процесу інтеграції, де кожен запис x_i представлений набором модальностей: $x_i = (x_i^{(num)}, x_i^{(img)}, x_i^{(sig)})$, де $x_i^{(mod)}$ – вхідні дані певної модальності.

Будується функція злиття представлень: $\varphi: (x_i^{(num)}, x_i^{(img)}, x_i^{(sig)}) \rightarrow z_i \in R^d$, де z_i – узагальнений вектор ознак для подальшої обробки.

Перед побудовою φ здійснюється попередня обробка даних:

- нормалізація: $x_i^{(mod)} \rightarrow \tilde{x}_i^{(mod)}$,
- синхронізація за часовими вікнами,
- відновлення пропущених даних за допомогою автоенкодерів.

Формалізовано цю відповідність як функцію відображення можна представити як: $\psi: C \rightarrow I, \psi(c_j) = i_j, \forall j = 1, \dots, n$, де $C = \{c_1, \dots, c_n\}$ – множина клінічних процедур, $I = \{i_1, \dots, i_n\}$ – множина відповідних інформаційних трансформацій.

Таким чином, на етапі формування простору ознак здійснюється не лише технічне злиття даних, а й семантичне узгодження логіки їх обробки з клінічними процедурами. Це є принципово важливою складовою побудови

прозорої, інтерпретованої та ефективної інформаційної технології для підтримки клінічного прийняття рішень.

Етап 3. Вибір моделей для класифікації

На цьому етапі слід визначити оптимальний набір моделей машинного навчання, здатних ефективно класифікувати стан пацієнта на основі багатовимірної представлення мультимодальних медичних даних з урахуванням гетерогенності, неповноти та часової неузгодженості вхідних джерел. До базових моделей, що використовуються для розв'язання задачі класифікації, включено як класичні алгоритми, так і глибокі нейронні мережі, зокрема згорткові нейронні мережі (CNN) – для обробки зображень та сигналів та рекурентні мережі (LSTM) – для часових рядів.

CNN автоматично витягують просторові ознаки (features) за допомогою фільтрів (ядер згортки), що навчаються, зберігаючи інваріантність до зміщення: $X \in R^{H \times W \times C}$ – вхідне зображення (або спектрограма сигналу), тоді згорткова операція визначається як: $Z_{i,j,k} = \sum_{m,n,c} X_{i+m,j+n,c} \cdot K_{m,n,c,k}$, де K – ядро згортки, Z – вихідний тензор ознак.

LSTM здатні зберігати довгострокову пам'ять, фільтруючи релевантну інформацію в послідовності через механізм вхідного, забувального та вихідного гейту. Нехай $X = [x_1, x_2, \dots, x_T]$, $x_t \in R^d$ – послідовність вхідних ознак, тоді LSTM виконує:

$$\begin{aligned} f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f), i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \\ \tilde{c}_t &= \tanh(W_c x_t + U_c h_{t-1} + b_c), c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \\ o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o), h_t = o_t \odot \tanh(c_t), \end{aligned} \quad (2.18)$$

де h_t – прихований стан, який використовується для класифікації на останньому кроці.

Для дисертаційного дослідження мультимодального аналізу використовується послідовне з'єднання $CNN \rightarrow LSTM$:

- CNN витягує локальні просторові ознаки зі зображень або сигналів,
- LSTM аналізує їхню часову динаміку (наприклад, у серії МРТ-знімків або у сигналі з розбивкою по вікнах).

Залежно від обраного підходу до злиття модальностей, можуть реалізовуватись два ключові принципи побудови класифікаційної системи, наведеного в підрозділі 2.4.

Етап 3.1: Принцип інтеграції мультимодальних ознак (Feature-level fusion)

Цей підхід передбачає попереднє об'єднання ознак з різних модальностей у єдиний вектор ознак ще до навчання моделі. Отриманий вектор репрезентує пацієнта у спільному ознаковому просторі. У цьому контексті:

- CNN використовується для вилучення просторових ознак з медичних зображень (МРТ) та спектрально-перетворених сигналів (ЕКГ, ЕЕГ).
- LSTM виконує подальшу обробку часової структури цих ознак, бо вони подані як послідовність (серії зображень або вікна сигналу).

$$x^{img,sig} \xrightarrow{CNN} z^{img,sig} = [z_1, z_2, \dots, z_T] \xrightarrow{LSTM} h^T \xrightarrow{f} y, \quad (2.19)$$

де:

$z^{img,sig}$ – вектор просторових ознак;

h^T – фінальний стан LSTM;

$y \in \{0,1\}$ – результат класифікації.

Таким чином, функція класифікації визначається як: $f: R^d \rightarrow \{0,1\}$, $y = f(V)$, де $V = \phi(X_1, X_2, \dots, X_k)$ – вектор, отриманий шляхом об'єднання ознак. А композиційна формула має вигляд:

$$y = f \left(\phi \left(LSTM \left([CNN(x_t^{(img)}) \parallel CNN(x_t^{(sig)})] \right), FC(x^{(num)}) \right) \right), \quad (2.20)$$

де:

- $CNN(x_t^{(img)}), CNN(x_t^{(sig)})$ – вилучення просторових ознак;
- $LSTM$ – узагальнення послідовності ознак у вектор h^T ;
- $FC(x^{(num)})$ – приведення числових ознак до спільного простору;
- ϕ – об'єднання модальностей (конкатенація);
- f – класифікатор шар з softmax.

Перевагою такого об'єднання є врахування міжмодальних кореляцій на рівні ознак та гнучкість до подальшого застосування глибоких архітектур.

Етап 3.2: Принцип інтеграції модальних моделей (Model-level fusion)

Цей принцип полягає у побудові окремих моделей для кожної модальності з подальшою агрегацією їх результатів. Формально представимо узагальнене векторне представлення стану пацієнта після попередніх етапів $V^* \in R^d$, та набір моделей класифікації $F = \{f_{CNN}, f_{LSTM}\}$:

- $f_{CNN}: R^{H \times W \times C} \rightarrow \{0,1\}$ – модель на основі зображення або спектрограми сигналу,
- $f_{LSTM}: R^{T \times d} \rightarrow \{0,1\}$ – модель на основі послідовних даних;
- $f_{NUM}: R^m \rightarrow [0,1]$ – модель MLP (англ. Multi-Layer Perceptron) для обробки табличних (структурованих) числових даних.

Відповідно, кожна модель має простір гіперпараметрів: $\theta_{CNN} \in \Theta, \theta_{LSTM} \in \Theta, \theta_{NUM} \in \Theta, f(V^*; \theta_i)$.

Для досягнення балансу між точністю, стійкістю та інтерпретованістю вводимо ваги $\alpha, \beta, \gamma \in [0,1]$, такі що: $\alpha + \beta + \gamma = 1$:

$$y = \alpha \cdot y_{CNN} + \beta \cdot y_{LSTM} + \gamma \cdot y_{NUM}, \alpha + \beta + \gamma = 1. \quad (2.21)$$

Це дозволяє врахувати внесок кожної модальності (зображення, сигнали, числові дані) в остаточне рішення.

Перевагою такого підходу є підвищена стійкість до втрат окремих модальностей та збереження ефективності моделей.

Таблиця 2.4

Інтерпретація у функціональну модель

Функціональний етап	Опис (у контексті CNN і LSTM)
3. Формування профілю	Побудова ознак: $V = \phi(M_1, \dots, M_k) \in R^d$ – для зображень (CNN) і сигналів (LSTM)
4. Виявлення невизначеності	Відновлення пропущених даних: $V \rightarrow V^*$ – через AutoEncoder
5. Аналітичне рішення	$y = f_{CNN}(V^*), y = f_{LSTM}(V^*)$
6. Пояснення рішення	$E = f_{exp}(y, V^*)$ – використання CAM (Class Activation Maps)

Таким чином, вибір базових моделей класифікації є основним етапом розробки інформаційної технології. Він забезпечує адаптацію до різних типів вхідних даних та дозволяє досягти балансу між точністю, інтерпретованістю та ефективністю рішень, що відповідає сучасним вимогам медичних ІТ-систем.

Етап 4. Валідація та оцінка ефективності

Після побудови та попереднього навчання моделей згідно з принципами Feature-level fusion та Model-level fusion, наступним критичним кроком є формалізована оцінка їхньої ефективності за допомогою узгоджених метрик, а також оптимізація гіперпараметрів для досягнення найкращого балансу між точністю, стійкістю та швидкодією.

Основним завданням даного етапу є знайти оптимальне значення гіперпараметрів моделі, яке мінімізує функцію втрат на валідаційній вибірці:

$$\theta^* = \arg \min_{\theta} L_{val}(f_{\theta}(X_{val}), Y_{val}), \quad (2.22)$$

де:

- θ – вектор гіперпараметрів (наприклад, кількість фільтрів у CNN, розмір прихованого шару LSTM);
- L_{val} – функція втрат на валідаційній вибірці;
- f_{θ} – модель класифікації з параметрами θ ;
- X_{val}, Y_{val} – валідаційна вибірка.

Для об'єктивного порівняння моделей вводиться набір метрик (2.11-2.14).

Додатково розраховуються:

- Latency (S) – час обробки одного зразка:

$$Latency(S) = \frac{T_{inference}}{N}, \quad (2.23)$$

де $T_{inference}$ – загальний час передбачення на тестовій вибірці; N – кількість зразків у тестовій вибірці.

- Robustness (R) – стійкість до шумів / пропусків: Підходи до формалізації можуть варіюватися, один із можливих варіантів:

$$Robustness = 1 - \left| \frac{F1_{clean} - F1_{noisy}}{F1_{clean}} \right|, \quad (2.24)$$

де: $F1_{clean}$ – F1-метрика на «чистих» даних, а $F1_{noisy}$ – F1-метрика на зашумлених або неповних даних. Якщо $R \approx 1 \rightarrow$ модель майже не втрачає якість при шумі, тобто висока стійкість.

- Стабільність (Var) – дисперсія результатів моделі при різних запусках або при крос-валідації, що свідчить про узагальнюваність:

$$Var = \frac{1}{K} \sum_{i=1}^K (F1_i - \overline{F1})^2. \quad (2.25)$$

Для інтегральної оцінки моделі вводиться функція оцінки якості:

Для кожної з моделей або для їх об'єднання обчислюється функція оцінки її якості:

$$Q(f_i) = \alpha_1 A_i + \alpha_2 S_i + \alpha_3 R_i, \sum_{j=1}^3 \alpha_j = 1, \quad (2.26)$$

де:

A_i – точність (Accuracy);

S_i – швидкодія (Latency);

R_i – стійкість до пропусків/шумів (Robustness).

α_j – вагові коефіцієнти, що регулюють значущість кожної характеристики у фінальній оцінці (обираються емпірично або експертно).

Після обчислення функції оцінки якості кожної моделі, найкраща конфігурація визначається за максимальним значенням $Q(f_i)$:

$$f^* = \arg \max_{f_i \in F} Q(f_i), \quad (2.27)$$

де F – множина всіх моделей після гіперпараметричної оптимізації.

Таким чином, побудована методологія охоплює весь життєвий цикл обробки мультимодальних медичних даних – від збору та попередньої обробки до класифікації стану пацієнта (Рис. 2.12). Вона забезпечує:

- інтеграцію гетерогенних джерел;
- стійкість до пропусків і шуму;
- підтримку багатовимірних структур даних;
- адаптацію до змін клінічної інформації;
- прозорість та інтерпретованість результатів.

На основі поданої схематично на рисунку 2.12 методології формуються моделі, алгоритми та програмні реалізації, які відповідають сучасним вимогам цифрової медицини та аналітичної підтримки клінічних рішень.




Рис. 2.12. Схема методології багатовимірного аналізу мультимодальних даних

У результаті поетапної побудови архітектури інформаційної технології багатовимірного аналізу мультимодальних медичних даних було сформовано цілісну методологічну та технічну основу, яка забезпечує ефективну, інтерпретовану й адаптивну обробку клінічної інформації в умовах сучасної цифрової медицини.

Отже, запропонований методологічний базис інформаційної технології багатовимірного аналізу мультимодальних медичних даних обраний правильно, оскільки він враховує як структурну складність джерел інформації, так і потребу в прозорості та адаптивності клінічних рішень. На його основі необхідно побудувати нові моделі, методи та механізми, які забезпечують:

- інтегровану обробку різнорідних медичних даних з урахуванням часових, просторових і логічних зв'язків між модальностями;
- глибоку інтерпретацію результатів аналізу, засновану на концептуальних структурах;
- адаптацію до неповних, зашумлених або нестабільних даних, притаманних реальній клінічній практиці;
- багатокритеріальну оптимізацію аналітичних процедур, що дозволить одночасно забезпечити високу точність, продуктивність та довіру до рішень;
- динамічне оновлення знань шляхом впровадження механізмів онлайн-навчання, самоадаптації та самопояснення рішень.

Таким чином, подальший розвиток технології ґрунтується на переході від загальної методології до конкретних алгоритмічних та технологічних реалізацій, що дозволяють формалізувати весь життєвий цикл аналізу мультимодальних медичних даних – від їх збору до прийняття обґрунтованого клінічного рішення.

Висновки до розділу 2

У другому розділі дисертаційної роботи сформовано методологічний базис інформаційної технології багатовимірного аналізу мультимодальних медичних даних. На основі аналізу філософських, загальнонаукових та прикладних принципів було обґрунтовано необхідність розробки інтерпретованої, адаптивної, масштабованої та багатокритеріально оптимізованої системи для обробки структурно складної, гетерогенної та динамічної медичної інформації.

1. Здійснено формалізацію основних етапів функціонування інформаційної технології, що включає структуру вхідних даних, моделі обробки, функцію класифікації та механізми пояснення результатів. Запропоновано математичну схему представлення процесів, яка слугує базою для побудови системи, здатної працювати з різнорідними, частково неповними або асинхронними медичними даними. Формалізація дає змогу забезпечити прозорість, структурованість і можливість валідації розробленої технології.

2. Сформульовано дослідницьку гіпотезу, згідно з якою поєднання ознак із кількох модальностей у багатовимірному просторі дозволяє досягти вищої точності, стійкості та адаптивності моделей при класифікації станів пацієнтів. Обґрунтовано доцільність використання багатокритеріального підходу як фундаменту методології. Гіпотеза також враховує виклики, пов'язані з неповнотою, шумами та гетерогенністю медичних даних.

3. Представлено концепцію багатовимірного аналізу, що базується на створенні єдиного узгодженого простору ознак, сформованого на основі адаптивної інтеграції різнорідних джерел медичної інформації. Концепція передбачає поділ обробки на модальні та міжмодальні рівні з подальшою агрегацією результатів. Це дозволяє зберігати семантичну цілісність кожної модальності й водночас отримувати узагальнені висновки високої точності.

4. Систематизовано принципи, що лежать в основі функціонування технології: інтегративність, узгодженість, адаптивність, пояснюваність, масштабованість, стійкість до пропусків і етичність. Визначено їхнє методологічне значення для побудови систем, що працюють у медичних умовах із високими вимогами до точності, прозорості та надійності. Принципи забезпечують узгодження між теоретичною моделлю й практичними вимогами клінічного середовища.

5. Сформовано загальну методологію побудови інформаційної технології, що поєднує формалізовані підходи до обробки даних, вибору моделей, агрегування результатів та побудови пояснень. Методологія враховує як аналітичні, так і інформаційні аспекти системної реалізації та визначає послідовність переходу від гіпотетичної моделі до готової прикладної технології. Вона орієнтована на підвищення ефективності підтримки медичних рішень на основі глибокої обробки мультимодальних даних.

Результати досліджень за другим розділом опубліковано в роботах автора [4, 7, 20, 27, 35] (Додаток Б).

РОЗДІЛ 3

ПОБУДОВА УНІФІКОВАНОГО ОЗНАКОВОГО ПРОСТОРУ ДЛЯ МУЛЬТИМОДАЛЬНИХ МЕДИЧНИХ ДАНИХ

У розділі 3 описано створення узгодженого та структурованого простору ознак, що поєднує різні медичні модальності для використання в аналітичних моделях. Подано побудову мел-частотних кепстральних коефіцієнтів для стислого подання аудіосигналів. Розглянуто застосування прихованих марковських моделей разом із глибокими нейронними мережами для моделювання динаміки аудіоданих. Як альтернативу проаналізовано метод опорних векторів з використанням фільтраційних і редукційних технік.

Представлено методи побудови дескрипторів зображень на основі алгоритмів SIFT, HOG та вейвлет-перетворення, що забезпечують масштабну, обертальну та просторово-частотну інваріантність. Наведено математичні основи обчислення градієнтів, ключових точок, а також порівняльний аналіз алгоритмів щодо їхньої ефективності, точності та стійкості до шуму.

Окрему увагу приділено уніфікації гетерогенних медичних модальностей, зокрема ЕЕГ, ЕКГ, МРТ та клінічних даних. Запропоновано підходи до цифрової обробки сигналів, спектрального аналізу, побудови воксельних структур томографічних даних та нормалізації ознак. Результатом є формування узгодженого ознакового простору у табличному форматі, який забезпечує інтеграцію всіх модальностей та підготовку до використання у моделях статистичного аналізу, машинного навчання та медичних систем.

3.1. Виділення ознак із сигналів на основі основі мел-частотних кепстральних коефіцієнтів

Мел-частотні кепстральні коефіцієнти (англ. Mel-frequency cepstral coefficients (MFCCs)) являють собою числові характеристики, що описують мел-кепстральне представлення сигналу. Вони є важливим етапом попередньої обробки сигналів у мультимодальних інформаційних системах. В основі

побудови цих коефіцієнтів лежить шкала мел, яка є психоакустичною одиницею висоти звуку, що відповідає особливостям сприйняття частот людським слухом.

Особливістю реалізованого підходу є врахування того, що частотна та амплітудна чутливість слухової системи людини не є лінійною. Наприклад, амплітуда не відповідає прямо відчутній гучності, що обумовлює потребу в адаптивному перетворенні вхідного сигналу перед його поданням на вхід алгоритмів машинного навчання. У цьому контексті MFCC слугують зручним представленням сигналу для подальшого аналізу, оскільки поєднують фізичні та перцептивні властивості звуку.

Аналогічним чином, сприйняття висоти звуку також не є лінійною залежністю від частоти, що показано на рисунку 3.1 [182]. Це зумовлює застосування нелінійних шкал і логарифмічних перетворень, які забезпечують узгодженість обчислених ознак із реальними характеристиками сприйняття аудіоінформації. У результаті, MFCC розглядаються в дисертації не лише як інженерний інструмент, а й як психоакустично обґрунтований метод узгодження аудіосигналів з вимогами ІТ-систем, що підвищує точність та інтерпретованість результатів класифікації в рамках мультимодального аналізу.




Рис. 3.1. Графік залежності висоти звуку в мелах від частоти коливань

Наводиться за [182]

У межах розробленого підходу до обробки аудіоданих у мультимодальних інформаційних технологіях, математичною основою для побудови мел-частотних кепстральних коефіцієнтів (MFCC) є нелінійне перетворення частоти,

яке узгоджується з особливостями сприйняття висоти звуку людиною. Відповідно до психоакустичної шкали мел, перетворення реальної частоти f (у герцах) у шкалу мел відбувається за формулою 3.1. Математично залежність звуку від частоти коливань є можливість представити як:

$$m = 1125 \ln(1 + f/700). \quad (3.1)$$

Ця формула забезпечує логарифмічне стискання частотного діапазону, наближаючи машинне представлення до особливостей людського слуху, що критично важливо при аналізі мовлення.

У свою чергу, кепстр є одним із видів гомоморфної обробки сигналів, тобто є функцією зворотного перетворення Фур'є від логарифму спектра потужності сигналу:

$$C_s(q) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \ln|S(\omega)|^2 e^{i\omega q} d\omega, \quad (3.2)$$

де $S(\omega)$ – спектр вхідного сигналу; q – кепстральний час.

Такий підхід дозволяє ефективно відокремлювати повільно змінні складові спектру (резонансні форманти) від швидко змінних (гармоніки), що є фундаментальним для виявлення акустичних ознак.

Таким чином, у межах запропонованої реалізації MFCC не лише забезпечують фізично обґрунтоване перетворення аудіосигналу, але й формують стиснене, стійке до завад ознакове представлення, яке зручно інтегрується з іншими модальностями в межах спільного ознакового простору.

Розроблена схема формування акустичної хвилі, представлена у вигляді функціональної блок-схеми на рисунку 3.2, може слугувати основою для цифрового моделювання сигналів.

Наведена на рисунку 3.2 схема процесу слугує теоретичною основою для реалізації ефективних алгоритмів обробки сигналів і формування ознакових представлень, придатних для подальшого використання в мультимодальних системах машинного навчання.




Рис. 3.2. Схема формування акустичної хвилі сигналу

Сигнал на виході цифрового фільтру в математичному представленні має вигляд:

$$f(t) = s(t) \otimes h(t), \quad (3.3)$$

де $s(t)$ – вид акустичної хвилі; $h(t)$ – характеристика параметрів фільтру.

У дискретному вигляді сигнал має вигляд: $x[n], 0 \leq n < N$.

Застосовуючи перетворення Фур'є, отримаємо:

$$X_a[k] = \sum_{n=0}^{N-1} x[n] e^{-\frac{2\pi i}{N} kn}, 0 \leq k < N. \quad (3.4)$$

Низка фільтрів формується на базі кінцевої функції, показаної через систему:

$$H_m = \begin{cases} 0 & k < f[m-1] \\ \frac{(k - f[m-1])}{(f[m] - f[m-1])} & f[m-1] \leq k < f[m] \\ \frac{(f[m+1] - k)}{f[m+1] - f[m]} & \\ 0 & \end{cases} \quad (3.5)$$

$$\begin{aligned} f[m] &\leq k < f[m+1] \\ k &> f[m+1], \end{aligned}$$

для якої:

$$f[m] = \left(\frac{N}{F_s}\right) B^{-1}(B(f_1)) + m \frac{B(f_h) - B(f_1)}{M+1}, \quad (3.6)$$

де $B(b)$ – перетворення значення частоти у мел-шкалу, відповідно:

$$B^{-1}(b) = 700 \left(\exp\left(\frac{b}{1125}\right) - 1 \right). \quad (3.7)$$

Частотна область визначається як: $F(\omega) = S(\omega)H(\omega)$. Після логарифмування отримаємо суму: $\ln[S^2(\omega) \cdot H^2(\omega)] = \ln S^2(\omega) + \ln H^2(\omega)$.

Застосовуючи перетворення Фур'є, отримаємо набори характеристик вихідного сигналу і фільтра, що не перетинаються:

$$C_s(q) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \ln[F(\omega)]^2 e^{i\omega q} d\omega. \quad (3.8)$$

Енергію для кожного окремого вікна знаходимо як:

$$S[m] = \ln \left(\sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k] \right), 0 \leq m \leq M. \quad (3.9)$$

У межах реалізації розробленого підходу до обробки модальних даних, дискретне косинусне перетворення (DCT) використовується як завершальний етап обчислення мел-частотних кепстральних коефіцієнтів (MFCC). На цьому етапі відбувається декореляція частотних ознак і перехід до компактного представлення, зручного для аналізу й класифікації.

Застосовуючи дискретне косинусне перетворення, отримаємо:

$$c[n] = \sum_{m=0}^{M-1} S[m] \cos(\pi n(m + 1/2)/M), 0 \leq n < M. \quad (3.10)$$

Ефективність обчислення MFCC досягається завдяки сегментації сигналу на короткі часові вікна. Для кожного фрагмента окремо здійснюється спектральний аналіз, побудова мел-банку, логарифмування та дискретне косинусне перетворення. Після цього кожному сегменту присвоюється вагова оцінка, яка відображає його значущість у формуванні акустичної моделі.

Такий підхід дозволяє не лише точніше представити динаміку ознак, а й адаптувати аналіз до змін частоти сигналу, що критично важливо для систем обробки та аналізу сигналів в умовах варіативного середовища. Запропоноване рішення оптимізує обчислювальне навантаження й підвищує надійність ознакової бази для подальшої інтеграції у мультимодальну ІТ-систему.

3.2. Виділення ознак із сигналів прихованими марковськими моделями

У межах запропонованого підходу до обробки сигналів можлива альтернатива здійснення обробки на основі прихованих марковських моделей (англ. Hidden Markov Model (HMM)). Вони дозволяють здійснювати ефективне розпізнавання сигналів у різноманітному акустичному середовищі. З огляду на велику варіативність звукових подій, попередній етап обробки передбачає застосування фільтра Калмана для зниження рівня шуму у вхідному сигналі.

Цей фільтр працює на основі методу мінімізації середньоквадратичної похибки оцінювання, використовуючи просторово-станову модель для опису динаміки сигналів і шумів. Станові змінні моделі оновлюються шляхом прогнозування на основі попередніх оцінок та поточних спостережень. Результати фільтрації отримуються за допомогою ітеративної процедури, яка забезпечує адаптивну обробку звуку в реальному часі.

Конкретні етапи функціонування фільтрації моделюються згідно з рівняннями:

$$\begin{aligned}x_k &= Ax_{k-1} + Bu_k + W_k, \\z_k &= Hx_k + v_k.\end{aligned}\tag{3.11}$$

У цих виразах описується визначення системи дискретних процесів керування x_k , які можна описати лінійними стохастичними диференціальними рівняннями та вимірними значеннями системи z_k . x_k відповідає стану системи в момент часу k . u_k – контрольна величина системи в момент часу k . A і B – параметри системи. z_k – вимірне значення в момент часу k . H – параметр вимірювальної системи. W_k – шум процесу, який вважається білим шумом Гауса,

і його коваріація дорівнює Q . v_k – шум вимірювання, який вважається білим шумом Гауса, і його коваріація дорівнює R .

Використання процесу моделювання системи робить можливим прогнозування поточного стану $x(k|k-1)$ на основі попереднього стану:

$$x(k|k-1) = Ax(k-1|k-1) + Bu_k, \quad (3.12)$$

де $x(k|k-1)$ позначає оптимальний результат попереднього стану.

Далі процес продовжується оновленням коваріації P :

$$P(k|k-1) = AP(k-1|k-1)A^T + Q. \quad (3.13)$$

Оптимальне оцінене значення $x(k|k)$ поточного стану k можна отримати шляхом поєднання прогнозованого значення та виміряного значення:

$$x(k|k) = x(k|k-1)g_k(z_k - Hx(k|k-1)), \quad (3.14)$$

де H^T являє собою транспозицію H у його вираженні, а g_k – коефіцієнт підсилення Калмана, визначений як $g_k = P(k|k-1)H^T / (HP(k|k-1)H^T + R)$.

У процесі роботи фільтра Калмана коваріація $x(k|k)$ у стані k оновлюється:

$$P(k|k) = (I - g_k H)P(k|k-1), \quad (3.15)$$

де I відповідає матриці 1. $P(k|k)$ зміниться на $P(k-1|k-1)$, коли система перейде в стан $k+1$.

За своєю суттю прихована модель Маркова являє собою імовірнісну графічну модель, яка описує два взаємозалежних стохастичних процеси: спостережуваний процес і прихований процес Маркова. Через обчислення ймовірності вибирається максимальна можливість оцінити вихідну послідовність прогнозованого звуку. Зазвичай дана модель комбінується з моделлю глибокої нейронної мережі (CNN), де НММ використовується для опису динамічних змін сигналів, тоді як CNN використовується для оцінки ймовірності спостережуваних особливостей.

Оскільки декодування в прихованій марковській моделі (НММ) базується на ймовірності правдоподібності, вихідна ймовірність, отримана з нейронної

мережі CNN, має бути перетворена у відповідну форму правдоподібності згідно з виразом:

$$p(x_t|q_t) = p(q_t|x_t)p(x_t)/p(q_t), \quad (3.16)$$

де x_t – це спостережуване значення; q_t – стан у момент часу t ; результуюча акустична ймовірність виражається наступним чином:

$$\begin{aligned} p(x|w) &= \sum_q p(x, q|w)p(q|w) \\ &\cong \max \pi(q_0) \prod_{t=1}^T a_{qt} - 1_{qt} \prod_{t=0}^T \frac{p(q_t|x_t)p(x_t)}{p(q_t)}, \end{aligned} \quad (3.17)$$

де w виражає можливу послідовність розпізнавання, отриману за допомогою алгоритму Вітербі; $p(q_t|x_t)$ обчислюється за допомогою CNN; $p(q_t)$ – апіорна ймовірність стану; $\pi(q_0)$ і $a_{qt} - 1_{qt}$ – ймовірність початкового стану та ймовірність переходу стану, визначені НММ [2].

За умови встановлення початкової ймовірності до значень $[1, 0, 0, \dots, 0]$, що означає, що навчання моделі може починатися лише з першого стану, визначаються такі статистики:

$$\begin{aligned} \gamma_t^c(j, k) &= \left[\frac{\alpha_t(j)\beta_t(j)}{\sum_{j=1}^N \alpha_t(j)\beta_t(j)} \right] \left[\frac{c_{jk}G(o_t^c, \mu_{jk}, \Sigma_{jk})}{\sum_{k=1}^K c_{jk}G(o_t^c, \mu_{jk}, \Sigma_{jk})} \right] = \\ &= \begin{cases} \frac{1}{p(o|\lambda)} \pi_j \beta_1(j) c_{jk} G(o_1^c, \mu_{jk}, U_{jk}), t = 1 \\ \frac{1}{p(o|\lambda)} \sum_{i=1}^N \alpha_t - 1(i) a_{ij} \beta_t(j) c_{jk} G(o_1^c, \mu_{jk}, U_{jk}), t > 1 \end{cases}, \end{aligned} \quad (3.18)$$

де $\alpha_t(j)$ – пряма ймовірність побачити послідовність спостереження $\{o_1, o_2, \dots, o_t\}$ в момент часу t і в прихованому стані q_t ; $\beta_1(j)$ – зворотна ймовірність генерації решти послідовності спостереження $\{o_1 + t, o_2 + t, \dots, o_T\}$ від часу $t + 1$ до кінця часу T після перебування в t у прихованому стані q_t у момент часу t ; c_{jk} – пропорція, присвоєна компоненті Гауса k для спостережень, пов'язаних зі станом s_j ; $p(o|\lambda)$ – граничний розподіл ймовірностей; G – функція Гауса; $\gamma_c^t(j, k)$ – вага.

На основі формул повторної оцінки НММ параметри генеруються наступним чином:

$$\begin{aligned}
 a_{ij} &= \frac{\sum_{c=1}^C \sum_{t=1}^{T_c-1} \xi_t^c(i, j)}{\sum_{c=1}^C \sum_{t=1}^{T_c-1} \gamma_t^c(i)} \\
 c_{jk} &= \frac{\sum_{c=1}^C \sum_{t=1}^{T_c} \gamma_t^c(j, k)}{\sum_{k=1}^K \sum_{c=1}^C \sum_{t=1}^{T_c} \gamma_t^c(j, k)} \\
 \mu_{jk} &= \frac{\sum_{c=1}^C \sum_{t=1}^{T_c} \gamma_t^c(j, k) ot^c}{\sum_{c=1}^C \sum_{t=1}^{T_c} \gamma_t^c(j, k)} \\
 \sum ij &= \frac{\sum_{c=1}^C \sum_{t=1}^{T_c} \gamma_t^c(j, k) (ot^c - \mu_{jk})(ot^c - \mu_{jk})'}{\sum_{c=1}^C \sum_{t=1}^{T_c} \gamma_t^c(j, k)},
 \end{aligned} \tag{3.19}$$

де C відповідає кількості навчальних вибірок; $\xi_t^c(i, j)$ представляє ймовірність перебування в прихованому стані s_i в момент часу t і перебування в прихованому стані s_j в момент часу $t + 1$.

Запропонований підхід, поєднаний із CNN, дозволяє збільшити стійкість та точність розпізнавання навіть у складних акустичних середовищах. Ця методика використовується як ядро алгоритмічної частини системи мультимодального аналізу сигналів, забезпечуючи адаптивність, масштабованість та інтеграцію з іншими модальностями.

3.3. Підходи до класифікації сигналів у мультимодальних системах

У межах розробленої моделі мультимодального аналізу сигнальних даних додатково реалізовано підхід на основі методу опорних векторів (англ. Support Vector Machines (SVM)) як альтернативу НММ+CNN для задач класифікації сигналів. Зокрема, SVM використовується для побудови оптимальної гіперплощини, що максимально відокремлює класи у просторі ознак.

При наявному навчальному наборі пар екземпляр-мітка $(x_i, y_i)_{i=1, \dots, m}$, де $x_i \in \mathbb{R}^n$ та $y_i \in \{1, -1\}^m$, SVM використовуються для пошуку гіперплощини для розділення даних із максимальним запасом. Для цього необхідно вирішити визначену задачу оптимізації [190]:

$$\min M = \frac{1}{2} W^T W \rightarrow y_i (W^T \phi(x_i) + b) \geq 1. \quad (3.20)$$

Задля удосконалення реалізації враховано м'який поріг класифікації, який дозволяє працювати зі слабо відокремлюваними або частково зашумленими даними. Це формує альтернативну задачу оптимізації з використанням штрафних змінних та гіперпараметра регуляризації, що дозволяє досягти балансу між узагальненням та чутливістю до даних навчального набору.

При використанні м'якого порогового визначення можна отримати основну проблему методу:

$$\min M = \frac{1}{2} W^T W + C \sum_{i=1}^n \xi_i \rightarrow y_i (W^T \phi(x_i) + b) \geq 1 - \xi_i; \xi_i \geq 0, \quad (3.21)$$

де $\{\xi_i\}$ являє собою змінні затримки, які дозволяють штраф через штрафну функцію $F(\xi)$, яка визначається як:

$$F(\xi) = \sum_{i=1}^n \xi_i, \quad (3.22)$$

де C відповідає параметру, який контролює компроміс між великим запасом і менш обмеженим порушенням.

При використанні методу опорних векторів класифікація базується на трьох кроках: використання нових та тембральних функцій, вибір функцій шляхом комбінування методів фільтра та обгортка та оптимізація класифікатора SVM [191]. Ознаки досліджуваного аудіоматеріалу обчислюються на основі короткочасного перетворення Фур'є, яке виражається відповідно до (3.23):

$$S(t, f_k) = \int_{-\infty}^{+\infty} s(\tau - t) w(\tau) \exp(-j2\pi \cdot f_k \cdot \tau) d\tau. \quad (3.23)$$

Для найкращої частотно-часової локалізації ефективним є використання вікна $w(t)$ зі змінною довжиною. Потім виділення ознак базується на поділі аудіосигналу $s(t)$ на послідовні кадри, де кожен кадр $s_k(t)$ з індексом k і тривалістю T_k обчислюється як:

$$s_k(t) = s(t) \cdot w_k(t), \quad (3.24)$$

де $w_k(t)$ являє собою вікно Ханна, яке виражається через:

$$w_k(t) = \begin{cases} 0.5 + 0.5 \cos\left(2\pi \frac{t}{T_k}\right); & \text{якщо } \frac{T_k}{2} \leq t \leq \frac{T_k}{2}. \\ 0 & \end{cases} \quad (3.25)$$

Оскільки всі обчислені ознаки не є релевантними для завдання класифікації, вони мають бути попередньо оброблені шляхом зменшення розмірності, щоб полегшити завдання класифікації. Ознаки спочатку фільтруються, щоб усунути зайві. Завдяки цій операції, яка вибирає змінні як етап попередньої обробки, отримані ознаки є менш корельованими, внаслідок чого виконується значне їх скорочення. Зазначена операція дозволить краще зрозуміти інформацію, що міститься в цій підмножині вибраних функцій. Таким чином, тривалість обчислення буде короткою для оболонки, яка вибирає лише ті ознаки, які покращують точність передбачення та покращують ефективність класифікації.

Для реалізації ефективної фільтрації ознак в інформаційних системах обирається структура, яка одночасно відповідає двом ключовим критеріям: відбір інформативних ознак для кожного класу та усунення надлишкових або високорельованих функцій. З цією метою застосовується підхід, побудований на принципах лінійного дискримінантного аналізу (англ. Linear Discriminant Analysis (LDA)), який ітераційно здійснює вибір ознак, задовольняючи обидва вищезазначені критерії.

Зазначений підхід реалізується у два етапи. На першому кроці, під час початкової ітерації, відбирається така функція, яка ще не використовувалась, але забезпечує максимізацію відношення між міжкласовою інерцією та загальною інерцією вибірки. Це співвідношення описується формулою:

$$\hat{d}^{(i)} = \arg \max_d \frac{\sum_{k=1}^K n_k (\mu_{d,k} - \mu_d)(\mu_{d,k} - \mu_d)^T}{\sum_{i=1}^n (f_{d,i}^{(l)} - \mu_d)(f_{d,i}^{(l)} - \mu_d)^T}, \quad (3.26)$$

де n відповідає загальній кількості ознак, n_k — кількість ознак, що належать до класу k , $f_{d,i}^{(l)}$ позначає значення ознаки індексу d , що впливає на вектор i , $\mu_{d,k}$ і μ відповідно позначають середнє значення ознаки d у класі k і для загального набору даних.

Другий крок цього методу спрямований на ортогоналізацію залишкової функції для наступної ітерації:

$$f^{(l+1)}_{d,i} = f^{(l)}_{d,i} - (f^{(l)}_d \cdot g_d) g_d \quad \forall d \neq \hat{d}^{(i)}, \quad (3.27)$$

де $f^{(i)}_{\hat{d}}$ відповідає вектору попередньо обраної ознаки $\hat{d}^{(i)}$, $g_{\hat{d}} = \frac{f^{(i)}_{\hat{d}}}{\|f^{(i)}_{\hat{d}}\|}$ є

нормалізованою функцією даної ознаки.

Отож, узагальнюючи викладене вище, зауважимо, що перший метод ґрунтується на використанні мел-частотних кепстральних коефіцієнтів (MFCC). Цей підхід дозволяє трансформувати сигнали у форму, зручну для подальшого аналізу, виокремлюючи акустичні характеристики.

Другий підхід базується на прихованих марковських моделях (HMM) і часто застосовується для моделювання часової динаміки сигналу. HMM забезпечує точну обробку змін акустичних ознак у часі.

Третій метод – це застосування машин векторної підтримки (SVM), що демонструє високу ефективність у класифікаційних задачах. SVM надає можливість чітко розмежовувати різні класи сигналів, включаючи виявлення специфічних шумів у навколишньому середовищі. Завдяки пошуку оптимальної гіперплощини для розділення класів, цей метод забезпечує високу точність у випадках, де присутні чітко виражені відмінності між аудіокатегоріями.

Усі три підходи, реалізовані в розробленому мультимодальному фреймворку, продемонстрували високу ефективність при різних сценаріях застосування, що дозволяє стверджувати про їх комплементарність у створенні інтелектуальних ІТ-рішень у сфері обробки медичних сигналів.

3.4. Виділення ознак з цифрових зображень

В області інформаційних технологій одним із поширених способів витягування ознак у цифрових зображеннях є SIFT (англ. Scale-Invariant Feature Transform) є масштабно-інваріантне перетворення ознак. Цей алгоритм базується на аналізі різниці Гаусса (англ. Difference of Gaussian (DoG)) для виявлення стійких ключових точок зображення незалежно від масштабів і поворотів.

Алгоритм SIFT реалізується через шість послідовних етапів: побудова масштабного простору, формування гауссової піраміди, виявлення екстремумів, точне позиціонування ключових точок, визначення їх орієнтації та створення дескрипторів, які відображають локальні особливості зображення. Ці дескриптори широко застосовуються в задачах розпізнавання об'єктів, порівняння зображень і класифікації у складних мультимодальних ІТ-системах [214].

Задля того, щоб симулювати багатомасштабні характеристики даних зображення, розроблена модель обробки, яка передбачає безперервну зміну параметрів масштабу для отримання зображень у різних роздільних здатностях. Масштабний простір визначає ступінь розмиття зображення. Різні масштаби можна представити як згортку зображень з ядрами Гаусса:

$$P(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (3.28)$$

$$L(x, y, \sigma) = G(x, y, \sigma) * P(x, y).$$

У свою чергу, побудова піраміди Гаусса передбачає створення зображень у кількох масштабах. Цей процес обчислює різницю значень пікселів між двома сусідніми шкалами:

$$\begin{aligned} (x, y, \sigma) &= (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y), \\ D(x, y, \sigma) &= L(x, y, k\sigma) - L(x, y, \sigma). \end{aligned} \quad (3.29)$$

У процесі виявлення крайньої точки пікселі в різниці Гаусса (DoG) порівнюються з їх сусідніми пікселями. За допомогою цього порівняння певні точки, незважаючи на різні умови, такі як яскравість, темрява або ефекти країв; демонструють стабільність і послідовність у різних масштабах.

Масштаб і положення точок ознак визначаються за допомогою методу найменших квадратів, застосованого до розширення другого порядку функції масштабу:

$$D(X) = D + \frac{\partial D^T}{\partial X^2} X + \frac{1}{2} X^T \frac{\partial^T D}{\partial X^2} X. \quad (3.30)$$

Коли перша похідна дорівнює 0, суть функції виражається таким чином:

$$\hat{X} = \frac{\partial^2 D^{-1}}{\partial X^2} \frac{\partial D}{\partial X}. \quad (3.31)$$

Отримання точки ознаки відбувається за таким рівнянням:

$$D(\hat{X}) = D + \frac{1}{2} \frac{\partial D^T}{\partial X} \hat{X}. \quad (3.32)$$

Далі для точки ознаки береться вибірка її сусідніх пікселів і вказуються параметри напрямку:

$$m(x, y) = \sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2},$$

$$\theta(x, y) = \tan^{-1} \left(\frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \right), \quad (3.33)$$

де $m(x, y)$ представляє шаблон градієнта на (x, y) , а діапазон становить 0° до 360° ; коли він розділений на n стовпців, то він показує напрямки.

У сфері інформаційних технологій широко застосовуються методи, орієнтовані на вилучення ознак із гістограм орієнтованих градієнтів (англ. Histogram of Oriented Gradients (HOG)), які дозволяють ефективно описувати локальні форми та контури в цифрових зображеннях.

Розроблено рішення, що передбачає інтеграцію HOG у пайплайн попередньої обробки зображень, які реалізується як послідовність етапів трансформації необробленого сигналу з матриці датчика у фінальне кольорове зображення високої якості. Структура пайплайна може відрізнятися залежно від виробника пристрою, з варіативністю в реалізації методу для кожного етапу та порядку їх виконання.

Одним із критичних кроків є демозаїка, яка перетворює одноканальне зображення, сформоване за шаблоном Байєра, у триканальне RGB-зображення шляхом інтерполяції відсутніх кольорних компонентів у кожному пікселі. Сучасні алгоритми демозаїки є ресурсоемними, оскільки націлені на мінімізацію кольорових артефактів і максимальну точність реконструкції.

Наступним важливим етапом є тональне відображення, що виконує стиснення динамічного діапазону зображення для його адаптації під дисплеї з

обмеженою розрядністю (зазвичай 8 біт на піксель). Найпоширенішим методом є гамма-корекція, яка трансформує значення інтенсивності пікселів $I^k(x, y)$ у нові значення $I'^k(x, y)$, відповідно до формули (3.34), забезпечуючи збереження візуального контрасту та відповідності до стандартів відображення.

$$I'^k(x, y) = A \times (I^k(x, y))^\gamma, \quad (3.34)$$

де x і y представляють координату x і координату y розташування пікселя відповідно, k представляє один із трьох каналів серед R, G і B. A і γ є двома параметрами перетворення для визначення ефекту гамма-стиснення.

Завершальним етапом обробки цифрового зображення в ІТ-системах є усунення шумів, які виникають як внаслідок особливостей роботи сенсора, так і на різних етапах формування зображення в пайплайні.

У межах методу Histogram of Oriented Gradients (HOG) основні етапи виділення ознак можна узагальнити як: обчислення градієнтів, групування за орієнтацією та формування дескрипторів.

1. Градієнтне обчислення виконується через аналіз просторових змін інтенсивності зображення в горизонтальному та вертикальному напрямках. З отриманих значень обчислюються модулі та кути векторів градієнтів.
2. Групування орієнтації дозволяє розбивати зображення на малі осередки (комірки), у межах яких величини градієнтів розподіляються по бінарних контейнерах відповідно до орієнтації градієнта кожного пікселя.
3. Формування дескриптора виконується через об'єднання комірок в блоки для виконання L2-нормалізації для забезпечення інваріантності до змін освітлення. Згодом усі нормалізовані гістограми в межах вікна виявлення поєднуються в єдиний HOG-дескриптор, який використовується для подальшого аналізу або класифікації у інформаційних системах.

Для забезпечення стабільності отриманих ознак в умовах змін зовнішнього середовища вперше пропонується додаткову адаптацію до рівня шуму зображення. Це дозволяє інтегрувати HOG-дескриптори у мультимодальні моделі, де зображення є лише одним із компонентів узгодженого аналізу поряд з іншими модальностями.

Для двовимірної функції $f(x, y)$, вирахування градієнтів із зображень шаблонів Байєра можна обчислити за допомогою похідних по x і y . Для цифрового зображення, де x і y є дискретними значеннями, похідні можуть бути апроксимовані кінцевими різницями.

Градієнт на місці пікселя (x, y) обчислюється як:

$$\begin{aligned} G_x &= I(x+1, y) - I(x-1, y), \\ G_y &= I(x, y+1) - I(x, y-1), \end{aligned} \quad (3.35)$$

де G_x і G_y представляють градієнти в горизонтальному та вертикальному напрямках відповідно.

Обчислення реалізуються шляхом згортання зображень із двома 1-D масками $[-1, 0, 1]$ і $[-1, 0, 1]^T$. Застосування 1-D масок на місці пікселя $(1, 2)$ створює:

$$\begin{aligned} G^B_{x(1,2)} &= I^B_{(1,3)} - I^B_{(1,1)}, \\ G^R_{y(1,2)} &= I^R_{(2,2)} - I^R_{(0,2)}, \end{aligned} \quad (3.36)$$

де G^B і G^R відповідають градієнтам синього і червоного каналів відповідно.

Два пікселі, що використовуються як вхідні значення для згорткової маски з коефіцієнтами 1 і -1, належать до одного й того самого кольорового каналу і розміщені на пікселях з аналогічними характеристиками. Це твердження залишається справедливим незалежно від їхнього розташування, за умови дотримання правильної схеми чергування в мозаїці Байєра.

Більше того, з урахуванням міжканальної кореляції, властивій природним зображенням, виконується наступна залежність:

$$\begin{aligned} I^B_{(1,3)} - I^B_{(1,1)} &\approx I^{\hat{R}}_{(1,3)} - I^{\hat{R}}_{(1,1)} \approx I^{\hat{G}}_{(1,3)} - I^{\hat{G}}_{(1,1)}, \\ I^B_{(2,2)} - I^B_{(0,2)} &\approx I^{\hat{B}}_{(2,2)} - I^{\hat{B}}_{(0,2)} \approx I^{\hat{G}}_{(2,2)} - I^{\hat{G}}_{(0,2)}. \end{aligned} \quad (3.37)$$

Оскільки у $I^{\hat{R}}$, $I^{\hat{G}}$ і $I^{\hat{B}}$ відсутні колірні компоненти у відповідних пікселях, то необхідне об'єднання рівнянь:

$$G \approx G^G \approx G^R \approx G^B. \quad (3.38)$$

Отже, обчислення градієнтів можливо здійснювати, використовуючи дані лише одного кольорового каналу. Це дозволяє зробити висновок, що градієнти

можуть бути ефективно отримані безпосередньо з необроблених зображень у форматі Байєра, без необхідності виконання демозаїки, за умови збереження міжканальної кореляції.

Ще одним підходом, що застосовується для обробки зображень в інформаційних технологіях, є вейвлет-перетворення, яке дозволяє розкласти зображення на окремі частотні компоненти. Такий підхід забезпечує можливість аналізу з різною просторовою та частотною роздільною здатністю, що особливо ефективно для локалізованого аналізу зображень.

На основі цих частотних компонентів здійснюється вилучення ознак, які слугують цифровим представленням вхідного зображення. Таким чином, вейвлет-перетворення розглядається як ефективний інструмент частотно-часового аналізу, що забезпечує адаптивну локалізацію інформації на зображеннях.

Дискретна вейвлет-функція $\psi_{j,k}(t)$ виражається таким чином [228]:

$$\psi_{j,k}(t) = s_0^{-j/2} \psi\left(\frac{t - ks_0^j \tau_0}{s_0^j}\right) = s_0^{-j/2} \psi(s_0^{-j} t - k\tau_0), \quad (3.39)$$

де j позначає параметр масштабу, який контролює розширення вейвлета.

В таблиці 3.1 наведено порівняння описаних вище методів.

Таблиця 3.1

Порівняльна таблиця методів обробки зображення

Метод	Принцип роботи	Переваги	Недоліки
SIFT (Scale-Invariant Feature Transform)	Визначає та описує локальні ознаки в зображеннях шляхом виявлення ключових точок, інваріантних до масштабу і обертання. Побудова масштабованого простору з допомогою гаусового фільтрування, знаходження екстремумів в зображеннях різниці гаусівських фільтрів, точне уточнення ключових точок.	– висока точність відповідності ознак. – інваріантність до масштабу та обертання; – робота з зображеннями різної якості.	– обчислювально витратний процес; – менш підходить для реального часу; – потребує значних ресурсів.

Продовження Табл. 3.1

Метод	Принцип роботи	Переваги	Недоліки
Вейвлет-перетворення	Розкладає зображення на різні частоти, що дозволяє багат шарове аналізування. Застосування дискретного перетворення вейвлетів для представлення зображення як комбінації масштабованих і перекладених вейвлетів. Для зменшення шуму використовуються жорстке і м'яке порогування.	– висока точність в багат шаровому аналізі; – зменшення шуму та збереження деталей; – добре підходить для обробки зображень з різними масштабами.	– чутливе до вибору порогових значення; – може не забезпечувати точну локалізацію ознак; – потребує обробки на кількох масштабах.
HOG (Histogram of Oriented Gradients)	Зосереджений на захопленні розподілу напрямків градієнтів в локалізованих ділянках зображення. Зображення ділиться на малі клітини, в кожній клітині обчислюються гістограми напрямків градієнтів, які нормалізуються по блоках для підвищення стійкості до змін освітлення і контрасту	– ефективний для виявлення об'єктів та форм; – добре працює для розпізнавання специфічних візерунків – стійкість до змін освітлення і контрасту.	– може не вловлювати тонкі деталі; – менш ефективний при значних варіаціях вигляду об'єктів; – менш підходить для складних фонових шумів.

3.5. Формування табличного представлення ознак із мультимодальних медичних даних

Для забезпечення можливості спільного аналізу мультимодальних даних в межах єдиної інформаційної системи, необхідно привести ці різноманітні джерела до уніфікованого формату. Найпоширенішим способом представлення таких даних у задачах машинного навчання є таблична структура, де кожен об'єкт описується вектором ознак.

У цьому контексті особливої актуальності набуває процес виділення релевантних ознак із вихідних сигналів або зображень та їх перетворення у числові вектори, що зберігають інформативність вихідної модальності. Такий підхід дозволяє інтегрувати різні типи медичних даних у спільний простір ознак, у якому можуть бути реалізовані методи класифікації, кластеризації, прогнозування та інші аналітичні задачі.

Для інтерпретації модальностей слід застосувати методи багатовимірного статистичного аналізу – канонічний кореляційний аналіз (CCA), Tensor Fusion (тензорне об'єднання), Principal Component Analysis (PCA), CNN.

Значна кількість дослідників [312–316, 318, 321, 323, 326, 327] зосередили увагу на вивченні медичних модальностей та пов'язаних атрибутів, що дало змогу систематизувати й класифікувати сучасні підходи до аналізу та ідентифікації даних. Результати цього узагальнення наведено в таблиці 3.2.

Таблиця 3.2

Інтеграція багатовимірних медичних даних у єдину систему

Модальність	Тип даних	Мета аналізу	Методи обробки
ЕЕГ	Сигнали мозкової активності	Виявлення епілепсії, когнітивних порушень	Вейвлет-перетворення, SVM, CNN для розпізнавання патернів
ЕКГ	Серцеві сигнали	Діагностика аритмії, оцінка варіабельності серцевого ритму	Метод Pan-Tompkins, аналіз BCP, RNN для моделювання послідовностей
MPT	Зображення структур та функцій органів	Виявлення пухлин, структурних аномалій	U-Net, ResNet для сегментації зображень, PCA для виділення основних компонентів
Клінічні дані	Лабораторні показники, анамнез	Прогнозування захворювань, комплексна оцінка стану	Імпутація даних, дерева рішень, Random Forest для класифікації

Ефективне представлення мультимодальних медичних даних уніфікованим чином є ключовим етапом побудови аналітичних моделей у межах інформаційних систем. Незважаючи на відмінності у природі джерел, дані потребують трансформації у табличну форму з чітко структурованими ознаками для подальшого машинного аналізу.

Сигнальні дані, зокрема ЕЕГ та ЕКГ, складаються з часових рядів, які фіксують біоелектричну активність організму в реальному часі. Базовим елементом таких рядів є амплітуда сигналу, яка реєструється спеціалізованими приладами через сенсори або електроди. Однак первинні сигнали не можуть бути використані безпосередньо: вони потребують попередньої обробки, зокрема фільтрації шуму, нормалізації, розбиття на сегменти та обчислення статистичних

або спектральних характеристик (середнє значення, ентропія, частотні компоненти тощо). Ці параметри і формують набір ознак для табличного представлення.

Медичні зображення МРТ потребують виділення інформативних структур об'ємних сегментів, контурів або кластерів, які потім описуються у вигляді числових векторів (наприклад, площа ураження, інтенсивність сигналу, текстурні особливості). Такі вектори додаються до загальної таблиці ознак, забезпечуючи узгоджене представлення структурної інформації.

Клінічні показники – це результати аналізів, анамнез, демографічні характеристики, які зазвичай уже мають табличну форму. Проте їх також необхідно привести до єдиного формату: числові значення нормалізуються, категоріальні – кодуються (наприклад, методом one-hot або ordinal encoding), пропущені значення – імітуються або заповнюються відповідними статистичними методами.

Після попередньої обробки всі модальності інтегруються в єдину табличну структуру, де кожен пацієнт або спостереження відповідає окремому рядку, а стовпці містять числові або категоріальні ознаки, отримані з різних джерел. Це дозволяє застосовувати класичні алгоритми машинного навчання, забезпечує сумісність із системами підтримки прийняття рішень і формує основу для побудови комплексних аналітичних моделей персоналізованої медицини.

Інтеграція об'єктивних даних із усіх доступних модальностей у єдину інформаційну систему дозволяє виявляти приховані кореляції між параметрами стану пацієнта. Це створює основу для глибшої персоналізації діагностичних і терапевтичних рішень, наприклад, з урахуванням наявності хронічних захворювань або генетичних ризиків.

Важливим етапом у цьому процесі є перетворення сирих фізіологічних сигналів ЕЕГ та ЕКГ у придатні для аналізу ознаки. Такі сигнали збираються за допомогою спеціалізованих пристроїв, які реєструють амплітуду біоелектричної активності в режимі реального часу. Амплітуда, як миттєве значення сигналу, є

базовим показником, що записується автоматично та відображає фізіологічний стан пацієнта.

Проте, для подальшого використання в аналітичних системах, ці дані повинні пройти етапи очищення, нормалізації та витягування інформативних ознак – таких як частотні характеристики, статистичні показники або часові залежності. Саме ці узагальнені ознаки і стають елементами табличного представлення, яке поєднує різні модальності в уніфікованому форматі, придатному для автоматизованого аналізу.

Початковим етапом такої обробки є фільтрація даних з метою усунення шумів, що можуть виникати внаслідок рухової активності пацієнта, електромагнітних перешкод, особливостей роботи сенсорного обладнання або зовнішнього фонового впливу. Для цього використовуються спеціалізовані фільтри, орієнтовані на відповідні частотні діапазони кожного типу сигналу. Зокрема, низькочастотний фільтр (англ. *Low-pass filter*) ефективно пригнічує високочастотні компоненти, які не є частиною корисного сигналу. Формально такий фільтр можна описати наступним виразом:

$$H(f) = \frac{1}{1 + \left(\frac{f}{f_c}\right)^2}, \quad (3.40)$$

де f_c – частота зрізу, що визначає межу пропускнуго діапазону.

Таким чином реалізується первинне очищення сигналу, яке забезпечує збереження його фізіологічно значущих компонентів і підвищує якість подальшої інтерпретації та аналізу.

Високочастотний фільтр (англ. *High-pass filter*), в свою чергу, видаляє низькочастотні перешкоди та обраховується таким чином:


$$H(f) = \frac{(f/f_c)^2}{1 + (f/f_c)^2}, \quad (3.41)$$

Відповідно, смуговий фільтр (англ. *Band-pass filter*) обчислюється наступним чином:

$$H(f) = \frac{(f/f_c)^2}{1 + \left(\frac{f^2/f_0^2}{\Delta f \cdot f}\right)^2}, \quad (3.42)$$

де f_0 – центральна частота; Δf – ширина смуги.

Фільтр низьких частот Баттерворта з частотою зрізу 30 Гц є ідеальним вибором для ЕЕГ та ЕКГ, оскільки він дозволяє зберігати клінічно важливі частотні компоненти та видалити шум. Це робить сигнал придатним для точного аналізу та діагностики. Нижче наведено витягнуті ознаки з сигналів, розраховані за формулами 3.40-3.42, які представлено в табличній формі.



Для фільтрування 3D-зображень МРТ застосовуються 3D-фільтри, які враховують сусідні пікселі у всіх трьох вимірах. Перетворення результативного сигналу МРТ в частотну область здійснюється через 3D-Фур'є перетворення:

$$F(u, v, w) = \iiint f(x, y, z) e^{-j2\pi(ux+vy+wz)} dx dy dz, \quad (3.43)$$

де:

- $f(x, y, z)$ – інтенсивність сигналу в просторі;
- $F(u, v, w)$ – частотне представлення зображення.

Фільтрування у частотній області $F_{filtered}(u, v, w)$ дорівнює добутку частотного представлення $F(u, v, w)$ та $H(u, v, w)$, де власне $H(u, v, w)$ визначає, які частоти пропускати.

Зворотне перетворення дає відфільтроване зображення і обчислюється наступним чином:

$$f_{filtered}(x, y, z) = \iiint F_{filtered}(u, v, w) e^{-j2\pi(ux+vy+wz)} du dv dw. \quad (3.44)$$

На рисунку 3.2 наведено приклад 3D-зображень МРТ: одне містить шум, друге – відфільтровано із застосуванням гауссового фільтру. Подано центральний зріз синтетичного 3D-зображення, яке містить високочастотний шум. Видно нерівномірності та сплески, що утруднюють аналіз. Після застосування гауссового фільтру (3.45) високочастотний шум було усунено. Зображення стало плавнішим, зберігаючи основну інтенсивність у висококонтрастних локаціях.

$$H(u, v, w) = e^{\frac{-u^2+v^2+w^2}{2\sigma^2}}, \quad (3.45)$$

де σ – ширина частотного діапазону.




Рис. 3.3. Приклад застосування гауссового фільтру на 3D-зображенні МРТ

На рисунку 3.3 наведено приклад іншого центрального зрізу синтетичного 3D-МРТ із вищим рівнем шуму. Наявність високочастотних компонентів робить його структуру нечіткою.





Рис. 3.4. Приклад застосування гауссового фільтру на 3D-зображенні МРТ із вищим рівнем шуму

Після застосування гауссового фільтру із більшою шириною згладження ($\sigma = 3$), зображення справа (Рис. 3.4) стає згладженим. Шум значно зменшений, а області високої інтенсивності залишаються чіткими.

Щоб представити це зображення у табличному форматі, потрібно структурувати інформацію про інтенсивності та просторове положення кожного вокселя. На першому етапі такого перетворення відбувається структурування вокселів, які описуються трьома координатами (x, y, z) та інтенсивністю I . Відповідно табличне представлення 2D-проекції відфільтрованих даних МРТ містить чотири стовпці x, y, z, I .

	X	Y	Z	Intensity
1	49	52	44	50.1285375706
2	49	52	45	52.2543726771
3	49	52	46	53.3210895721
4	49	52	47	53.6147063716
5	49	52	48	53.409857545
6	49	52	49	52.926589356
7	49	52	50	52.3164811578
8	49	52	51	51.6756383281
9	49	52	52	51.0722935951
10	49	52	53	50.5662314621
11	49	52	54	50.2081362301
12	49	52	55	50.0184609151
13	49	52	57	50.0298601541
14	49	52	58	50.1279749822
15	49	52	59	50.245494898
16	49	52	60	50.3785131012




Перетворення 3D-зображення, представлене в табличній формі на рисунку 3.4, відповідає вокселю з координатами x, y, z та значенням інтенсивності.

Просторова проєкція інтенсивностей сигналу у 2D показує розподіл даних, де кольори відображають значення інтенсивності після фільтрації. Це демонструє, як саме дані МРТ можна перевести в табличний формат, що спрощує подальший аналіз.

Для здійснення поділу об'єкта на анатомічні області відбувається просторове розбиття зв'язку координат (x, y, z) . Для кожного вокселя визначається анатомічна область, до якого він належить. Відповідно, оновлюється новим стовпцем «Область». Інтенсивність за областями визначається через усереднення або аналіз інтенсивностей для кожної області.


Нижче наведено приклад перетворення МРТ зображення в табличну форму з виділенням ознак.



Перетворення 3D-зображення МРТ у табличний формат відкриває можливості для використання широкого спектра аналітичних інструментів і методів. Таблична форма є корисною для різних задач багатовимірної аналізу.

Побудова гістограм або графіків розподілу інтенсивностей дозволяє визначити області з високою активністю. Просторові залежності через дослідження взаємозв'язку між сусідніми вокселями через координати x, y, z дозволяють візуалізувати їх для подальшого аналізу.

Клінічні дані подаються в табличному вигляді, структуровано. Кожна колонка таблиці – це ознака модальності.



Отож, в процесі застосування описаних алгоритмів для обробки модальних даних отримано вектори ознак ЕЕГ, ЕКГ, МРТ модальностей та клінічних даних, які сформовано в табличному вигляді, на вхід у систему для подальшого їх аналізу.

Висновки до розділу 3

1. Виділення ознак на основі MFCC забезпечує ефективне представлення акустичних сигналів. Завдяки нелінійному перетворенню частоти, логарифмічному стисненню спектру та використанню DCT, MFCC дозволяють виокремити ознаки, що критично важливо для задач класифікації в умовах шуму та варіативного середовища. Запропонований підхід не лише формалізує процес перетворення сигналу, але й інтегрує його у мультимодальну модель, підвищуючи точність, інтерпретованість та надійність прийняття рішень у складних інформаційних середовищах. Таким чином, MFCC слугують ключовою складовою методології багатовимірного аналізу мультимодальних даних.

2. Використання прихованих марковських моделей у поєднанні з фільтрами Калмана та глибокими нейронними мережами забезпечує високоточне відображення динамічних характеристик сигналів у мультимодальному аналізі. Представлена методика дозволяє ефективно моделювати часову структуру сигналів, знижувати вплив шуму та адаптувати обробку до складних акустичних

умов. Завдяки ймовірнісному моделюванню та гнучкому оновленню параметрів модель демонструє стійкість і масштабованість, що є критично важливим для побудови інтелектуальних інформаційних систем з багатомодальним введенням.

3. Обґрунтовано доцільність використання різних підходів до класифікації сигналів залежно від типу вхідних даних, задачі та вимог до точності. Метод SVM продемонстрував високу ефективність при чіткому розмежуванні класів, а також гнучкість при роботі з зашумленими або слабко відокремленими вибірками. Застосування лінійного дискримінантного аналізу дозволило зменшити надлишковість ознак і підвищити інформативність вхідних даних. У порівнянні з MFCC та HMM, метод SVM краще реалізується для класифікації статичних ознак, тоді як інші підходи краще враховують часову динаміку. Інтеграція цих методів у спільний мультимодальний фреймворк забезпечує адаптивність, точність та узгодженість системи при обробці різномірних медичних сигналів.

4. У результаті аналізу сучасних підходів до побудови ознак цифрових зображень встановлено, що кожен із методів – SIFT, HOG, вейвлет-перетворення – є доцільними у різних умовах застосування. Метод SIFT забезпечує високу точність при порівнянні об'єктів незалежно від масштабу, але є ресурсомістким. HOG характеризується стійкістю до змін освітлення та ефективністю в задачах розпізнавання форм, однак менш придатний до класифікації об'єктів зі складною структурою. Вейвлет-перетворення дозволяє гнучко аналізувати зображення на різних рівнях деталізації, особливо в задачах зі зменшенням шуму. Інтеграція цих методів у єдину систему дозволяє створити надійний механізм обробки зображень, адаптований до умов мультимодального аналізу.

5. Застосування описаних у розділі методів виділення ознак із різних медичних модальностей створює формальне підґрунтя для побудови табличного представлення даних. Така уніфікована структура ознак забезпечує узгоджене і систематизоване подання інформації, необхідне для подальшого ефективного багатовимірного аналізу. Застосування фільтрації, декомпозиції сигналів та проєкційного відображення воксельних структур забезпечує збереження

критично важливої інформації під час перетворення. Таким чином, отримані табличні структури формують основу для подальшої побудови систем глибокого аналізу, класифікації станів пацієнтів та прийняття діагностичних рішень у рамках мультимодальної інформаційної технології.

Результати досліджень за третім розділом опубліковані в роботах автора [15, 17, 23, 26, 28, 34, 41, 44, 52, 55] (Додаток Б).

РОЗДІЛ 4

МОДЕЛІ РЕПРЕЗЕНТАЦІЇ ТА ЗЛИТТЯ МУЛЬТИМОДАЛЬНИХ ДАНИХ

У четвертому розділі запропоновано формальні та алгоритмічні основи побудови інтерпретованої інформаційної технології для класифікації стану пацієнтів на основі багатовимірних мультимодальних медичних даних. Основна увага зосереджена на розробці та вдосконаленні моделей концептуального аналізу даних, що інтегрують інформацію з гетерогенних джерел: електрокардіографічних сигналів, електроенцефалографічних показників, магнітно-резонансної томографії, а також анамнестичних характеристик.

Обґрунтовано використання концептуального аналізу даних як базового підходу до формалізації структурних взаємозв'язків між медичними об'єктами (пацієнтами) та їх ознаками. Застосовано формальні контексти, решітки концептів і Hasse-діаграми для побудови ієрархічної структури знань. Це дозволяє ефективно виявляти класи пацієнтів зі схожими симптомами та підтримувати прийняття клінічних рішень на основі логічної інтерпретації даних.

Дослідження присвячено побудові моделі багатовимірного концептуального аналізу, яка дозволяє здійснювати структуровану інтеграцію даних з різних модальностей. Введено поняття багатовимірних формальних контекстів та концептів, а також механізм побудови асоціативних правил, що виводяться з множини перетинів ознак у різних підпросторах. Такий підхід уможливорює опис складних міжмодальних залежностей і виявлення латентних закономірностей, що є важливим у медичних завданнях діагностики.

Запропоновано механізм багатокритеріального покращення (multi-criteria optimization) процесу побудови концептів, який враховує низку якісних показників: інформативність, стійкість до шуму, міжмодальну узгодженість, специфічність та повноту охоплення. Введено векторну функцію якості концепту та здійснено відбір Парето-оптимальних рішень. Це забезпечує можливість формування підмножини концептів, найбільш придатних до використання в задачах інтерпретованої класифікації та персоналізованої медицини.

4.1. Концептуальний аналіз даних для багатовимірної обробки мультимодальної медичної інформації

Концептуальний аналіз даних (CAD) в інформаційній технології розглядається як формальна модель виявлення зв'язків між множинами об'єктів та ознак у багатовимірному інформаційному просторі. Модель базується на побудові формальних контекстів, що відображають структуровані взаємозалежності між елементами даних з різних модальностей [18, 31, 34].

Основними структурними компонентами моделі є [4, 9]:

- Множина об'єктів G – медичні кейси, пацієнти, записи.
- Множина ознак M – параметри, що характеризують об'єкти (клінічні, сигнальні, текстові, візуальні тощо).
- Відношення $I \subseteq G \times M$ – бінарна залежність між об'єктами та ознаками.
- Формальний контекст $K = (G, M, I)$ – основа побудови концептуальної решітки.
- Концепт-пара (A, B) , де $A \subseteq G$, $B \subseteq M$, така, що $A' = B$ і $B' = A$.

Модель дозволяє [39, 62]:

- автоматично ідентифікувати класи об'єктів з подібними характеристиками;
- виявляти приховані логічні закономірності між модальностями;
- побудувати ієрархічну структуру концептів для інтерпретованої візуалізації;

а також може слугувати основою для створення узагальненого опису пацієнта або патології.

Використання моделі CAD в аналітичному модулі не лише забезпечує пояснюваність результатів, але й сприяє оптимізації класифікаційних структур, підвищенню точності, узагальнюваності та інтегративності в системі підтримки клінічних рішень [1].

Метою моделі концептуального аналізу даних (CAD) є виявлення структурованих взаємозв'язків між об'єктами (пацієнтами або клінічними ситуаціями) та множинами ознак (медичних характеристик, параметрів), що

походять із різних модальностей. CAD слугує базою для класифікації, інтерпретації та візуалізації даних у вигляді концептуальних структур.

Модель ґрунтується на формальному контексті $K = (G, M, I)$, що створюється шляхом трансформації вхідних медичних даних у бінарну форму. Кожне поєднання об'єкта з ознакою відображає наявність або відсутність клінічного параметра, що дозволяє збудувати решітку концептів – ієрархічну структуру понять, у межах якої моделюється простір знань.

Ця ієрархія є не лише засобом візуалізації, а й дієвим інструментом семантичного узагальнення: від конкретних симптомів до узагальнених патологічних станів, що підвищує ефективність аналізу й надає змогу інтерпретувати приховані закономірності.

Для побудови концептів використовуються оператори деривації, які визначають зв'язок між об'єктами та ознаками:

- Для підмножини об'єктів $A \subseteq G$: $A' = \{m \in M \mid \forall g \in A: (g, m) \in I\}$, де A' – множина всіх ознак, спільних для всіх об'єктів з A .
- Для підмножини ознак $B \subseteq M$: $B' = \{g \in G \mid \forall m \in B: (g, m) \in I\}$, де B' – множина всіх об'єктів, які мають всі ознаки з B .

Формальний концепт визначається як впорядкована пара: (A, B) , де $A \subseteq G$, $B \subseteq M$, що задовольняє умову: $A' = B$ та $B' = A$. Тобто A – екстенс концепту: множина об'єктів, які мають ознаки з B , а B – інтенс (intent) концепту: множина ознак, спільних для всіх об'єктів з A .

Множина всіх формальних концептів контексту K утворює решітку $B(K)$ із частковим порядком: $(A_1, B_1) \leq (A_2, B_2) \Leftrightarrow A_1 \subseteq A_2 (\Leftrightarrow B_2 \subseteq B_1)$.

Це означає, що концепт (A_1, B_1) є підконцептом для (A_2, B_2) , якщо всі об'єкти з A_1 належать до A_2 , тобто мають більше ознак (менший інтенс).

До властивостей решітки $B(K)$ слід віднести такі:

- $B(K)$ є повною решіткою: кожна підмножина концептів має супремум (найменшу верхню межу) і інфімум (найбільшу нижню межу).
- Структура решітки відображає ієрархію понять: від загальних до специфічних.

- Решітка може бути візуалізована як Hasse-діаграма, де вузли – концепти, а ребра – відношення включення між екстентами/інтентами.

Для кращого розуміння моделі побудови формальних концептів у межах концептуального аналізу даних розглянемо приклад, що ілюструє, як із табличного подання даних можна автоматично виявити структуровані зв'язки між об'єктами (пацієнтами) та їхніми ознаками (симптомами) [35-38, 335].

Маємо таблицю, яка відображає наявність певних симптомів у трьох пацієнтів. Такий формальний контекст визначається трьома множинами: множиною об'єктів $G = \{g_1, g_2, g_3\}$, множиною ознак $M = \{m_A, m_B, m_C\}$ і бінарним відношенням інцидентності $I \subseteq G \times M$, що задає факт наявності певного симптому у відповідного пацієнта.

пацієнт	симптом А (m_A)	симптом В (m_B)	симптом С (m_C)
пацієнт 1 (g_1)	+	+	
пацієнт 2 (g_2)	+		+
пацієнт 3 (g_3)	+	+	+

У межах цього контексту можемо побудувати формальні концепти – пари множин об'єктів та ознак, які повністю узгоджуються між собою. Наприклад, якщо пацієнт g_3 має симптоми m_A, m_B, m_C , то множина $A = \{g_3\}$ породжує множину ознак $A' = \{m_A, m_B, m_C\}$, а навпаки, множина ознак $B = \{m_A, m_B, m_C\}$ породжує множину пацієнтів $B' = \{g_3\}$. Таким чином, отримаємо формальний концепт $(\{g_3\}, \{m_A, m_B, m_C\})$, який інтерпретується як “пацієнт, що має всі три симптоми”.

Подібні концепти можуть бути автоматично згенеровані для всіх підмножин даних, утворюючи решітку формальних понять, яка унаочнює ієрархію знань у вигляді Hasse-діаграми. Це дозволяє виявляти типові й атипові клінічні картини, знаходити кластери пацієнтів із подібними ознаками та підтримувати прийняття медичних рішень на основі структурованих залежностей між даними.

На рисунку 4.1 представлено Hasse-діаграму, яка ілюструє частковий порядок між формальними концептами у решітці $B(K)$, побудованій на основі формального контексту концептуального аналізу даних (CAD).




Рис. 4.1. Hasse-діаграма, побудована на основі формального контексту концептуального аналізу даних

До елементів діаграми слід віднести [2, 23]:

- Вузли – кожен вузол представляє формальний концепт у вигляді пари: (A, B) , де A – множина об'єктів, B – множина ознак.
- Ребра – лінії між вузлами вказують на відношення включення між концептами. Вони з'єднують концепти згідно з ієрархією:
 - Знизу вгору: чим вище вузол, тим більш загальний концепт (менше ознак, більше об'єктів).
 - Зверху вниз: тим більш специфічний концепт (більше ознак, менше об'єктів).

Таким чином, в рамках запропонованої формалізації кожен пацієнт описується у вигляді багатовимірною вектора мультимодальних ознак, який доповнюється умовним контекстом, що враховує індивідуальні особливості. Визначення формального контексту знань дозволяє побудувати структуровану модель, в якій реалізується зв'язок між пацієнтами та їхніми клінічними характеристиками через відношення інцидентності.

Розглянемо детальний опис наведеної математичної моделі системи багатовимірного аналізу мультимодальних медичних даних, де множина всіх пацієнтів позначена як $P = \{p_1, p_2, \dots, p_n\}$. Кожен пацієнт p_i характеризується вектором мультимодальних ознак у багатовимірному просторі: $X_i = (x_{i1}, x_{i2}, \dots, x_{im})$, де x_{ij} – значення j -ої ознаки для пацієнта p_i ; m – кількість ознак (мультимодальні дані: біосигнали, зображення, текстові показники тощо).

Формальний контекст знань визначається трійкою: $K = (G, M, I)$, де $G \subseteq P$ – множина об'єктів (пацієнтів); $M = \{m_1, m_2, \dots, m_k\}$ – множина атрибутів (клінічні ознаки, симптоми, стани); $I \subseteq G \times M$ – відношення “пацієнт має атрибут” [2, 20].

Уведення простору умов $\Omega = \{(c_1, c_2, \dots, c_l)\}$, де c_j – значення j -ої умовної характеристики (вік, стать, анамнез, супутні захворювання) забезпечує гнучкість та персоналізацію моделі, що є надзвичайно важливим у медичних застосуваннях, де стан пацієнта залежить не лише від симптомів, а й від супутніх чинників. Відтак функція оцінки стану $S(p_i) = f(X_i, \Omega)$ виступає основним елементом у процесі прийняття клінічних рішень.

На цій основі можна формалізувати задачу побудови алгоритму $f: X \times \Omega \rightarrow C$, який дозволяє здійснювати класифікацію пацієнтів за станами. Така постановка створює передумови для розробки адаптивних, інтерпретованих і масштабованих аналітичних моделей, що лежать в основі інтелектуальної інформаційної технології обробки мультимодальних медичних даних [16, 20, 339].

Для навчання та тестування моделей концептуального аналізу використано мультимодальний набір медичних даних, який сформований в результаті обробки модальностей методами, наведеними в Розділі 3 (Додаток В). Табличні дані охоплюють ознаки чотирьох модальностей:

- ЕКГ: QT-інтервал, RR-інтервал, QRS-довжина, P-інтервал, ST-депресія, варіабельність ЧСС;
- ЕЕГ: спектральні та ентропійні характеристики (потужність α -, β -, δ -, γ -ритмів, індекс θ/α , спектральна ентропія);

- МРТ: об'єм гіпоінтенсивних зон, ентропія текстури сірої речовини, контрастність, форма латерального шлуночка;
- Анамнез: вік, стать, наявність діабету, гіпертонії, ІМТ, перенесення інсульту, куріння.

Наведемо характеристики ознак по кожній модальності та їхні клінічні норми.

Таблиця 4.1

Характеристика ознак по кожній модальності сформованого набору даних

Назва ознаки	Опис та метод вимірювання	Норма
Модальність: ЕКГ (електрокардіограма)		
QT_interval	Вимірюється від початку комплексу Q до кінця зубця Т. Відображає період електричної активності шлуночків (деполяризація + реполяризація).	Ж: 350–440 мс Ч: 360–460 мс
RR_interval	Інтервал між двома сусідніми зубцями R на ЕКГ (відображає частоту серцебиття).	600–1000 мс (HR: 60–100 уд/хв)
QRS_duration	Визначається як тривалість комплексу QRS (від початку Q до кінця S). Показує швидкість деполяризації шлуночків.	< 120 мс
P_interval	Вимірюється від початку зубця Р до початку QRS. Показує час, необхідний для проходження імпульсу через передсердя.	120–200 мс
ST_depression	Зниження сегменту ST нижче ізолінії на ≥ 0.5 мм (0,05 mV) у двох суміжних відведеннях. Часто вимірюється у II, V4–V6.	0 мВ (патологія: $\geq 0,05$ –0,1 мВ)
HRV	Розраховується як стандартне відхилення RR-інтервалів. Відображає варіабельність частоти серцебиття, регульовану вегетативною нервовою системою.	>50 мс (здорові особи)
Модальність: ЕЕГ (електроенцефалографія)		
Alpha_power	Середня потужність (або амплітуда) сигналу в діапазоні 8–13 Гц. Визначається за допомогою спектрального аналізу (наприклад, FFT).	Зростає у стані спокою з закритими очима. Норма: 8–13 Гц.
Beta_power	Потужність у діапазоні 13–30 Гц. Відображає активацію кори при розумовій активності, емоціях, стресі.	Підвищується при зосередженості. Норма: 13–30 Гц.
Peak_frequency	Частота, на якій спостерігається максимальна потужність сигналу (головна гармоніка). Визначається як $\arg\max$ у спектрі потужності.	Зазвичай 9–11 Гц (альфа-пік у здорових осіб).
Spectral_entropy	Визначається на основі нормалізованого спектра сигналу	0.7–0.9 – норма. Знижується при патологіях.
Theta_alpha_index	Відношення потужностей θ (4–7 Гц) до α (8–13 Гц). Визначає рівень збудження/сонливості.	У здорових дорослих: $\sim 0,3$ –0,5. Зростає при втомі або сонливості.
Frontal_coherence	Когерентність (міра синхронізації фаз) між фронтальними електродами	Норма (спокій, очі закриті) 0,3 – 0,6. Висока когерентність > 0,6 (може бути при епілепсії, інтактній корі). Знижена когерентність < 0,3 (можлива при інсульті, дисконект-синдромі).

Продовження Табл. 4.1

Назва ознаки	Опис та метод вимірювання	Норма
Модальність: МРТ (магнітно-резонансна томографія)		
Hypointense_volume	Загальний об'єм зон з пониженою інтенсивністю сигналу (гіпоінтенсивних ділянок) на T1/T2-зважених зображеннях. Визначається через сегментацію вогнищ.	Норма: < 1,5 см ³ у здорових <60 років. > 3–4 см ³ – ішемічні/атрофічні ураження.
GM_texture_entropy	Ентропія текстури сірої речовини	Знижується при нейродегенерації (Альцгеймер, ПМД). Норма ≈ 3,5–4,5 у лог. шкалі.
GM_WM_contrast	Визначається як різниця середньої інтенсивності між сірою (GM) та білою (WM) речовиною:	Норма: 0,2–0,4. <0,15 – ознака розмиття меж (нейродегенерація).
Periventricular_intensity	Середнє значення інтенсивності біля латеральних шлуночків (перивентрикулярно), часто вимірюється в ROI-областях.	Норма: низька (в межах 0,3–0,5, відносна шкала). Підвищення – лейкоареоз, гліоз.
Parietal_LBP	LBP (Local Binary Patterns) – метод аналізу локальних шаблонів текстури. Розраховується як гістограма LBP-кодів у тім'яній області.	В нормі – рівномірний розподіл. Зростання складності (ентропія > 2,5) – маркер деменції.
Lateral_ventricle_shape	Оцінюється за формальними метриками форми шлуночка (еліптичність, ексцентриситет, обвідна площа). Часто автоматично: e.g. FSL/FreeSurfer.	У нормі – симетричні, незначно вигнуті. Деформація >30% – гідроцефалія, атрофія.
Модальність: Клінічні дані		
Age	Ціле число (20–90 років)	Вік > 65 років – фактор ризику когнітивних та судинних порушень
Sex	Категоріальна змінна (“М”/“F”)	Враховується для статевозалежних патологій та реакції на лікування.
Diabetes	Бінарна (0 – ні, 1 – так)	Діабет підвищує ризик інсульту, деменції, судинних ускладнень
Hypertension	Бінарна (0 – ні, 1 – так)	Один з ключових факторів ризику ішемічної хвороби мозку.
Smoking	Бінарна (0 – ні, 1 – так)	Зростання ризику атеросклерозу, інсульту, гіпоксії
BMI	Дійсне число (~18.5 – 35)	18,5–24,9 – норма; >25 – надмірна вага; >30 – ожиріння.
Stroke_history	Бінарна (0 – ні, 1 – так)	Прямий фактор ризику рецидиву, впливає на нейровізуальні та ЕЕГ-показники.

Перед побудовою формального контексту всі числові ознаки було нормалізовано, а категоріальні – бінаризовано (one-hot encoding). Для вирівнювання кількості спостережень у кожному класі використовувався механізм DataSampler. Усі процедури попередньої обробки, побудови концептів та візуалізації реалізовано у середовищі RStudio.

Для забезпечення можливості застосування методів формального концептуального аналізу (FCA) усі ознаки, що використовувались у дослідженні, було приведено до дискретного бінарного вигляду. Така трансформація дозволяє сформувати формальний контекст у вигляді бінарної таблиці «об'єкти–ознаки»,

де значення 1 відповідає наявності певної властивості у пацієнта, а 0 – її відсутності.

Основні кроки бінаризації:

1. Вибір ознак, де з кожної модальності було відібрано по кілька найбільш інформативних параметрів згідно попереднього аналізу.
2. Встановлення порогових значень, де для кожної ознаки визначено порогові межі, на основі яких вона переводилась у бінарний формат (наприклад, $QT\_interval > 450$ мс вважається патологією).
3. Формалізація умов, де кожна бінаризована ознака позначала наявність патологічного/критичного відхилення від норми. Наприклад:
 - $m_1 = 1$, якщо $QT\_interval > 450$ мс;
 - $m_3 = 1$, якщо $Theta\_alpha\_index > 1$;
 - $m_5 = 1$, якщо $Age > 65$ років.
4. Категоріальні ознаки (такі як стать, наявність діабету, гіпертонії, історія інсульту) кодувалися напряму: 1 – наявність, 0 – відсутність.
5. Формування контексту: кожен пацієнт був представлений як набір бінарних ознак, що відображають наявність або відсутність медичних характеристик. Це дало змогу побудувати концептуальну решітку, що візуалізує структуру взаємозв'язків між ознаками та групами пацієнтів.

Наведемо приклад побудови формального контексту та концептуальної решітки на основі реальних ознак з описаного датасету. Щоб не ускладнювати діаграму, використаємо чотирьох пацієнтів та шість ознак з різних модальностей.

Таблиця 4.2

Фрагмент датасету (бінаризований для CAD)

Пацієнт	QT↑	ST↓	Theta_alpha_index > 1	GM_texture_entropy < 0,6	Age > 65	Diabetes
P_1	1	0	1	0	1	1
P_2	1	1	0	1	0	0
P_3	1	1	1	1	1	1
P_4	0	1	0	1	1	0

Відповідно, для формального концептуального аналізу ознаки (M) позначаються через: $m_1 = QT↑$; $m_2 = ST↓$; $m_3 = Theta\_alpha\_index > 1$; $m_4 =$

$GM\_texture\_entropy < 0,6$; $m_5 = Age > 65$; $m_6 = Diabetes$. Об'єкти (G) представлені через: $g_1 = P_1$; $g_2 = P_2$; $g_3 = P_3$; $g_4 = P_4$.

Таблиця 4.3

Формальний контекст $K=(G,M,I)$

Об'єкти	m_1	m_2	m_3	m_4	m_5	m_6
g_1	+		+		+	+
g_2	+	+		+		
g_3	+	+	+	+	+	+
g_4		+		+	+	

Таблиця 4.4

Концепти формальних ознак пацієнтів

№	Екстент А (пацієнти)	Інтент В (спільні ознаки)
1	$\{g_1, g_3\}$	$\{m_1, m_3, m_5, m_6\}$
2	$\{g_2, g_3\}$	$\{m_1, m_2, m_4\}$
3	$\{g_3\}$	$\{m_1, m_2, m_3, m_4, m_5, m_6\}$
4	$\{g_2, g_4\}$	$\{m_2, m_4\}$
5	$\{g_1\}$	$\{m_1, m_3, m_5, m_6\}$

Отож, в результаті аналізу таблиці 4.4 утворено 5 концептів, де екстент – множина пацієнтів, які мають певні спільні ознаки та інтент – спільні ознаки цих пацієнтів:

- Концепт 1 $\{g_1, g_3\}$ – пацієнти, які мають однакові ознаки: m_1 (QT-інтервал), m_3 (QRS-довжина), m_5 (ентропія MPT), m_6 (варіабельність ЧСС).
- Концепт 2 $\{g_2, g_3\}$ – об'єднані пацієнти з ознаками: m_1, m_2 (EEG θ/α), m_4 (інтенсивність перивентрикулярно).
- Концепт 3 $\{g_3\}$ – пацієнт, що має всі можливі ознаки у наборі (суперконтекст).
- Концепт 4 $\{g_2, g_4\}$ – лише ознаки m_2 та m_4 , що є спільними між цими пацієнтами.
- Концепт 5 $\{g_1\}$ – дублює концепт 1, але з одним об'єктом у екстенті.

На рисунку 4.2 зображено Hasse-діаграму формальної концептуальної решітки, побудовану на основі підмножини мультимодального медичного датасет, де вузли діаграми відповідають формальним концептам, кожен з яких визначається:

- Extent A – множина пацієнтів (наприклад, $\{g_1, g_3\}$), які мають спільні ознаки;
- Intent B – множина ознак (наприклад, $\{m_1, m_3, m_5, m_6\}$), які одночасно притаманні всім цим пацієнтам.

Відношення між вузлами ілюструють частковий порядок узагальнення, де перехід від вузла вище до нижчого вказує на додавання ознак (спеціалізацію) та звуження множини пацієнтів. Відповідно, вузли вище в ієрархії відповідають більш загальним концептам, які охоплюють більше пацієнтів із меншою кількістю ознак. Однак, вузли нижче є більш специфічними, мають більше ознак, але застосовуються до меншої кількості пацієнтів. Найбільш специфічний концепт – вузол, що містить одного пацієнта (g_3) та повний набір ознак, що йому притаманний.

У Hasse-діаграмі (Рис. 4.2), формальний концепт 4 ($\{g_2, g_4\}, \{m_2, m_4\}$) не відображено, тому що він покривається іншими концептами та не є замкненою множиною. Адже існує концепт 2: $\{g_2, g_3\} \rightarrow \{m_1, m_2, m_4\}$, в якому теж присутні $\{m_2, m_4\}$, а Extent включає g_3 . Отже, $\{g_2, g_4\}, \{m_2, m_4\}$ – не є максимальним (замкненим) концептом, а саме такими є лише ті, що включають усі можливі атрибути, спільні для всіх елементів множини. Концепт $\{g_2, g_4\}, \{m_2, m_4\}$ не потрапив до решітки, оскільки він не є формальним концептом FCA, тобто його інтент можна розширити (включити m_1), і тоді він уже відповідатиме іншому концепту.

Ця діаграма дозволяє виявити стійкі поєднання ознак, які повторюються у різних пацієнтів, і може слугувати основою для виявлення патернів стану здоров'я або класифікаційних правил у клінічному аналізі.

Таким чином, модель системи багатовимірної аналізу мультимодальних медичних даних формалізує весь життєвий цикл даних у мультимодальній медичній системі – від збору, узгодження, інтеграції й аналізу до інтерпретації та клінічного рішення.

Формальна решітка концептів (Hasse-діаграма)




Рис. 4.2. Візуалізація формальної решітки концептів у вигляді
Hasse-діаграми

У наступному розділі на основі цієї моделі буде сформовано архітектуру інформаційної технології, що включатиме модулі для попередньої обробки, синхронізації часових рядів, інтерпретації (класифікації) стану пацієнтів, візуалізації результатів, а також розглянуто принципи і конкретні алгоритми їх реалізації.

4.2. Застосування багатовимірною концептуального аналізу до обробки мультимодальних медичних даних

Система концептуального аналізу даних на основі багатомірних формальних контекстів (англ. Multidimensional Formal Context Analysis, MFCA) є сучасним методом аналізу даних, який базується на формальній теорії концептів (англ. Formal Concept Analysis, FCA) [23, 25]. Формальна теорія концептів є широко визнаним підходом для виявлення взаємозв'язків між

об'єктами та їх властивостями на основі формалізованого опису. Основними її елементами є формальні контексти, концепти та їх властивості [20, 23].

Багатомірні формальні контексти відображають розширення класичних формальних контекстів, у яких об'єкти, атрибути та додаткові характеристики можуть бути пов'язані із кількома контекстами одночасно. Така структура дозволяє враховувати різноманітні аспекти визначених об'єктів та забезпечує ефективний багатовимірний аналіз даних.

У цьому підході багатомірні концепти описують групи об'єктів, що мають спільні властивості в множині формальних контекстів, розширюючи класичну модель FCA для аналізу складних залежностей. Багатомірні атрибути, відповідно, виступають характеристиками об'єктів, що мають значення у різних контекстах і допомагають будувати багатовимірні зв'язки між даними [21, 23]. Таким чином, MFCA стає основою формальної моделі інформаційної технології багатовимірного аналізу мультимодальних медичних даних, яка поєднує:

1. Структурування вхідних даних.
2. Виявлення латентних концептів у багатовимірному просторі.
3. Формалізацію логічних зв'язків між медичними об'єктами.
4. Інтерпретовану класифікацію клінічних станів.
5. Візуалізацію ієрархії знань.

Формалізуємо модель інформаційної технології багатовимірного аналізу мультимодальних медичних даних, засновану на концептуальному аналізі з використанням багатовимірних формальних контекстів.

Описова модель системи багатовимірного аналізу мультимодальних медичних даних базується на поєднанні концептуального аналізу даних (CAD) та механізмів машинного навчання з урахуванням клінічного контексту. Основна мета такої моделі – ефективно виявлення закономірностей у великих масивах різномірної інформації про пацієнтів, їхній стан, симптоми, а також контекстуальних факторів, які можуть впливати на діагностичний висновок.

Модель розглядає пацієнтів як об'єкти, кожен з яких описується вектором ознак у багатовимірному просторі. Ці ознаки можуть походити з різних джерел

(модальностей): ЕКГ, МРТ, ЕЕГ, клінічних записів, лабораторних даних, текстових анамнезів тощо.

Формальний контекст є базовою математичною моделлю, яка репрезентує дані у вигляді таблиці, де рядки відповідають об'єктам, а стовпці – атрибутам. Значення у комірках (1 або 0) відображають наявність або відсутність відповідного атрибуту в об'єкті. Такий підхід дає змогу структурувати різні типи даних, зокрема текстові, візуальні чи аудіальні модальності.

Щоб краще зрозуміти, як працює система концептуального аналізу даних на основі багатомірних формальних контекстів, розглянуто основні поняття, які використовуються в ІТ системі.

1. Формальний контекст – це математична модель, яка використовується для представлення даних у вигляді таблиці, де рядки відповідають об'єктам, а стовпці – атрибутам. Кожна комірка таблиці містить 1 або 0, в залежності від того, чи має об'єкт заданий атрибут. Формальний контекст може бути використаний для різних модальностей.

Нехай O є множина об'єктів та множина атрибутів A . Формальний контекст C – це матриця M розміром $|O| \times |A|$, де кожен рядок відповідає об'єкту, а кожен стовпець – атрибуту. Комірка $M[i, j]$ містить 1 або 0, відповідно до того, чи має об'єкт i атрибут j .

Формально контекст виражається як: $C = (O, A, M)$, де

- O – множина об'єктів;
- A – множина атрибутів;
- M – матриця розміром $|O| \times |A|$, де $M[i, j] = 1$, якщо об'єкт i має атрибут j , та $M[i, j] = 0$ в іншому випадку.

2. Багатовимірний формальний контекст – це формальний контекст, який містить декілька таблиць, що представляють дані різних типів. Використання багатовимірних формальних контекстів дозволяє аналізувати дані з різних джерел та отримувати повне представлення реалізації ІТ.

Для формального представлення наведено:

- Набір множин об'єктів $O^{(k)}$ для кожної виміру $k \in K$, де K – це індекс множин об'єктів (виміри або різні типи об'єктів).
- Набір множин атрибутів $A^{(k)}$ для кожного виміру $k \in K$.
- Множини відношень між об'єктами та атрибутами для кожного виміру $I^{(k)} \subseteq O^{(k)} \times A^{(k)}$.

Таким чином, кожен вимір k визначається своїм формальним контекстом $K^{(k)} = (O^{(k)}, A^{(k)}, I^{(k)})$, де $I^{(k)}$ – це відношення між об'єктами та атрибутами в контексті k .

Отож, багатомірний формальний контекст – це кортеж $M = (\{K^{(k)} = (O^{(k)}, A^{(k)}, I^{(k)})\}_{k \in K})$, де $K^{(k)}$ – це набір формальних контекстів для кожного виміру $k \in K$.

Формальне поняття в багатомірному контексті визначається як кортеж множин об'єктів та атрибутів $(B_1, B_2, \dots, B_k, C_1, C_2, \dots, C_k)$, для всіх вимірів $k \in K$, де:

- $B_k \subseteq O^{(k)}$ – це підмножина об'єктів для виміру k ,
- $C_k \subseteq A^{(k)}$ – це підмножина атрибутів для виміру k .

Ці множини пов'язані між собою через відношення $I^{(k)}$, відповідно для всіх $k \in K$ справедливим є:

$$\begin{aligned} B_k &= \{o \in O^{(k)} \mid \forall a \in C_k, (o, a) \in I^{(k)}\}, \\ C_k &= \{a \in A^{(k)} \mid \forall o \in B_k, (o, a) \in I^{(k)}\}. \end{aligned} \tag{4.1}$$

Концепти, визначені у такий спосіб, дають змогу виводити асоціативні правила виду: $\{B\} \Rightarrow \{C\}$, де B і C – відповідні множини об'єктів і властивостей, що встановлюють залежності між групами об'єктів і властивостей на основі їх спільних характеристик.

Для демонстрації практичної реалізації ІТ запропоновано приклад побудови моделі концептуального аналізу з використанням трьох модальностей: тексту, зображення та аудіо.

Етап 1: Формування формального контексту.

Розглядаються три об'єкти:

- O_1 : Стаття про здорове харчування.
- O_2 : Зображення овочів.
- O_3 : Аудіо інтерв'ю з дієтологом.

Відповідно, отримані певні властивості (атрибути):

- Текстові властивості (M_1):
 - T_1 : Здоров'я.
 - T_2 : Дієта.
 - T_3 : Овочі.
- Зображення (M_2):
 - I_1 : Овочі.
 - I_2 : Фрукти.
 - I_3 : Страва.
- Аудіо властивості (M_3):
 - A_1 : Інтерв'ю.
 - A_2 : Рецепти.
 - A_3 : Поради.

У таблиці 4.5 представлено взаємозв'язки між об'єктами та властивостями при визначенні формального контексту.

Таблиця 4.5

Бінарні відношення I між об'єктами та властивостями при визначенні формального контексту

Об'єкт	T_1	T_2	T_3	I_1	I_2	I_3	A_1	A_2	A_3
O_1	+	+					+		
O_2			+	+					
O_3							+	+	+

Етап 2: Утворення формального контексту

Отож, формальний контекст має вигляд: $K = (G, M, I)$, де:

- $G = \{O_1, O_2, O_3\}$ – множина об'єктів.
- $M = M_1 \cup M_2 \cup M_3 = \{T_1, T_2, T_3, I_1, I_2, I_3, A_1, A_2, A_3\}$ – множина властивостей.

- I – бінарне відношення, наведене в Табл. 4.5.

Етап 3. Визначення формальних концептів.

Відповідно до даних Табл. 4.1 можна визначити концепти ІТ:

1. Концепт C_1 :

- Об'єкт (A): O_1 ;
- Властивості (B): T_1, T_2, A_1 .

2. Концепт C_2 :

- Об'єкт (A): O_2 ;
- Властивості (B): T_3, I_1 .

3. Концепт C_3 :

- Об'єкт (A): O_3 ;
- Властивості (B): A_1, A_2, A_3 .

Етап 4. Формулювання асоціативних правил

На основі визначених з таблиці 4.5 концептів виведено відповідні асоціативні правила:

1. Правило $R_1: \{O_1\} \Rightarrow \{T_1, T_2, A_1\}$,
2. Правило $R_2: \{O_2\} \Rightarrow \{T_3, I_1\}$,
3. Правило $R_3: \{O_3\} \Rightarrow \{A_1, A_2, A_3\}$.

Таким чином, наведений приклад демонструє, як на основі багатовимірних формальних контекстів можна будувати моделі концептуального аналізу мультимодальних даних, визначаючи об'єкти, їх властивості та встановлюючи зв'язки між ними. Використання цієї методики дозволяє виявляти приховані закономірності в даних, що є важливим для підвищення ефективності прийняття рішень у складних інформаційних середовищах. Наочне представлення отриманих результатів наведено на рисунку 4.3, де відображено модель багатовимірних формальних контекстів у вигляді діаграми.




Рис. 4.3. Приклад моделі багатовимірних формальних контекстів

Основна концепція моделі, представленої на рисунку 4.3, полягає у пошуку спільних підмножин об'єктів і атрибутів у багатовимірному формальному контексті для побудови концептів. Реалізація інформаційної технології аналізу даних може здійснюватися за допомогою різних методичних підходів, таких як методи відбору або пошуку.

Щоб показати, як модель концептуального аналізу на основі багатовимірних формальних контекстів (MFCA) працює на прикладі сформованого датасету (Додаток В), нижче наведено фрагмент даних, що охоплює декілька модальностей, та представлено результати за етапами побудови концептуальної моделі.

Пацієнт (P)	QT_high > 440 мс	Theta_Alpha > 1	Age > 65	Diabetes
P_1	+	+	+	+
P_2	+			+
P_3	+	+	+	
P_4				+

Етап 1: Формальні контексти за модальностями

– Модальність 1 – ЕКГ (QT_high): P_1, P_2, P_3 ;

- Модальність 2 – ЕЕГ (Theta_Alpha): P_1, P_3 ;
- Модальність 3 – Анамнез: $Bik > 65$ (Age): P_1, P_3 та Діабет (Diabetes): P_1, P_2, P_4 .

Етап 2: Побудова концептів

- Концепт C_1 : Об'єкт: $\{P_1\}$; Ознаки: $\{QT\_high, Theta\_Alpha, Age, Diabetes\}$.
- Концепт C_2 : Об'єкт: $\{P_2\}$; Ознаки: $\{QT\_high, Diabetes\}$.
- Концепт C_3 : Об'єкт: $\{P_3\}$; Ознаки: $\{QT\_high, Theta\_Alpha, Age\}$.
- Концепт C_4 : Об'єкт: $\{P_4\}$; Ознаки: $\{Diabetes\}$.

Етап 3: Формулювання асоціативних правил

$R_1: \{QT\_high, Diabetes\} \Rightarrow \{P_1, P_2\} \rightarrow$ якщо у пацієнта подовжений інтервал QT та діабет, він належить до групи P_1 або P_2 .

$R_2: \{QT\_high, Theta\_Alpha, Age\} \Rightarrow \{P_1, P_3\} \rightarrow$ якщо у пацієнта ці три ознаки, то він належить до групи P_1 або P_3 .

$R_3: \{Diabetes\} \Rightarrow \{P_4\} \rightarrow$ якщо є лише діабет, можливо, це пацієнт P_4 .

$R_4: \{QT\_high, Theta\_Alpha, Age, Diabetes\} \Rightarrow \{P_1\}$.

Ось повний список максимально інформативних асоціативних правил (імплікацій), які можна сформулювати на основі наданих концептів:

$C_1 (\{P_1\}; \{QT\_high, Theta\_Alpha, Age, Diabetes\})$:

- $\{QT\_high, Theta\_Alpha, Age, Diabetes\} \Rightarrow \{P_1\}$
- $\{QT\_high, Theta\_Alpha, Age\} \Rightarrow \{P_1\}$
- $\{QT\_high, Theta\_Alpha, Diabetes\} \Rightarrow \{P_1\}$
- $\{QT\_high, Age, Diabetes\} \Rightarrow \{P_1\}$
- $\{Theta\_Alpha, Age, Diabetes\} \Rightarrow \{P_1\}$
- $\{QT\_high, Theta\_Alpha\} \Rightarrow \{P_1\}$
- $\{QT\_high, Age\} \Rightarrow \{P_1\}$
- $\{QT\_high, Diabetes\} \Rightarrow \{P_1\}$
- $\{Theta\_Alpha, Age\} \Rightarrow \{P_1\}$
- $\{Theta\_Alpha, Diabetes\} \Rightarrow \{P_1\}$
- $\{Age, Diabetes\} \Rightarrow \{P_1\}$

- $\{QT\_high\} \Rightarrow \{P_1\}$ (але цей атрибут не є унікальним, бо ще є у P_2 і P_4)
- $\{Diabetes\} \Rightarrow \{P_1\}$ (не унікальне – є ще у P_2 та P_4), тому залишаємо лише ті, що справді унікальні для P_1 :
- $\{QT\_high, Theta\_Alpha, Age, Diabetes\} \Rightarrow \{P_1\}$
- $\{QT\_high, Theta\_Alpha, Age\} \Rightarrow \{P_1\}$

$C_2 (\{P_2\}; \{QT\_high, Diabetes\})$:

- $\{QT\_high, Diabetes\} \Rightarrow \{P_2\}$

$C_3 (\{P_3\}; \{QT\_high, Theta\_Alpha, Age\})$:

- $\{QT\_high, Theta\_Alpha, Age\} \Rightarrow \{P_3\}$

$C_4 (\{P_4\}; \{Diabetes\})$:

- $\{Diabetes\} \Rightarrow \{P_4\}$ (але $Diabetes$ є ще у P_1 і P_2 – не унікальне $\Rightarrow$ правило не максимальне), тому уникнемо цієї імплікації, бо вона не забезпечує однозначної ідентифікації об'єкта.

На основі побудованих асоціативних правил було ідентифіковано унікальні комбінації ознак, що однозначно характеризують окремих пацієнтів. Правила виду $\{QT\_high, Theta\_Alpha, Age, Diabetes\} \Rightarrow \{P_1\}$, $\{QT\_high, Theta\_Alpha, Age\} \Rightarrow \{P_1\}$, $\{QT\_high, Diabetes\} \Rightarrow \{P_2\}$ та $\{QT\_high, Theta\_Alpha, Age\} \Rightarrow \{P_3\}$ демонструють, що певні поєднання параметрів біомедичних і демографічних даних є достатніми для точного розпізнавання індивідуального стану пацієнта. Водночас окремі ознаки, що зустрічаються у кількох пацієнтів, не забезпечують однозначності ідентифікації, що підтверджує необхідність комплексного аналізу мультимодальних даних. Отримані правила можуть бути використані для побудови ефективних алгоритмів класифікації та підтримки прийняття клінічних рішень, підвищуючи точність діагностики та персоналізацію лікування.

4.3. Багатокритеріальний підхід до формування простору ознак мультимодальних даних

У межах концептуального аналізу мультимодальних даних важливим напрямом є застосування методів багатокритеріального покращення (англ. Multi-

Criteria Optimization, MCO), які забезпечують узгоджене врахування кількох незалежних критеріїв при оцінюванні альтернативних рішень. Такі методи доповнюють концептуальний апарат CAD і дозволяють формувати множину Парето-оптимальних концептів для подальшого відбору на основі заданих цільових функцій.

На відміну від традиційного підходу, орієнтованого на одну мету або один критерій, багатокритеріальне покращення дозволяє одночасно оцінювати якість представлення кожної модальності, її інформативність, стійкість до шуму, ступінь узгодженості з іншими модальностями тощо. У випадку обробки мультимодальних даних це особливо актуально, адже кожен тип даних має власні метричні властивості, які не можна звести до єдиної шкали.

У межах сформованої моделі концептуального аналізу мультимодальних даних важливим етапом є оптимізація сформованих концептів з урахуванням множини взаємопов'язаних критеріїв. Це дозволяє не лише відображати структурні зв'язки між пацієнтами та їх характеристиками, але й відбирати найрелевантніші концепти, що максимально відповідають поставленим діагностичним або прогностичним завданням [33].

З цією метою до моделі вводиться багатокритеріальна функція якості концепту, що відображає сукупність оцінок за такими показниками:

- Інформативність концепту (I) – ступінь значущості обраної групи атрибутів у медичному контексті.
- Стійкість до шуму (R) – здатність концепту зберігати стабільність при варіаціях у вхідних даних.
- Узгодженість між модальностями (C) – міра когерентності атрибутів, що походять із різних джерел (наприклад, ЕКГ + текст).
- Специфічність концепту (S) – ступінь відмінності концепту від інших у решітці знань.
- Повнота охоплення (K) – кількість об'єктів, які потрапляють у концепт.

На основі цих критеріїв вводиться векторна функція якості концепту:

На основі цих критеріїв вводиться векторна функція якості концепту: $\vec{F}(C_i) = (f_1(C_i), f_2(C_i), \dots, f_n(C_i))$, $C_i \in B(K)$, де $f_j(C_i)$ – значення j -го критерію для концепту C_i , а $B(K)$ – решітка всіх можливих концептів у формальному контексті K .

Таким чином, завдання багатокритеріального покращення формулюється як знаходження підмножини концептів $C^* \subset B(K)$, які є парето-оптимальними за векторною функцією $\vec{F}$, тобто таких, що не існує іншого концепту C' , який одночасно є не гіршим за C^* за всіма критеріями та кращим хоча б за одним: $\exists C' \in B(K): \vec{F}(C') > \vec{F}(C^*)$.

У цьому контексті, модель концептуального аналізу даних із багатокритеріальним покращенням (CAD+MCO) стає інструментом не лише для виявлення структурних знань, а й для обґрунтованого вибору найкращих концептів, що можуть бути використані в подальшій класифікації, інтерпретації або візуалізації в системах клінічної підтримки прийняття рішень.

Оскільки кожна модальність у мультимодальних даних характеризується власними параметрами якості, важливо забезпечити узгоджене прийняття рішень у межах загальної аналітичної моделі. У цьому контексті багатокритеріальна оптимізація дозволяє не лише покращувати показники кожної окремої модальності, але й досягати компромісного глобального рішення, яке є оптимальним з точки зору всієї системи в цілому.

Для цього необхідно формалізувати модель багатокритеріального покращення із урахуванням індивідуальних цілей кожного інформаційного каналу. Саме така постановка задачі створює підґрунтя для математичного опису процесу оптимізації мультимодальних даних, який наведено нижче.

Для формального визначення ІТ багатокритеріального покращення мультимодальних даних розглянуто вектор ознак $x^{(m)} \in R^{d_m}$, де кожна модальність $m \in \{1, 2, \dots, M\}$ має різні характеристики та критерії оцінювання, які потрібно покращити [107, 152].

Для кожної модальності m вводиться кілька критеріїв: $f_i(x^{(m)}): X^{(m)} \rightarrow R$, $i = 1, 2, \dots, K_m$. Слід розглянути задачу, яка полягає у знаходженні таких рішень $x^{(1)}, x^{(2)}, \dots, x^{(M)}$, які мінімізують або максимізують всі критерії для кожної модальності:

$$\min_{x^{(1)}, x^{(2)}, \dots, x^{(M)}} f(x^{(1)}, x^{(2)}, \dots, x^{(M)}) = \quad (4.2)$$

$$[f_1(x^{(1)}), f_2(x^{(1)}), \dots, f_{K_1}(x^{(1)}), \dots, f_1(x^{(M)}), \dots, f_{K_M}(x^{(M)})],$$

де $f_i(x^{(m)})$ – це критерії для модальності m , а $f(x^{(1)}, x^{(2)}, \dots, x^{(M)})$ – вектор критеріїв, який об'єднує всі модальності.

Багатокритеріальне покращення в САД дозволяє одночасно враховувати кілька критеріїв якості при аналізі мультимодальних даних або концептуальних моделей. Формально це виражається через пошук Парето-оптимальних рішень, використання вагових коефіцієнтів для лінійної згортки критеріїв або через методи еволюційної ІТ для знаходження компромісних рішень [124, 138].

Передусім, неможливо одночасно мінімізувати або максимізувати всі критерії для кожної модальності. Тому шукається множина Парето-оптимальних рішень $X^* = (x^{(1)}, x^{(2)}, \dots, x^{(M)})$, яка покращує один критерій, не погіршуючи при цьому інші: $f_i(X) \leq f_i(X^*) \forall i$ та $f_j(X) < f_j(X^*)$ для деякого j .

Парето-фронт – це множина всіх Парето-оптимальних рішень, які представляють компромісні варіанти між різними критеріями для різних модальностей. Прикладом є ІТ багатокритеріального покращення, яку можна перетворити в задачу одномірного покращення за допомогою вагових коефіцієнтів для кожного критерію. Для цього використовують лінійну згортку критеріїв [156, 166, 167]:

$$F(X) = \sum_{m=1}^M \sum_{i=1}^{K_m} \lambda_i^{(m)} f_i(x^{(m)}), \quad (4.3)$$

де $\lambda_i^{(m)} \geq 0$ – вагові коефіцієнти, які визначають важливість кожного критерію для модальності m , та $\sum_{i=1}^{K_m} \lambda_i^{(m)} = 1$.

Ця модель дозволяє знайти рішення, яке є компромісом між усіма критеріями, шляхом підбору ваг та її критеріїв для кожної модальності.

Для знаходження множини Парето-оптимальних рішень часто використовують ІТ, такі як NSGA-II (англ. Non-dominated Sorting Genetic Algorithm II). Зазначена методика знаходить рішення, які належать Парето-фронті, шляхом генетичних операцій (селекція, кросовер, мутація) та відбору домінуючих рішень.

Такі ІТ є ефективними для багатовимірних задач, де кількість критеріїв і модальностей велика, де не можна заздалегідь визначити ваги для кожного критерію. Модель ідеальної точки полягає в обчисленні відстані між кожним рішенням і так званою ідеальною точкою $z^* = [z_1^*, z_2^*, \dots, z_K^*]$:

$$\min_{x^{(1)}, x^{(2)}, \dots, x^{(M)}} \sum_{m=1}^M \sum_{i=1}^{K_m} \|f_i(x^{(m)}) - z_i^*\|. \quad (4.4)$$

Вона дозволяє знаходити рішення, які максимально наближаються до ідеальної точки, мінімізуючи відстань до оптимальних значень кожного критерію [195, 229].

Для реалізації ІТ показано задачу мультимодальної класифікації, де визначаються критерії кожної модальності [235, 236]:

- Текстові дані: $f_1(x^{(1)})$ – точність класифікації тексту, $f_2(x^{(1)})$ – час обробки тексту.
- Зображення: $f_1(x^{(2)})$ – якість розпізнавання об'єктів, $f_2(x^{(2)})$ – розмір моделі для обробки зображень.
- Числові дані: $f_1(x^{(3)})$ – точність прогнозування, $f_2(x^{(3)})$ – кількість використаних ресурсів.

ІТ багатокритеріального покращення полягає у знаходженні певних рішень, які максимізують точність та якість класифікації або прогнозування для кожної модальності, водночас мінімізуючи час обробки. Ефективне рішення належить до Парето-фронті, де можливий компроміс між всіма критеріями ІТ.

Щоб вивести концепцію багатокритеріального покращення на модель інформаційної технології обробки мультимодальних медичних даних, потрібно:

1. Формалізувати множину критеріїв оцінки. Для цього модель повинна враховувати кілька незалежних критеріїв, що характеризують якість кожної модальності та загального результату:

- q_1 : точність класифікації (accuracy);
- q_2 : повнота (recall);
- q_3 : швидкість обробки (processing time);
- q_4 : узгодженість між модальностями (modality agreement);
- q_5 : інформативність ознак (feature relevance).

Всі ці критерії можуть бути представлені у вигляді векторної функції якості: $Q(X_i, \Omega) = [q_1(X_i, \Omega), q_2(X_i, \Omega), \dots, q_k(X_i, \Omega)]$.

2. Задати цільову функцію та Парето-оптимальність. Замість пошуку одного «найкращого» рішення виводимо Парето-фронт – множину рішень, які неможливо покращити за одним критерієм, не погіршивши інші.

Формально: $f^* = \arg \max_{f \in F} Q(f(X_i, \Omega))$ (в сенсі Парето-домінування)

3. Інтегрувати багатокритеріальний відбір у процес формування концептів. Кожен формальний концепт $C = (A, B)$ додатково оцінюється за всіма критеріями $q_1, \dots, q_k$. Таким чином:

- Для кожного концепту розраховується вектор оцінки якості.
- Концепти, які лежать на Парето-фронті, зберігаються для подальшого аналізу або класифікації.

4. Побудувати багаторівневу модель. Формальні рівні:

- Рівень 1: Формування множини мультимодальних формальних контекстів $K^{(1)}, K^{(2)}, \dots, K^{(n)}$.
- Рівень 2: Генерація концептів з кожного $K^{(i)}$.
- Рівень 3: Оцінювання кожного концепту за критеріями Q .
- Рівень 4: Побудова Парето-фронтів $C_{Pareto} \subseteq C$.
- Рівень 5: Вибір найбільш інтерпретованого концепту для клінічного рішення.

5. Візуалізація та інтерпретація. На фінальному етапі реалізується візуальна модель, яка:

- відображає ієрархію концептів (наприклад, Hasse-діаграма),
- підкреслює концепти, що належать до Парето-фронту,
- ілюструє компроміси між критеріями (наприклад, точність проти часу).

Як приклад, представимо інформаційну систему, яка реалізує концептуальний аналіз мультимодальних медичних даних з використанням багатовимірних формальних контекстів та методів багатокритеріальної оптимізації (МСО).

Для забезпечення інтерпретованої класифікації стану пацієнта було здійснено генерацію множини концептів на основі поєднань ознак із сформованого набору мультимодальних медичних даних (Додаток В). До розгляду були включені 25 ознак, які охоплюють електрокардіографічні, нейровізуалізаційні, спектральні та клінічні параметри, а саме:

- Кардіо-сигнали: QT_interval, RR_interval, QRS_duration, P_interval, ST_depression, HRV;
- Спектральні EEG-ознаки: Alpha_power, Beta_power, Peak_frequency, Spectral_entropy, Theta_alpha_index, Frontal_coherence;
- МРТ-характеристики: Hypointense_volume, GM_texture_entropy, GM_WM_contrast, Periventricular_intensity, Parietal_LBP, Lateral_ventricle_shape;
- Клініко-анамнестичні ознаки: Age, Sex, Diabetes, Hypertension, Smoking, BMI, Stroke_history.

З використанням комбінацій цих ознак (по 2, 3 та 4 одночасно) було автоматично сформовано 15 250 концептів, кожен із яких репрезентує окремий підхід до класифікації пацієнта на основі обмеженої підмножини характеристик. Такий підхід дає змогу виявити локальні патерни в даних та оцінити важливість різних груп ознак. Нижче наведено приклади перших 10 концептів:

Concept_ID	Ознаки	Concept_ID	Ознаки
C_1	(QT_interval, RR_interval)	C_6	(QT_interval, Alpha_power)
C_2	(QT_interval, QRS_duration)	C_7	(QT_interval, Beta_power)
C_3	(QT_interval, P_interval)	C_8	(QT_interval, Peak_frequency)
C_4	(QT_interval, ST_depression)	C_9	(QT_interval, Spectral_entropy)
C_5	(QT_interval, HRV)	C_{10}	(QT_interval, Theta_alpha_index)

Для кожного концепту було передбачено обчислення багатовимірної функції якості:

$$Q(C_i) = [q_1^{(i)}, q_2^{(i)}, q_3^{(i)}], \quad (4.5)$$

де:

- q_1 – точність класифікації (accuracy) (формула 2.11),
- q_2 – час обробки (processing time) (формула 2.23),
- q_3 – стійкість до шуму (robustness) (формула 2.24).

Цей підхід створює підґрунтя для подальшої багатокритеріальної оптимізації, яка дозволяє знайти Парето-оптимальну множину концептів, що забезпечують найкращий компроміс між точністю, швидкістю, стабільністю та інтерпретованістю.

Множина концептів розглядається як набір точок у тривимірному просторі критеріїв Q . Парето-домінування означає наступне:

Концепт C_a домінує над концептом C_b (позначається $C_a > C_b$), якщо:

- $q_k^{(a)} \geq q_k^{(b)}$ для всіх критеріїв $k = 1, \dots, 3$,
- і принаймні для одного критерію більший результат: $q_j^{(a)} > q_j^{(b)}$.

Парето-фронт – це підмножина концептів, які не домінуються жодним іншим. Ці концепти є найкращими компромісними рішеннями, адже для жодного з них не існує іншого концепту, який був би кращим за всіма критеріями одночасно.

Алгоритм пошуку Парето-фронту включає наступні кроки:

- Вхід: множина концептів $C = \{C_1, \dots, C_N\}$ та їх вектори якості $Q(C_i)$.
- Для кожного концепту C_i перевіряємо, чи існує концепт C_j , який домінує над C_i .
- Якщо такого концепту немає – C_i належить до Парето-фронту.
- Всі такі концепти формують множину $C_{Pareto} \subseteq C$.

У таблиці 4.6. наведено розраховані критерії по перших десяти сформованих концептах.

Таблиця 4.6

Розрахунок критеріїв для кожного концепту

Concept_ID	Ознаки	Accuracy q_1	Time (с) q_2	Robustness q_3
C_1	(QT_interval, RR_interval)	0,85	1,5	0,80
C_2	(QT_interval, QRS_duration)	0,83	1,4	0,78
C_3	(QT_interval, P_interval)	0,80	1,3	0,82
C_4	(QT_interval, ST_depression)	0,82	1,6	0,75
C_5	(QT_interval, HRV)	0,87	1,7	0,85
C_6	(QT_interval, Alpha_power)	0,78	1,8	0,70
C_7	(QT_interval, Beta_power)	0,79	1,5	0,72
C_8	(QT_interval, Peak_frequency)	0,81	1,9	0,76
C_9	(QT_interval, Spectral_entropy)	0,75	2,0	0,69
C_{10}	(QT_interval, Theta_alpha_index)	0,84	1,4	0,79

За даними таблиці 4.6 проведено аналіз домінування концептів: початок з C_1 . Наведено його порівняння з іншими концептами:

- C_5 має кращу точність ($0,87 > 0,85$), але гірший час ($1,7 > 1,5$) → не домінує.
- C_{10} має менший час ($1,4 < 1,5$), але точність трохи менша ($0,84 < 0,85$), не домінує.
- Інші концепти або мають гірші показники, або не домінують C_1 .

Отже, C_1 не домінує.

C_2 порівнюється з C_1 :

- C_1 має кращу точність ($0,85 > 0,83$), але гірший час ($1,5 > 1,4$), тому не домінує.

C_2 порівнюємо з C_3 :

- C_3 має гіршу точність ($0,80 < 0,83$), тому не домінує.

C_2 порівнюється з C_{10} :

- C_{10} має більшу точність ($0,84 > 0,83$), час однаковий або кращий ($1,4 = 1,4$), але стійкість більша ($0,79 > 0,78$), отже C_{10} домінує C_2 .

Значить, C_2 домінує.

C_3 порівнюється з C_1 :

- C_1 має більшу точність ($0,85 > 0,80$), час більший ($1,5 > 1,3$), стійкість нижча ($0,80 < 0,82$) – не домінує.

C_3 порівнюється з C_5 :

- C_5 має кращу точність, але гірший час.

Порівнюється з C_1 , C_5 , C_{10} – жоден концепт не домінує з C_3 за всіма трьома критеріями. Отже, C_3 не домінує.

C_4 порівнюється з C_1 :

- C_1 кращий по точності і стійкості, час кращий ($1,5 < 1,6$), C_1 домінує C_4 .

Отже, C_4 домінує.

C_5 порівнюється з C_1 :

- C_5 кращий по точності ($0,87 > 0,85$), але час гірший ($1,7 > 1,5$), не домінує.

Порівнюється з іншими – жоден концепт не має кращих показників по всіх трьох критеріях. Отже, C_5 не домінує.

Порівнюється з C_6 , але більшість концептів кращі по точності, часу та стійкості. Наприклад, C_1 домінує C_6 . Отже, C_6 домінує.

C_7 аналогічно, C_1 домінує C_7 .

Перевіряємо C_8 : C_1 домінує над C_8 (краща точність і кращий час).

Перевіряємо C_9 – домінований усіма кращими концептами.

Перевіряємо C_{10} та порівнюємо з C_1 : C_1 має більшу точність ($0,85 > 0,84$), але гірший час ($1,5 > 1,4$).

Немає концепту, який домінує над C_{10} за всіма критеріями. Отже, C_{10} не домінує.

Парето-фронт містить концепти C_1 , C_3 , C_5 , C_{10} , які представляють найкращі компроміси між точністю, часом обробки та стійкістю до шуму.

Такий підхід дозволяє досягнути оптимального балансу між ефективністю, точністю, пояснюваністю та гнучкістю. Завдяки багатокритеріальному покращенню лікар отримує адаптивний інструмент прийняття рішень, який враховує множинні аспекти обробки мультимодальних медичних даних – від синтаксичного до семантичного рівня.

Виведення багатокритеріального покращення на модель означає інтеграцію для оцінювання якості за множиною критеріїв з подальшим вибором оптимальних рішень з Парето-фронту. Це забезпечує баланс точності, швидкодії та узгодженості при роботі з мультимодальними даними та підвищує ефективність підтримки клінічних рішень.

Таким чином, багатокритеріальне покращення виступає як потужний методологічний інструмент, який дозволяє досягти оптимального балансу між точністю, ефективністю та ресурсною доцільністю при обробці мультимодальних даних. Завдяки можливості одночасного врахування багатьох критеріїв для кожної модальності, такі підходи забезпечують гнучке налаштування аналітичної системи відповідно до конкретних вимог задачі.

Висновки до розділу 4

У четвертому розділі дисертації представлено систему математичних моделей, які формують теоретичну основу інформаційної технології багатовимірного аналізу мультимодальних медичних даних. Розроблені моделі дозволяють ефективно інтегрувати, аналізувати та інтерпретувати гетерогенні медичні дані з різних джерел, забезпечуючи високу точність та адаптивність у задачах класифікації.

1. Обґрунтовано застосування концептуального аналізу даних як базового підходу до репрезентації мультимодальних медичних даних, що забезпечує формалізацію взаємозв'язків між об'єктами (пацієнтами) та ознаками різної природи (сигнальні, візуальні, текстові, клінічні). Реалізація моделі у вигляді формального контексту дозволила побудувати структуру знань у формі концептуальної решітки, що унаочнює ієрархію патологічних станів і типовість комбінацій медичних характеристик.

2. Запропоновано модель багатовимірного концептуального аналізу, яка дозволяє поєднувати кілька формальних контекстів відповідно до модальностей, формуючи складні багатовимірні концепти. Це забезпечило можливість детального аналізу міжмодальних закономірностей та асоціативних

залежностей між об'єктами, які мають схожі ознаки в різних модальностях, що є критично важливим у задачах класифікації.

3. Розроблено механізм багатокритеріального покращення концептів, що передбачає одночасний аналіз кількох критеріїв якості (інформативність, стійкість, когерентність, специфічність, повнота) та визначення множини Парето-оптимальних концептів. Це дозволило здійснити раціональний вибір найбільш релевантних класифікаційних структур для задач клінічного прогнозування на основі складних, неповних або гетерогенних даних.

4. Доведено, що поєднання CAD, MFCA, MCO дозволяє сформувати адаптивну та ефективну інформаційну технологію, орієнтовану на медичне застосування. Така технологія забезпечує цілісну обробку мультимодальних даних на всіх етапах – від збору, бінаризації, побудови формальних концептів до оптимізації, класифікації та візуалізації результатів. Вона слугує основою для побудови системи підтримки клінічних рішень із високим ступенем інтерпретованості.

5. Практична реалізація запропонованих моделей на сформованому мультимодальному медичному наборі даних підтвердила їх ефективність і адаптованість до клінічного використання. Побудовано понад 15 000 концептів, сформовано Парето-фронт оптимальних варіантів та реалізовано візуалізацію структури знань у вигляді Hasse-діаграм. Це дозволило не лише виявити типові клінічні патерни, а й сформувати логічно обґрунтовані асоціативні правила, придатні для автоматизованого клінічного аналізу.

Результати досліджень за четвертим розділом опубліковано в роботах автора [20, 35, 44, 45, 54, 55] (Додаток Б).

РОЗДІЛ 5

МЕТОДИ УНІФІКАЦІЇ ТА ІНТЕГРАЦІЇ МУЛЬТИМОДАЛЬНИХ МЕДИЧНИХ ДАНИХ У ВЕКТОРАХ ОЗНАК ТА РІШЕНЬ

У п'ятому розділі представлено комплексну методологію побудови єдиного аналітичного простору для обробки, аналізу та прогнозування на основі мультимодальних медичних даних. Враховано як структурну неоднорідність, так і різну природу джерел даних, що вимагає глибокої інтеграції на рівні як ознак, так і рішень. Розділ об'єднує теоретичні основи, алгоритмічні рішення та прикладні реалізації, що дозволяють забезпечити як інтерпретованість, так і високу прогностичну здатність.

Розглянуто методи виявлення та оцінки структурної узгодженості між модальностями. Запропоновано критерії когерентності та кореляційної узгодженості, а також алгоритми для виявлення внутрішньої структурної гармонії між просторами ознак різних джерел, що є передумовою для подальшої інтеграції.

Зосереджено увагу на методах інтеграції даних і побудові уніфікованого простору ознак. Докладно проаналізовано два принципи – інтеграції мультимодальних ознак (Feature-level fusion) та інтеграції модальних моделей (Model-level fusion). Для інтеграції мультимодальних ознак обґрунтовано застосування методів зменшення розмірності, що дозволяє сформувати єдиний багатовимірний простір ознак, придатний до візуалізації, класифікації та аналізу подібностей. Інтеграція модальних моделей розглядається як об'єднання модальностей на рівні рішень, що забезпечує гнучкість і стійкість у випадках відсутності окремих модальностей.

В межах розділу увага зосереджується на методах порівняння динамічних і синтетичних систем мультимодального середовища з метою оцінювання їх ефективності та узгодженості. Таким чином, розділ демонструє цілісну архітектуру побудови уніфікованого аналітичного простору на основі мультимодальних медичних даних, який підтримує різні сценарії обробки та адаптивної інтеграції у динамічних інформаційних системах.

5.1. Методи виявлення структурних відповідностей мультимодальних даних у багатовимірному просторі

У сучасних інформаційних технологіях аналізу медичних даних дедалі важливішим стає врахування мультимодальної природи інформації. Модальності даних охоплюють різні типи інформації, такі як текст, зображення, звук та числові показники. Для реалізації мультимодального підходу необхідним є поєднання різних модальностей з метою формування узгодженого та комплексного опису об'єктів дослідження.

Кожна модальність має власні структурні та семантичні характеристики, що зумовлює необхідність розробки індивідуальних підходів до її обробки та аналізу. Вони можуть класифікуватися за форматом даних, способом представлення, структурою ознак, рівнем абстракції та типом інформації, що передається. У межах даного дослідження запропоновано класифікацію модальностей, яка базується на їхній природі, типу подання інформації та рівні складності обробки (Табл. 5.1). Такий підхід дозволяє структурувати процес аналізу і забезпечити узгоджене трактування різних типів даних у межах єдиного аналітичного середовища.

Таблиця 5.1.

Основні типи даних та приклади їх представлення у мультимодальному середовищі

Тип даних	Опис	Приклад
Числові дані	Цифрові значення, які представляють числа	10, 3.14, -7
Категорійні	Категорії або групи без внутрішнього порядку	Червоний, синій, зелений
Різнотипові	Різні типи даних в одному наборі	Ім'я (текст), вік (число), статус (логічний)
Мультимодальні	Дані, що містять різні види інформації	Зображення, текстовий опис, аудіозапис
Консолідовані	Комбінація різних типів даних у структурі	Ім'я (текст), вік (число), адреса (текст), електронна пошта (текст)

Ця класифікація забезпечує основу для вибору відповідних математичних засобів обробки, таких як побудова векторних або тензорних представлень, вибір функцій подібності, а також визначення рівня важливості ознак під час класифікації. Зокрема, для кожного типу даних можуть застосовуватися різні метрики, що враховують природу та шкалу вимірювання відповідних ознак.

З метою забезпечення єдиної основи для подальшої інтеграції даних у багатовимірному просторі, необхідно застосовувати формалізовані методи виявлення структурної подібності між об'єктами різних модальностей. Важливим завданням мультимодального аналізу є саме виявлення подібності між об'єктами, представленими у різних формах: текстових описах, числових показниках, візуальних зображеннях чи біомедичних сигналах. Через гетерогенність таких даних постає потреба в уніфікованих підходах до оцінювання подібності, які враховують як структурну, так і семантичну складову кожної модальності.

У цьому контексті особливої актуальності набуває побудова спільного аналітичного простору, в межах якого можливо порівнювати об'єкти незалежно від їх джерела походження. Формалізація відстаней або ступенів схожості між об'єктами різної природи є основою для реалізації таких завдань, як класифікація, кластеризація, пошук аналогів чи побудова рекомендаційних систем.

Методи метричного аналізу, зокрема евклідова відстань, косинусна подібність, манхеттенська метрика та їх узагальнення на тензорні простори дозволяють кількісно оцінити відстані між елементами у багатовимірному просторі ознак. Застосування цих підходів забезпечує надійну математичну основу для подальшої побудови ефективних алгоритмів обробки мультимодальних медичних даних [284, 303].

Більше того, для виявлення подібностей у багатовимірних наборах даних доцільно використовувати комбінації різних модальностей. Наприклад, модальності тексту та зображень можуть спільно аналізуватись у випадках зображень із підписами або медичних знімків із клінічними описами. Також комбінації числових і текстових даних дозволяють підвищити точність

діагностичних висновків у складних випадках. У таких наборах даних можуть одночасно використовуватись числові значення (розміри, часові мітки), категоріальні ознаки (класифікаційні мітки), текстові описи, аудіо та відео.

Кількість вимірів у такому багатовимірному представленні визначається кількістю залучених модальностей, а також глибиною кожної з них. Наприклад, числові та текстові модальності матимуть різні простори ознак, але при об'єднанні вони формують спільне багатовимірне представлення, придатне для обчислювального аналізу [284, 303].

Таким чином, запропонований мультимодальний підхід є ефективною технологією для виявлення подібностей у багатовимірних наборах даних та полягає у здатності відображати різні аспекти одного об'єкта через призму різнорідних джерел інформації. У результаті створюється аналітична модель, яка розглядає об'єкт як комплексну структуру, дозволяючи виявляти глибинні залежності та взаємозв'язки, що залишаються невидимими у межах однієї модальності. Це відкриває нові перспективи для побудови інтелектуальних медичних систем підтримки рішень, які працюють із широким спектром гетерогенних даних.

Тому, на підставі розроблених у Розділі 4 моделей репрезентації, злиття та багатокритеріального покращення мультимодальних медичних даних, наступним кроком є емпірична перевірка їх ефективності на конкретному прикладі. З цією метою було сформовано мультимодальний медичний набір даних (Додаток В), який включає фізіологічні, нейрофізіологічні, структурно-візуальні та клінічні характеристики пацієнтів.

Реалізація авторської методики на зазначеному наборі даних дозволяє:

- оцінити здатність канонічного дискримінантного аналізу ефективно об'єднувати ознаки з різних джерел та забезпечувати розділення класів;
- виявити структуровані патерни у формі концептів із застосуванням багатовимірного формального аналізу;

- перевірити, наскільки запропоновані метрики якості та багатокритеріальна оптимізація дозволяють отримати інтерпретовані і стійкі до шуму рішення.

Таким чином, нижче подано практичну реалізацію поетапної методики, яка демонструє її дієвість у задачах класифікації та інтерпретації стану пацієнтів на основі гетерогенних даних.

Для забезпечення ефективного математичного опрацювання такого типу інформації необхідно формалізувати структуру подання мультимодальних даних. Це дає змогу системно підходити до задач класифікації, аналізу подібності, виявлення патернів і побудови прогностичних моделей.

Формальне представлення мультимодальних даних описується як сукупність різнорідних (гетерогенних) модальностей $M = \{M_1, M_2, \dots, M_n\}$, де кожна модальність M_i являє собою окремий тип даних. Кожен об'єкт у мультимодальному наборі даних представлений як вектор x , що складається з кількох компонентів, кожен із яких відповідає одній з модальностей. Отож, $X = \{x_1, x_2, \dots, x_N\}$ – це набір мультимодальних об'єктів, а $M_i(x_j)$ – це проєкція об'єкта x_j на модальність M_i , тобто дані з цієї модальності для конкретного об'єкта x_j [278, 279].

Відповідно, мультимодальний об'єкт записується як сукупність його модальностей, що є основою для математичної інтерпретації їхньої взаємодії у межах єдиного інформаційного простору.

$$x_j = (M_1(x_j), M_2(x_j), \dots, M_n(x_j)). \quad (5.1)$$

Особливістю розробленого підходу є представлення методології проєкції кожного об'єкта на відповідні модальності. Це дозволяє структурувати дані та забезпечувати їх уніфіковане опрацювання. Подана формалізація забезпечує інтегроване подання мультимодальної інформації, що є основою для розробки інноваційних аналітичних методів у рамках запропонованої інформаційної технології.

Якщо розглянути мультимодальний набір даних, який включає три модальності: текстові описи, зображення та аудіозаписи, то кожен об'єкт у цьому наборі можна подати наступним чином:

- $M_1(x_j)$ – це числові характеристики;
- $M_2(x_j)$ – це вектор ознак зображення;
- $M_3(x_j)$ – це аудіофайли або їхні відповідні векторні ознаки.

Отже, мультимодальний набір даних можна описати через сукупність різних модальностей, які разом складають повну інформацію про певний об'єкт.

Наведене в (5.1) формальне представлення передбачає вирішення проблеми просторової невідповідності між даними різних модальностей, а також пошуку загальних закономірностей між ними. Тому, для аналізу різнорідних даних вперше вводиться функція спільного простору ознак або відповідних перетворень для кожної модальності. Адже завданням даного дослідження є створення загального простору для всіх модальностей та побудова моделей, які можуть навчатися на різних типах даних одночасно. Етапи побудови таких моделей визначаються як послідовність чотирьох кроків [232, 234]:

1. Представлення кожної модальності як об'єкта x_j , що визначаються ознаками:

$$x_j = (M_1(x_j), M_2(x_j), \dots, M_n(x_j)). \quad (5.2)$$

2. Узгодження та перетворення. Для аналізу гетерогенних даних необхідно забезпечити узгоджене представлення даних у різних модальностях. Це досягається через:

- Проекцію в спільний простір, де функції $\Phi_1, \Phi_2, \dots, \Phi_n$ – це перетворення для кожної модальності, які проєктують дані у спільний простір ознак Z :

$$z_j = (\Phi_1(M_1(x_j)), \Phi_2(M_2(x_j)), \dots, \Phi_n(M_n(x_j))), \quad (5.3)$$

де z_j – це спільне представлення для об'єкта x_j в загальному просторі Z .

- Метричне навчання, яке для вимірювання подібності між об'єктами в різних модальностях використовує функцію подібності $d(M_i(x_j), M_k(x_l))$, яка вимірює відстань або подібність між двома об'єктами в різних модальностях M_i та M_k . Це дозволяє порівнювати об'єкти, представлені у різних модальностях.

3. Інтеграція для спільного аналізу, завданням якого є побудова моделі, яка інтегрує інформацію з різних модальностей. Її формалізують через функцію втрат L , що враховує інформацію з усіх модальностей:

$$L = \sum_{i=1}^n \alpha_i L_i(M_i(x), y), \quad (5.4)$$

де L_i – функція втрат для кожної модальності M_i , y – істинна мітка або ціль для об'єкта x , а α_i – вагові коефіцієнти, що визначають важливість кожної модальності.

4. Останнім етапом є побудова моделі.

Після узгодження та інтеграції модальностей будується класифікаційна модель:

$$f(x_j) = f\left(\Phi_1\left(M_1(x_j)\right), \Phi_2\left(M_2(x_j)\right), \dots, \Phi_n\left(M_n(x_j)\right)\right), \quad (5.5)$$

де $f(x_j)$ – це прогноз для об'єкта x_j , який враховує всі модальності.

Така технологія дозволяє ефективно об'єднувати дані різних типів, зменшуючи просторову невідповідність та виявляти приховані взаємозв'язки між різними джерелами інформації.

У межах запропонованої методики було реалізовано повний цикл аналізу гетерогенних медичних даних для задачі класифікації пацієнтів за наявністю в анамнезі інсульту (ознака `Stroke_history`, Додаток В).

На етапі формалізації мультимодального представлення основним завданням є побудова єдиного математичного простору ознак за принципом інтеграції мультимодальних ознак (Feature-level fusion), який дозволяє спільно аналізувати гетерогенні (різнорідні за природою) медичні дані, отримані з кількох джерел, зокрема: сигнальних, структурних, клінічних.

Кожен об'єкт (пацієнт) описується множиною векторів $X_i \in R^d$, де i – номер модальності. Було реалізовано узгодження ознак через стандартизацію та кодування категоріальних змінних, а також формування уніфікованого простору:

$$X = [X_{EKG}, X_{EEG}, X_{MRI}, X_{clinical}].$$

Нехай кожен пацієнт описується множиною векторів:

$$X_i \in R^{d_i}, i = 1, 2, \dots, M.$$

де:

- X_i – вектор ознак для i -ї модальності,
- d_i – кількість ознак у відповідній модальності,
- M – загальна кількість модальностей.

Для цього випадку $M=4$, модальності мають наступну структуру:

№	Модальність	Позначення	Ознаки
1	ЕКГ	X_{EKG}	QT_interval, HRV, QRS_duration, P_interval, ST_depression
2	ЕКГ	X_{EEG}	Theta_alpha_index, Frontal_coherence, Alpha_power, Beta_power
3	MPT	X_{MRI}	GM_WM_contrast, Hypointense_volume, Parietal_LBP, Lateral_ventricle_shape
4	Клінічні дані	$X_{clinical}$	Age, Sex, Diabetes, Hypertension, BMI, Smoking

Для забезпечення можливості математичного злиття ознак із різних модальностей були проведені наступні перетворення:

- Нормалізація/стандартизація:
 - Для кількісних ознак застосовано Z-нормалізацію: $X_{norm} = \frac{X-\mu}{\sigma}$, де μ – середнє значення по вибірці, σ – стандартне відхилення.
- Кодування категоріальних змінних:
 - Змінна Sex кодувалася як 0 (Female), 1 (Male).
 - Змінні Smoking, Diabetes, Hypertension – як бінарні індикатори.
- Обробка пропущених значень:
 - Застосовано заповнення за допомогою медіани (для кожної ознаки в межах класу).

Зазначені етапи попередньої обробки дозволили забезпечити узгодженість масштабів та форматів даних, що є критично важливим для подальшого об'єднання ознак із різних модальностей у єдиний простір ознак.

Нормалізація кількісних змінних шляхом Z-стандартизації дозволила усунути вплив різних одиниць виміру та варіацій у масштабі між ознаками (наприклад, між QT_interval у мілісекундах та Spectral_entropy у безрозмірних одиницях).

На основі наведених середніх значень та стандартних відхилень для 20 мультимодальних ознак (Додаток В) можна зробити кілька аналітичних висновків щодо стабільності, варіативності та інформативності даних (Табл. 5.2).

Таблиця 5.2

Загальна аналітика: середнє та стандартне відхилення мультимодального набору даних

Ознака	Середнє (μ)	Ст. відхилення (σ)	Коефіцієнт варіації ($CV = \frac{\sigma}{\mu} 100\%$)	Інтерпретація варіацій
QT_interval	400,58	29,36	7,3	Низька варіативність
RR_interval	807,08	99,70	12,4	Помірна варіативність
QRS_duration	100,06	9,83	9,8	Низька варіативність
P_interval	109,72	15,40	14,0	Помірна варіативність
ST_depression	0,10	0,05	50,0	Висока варіативність
HRV	49,07	20,14	41,0	Висока варіативність
Alpha_power	9,94	2,05	20,6	Помірна варіативність
Beta_power	8,04	2,08	25,9	Помірна варіативність
Peak_frequency	10,02	1,01	10,1	Низька варіативність
Spectral_entropy	0,80	0,10	12,5	Помірна варіативність
Theta_alpha_index	1,19	0,29	24,4	Помірна варіативність
Frontal_coherence	0,60	0,10	16,7	Помірна варіативність
Hypointense_volume	1,99	0,82	41,2	Висока варіативність
GM_texture_entropy	0,50	0,10	20,0	Помірна варіативність
GM_WM_contrast	1,81	0,30	16,6	Помірна варіативність
Periventricular_intensity	1,20	0,20	16,7	Помірна варіативність
Parietal_LBP	0,30	0,05	16,7	Помірна варіативність
Lateral_ventricle_shape	0,70	0,10	14,3	Помірна варіативність
Age	67,21	13,08	19,5	Помірна варіативність
BMI	27,09	4,01	14,8	Помірна варіативність

На основі статистичних характеристик ознак (середніх значень і стандартних відхилень) проведено аналіз варіативності параметрів. Для цього

обчислено коефіцієнт варіації (CV), що дозволив класифікувати ознаки за ступенем стабільності (Рис. 5.1):

- Ознаки з низькою варіативністю ($CV < 10\%$) – такі як QT_interval, QRS_duration, Peak_frequency – свідчать про стабільну поведінку серед пацієнтів і можуть виступати як базові предиктори.
- Ознаки з високою варіативністю ($CV > 30\%$) – HRV, ST_depression, Hypointense_volume – мають потенціал бути дискримінативними, оскільки демонструють значне розсіювання між об'єктами, проте потребують уважного опрацювання через можливу чутливість до шуму.
- Більшість ознак мають помірну варіативність (10–25%), що є оптимальним для побудови моделей. Зокрема, Age, BMI, Theta_alpha_index, Frontal_coherence поєднують у собі стабільність та інформативність.




Рис. 5.1. Діаграма коефіцієнтів варіації (CV) для кожної ознаки сформованого мультимодального набору даних

Таким чином, попередня стандартизація ознак не лише забезпечує коректне функціонування моделей машинного навчання та статистичного

аналізу, але й дозволяє провести попередній аналіз стабільності та впливу кожної ознаки на загальний мультимодальний профіль пацієнта.

При формуванні канонічних функцій (CDA) або виборі концептів (CAD) слід враховувати коефіцієнт варіації (CV) для вагового врахування внеску ознак. Ознаки з високим CV можуть домінувати при Z-нормалізації, тому доцільно або обмежити їх вплив (регуляризація), або використовувати вагові коефіцієнти. Також ST_depression або HRV можуть бути біомаркерами ризику через високу індивідуальну варіативність. Комбінування ознак із різною варіативністю в CDA або CAD дозволяє ефективно збалансувати стабільні та чутливі характеристики, що підвищує як надійність, так і інформативність моделі.

Кодування категоріальних змінних – це процес перетворення номінативних (текстових) або категоріальних ознак у числовий формат, що дозволяє використовувати їх у математичних та машинних моделях. Для медичних змінних, таких як Sex, Smoking, Diabetes, Hypertension, зазвичай застосовується бінарне (dummy) кодування, оскільки ці змінні мають лише два стани (0/1).

Для забезпечення математичної обробки категоріальні змінні були закодовані у числовий формат: змінна Sex – як 0 (Female) та 1 (Male); змінні Smoking, Diabetes, Hypertension – як бінарні індикатори (0 – ні, 1 – так). Це дозволило включити їх до єдиного простору ознак без порушення статистичної коректності та забезпечило сумісність з обраними алгоритмами аналізу. Такий тип кодування зберігає бінарну інтерпретацію ознаки та дозволяє використовувати їх в лінійних моделях, CDA, CNN.

Для заповнення пропущених значень застосовано медіанну імпутацію в межах класу, що забезпечує стабільність статистичних оцінок, враховує можливу гетерогенність розподілів між групами та мінімізує вплив викидів. Такий підхід особливо доречний у медичних задачах, де точність і сталість розподілів мають критичне значення для побудови достовірних моделей аналізу пацієнтів.

На підтвердження доцільності такого підходу було проведено перевірку на наявність викидів за правилом $1.5 \times \text{IQR}$, результати якої дозволили оцінити реальну варіативність ознак. Виявлено лише незначну кількість відхилень:

- ST_depression: 19 викидів (~1,9 % значень);
- Hypointense_volume: 1 викид (~0,1 %).

Інші ознаки не містять викидів, що свідчить про відносну стабільність і коректність більшості ознак.




Рис. 5.2. Діаграми boxplot ознак ST_depression та Hypointense_volume мультимодального набору даних

Продовжуючи аналіз, доцільно оцінити потенційний вплив виявлених викидів на подальші етапи моделювання, зокрема – побудову дискримінантних функцій та інших статистичних моделей. Навіть невелика кількість екстремальних значень, як у випадку зі ST_depression та Hypointense_volume, може мати непропорційно великий вплив на результати, особливо у високочутливих до розподілу методах, таких як канонічний дискримінантний аналіз (CDA).

З огляду на це зауважимо:

- Ознака ST_depression, яка виявила відносно більшу кількість викидів (1,9%), повинна розглядатись з обережністю. Її вплив доцільно або послабити через вагове зменшення при обчисленні канонічних функцій, або за потреби – трансформувати (наприклад, логарифмічно чи порогово).

- Ознака `Hypointense_volume` має одиничний викид, тому може бути залишена без додаткової обробки, однак варто перевірити цей випадок на рівні конкретного пацієнта (наприклад, чи не є це артефактом знімка).

Наведемо аналітичне обґрунтування, додаткової обробки ознаки `ST_depression` при наявності викидів. При канонічний дискримінантний аналіз (CDA) відбувається пошук лінійної комбінації ознак: $Z = XW = w_1x_1 + w_2x_2 + \dots + w_px_p$, де x_j – нормалізовані значення ознак, а w_j – вагові коефіцієнти, що максимізують міжкласову дисперсію відносно внутрішньокласової: $\max_W \frac{W^T S_B W}{W^T S_W W}$.

При цьому екстремальні значення ознаки (викиди) суттєво впливають на S_W (матрицю внутрішньокласової коваріації), що може призвести до:

- переоцінки варіацій ознаки;
- нестабільного значення коефіцієнта w_j ;
- викривлення канонічних напрямків.

Варіанти пом'якшення впливу `ST_depression`:

- Вагове зменшення впливу (шкалювання ознаки). Для зниження впливу ознаки з високим коефіцієнтом варіації можна застосувати вагову регуляризацию: $x_j^{scaled} = \frac{x_j}{CV_j}$, де $CV_j = \frac{\sigma_j}{\mu_j}$ – коефіцієнт варіації ознаки.

Таким чином, якщо CV високий, ознака автоматично зменшує свій внесок.

- Логарифмічна трансформація. Для симетризації розподілу та зменшення впливу великих значень: $x_j^{transformed} = \log(x_j + \epsilon)$, $\epsilon > 0$. Це «стискає» верхній край розподілу, роблячи ознаку менш чутливою до викидів.
- Winsorization (обрізка викидів). Можна штучно обмежити верхній (або нижній) край значень ознаки до 95-го перцентилі: $x_j = \min(x_j, P95(x_j))$ або симетрично за IQR:

$$x_j^{wins} = \begin{cases} Q1 - 1,5 \cdot IQR, & \text{якщо } x_j < Q1 - 1,5 \cdot IQR \\ Q3 + 1,5 \cdot IQR, & \text{якщо } x_j > Q3 + 1,5 \cdot IQR \\ x_j, & \text{в інших випадках} \end{cases}$$

Оскільки ознака `ST_depression` має невелику кількість викидів (1,9%) та є біомедично важливою (ознака ішемії), проте вона має високий $CV = 50\%$, то

доцільно застосувати комбінацію: Z-нормалізація→Winsorization верхнього хвоста→перевірка стабільності ваг в CDA. На рисунку 5.3 показано, як змінився розподіл ST_depression після запропонованих трансформацій.




Рис. 5.3. Зміна розподілу ознаки ST_depression після застосування: Z-нормалізація→Winsorization верхнього хвоста→Логарифмічної трансформації

На графіках показано, що оригінальний розподіл (ST_depression) містить помітні викиди (правий хвіст значно витягнутий). Після Winsorization значення обрізані на верхній межі → правий хвіст зменшено. Розподіл став більш симетричним. Метод дозволяє зберегти ознаку у початковому масштабі, але з контрольованими екстремальними значеннями. За логарифмічно трансформованим підходом розподіл симетризувався за рахунок стиснення великих значень, застосовується, коли ознака має експоненційне зростання або велике зміщення вправо.

Обидва підходи (Winsorization і логарифмування) суттєво знижують вплив викидів, і їх доцільно застосовувати перед побудовою моделей CDA, особливо коли CV високий.

У таблиці 5.3 наведено вибір обробки ознак залежно від CV, за критеріями: наприклад, якщо $CV > 30\%$, то слід застосовувати логарифмічну трансформацію, для $15\% \leq CV \leq 30\%$ – Winsorization, а для $CV < 15\%$, то Z-нормалізацію.

Таблиця 5.3

Аналіз ознак мультимодального набору даних за CV

Ознака	CV (%)	Рекомендована обробка
QT_interval	7,33	Z-нормалізація
RR_interval	12,35	Z-нормалізація
QRS_duration	9,82	Z-нормалізація
P_interval	14,04	Z-нормалізація
ST_depression	50,85	Логарифмічна трансформація
HRV	41,04	Логарифмічна трансформація
Alpha_power	20,61	Winsorization
Beta_power	25,91	Winsorization
Peak_frequency	10,09	Z-нормалізація
Spectral_entropy	12,08	Z-нормалізація
Theta_alpha_index	24,49	Winsorization
Frontal_coherence	16,94	Winsorization
Hypointense_volume	41,01	Логарифмічна трансформація
GM_texture_entropy	19,73	Winsorization
GM_WM_contrast	16,65	Winsorization
Periventricular_intensity	16,54	Winsorization
Parietal_LBP	16,65	Winsorization
Lateral_ventricle_shape	14,54	Z-нормалізація
Age	19,46	Winsorization
BMI	14,80	Z-нормалізація

Після приведення всіх ознак до уніфікованого числового масштабу та усунення можливих впливів варіативності шляхом трансформацій, наступним критично важливим етапом стала обробка пропущених значень. У медичних даних пропуски можуть бути зумовлені як технічними обмеженнями (наприклад, відсутність результатів МРТ), так і клінічними причинами (непоказання до певних обстежень).

Для забезпечення цілісності вибірки та коректності подальшого аналізу було застосовано медіанну імпутацію в межах кожного класу. Формально, для кожної ознаки x_j , пропущені значення x_{ij} у класі $y_i = k$ замінювалися на медіану $\tilde{x}_j^{(k)}$, обчислену серед пацієнтів цього ж класу без пропусків. Це дозволяє зберегти характерну структуру даних у межах кожного класу та знизити вплив потенційних викидів: $x_{ij} := \text{median}(\{x_{ij} \mid x_{ij} \neq \text{NaN}, y_i = k\})$.

У таблиці 5.4 наведено порівняння середніх та медіанних значень по всіх ознаках, впорядкованих за відносною різницею (%) між ними.

Таблиця 5.4

Порівняння середніх та медіанних значень за ознаками
мультимодального набору даних

№	Ознака	Середнє (μ)	Медіана ($\tilde{x}$)	Абсолютна різниця	Відносна різниця (%)
1	ST_depression	0,0975	0,0991	0,0016	1,591
2	BMI	27,0920	26,9000	0,1920	0,709
3	Periventricular_intensity	1,1992	1,1923	0,0069	0,579
4	Alpha_power	9,9437	9,8905	0,0532	0,535
5	Theta_alpha_index	1,1880	1,1831	0,0049	0,414
6	Beta_power	8,0384	8,0100	0,0285	0,354
7	Frontal_coherence	0,5989	0,5968	0,0021	0,352
8	Parietal_LBP	0,3016	0,3026	0,0010	0,317
9	Age	67,2080	67,0000	0,2080	0,309
10	GM_WM_contrast	1,8096	1,8151	0,0055	0,302
11	Lateral_ventricle_shape	0,6961	0,6942	0,0019	0,269
12	P_interval	109,7192	110,0028	0,2836	0,258
13	Spectral_entropy	0,7988	0,8004	0,0016	0,205
14	HRV	49,0652	49,1435	0,0782	0,159
15	RR_interval	807,0836	806,3077	0,7759	0,096
16	QRS_duration	100,0583	99,9975	0,0609	0,061
17	GM_texture_entropy	0,5030	0,5033	0,0003	0,057
18	QT_interval	400,5800	400,7590	0,1791	0,045
19	Hypointense_volume	1,9942	1,9949	0,0006	0,032
20	Peak_frequency	10,0183	10,0191	0,0008	0,008

На підставі наведених статистичних характеристик (середнє та медіана) для 20 ознак мультимодального медичного профілю можна зробити наступні висновки (Табл. 5.4): для більшості ознак середнє та медіана практично збігаються або відрізняються незначно (у межах 0,5%). Це свідчить про те, що розподіли є симетричними або близькими до нормальних, без суттєвого перекосу. Такі ознаки, як: QT_interval, RR_interval, QRS_duration, P_interval, HRV, Alpha_power, Beta_power, Peak_frequency, Spectral_entropy, Theta_alpha_index, Frontal_coherence, Hypointense_volume, GM_texture_entropy, GM_WM_contrast, Age, BMI – мають стабільну центральну тенденцію, що дозволяє використовувати як середні, так і медіанні оцінки для подальших статистичних аналізів в CDA.

Ознака ST_depression має незначну різницю між середнім (0,0975) і медіаною (0,0991). Хоч ця різниця мала, вона може сигналізувати про невеликий

лівосторонній перекиї розподілу або наявність поодиноких занижених значень (викидів).

Це узгоджується з попереднім виявленням викидів у цій ознаці (19 випадків $\approx 1,9\%$), тож її вплив у моделях аналізу слід обмежити через логарифмічну трансформацію.

Оскільки ознаки охоплюють різні модальності, можна зробити висновок, що попередня обробка даних була успішною, і всі модальності гармонізовані для подальшої інтеграції в уніфікований простір ознак.

Об'єднання трансформованих даних із різних модальностей дозволить перейти до формалізації мультимодального представлення, в якому кожен пацієнт описується уніфікованим вектором характеристик. Це, у свою чергу, стало основою для побудови канонічних дискримінант (CDA), вибору релевантних концептів (CAD), а також ефективної класифікації стану пацієнтів з урахуванням складної структурної неоднорідності медичних даних.

5.2. Методи інтеграції модальностей та побудова уніфікованого простору ознак мультимодальних медичних даних

Важливим аспектом створення ефективної інформаційної технології для аналізу мультимодальних медичних даних є побудова уніфікованої системи представлення, що забезпечує спільну обробку числових, сигнальних, візуальних і клінічних джерел. Кожна модальність має власні властивості, тому інтеграція в спільний простір потребує формального узгодження.

Уніфіковане мультимодальне представлення пацієнтів: кожен рядок описує одного пацієнта, а стовпці включають ознаки з різних джерел:

Структура представлення:

- ЕКГ-модальність: QT_interval, RR_interval, QRS_duration, P_interval, ST_depression, HRV
- ЕЕГ-модальність: Alpha_power, Beta_power, Peak_frequency, Spectral_entropy, Theta_alpha_index, Frontal_coherence

- MPT: Hypointense_volume, GM_texture_entropy, GM_WM_contrast, Periventricular_intensity, Parietal_LBP, Lateral_ventricle_shape
- Клінічні ознаки: Age, Sex, BMI, Diabetes, Hypertension, Smoking, Stroke_history

Нехай кожен пацієнт i представлений мультимодальним вектором ознак:

$$x^{(i)} = \left[\begin{array}{c} x_1^{(i)}, \dots, x_6^{(i)}, x_7^{(i)}, \dots, x_{12}^{(i)}, x_{13}^{(i)}, \dots, x_{18}^{(i)}, x_{19}^{(i)}, \dots, x_{25}^{(i)} \\ \text{ЕКГ} \qquad \qquad \text{ЕЕГ} \qquad \qquad \text{МРТ} \qquad \text{Клінічні дані} \end{array} \right] \in R^{25}, \text{ де нормований}$$

вектор ознак першого пацієнта має вигляд:

$$x^1 = [0,48, 1,34, -0,69, -1,86, -0,85, -0,38, -1,03, 0,75, -0,05, 0,79, -0,64, -1,13, -0,13, 0,85, -0,39, 0,36, 0,21, 0,40, -0,15, 1, 0, 0, 0, -0,37, 1]$$

Це дозволяє задати мультимодальний простір ознак як прямий добуток підпросторів: $X = R_{\text{ЕКГ}}^6 \times R_{\text{ЕЕГ}}^6 \times R_{\text{МРТ}}^6 \times R_{\text{Клінічні дані}}^7$.

де:

- кожен блок має відповідну фізіологічну/клінічну інтерпретацію,
- дані є кількісними, нормалізованими для подальшого аналізу.

Уніфіковане представлення за принципом інтеграції модальних моделей (Model-level fusion) описується вектором з 25 кількісних нормалізованих ознак, що формалізується як: $\tilde{x}_j \in R^{25}, j = 1, \dots, N$, де: $\tilde{x}_j$ – уніфікований вектор ознак для j -го пацієнта, N – кількість пацієнтів у вибірці.

Уніфіковане представлення пацієнта 25 нормалізованими ознаками, згрупованих за модальностями дозволяє моделі обробляти всі джерела інформації в єдиному векторному просторі, забезпечуючи структурну інтеграцію та основу для подальшого аналізу: класифікації, виявлення концептів, CDA.

Метою є побудова моделі двокласової класифікації, яка за вектором ознак $x^{(i)} \in X$ прогнозує мітку класу $y^{(i)} \in \{0,1\}$, що відповідає наявності або відсутності інсульту в анамнезі: $f: X \rightarrow \{0,1\}$, де $X = R^{25}$.

Цільова змінна:

- Stroke_history = 1 – у пацієнта був діагностований інсульт;
- Stroke_history = 0 – інсульту не було.

Після формування уніфікованого вектора ознак було застосовано канонічний дискримінантний аналіз (CDA) – статистичний метод, що дозволяє

зменшити розмірність багатовимірних медичних даних, зберігаючи при цьому максимальну міжкласову варіацію. У задачі багатокласової класифікації (наприклад, класифікація стану пацієнтів на $n \geq 3$ груп) було застосовано канонічний дискримінантний аналіз (CDA) з метою зменшення розмірності та побудови лінійного підпростору, в якому класи є максимально відокремленими.

У нормалізованому наборі:

- Кількість класів: $n = 2$ (тобто наявність / відсутність інсульту),
- Кількість ознак: $m = 24$,
- Кількість канонічних компонент (за CDA): $k = \min(n - 1, m) = \min(1, 24) = 1$

Отже, канонічний дискримінантний аналіз (CDA) формально зводиться до пошуку одного вектора $w \in R^{24}$, який максимізує: $J(w) = \frac{w^T S_B w}{w^T S_W w}$,

де:

- S_B – міжкласова матриця дисперсії, яка характеризує віддаленість центрів класів;
- S_W – внутрішньокласова матриця дисперсії, яка характеризує розсіювання всередині кожного класу;
- w – канонічний вектор, що задає напрям проєкції для найкращого розділення класів у просторі ознак.

Проекція відбувається наступним чином: кожен пацієнт $x^{(i)} \in R^{24}$ проєктується на вісь w : $z^{(i)} = w^T x^{(i)}$. Отримані скалярні значення $z^{(i)} \in R$ – це координати в новій 1D-площині. Побудова гістограми за цими значеннями показує, наскільки реально CDA розділяє групи (Рис. 5.4).




Рис. 5.4. Розподіл пацієнтів за першою канонічною компонентою CDA

На рисунку 5.4 кожен пацієнт спроектований на лінійний простір, що максимально відокремлює класи $\text{Stroke\_history} = 0$ та 1 . Помітно, що компонента частково розділяє ці дві групи – центри зміщені, але є значне перекриття.

На рисунку 5.5 наведено канонічний вектор w , де показано вагові коефіцієнти для кожної ознаки, які визначають її внесок у побудову дискримінантної осі (CDA).




Рис. 5.5. Вплив ознак на канонічну компоненту CDA ($|w|$)

З аналізу ваг w_i видно, що найсильніша модальність – ЕЕГ (електроенцефалографія), адже її ознаки відображають функціональні порушення в мозку, що супроводжують інсульт:

- Alpha_power (коеф. $\approx +0,085$): вища потужність α -ритму асоціюється з наявністю інсульту.
- Theta_alpha_index (коеф. $\approx -0,065$): зменшує дискримінант, тобто ознака характерна для неінсультної групи.
- Frontal_coherence: відносно важлива, показує когерентність у фронтальних ділянках мозку.

Найпозитивніше сприяють класифікації наступні ознаки:

Ознака	w_i
Alpha_power (EEG)	+0.085
Hypertension (клінічні дані)	+0.085
Periventricular_intensity (MPT)	+0.064
BMI (клінічні дані)	+0.057
Lateral_ventricle_shape (MPT)	+0.038

Зменшують проєкцію наступні ознаки:

Ознака	w_i
Sex (клінічні дані)	-0.163
P_interval (ЕКГ)	-0.122
Theta_alpha_index (EEG)	-0.065
HRV (ЕКГ)	-0.062
GM_WM_contrast (MPT)	-0.057

Модальність MPT дозволяє зафіксувати морфологічні маркери пошкодження мозку, важливі для класифікації:

- Periventricular_intensity (коеф. $\approx +0,064$): підвищена інтенсивність навколо шлуночків часто пов'язана з ішемічними змінами.
- Lateral_ventricle_shape (коеф. $\approx +0,038$): форма шлуночків може свідчити про атрофію або ішемічні ураження.
- GM_WM_contrast (коеф. $\approx -0,057$): зниження контрасту між сірою і білою речовиною – характерна ознака патології.

Клінічні дані є критично важливими і підсилюють мультимодальну модель:

- Hypertension (коеф. $\approx +0,085$): артеріальна гіпертензія – один із найсильніших факторів ризику інсульту.
- BMI (коеф. $\approx +0,057$): підвищена маса тіла часто пов'язана з гіпертензією та атеросклерозом.

- Sex (коэф. $\approx -0,163$): негативне значення вказує, що одна зі статей (ймовірно, жінки) частіше трапляються серед пацієнтів без інсульту в цій вибірці.

ЕКГ ознаки відіграють допоміжну роль, але зберігають значення:

- P_interval (коэф. $\approx -0,122$): довший інтервал P асоціюється з неінсультними пацієнтами в цьому наборі.
- HRV (коэф. $\approx -0,062$): знижена варіабельність ЧСС притаманна станам стресу або пошкодження ВНС, проте тут вона більше характерна для групи без інсульту.

Проведений канонічний дискримінантний аналіз підтвердив ефективність об'єднання різних типів медичних ознак у межах єдиного мультимодального простору. Аналіз ваг канонічної компоненти засвідчив, що жодна окрема модальність (наприклад, лише ЕЕГ або лише клінічні дані) не є домінуючою. Навпаки, найбільш значущі ознаки належать до різних джерел інформації – електрофізіологічних, структурних та клінічних.

Це свідчить про те, що структурні характеристики мозку (МРТ), функціональні показники (ЕЕГ) та клінічні фактори (анамнез, вік, гіпертензія тощо) разом забезпечують комплексне відображення стану пацієнта. Їх поєднання формує найбільш інформативну дискримінантну базу, яка дозволяє краще відокремлювати групи пацієнтів із наявністю або відсутністю інсульту в анамнезі.

Крім того, отримані вагові коефіцієнти (вектор w) дозволяють інтерпретувати вплив кожної ознаки: з'ясувати, які характеристики найбільше сприяють належності до певної групи. Це, у свою чергу, підвищує прозорість та клінічну інтерпретованість моделі, що особливо важливо для застосування у сфері підтримки медичних рішень.

У завданні мультимодального аналізу пацієнтів метою є побудова єдиної класифікаційної моделі, яка об'єднує інформацію з кількох джерел (модальностей): $M_1^{(x)}, M_2^{(x)}, \dots, M_n^{(x)}$ – ознаки, отримані з різних модальностей. Оскільки кожна модальність має різну інформативність, доцільно модифікувати

функцію втрат, щоб вона узгоджено враховувала якість передбачення по кожному джерелу (формула 5.4).

Якщо модальність M_i є надійною і важливою, то α_i буде вищим. Якщо модальність містить шум або пропуски, її вклад у загальну помилку можна зменшити або виключити (якщо $\alpha_i = 0$). Форма L дозволяє моделі гнучко комбінувати знання з різних джерел, не змушуючи модель обирати лише одну модальність.

Усі модальності мають майже однакову вагу, отже, всі інформативні приблизно однаково $\alpha_{\text{ЕКГ}} = 0,2510$, $\alpha_{\text{ЕЕГ}} = 0,2487$, $\alpha_{\text{МРТ}} = 0,2495$, $\alpha_{\text{клінічні дані}} = 0,2509$.

Наступним кроком обчислювались індивідуальні втрати (log loss) для кожної модальності у вашому наборі, цільова змінна: Stroke_history (0 або 1).

Дані поділено на 70 % тренувальні, 30 % тестові. Стратифікація зберігає пропорцію класів у кожній підвибірці. Для кожної модальності будувалась своя модель, яка прогнозує ймовірність належності до класу 1 (інсульт).

$$P(y = 1 | x) = \sigma(z) = \frac{1}{1+e^{-z}}, \text{ де } z = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n, \quad (5.6)$$

де:

- $x = (x_1, x_2, \dots, x_n)$ – вектор ознак пацієнта,
- w_0 – вільний член (зсув, bias),
- w_i – ваговий коефіцієнт для ознаки x_i ,
- $\sigma(z)$ – сигмоїдна функція активації,
- z – лінійна комбінація ознак.

Для тестової вибірки обчислимо середню log loss (Табл 5.5) за формулою:

$$\text{LogLoss} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)].$$

Наступним кроком є розрахунок інтегрованої втрати L у мультимодальному аналізі:

$$L = 0,2510 \cdot 0,6955 + 0,2487 \cdot 0,7020 + 0,2495 \cdot 0,6998 + 0,2509 \cdot 0,6959 = 0,6983.$$

Таблиця 5.5

Результати розрахунку log loss на тестувальному наборі даних

Модальність	Ознаки	Значення log loss
ЕКГ	6 ознак	0,6955
ЕЕГ	6 ознак	0,7020
МРТ	6 ознак	0,6998
Клінічні дані	6 ознак	0,6959

Інтегрована втрата $L \approx 0,6983$ підтверджує ефективність використання мультимодального підходу для класифікації клінічного стану пацієнтів. Обчислені ваги α_i , що визначають внесок кожної модальності, виявилися майже рівними, оскільки логарифмічні втрати для ЕКГ, ЕЕГ, МРТ та клінічних даних знаходяться в однаковому діапазоні. Це свідчить про те, що жодна модальність не є домінуючою, і всі вони містять комплементарну діагностичну інформацію.

Таким чином, запропонована формалізація функції втрат забезпечує гнучку інтеграцію ознак з різних джерел, дозволяючи побудувати збалансовану модель без перекосів на користь однієї модальності. Це критично важливо для роботи з гетерогенними медичними даними, де кожен тип сигналу може нести унікальні ознаки патології.

Після нормалізації, гармонізації та формування уніфікованого простору ознак, здійснюється побудова класифікаційної моделі, яка поєднує інформацію з кількох незалежних медичних модальностей. На рисунку 5.6 наведено схему побудови моделі за принципом інтеграції модальних моделей (Model-level fusion). Кожна з модальностей розглядається як окремий підпростір ознак, де на першому підетапі кожен блок ознак обробляється окремо за допомогою функцій трансформації Φ_i . Далі всі трансформовані підпростори об'єднуються у єдиний уніфікований вектор ознак $\tilde{x}$ який слугує основою для побудови прогностичної моделі.

На другому підетапі до об'єднаного вектора ознак застосовується модель класифікації $f(\tilde{x})$, яка повертає ймовірність належності об'єкта до класу $y = 1$. Після порогового прийняття рішення, отримується класифікаційний прогноз.




Рис. 5.6. Схема побудови моделі класифікації пізнього злиття

Принцип інтеграції мультимодальних ознак (Feature-level fusion) у мультимодальному аналізі будується на ідеї поєднання всіх ознак з різних модальностей на самому початку, щоб утворити єдиний простір ознак, з яким працює один класифікатор (Рис. 5.7).




Рис. 5.7. Схема побудови моделі класифікації раннього злиття

У межах побудови мультимодальної прогностичної моделі особливу увагу приділено формуванню уніфікованого простору ознак, який забезпечує можливість спільного аналізу даних з різних джерел. Для цього було реалізовано підхід раннього злиття (early fusion), за якого всі числові ознаки з різних модальностей об'єднуються в єдиний вектор ознак для кожного пацієнта.

На етапі злиття ознак (формування об'єднаного простору) поєднуються всі модальності в один простір ознак, який представляє кожного пацієнта у вигляді єдиного числового вектора. Формально, так як і в пізньому злитті, кожна модальність має набір ознак: ЕКГ $\rightarrow x^{(1)} \in R^6$, ЕЕГ $\rightarrow x^{(2)} \in R^6$, МРТ $\rightarrow x^{(3)} \in R^6$, Клінічні дані $\rightarrow x^{(4)} \in R^6$. Об'єднаний ознаковий простір: $X = R^6 \times R^6 \times R^6 \times R^6 = R^{24}$. Кожен пацієнт описується уніфікованим вектором: $\tilde{x}_i = [x_i^{(1)}, x_i^{(2)}, x_i^{(3)}, x_i^{(4)}] \in R^{24}$.

Наступним етапом є застосування CDA з цільовою змінною Stroke_history, що дозволило сформувати одновимірну канонічну компоненту, яка зберігає найбільш релевантну інформацію для розділення класів першому етапі.

Формальна побудова 1D-проекції у CDA представлена у вигляді матриці ознак $X \in R^{n \times m}$, де: n – кількість пацієнтів, m – кількість об'єднаних ознак. Є вектор міток: $y \in \{0,1\}^n$.

Канонічний дискримінантний аналіз (CDA) формально зводиться до пошуку одного вектора $w \in R^{24}$, який максимізує: $w = \arg \max \frac{w^T S_B w}{w^T S_W w}$,

де:

- S_B – міжкласова матриця дисперсії, яка характеризує віддаленість центрів класів;
- S_W – внутрішньокласова матриця дисперсії, яка характеризує розсіювання всередині кожного класу;
- w – канонічний вектор, що задає напрям проекції для найкращого розділення класів у просторі ознак.

Це приводить до задачі: $S_B w = \lambda S_W w$.

Проекція відбувається наступним чином: кожен пацієнт $x^{(i)} \in R^{24}$ проєктується на вісь w : $z^{(i)} = w^T x^{(i)}$. Всі $z^{(i)}$ формують нову 1D-ознаку, яка може бути використана як інтерпретована ознака для моделі та основа для візуалізації (Рис. 5.8).




Рис. 5.8. Розподіл пацієнтів за першою канонічною компонентою CDA

На гістограмі видно, що розподіли класів ("інсульт" / "без інсульту") накладаються один на одного. Відокремлення класів часткове, що вказує на помірну дискримінантну структуру.

Канонічний дискримінантний аналіз знаходить найкращу лінійну комбінацію ознак, що найкраще відокремлює класи. Ця комбінація визначається вектором ваг w , який застосовується до кожного вектора ознак $\tilde{x}_i$, щоб отримати скаляр: $x_i^{CDA} = w^T x_i$. В результаті, весь багатовимірний простір (R^{24}) проєктується на одну вісь – лінію, яка максимально розділяє пацієнтів з інсультом і без нього.

На практиці знайдено ваги (коефіцієнти) канонічної осі w , які показують, які ознаки, важливі для розділення класів (Табл. 5.6).

Таблиця 5.6

Ваги ознак у CDA-компоненті

№	Ознака	Вага w_i
1	Sex	-0,68004935086103
2	P interval	-0,5114200426300456
3	Alpha power	0,3550755503075123
4	Hypertension	0,35464319666297517
5	Theta alpha index	-0,27165305565000436
6	Periventricular intensity	0,2656062249796071

Продовження Табл. 5.6

№	Ознака	Вага w_i
7	HRV	-0,2584236143175017
8	BMI	0,23974291997400576
9	GM_WM_contrast	-0,23682337948769897
10	Hypointense volume	-0,17479597694026588
11	QRS_duration	-0,16297741295964965
12	Lateral ventricle shape	0,1605468733653435
13	Parietal_LBP	-0,14245843540247885
14	Diabetes	-0,13481867946015746
15	ST_depression	0,13114536329070858
16	Beta_power	-0,08902407191402371
17	GM_texture_entropy	0,08318631815251858
18	Frontal_coherence	-0,07733829270070036
19	Age	0,062203639038022125
20	Spectral_entropy	-0,0552610550322238
21	QT_interval	-0,02878510943238647
22	RR_interval	-0,021383406577536
23	Peak_frequency	0,01969451180062348
24	Smoking	-0,002704745872223857

Таблиця 5.6 містить вагові коефіцієнти w_i , які були обчислені в результаті канонічного дискримінантного аналізу (CDA) на уніфікованому векторі ознак. Кожне значення w_i показує вплив відповідної ознаки на дискримінантну функцію, яка максимізує міжкласову варіацію. Абсолютне значення $|w_i|$ відображає важливість ознаки: чим більше значення, тим сильніший вплив на розділення класів.

Ознака	Вага w_i	Абсолютне значення $ w_i $	Інтерпретація
Sex	-0,68	0,68	Стать – сильний дискримінатор
P_interval	-0,51	0,51	ЕКГ-показник – важливий фактор
Alpha_power	+0,36	0,36	ЕЕГ – підвищене значення корелює з інсультом
Hypertension	+0,35	0,35	Наявність гіпертензії – важливий фактор ризику
Theta_alpha_index	-0,27	0,27	Показник мозкової активності – зменшується при інсульті
Periventricular_intensity	+0,27	0,27	MRI-показник – збільшується при патології

Абсолютні ваги ознак $|w_i|$ мають сенс при ранньому злитті, адже вся модель бачить весь вектор ознак, сформований із усіх модальностей одночасно. Це дає змогу оцінити відносну важливість ознак різних джерел у єдиному просторі.

Тепер, коли маємо уніфікований вектор ознак $\tilde{x}_i \in R^{24}$, розуміємо вплив кожної ознаки (через ваги CDA), можемо перейти до моделювання. Усі ознаки подаються одночасно на вхід моделі early fusion, жодна модальність не обробляється окремо (Рис. 5.7).

На основі проаналізованих даних наведемо порівняльну таблицю 5.7 раннього (early) та пізнього (late) злиття у мультимодальному аналізі медичних даних.

Таблиця 5.7

Порівняльний аналіз раннього (early) та пізнього (late)
злиття мультимодальних даних

Ознака	Early Fusion	Late Fusion
Об'єднання модальностей	На етапі сирих або попередньо очищених ознак	Після окремого перетворення кожної модальності
Форма об'єднання	Конкатенація сирих ознак у єдиний вектор	Конкатенація перетворених ознак
Трансформація ознак	Після злиття (однакова для всіх)	Перед злиттям (індивідуально для кожної модальності)
Гнучкість до неоднорідних даних	Низька (всі модальності мають бути однорідними)	Висока (можна обробити модальності різними методами)
Інтерпретованість	Складна, всі ознаки одночасно	Вища, видно вплив кожної модальності окремо
Приклад формалізації	$x = [x_1^{(\text{ЕКГ})}, x_2^{(\text{ЕЕГ})}, x_3^{(\text{МРТ})}, x_4^{(\text{клінічні дані})}] \rightarrow f(x)$	$\tilde{x} = [\phi_1(M_1^{(\text{ЕКГ})}), \phi_2(M_2^{(\text{ЕЕГ})}), \phi_3(M_3^{(\text{МРТ})}), \phi_4(M_4^{(\text{клінічні дані})})] \rightarrow f(\tilde{x})$

Отож, мультимодальний підхід є ефективним інструментом аналізу багатовимірних даних, оскільки забезпечує комплексне представлення об'єктів із врахуванням структурної та функціональної неоднорідності джерел. Інтеграція кількох модальностей через раннє або пізнє злиття дозволяє виявляти приховані закономірності та підвищувати інформативність моделей.

Таким чином, результати, отримані в цьому підрозділі, підтверджують доцільність використання мультимодального аналізу для побудови інтелектуальних систем класифікації складних об'єктів, з урахуванням різних форм представлення даних.

5.3. Методи побудови уніфікованих просторів ознак для комплексного представлення мультимодальних медичних даних

У сучасних медичних дослідженнях дедалі частіше використовуються мультимодальні дані, які поєднують інформацію з різних джерел: електрокардіограми (ЕКГ), електроенцефалограми (ЕЕГ), магнітно-резонансної томографії (МРТ), клінічних показників, анамнезу пацієнта тощо. Кожна з модальностей має свою природу, масштаб, тип даних (безперервні, категоріальні, структуровані або неструктуровані) та розмірність.

Основною проблемою аналізу мультимодальних даних є гетерогенність:

- різні модальності мають нерівну кількість ознак,
- використовують різні шкали вимірювання (наприклад, мілісекунди в ЕКГ, вольти в ЕЕГ, інтенсивність зображення в МРТ),
- мають різні ступені впливу на результат.

Через це виникає неузгодженість простору ознак, що унеможливорює безпосереднє використання стандартних моделей машинного навчання без попередньої трансформації або інтеграції.

Метою є побудова уніфікованого простору ознак, у якому:

- кожна модальність буде адекватно представлена й узгоджена з іншими,
- збережеться інформативність ознак,
- буде забезпечено можливість інтерпретації,
- буде створена база для розробки єдиної ефективної прогностичної моделі.

Таким чином, формування такого простору є необхідною умовою для інтегрованого аналізу складних медичних даних, що дозволяє виявляти приховані зв'язки між модальностями, підвищувати точність класифікації та формувати обґрунтовані клінічні висновки.

У задачах машинного навчання простір ознак (feature space) – це n -вимірний простір, в якому кожен об'єкт представлений вектором значень ознак (характеристик, параметрів). Якщо об'єкт має m ознак, то він належить простору R^m .

Уніфікований простір ознак – це багатовимірний простір, у якому всі модальності поєднані в один цілісний опис об'єкта: $x = [x_{\text{ЕКГ}}, x_{\text{ЕЕГ}}, x_{\text{МРТ}}, x_{\text{Клініка}}] \in R^{25}$. Такий простір дозволяє працювати з гетерогенними даними як з єдиним вектором.

Основними проблемами побудови уніфікованого простору є:

1. Різні шкали ознак. Наприклад, вік вимірюється в роках (від 0 до 100), а ентропія – в межах [0, 1]. Без нормалізації модель буде надавати перевагу ознакам з більшим діапазоном.
2. Кореляція ознак, де ознаки з різних модальностей можуть бути мультиколінеарними, що призводить до надмірності інформації та погіршення узагальнення.
3. Пропущені значення ускладнює побудову простору без застосування імпутації.
4. Шум та артефакти особливо характерні для сигналів ЕЕГ та ЕКГ, які можуть спричинити викривлення векторів ознак.
5. Гетерогенність типів даних.

Щоб забезпечити ефективну побудову моделей у мультимодальному середовищі, простір ознак має відповідати таким критеріям:

Вимога	Пояснення
Повнота	Враховані всі ключові модальності та ознаки
Узгодженість	Значення узгоджені за шкалами, типами, значеннями
Масштабованість	Можна додати нові модальності без перебудови всього простору
Інтерпретованість	Можливість зрозуміти, які ознаки впливають на рішення моделі
Низька надмірність	Уникнення дублювання або тісно скорельованих ознак
Обробка пропущених значень	Передбачено стратегії для частково заповнених модальностей

Багатовимірні дані характеризуються наявністю великої кількості змінних або ознак, що використовуються для опису складних об'єктів чи процесів. У сучасних медичних інформаційних системах такі дані часто представлені в мультимодальному вигляді. Зі зростанням обсягів даних та їх складності постає необхідність у побудові уніфікованих ознакових просторів, які дозволяють ефективно інтегрувати інформацію з різнорідних модальностей.

У межах мультимодального аналізу виділяють два основних підходи до інтеграції ознак: раннє злиття (early fusion), коли всі ознаки з різних модальностей об'єднуються до побудови моделі, та пізнє злиття (late fusion), коли спочатку формуються локальні моделі для кожної модальності, результати яких далі інтегруються.

Побудова уніфікованого простору ознак є важливим кроком у реалізації підходу раннього злиття. Такий простір дозволяє забезпечити комплексне представлення пацієнта та застосувати до нього універсальні методи класифікації.

Разом з тим, побудова уніфікованого простору стикається з низкою типових викликів багатовимірного аналізу, зокрема:

- «прокляття розмірності» – збільшення кількості ознак може зменшити узагальнюючу здатність моделей;
- кореляція між ознаками – надмірна інформаційна надлишковість;
- наявність шумів і пропущених значень;
- складність інтерпретації результатів;
- висока обчислювальна складність при моделюванні.

Ці проблеми ілюструє рисунок 5.9, де набори даних часто включають численні змінні для опису складних явищ. Вони впливають на ефективність обчислень, продуктивність моделі та можливість її інтерпретації.




Рис. 5.9. Проблеми багатовимірного аналізу даних

Щоб забезпечити ефективне функціонування уніфікованого простору ознак, необхідно:

- застосовувати методи зменшення розмірності (CDA), які дозволяють виділити найбільш інформативні проєкції ознак;
- використовувати методи нормалізації та уніфікації шкал модальностей;
- формувати структуровану архітектуру об'єднання ознак, яка враховує природу та значущість кожної модальності;
- будувати моделі, що здатні обробляти складні залежності між ознаками та забезпечують високу точність при класифікації та прогнозуванні.

Таким чином, побудова уніфікованого простору ознак є не лише технічним етапом, а й ключовою методологічною основою для реалізації мультимодального аналізу в складних медичних системах. Детальну характеристику типових проблем багатовимірного аналізу представлено в таблиці (B1) додатку В.

Технології аналізу багатовимірних даних відкриває широкі можливості для дослідження складних інформаційних систем, проте потребують урахування зазначених вище численних проблем. Успішна робота з такими даними вимагає комбінування сучасних інформаційних технологій, зменшення розмірності, ефективної обробки даних та обчислювальних процесів [231, 316]. Розв'язання цих проблем є ключем до отримання точних, інформативних та персоналізованих рішень.

Одним із ключових рішень у структурному поданні таких складних даних є використання багатовимірної моделі (data cube), яка в контексті медичних ІТ-систем дозволяє інтегрувати різноманітні модальності в єдине представлення (Рис. 5.10 (а)).

Перевагою підходу є використання кубічної структури не лише як сховища, а й як аналітичного інструменту, що дає змогу здійснювати багаторівневу агрегацію, формувати зрізи (slice & dice) і проєкції даних та ефективно виявляти закономірності в просторі мультимодальних ознак. Даний підхід забезпечить системну інтеграцію даних, масштабованість та

інтерпретованість результатів, що є критично важливим для прийняття медичних рішень.

Куб даних – це багатовимірна структура, яка містить виміри, що описують ознаки даних, та метрики або показники, які є їх числовими значеннями на основі вимірів. В роботі запропоновано трактувати медичний мультимодальний набір даних як куб даних, у якому кожен вимір відповідає окремій модальності (наприклад, пацієнт – час – тип дослідження – модальність). Формально куб даних D має вигляд:

$$D: Dim_1 \times Dim_2 \times \dots \times Dim_n \rightarrow R, \quad (5.7)$$

де Dim_i – вимір, а R – простір числових метрик.




Рис. 5.10. (а) Куб мультимодальних даних;

(б) Екземпляр куба мультимодальних даних

Наприклад, якщо: Dim_1 – час (T), Dim_2 – пацієнти (P), Dim_3 – модальність даних (M), а значення $D(t, p, m)$ – це метрика, наприклад, точність діагнозу для пацієнта p , у момент часу t , за типом даних m .

Куб даних є базовою конструкцією логічного рівня для опису багатовимірної бази даних і служить основною одиницею їх введення та виведення для всіх операторів. Він визначається як кортеж $\langle D; M; A; f \rangle$, де чотири компоненти вказують на характеристики куба. Цими характеристиками є :

- Набір із n розмірів $D = \{d_1, d_2, \dots, d_n\}$, де d_i є назвою виміру, отриманого із домену $dom_{dim(i)}$.
- Набір із k заходів $M = \{m_1, m_2, \dots, m_k\}$, де m_i є назвою міри, отриманої із домену $dom_{measure(i)}$.
- Набір імен розмірів та імен мір $D \cap M = \emptyset$.
- Набір із t атрибутів $A = \{a_1, a_2, \dots, a_t\}$, де a_i – це ім'я атрибута, отримане з домену $dom_{attr(i)}$.
- Відображення один до багатьох $f: D \rightarrow A$, тобто існує відповідний кожному виміру набір атрибутів. Таке відображення наборів атрибутів, що належать вимірам та попарно не перетинаються, мають вигляд:
 $\forall i, j, i \neq j, f(d_i) \cap f(d_j) = \emptyset$.

Для пояснення наведених вище визначень слід розглянути багатовимірну медичну систему. Розглянемо багатовимірне представлення інформаційної системи, де $M = \{\text{стан пацієнта}\}$, $D = \{\text{Час, Пацієнти, Модальності}\}$ та $A = \{\text{день, місяць, рік, прізвище та ім'я пацієнта, гендер, тиск, симптоми, МРТ}\}$.

Кожен із вимірів описується певними атрибутами; для куба медичної системи багатовимірне відображення f подається таким чином:

$$\begin{aligned}
 f(\text{Час}) &= \{\text{рік, місяць, день}\}; \\
 f(\text{Пацієнти}) &= \{\text{Прізвище, ім'я, гендер}\}; \\
 f(\text{Модальності}) &= \{\text{тиск, симптоми, МРТ}\}.
 \end{aligned}
 \tag{5.8}$$

Слід зауважити, що ці три набори атрибутів, які показані вище на рисунку 5.10, не перетинаються. Для визначення конкретних параметрів по кожному атрибуту потрібно вказати значення різним мірам уздовж усіх вимірів. Заповнений куб називається його екземпляром. Можна представити куб, що визначається кортежем $\langle D, M, A, f, V, g \rangle$, де елементи D, M, A та f успадковують дані від батьківського куба, а V зберігає набір значень, які використовувались для його заповнення. Кожен елемент $v_i \in V$ є k -кортежем $\langle \mu_1, \mu_2, \dots, \mu_k \rangle$. Кожне μ_i є екземпляром i -ї міри. Відповідно, g представляє відображення

$g: dom_{dim(1)} \times dom_{dim(2)} \times \dots \times dom_{dim(n)} \rightarrow V$. Інтуїтивно, відображення g вказує на певні значення, які пов'язані з клітинками екземпляра куба. Два екземпляри куба, що відповідають одному кубу, відрізнятимуться лише в кортежі $\langle V, g \rangle$ [316].

Багатовимірний куб, наведений на рисунку 5.10(б), математично представлений через оператори.

Першим використовується оператор обмеження (σ), який встановлює межі значення одного або кількох вимірів. Нехай атомарний предикат p являється логічним виразом, що включає один вимір. Складений предикат P є виразом, який включає набір атомарних предикатів $\{p_1, p_2, \dots, p_l\}$, $l \geq 1$, що мають вигляд:

$$P = p_1 \langle op \rangle p_2 \langle op \rangle \dots \langle op \rangle p_l, \quad (5.9)$$

де $\langle op \rangle$ представляє логічний оператор (AND, OR).

Для обмеження оператора розроблена алгебра, що визначається наступним чином:

- Вхідні дані: куб $C_I = \langle D, M, A, f, V, g \rangle$ міра для агрегування m_i та набір атрибутів вимірювання групування S .
- Вихід: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O = D, M_O = M, f_O = f, V_O \subseteq V, g_O = g$, де кожен елемент $g_p^{-1}(V_p)$ задовольняє P .
- Математична нотація: $\sigma_p(C_I) = C_O$.

Наступним є оператор агрегації вимірів. Він оснований на реляційних агрегатних функціях (SUM, AVG, MAX) і дозволяє їх застосовувати до кубів з одним або кількома вимірами, вказаними як атрибути групування. Математично він представляється через агрегатну функцію h , що визначена на одній мірі m_i , та S як набір атрибутів виміру групування $\{a_1, a_2, \dots, a_g\}$, $S \subseteq A$. Відповідно, взаємне відображення визначене через $\delta: A \rightarrow D$, де δ представляє відображення атрибута a_i на назву виміру d_i . Отож, розроблена алгебра оператора агрегації представлена наступним чином [329]:

- Вхідні дані: куб $C_I = \langle D, M, A, f, V, g \rangle$ та міра для агрегування m_i набору атрибутів вимірювання групування S .
- Вихід: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O = \{d_1, d_2, \dots, d_q\}$, $q = |S|$, та $\forall_{a_i \in S} d_i = \delta_{a_i}$. Крім того, $M_O = \{m_i\}$, $A_O = \cup_{\forall d_i \in D_O} f(d_i)$ та $f_O = f$. V_O представляє значення отримане через агрегатну функцію h до елементів V та g_O представляє відображення $g_O: \text{dom}_{\dim(1)} \times \text{dom}_{\dim(2)} \times \dots \times \text{dom}_{\dim(q)} \rightarrow V_O$.
- Математична нотація: $\alpha_{h, m_i, S}(C_I) = C_O$.

Для зв'язку кубів можна використовувати двійковий оператор декартового добутку ($\times$). Нижче розроблена алгебра декартового оператора:

- Вхідні дані: куби $C_{I1} = \langle D_1, M_1, A_1, f_1, V_1, g_1 \rangle$ та $C_{I2} = \langle D_2, M_2, A_2, f_2, V_2, g_2 \rangle$.
- Результат: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O = D_1 \cup D_2$; $M_O = M_1 \cup M_2$; $A_O = A_1 \cup A_2$; $V_O = V_1 \times V_2$ та $|V_O| = |V_1| \times |V_2|$. Тобто f_O можна отримати з f_1 та f_2 . g_O представляє відображення $g_O: \text{dom}_{\dim(1)} \times \text{dom}_{\dim(2)} \times \dots \times \text{dom}_{\dim(q)} \rightarrow V_O$, де $q = |D_O|$.
- Математична нотація: $C_{I1} \times C_{I2} = C_O$.

Ще одним оператором є об'єднання. Воно використовується для зв'язку двох кубів, що мають один або більше спільних вимірів та є ідентичними в розмірах до відповідних наборів атрибутів. Прикладом є приєднання кубів: $C_1 = \langle D_1, \dots, f_1, \dots \rangle$ та $C_2 = \langle D_2, \dots, f_2, \dots \rangle$, де $D_1 \cap D_2 \neq \emptyset$ та $\forall d_i \in (D_1 \cap D_2)$, $f_1(d_i) = f_2(d_i)$. $D_1 \cap D_2$ називаються загальними розмірами (cd), тому $D_1 \cap D_2 = \{cd_1, cd_2, \dots, cd_l\}$. Об'єднання слід виразити через тотожність: $C_1 \bowtie C_2 = \sigma_P(C_1 \times C_2)$, де предикат P представлений у формі $P = [(C_1, cd_1 = C_2, cd_1) \wedge (C_1, cd_2 = C_2, cd_2) \wedge \dots \wedge (C_1, cd_l = C_2, cd_l)]$.

Наступним є оператор різниці, який показує відмінність двох кубів та визначається певним чином:

- Вхідні дані: куб $C_{I1} = \langle D_1, M_1, A_1, f_1, V_1, g_1 \rangle$ та куб $C_{I2} = \langle D_2, M_2, A_2, f_2, V_2, g_2 \rangle$.

- Результат: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O, M_O, A_O = D_1, M_1, A_1 = D_2, M_2, A_2$, $f_O = f_1$ та $V_O = V_1 - V_2$. Оператор різниці видаляє ту частину куба C_{I1} , що є спільною для обох кубів.
- Математична нотація: $C_{I1} - C_{I2} = C_O$.

Важливим для аналізу є оператор перетворення pull $\emptyset$, який використовується для витягування або перетворення значень мір за певним критерієм. Він дає змогу виділити частину мір на підмножині для визначення перетворення – функція, яка відображає кожну міру у відповідне значення з домену (область значень цієї міри). Процес перетворення оператора визначається через:

- Вхідні дані: куб $C_I = \langle D; M; A; f; V; g \rangle$, де D_R – набір імен вимірів.
- Результат: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O = D \cup k(d_{Ri})$; $M_O = M - R$; $A_O = A \cup f_O(k(d_{Ri}))$. Відомо, що f_O можна вивести з f , а домен V_O змінюється, оскільки всі значення в C_O не включають компоненти R .
- Математична нотація: $\emptyset_{[R, D_R, k]}(C_I) = C_O$.

Запропонований оператор push (ψ) перетворює розміри на міри таким чином:

- Вхідні дані: куб $C_I = \langle D; M; A; f; V; g \rangle$ та ім'я розміру для перетворення d_i .
- Результат: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O = D - d_i$; $M_O = M \cup f(d_i)$; $A_O = A - f(d_i)$ та $f_O = f$. Для V_O : $dom_{V_O} = dom_V \times dom_{\mu_1} \times \dots \times dom_{\mu_p}$, де $f(d_i) = \{\mu_1, \mu_2, \dots, \mu_p\}$ та $|V_O| = |V|$.
- Математична нотація: $\psi_{d_i}(C_I) = C_O$.

Наступним представлений оператор розбиття, який відображає агрегацію для групування значень куба. Нехай t представляє відображення $t: dom_{dim(1)} \times dom_{dim(2)} \times \dots \times dom_{dim(n)} \rightarrow V_G$, де V_G – набір груп, що складаються зі значень. R є набором атрибутів розмірності розділення $\{a_1, a_2, \dots, a_q\}$ такий, що $R \subseteq A$. Процес розбиття куба визначається наступним чином [6]:

- Вхідні дані: куб $C_I = \langle D; M; A; f; V; g \rangle$, де t є функцією розбиття.

- Результат: куб $C_O = \langle D_O, M_O, A_O, f_O, V_O, g_O \rangle$, де $D_O = D$; $M_O = M$; $\forall a_i \in R$, $A_O = A \cup t_{(a_i)}$ та $f_O = f$, $|V_O| = |V|$.
- Математична нотація: $\gamma_{t,R}(C_I) = C_O$.

Опис операторів та процесів, що реалізують перетворення багатовимірних кубів, слугує основою для розроблення інформаційної технології, орієнтованої на роботу з багатовимірними базами даних. Такий підхід дозволяє формалізувати універсальні оператори трансформації, агрегації та візуалізації даних, що забезпечує узагальнене представлення і уніфіковану обробку різнорідних інформаційних структур. У контексті аналізу мультимодальних медичних даних це створює концептуальне підґрунтя для побудови технології, здатної інтегрувати та ефективно обробляти дані з різних модальностей.

Однак для практичного впровадження запропонованих підходів необхідно продемонструвати їхню ефективність на конкретному прикладі. З цією метою далі розглядається процес перетворення багатовимірних просторів ознак за допомогою методу головних компонент на основі реального набору нормалізованих медичних даних.

У якості вхідних даних використовується вектор ознак пацієнта, який охоплює чотири основні модальності (Додаток В):

- ЕКГ: QT = 400 мс, RR = 1000 мс, HRV = 50 мс, QRS = 110 мс, ST_depression = 0,3, P_interval = 180 мс;
- ЕЕГ: Alpha_power = 0,32, Beta_power = 0,45, Theta_alpha_index = 1,1, Spectral_entropy = 0,78, Peak_frequency = 9,5 Гц, Frontal_coherence = 0,66;
- МРТ: GM/WM contrast = 0,67, Periventricular_intensity = 0,42, LBP = 0,21, GM_texture_entropy = 0,58, Hypointense_volume = 0,34, Lateral_ventricle_shape = 0,49;
- Клінічні дані: Вік = 65 років, Стать = Ж, ІМТ = 27,8, Гіпертензія = так (1), Цукровий діабет = ні (0), Куріння = так (1).

Попередньо всі значення нормалізуються до єдиного масштабу, що дозволяє уникнути домінування окремих показників при обчисленні метрик

подібності або під час зведення даних. У результаті формується нормалізований вектор ознак пацієнта:

$$x^1 = \begin{bmatrix} 0,48, 1,34, -0,69, -1,86, -0,85, -0,38, -1,03, 0,75, -0,05, 0,79, -0,64, -1,13, -0,13, 0,85, \\ -0,39, 0,36, 0,21, 0,40, -0,15, 1, 0, 0, 0, -0,37, 1 \end{bmatrix}.$$

У подальшому метод головних компонент застосовується для редукції простору ознак. PCA дозволяє зменшити розмірність даних, зберігаючи найбільш інформативні напрямки варіації, що важливо для побудови узагальнених моделей прогнозування. За рахунок лінійного перетворення простору PCA забезпечує компресію інформації та зменшення надлишковості, дозволяючи ефективно візуалізувати дані та зменшити навантаження на моделі машинного навчання.

Таким чином, багатовимірне представлення мультимодальних даних дозволяє поєднати інформацію з різних джерел у єдиному форматі, придатному для математичного аналізу. При цьому важливим є розуміння різниці між раннім злиттям (early fusion) та пізнім злиттям (late fusion) даних:


- Раннє злиття передбачає об'єднання ознак на етапі формування єдиного вектора, як у наведеному прикладі, що дозволяє врахувати крос-модальні кореляції вже на етапі трансформації.
- Пізнє злиття, натомість, передбачає окрему обробку кожної модальності з подальшим агрегуванням результатів моделей, що обмежує можливість врахування міжмодальних взаємозв'язків на рівні ознак, але підвищує гнучкість і стійкість до неповних даних.

Суть раннього злиття (Early Fusion) – це створення єдиного багатовимірного простору на рівні ознак для побудови моделі. Багатовимірне представлення є уніфікованим, адже всі модальності поєднуються в один спільний простір ознак: $x_i = [x_i^{(\text{ЕКГ})}, x_i^{(\text{БЕГ})}, x_i^{(\text{МРТ})}, x_i^{(\text{Клінічні дані})}] \in R^d$, де $d = d_1 + d_2 + d_3 + d_4$. Отримується багатовимірний вектор ознак, в якому можливе виявлення взаємозв'язків між модальностями

На рисунку 5.11(а) представлено уніфікований простір ознак, побудований на основі даних із чотирьох модальностей: ЕКГ, ЕЕГ, МРТ та клінічних показників, де кожна точка представляє одного пацієнта, а колір вказує на модальність походження ознак. Високовимірні дані (R^{24}) проєктовано у тривимірний простір за допомогою методу головних компонент (РСА) для візуалізації, де осі підписані як компоненти, відповідно:


- Компонента 1 (PC1) – перша головна компонента: напрям, що пояснює найбільшу дисперсію (варіативність) у даних. Це найінформативніша проєкція усіх 24 ознак.
- Компонента 2 (PC2) – друга головна компонента: напрям, перпендикулярний до першої, що пояснює другу за величиною дисперсію.
- Компонента 3 (PC3) – третя головна компонента: ще один незалежний напрям, що пояснює третю за значущістю частину дисперсії.

Багатовимірний простір ознак (PCA-проєкція 24D → 3D)



(а)

Багатовимірне подання одного пацієнта (24 ознаки)



(б)

Рис. 5.11. (а) Уніфікований простір ознак для мультимодальних медичних даних; (б) Багатовимірне подання ознак одного пацієнта в результаті раннього

злиття

Ці компоненти – це лінійні комбінації початкових ознак, які зберігають найбільшу кількість інформації з початкового простору розмірності 24, але

зведені до трьох вимірів для візуалізації. Кожна точка – пацієнт, представлений у новому просторі з координатами (PC1, PC2, PC3).

На рисунку 5.11 (б) представлено багатовимірне подання одного пацієнта у вигляді вектора ознак $x^1 \in R^{24}$. Ця візуалізація багатовимірного простору ознак для одного пацієнта дозволяє бачити розподіл характеристик пацієнта в єдиній координатній системі.

При пізньому злитті (Late Fusion) немає спільного простору ознак як такого. Дані кожної модальності обробляються окремою моделлю $\rightarrow$ рішення об'єднуються на рівні мета-класифікатора: $f_1(x_i^{(1)}), f_2(x_i^{(2)}), f_3(x_i^{(3)}), f_4(x_i^{(4)})$ та повертають ймовірність належності до класу: $p_1, p_2, p_3, p_4 \in [0,1]$. Потім об'єднуються у вектор: $z_i = [p_1, p_2, p_3, p_4]$ та подається у модель-класифікатор: $\hat{y}_i = f(z_i)$.




Рис. 5.12. Візуалізація розділення класів у кожній модальності

На рисунку 5.12 наведено приклад класифікатора на основі даних після побудови окремих моделей на ЕКГ, ЕЕГ, МРТ, клінічних даних. На візуалізаціях також показано, як розділяються класи у кожній модальності після проєкції в простір рішень.

На рисунку 5.13 представлена 3D-проекція простору векторів, сформованих у результаті пізнього злиття, в якому кожна точка відповідає одному пацієнту з набору даних. Координати точки (PC1, PC2, PC3) – це значення трьох головних компонент, отриманих після застосування методу головних компонент (PCA) до метавекторів. Метавектор для кожного пацієнта – це набір вихідних рішень (наприклад, ймовірностей інсульту), отриманих з окремих моделей для кожної модальності: $meta_{vector} = [P_{stroke}^{(ЕКГ)}, P_{stroke}^{(ЕЕГ)}, P_{stroke}^{(МРТ)}, P_{stroke}^{(Клініка)}]$.




Рис. 5.13. 3D-проекція простору векторів, сформованих у результаті пізнього злиття

Тобто кожен пацієнт представлений у вигляді вектора з чотирьох чисел, який відображає узагальнене рішення всіх модальностей. Цей вектор було спроектовано у 3D-простір методом PCA для полегшення візуального аналізу, адже PCA може бути застосовано до метавекторів – векторів вихідних рішень моделей для аналізу структури метапростору та візуалізації узагальнених рішень.

Отож, для багатовимірного представлення мультимодальних даних різниця між раннім і пізнім злиттям є суттєвою. В таблиці 5.8 наведено порівняння таких підходів.

Таблиця 5.8

Порівняння багатовимірного представлення мультимодальних даних:
різниця між раннім і пізнім злиттям

Критерій	Раннє злиття	Пізнє злиття
Єдиний простір ознак	Так	Ні
Можливість зменшення розмірності	Так (PCA, CDA)	Тільки на рівні рішень
Урахування міжмодальних зв'язків	Так	Обмежене
Гнучкість до відсутніх модальностей	Менша	Вища
Побудова багатовимірного простору	Уніфікований простір	Немає єдиного простору ознак

Питання абстрагування й злиття мультимодальних даних та їх візуальна аналітика є викликом для скоординованої візуалізації (англ. Coordinated multiple views). Зазначена технологія дозволяє користувачам виявляти закономірності та перевіряти взаємозв'язки в кількох візуалізаціях одного чи кількох наборів даних. Для цього потрібно розробити модель для координації ознак між вимірами, які створені з різнорідних наборів даних.

Основна ідея спрямована на те, що всі дані надходять безпосередньо, на вимогу від автономних, гетерогенних, об'єднаних джерел даних. В означеному контексті є проблемою сприяння візуальному дослідженню шаблонів, що містяться в різних наборах даних в контексті цифрового бачення. Новизна цієї технології полягає в проєктуванні та реалізації скоординованих множин представлення для аналізу слабозв'язаних наборів даних, які мають різноманітні та унікальні структури.

Технологія координування множин надає дослідницьке середовище візуалізації, де представлення пов'язані між собою таким чином, що будь-яка маніпуляція користувача в одному поданні автоматично координується з будь-яким іншим для сприяння взаємодії. У цій інтерактивній конструкції візуалізації два або більше вимірів даних розширюють сферу аналізу, узгоджуючи кілька ознак даних, полегшуючи їх порівняння, створюючи багатовимірний зв'язок між ними, що дозволяє підвищити продуктивність бази даних.

Для зв'язування кількох вимірів слід дотримуватись формальних підходів до моделювання та координації кубів даних, де за основу беруться:

- програмування на основі обмежень;
- підхід реляційної схеми;
- шаблон проектування програмного забезпечення, який зазвичай використовується для розробки інтерфейсів користувача;
- спільні ознаки для візуалізації.

Обґрунтовано, що ці підходи спрямовані на різні рівні абстракції та для координації кубів даних. Вони застосовують шаблон скоординованої візуалізації, для розділення специфікації або для порівняння моделі даних та моделей представлення.

Для прикладу наведено координацію моделі Snap-Together, де відтворюються спрощені способи створення певного запиту за допомогою реляційних схем. Відповідно, користувачі контролюють координацію даних, вказуючи реляційне з'єднання між схемами набору даних. Це дозволяє «прив'язувати візуалізації» через відображення у формі:

$$(view_a, action_a, tuple_a) \leftrightarrow (view_b, action_b, tuple_b), \quad (5.10)$$

де:

- $view_a, view_b$ – представлення (візуалізації) даних модальностей a та b ;
- $action_a, action_b$ – дії, які виконуються над даними a та b ;
- $tuple_a, tuple_b$ – реляційні екземпляри даних для модальностей a та b .

Детальний розгляд формального представлення координації між двома наборами дій та пов'язаними з ними наборами даних у контексті мультимодальних даних у багатовимірному просторі дозволить удосконалити інформаційні процеси. Для цього слід перетворити елементи $\langle view, action, tuple \rangle$ на вектори в багатовимірному просторі для подальшої інтеграції модальностей.

Відповідно, дані для модальностей a і b описуються як набори ознак, що перетворюються в багатовимірний простір:

$$tuple_a \rightarrow v_a \in R^{d_a}, tuple_b \rightarrow v_b \in R^{d_b}. \quad (5.11)$$

Дії над мультимодальними даними перетворюються на вектори таким чином:

$$action_a \rightarrow u_a \in R^k, action_b \rightarrow u_b \in R^k. \quad (5.12)$$

Для узгодження представлень, слід дотримуватись розроблених правил, що зводить їх у спільний багатовимірний простір:

$$z_a = f_a(v_a, u_a) \in R^m, z_b = f_b(v_b, u_b) \in R^m, \quad (5.13)$$

де f_a, f_b – функції перетворення, які відображають відповідні модальності та дії у спільному просторі координат.

У рамках запропонованої інформаційної технології особливу увагу приділено формалізації механізмів координації міжмодальних представлень. Автором впроваджено концепт узгодженості ознак, що подається як математичне наближення: $z_a \approx z_b$, де z_a та z_b – вектори ознак, що походять із різних модальностей, але описують один і той самий об'єкт або сутність у різних проєкціях.

Відповідно для інтеграції та перевірки коректності даних використовуються реляційні ключі id_a та id_b . Це унікальні ідентифікатори, які відповідають $tuple_a$ та $tuple_b$. Їх взаємодія виконується через порівняння: $id_a = id_b$, що вказує на зв'язок між первинними або зовнішніми ключами.

Для забезпечення інтеграції між векторними представленнями модальностей та реляційними даними потрібна формалізація зв'язку між a та b :

$$C(z_a, z_b) = \delta(z_a, z_b) + \lambda \cdot \text{Match}(id_a, id_b), \quad (5.14)$$

де:

- $\delta(z_a, z_b)$ – метрика подібності (наприклад, евклідова відстань або косинусна схожість);
- $\text{Match}(id_a, id_b)$ – функція перевірки ідентифікаторів;
- λ – ваговий коефіцієнт.

Представлена модель призначена для вирішення питань проєктування координації без упередженості до певної парадигми даних, навігації чи зв'язку. Щоб досягти цього, потрібно представити формальну багаторівневу модель, в якій координація відбувається на будь-якому етапі потоку даних.

Багатовимірний набір даних описується в реляційному табличному представленні з n записів (або рядків) і p атрибутів (або стовпців) та

зображається як сукупність n точок у p -вимірному евклідовому просторі. Такий принцип подання даних базується на реляційній моделі даних, яка є стандартом де-факто для багатьох реалізацій баз даних. Для інтеграції цієї структури з багатовимірним кубом даних, вперше запропоновано концептуальне зіставлення, де:

- атрибути таблиці (модальності) переходять у виміри куба (dimensions);
- записи таблиці поєднуються зі значеннями вимірів;
- вхідні параметри перетворюються у міри (measures) кубу.

В запропонованій інтеграції куб даних розглядається як розширена реляційна таблиця, де кожна його частинка містить агреговану або обчислену ознаку для поєднання вимірів. Таке представлення дозволяє ефективно виконувати:

- запити типу slice & dice (вибір підмножини даних);
- операції зведення та агрегації (roll-up, drill-down);
- аналітичну обробку даних із різних модальностей у межах єдиної структурованої моделі.

Розроблена авторська інтеграція реляційної таблиці з концептом куба даних дозволяє зберігати гнучкість класичної бази даних та водночас реалізовувати складні аналітичні сценарії для медичних мультимодальних даних.

Розміри куба охоплюють ієрархічну структуру, яка забезпечує рівні агрегації даних [16, 19]. Ці ієрархічні рівні агрегації формують абстракцію для дослідження вимірів куба даних.

У контексті наведеного вище прикладу ієрархічна структура просторового виміру є важливою технологією управління даними. Адже більшість наборів даних, які подаються через об'єднані джерела, агрегуються на певному просторовому рівні. Зазвичай цей рівень описує стан пацієнта. Деякі набори даних подаються лише на одному рівні, проте більшість є доступними на різних рівнях агрегації. Це створює певне ускладнення через наявність кількох стандартів, де співіснують різні версії просторових ієрархічних розмірів.

Об'єднання ієрархії та просторових рівнів у орієнтований ациклічний граф G приведе до визначення зв'язку між різними рівнями агрегації. Формально, граф G визначається як пара (V, E) , де V є набором вершин, який представляє просторові рівні; E – набір ребер між вершинами $E \subseteq (u, v) | u, v \in V \wedge u \neq v$, які представляють батьківсько-дочірній або вкладений зв'язок між рівнями.

Сформоване математичне представлення інформаційної технології обґрунтовує важливість координації між представленнями, отриманими з різних наборів даних та створених на різних рівнях. За онтологічну основу беруться набори даних, які представлені кубом $C = D, M, A, f$ з атрибутом $a^* \in A$ – ключ набору даних. Він містить ідентифікатори з певного просторового рівня $v^* \in V$ графа G . Відповідно, застосовується стандартизований рівень агрегації для набору даних. Такі специфікації, як первинний ключ a^* та просторовий рівень v^* , вказуються в реєстрі метаданих. Також цей реєстр містить метадані для розмірів, показників і атрибутів.

Важливим аспектом для налаштування координації є створення груп візуалізації, які є набором асоціативних вимірів. Як було зазначено в попередньому розділі, у більшості інструментів візуалізації ці групи мають бути визначені користувачами. Це означає, що певна конфігурація n представлень вимагає перевірки щонайбільше 2^n можливих комбінацій.

Потрібно автоматично встановити зв'язок, тим самим відійти від ручного його визначення в базових зв'язках даних або в самих представленнях. Це важливо при розробці ефективної інформаційної технології.

Для автоматичного створення груп для переглядів запропонований підхід перевіряє зв'язок або координацію між базовими кубами даних, на яких базуються представлення [316]. Для цього слід ознайомитись з трьома стратегіями (Рис. 5.14):

1. Загальні куби даних з кількома вимірами, що належать до однієї групи візуалізації.
2. Похідні куби даних, що згенеровані за допомогою узагальнених аналітичних функцій (таких як класифікатор, просторовий аналіз) або за

допомогою більш базових операторів куба, таких як оператор обмеження (σ), оператор агрегації (α) та їх комбінації.

3. Куби даних з універсальними загальними розмірами – це два набори даних із двох окремих об'єднаних джерел, які можна зв'язати за умови спільного виміру.

Зазначені стратегії слід використовувати для побудови графа залежностей, у якому потрібно встановити потенційну координацію між представленнями на основі базових наборів даних. Координація цього графа відповідає комутативним і транзитивним властивостям.

До прикладу, перша стратегія схожа на самооб'єднання Snap-Together. Усі види використовують один і той самий набір даних для автоматично координування. Таким чином, первинний ключ a^* загального набору даних забезпечує посилення на будь-які взаємодії між переглядами. Отож, вибір або взаємодія транслюватиме значення ключа до всіх інших представлень, які використовують той самий набір даних.




Рис. 5.14. Автоматичне створення груп візуалізації: (a) Загальні куби даних; (b) Похідні куби даних; (c) Куби зі спільною розмірністю.

Друга стратегія використовує функції, які створюють агрегації даних у більш складну їх класифікацію. У більшості випадків результуючі набори даних зберігають структурні властивості вихідного набору даних. Таким чином, усі

набори даних у ланцюжку аналізу даних можуть групуватись в один взаємозалежний простір. У контексті даного прикладу ця залежність підтримується та використовується для координації візуалізації.

Отож, куб даних і його похідні куби мають спільний атрибут в межах спільного виміру і, відповідно, можуть бути автоматично скоординовані. Як один із варіантів використання – забезпечення автоматичного зв'язування між представленнями (наприклад, статистичними агрегатними діаграмами), які підсумовують дані (агрегація куба даних), і показують окремі спостереження (комірки куба даних). Формально можна визначити цей сценарій наступним чином: Нехай T є операцією над кубом, яка створює інший куб: $C = \langle D, M, A, f \rangle \rightarrow C' = \langle D', M', A', f' \rangle = T(C)$. Координата $L_{CC'}$ між C та C' може бути автоматично призначена за умови:

$$\begin{aligned} D^* &= D \cap D' \neq \emptyset \\ A^* &= A \cap A' \neq \emptyset \end{aligned} \quad (5.15)$$

$$\exists a_i, a_i \in f(D^*) \cap f'(D^*), a_i \in A^*.$$

Використовуючи приклад, наведений на рисунку 5.10, автоматичну координацію між представленнями, які створені за допомогою операцій обмеження та агрегації куба, можна встановити наступним чином (Табл. 5.9).

Таблиця 5.9

Координація між представленнями даних, які використовують куб даних та його похідні

Загальні розміри $f(D^*) \cap f'(D^*)$	V	V'	V''	V'''
V		{Прізвище пацієнта, MPT}	{Прізвище}	{MPT}
V'	{Прізвище пацієнта, MPT}		{Прізвище}	{MPT}
V''	{Прізвище}	{Прізвище}		{}
V'''	{MPT}	{MPT}	{}	

Автором пропонується два способи, якими можна встановити координацію для фактичних даних на рівні кортежу (рядка). Якщо координація виконується, коли значення даних збігаються для всіх загальних атрибутів, тобто зв'язок визначається за допомогою оператора AND, тоді використовується консервативний підхід:

$$\forall a_i, a_i \in A^*, t_C(a_i) = t_{C'}(a_i), \quad (5.16)$$

де:

- $t_C(a)$ – це значення кортежу атрибута a в кубі C ;
- A^* – це набір атрибутів спільних розмірів.

Якщо відповідні куби даних мають спільний первинний ключ a^* в межах загальних розмірів, то координація є однозначною. В іншому випадку може мати місце відображення один-до-багатьох (сюр'єктивне). Такий зв'язок між детальними наборами даних і підсумковими наборами даних (наприклад, підрахунками певного виміру, отриманими за допомогою оператора агрегування куба, або гістограмою класів Дженкса) у візуальному відображенні є бажаним в аналітичному інтерфейсі. В таблиці 5.9 можна встановити координацію «один-до-багатьох» між, наприклад, V' і V'' на основі виміру Прізвища або V і V''' на основі МРТ.

Якщо координація виконується принаймні для одного набору відповідних значень будь-яких атрибутів, тоді вибирається агресивний підхід. Це робиться за допомогою операції OR над значеннями загальних атрибутів. Наслідки такого підходу визначаються у тому, що зв'язування намагається знайти якомога більше збігів кортежів; якщо екземпляри даних мають загальне значення атрибута, то зв'язок встановлюється. Це жадібне об'єднання:

$$\exists a_i, a_i \in A^*, t_C(a_i) = t_{C'}(a_i). \quad (5.17)$$

Третя стратегія передбачає, що набори даних для певної області застосування мають спільний вимір:

$$C = \langle D, M, A, f \rangle, C' = \langle D', M', A', f' \rangle. \quad (5.18)$$

Координати $L_{CC'}$ між C і C' можна автоматично призначити, якщо: $D \cap D' \neq \emptyset$.

Хоча набори даних надходять від різних джерел даних, та багато з них мають спільний просторовий вимір, який базується на тій самій просторовій структурі. Ця структура є загальною ієрархією просторової агрегації, яка інкапсульована як орієнтований ациклічний граф G . Кожен набір даних повинен мати розмір ID, який відображається як атрибут первинного ключа. Цей атрибут повинен містити стандартизований просторовий ідентифікатор.

Проте у запропонованому підході існують проблеми, які потребують подальшого дослідження. Перша – продуктивність. У пропонованій реалізації автоматичне зв'язування між вимірами на основі загальних довільних розмірів здійснюється лінійним скануванням кортежів. Це забезпечує прийнятний час на отримання відповіді для кількох сотень кортежів (або функцій). Проте більш складний процес індексування (наприклад, індексування за вимогою або автоматичне кешування) потребує перевірки. Відповідно, нормалізація на льоту та зіставлення один-до-багатьох є складним процесом з обчислювальної точки зору.

Одним із можливих рішень, запропонованих для подолання цієї проблеми, є використання індексування в реальному часі під час попередньої вибірки даних або під час створення представлень. Це особливо корисно для взаємодії, де критично важливим є час відповіді, наприклад під час очищення. Хоча деякі з цих кроків можна виконати на стороні клієнта, туди також можна перенести складні обчислювальні перетворення (наприклад, застосування регулярних виразів) на серверний процес, який виконується один раз після процесу виявлення та отримання даних.

Зв'язування «один-до-одного» за допомогою просторового виміру обробляється достатньо добре, оскільки просторові ідентифікатори, як правило, є індексованими первинними ключами. Проблемою є складність у підтримці цього ієрархічного виміру. Вона полягає в тому, що два просторові рівні можуть не ідеально вкладатись один в одного. У цій ситуації потенційною можливістю є використання таблиці узгодженості.

5.4. Формалізація та трансформація простору мультимодальних медичних даних у динамічних і статичних інформаційних системах

В контексті медичних інформаційних систем мультимодальні підходи розглядаються як інтеграційні структури, здатні ефективно обробляти та синхронізувати різноманітні типи даних. Такі ІТ-системи спеціалізуються на обробці часових змін, пов'язаних зі звуковими сигналами, відеопотоками або даними з датчиків, і на аналізі взаємозв'язків між цими модальностями в контексті їх динаміки.

Застосування методів представлення мультимодальних медичних даних для моделювання динамічних систем зосереджується на тому, як інтеграція різних джерел інформації може сприяти точнішому розумінню системної поведінки в часі та формуванню прогнозних моделей у складних обчислювальних середовищах.

Моделювання динамічних систем є важливим інструментом для аналізу та оптимізації складних процесів, зокрема в інформаційних системах. Метод подання мультимодальних даних надає можливість враховувати різноманітні аспекти функціонування таких систем, що значно підвищує точність моделей.

Метод подання мультимодальних медичних даних полягає в інтеграції різних типів інформації. Тому розроблено модель представлення мультимодальних даних, що дозволяє моделювати часову поведінку пацієнта або інформаційної медичної системи через інтеграцію:

- темпоральних характеристик (тривалість госпіталізації, періоди між процедурами);
- станів медичної системи (черги обробки даних, доступність обладнання);
- інтенсивності потоків (навантаження на діагностичні модулі, частота запитів до системи).

Цей підхід реалізується у вигляді аналітичної динамічної моделі, здатної адаптивно реагувати на зміни в даних і формувати обґрунтовані рішення щодо маршрутизації пацієнтів, оптимізації ресурсів та виявлення критичних станів.

На відміну від синтетичних моделей, які базуються на фіксованих припущеннях і використовуються для попередньої оцінки ефективності (зокрема, під час розробки медичних ІТ-систем), динамічні моделі – зокрема на основі марковських процесів – враховують часові залежності, стохастичну природу медичних даних та змінність станів пацієнтів, що робить їх придатними для високоточних клінічних прогнозів.

Основним недоліком синтетичних моделей є їх недостатня гнучкість, при врахуванні змін станів у реальному часі. При цьому динамічні моделі, на основі марковських процесів, враховують часо-залежну складову системи. В Табл. 5.10 наведений порівняльний аналіз моделей, за визначеними критеріями.

Функціонування статичної мультимодальної ІТ-системи зводиться до обробки даних з різних джерел. Основні параметри такої системи – обчислювальна потужність, час обробки, обсяг запитів та навантаження на інфраструктуру – залишаються фіксованими впродовж усього циклу виконання.

Таблиця 5.10

Порівняння синтетичних і динамічних моделей

Критерій	Синтетичні моделі	Динамічні моделі
Гнучкість	Обмежена	Висока
Врахування змін у часі	Відсутнє	Є (наприклад, перехід між фазами)
Складність реалізації	Низька	Середня або висока
Точність результатів	Менш точні	Точніші завдяки врахуванню динаміки

З таблиці 5.10. видно, що статичні мультимодальні ІТ-системи оперують фіксованими параметрами (навантаження, обсяг даних, тривалість обробки), що обмежує їхню здатність реагувати на клінічну динаміку пацієнтів. Це означає, що система не адаптується до зовнішніх змін або змінних параметрів середовища, а функціонує в рамках заданої конфігурації, що характерно для ІТ-архітектур із жорстко визначеними умовами роботи.

У статичних мультимодальних системах основні характеристики залишаються сталими, що дозволяє використовувати аналітичні формули для оцінки їх продуктивності та навантаження. Розглянемо кожну детально:

1. Модель продуктивності системи (P_{sys}) визначається як кількість даних, які система може обробити за одиницю часу:

$$P_{sys} = \frac{\sum_{i=1}^n D_i \cdot \lambda_i}{T_{total}}, \quad (5.19)$$

де:

- D_i – середній обсяг даних типу i ,
- λ_i – інтенсивність надходження запитів типу i (кількість запитів/с),
- T_{total} – загальний час обробки всіх типів запитів.

2. Модель навантаження системи (U) розраховується як відношення сумарного часу, потрібного для обробки запитів, до доступного часу роботи:

$$U = \sum_{i=1}^n \frac{\lambda_i \cdot T_i}{C}, \quad (5.20)$$

де:

- $T_i = t_i \cdot D_i$ – час обробки одного запиту типу i ,
- C – пропускна здатність системи (обсяг даних, що система може обробити за одиницю часу).

Система є стабільною, якщо $U < 1$.

3. Пропускна здатність системи визначається як зворотна величина середнього часу обробки одного запиту:

$$C = \frac{1}{\frac{\lambda_i \cdot D_i}{\lambda_{total}}}, \quad (5.21)$$

де λ_{total} – загальна інтенсивність запитів.

4. Для кожного типу даних можна оцінити середній час очікування у черзі (T_{queue}) через навантаження системи:

$$T_{queue} = \frac{U}{\lambda_{total} \cdot (1-U)}. \quad (5.22)$$

Розрахована продуктивність статичної мультимодальної ІТ-системи за кожним типом даних. Відповідно сервер для оцінки продуктивності та навантаження статичної мультимодальної системи представлений вхідними параметрами:

- числовими даними $D_{num}=2$ МБ, $\lambda_{num}=10$ запитів/с, $T_{num}=0,4$ с.;
- графічними даними $D_{img}=10$ МБ, $\lambda_{img}=5$ запитів/с, $T_{img}=5$ с.;
- аудіо даними $D_{audio}=100$ МБ, $\lambda_{audio}=1$ запит/с, $T_{audio}=200$ с.

За наведеними вище формулами, продуктивність статичної мультимодальної системи розраховується:

$$P_{sys} = \frac{(2 \cdot 10) + (10 \cdot 5) + (100 \cdot 1)}{0,4 \cdot 10 + 5 \cdot 5 + 200 \cdot 1} = \frac{20 + 50 + 100}{4 + 25 + 200} = \frac{170}{229} \approx 0,743 \text{ МБ/с.}$$

Відповідно навантаження системи розраховується за формулою:

$$U = \frac{(10 \cdot 0,4) + (5 \cdot 5) + (1 \cdot 200)}{400} = \frac{4 + 25 + 200}{400} = \frac{229}{400} \approx 0,572.$$

При таких вхідних параметрах середній час очікування системи дорівнює:

$$T_{queue} = \frac{0,572}{16 \cdot (1 - 0,572)} \approx \frac{0,572}{16 \cdot 0,428} \approx \frac{0,572}{6,848} \approx 0,0836 \text{ с.}$$

Отже, статична система забезпечує стабільну продуктивність і низький час очікування, якщо навантаження не перевищує порогового значення ($U < 1$). При наведених вище вхідних параметрах система працює стабільно із завантаженням 57,2 % та середнім часом очікування 0,0836 с. Однак при збільшенні запитів продуктивність може погіршуватись через відсутність адаптивності.

У статичних системах всі параметри є сталими, а модель будується на основі фіксованих характеристик обробки даних. На попередніх вхідних модальностях можна розглянути етапи моделювання мультимодальної статичної моделі. Загальний обсяг даних для обробки (D_{total}) розраховуються за формулою:

$$D_{total} = \lambda_{num} \cdot D_{num} + \lambda_{img} \cdot D_{img} + \lambda_{audio} \cdot D_{audio}. \quad (5.23)$$

Підставивши значення, отримали:

$$D_{total} = 10 \cdot 2 + 5 \cdot 10 + 1 \cdot 100 = 20 + 50 + 100 = 170 \text{ МБ.}$$

Сумарний час роботи системи (T_{total}) визначається як сума часу, необхідного для обробки кожного типу даних:

$$T_{total} = \lambda_{num} \cdot T_{num} + \lambda_{img} \cdot T_{img} + \lambda_{audio} \cdot T_{audio}. \quad (5.24)$$

Відповідно, проведений розрахунок показав:

$$T_{total} = 10 \cdot 0,4 + 5 \cdot 5 + 1 \cdot 200 = 4 + 25 + 200 = 229 \text{ с.}$$

Отож, середню продуктивність системи (P_{avg}) розраховано за формулою:

$$P_{avg} = \frac{D_{total}}{T_{total}}. \quad (5.25)$$

Результат обчислення приведено до:

$$P_{avg} = \frac{170}{229} \approx 0,72 \text{ МБ/с.}$$

Наступним етапом є оцінка завантаження системи (U_{static}), яка визначається через відношення часу обробки до доступного часу роботи:

$$U_{static} = \frac{T_{total}}{T_{available}}. \quad (5.26)$$

Виначено доступний час роботи системи $T_{available}=470$ с, відповідно:

$$U_{static} = \frac{229}{470} \approx 0,49.$$

Ця модель демонструє, яким чином обмеження статичної системи впливають на її здатність ефективно обробляти мультимодальні дані. Продуктивність статичної системи складає приблизно 0,72 МБ/с, що є прийнятним для невеликих навантажень. Завантаження системи становить 49 %. Це означає, що система функціонує в допустимих межах. Тому, для ефективної роботи статичної системи необхідно: зменшити кількість оброблюваних відео запитів, використовувати паралельну обробку даних.

Отож, обмеження статичних мультимодальних ІТ-систем, пов'язані з жорстко заданими параметрами обробки, не дозволяють їм ефективно реагувати на змінну клінічну інформацію та складні діагностичні сценарії. У відповідь на ці виклики запропоновано підхід, орієнтований на створення гнучких, адаптивних ІТ-архітектур, що поєднують принципи самоконтрольованого навчання з багатовимірним аналізом мультимодальних потоків медичних даних.

Запропонована концепція дозволяє автоматично адаптувати обчислювальні процеси, прогнозувати потенційні зміни у станах пацієнтів і підвищувати точність прийнятих рішень завдяки використанню контекстуальної інформації з різномірних джерел у режимі реального часу. Це відкриває перспективи для побудови інтелектуальних медичних систем нового покоління, здатних до самоорганізації, стійкої обробки неповних даних та ефективного реагування на змінні клінічні умови.

Продуктивність та надійність динамічних систем є ключовими показниками ефективності протікання інформаційних потоків. Ці характеристики безпосередньо впливають на здатність системи виконувати задані функції у визначених умовах.

Відповідно за формулами 5.46, визначається продуктивність такої системи. P розглядається як якісна ознака обчислювальної потужності системи: $P = \frac{I_{out}}{T}$, де I_{out} – обсяг обробленої інформації, T – час виконання завдання.

Для розподілених систем продуктивність може бути виражена через суму продуктивностей компонентів: $P_{total} = \sum_{i=1}^n P_i$, де P_i – продуктивність i -того компонента, n – кількість компонентів.

Надійність системи $R(t)$ – ймовірність того, що система буде працездатною протягом часу t . Вона обчислюється за формулою: $R(t) = e^{-\lambda t}$, де λ – інтенсивність відмов (кількість відмов за одиницю часу), t – час роботи системи.

Для системи, що складається з кількох компонентів, загальна надійність залежить від способу їх з'єднання. Серійне з'єднання: $R_{total}(t) = \prod_{i=1}^n R_i(t)$, де $R_i(t)$ – надійність i -того компонента. Паралельне з'єднання: $R_{total}(t) = 1 - \prod_{i=1}^n (1 - R_i(t))$.

У динамічних систем їх стан змінюється у часі, що можна описати за допомогою марковських процесів. Нехай $X(t)$ – стан системи у час t , тоді:

$$P_{ij}(t) = P_r(X(t + \Delta t) = j \mid X(t) = i), \quad (5.27)$$

де $P_{ij}(t)$ – ймовірність переходу системи зі стану i у стан j .

Граничний розподіл станів можна знайти, розв'язуючи систему рівнянь:

$$\begin{cases} \pi_j \sum_{i \neq j} P_{ij} = \sum_{i \neq j} \pi_i P_{ij} \\ \sum_j \pi_j = 1 \end{cases}, \quad (5.28)$$

де π_j – гранична ймовірність перебування у стані j .

Наведені моделі дозволяють оцінити:

1. Середній час очікування відповіді (T_{resp}):

$$T_{resp} = \frac{\sum_j \pi_j \cdot T_j}{n}, \quad (5.29)$$

де T_j – час обробки у стані j .

2. Коефіцієнт завантаження системи (U):

$$U = \frac{\lambda}{\mu}, \quad (5.30)$$

де λ – інтенсивність запитів, μ – інтенсивність їх обробки.

Наведені моделі забезпечують інструменти для оптимізації продуктивності та надійності систем у реальному часі. Представлено приклад динамічної системи, яка обробляє мультимодальні дані на сервері зі змінними навантаженнями. На вхід в систему подаються три модальності з визначеним середнім обсягом одного запиту:

- для числових даних – 2 МБ;
- для графічних даних – 10 МБ;
- для аудіоданих – 100 МБ.

Розраховано час обробки певної модальності: $t_{num}=0,2$ МБ/с, $t_{img}=0,5$ МБ/с, $t_{audio}=2$ МБ/с. Також, відомою є інтенсивність надходження запитів для кожного типу даних: $\lambda_{num}=10$ запитів/с, $\lambda_{img}=5$ запитів/с, $\lambda_{audio}=1$ запит/с. Отож, розрахуємо інтенсивність запитів всіх типів даних:

$$\lambda = \lambda_{num} + \lambda_{img} + \lambda_{audio} = 10 + 5 + 1 = 16 \text{ запитів/с}$$

Щоб розпочати моделювання динамічних мультимодальних систем, слід визначити середній час обробки кожної модальності. На першому кроці необхідно розрахувати середній час обробки для кожної з модальностей. Цей

показник еквівалентний середньому часу, що витрачається під час моделювання статичної системи. Для різних типів модальностей ці значення становлять: $T_{num} = 0,2$ с, $T_{img} = 1$ с, $T_{audio} = 5$ с. Тоді середній час обробки (T_{avg}):

$$T_{avg} = \frac{10 \cdot 0,2 + 5 \cdot 1 + 1 \cdot 5}{16} = \frac{2 + 5 + 5}{16} = 0,75 \text{ с.}$$

Середня кількість запитів у системі (L):

$$L = \lambda \cdot T_{avg} = 16 \cdot 0,75 = 12 \text{ запитів.}$$

Наступним етапом є розрахунок середнього навантаження системи (U), де загальна інтенсивність обробки (μ) системи для кожної модальності обчислюється за формулою:

$$\mu_{num} = \frac{1}{T_{text}} = \frac{1}{0,2} = 5 \text{ запитів/с,}$$

$$\mu_{img} = \frac{1}{T_{img}} = \frac{1}{1} = 1 \text{ запит/с,}$$

$$\mu_{audio} = \frac{1}{T_{video}} = \frac{1}{5} = 0,2 \text{ запитів/с.}$$

Відтак, для кожної модальності можна визначити значення коефіцієнта навантаження системи (U), яке відповідатиме наступним показникам:

$$U_{num} = \frac{\lambda_{num}}{\mu_{num}} = \frac{10}{5} = 2,$$

$$U_{img} = \frac{\lambda_{img}}{\mu_{img}} = \frac{5}{1} = 5,$$

$$U_{audio} = \frac{\lambda_{audio}}{\mu_{audio}} = \frac{1}{0,2} = 5.$$

За умови, що система обробляє дані послідовно, можна визначити ймовірність її простою (π_0) для кожної модальності, яка дорівнюватиме:

$$\pi_0 = \frac{1}{1 + U_{num} + U_{img} + U_{audio}} = \frac{1}{1 + 2 + 5 + 5} = 0,08.$$

Таким чином, згідно із законом Літтла, середній час очікування запиту в черзі (T_{resp}) обчислюється наступним чином:

$$T_{resp} = \frac{L}{\lambda}, \quad (5.31)$$

$$T_{resp} = \frac{12}{16} = 0,75 \text{ запитів/с.}$$

Отже, розроблена динамічна мультимодальна система характеризується значним рівнем навантаження, що зумовлено передусім відеозапитами, обробка яких потребує найбільше часу. Для підвищення ефективності доцільно покращити процес обробки відеоданих або ж призначити окремий сервер спеціально для цієї мети.

Відповідно до запропонованого бачення, аналітична модель функціонування динамічної мультимодальної ІТ-системи має бути сформована на основі концепції інформаційного потоку як повноцінного ресурсу, який відіграє критичну роль у процесах оперативного реагування, моніторингу клінічного стану пацієнтів та прийняття медичних рішень.

Запропонована модель передбачає інтеграцію двох апаратних рівнів:

1. Серверного шару – відповідального за централізовану обробку, агрегацію, аналіз та зберігання мультимодальних медичних даних. Цей рівень включає високопродуктивні обчислювальні вузли, які реалізують алгоритми багатовимірної аналізу, розподіленого навчання та адаптивної синхронізації модальностей.
2. Периферійного шару – представленого мікроконтролерами та сенсорними пристроями, які виконують зчитування даних у режимі реального часу. Ці пристрої здійснюють первинну обробку (наприклад, попередню фільтрацію або нормалізацію) та передають результати на центральний сервер.

Ототожнюючи функціонування динамічної мультимодальної системи обґрунтовано необхідність застосування математичних методів аналізу динаміки потоків – таких як черги з пріоритетами, марковські мережі, моделі перехідних станів – для забезпечення стійкості, прогнозованості та оптимізації обробки в умовах високої структурної складності та варіативності навантажень.

Особливістю запропонованого підходу є впровадження інтелектуальних інтерфейсів, які працюють з мультимодальними даними задля підвищення

інформаційних процесів та забезпечення гнучкої взаємодії з користувачем. Для цього застосовуються методи машинного навчання, що дають змогу покращити функціонування інтерфейсів. Інтеграція мультимодальних джерел даних забезпечує ефективну взаємодію інтелектуальних інтерфейсів, що входять до складу мультимодальної динамічної системи.

У рамках динамічної архітектури медичної IT-системи реалізовано підхід до моніторингу клінічного стану пацієнтів на основі уніфікованої структури представлення даних, що інтегрує часові, візуальні, аудіо та сенсорні модальності. Така структура дозволяє проводити багатовимірний аналіз станів пацієнтів, виявляти критичні зміни у параметрах та своєчасно формувати прогностичні медичні висновки.

Висновки до розділу 5

У розділі 5 було обґрунтовано методологічні основи побудови інформаційної технології (IT) для обробки багатовимірних мультимодальних медичних даних. На основі аналізу та розроблення відповідних методів і моделей сформовано цілісний підхід до реалізації аналітичної платформи, що здатна ефективно обробляти, інтегрувати, узагальнювати й оцінювати інформацію з різних джерел.

1. Запропоновано підхід до виявлення та кількісної оцінки структурної узгодженості між ознаками різних модальностей, що дозволяє виявляти латентні зв'язки між джерелами даних. Формалізовано критерії когерентності, кореляційної та топологічної сумісності, які дозволяють здійснювати попередній аналіз перед інтеграцією. Це забезпечує обґрунтований вибір методів подальшої обробки та підвищує ефективність об'єднання модальностей.

2. Доведено доцільність використання раннього злиття для формування уніфікованого простору ознак, що дозволяє враховувати міжмодальні взаємозв'язки та застосовувати методи зменшення розмірності (CDA). Порівняльний аналіз раннього та пізнього злиття показав, що кожен підхід має

свої переваги: раннє злиття – для створення інтерпретованих моделей у спільному просторі ознак, пізнє злиття – для підвищення стійкості моделей у випадку часткової втрати модальностей.

3. На основі реального набору даних із 24 нормалізованих ознак сформовано простір ознак, який охоплює дані з ЕКГ, ЕЕГ, МРТ та клінічних показників. Продемонстровано, як за допомогою методу головних компонент (РСА) відбувається редукція розмірності із збереженням основної варіації. Побудовано візуальні 2D/3D-проекції, які ілюструють розділення пацієнтів за класами, що є ключовим для створення точних та інтерпретованих моделей класифікації.

4. Запропоновано концепцію метавекторів для реалізації пізнього злиття: для кожної модальності будується окремий класифікатор, а їх вихідні рішення агрегуються у єдиний метапростір. Показано, що РСА може бути застосоване до метавекторів для візуалізації простору рішень і порівняння моделей. Побудовано метакласифікатор, який демонструє здатність комбінувати прогнози окремих модальностей у єдине, узгоджене рішення. Це забезпечує гнучкість та адаптивність аналітичної системи до динамічних змін у структурі даних.

5. Здійснено порівняльний аналіз динамічних та синтетичних систем у мультимодальному аналітичному середовищі. Обґрунтовано доцільність їх комбінованого використання, а також запропоновано метрики для оцінювання якості й узгодженості результатів у контексті підтримки клінічних рішень. Зроблено висновок, що динамічні моделі краще підходять для задач моніторингу та своєчасного виявлення змін у стані пацієнта, тоді як синтетичні – для інтегрованого аналізу історичних даних і довгострокових прогнозів. Комбіноване використання обох типів моделей дозволяє досягнути вищої ефективності при прийнятті медичних рішень.

Результати досліджень за п'ятим розділом опубліковані в роботах автора [1, 3, 5, 7, 9, 13, 16, 25, 30, 33, 45, 47, 49] (Додаток Б).

РОЗДІЛ 6

РОЗРОБЛЕННЯ АРХІТЕКТУРИ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ТА АПРОБАЦІЯ СФОРМУЛЬОВАНИХ ГІПОТЕЗ

У шостому розділі запропоновано комплексну інформаційну технологію багатовимірної аналізу мультимодальних медичних даних із використанням сучасних методів глибокого навчання, машинного навчання та розподілених обчислювальних платформ. Метою дослідження є підвищення точності, здатності до узагальнення та масштабованості клінічних моделей шляхом інтеграції гетерогенних джерел інформації, зокрема електроенцефалографії, електрокардіографії, магнітно-резонансної томографії та клінічних даних.

Запропонована архітектура підтримує два підходи інтеграції даних, що формуються на принципах: інтеграції мультимодальних ознак, який полягає в поєднанні ознак, що належать до інтеграції мультимодальних ознак та побудові моделей класифікаторів станів об'єкта, що здійснюється на рівні модальних ембедінгів. Для моделювання просторово-часових залежностей використано гібридні нейронні архітектури, зокрема Inception ResNet v1, DenseNet121, LSTM, BiLSTM, TCN та Transformer з механізмом уваги. Особливу увагу приділено формуванню уніфікованого ознакового простору, який забезпечує об'єднання даних з різних модальностей у єдину структуру, придатну для подальшої класифікації.

У дослідженні використано сформовану медичну базу даних, що містить записи про пацієнтів, розподілених на п'ять діагностичних категорій: Healthy, Ischemic, Hemorrhagic, Poststroke, OtherNeuropathology. Було сформовано матрицю ознак. Цільову змінну представлено у форматі one-hot encoding.

Здійснено повний цикл обробки даних: попереднє очищення, імпутацію пропущених значень, нормалізацію ознак, формування навчальної вибірки та побудову моделей класифікації з наступною валідацією. Для класифікації застосовано ансамблеві алгоритми (Random Forest, XGBoost), а також нейронні мережі із Softmax-шаром.

У межах розділу також розглянуто питання масштабування інформаційної технології для обробки великих масивів медичних даних. Обґрунтовано доцільність застосування розподілених обчислень з використанням платформ Hadoop і Apache Spark. Проведено порівняльний аналіз ефективності цих систем на етапах ETL та навчання моделей.

Загалом запропонована технологія поєднує структурну інтеграцію, адаптивні архітектури глибокого навчання та засоби масштабованої обробки, створюючи ефективний інструментарій для класифікації клінічних станів і підтримки медичних рішень.

6.1. Розроблення архітектурного вирішення системи

Мультимодальні системи класифікації станів пацієнта складаються з чотирьох ключових модулів: модуль покриття даних, модуль генерації ознак, модуль порівняння та модуль прийняття рішень, як показано на рисунку. 6.1. У замкнених задачах ідентифікації користувача модуль порівняння не використовується, оскільки він спеціально розроблений для перевірки завдань. Замість цього він замінюється модулем класифікації.




Рис. 6.1. Модулі компонентів для мультимодальної медичної системи

На рисунку 6.1 показано, що на вхід пропонується завантажувати модальності у модуль збору даних. Він охоплює пристрої, які відповідають за отримання медичних сигналів та 3D-зображень даних та клінічних даних з баз даних. Цей модуль також містить методи попередньої обробки вихідних даних, включаючи покращення якості та зменшення шумів і перешкод.

Наступним кроком, представленим на рисунку 6.1, є модуль вилучення ознак, який спеціально розроблений для створення стислого та інформативного представлення наданих даних. У задачах аналізу зображень МРТ цей модуль може використовувати ознаки, отримані за допомогою класичних алгоритмів машинного навчання, таких як регресія та кластеризація (наприклад, бінарні шаблони, методи опорних векторів, ансамбль дерев рішень тощо). Подібним чином у задачах аналізу мовного сигналу можна використовувати методи виділення ознак.

Модуль класифікації (Рис. 6.1) є важливим компонентом мультимодальної медичної системи. Він використовує алгоритми, які шукають шаблони у витягнутих даних, для точної ідентифікації стану пацієнта. У випадку алгоритмів, оснований на згорткових нейронних мережах (CNN), функції генерації ознак і класифікації об'єднані в один модуль. Згодом вихідні дані мультимодальної системи додатково обробляються модулем прийняття рішень, який аналізує результат класифікатора та приймає остаточне рішення щодо результату розпізнавання стану пацієнта.

Методи проектування схем мультимодальних систем та розробки мультимодальних алгоритмів розробляються з використанням двох основних підходів: послідовного та паралельного. У послідовному підході вихідні результати одного біометричного аналізу модальності використовуються для звуження області пошуку потенційних пацієнтів, а потім ця інформація передається на вхід наступного блоку для подальшого аналізу. З іншого боку, при паралельному підході біометрична інформація різної природи аналізується одночасно. Крім того, існує три рівні, на яких може відбуватися поєднання модальностей: рівень ознак, процес прийняття рішень та рівень порівняння.

Для послідовного та паралельного підходів існують інші стратегії поєднання аналізу біометричних даних, включаючи мультиалгоритмічні системи та мультисенсорні біометричні системи. Мультиалгоритмічні системи передбачають використання різних методів для аналізу однієї модальності. Вибір конкретного метода визначається умовами роботи системи. Вони можуть працювати одночасно, але остаточне рішення щодо ідентифікації стану пацієнта приймається модулем прийняття рішень, який об'єднує результати кількох методів.

Для розробки мультимодального алгоритму ідентифікації на основі згорткової нейронної мережі (CNN) інтеграція модальностей на рівні ознак є вирішальним кроком. Двома методами комбінування модальностей у таких технологіях є конкатенація та білінійна комбінація. Конкатенація передбачає об'єднання ознак, отриманих із незалежних модальностей, у єдиний вектор ознак за допомогою рівня конкатенації. Цей підхід дозволяє методу використовувати інформацію, отриману кожною модальністю незалежно. З іншого боку, білінійна комбінація поєднує модальності на рівні ознак шляхом виконання поелементних добутків між відповідними елементами векторів ознак. Цей підхід фіксує взаємодію між модальностями та може посилити дискримінаційну силу методу. Рисунок 6.2 ілюструє ці методи та їх інтеграцію в мультимодальний алгоритм ідентифікації на основі CNN.




Рис. 6.2. Об'єднання модальностей рівня функцій за допомогою операцій конкатенації (a) та білінійної комбінації (b)

На рисунку 6.2 представлено дві архітектури нейронних мереж, які використовують різні підходи до об'єднання ознак, отриманих із п'яти входів, для виконання завдань класифікації. Щодо архітектури з конкатенацією ознак (Рис. 6.2 (а)), то обробка ознак у ній проходить через окремі згорткові шари (Convolutional layers), які використовуються для вилучення локальних ознак із вхідних даних. Після цього вилучені ознаки обробляються через повнозв'язні шари (Fully connected layers), які перетворюють їх у векторні представлення. Відповідно, отримані вектори з п'яти входів об'єднуються шляхом конкатенації (Concatenation layer), тобто склеювання п'яти векторів уздовж певної осі, де об'єднаний вектор подається на повнозв'язний шар для подальшої обробки. На виході використовується SoftMax, яка виконує ймовірнісну класифікацію за певними класами.

Побудова шару конкатенації базується на наступних математичних операціях, де q_{m_1} – це набір, сформований під час модального аналізу m_1 з l ознаками, а a_{m_2} – це набір, сформований під час модального аналізу m_2 з k ознаками:

$$\begin{aligned} q_{m_1} &= \{q_1, q_2, q_3, \dots, q_l\}, \\ a_{m_2} &= \{a_1, a_2, a_3, \dots, a_k\}. \end{aligned} \quad (6.1)$$

Наступним кроком є формування комбінованого набору ознак p , який математично описується такими формулами:

$$\begin{aligned} p &= \{q_{m_1}, a_{m_2}\}, \\ p &= \{q_1, q_2, q_3, \dots, q_l; a_1, a_2, a_3, \dots, a_k\} \\ p &\in R^{k+l}. \end{aligned} \quad (6.2)$$

Після етапу конкатенації наступний повністю зв'язаний рівень використовується для зменшення розмірності простору ознак. Обрана архітектура полегшує перевірку мультимодального методу, зосередженого на розпізнаванні МРТ зображень. За допомогою цього методу спектральне відображення ознак аналізується за принципами аналізу зображень із використанням двовимірних ядер згортки.

Перевагами архітектури з конкатенацією ознак (Рис. 6.2(a)) є простота в реалізації та можливість швидкої інтеграції ознак з різних модальностей. Але при цьому ігноруються взаємозв'язки між ознаками всіх вхідних модальностей.

Щодо архітектури з білінійною комбінацією (Рис. 6.2(b)), то структура процесів на вході однакова з попередньою, проте замість простого склеювання ознак, як у першій архітектурі, застосовується білінійна комбінація (Bilinear combination layer). Символ $\otimes$ вказує на взаємодію між ознаками із п'яти входів. Це може бути, наприклад, поелементне множення всіх векторів або інший тип нелінійної комбінації. Такий підхід дозволяє врахувати взаємозв'язки між всіма ознаками.

Білінійна комбінація наборів ознак q_{m_1} та a_{m_1} описується за формулою:

$$\begin{aligned} q_{m_1} &= \{q_1, q_2, q_3, \dots, q_l; a_1, a_2, a_3, \dots, a_k\}, a_{m_2} \\ &= \{q_l, a_1, a_2, a_3, \dots, a_k\}, \\ p &= q_{m_1} \times a_{m_2}, \\ p &= \{p_1, p_2, p_3, \dots, p_n\}, p \in R^n. \end{aligned} \quad (6.3)$$

Після цього виконується етап нормалізації результуючого вектора p :

$$\begin{aligned} f_n &= \{1, p_n \geq 0 - 1, \text{або} \\ f &= \{f_1, f_2, f_3, \dots, f_n\}, f \in R^n \\ x &= f \sqrt{|p|}, \\ z &= \frac{x}{\|x\|_2}. \end{aligned} \quad (6.4)$$

При такому підході кількість ознак у наборах q_{m_1} та a_{m_1} повинна бути рівною.

Відповідно, після білінійного об'єднання отриманий вектор ознак подається на повнозв'язний шар для подальшого аналізу. На виході також використовується SoftMax для класифікації.

Ця архітектура є обчислювально складнішою та потребує більшого обсягу даних для навчання. Відповідно, архітектура (Рис. 6.2(a)) підходить для простих задач, де важлива лише сукупність ознак із різних джерел, а архітектура (Рис.

6.2(b)) краще працює, якщо між ознаками різних входів існує складна взаємозалежність.

У традиційних CNN різні розміри ядер застосовуються послідовно для виявлення різноманітних ознак. На противагу цьому, Inception використовує принцип паралельної обробки, що дозволяє одночасно отримувати кілька векторів ознак.

У контексті багатовимірного аналізу мультимодальних даних, архітектури, подібні до Inception, використовують підхід паралельної обробки для одночасного аналізу різних аспектів даних. Замість застосування фіксованого розміру «ядер» або функцій для обробки, такі архітектури включають декілька паралельних «гілок» або «міні-мереж». Кожна з цих гілок виконує аналіз через власну специфічну призму, забезпечуючи багатовимірний погляд на дані.

Цей підхід особливо важливий для мультимодальних даних, оскільки кожна модальність може мати свої унікальні особливості. Паралельні гілки дозволяють одночасно враховувати різні властивості даних, такі як часові ряди (наприклад, ЕЕГ і ЕКГ), структурні особливості (МРТ), числові показники (клінічні дані) або акустичні характеристики (аудіо). Кожна гілка фокусується на своєму наборі функцій, які потім інтегруються для формування єдиного представлення.

Таким чином, архітектура Inception дозволяє ефективно враховувати різноманітність властивостей мультимодальних даних, забезпечуючи їх комплексний аналіз та сприяючи підвищенню точності моделі.

У багатовимірному аналізі мультимодальних даних модуль Inception функціонує як багатофункціональний вузол. Замість послідовного підходу він виконує кілька операцій обробки паралельно, наприклад, застосування згорток різних розмірів (1×1 , 3×3) для вилучення різних типів характеристик. Це дозволяє одночасно отримувати кілька наборів ознак із різних модальностей, таких як ЕЕГ, ЕКГ, МРТ, клінічні дані та аудіосигнали (Рис. 6.3).




Рис. 6.3. Проста версія Inception модуля (використання паралельних операцій)

Після виконання паралельних операцій усі отримані ознаки об'єднуються в єдиний набір характеристик, що сприяє підвищенню точності аналізу. Незважаючи на те, що вихідні розміри ознак для кожної операції можуть відрізнятися через різні розміри ядер, вони уніфікуються за допомогою техніки вирівнювання розмірів, що дозволяє створити єдину матрицю характеристик для подальшого аналізу.

Модуль Inception зі зменшенням розмірності, використовуючи згортки 1×1 перед згортками 3×3 і 5×5 , дозволяє зменшити розмірність вхідних даних (Рис. 6.4). Це особливо корисно для багатовимірного аналізу мультимодальних даних, оскільки знижує обчислювальні вимоги та підвищує точність шляхом зосередження на важливих піксельних або точкових характеристиках.

Модифікована архітектура, така як Inception ResNet v1, включає «залишкові з'єднання» (residual connections), що забезпечують стабільність потоку градієнтів навіть при роботі з великими багатовимірними даними. Завдяки цьому можна інтегрувати ознаки з різних модальностей, зберігаючи узгодженість даних, що дозволяє ефективно працювати навіть із глибокими та складними наборами даних.




Рис. 6.4. Inception модуль зі зменшенням розмірів (зменшення розмірності)

Цей підхід дозволяє вирішувати завдання аналізу мультимодальних даних, наприклад, визначення когнітивного стану пацієнтів або прогнозування ризику захворювань, використовуючи широкий спектр параметрів з різних джерел (Рис. 6.5).

Модель Inception ResNet v1, наведена на рисунку 6.5, адаптується до багатовимірного аналізу мультимодальних даних, починаючи з вхідного обсягу даних із різних модальностей, таких як зображення, часові ряди або категорійні ознаки. У базовій формі модель може працювати з модальностями, представленими у вигляді багатовимірних структур, наприклад, зображення МРТ розміром 160x160x3 або векторами ознак, отриманими з ЕЕГ, ЕКГ, аудіоданих і клінічних показників.

На початкових етапах (Рис. 6.5) модель зосереджується на вилученні базових ознак, таких як просторові або часові закономірності. Цей процес включає перетворення даних через згорткові операції та об'єднання (pooling), що дозволяє зменшити розмірність вхідних даних до спрощеного багатовимірного представлення. Наприклад, дані ЕЕГ або ЕКГ можуть бути перетворені у векторні представлення з меншою розмірністю, але збереженням критичних ознак, таких як частотні ритми чи варіабельність серцевого ритму.




Рис. 6.5. Архітектура Inception Resnet v1 моделі

Також модель включає блоки Inception-ResNet-A, Inception-ResNet-B і Inception-ResNet-C, які адаптовані для аналізу ознак із різних модальностей. Ці блоки використовують концепцію паралельного вилучення ознак, як у традиційних модулях Inception, але доповнюють її залишковими зв'язками (residual connections), які зберігають стабільність моделі та забезпечують точніше представлення багатовимірних даних.

Для мультимодального аналізу ці блоки можуть бути спеціально налаштовані:

- ЕЕГ та ЕКГ для розпізнавання шаблонів хвиль або комплексів QRS.
- МРТ при виділенні локальних характеристик, таких як інтенсивність або об'єм тканин.
- Аудіо для частотних та амплітудних патернів.
- Клінічні дані для оцінки ризиків та кореляцій між змінними.

Результат роботи цих блоків – це компактне багатовимірне представлення даних із різних модальностей, що підготовлене для подальшого аналізу.

Після вилучення ознак модель використовує стратегію глобального об'єднання середніх значень (max pooling), що забезпечує консолідацію вилучених ознак у єдине представлення. Цей етап інтегрує інформацію з різних модальностей у зручний формат для аналізу або класифікації. Наприклад, інтеграція амплітуд ЕЕГ, варіабельності серцевого ритму із ЕКГ, інтенсивності з МРТ та категорійні дані з клінічної бази даних.

На завершальному етапі модель переходить до класифікаційного блоку, який відповідає за прийняття рішень і визначенні результату аналізу. Цей блок включає такі компоненти:

1. Лінійний шар ($1792 \rightarrow 512$), який зменшує багатовимірний вектор ознак до 512 компонентів.
2. BatchNorm1D (512), що нормалізує ознаки для покращення стабільності моделі.
3. Лінійний шар ($512 \rightarrow \text{num\_classes}$), який визначає клас або стан пацієнта (наприклад, здоровий/патологія).

Ця архітектура забезпечує ефективну інтеграцію ознак із кількох модальностей, дозволяючи проводити точний аналіз багатовимірних медичних даних.

Класифікаційний блок у базовій архітектурі Inception ResNet v1 починається зі щільного лінійного перетворення, яке перетворює вектор ознак із високою розмірністю (наприклад, 1792) у компактне багатовимірне представлення (512-вимірний вектор). Це дозволяє вибрати найбільш значущі ознаки із широкого набору функцій, витягнутих із таких модальностей, як ЕЕГ, ЕКГ, МРТ, аудіо та клінічні дані, тим самим, зменшити кількість обчислень для оптимізації прогнозування.

Далі застосовується шар пакетної нормалізації (Batch Normalization), який забезпечує стабільність значень у векторі ознак та прискорює навчання і мінімізує ризик перенавчання.

Фінальним кроком є лінійний рівень, який перетворює ознаки в кінцеві оцінки прогнозу для кожного класу (наприклад, стан пацієнта, когнітивний статус, ризик серцево-судинних захворювань).

У багатовимірному аналізі мультимодальних даних можна розглянути альтернативну архітектуру, взятую з класифікаційним блоком Fastai (Рис. 6.6). Він зосереджується на оптимальному використанні ознак, закодованих у картах властивостей (feature maps), для створення узгодженого прогнозу. Кожна модальність може бути представлена окремими вагами, що підвищує точність прогнозування для комплексних медичних сценаріїв.



Рис. 6.6. Етапи процесу класифікаційного блоку Fastai

В таблиці 6.1 представлені два підходи до класифікаційних блоків (оригінальний Inception ResNet v1 та блок Fastai), акцентуючи увагу на їхніх характеристиках і можливостях інтеграції даних для багатовимірного аналізу мультимодальних даних.

Таблиця 6.1

Порівняльний аналіз підходів Inception ResNet v1 та Fastai

Параметр	Оригінальний блок Inception ResNet v1	Блок Fastai
Вхідний вектор	1792	Залежить від кількості модальностей
Лінійне перетворення	1792 → 512	Гнучке зменшення розмірності
Пакетна нормалізація	BatchNorm1D (512)	BatchNorm1D для кожної модальності
Фінальний шар	512 → num_classes	Гнучке налаштування
Застосування до мультимодальних даних	Часткове	Повна інтеграція

Представлені в таблиці 6.1 характеристики підходу Inception ResNet v1 забезпечують базову інтеграцію модальностей із фіксованими параметрами, що підходить для традиційних задач. Натомість блок Fastai пропонує кращу гнучкість і адаптацію до мультимодальних даних, дозволяючи більш ефективно враховувати специфіку кожної модальності. Це робить його ефективним вибором для задач, пов'язаних із багатовимірним аналізом мультимодальних даних.

Ці блоки відіграють ключову роль у багатовимірному аналізі мультимодальних даних, дозволяючи врахувати специфіку кожної модальності та інтегрувати їх у єдину прогнозну модель.

У сфері багатовимірного аналізу мультимодальних даних було розроблено різноманітні архітектури нейронних мереж, спрямовані на ефективну інтеграцію та аналіз різних типів інформації. Хоча Inception ResNet v1 досягає високої ефективності в обробці візуальних даних, DenseNet121 стає потужним інструментом для обробки аудіоданих, представлених у вигляді спектрограм, і може бути адаптований для роботи з іншими модальностями.

На відміну від підходу Inception ResNet v1, що зосереджується на балансі між глибиною та шириною мережі, архітектура DenseNet121 орієнтована на збереження й максимальне використання інформації шляхом тісного зв'язку між усіма шарами. Глибокі нейронні мережі часто стикаються з проблемами втрати інформації через велику кількість шарів, що збільшує відстань між вхідними та вихідними сигналами. Це ускладнює обчислення градієнтів і може призводити до втрати важливих ознак під час аналізу.

DenseNets реалізують концепцію повторного використання ознак (feature reuse), що дозволяє створювати ефективніші моделі з меншою кількістю параметрів, підкреслюючи раціональний підхід до проектування. Це особливо важливо для багатовимірного аналізу мультимодальних даних, де інформація з різних модальностей інтегрується в єдину модель.

Нижче наведені основні концепти DenseNet121 у контексті мультимодальних даних:

1. Традиційні нейронні мережі прямого зв'язку (feed forward) вихід кожного шару передається як вхід наступного шару після виконання операцій згортки, об'єднання (pooling), пакетної нормалізації та активації. Рівняння (6.5) виглядає наступним чином:

$$x_l = H_l(x_{l-1}), \quad (6.5)$$

де H_l – функція обробки (наприклад, згортка або pooling).

2. Розширення в ResNet додає пропускові зв'язки (skip connections), що покращує потік градієнтів. Рівняння (6.6) модифікується:

$$x_l = H_l(x_{l-1}) + x_{l-1}. \quad (6.6)$$

3. DenseNet121 змінює підхід, об'єднуючи (concatenating) вихідні карти ознак із вхідними замість підсумовування. Це дозволяє кожному шару мати доступ до всіх попередніх карт ознак:

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]). \quad (6.7)$$

4. Для забезпечення сумісності розмірів карт ознак DenseNet121 організовано в DenseBlocks, де розміри карт залишаються незмінними, але між блоками додаються перехідні шари (transition layers). Ці шари виконують: пакетну нормалізацію, згортку 1×11 та об'єднання 2×22 , щоб зменшити дискретизацію.

5. Оскільки карти ознак об'єднуються, то кількість каналів зростає з кожним шаром. Для шару l кількість каналів можна обчислити за формулою:

$$k_l = k_0 + k \cdot (l - 1), \quad (6.8)$$

де k – це швидкість зростання, яка визначає, скільки нової інформації додається на кожному рівні.

6. У контексті мультимодального аналізу DenseNet121 дозволяє інтегрувати різні типи ознак (наприклад, альфа-хвилі з ЕЕГ, варіабельність серцевого ритму з ЕКГ, об'єм тканин з МРТ) у єдину мережу. Такий підхід забезпечує: покращений потік інформації між шарами, глибший аналіз даних та можливість ефективної інтеграції числових і категорійних ознак.

На рисунку 6.7 наведено приклад моделі DenseNet121 для мультимодальних даних.




Рис. 6.7. Приклад моделі DenseNet121 для мультимодальних даних

Ця модель забезпечує високоякісний аналіз взаємозв'язків між модальностями, а також дозволяє масштабувати систему для роботи з великими наборами даних. На рисунку можна побачити, як кожен новий щільний блок у моделі DenseNet121 додає карти ознак до попереднього блоку, забезпечуючи збереження інформації на всіх рівнях. Це об'єднання називають обходом підключенням (bypass connection), що дозволяє поєднувати нову інформацію з уже існуючими даними з попередніх рівнів. Темп зростання в 32 карти ознак є ключовим параметром, що визначає розширення мережі.

У щільному блоці обсяг карт ознак залишається постійним, а кількість фільтрів збільшується. Кожен шар додає 32 нові карти ознак до попередніх, що пояснює розширення розміру блоку від 64 до 256 після шести шарів. Перехідний блок використовується для зменшення обсягу даних і розміру карт ознак. Це досягається за допомогою згортки 1×11 із 128 фільтрами, після чого застосовується об'єднання 2×22 з кроком 2, що зменшує обсяг даних удвічі.

На рисунку 6.8 зображено, як у кожному щільному шарі використовується згортка 1×11 із 128 фільтрами для зменшення розміру карт ознак, після чого згортка 3×33 додає 32 карти ознак, що відповідає темпу зростання. Ця комбінація забезпечує ефективне поєднання нової інформації з існуючими картами ознак.




Рис. 6.8. Повне схематичне зображення мережі DenseNet121

Архітектура, наведена на рисунку 6.8, дозволяє здійснювати багаторівневий аналіз мультимодальних даних, забезпечуючи збереження як унікальних, так і спільних ознак кожної модальності. Завдяки здатності працювати з різними джерелами даних, DenseNet121 ефективно інтегрує часові, просторові та категорійні ознаки в єдину модель для аналізу стану пацієнтів або прогнозування.

Для аналізу часових рядів ЕЕГ та ЕКГ використані спеціалізовані моделі. Відповідно часові ряди ЕЕГ представляють активність мозкових хвиль у часі, що робить їх складними для аналізу. Тому для їх обробки застосовується модель Long Short-Term Memory (LSTM). Це тип рекурентної нейронної мережі (RNN), яка зберігає інформацію про довготривалі залежності. Формально, модель обчислюється: $h_t = LSTM(x_t, h_{t-1}, c_{t-1})$, де x_t – це амплітуда вхідного сигналу в момент часу t : $X = \{x_1, x_2, \dots, x_t\}$, h_t – стан пам'яті, а c_t – стан комірки, які дозволяють зберігати та відкидати інформацію залежно від контексту. Застосування моделі Long Short-Term Memory (LSTM) визначає когнітивні стани, такі як розслаблення або стрес, через аналіз альфа-хвиль та бета-ритмів.

Для визначення мозкової активності під час виконання когнітивних завдань застосовується модель Temporal Convolutional Networks (TCN), яка

обробляє часові ряди за допомогою згорткових шарів, що аналізують як короткострокові, так і довготривалі залежності. Для цього використовуються каузальні згортки, щоб забезпечити залежність майбутніх станів від минулих: $y_t = \sum_{i=0}^{k-1} w_i x_{t-i}$, де w_i – ваги згортки.

Для дослідження синхронізації мозкових хвиль ЕЕГ у різних станах застосовується Transformer-based Models, яка використовує механізм уваги (attention), щоб виявити ключові моменти в сигналі. Модель оцінює ваги уваги: $Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$, де Q, K, V – запити, ключі та значення, пов'язані з даними.

Для обробки часової послідовності ЕКГ, що відображає електричну активність серця, застосовується Convolutional Neural Networks (CNN). Модель ефективно виділяє локальні ознаки, такі як піки QRS, із сигналів ЕКГ. Формально, сигнал подається через згортковий шар: $f(x) = \sigma\left(\sum_{i=1}^k w_i x_{t-i} + b\right)$, де w_i – ядро згортки, а σ – функція активації.

Додатково Bidirectional LSTM (BiLSTM) аналізує сигнал у двох напрямках – прямому ($h_t^{\rightarrow}$) та зворотньому ($h_t^{\leftarrow}$). Формально процес проходження має вигляд: $h_t = [h_t^{\rightarrow}, h_t^{\leftarrow}]$.

Для точного визначення меж комплексів QRS застосовується Hybrid CNN-LSTM Architectures, що поєднує переваги локального вилучення ознак (CNN) та обробки послідовностей (LSTM). Формально модель має вигляд: $h_t = LSTM(CNN(x_t))$. Її застосовують для моніторингу тривалих патологій, таких як тахікардія чи фібриляція передсердь.

Додатковими методами для обробки сигналів ЕКГ є методи Wavelet Transform + Machine Learning Models.

Розкладання сигналу на частотні компоненти за допомогою вейвлет-перетворення представлено: $W(a, b) = \int_{-\infty}^{\infty} x(t)\psi\left(\frac{t-b}{a}\right)dt$, де a – масштаб, а b – зсув.

Автоенкодери зменшують розмірність сигналів, зберігаючи важливу інформацію. Відповідно розрахується компресія: $h = \sigma(W_x + b)$, та відновлення: $x' = \sigma(W^T h + b')$ для виявлення аномалій у сигналах.

Як приклад реалізації інтеграції модальностей можна розглянути застосування LSTM-мережі для обробки сигналів ЕЕГ з метою аналізу альфаритмів і виявлення стану розслаблення. Паралельно може бути використана CNN-модель для обробки ЕКГ і визначення показників варіабельності серцевого ритму для оцінки рівня стресу.

Після обробки кожна з моделей формує векторне представлення відповідної модальності, яке згодом може бути об'єднане у єдиний багатовимірний вектор. Такий вектор дозволяє здійснювати подальший узагальнений аналіз у межах багатомодальної системи.

Використання LSTM і CNN обумовлене їх ефективністю при роботі з часовими рядами, оскільки вони здатні виділяти ключові ознаки, які надалі інтегруються з даними з інших джерел у рамках багатовимірного аналізу.

6.2. Методика побудови класифікаційних моделей на основі уніфікованого простору ознак

Уніфікований простір ознак, сформований на принципі інтеграції мультимодальних ознак (Feature-level fusion), є основою для побудови інтегрованих класифікаційних моделей. У попередньому розділі було детально розглянуто підходи до уніфікації, інтеграції та трансформації цього простору, включаючи етапи нормалізації, імпутації пропущених значень, вирівнювання часових шкал, усунення мультиколінеарності та редукції розмірності за допомогою методів, таких CDA.

Цей багатовимірний простір ознак дозволяє здійснювати високоточну класифікацію клінічних станів, зокрема виявлення ризику інсульту. У межах Розділу 5 була реалізована двокласова класифікація, яка дала змогу протестувати ефективність побудованого простору в задачі розмежування станів інсульт / неінсульт.

Проте в умовах практичного медичного застосування виникає потреба в більш детальній диференціації станів пацієнтів. З огляду на це, в розділі 5 здійснено розширення задачі класифікації до п'яти клінічних категорій. Такий підхід дозволяє не лише виявляти наявність патології, а й проводити точніший клінічний аналіз, що відповідає реаліям практичної діагностики.

Для цього, у процесі підготовки даних для задачі мультикласової класифікації станів пацієнтів було здійснено розширення початкового датасету (Додаток В). Зокрема, до базового набору ознак, що об'єднував дані з модальностей ЕКГ, ЕЕГ, МРТ та клінічної інформації, було додано п'ять нових спеціалізованих медичних показників. Це дозволило точніше диференціювати пацієнтів за клінічними категоріями та сформувавши класи відповідно до встановлених медичних критеріїв.

У оновленому датасеті було додано такі ознаки:

1. Ischemia_score – індекс ішемічного ураження, що відображає ступінь ішемії на основі результатів МРТ;
2. Hemorrhage_score – оцінка наявності або тяжкості крововиливу, критична для діагностики геморагічного інсульту;
3. Poststroke_score – оцінка стану пацієнта після перенесеного інсульту (враховує час, що минув, та інші клінічні показники);
4. EEG_anomaly_score – індекс відхилень в активності мозку, зафіксованих за допомогою ЕЕГ (наприклад, підвищена θ -активність);
5. Clinical_stability_index – узагальнена оцінка стабільності клінічного стану пацієнта, що включає динаміку симптомів та інші фактори.

Додавання цих ознак дозволило створити логічно обґрунтовану систему правил для автоматичного формування міток п'яти клінічних класів:

- Здоровий;
- Ішемічний інсульт;
- Геморагічний інсульт;
- Постінсультний стан;
- Інші нейропатології.

Додаткові дані було сформовано на основі уже наявних змінних та зовнішніх аналітичних правил (у межах медичного експертного підходу). Було сформовано п'ять нових ознак:

Назва ознаки	Метод формування
Ischemia_score	Обчислено за правилами оцінки ішемії на основі інтенсивності сигналів МРТ
Hemorrhage_score	Виведено на основі локалізації та яскравості крововиливів (MRI_bleed)
Poststroke_score	Інтегрує час після інсульту, стабільність та рівень ураження
EEG_anomaly_score	Побудовано на основі потужності θ -хвиль, ентропії та спектру
Clinical_stability_index	Розраховано за допомогою шкал стабільності стану (зокрема, через status_flag)

Формально, новий датасет було отримано через процедуру злиття:

$$D_{extended} = D_{base} \cup F_{derived},$$

де:

- $D_{base} \in R^{n \times p}$ – початковий набір даних із n пацієнтів та p ознаками;
- $F_{derived} \in R^{n \times 5}$ – новий фрейм із п'яти нових ознак, створений для кожного пацієнта;
- результатом є $D_{extended} \in R^{n \times (p+5)}$.

На етапі узгодження та перевірки ознак у мультимодальному просторі було здійснено комплексну перевірку та узгодження ознак, що входять до формалізованого представлення мультимодального медичного профілю пацієнта. Це дозволило забезпечити цілісність, логічну узгодженість та коректність структури даних перед подальшим аналізом і моделюванням.

Перш за все, було перевірено відсутність конфліктів у назвах ознак. Це включало виявлення дублікатів, некоректних або неоднозначних найменувань, що могли б призвести до плутанини під час обробки даних. Усі ознаки були чітко ідентифіковані та уніфіковані відповідно до стандартизованої номенклатури.

Для забезпечення порівнюваності числових значень між різними модальностями було проведено масштабування ознак до єдиної шкали. У тих випадках, де спостерігались значні відмінності в діапазонах значень, застосовувалась Z-нормалізація. Це дозволило уникнути домінування окремих

параметрів при обчисленні метрик подібності чи трансформації простору. Формально цей процес описувався в п. 5.1.

Отож оновлений датасет є розширеною версією попереднього набору (Додаток В) і містить повну інтеграцію ознак із кількох медичних модальностей (ЕКГ, ЕЕГ, МРТ, клінічні показники), підготовлену для задачі багатокласової класифікації. Структура датасету: кількість записів (пацієнтів): 1000, кількість ознак (колонок): 30. Цільова змінна: *diagnosis* – категоріальна змінна, що кодує п'ять класів: здоровий, ішемічний інсульт, геморагічний інсульт, постінсультний стан, інші нейропатології.

Охарактеризуємо ознаки, за якими формувалася набір даних:

1. ЕКГ-ознаки (ECG): *QT_interval*, *RR_interval*, *QRS_duration*, *P_interval*, *ST_depression*, *HRV*, тип: числові. Відображають часові та амплітудні характеристики електрокардіографічних сигналів.
2. ЕЕГ-ознаки (EEG): *EEG_theta_power*, *EEG_alpha_power*, *EEG_beta_power*, *EEG_gamma_power*, *EEG_entropy*, *EEG_asymmetry*, *EEG_abnormal*, тип: числові (крім *EEG_abnormal*, який є бінарним). Показують спектральну активність мозку, зокрема розподіл потужностей у різних діапазонах частот.
3. МРТ-ознаки (MRI): *MRI_infarct_score*, *MRI_bleed_score*, *MRI_index*, тип: числові. Кількісні показники патологій за даними магнітно-резонансної томографії.
4. Клінічні ознаки: *Age*, *Sex*, *Blood_Pressure*, *Cholesterol*, *Glucose*, *Heart_Disease*, *Stroke_history*, *Time_after_stroke*, *Clinical_status*, тип: числові, категоріальні, бінарні. Відображають анамнез, демографію, супутні захворювання та клінічні параметри.

Для формування цільової змінної *diagnosis* застосовувалися медично обґрунтовані правила класифікації, які враховували комплекс клінічних та інструментальних параметрів пацієнта. Зокрема, до ключових факторів належали:

- історія інсульту (*Stroke_history*),

- показники ураження мозкової тканини за результатами МРТ (MRI_infarct_score та MRI_bleed_score),
- наявність патологічних змін в ЕЕГ (EEG_abnormal),
- поточний клінічний статус пацієнта (Clinical_status),
- тривалість часу, що минув з моменту інсульту (Time_after_stroke).

Порогові значення для виявлення ішемічного та геморагічного інсульту встановлювалися на основі відповідних складених скорів, що інтегрують кількісну інформацію з різних модальностей.

На основі цих критеріїв було реалізовано формалізований підхід до побудови цільових міток, призначених для багатокласової класифікації пацієнтів згідно з п'ятьма клінічними категоріями. У процесі побудови міток застосовувалися правила логічного поділу, які враховували ключові показники мультимодального профілю. Відповідні умови класифікації охоплюють історію інсульту, вікові критерії, а також значення клініко-функціональних індексів, таких як:

- EEG_anomaly_score – інтегральний показник аномалій у електроенцефалограмі;
- Ischemia_score, Hemorrhage_score, Poststroke_score – кількісні індекси виявлення ішемічних, геморагічних змін та постінсультного стану відповідно;
- Clinical_stability_index – оцінка загального клінічного стабільного стану пацієнта.

На основі аналізу набору даних (Додаток В) структура уніфікованого вектора ознак має чітку відповідність до мультимодальних медичних блоків. Нижче наведено деталізовану схему побудови цього вектора одного пацієнта для подання на вхід класифікаційній моделі:

$$X_{unified}^1 = [0,25, -0,41, 1,10, 0,45, -0,78, 0,30, 1,04, 0,55, -0,12, 0,77, 1,30, 0,22, 0,85, -0,35, 0,60, 1,12, 0,48, -0,72, 0,92, 1,0, 1,0, 0,0, 1,0, 0,22, 0,78, 0,45, 0,63, 0,58, 0,31, 1,0]$$

Для забезпечення узгодженості та об'єктивності класифікації, як еталонні порогові значення (threshold) для кожного індикатора були обрані середні

значення по вибірці (mean). Такий підхід дозволяє формалізувати поділ на класи згідно з емпіричним розподілом ознак і водночас уникнути жорстких апріорних меж, що підвищує гнучкість і адаптивність моделі (Табл. 6.2).

Таблиця 6.2

Зведена таблиця порогових значень ознак

Показник	Середнє (mean)	Стандартне відхилення (std)	min	25 %	50 %	75 %	max	Встановлений поріг (threshold)
EEG_anomaly_score	4,84	0,55	3,41	4,45	4,82	5,19	6,79	4,83
Ischemia_score	1,25	0,41	-0,28	0,98	1,25	1,53	3,05	1,25
Hemorrhage_score	0,75	0,10	0,40	0,68	0,75	0,82	1,16	0,75
Poststroke_score	33,86	6,55	22,5	28,5	34,0	39,5	45,0	33,86
Clinical_stability_index	24,15	4,06	12,89	21,27	24,11	26,87	34,51	24,15

На основі зазначених порогів реалізовано правила віднесення до класів (у порядку пріоритету):

1. Здорові пацієнти (Healthy):

- Відсутність інсульту: $\text{Stroke\_history} == 0$;
- Вік: $\text{Age} < 60$;
- Значення індикаторів нижче порогу: $\text{EEG\_anomaly\_score} < 4,83$;
 $\text{Ischemia\_score} < 1,25$; $\text{Hemorrhage\_score} < 0,75$.

2. Ішемічний інсульт (Ischemic):

- $\text{Stroke\_history} == 1$;
- $\text{Ischemia\_score} \geq 1,25$;
- $\text{EEG\_anomaly\_score} \geq 4,83$.

3. Геморагічний інсульт (Hemorrhagic):

- $\text{Stroke\_history} == 1$;
- $\text{Hemorrhage\_score} \geq 0,75$.

4. Постінсультний стан (Poststroke):

- $\text{Stroke\_history} == 1$;
- $\text{Poststroke\_score} \geq 33,86$;
- $\text{Clinical\_stability\_index} \geq 24,15$.

5. Інші неврологічні порушення (OtherNeuropathology):

- Всі інші випадки, що не відповідають жодному з попередніх критеріїв.

На попередньому етапі було проведено аналіз розподілу пацієнтів за діагностичними класами у відповідності до п'яти визначених категорій. Результати розподілу наведено в таблиці 6.3.

Таблиця 6.3

Розподіл класів	
Клас	Кількість спостережень
OtherNeuropathology	579
Hemorrhagic	193
Ischemic	118
Poststroke	87
Healthy	23

Аналіз розподілу діагностичних класів виявив суттєву нерівномірність вибірки. Найчисельнішим є клас OtherNeuropathology (579 спостережень), що становить абсолютну більшість. Натомість клас Healthy містить лише 23 записи, тобто менше ніж 3 % від загальної кількості. Подібна диспропорція може призвести до зміщення моделей у бік переважно представлених класів, тоді як менш чисельні (особливо Healthy, Poststroke, Ischemic) залишаються недостатньо репрезентованими. У результаті це підвищує ризик низької чутливості (recall) для критично важливих, але рідкісних клінічних станів.

Щоб мінімізувати негативний вплив дисбалансу на ефективність класифікаційних моделей, було застосовано метод балансування вибірки через апсемплінг (over-sampling). Суть цього підходу полягає у збільшенні кількості спостережень у кожному з малочисельних класів до рівня найбільшого. У даному випадку референтним був обраний клас OtherNeuropathology (579 записів). Для класів Healthy, Ischemic, Hemorrhagic, Poststroke було застосовано випадкову вибірку з поверненням (метод `resample(replace=True)`), що дозволило сформувати збалансовану навчальну вибірку з рівною кількістю прикладів для кожного класу.

Цей підхід покращив загальну збалансованість моделі, підвищив чутливість до малочисельних категорій і забезпечив однакову важливість класів

під час навчання. Разом з тим, для прийняття зваженого рішення щодо доцільності балансування було проведено порівняльний аналіз підходів зі збереженням і без збереження початкового розподілу:

Характеристика	Незбалансовані класи	Збалансовані класи (апсемплінг)
Переваги	– Зберігається реальний розподіл класів. – Немає дублювання даних, отже, зменшується ризик перенавчання. – Моделі типу градієнтного бустингу (наприклад, XGBoost, LightGBM) добре працюють з незбалансованими даними, якщо правильно задати ваги.	– Моделі отримують однакову увагу до кожного класу, особливо до малопредставлених. – F1-score, recall та precision по кожному класу зростають, якщо правильно валідовано. – Це особливо корисно, якщо мета – класифікація рідкісного стану.
Недоліки	– Моделі можуть "ігнорувати" малочисельні класи, бо оптимізаційна функція зосереджується на загальній точності. – Чутливість (recall) та F1 для малочисельних класів буде низькою.	– Апсемплінг створює дублікати, що може спричинити overfitting. – Результати можуть втратити зв'язок із реальними пропорціями у популяції (якщо це має клінічне значення). – Для великих наборів апсемплінг може бути неефективним за обсягом пам'яті.

Залежно від цілей дослідження, обидва підходи мають право на застосування. Якщо пріоритетом є виявлення рідкісних патологій та аналіз якості класифікації в межах кожного класу, доцільно застосовувати балансування. Натомість, якщо важливо зберегти реалістичний клінічний розподіл, то краще зберігати природний баланс, але компенсувати його інструментально.

У таких випадках як альтернативу апсемплінгу можна використовувати:

1. Класові ваги (class weights) – у моделях SVM, Random Forest;
2. Альтернативні метрики, що враховують дисбаланс (macro-F1, per-class recall, balanced accuracy);
3. SMOTE або ADASYN – методи синтетичного генерації нових прикладів у межах малочисельних класів.

Для ілюстрації підходу з використанням класових ваг нижче наведено приклад таблиці ваг 6.4 для кожного класу, розрахованих за формулою:

$$w_c = \frac{N_{\text{заг}}}{k \cdot N_c}, \quad (6.9)$$

де $N_{\text{заг}}$ – загальна кількість спостережень, k – кількість класів, N_c – кількість спостережень класу c .

Таблиця 6.4

Розрахунок ваг класів

Клас	Кількість спостережень	Вага класу
OtherNeuropathology	579	0,345
Hemorrhagic	193	1,036
Ischemic	118	1,695
Poststroke	87	2,299
Healthy	23	8,696

Таким чином, менш представлені класи отримують пропорційно більшу вагу при навчанні моделі, що частково компенсує ефект дисбалансу без необхідності створення дублікатів або зміни структури вибірки.

Розмірність уніфікованого вектора ознак ($X.\text{shape} = N \times 30$) залишається сталою, незалежно від обраної стратегії боротьби з дисбалансом – чи то апсемплінг, чи вагове коригування. Така стабільність формату входу забезпечує гнучкість при підключенні різних моделей та спрощує реалізацію крос-валідації.

Водночас, незалежно від обраної стратегії подолання дисбалансу, важливим етапом підготовки до моделювання є аналіз внутрішньої структури ознак. Він дозволяє виявити надлишкові, дубльовані або тісно пов'язані між собою параметри, що можуть впливати на стабільність і продуктивність класифікаційної моделі.

Одним із ключових інструментів такого аналізу є побудова кореляційної матриці Пірсона, яка відображає силу та напрямок зв'язку між числовими ознаками уніфікованого простору. Цей підхід дає змогу оцінити ступінь мультиколінеарності та логічну узгодженість між параметрами, що походять з різних джерел (модальностей) медичних даних.




Рис. 6.9. Інтерпретація кореляційної матриці

На рисунку 6.9 відображено силу та напрямок зв'язку між усіма числовими ознаками уніфікованого простору. Виділимо основні означення:

- Висока кореляція між Ischemia_score та Hypointense_volume ($r = 0,99$) свідчить про можливу надмірність або дублювання інформації щодо ішемічних уражень у МРТ-профілі.
- Схожий висновок стосується пари Poststroke_score та Age ($r = 0,999$) – високий зв'язок може вказувати як на вікову обумовленість постінсультного стану, так і на залежність алгоритму оцінки Poststroke_score від віку пацієнта.
- Потужна позитивна кореляція між Clinical_stability_index та HRV ($r = 0,83$) підтверджує клінічні закономірності: варіабельність серцевого ритму є важливим індикатором загального стану автономної регуляції.

- EEG_anomaly_score та Alpha_power ($r = 0,75$) – типовий зв'язок для пацієнтів із порушенням мозкової активності, що фіксується у вигляді змін спектральних компонент ЕЕГ.
- Негативна кореляція між Class_OtherNeuropathology та Stroke_history ($r = -0,73$) є очікуваною, оскільки класи взаємовиключні.

Ознаки, що демонструють високий рівень кореляції між собою, можуть містити надлишкову або дубльовану інформацію. Це варто враховувати під час ухвалення рішень щодо зменшення розмірності ознакового простору. Такий підхід дає змогу зберегти максимальний обсяг інформативності за рахунок меншої кількості узагальнених компонент.

У той же час виявлення сильних статистичних зв'язків між окремими ознаками підтверджує внутрішню логіку структури даних і свідчить про достовірність обчислених показників. Це особливо важливо в контексті мультимодального аналізу, де очікується узгодженість між фізіологічними, нейрофізіологічними та клінічними параметрами.

При подальшому моделюванні важливо дотримуватись балансу між інформативністю та мультиколінеарністю. У разі використання моделей, що нечутливі до корельованих ознак (наприклад, глибокі нейронні мережі або дерева рішень), збереження всіх змінних є припустимим. Натомість для лінійних методів або моделей, де мультиколінеарність може впливати на інтерпретованість або стабільність навчання, доцільним є попередній відбір або трансформація ознак.

Для глибшого аналізу структури простору ознак може бути застосований метод головних компонент (РСА), що дозволяє з'ясувати, наскільки сильно наявні кореляції впливають на розмірність і варіативність даних, а також оцінити потенціал їх компактного узагальнення без суттєвої втрати інформації.

Щоб проілюструвати цей підхід, було побудовано графік кумулятивної дисперсії, що показує, яку частку загальної варіативності даних пояснюють головні компоненти.




Рис. 6.10. Кумулятивна дисперсія при PCA

На графіку зображено кумулятивну частку дисперсії, що пояснюється головними компонентами (PCA). Основні спостереження наведені нижче.

Кількість компонент	Кумулятивна частка дисперсії	Пояснення
1	~28%	Лише перша головна компонента містить майже третину всієї інформації
5	~65%	Перші 5 компонент покривають понад половину варіативності
10	~87%	Достатньо 10 компонент, щоб зберегти ~87% всієї інформації
15	~96%	Додаткові компоненти додають дедалі менше інформації

У дослідженні використано набір із 30 числових ознак, які формують узагальнений мультимодальний профіль пацієнта. Такий набір є повним та репрезентативним для опису стану пацієнтів, однак включає потенційно корельовані та надлишкові ознаки. Для виявлення узагальнених трендів у структурі цих ознак і зменшення їх кількості без втрати змістовної інформації було застосовано метод головних компонент (PCA). Цей метод дозволяє трансформувати вихідний набір показників у новий простір меншої розмірності, де кожна компонента є лінійною комбінацією початкових змінних. При цьому компоненти впорядковані за спаданням внеску у загальну дисперсію даних.

Результати PCA показали, що перша головна компонента (PC1) пояснює близько 28 % загальної варіативності. Тобто, тільки одна нова узагальнена змінна (PC1), яка може поєднувати вагомі внески таких показників, як HRV, Age

та Ischemia_score, вже містить майже третину всієї суттєвої інформації про відмінності між пацієнтами.

Перші п'ять компонент у сукупності охоплюють понад 65% змістовної дисперсії. Це означає, що замість 30 окремих ознак можна використовувати лише 5 нових узагальнених характеристик, сформованих на основі важливих комбінацій ознак, наприклад, поєднання спектральних ЕЕГ-показників, вікових та клінічних індексів, структур мозку з МРТ тощо.

Додаткове включення ще п'яти компонент (тобто до 10 загалом) дозволяє зберегти 87 % загальної інформації, що є достатнім для більшості прикладних задач класифікації. При цьому структура ознакового простору значно спрощується, а самі дані стають більш компактними та менш шумовими.

У разі потреби високої точності можна включити до 15 головних компонент, що дозволяє зберегти понад 96 % початкової дисперсії. Це є оптимальним компромісом між повнотою представлення та ефективністю обробки даних.

Таким чином, метод PCA дозволяє значно зменшити розмірність вхідного простору, усуваючи дублювання інформації та покращуючи обчислювальну стабільність моделей. Отримані компоненти є статистично незалежними та формують узагальнений простір, у якому збережено більшість ключових варіацій первинних ознак. Це відкриває можливості для побудови більш компактних, інтерпретованих і точних моделей прогнозування в рамках аналізу мультимодальних медичних даних.

На двовимірній візуалізації (Рис. 6.11 (а)), побудованій на основі перших двох головних компонент (PC1 та PC2) методу головних компонент (PCA), кожен запис у наборі даних представлено у вигляді точки. Її положення на площині визначається значеннями проєкції уніфікованого вектору ознак пацієнта на нову систему координат, що сформована PCA.




Рис. 6.11. а) 2D-Візуалізація головних компонент (PC1 та PC2); б) 3D PCA проекція для п'яти класів стану пацієнта

Ця нова система координат є результатом трансформації початкового багатовимірного простору (з 30 ознак) у простір з меншою розмірністю, зокрема, до двох вимірів (PC1 і PC2). Головні компоненти є лінійними комбінаціями первинних ознак, які побудовані так, щоб максимально зберігати варіативність даних.

- PC1 пояснює найбільшу частку загальної дисперсії та відображає той напрямок у просторі ознак, за яким дані змінюються найбільше. Наприклад, саме ця компонента може містити поєднану інформацію з таких ознак, як Age, HRV, Ischemia_score, тощо.
- PC2 є ортогональною (незалежною) до PC1 і відповідає за другу за значущістю вісь варіацій у даних, яка не покривається першою компонентою.

На графіку 6.11 (а) PCA кожна точка зафарбована відповідно до належності до одного з п'яти клінічних класів: Healthy, Ischemic, Hemorrhagic, Poststroke, OtherNeuropathology. Це дозволяє візуально оцінити розподіл спостережень у компактному узагальненому просторі та визначити ступінь відокремленості між класами.

- Якщо спостерігаються чіткі скупчення точок одного кольору, просторово віддалені від інших – це вказує на наявність латентної (прихованої) структури у даних, яку класифікаційна модель може ефективно виявляти.
- Якщо ж точки різних класів значною мірою накладаються або змішані, наприклад, класи Poststroke та Hemorrhagic, це свідчить про близькість або перетин у мультимодальних профілях, що потенційно ускладнює задачу класифікації.

Таким чином, PCA виконує не лише редукцію розмірності (наприклад, з 30 до двох вимірів, як на рисунку 6.11 (а)), але й дозволяє:

- зменшити обчислювальну складність подальших моделей;
- уникнути впливу мультиколінеарності (надлишкових зв'язків між ознаками);
- виявити приховану структуру в даних;
- візуально оцінити, наскільки ефективно модель зможе розрізнити класи на основі доступних ознак.

Отож, замість того, щоб аналізувати усі 30 первинних ознак, PCA дозволяє скоротити розмірність ознакового простору, залишивши лише ті компоненти, які містять основну інформацію про відмінності між пацієнтами. Наприклад, перші 10 головних компонент охоплюють майже 87% загальної варіативності, а отже, можуть ефективно замінити початковий повний набір без суттєвої втрати інформативності. Це особливо важливо при побудові моделей, оскільки знижує ризик перенавчання, зменшує обчислювальні витрати та покращує інтерпретованість результатів.

Щоб ще більше спростити структуру даних для аналізу (Рис. 6.11 (b)), формуються нові «узагальнені» ознаки, що поєднують у собі інформацію з багатьох первинних показників: PC1, PC2, PC3. Разом ці три компоненти формують новий тривимірний простір, у якому кожен пацієнт представлений у вигляді точки з координатами (PC1, PC2, PC3). Це дозволяє візуалізувати розподіл пацієнтів, оцінити наявність кластерів, перетинів між класами та потенціал для коректної класифікації. У випадку, коли точки різних класів

грубуються в окремі зони, можна стверджувати про наявність латентної структури у даних, що добре виявляється за допомогою PCA.

Мультимодальна модель сформована за принципом інтеграції мультимодальних ознак (Feature-level fusion) була навчена з використанням алгоритму Random Forest із параметром `class_weight='balanced'`, що дозволяє врахувати дисбаланс між п'ятьма клінічними класами.

Для оцінки якості класифікації застосовувалась метрика збалансованої точності (balanced accuracy), яка особливо доречна в умовах нерівномірного розподілу даних по класах.

Навчальні дані були попередньо розділені: 80 % – тренувальна вибірка та 20 % – тестова вибірка, що не використовувалась у процесі навчання, а слугувала для підсумкової оцінки.

У межах тренувальної вибірки додатково здійснювалось розділення на тренувальну та валідаційну підмножини (у пропорції 80:20), що дозволило відстежувати якість моделі на не баченій під час навчання частині даних.

На рисунку 6.12 подано динаміку точності та значення метрики на тренувальних та валідаційних підмножинах під час побудови ансамблю дерев. Результати свідчать про стабільність навчання, узгодженість класифікатора та здатність до узагальнення.

На графіках представлено еволюцію точності (accuracy) та втрат (loss) моделі протягом 50 епох тренування:

- Графік точності демонструє загальної точності моделі під час навчання. На тренувальній вибірці (Train Accuracy) показане поступове зростання точності понад 90% на тренувальних даних, що свідчить про навчання моделі. На валідаційній (Validation Accuracy) також зростає до 88-89 % , але з меншою амплітудою, що вказує на поступове узагальнення моделі.
- Графік втрат показує на Train Loss зниження в міру навчання, що є ознакою мінімізації функції втрат., а на Validation Loss показана подібна динаміка, що підтверджує не перенавчання моделі.




Рис. 6.12. Динаміка точності для мультимодальної моделі інтеграції мультимодальних ознак (Feature-level fusion)

Представлені на рисунку 6.12 графіки свідчать про стабільне навчання моделі та добре узагальнення на валідаційних даних.

Матриця невідповідностей (Рис. 6.13), побудована для задачі багатокласової класифікації на основі п'яти клінічних категорій (Healthy, Ischemic, Hemorrhagic, Poststroke, Other), наочно демонструє ефективність роботи моделі та характер її помилок. У цій матриці рядки відповідають істинним класам пацієнтів, а стовпці – передбаченим модельним класифікаціям. Ідеальним випадком є ситуація, коли всі значення зосереджені на головній діагоналі, що вказує на повну відповідність між реальними та передбаченими діагнозами.




Рис. 6.13. Матриця невідповідностей для валідаційних даних мультимодальної моделі раннього злиття

З аналізу видно, що модель безпомилково класифікує пацієнтів із класу OtherNeuropathology – усі 200 випадків були правильно віднесені до відповідної

категорії. Клас Healthy також розпізнається надійно: у 190 з 200 випадків модель зробила правильну класифікацію, лише в 10 випадках (п'ять прикладів класифіковано як Ischemic, ще п'ять – як OtherNeuropathology) допущено помилки.

Класи Ischemic та Hemorrhagic демонструють добру якість класифікації, що свідчить про високу здатність моделі до розпізнавання, хоча присутні поодинокі перехресні помилки – ішемічні стани іноді плутаються з постінсультними або іншими нейропатологіями. Кілька випадків Poststroke були помилково класифіковані як ішемічний інсульт, але загальна ефективність моделі для цього класу залишається високою.

Ці результати підтверджуються кількісними метриками, поданими в таблиці 6.5, яка відображає значення точності (precision), повноти (recall) та F1-метрики для кожного з п'яти клінічних класів. Найвищу якість класифікації демонструють класи Healthy та Hemorrhagic, які мають ідеальну точність (1,00) та високу повноту (0,95), що свідчить про високу впевненість моделі в цих передбаченнях. Клас Poststroke також показує збалансовану ефективність: precision = 0,951 та recall = 0,975, що свідчить про незначні помилки класифікації при збереженні високої чутливості. Дещо нижчі, але все ще високі результати має Ischemic, для якого точність становить 0,949, а повнота – 0,925, що може бути пов'язано з перехресними ознаками з іншими класами, зокрема Poststroke. Щодо OtherNeuropathology, цей клас має найвищу повноту (1,00), однак точність дещо нижча – 0,909, що свідчить про те, що певна кількість зразків інших класів була помилково віднесена до нього.

Загальна точність моделі становить 96 %, а значення макро- та зважених середніх (macro avg, weighted avg) метрик також підтверджують збалансовану якість класифікації по всіх класах (обидва значення – 0,962). Це свідчить про здатність моделі ефективно працювати навіть в умовах багатокласової постановки задачі з потенційно складними та подібними між собою станами. Така модель може бути використана як додатковий інструмент клінічного

підтримання рішень, допомагаючи лікарям підвищувати точність діагностики у складних випадках.

Таблиця 6.5

Звіт про метрики продуктивності моделі раннього злиття на основі даних валідації

Метрики	Healthy	Hemorrhagic	Ischemic	Other	Poststroke
Precision	1,0	1,0	0,95	0,9	0,95
Recall	0,95	0,95	0,93	1,0	0,98
F1-score	0,97	0,97	0,94	0,95	0,96
Accuracy	0,96				
Macro avg	0,962				
Weighted avg	0,962				

Проведене моделювання класифікації на основі мультимодальних медичних даних підтвердило ефективність підходу раннього злиття ознак з різних джерел у вигляді уніфікованого вектора. Застосування методу головних компонент (PCA) дозволило суттєво зменшити розмірність ознакового простору без втрати інформативності, що позитивно вплинуло на стабільність та швидкодію моделі.

Результати класифікації, зокрема високі показники точності, повноти та F1-метрики (більшість значень $> 0,95$), а також чітка діагональна структура матриці невідповідностей свідчать про здатність моделі достовірно відрізняти між собою різні клінічні стани. Незначні помилки класифікації спостерігались переважно між суміжними або клінічно схожими категоріями, що є очікуваним у медичному контексті.

Загалом, запропонований підхід довів свою практичну доцільність і може бути використаний як основа для побудови автоматизованої системи підтримки діагностичних рішень. Він демонструє високу точність навіть при складній структурі класів і потенційній кореляції між ознаками, зберігаючи гнучкість для подальшого масштабування або адаптації до нових даних.

6.3. Методика побудови класифікаційних моделей на основі метарішень у мультимодальних медичних системах

Зважаючи на складну й гетерогенну природу мультимодальних медичних даних, ефективне представлення й інтеграція інформації з різних джерел є важливим в задачах клінічної діагностики. Якщо у попередньому підрозділі було реалізовано підхід за принципом інтеграції мультимодальних ознак (Feature-level fusion), який передбачав об'єднання всіх ознак у єдиний уніфікований вектор на вході до моделі, то в цьому підрозділі розглянуто альтернативний принцип багатовимірної аналізу мультимодальних даних оснований на принципі інтеграції модальних моделей (Model-level fusion).

Модель інтеграції модальних моделей передбачає попередню обробку кожної модальності окремими нейронними моделями. Результати цих модальних блоків далі агрегуються на рівні більш високої абстракції, зазвичай у вигляді інтегрованого простору логітів, ембедінгів або проміжних прогнозів. Такий підхід дозволяє зберегти специфіку кожного типу даних, а також підвищити гнучкість і точність моделі в умовах мультиколінеарності, нерівномірної якості чи неповноти окремих модальностей.

У межах реалізованої архітектури моделі кожна модальність проходить окремий шлях обробки (через блоки CNN або LSTM), після чого результати об'єднувались на спільному рівні класифікаційного шару. Це дозволило моделі не лише зберігати індивідуальні характеристики різних джерел, але й ефективно інтегрувати їх у загальне рішення щодо стану пацієнта.

На рисунку В.1 (Додатку В) представлено архітектуру моделі, сформованої за принципом інтеграції моделей модальностей, яка реалізує багатоканальну обробку мультимодальних медичних даних для задачі п'ятикласової класифікації клінічного стану пацієнта. Кожна модальність обробляється окремим шляхом із власною архітектурою, що дозволяє зберігати специфічні особливості джерела, після чого результати узагальнюються шляхом

конкатенації модальних представлень (енбедінгів) та подаються на фінальний класифікаційний блок.

Отож, формально модель Model-level fusion відповідає наступним етапам:

- M_i – локальна модель для i -ї модальності;
- $\vec{p}_i = M_i(\vec{x}_i) \in R^5$ – вектор ймовірностей по класах;
- $\vec{z} = [\vec{p}_1, \vec{p}_2, \dots, \vec{p}_k] \in R^{5k}$ – метапростір;
- M_{meta} – метакласифікатор;
- Остаточне рішення: $\hat{y} = M_{meta}(\vec{z})$.

Описаний вище принцип багатовимірною аналізу мультимодальних даних, що ґрунтується на принципі інтеграції моделей модальностей, поетапно розкритий на прикладі створеного набору даних (Додаток В).

Обробка ЕКГ-сигналу

Електрокардіографічний сигнал є одновимірним часовим рядом, що відображає електричну активність серця. Він містить ритмічні та морфологічні патерни, які несуть діагностичну інформацію щодо ішемічних процесів, аритмій, нестабільності ритму та інших серцево-судинних порушень.

Для автоматизованої обробки ЕКГ в рамках мультимодальної системи застосовується згорткова нейронна мережа (1D-CNN), яка здатна автоматично виявляти локальні аномалії та характерні часові інтервали без потреби у ручному виділенні ознак.

Основні етапи модальної обробки ЕКГ:

Вхідні ознаки:

- QT_interval
- RR_interval
- QRS_duration
- P_interval
- ST_depression
- HRV (варіабельність серцевого ритму)

Ці параметри є статистичними дескрипторами, обчисленими із сирого ЕКГ-сигналу на попередньому етапі обробки.

1. Згорткова обробка (1D-CNN): 1D-CNN застосовується до послідовності ознак або до сегментів сигналу, щоб виділити локальні шаблони, що вказують на фізіологічні або патологічні зміни (наприклад, подовження інтервалу QT або зниження сегмента ST, характерні для ішемії).

2. Агрегування (Pooling / Hidden state): для отримання фіксованого розміру векторного представлення сигналу використовується глобальна операція агрегування GlobalMaxPooling1D. Вона дозволяє зібрати найінформативніші активації згорткових фільтрів по всій довжині вхідної послідовності.

3. Повнозв'язний шар (Dense): стиснутий вихід із шару пулінгу передається до Dense-шару, який формує компактне числове представлення сигналу (модальний енбедінг). Розмірність цього вектора зазвичай обирається як 64.

4. Модальний енбедінг ЕКГ: результатом є фіксовановимірний вектор, що репрезентує ЕКГ-модальність пацієнта в просторі ознак. Цей вектор подається як вхід до моделі злиття (метакласифікатора).

Наступним є формування вхідного тензора для моделі згорткової нейронної мережі (1D-CNN) на основі ЕКГ-ознак. Для побудови моделі аналізу електрокардіографічних даних було сформовано вхідний вектор ознак, який включає шість ключових параметрів, що характеризують функціональний стан серцево-судинної системи: $QT\_interval = 414,9$; $RR\_interval = 939,9$; $QRS\_duration = 93,2$; $P\_interval = 81,4$; $ST\_depression = 0,06$; $HRV = 41,5$. Кожен запис (відповідний одному пацієнту) представлено у вигляді одновимірного вектора:

$$x = [QT_{interval}, RR_{interval}, QRS_{duration}, P_{interval}, ST_{depression}, HRV] \in R^6.$$

Перед подачею у модель ознаки було попередньо нормалізовано із застосуванням методу MinMaxScaler, який переводить значення кожного параметра до інтервалу $[0,1]$, що дозволяє уникнути домінування ознак із великою абсолютною шкалою при оптимізації моделі.

Оскільки згорткова нейронна мережа (1D-CNN) очікує на вхід тензор тривимірної структури, вектор ознак для кожного спостереження було трансформовано до формату: $X \in R^{(1 \times 6 \times 1)}$, де: 1 – розмір міні-батчу (кількість

прикладів, у цьому випадку один пацієнт), 6 – кількість часових «позицій» (тобто кількість ознак), 1 – кількість каналів (оскільки кожна ознака розглядається як скалярний сигнал в одній часовій точці).

Таким чином, кожен нормалізований вектор ознак було перетворено у тензор наступного вигляду:

$$X = [[QT]^T [RR]^T [QRS]^T [P]^T [ST]^T [HRV]^T] = \begin{bmatrix} [x_1] \\ [x_2] \\ [x_3] \\ [x_4] \\ [x_5] \\ [x_6] \end{bmatrix} \in R^{6 \times 1}, \quad (6.10)$$

де кожен $[x_i]$ – нормалізоване значення відповідної ЕКГ-ознаки.

Для одного запису процес формалізації тензора має вигляд:

`features = np.array([[414,9, 939,9, 93,2, 81,4, 0,06, 41,5]])` → нормалізація → `.reshape(1, 6, 1)` → готовий тензор (1, 6, 1) для подачі в 1D-CNN.

Цей тензор передається до згорткової частини моделі, де за допомогою ядер згортки відбувається автоматичне виявлення локальних патернів і аномалій. Подальше застосування операції глобального пулінгу (GlobalMaxPooling) дозволяє отримати стислий опис усієї структури вхідного сигналу. Після цього результат проходить через повнозв'язний (Dense) шар для формування модального енбедінгу – компактного числового представлення сигналу, що може бути використане у процесі інтеграції з іншими модальностями.

Отож, для першого пацієнта із значеннями ознак: QT_interval = 414,9; RR_interval= 939,9; QRS_duration = 93,2; P_interval= 81,4; ST_depression=0,06; HRV = 41,5 модель може виявити патерни, що відповідають нестабільності ритму, притаманній ішемічному стану. У результаті після обробки через CNN → GlobalMaxPooling → Dense, формується 64-елементний вектор, що стискає ці характеристики у модальне представлення.

Обробка EEG-сигналу

Електроенцефалографічний (ЕЕГ) сигнал є багатоканальним часовим рядом, що відображає електричну активність головного мозку. Він містить

критично важливу інформацію про частотні патерни, які мають діагностичну цінність при виявленні когнітивних порушень, постінсультних змін, функціональної дискоординації тощо. Завдяки своїй високій часовій роздільній здатності, ЕЕГ дозволяє аналізувати як короточасні зміни, так і сталі порушення активності у різних частотних діапазонах.

Першим етапом, як і в попередній модальності, є формування вхідного вектора ознак:

- Alpha_power
- Beta_power
- Spectral_entropy
- Peak_frequency
- Theta_alpha_index
- Frontal_coherence

Ці ознаки узагальнюють спектральну структуру ЕЕГ, показники узгодженості та рівень виявлених аномалій.

Для автоматизованого аналізу застосовується згорткова нейронна мережа (CNN), яка обробляє або спектрограми (як спектрально-часові образи), або безпосередньо вектор спектральних ознак. Такий підхід дозволяє виявляти характерні зміни у мозковій активності, зокрема підвищення потужності θ - або β -діапазонів, зниження ентропії або зміщення пікової частоти.

Після згорткових шарів застосовується операція глобального пулінгу (GlobalMaxPooling), яка агрегує інформацію по всіх часових вікнах або каналах у єдиний вектор. Це дозволяє зберегти найінформативніші патерни з усього сигналу: `features = np.array([[7,77, 9,5, 9,9, 0,88, 0,9, 0,5]])` → нормалізація → `.reshape(1, 6, 1)` → готовий тензор (1, 6, 1) для подачі в 1D-CNN.

Отриманий згортковий вектор подається на вхід повнозв'язного шару, який стискає його до фіксованої розмірності 64-елементного вектора. Цей вектор є модальним енбедінгом, тобто компактним числовим представленням ЕЕГ-сигналу, що може бути інтегровано з енбедінгами інших модальностей у рамках метамоделі.

Обробка МРТ-даних

Магнітно-резонансна томографія (МРТ) забезпечує просторову візуалізацію мозкових тканин і структур, що дає змогу виявляти морфологічні зміни, пов'язані з ішемічними, геморагічними та постінсультними станами. У цьому дослідженні МРТ-дані представлені у вигляді структурованих числових ознак, які були попередньо екстраговані зі зображень із використанням медичних програмних засобів.

Вхідний вектор ознак: Hypointense_volume, GM_texture_entropy, GM_WM_contrast, Periventricular_intensity, Parietal_LBP, Lateral_ventricle_shape одного запису має вигляд: $X = [1,9, 0,6, 1,7, 1,3, 0,3, 0,7]$. Ці характеристики передають кількісну інформацію про інтенсивність, текстуру, симетрію та форму мозкових структур.

На цьому етапі проводиться попередня обробка: застосовується нормалізація (Z-перетворення), а також редукція розмірності за допомогою методу головних компонент (РСА) для зменшення надмірності або покращення узагальнення.

Отриманий вектор ознак подається на один або кілька повнозв'язних шарів (Dense layers). Метою цього етапу є стискання простору до модального енбедінгу, тобто представлення фрагменту МРТ у вигляді вектора фіксованої довжини 64.

Вектор передає ключові просторові патерни і статистики, що характеризують морфологію мозку пацієнта. Цей вектор надалі інтегрується з іншими модальностями або подається на окрему модель класифікації.

Обробка клінічних даних

Клінічні ознаки включають числові змінні (наприклад, вік, індекс маси тіла, показники стабільності стану) та категоріальні (наприклад, стать, наявність діабету чи гіпертензії). На етапі кодування числові ознаки стандартизуються, а категоріальні – перетворюються через one-hot-encoding або використовуються embedding-репрезентації. Об'єднані ознаки подаються на Dense-шар,

результатом якого є стислий числовий вектор, що відображає клінічний стан пацієнта.

Формування модального представлення відбувається після попередньої обробки, коли всі ознаки конкатенуються у єдиний вектор, який подається на один або кілька повнозв'язних шарів Dense layers. Результатом є модальний енбедінг – компактне числове представлення клінічного стану пацієнта, яке, як правило, має фіксовану розмірність 32 компоненти.

На етапі об'єднання модальних ознак (Рис. В.1 (додаток В)) усі модальні енбедінги об'єднуються шляхом конкатенації в єдиний вектор ознак, що репрезентує пацієнта в уніфікованому ознаковому просторі. Такий підхід дозволяє зберігати специфічну інформацію кожної модальності, водночас забезпечуючи єдине представлення для задачі класифікації.

Аналітичне формулювання для пацієнта i зібрані ознаки з чотирьох модальностей:

- $x_i^{ECG} \in R^{d_1}$ – вектор, що репрезентує ознаки електрокардіограми;
- $x_i^{EEG} \in R^{d_2}$ – вектор ознак електроенцефалограми;
- $x_i^{MRI} \in R^{d_3}$ – числове представлення морфології мозку з МРТ;
- $x_i^{Clinical} \in R^{d_4}$ – ознаки клінічного стану.

Після обробки кожної модальності відповідною моделлю отримується модальний енбедінг – стислий числовий вектор фіксованої розмірності: $z_i^{ECG} \in R^{k_1}, z_i^{EEG} \in R^{k_2}, z_i^{MRI} \in R^{k_3}, z_i^{Clinical} \in R^{k_4}$. Після обробки: $z^{ECG} = R^{64}, z^{EEG} = R^{64}, z^{MRI} = R^{64}, z^{Clinical} = R^{32}$.

Для формування уніфікованого ознакового простору всі модальні представлення конкатенуються в єдиний вектор:

$$Z_i = \text{Concat}(z_i^{ECG}, z_i^{EEG}, z_i^{MRI}, z_i^{Clinical}) \in R^k, \text{ де } k = k_1 + k_2 + k_3 + k_4.$$

Отриманий вектор $Z_i \in R^{224}$ подається на мета-модель класифікації Random Forest для передбачення класу $\hat{y}_i = \text{MetaModel}(Z_i)$.

Саме вектор Z_i , що формується після обробки кожної модальності через CNN, є вхідними даними для метамоделі Random Forest, яка й виконує фінальне передбачення класу.

На останньому етапі вектор подається на класифікаційний блок, що складається з одного або кількох повнозв'язних шарів і завершується шаром Softmax. Softmax-функція генерує ймовірнісний розподіл між п'ятьма можливими діагностичними класами: Healthy, Ischemic, Hemorrhagic, Poststroke, OtherNeuropathology. Модель повертає той клас, для якого ймовірність є максимальною.

Отриманий вектор Z_i подається на багат шаровий перцептрон, що складається з одного або кількох повнозв'язних шарів (Dense Layers) і завершується шаром Softmax:

$$\hat{y}_i = \text{Softmax}(\text{Dense}_2(\text{ReLU}(\text{Dense}_1(Z_i))))), \quad (6.11)$$

де:

- Dense_1 – шар перетворення ($224 \rightarrow 128$);
- Dense_2 – вихідний шар ($128 \rightarrow 5$);
- Softmax – функція, яка перетворює вихід на вектор ймовірностей по п'яти класах: $\hat{y}_i = [p_1, p_2, p_3, p_4, p_5], \sum_{k=1}^5 p_k = 1$.

Розширена багатокласова постановка задачі охоплює п'ять основних категорій: Healthy, Ischemic, Hemorrhagic, Poststroke, Other, що дає змогу врахувати як гострі стани, так і хронічні або не специфіковані нейропатології. У цьому підрозділі буде детально описано архітектуру моделі пізнього злиття, етапи її навчання та валідації, а також порівняльний аналіз її ефективності відносно моделі раннього злиття.

Фінальний передбачений клас – це клас із найбільшою ймовірністю:
 $\text{Predicted\_Class} = \arg \max_k \hat{y}_i^{(k)}.$

Після Softmax: $\hat{y}_i = [0,02, 0,65, 0,10, 0,13, 0,10]$. Тоді найвища ймовірність – Ischemic (65%), класифікація: Ischemic Stroke.

На відміну від моделі інтеграції мультимодальних ознак, де всі ознаки об'єднуються на рівні входу в єдиний простір для навчання універсального класифікатора, методика метарішень ґрунтується на принципі інтеграції модальних моделей (Model-level fusion), в межах якої кожна модальність аналізується окремим спеціалізованим класифікатором. Далі їхні локальні рішення комбінуються за допомогою метарівня – моделі метарішень, яка вивчає закономірності між передбаченнями локальних моделей і справжніми класами.

Для навчання мультимодальної моделі Model-level fusion було використано алгоритм Random Forest із параметром `class_weight='balanced'`, що дозволило ефективно компенсувати дисбаланс між п'ятьма діагностичними класами: Healthy, Ischemic, Hemorrhagic, Poststroke та OtherNeuropathology.

Вхідні дані кожної модальності попередньо оброблялися окремо для формування модальних енбедінгів, які згодом конкатенувалися в єдиний вектор ознак. Отриманий вектор подавався на модель класифікації, що реалізує пізнє злиття інформації з усіх джерел.

Дані було попередньо розділено на тренувальну 80 % та тестову 20 % вибірки. Тестова вибірка не використовувалась під час навчання і слугувала для фінальної оцінки узагальнюючої здатності моделі.

Крім того, у межах тренувальної вибірки виконувалось додаткове розділення на тренувальну та валідаційну підмножини у співвідношенні 80:20, що дозволяло контролювати якість моделі на даних, не використаних безпосередньо під час оновлення ваг моделі, і здійснювати налаштування гіперпараметрів з урахуванням ризику перенавчання.

Модель Model-level fusion була навчена протягом 50 епох із використанням оптимізатора Adam при швидкості навчання 0,001. Використання цього оптимізатора дозволило досягти швидкої та стабільної збіжності, що дало перевагу в порівнянні з моделлю раннього злиття.

Процес навчання контролювався за допомогою метрик узагальненої точності (accuracy) та функції втрат (loss), що обчислювалися окремо для

тренувальної та валідаційної підмножин. На Рис. 6.14 візуалізовано динаміку цих метрик:

- Лівий графік демонструє поступове зростання точності як на тренувальній, так і на валідаційній підмножинах. Це свідчить про ефективне навчання моделі без ознак перенавчання.
- Правий графік показує спад функції втрат, що також підтверджує стабільне покращення якості класифікації.




Рис. 6.14. Динаміка точності для мультимодальної моделі пізнього злиття

На рисунку 6.14 ліва частина графіка демонструє точність класифікації на тренувальній вибірці. Видно, що модель досягає майже 100 % точності вже при 10 деревах, що свідчить про швидке й майже ідеальне навчання на відомих прикладах. Червона лінія відображає точність на валідаційній підмножині, яка залишається на рівні 0,6–0,65 навіть зі зростанням кількості дерев, і не демонструє суттєвого покращення. Така динаміка є чітким індикатором перенавчання (overfitting), тобто модель «запам'ятовує» тренувальні дані, але втрачає здатність до узагальнення, тобто показує гірші результати на нових, невідомих даних.

Права частина графіка демонструє Train Loss (помаранчева лінія) різко знижується до майже нульового рівня, що знову ж таки свідчить про ідеальне запам'ятовування тренувального набору. Проте Validation Loss (червона лінія) знижується на початкових ітераціях, але зупиняється на рівні 0,7 і не покращується навіть при збільшенні кількості дерев понад 15.

Це підтверджує перенавчання: хоча модель продовжує вдосконалювати свої передбачення на тренувальних даних, якість прогнозів на валідації стабілізується або навіть погіршується, що суперечить очікуваному ефекту від збільшення складності моделі.

Причиною такої поведінки в контексті моделі Model-level fusion є надмірна інформативність модальних ембедінгів, які були передані до класифікатора представлення з кожної модальності, які вже мають високу здатність до розмежування класів. Таким чином, об'єднаний вектор стає надзвичайно багатовимірним і «щільним» з погляду інформації, що легко дозволяє моделі ідеально адаптуватися до тренувальних даних.

Вибір моделі-класифікатора, особливо з великою кількістю дерев, також впливає на динаміку точності моделі: вони мають високу апаратну потужність і здатні відновити навіть складні шаблони у тренувальних даних, проте за відсутності регуляризації – це призводить до втрати узагальнення. Відсутність обмежень на глибину дерев призводить до перенавчання. Отож для регуляризації моделі потрібно зменшити глибину дерев (`max_depth`), додати `min_samples_leaf`, `subsample`, `colsample_bytree`. Такими діями спричинимо зменшення схильності до перенавчання (Рис. 6.15).




Рис. 6.15. Динаміка збалансованої точності Random Forest Моделі
(10 дерев)

На графіку зображено динаміку збалансованої точності (balanced accuracy) моделі Model-level fusion на основі Random Forest із меншою кількістю дерев (до

10). Видно, що точність як на тренувальній, так і на валідаційній підмножинах зростає зі збільшенням кількості дерев, досягаючи стабільного рівня при 10 деревах. Це свідчить про ефективність ансамблю навіть за обмеженої складності моделі.

На рисунку 6.15 тренувальна точність стабільно вища, але розрив невеликий, особливо при $n=10$, що вказує на відсутність перенавчання. Validation Balanced Accuracy при $n=10$ досягає приблизно 0,94, що є дуже хорошим результатом для мультимодальної задачі. Отож, модель з 10 деревами дає оптимальний компроміс між точністю і простотою, де точність на валідації стабільно зростає.

Матриця невідповідностей, представлена на рисунку 6.16, відображає ефективність класифікації п'яти класів патологічних та здорових станів мозку за допомогою моделі пізнього злиття, побудованої з використанням ансамблю з 10 дерев Random Forest. По вертикальній осі подано істинні мітки класів, тоді як по горизонтальній – класи, передбачені моделлю. Кожна клітинка матриці містить кількість прикладів, які належать до певного класу, але були класифіковані як інший.




Рис. 6.16. Матриця невідповідностей для валідаційних даних мультимодальної моделі Model-level fusion зменшеної складності (10 дерев)

Рисунок 6.16 ілюструє матрицю невідповідностей, отриману на основі результатів моделі Model-level fusion, протестованої на валідаційній підмножині з 200 прикладів. У межах задачі багатокласової класифікації оцінюється ефективність моделі щодо розпізнавання п'яти клінічних станів: Healthy, Ischemic, Hemorrhagic, Poststroke, OtherNeuropathology. Аналіз матриці дозволяє деталізувати розподіл правильних і помилкових передбачень, виявити характерні джерела плутанини між класами та встановити зони потенційного покращення.

Модель коректно класифікувала Healthy – чотири з п'яти прикладів, незважаючи на малу кількість прикладів. Це свідчить про достатню розпізнаваність здорового стану, хоча невеликий обсяг представлення обмежує надійність цієї оцінки.

Hemorrhagic модель правильно класифікувала 22 з 35 зразків, однак 13 випадків помилково віднесено до класу OtherNeuropathology. Це свідчить про часткову плутанину між геморагічними ураженнями та іншими невропатологіями.

OtherNeuropathology найбільший клас – 116 прикладів, з яких 82 класифіковано правильно. Висока ефективність пояснюється як інформативністю ознак, так і високою представленістю цього класу у вибірці.

Ischemic модель класифікує лише два з шести прикладів правильно, решта чотири помилково віднесені до OtherNeuropathology. Це вказує на критично низьку чутливість до ішемічних станів та відсутність чіткої межі ознак, що відділяють цей клас від інших.

У класі Poststroke з 38 прикладів правильно класифіковано лише 17, тобто менше половини. 21 випадок сплутано з Other, що свідчить про значне перекриття ознак.

Результати, відображені на рисунку 6.16, підтверджують, що модель пізнього злиття загалом забезпечує прийнятний рівень класифікації, однак має суттєві обмеження у точному розпізнаванні менш представлених або клінічно схожих класів, зокрема Ischemic та Poststroke. У підсумку, отримана матриця

невідповідностей є основою для подальшого вдосконалення архітектури моделі пізнього злиття.

Таблиця 6.6

Звіт про метрики продуктивності моделі пізнього злиття
на основі даних валідації

Метрики	Healthy	Hemorrhagic	Ischemic	Other	Poststroke
Precision	0,67	0,76	0,30	0,77	0,41
Recall	0,80	0,63	0,33	0,75	0,55
F1-score	0,73	0,69	0,31	0,76	0,47
Accuracy	0,715				

У таблиці 6.6 представлено ключові метрики продуктивності моделі пізнього злиття (late fusion) для задачі багатокласової класифікації клінічних станів пацієнтів на основі об'єднаних ознак з різних модальностей. Зокрема, оцінюється точність (precision), повнота (recall), F1-метрика та підтримка (support) для кожного з п'яти класів: Healthy, Ischemic, Hemorrhagic, Poststroke, OtherNeuropathology. Загальна точність моделі на тестових даних становить 71,5 %, що є прийнятним результатом, але потребує подальшого вдосконалення для клінічного застосування.

Для класу Healthy модель продемонструвала високий рівень повноти (recall = 0,80), що означає, що чотири з п'яти здорових пацієнтів були правильно класифіковані. Проте точність становить лише 0,67, тобто третина зразків, передбачених як “Healthy”, виявилися належними до інших класів. Через низьку підтримку (лише 5 зразків) оцінка цього класу нестабільна, і результати можуть значно змінюватися при зміні даних.

Для класу Hemorrhagic точність є високою (0,76), тобто більшість передбачень як “Hemorrhagic” були правильними. Однак повнота (recall = 0,63) вказує на те, що модель пропустила значну частину справжніх випадків – частина з них була помилково віднесена до класу “Other”. F1-score = 0,69 свідчить про загалом помірну ефективність розпізнавання геморагічного інсульту.

Клас Ischemic класифікується найгірше. Повнота лише 0,33, тобто з шести наявних зразків лише два були правильно ідентифіковані. Ще гірша ситуація із точністю ($\text{precision} = 0,29$), тобто модель часто помилково відносить зразки інших класів до ішемічного. Відповідно, $\text{F1-score} = 0,31$ вказує на слабку розпізнаваність ішемічного інсульту, що є критичним для клінічного застосування.

Клас OtherNeuropathology має найкращі показники серед усіх: $\text{precision} = 0,77$, $\text{recall} = 0,75$, $\text{F1} = 0,76$. Це пов'язано з великою кількістю прикладів у вибірці ($\text{support} = 116$), що дає змогу моделі краще навчитися розпізнавати цей клас. Незначні помилки можуть бути пов'язані з накладанням на класи Poststroke або Hemorrhagic.

Результати для класу Poststroke є незадовільними: точність лише 0,41, що означає, що менше половини зразків, передбачених як Poststroke, справді належать цьому класу. Повнота дещо вища (0,55), але $\text{F1-score} = 0,47$ вказує на те, що модель має труднощі з відмежуванням постінсультного стану від інших патологій, зокрема ішемічного інсульту та інших нейропатологій.

На основі класифікаційного звіту можна зробити висновки щодо якості розпізнавання кожного з п'яти клінічних класів у моделі пізнього злиття. Модель демонструє високу ефективність класифікації для більшості класів, особливо для “Healthy”, “Hemorrhagic”, “Poststroke” і “OtherNeuropathology”. Найбільші труднощі виникають при розпізнаванні ішемічного інсульту, що може бути зумовлено як низькою кількістю навчальних прикладів цього класу, так і близькістю ознак до інших станів. Для покращення класифікації Ischemic доцільно розширити вибірку або ввести додаткові інформативні ознаки.

Проведений порівняльний аналіз моделей раннього та пізнього злиття на однаковій валідаційній вибірці з 200 прикладів показав перевагу моделі раннього злиття в контексті точності класифікації, стабільності метрик та здатності до узагальнення. Модель пізнього злиття, незважаючи на архітектурну гнучкість, продемонструвала нижчу продуктивність, особливо для класів з низькою представленістю або перехресними клінічними ознаками. Надалі рекомендовано

використовувати моделі інтеграції ознак у задачах із високими вимогами до точності, залишаючи інтеграцію моделей для сценаріїв, де критичною є модальність-специфічна обробка або масштабованість системи.

Для тестування на окремій тестовій вибірці слід обрати модель раннього злиття, тому що модель показала кращі результати за всіма метриками (Порівняння результатів у таблицях 6.4 та 6.5): Ассигасу: 0,96 проти 0,715.

Модель інтеграції моделей модальностей має ознаки перенавчання: дуже низькі метрики на валідаційній вибірці, падіння точності на деяких класах, наприклад, Ischemic: $\text{precision} = 0,30$. Тому потрібно провести тестування моделі, яка на валідації показала стабільну і високу якість.

Результати, зображені на рисунку 6.17, свідчать про ефективність моделі інтеграції ознак модальностей у задачі багатокласової класифікації клінічних станів пацієнтів на основі мультимодальних медичних даних. Аналіз матриці невідповідностей, побудованої на 200 тестових прикладах, демонструє, що модель найкраще розпізнає класи Hemorrhagic та Poststroke – усі відповідні приклади були правильно класифіковані, що вказує на наявність чітких, добре відокремлюваних ознак у цих категоріях.




Рис. 6.17. Матриця невідповідностей для тестової вибірки моделі інтеграції мультимодальних ознак

Разом з тим, модель частково помиляється у класифікації пацієнтів із класами Healthy, Ischemic та OtherNeuropathology. Зокрема, для класу Healthy

лише половина прикладів була ідентифікована правильно (10 із 20), тоді як інші були помилково віднесені до Other. Подібна ситуація спостерігається і для класу Ischemic: 10 з 40 прикладів були класифіковані як Other, що свідчить про часткове перекривання ознак між цими станами. Клас OtherNeuropathology також зазнає певних труднощів у класифікації – 10 прикладів із 50 були помилково ідентифіковані як Poststroke.

Загалом, модель демонструє високу здатність до узагальнення та точності в межах більшості класів, проте помилки у розрізненні станів, які мають часткову симптоматичну або ознакову схожість, зокрема між Ischemic, Healthy та Other, свідчать про необхідність додаткового аналізу. Можливими шляхами покращення є розширення ознакового простору за рахунок специфічніших індикаторів, переформулювання меж між подібними класами.

Згідно з матрицею невідповідностей (Рис. 6.17), точність класифікації (Accuracy) для моделі інтеграції ознак на 200 прикладах обчислюється як:

$$Accuracy = \frac{\text{Кількість правильних класифікацій}}{\text{Загальна кількість прикладів}} = \frac{10 + 40 + 30 + 40 + 50}{200} = 0,85.$$

Це означає, що модель правильно класифікує 85 % прикладів на тестовій вибірці з 5 класами. Таким чином, вона демонструє, що модель Feature-level fusion успішно справляється з диференціацією найбільш відокремлених класів, однак вимагає подальшої адаптації для покращення точності у випадках перехресних станів і менш представлених діагностичних категорій.

Таблиця 6.7

Звіт про метрики продуктивності моделі раннього злиття на тестовій вибірці

Метрики	Healthy	Hemorrhagic	Ischemic	Other	Poststroke
Precision	1,0	1,0	1,0	0,67	0,83
Recall	0,5	1,0	0,75	0,8	1,0
F1-score	0,67	1,0	0,86	0,73	0,91
Accuracy	0,85				

Отримані результати (Табл. 6.7) демонструють, що модель Feature-level fusion здатна до узагальнення на невідомих даних та ефективна при інтеграції ознак із різних модальностей.

Особливо високі результати спостерігаються для класів Hemorrhagic (Precision, Recall, F1-score = 1,00) та Poststroke (Recall = 1,00, F1-score = 0,91), що вказує на чітку диференційованість відповідних патологічних станів. Крім того, клас Ischemic також класифікується з високою ефективністю (F1-score = 0,86), хоча Recall = 0,75 свідчить про часткову втрату справжніх позитивних прикладів.

Разом із тим, виявлено низку обмежень моделі, які потребують уваги. Зокрема, низький показник Recall (0,5) для класу Healthy вказує на значну ймовірність хибнонегативних рішень, що є критичним у клінічному контексті через ризик пропущення здорових пацієнтів. Також, невисока специфічність для класу OtherNeuropathology (Precision = 0,67, F1-score = 0,73) свідчить про схильність моделі до помилкової класифікації інших станів як “Other”, що знижує точність у діагностичному розрізненні.

Таким чином, модель інтеграції мультимодальних ознак показує високу ефективність класифікації у більшості клінічних класів, однак для підвищення її практичної значущості доцільним є подальше покращення розпізнавання класу Healthy та зниження перехресної плутанини з класом OtherNeuropathology. Для цього рекомендовано застосування балансування вибірки, зважування втрат або розширення ознакового простору із включенням додаткових інформативних біомаркерів.

Загальні результати свідчать про здатність моделі працювати з мультимодальними даними та підтверджують її потенціал для подальшого використання у подібних задачах. Таким чином, модель має практичну цінність як допоміжний інструмент у медичній діагностиці, а її подальше вдосконалення може сприяти більш точному, надійному та інтерпретованому прийняттю клінічних рішень у складних діагностичних випадках.

6.4. Застосування розподілених обчислень та оптимізаційних алгоритмів у роботі з великими медичними даними

Останні результати класифікації клінічних станів на основі мультимодальних медичних даних свідчать про ефективність запропонованої

архітектури раннього та пізнього злиття. Виявлено, що моделі, побудовані на об'єднанні ознак з ЕЕГ, МРТ та клінічної інформації, здатні забезпечити високу точність у диференціації між станами здоров'я, ішемічного та геморагічного інсульту, постінсультного періоду та інших нейропатологій. Разом з тим, ці методи передбачають попередню обробку великих обсягів часових та структурованих даних, що висуває додаткові вимоги до продуктивності системи.

Адаптація методів вирівнювання, крос-кореляції та оптимізації часових міток до роботи з великими масивами даних потребує високопродуктивних рішень для обробки, зберігання та аналізу. Особливо це актуально у випадку синхронізації часових рядів з ЕКГ, ЕЕГ, МРТ або інших біосигналів, які мають складну динамічну структуру та великі обсяги. У цьому контексті доцільним є використання низки ефективних ІТ-рішень для масштабування: зокрема, застосування багатопоточності або розподілених обчислень наприклад, Hadoop, Spark для паралельного обчислення DTW-матриць, GPU-прискорення для інтенсивних чисельних операцій, а також застосування швидших наближених алгоритмів, таких як FastDTW, що зменшують часову складність з $O(n^2)$ до $O(n \log n)$.

Крім того, критично важливо забезпечити ефективне зберігання та доступ до медичних даних. З огляду на те, що медична інформація включає як структуровані записи (електронні історії хвороб, лабораторні дані), так і неструктуровані формати (зображення, ЕКГ-сигнали, аудіо- та відеозаписи), слід впроваджувати сучасні підходи до зберігання – такі як формати HDF5 або Parquet, які забезпечують швидкий доступ до підмножин даних без потреби перечитувати весь масив. Це дозволяє оперативно оновлювати та аналізувати нові надходження без надлишкових обчислень.

Таким чином, підвищення ефективності обробки мультимодальних медичних даних потребує не лише вдосконалення моделей машинного навчання, але й побудови оптимізованої ІТ-інфраструктури, здатної масштабовано, швидко та стабільно працювати з великими обсягами гетерогенних часових даних.

Великі дані – це термін, що описує інформацію, яка перевищує можливості традиційних методів зберігання, обробки та аналізу. Дані такого виду мають великий обсяг, складні та різномірні, що традиційні технології не можуть ефективно з ними працювати. Основні виклики великих даних полягають не лише в їхньому розмірі, але й у відсутності чіткої структури.

Ці дані можуть бути занадто великими для розміщення на одному сервері, надто неструктурованими для представлення у вигляді таблиць або занадто швидкоплинними, щоб бути збереженими у традиційному сховищі. Таким чином, великі дані часто мають хаотичний характер, що потребує спеціальних технологій та підходів для їх обробки.

Стандартні методи аналізу, які ефективно працюють із невеликими структурованими даними, є неідеальними при обробці великих даних через їхній розмір, складність та гетерогенність. Великі дані здебільшого неструктуровані або мають лише часткову структуру, що значно ускладнює їх аналіз.

Таблиця 6.8 демонструє ключові відмінності між традиційними методами аналізу даних та підходами, що використовуються для роботи з великими даними.

Таблиця 6.8

Порівняння традиційної аналітики та аналітики великих даних

Характеристика	Традиційна аналітика	Аналітика великих даних
Джерела даних	Однорідні джерела, що постачають лише структуровані та статичні дані	Різномірні джерела, що забезпечують структуровані, напівструктуровані, неструктуровані та потокові дані
Зберігання даних	Ізольовані сервери для зберігання	Хмарні платформи (публічна, приватна або гібридна хмара)
Технологія баз даних	Реляційні бази даних (структуровані сховища даних у вигляді рядків і стовпців)	NoSQL бази даних для роботи з неструктурованими даними
Обробка даних	Використання централізованої архітектури	Застосування розподіленої архітектури
Аналітика	Виконується за статичними, попередньо зібраними даними	Забезпечується аналітика в реальному часі, включаючи обробку потоків

Технології диференціації, такі як Hadoop, допомагають універсально зберігати та обробляти як структуровані, так і неструктуровані дані для аналізу. Їх універсальність полягає в зберіганні та обробці даних різноманітними способами. На Рис. 6.18 показано чотири основні стадії обробки даних у Hadoop.




Рис. 6.18. Схема обробки даних у Hadoop

На рисунку 6.18 схематично представлено архітектуру обробки даних із використанням платформи Hadoop, яка добре адаптується для аналізу великих обсягів структурованих та неструктурованих медичних даних. Отож, кожен етап процесу обробки даних являє собою потік, у якому медичні дані проходять через усі етапи обробки — від збору до отримання аналітичної інформації. Це забезпечує безперервний рух даних із різних джерел, таких як лікарні, лабораторії або пристрої для моніторингу стану пацієнтів. На етапі завантаження відбувається збір поточкових даних із різноманітних джерел. На проміжному етапі — модальності тимчасово зберігаються в Hadoop Distributed File System (HDFS) перед обробкою. Такий підхід дозволяє працювати з великими обсягами даних, для яких не застосовуються традиційні сховища.

Блок управління даними та робочими процесами забезпечує контроль процесу обробки медичних даних: контролює формат, забезпечує якість та структурування даних. На цьому етапі здійснюється організація робочих

процесів для їх автоматизації аналізу, до прикладу, для виявлення патологій на МРТ або обробка сигналів ЕКГ для пошуку аритмій.

Після обробки дані стають доступними для аналітики та прийняття рішень. Це дозволяє лікарям отримати швидкий доступ до історії пацієнта та результатів аналізу, аналітичним системам – використовувати дані для прогнозування захворювань або формування протоколів лікування.

Важлива інформація, яку отримують із даних після обробки, включає: виявлення патологій (пухлин, аномалій) за допомогою штучного інтелекту, прогнозування ризиків захворювань на основі генетичних даних або анамнезу та рекомендації щодо індивідуального лікування або медичного втручання.

Hadoop Framework виконує роль платформи для обробки великих медичних даних, а використання MapReduce – для паралельної обробки великих обсягів інформації. Для швидшого отримання результатів потрібна їх інтеграція з інструментами аналітики Apache Spark в режимі реального часу.

Фізична інфраструктура включає сервери та кластерні системи для обробки та зберігання даних. У випадку з медичними даними це також може включати спеціалізовані сервери для зберігання великих медичних зображень або захищені середовища для забезпечення конфіденційності даних.

Така інформаційна технологія (Рис. 6.18) дозволяє ефективно працювати з великими медичними даними, забезпечуючи їх обробку в реальному часі, аналіз на основі штучного інтелекту, а також отримання інсайтів, що допомагають у діагностиці, лікуванні та дослідженнях.

MapReduce, як ключова програмна парадигма Hadoop, дозволяє виконувати розподілену обробку великих обсягів медичних даних на різних рівнях та забезпечує глибокий аналіз для підтримки рішень у медичних установах.

Парадигма MapReduce передбачає організацію даних у вигляді списків, обробка яких відбувається у три етапи (Рис. 6.19):

1. *Стадія Map*. На цьому етапі дані проходять первинну обробку за допомогою функції *map()*, яка визначається користувачем. Тут проходять

обробку набори електронних медичних записів пацієнтів для виділення ключових метрик (наприклад, рівня глюкози, артеріального тиску). Відповідно, функція *map()* фільтрує дані та перетворює їх на множину пар ключ-значення (key-value), де ключ – це ідентифікатор пацієнта, а значення – його медичні показники.

2. *Стадія Shuffle*. На цьому етапі дані сортуються та групуються за ключами, відповідно до одного пацієнта (ключ). Таким чином готується інформація для подальшого аналізу.
3. *Стадія Reduce*. Тут обробляються дані, згруповані на попередньому етапі, і формується фінальний результат.




Рис. 6.19. Огляд процесу виконання MapReduce

На рисунку 6.19 схематично показано використання технології MapReduce для розподіленої обробки медичних даних. Слід розглянути схему з точки зору застосування модальностей щодо оцінювання стану пацієнтів. Основним є програмний код (User Program), який створений для пошуку пацієнтів з певними характеристиками. Головний вузол (Master) координує роботу обчислювальної системи. Він розбиває завдання на підзадачі (*map*), та призначає їх на обробку дані певної групи пацієнтів (*worker*). Відповідно, вхідні файли (Input Files) розбиваються на частини (*split 0, split 1, ..., split n*) для обробки.

На фазі Map (Map Phase) кожен (*worker*) виконує завдання, визначені функцією *map*: витягує потрібні параметри (вік, діагнози, результати аналізів); фільтрує дані за критеріями; формує проміжні файли з парами ключ-значення (наприклад, ключ – ідентифікатор пацієнта, значення – результати аналізів).

Проміжні результати (Intermediate Files) зберігаються на локальних дисках. Фаза Reduce (Reduce Phase) займається зчитуванням проміжних даних (*remote read*) для їх узагальнення. На цьому етапі проводиться групування даних за ключами (наприклад, всі дані одного пацієнта). Саме виконання функції *reduce* обчислює кінцевий результат, наприклад визначає середній рівень глюкози для кожного пацієнта або здійснює підрахунок кількості пацієнтів з аномальними показниками.

Кінцеві результати (Output Files) зберігаються у вигляді вихідних файлів, які доступні для подальшого аналізу або звітності. Це може бути зведений звіт про стан здоров'я пацієнтів у лікарні, список пацієнтів, що потребують термінового втручання, або аналітика для прогнозування захворювань.

Така архітектура, що її наведено на рисунку. 6.19, забезпечує паралельну обробку великих обсягів медичних даних, дозволяючи ефективно аналізувати дані з різних джерел, підтримувати прийняття рішень у реальному часі та підвищувати точність діагностики і покращувати якість медичних послуг.

На сьогодні лідерські позиції у застосуванні парадигми MapReduce та створенні програмної платформи для організації розподіленої обробки великих обсягів даних займають технології Apache Hadoop MapReduce та Apache Spark.

Apache Hadoop MapReduce – це вільна платформа для організації обробки великих обсягів даних (вимірюється у петабайтах) з використанням парадигми MapReduce (Рис. 6.20 (а)). Ця парадигма дозволяє здійснювати поділ відособлених фрагментів, кожен з яких може бути запущений на окремому вузлі кластера. До складу Hadoop входить реалізація розподіленої файлової системи Hadoop HDFS, яка автоматично забезпечує резервування даних та є оптимізованою для роботи з MapReduce. Для спрощення доступу до даних в сховищі Hadoop розроблена SQL-подібна мова Hive, яка є свого роду SQL для

MapReduce, і запити якої можуть бути розпаралелені й оброблені кількома Hadoop-платформами.

Apache Spark – це високопродуктивний технічний засіб для обробки даних, що зберігаються в кластері Hadoop (Рис. 6.20 (b)). Порівняно з попереднім Hadoop MapReduce, Spark забезпечує в 100 разів більшу продуктивність при обробці даних у пам'яті та у 10 разів більшу – при розміщенні даних на дисках.




Рис. 6.20. Приклад процесу розподілу мультимодальних даних у:
(a) Hadoop MapReduce; (b) Spark.

На рисунку 6.20 (a) демонструється недолік традиційного MapReduce (повільний через численні операції зчитування та запису на диск) та перевага паралельної обробки, що дозволяє ефективніше працювати з великими даними, використовуючи сучасні технології для розподілених обчислень. Відповідно, на рисунку 6.20 (b) показано, що використання паралельної обробки в оперативній пам'яті значно ефективніше, ніж традиційний підхід зчитування-запису на диск, особливо при обробці великих обсягів даних.

На рисунку 6.21 наведено приклад розподілу мультимодальних даних на час виконання для різної кількості пацієнтів. Показано порівняння тривалості обробки даних для технологій Hadoop і Spark для різної кількості пацієнтів (1000, 5000, 10000, 20000, 30000).

Кожна ітерація в Hadoop відбувається через повільне читання/запис з диску, де час обробки є лінійним і значно вищим. Застосування Spark дозволяє обробляти дані у пам'яті. Час для першої ітерації буде трохи більший через завантаження даних у пам'ять. Подальші ітерації є значно швидшими.

Hadoop демонструє лінійне зростання часу обробки даних із збільшенням кількості пацієнтів. Наприклад, для 30 тис. пацієнтів швидкість обробки становить 4000 секунд.



Рис. 6.21. Порівняльний аналіз продуктивності Hadoop MapReduce та Spark платформ

Spark працює значно швидше завдяки обробці в пам'яті (RAM). Відповідно, для 30000 пацієнтів час обробки знижено до 1200 секунд. Отож, швидкість обробки медичних мультимодальних даних у Spark в 3-4 рази краща за Hadoop. Цей результат підтверджує, що Spark є оптимальним рішенням для обробки великих даних завдяки ефективнішому використанню ресурсів пам'яті.

Обробка мультимодальних медичних даних є багатовимірною задачею, оскільки кожен тип даних додає власний вимір до аналізу. Нижче показано, як обсяг даних, їх модальності та час обробки можна відобразити у багатовимірному просторі.

Для оцінки продуктивності при обробці мультимодальних даних важливо проаналізувати, як обсяг даних впливає на час обробки. Нижче наведено

представлення мультимодальних даних для аналізу у багатовимірному просторі (Табл. 6.9).

Таблиця 6.9

Вхідні мультимодальні медичні дані для обробки технологіями Hadoop
MapReduce та Spark

Тип даних	Обсяг даних (збільшення)	Формат
ЕКГ сигнали	100, 500, 1000, 5000 записів	Часові ряди (n×m)
ЕЕГ сигнали	100, 500, 1000, 5000 записів	Часові ряди (n×m)
МРТ зображення	10, 50, 100, 500 зображень	3D-зображення
Клінічні дані	1000, 5000, 10,000 записів	Таблиці CSV

Процес обробки даних показано на рисунку 6.22, де вхідні дані за допомогою технологій MapReduce або Spark сортуються та групуються за відповідними ключами і представлені у вихідному файлі як агреговані аналітичні висновки.




Рис. 6.22. Огляд процесу використання технологій Hadoop MapReduce та Spark

Після проведених експериментів із застосуванням технологій Hadoop MapReduce та Spark була сформована Таблиця 6.9, де вказано тривалість обробки.

Слід детально розглянути дані результатів експериментів, сформованих у таблиці 6.10. Отож, друга колонка таблиці формувалась з обсягу вхідних даних, структура та формат модальностей представлені в таблиці 6.9 та на рисунку 6.22.

Дані ETL-процесу (Hadoop) розраховуються на основі обсягу даних та обмежень Hadoop MapReduce щодо швидкості обробки. Розрахунок оцінки часу ETL-процесу (Hadoop) проводився за наведеною формулою:

$$T_{ETL(Hadoop)} = k \cdot V_{\text{даних (MB)}} \quad (6.12)$$

де:

- $T_{ETL(Hadoop)}$ – час ETL у секундах;
- k – коефіцієнт швидкості обробки Hadoop (враховує дискові операції, складність процесу);
- $V_{\text{даних (MB)}}$ – обсяг даних у MB.

Таблиця 6.10

Представлення часу обробки під час експериментів для Hadoop і Spark платформ

Тип даних	Обсяг даних (MB)	ETL-процес (Hadoop, с)	ETL-процес (Spark, с)	Час навчання (Hadoop, с)	Час навчання (Spark, с)	Загальний час (Hadoop, с)	Загальний час (Spark, с)
ЕЕГ	100	8	5	40	30	48	35
	500	16	10	120	90	136	100
	1000	40	25	240	180	280	205
	5000	160	100	960	720	1120	820
ЕКГ	100	4	2,5	24	15	28	17,5
	500	12	7,5	72	45	84	52,5
	1000	32	20	144	90	176	110
	5000	120	75	576	360	696	435
МРТ	200	24	15	240	180	264	195
	1000	96	60	960	720	1056	780
Клінічні дані	50	4	2,5	8	5	12	7,5
	500	24	15	80	50	104	65

Для порівняння результатів загального часу обробки між платформами Hadoop і Spark можна застосувати кілька підходів:

1. Обчислення абсолютної різниці часу: $\Delta T = T_{Hadoop} - T_{Spark}$.
2. Обчислення відносної переваги Spark (прискорення):

$$\text{Коефіцієнт прискорення} = \frac{T_{Hadoop}}{T_{Spark}}.$$

3. Обчислення середнього прискорення: Середнє прискорення =

$$\frac{1}{n} \sum_{i=1}^n \left(\frac{T_{Hadoop,i}}{T_{Spark,i}} \right).$$

Результати обчислень наведено в таблиці 6.11.

Таблиця 6.11

Порівняння результатів загального часу обробки між платформами
Hadoop і Spark

№	Hadoop (с)	Spark (с)	ΔT (с)	Прискорення (рази)
1	48	35	13	1,37
2	136	100	36	1,36
3	280	205	75	1,37
4	1120	820	300	1,37
5	28	17,5	10,5	1,60
6	84	52,5	31,5	1,60
7	176	110	66	1,60
8	696	435	261	1,60
9	264	195	69	1,35
10	1056	780	276	1,35
11	12	7,5	4,5	1,60
12	104	65	39	1,60

Отже, середня економія часу Spark від Hadoop:

$$\text{Середня економія} \approx \frac{\text{сума } \Delta T}{12} \approx \frac{1211,5}{12} \approx 101,0 \text{ с.}$$

Середнє прискорення Spark над Hadoop:

$$\text{Середнє прискорення} \approx 1,50.$$

У результаті порівняльного аналізу продуктивності обробки даних на платформах Hadoop та Apache Spark встановлено, що Spark демонструє стабільну перевагу за швидкістю, забезпечуючи прискорення в 1,35–1,60 рази. Середній виграш у часі перевищує 100 секунд на одну задачу, що особливо помітно при обробці великих обсягів даних (наприклад, 1120 с проти 820 с). Це підтверджує доцільність використання Apache Spark як базової платформи для реалізації масштабованих медичних інформаційних систем, здатних функціонувати в режимі реального часу.

Висновки до розділу 6

У шостому розділі дисертаційної роботи представлено комплексну інформаційну технологію багатовимірної аналізу мультимодальних медичних даних, яка поєднує сучасні методи глибокого навчання, ансамблеві алгоритми

класифікації та розподілену обробку даних для забезпечення високої точності, масштабованості та продуктивності в клінічних умовах. Запропонована система реалізує повний цикл обробки гетерогенних медичних даних: від збору та попередньої підготовки до інтеграції, моделювання та класифікації станів пацієнтів.

1. Розроблено архітектуру мультимодальної системи, що включає модулі вилучення ознак, інтеграції на рівні ознак, моделювання часових залежностей і прийняття рішень. Інтеграція модальностей реалізована за допомогою двох основних підходів – конкатенації та білінійної комбінації ознак, що дозволяє ефективно поєднувати інформацію з ЕКГ, ЕЕГ, МРТ та клінічних джерел. Запропоновано методику побудови уніфікованого ознакового простору з подальшим формуванням цільової змінної у форматах числових класів і one-hot encoding. У результаті сформовано узгоджений датасет із 1000 пацієнтів, які класифіковані за п'ятьма клінічними станами.

2. Для обробки просторово-часових залежностей застосовано гібридні нейронні архітектури: CNN, Inception, DenseNet, ResNet, LSTM, BiLSTM, CNN-LSTM та Transformer. Результати експериментів засвідчили, що ці архітектури забезпечують високу точність класифікації, особливо при поєднанні різних модальностей. Наприклад, використання CNN-LSTM дозволило досягти $AUC > 0,89$ для задач довготривалого моніторингу. Інтеграція моделі Fastai забезпечила адаптивну обробку ознак і масштабованість системи до кількості доступних модальностей.

3. Порівняльний аналіз двох принципів: об'єднання мультимодальних ознак та об'єднання моделей модальностей показав перевагу першого, де точність на тестовій вибірці становила 85 %, із максимальними значеннями F1-score для класів *Hemorrhagic* (1,00), *Poststroke* (0,91) та *Ischemic* (0,86). Натомість модель об'єднання моделей модальностей досягла лише 71,5 % точності, а F1-score для класу *Ischemic* склав 0,31, що свідчить про обмежену здатність цієї моделі до узагальнення без подальшої оптимізації ембедінгів. Водночас виявлено, що найменша чутливість спостерігається для класу *Healthy* ($Recall =$

0,50), що зумовлює необхідність балансування вибірки, наприклад, за допомогою SMOTE.

4. Аналітичне моделювання за допомогою Random Forest та XGBoost показало, що ансамблеві моделі з малою кількістю дерев (до 10) демонструють задовільну продуктивність. Проте подальше збільшення складності призводить до перенавчання, що підтверджено аналізом кривих точності та log-loss. З огляду на це, рекомендовано використовувати оптимізовані функції втрат, вагові коефіцієнти класів і модифіковані структури класифікаторів.

5. У межах обробки великих обсягів даних обґрунтовано доцільність застосування платформи Apache Spark. Проведений порівняльний аналіз показав, що Spark забезпечує прискорення обробки в 1,35–1,60 рази, із середнім виграшем у часі понад 100 секунд на задачу. Зокрема, найвища ефективність досягнута у випадках обробки великих обсягів (наприклад, 1120 с проти 820 с), що свідчить про доцільність використання Spark для масштабованих клінічних систем реального часу.

Результати досліджень за шостим розділом опубліковано в роботах автора [1, 2, 10, 12, 17, 18, 20, 21, 22, 31, 35, 38, 39, 45, 48, 50] (Додаток Б).

ВИСНОВКИ

У дисертаційній роботі вирішена актуальна науково-прикладна проблема, що полягає у розробленні методології, на основі якої створено інформаційну технологію для інтеграції, обробки та аналізу мультимодальних медичних даних. Запропонована технологія формує узгоджений ознаковий простір, підвищує точність та інтерпретованість класифікації клінічних станів, забезпечує адаптивність до гетерогенності й неповноти вхідних даних, а також масштабованість і швидкодію в умовах реального клінічного середовища. Рішення базуються на поєднанні моделей машинного навчання, що усуває обмеження існуючих підходів і підвищує практичну значущість технології для медичних інформаційних систем.

У роботі отримано наступні наукові та практичні результати:

1. Вперше запропоновано концепцію аналізу мультимодальних медичних даних, що передбачає виділення інформативних ознак для кожної модальності та їх об'єднання у єдиний багатовимірний ознаковий простір, що на відміну від існуючих підходів, дозволяє формувати узгоджене представлення даних, яке враховує специфіку кожного джерела, підвищує інформативність вхідного масиву та покращує точність класифікації клінічних станів. Реалізація узагальненого ознакового простору – матриця $X \in R^{1000 \times 24}$ – забезпечила загальну точність класифікації на рівні 85 %, що підтверджує ефективність підходу для клінічних задач.

2. Вперше сформульовано принципи багатовимірного аналізу мультимодальних даних, що забезпечили створення технології, здатної інтегрувати різноманітні ознаки та модальні моделі для підвищення точності, надійності й адаптивності класифікаційних систем в умовах гетерогенності та неповноти медичних даних.

3. Вперше розроблено метод інтеграції модальних даних, який полягає у поєднанні цих даних за певними ознаками, що, на відміну від існуючих, буде точки спостереження шляхом адаптивного, погодженого та поетапного об'єднання даних із різних модальностей в єдиний вектор та поєднання цих

векторів, що дозволяє створити із окремих точок спостереження за пацієнтом спільний масив вхідних даних та формувати модель-класифікатор. Отримані результати демонструють загальну точність моделі на 96 %, а значення макро- та зважених середніх метрик – 0,962, що свідчить про збалансовість класів навіть у багатокласових задачах. Це робить метод перспективним для клінічних систем підтримки рішень та підвищення точності діагностики у складних випадках.

4. Вперше розроблено метод побудови мультимодальної моделі, який передбачає створення окремих моделей для кожної модальності та використання результатів їхнього моделювання для класифікації станів пацієнта. На відміну від існуючих, інтегрує результати моделювання в єдину ієрархічну структуру, що дозволяє підвищити кількість правильно класифікованих станів. Запропонована мультимодальна модель досягла 71,5% загальної точності класифікації. Найвищі результати отримано для класів Healthy (0,73) та Other (0,76), що показує здатність моделі добре розпізнавати стани з вираженими чіткими ознаками. Водночас низькі показники precision та recall для класу Ischemic ($F1 = 0,31$) свідчать про складність у відмежуванні схожих клінічних станів і вказують на потребу вдосконалення простору ознак для підвищення точності розпізнавання подібних патологій.

5. Розширено метод вибору інформативних ознак, адаптований до умов гетерогенності джерел даних, завдяки формуванню багатовимірного ознакового простору з урахуванням їх кореляційної узгодженості, що зменшило ризик сильних залежностей та підвищило стабільність моделі. Вибрані ознаки Alpha_power, GM_WM_contrast, Spectral_entropy продемонстрували низьку міжмодальну кореляцію та високу класифікаційну значущість. Це забезпечило зменшення надмірності даних, підвищення стійкості до шуму та точність на рівні 85% на тестовій вибірці.

6. Удосконалено метод оцінювання ефективності аналізу мультимодальних даних, що ґрунтується на порівнянні результатів експериментів за точністю, повнотою, F1-метрикою, часом обробки та стабільністю роботи моделей. Такий підхід дозволяє об'єктивно визначити переваги запропонованої інформаційної

технології, збільшити кількість правильно класифікованих станів пацієнтів та забезпечити адаптацію системи до клінічних умов. Застосування методу показало суттєву перевагу моделі інтеграції ознак (Feature-level fusion) над інтеграцією модальних моделей (Model-level fusion) у багатокласовій класифікації клінічних станів. Модель Feature-level fusion забезпечила загальну точність моделі на 96% при значеннях macro avg та weighted avg F1-метрики на рівні 0,962, що свідчить про збалансовану якість класифікації по всіх п'яти класах, включно з найбільш складними (Ischemic, Poststroke). Натомість модель Model-level fusion продемонструвала помітно нижчі показники точності – 71,5 % та значне зниження F1-метрики для класу Ischemic (0,31), що вказує на труднощі у розмежуванні подібних патологічних станів. Високі результати моделі інтеграції ознак зумовлені формуванням узгодженого ознакового простору на етапі попередньої обробки, що зменшує втрати інформації. Це підтверджує доцільність використання моделі feature-level fusion для медичної діагностики. Використання Apache Spark прискорило обробку в 1,35–1,6 рази порівняно з Hadoop, забезпечивши середній виграш понад 100 секунд на задачу. Отримані результати свідчать про ефективність розробленої технології для масштабованого медичного аналізу.

Таким чином, у дисертації усунено обмеження існуючих методів аналізу мультимодальних медичних даних, що дало змогу створити науково обґрунтовану та практично реалізовану платформу для класифікації станів пацієнтів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Abdullah, S. S., Ameen, S. Y., Sadeeq, M. M. A., & Zeebaree, S. R. (2021). Multimodal emotion recognition using deep learning. *Journal of Applied Science and Technology Trends*, 2(2), 52–58. <http://doi.org/10.38094/jastt20291>
2. Priss, U. (2006). Formal Concept Analysis in Information Science. *Annual Review of Information Science and Technology*, 40(1), 521–543.
3. Bělohlávek, R. (2004). Concept lattices and order in fuzzy logic. *Annals of Pure and Applied Logic*, 128(1–3), 277–298.
4. Bayoudh, K., Knani, R., Hamdaoui, F., & Mtibaa, A. (2022). A survey on deep multimodal learning for computer vision: advances, trends, applications, and datasets. *The Visual Computer: International Journal of Computer Graphics*, 38, 2939–2970. <https://doi.org/10.1007/s00371-021-02166-7>
5. Behrad, F., & Abadeh, M. S. (2022). An overview of deep learning methods for multimodal medical data mining. *Expert Systems with Applications*, 200, 117006. <https://doi.org/10.1016/j.eswa.2022.117006>
6. Boyko, N. (2021). Models and algorithms for multimodal data processing. *WSEAS Transactions on Information Science and Applications*, 20, 87–97. <http://doi.org/10.37394/23209.2023.20.11>
7. Boyko, N. (2023). Research into machine learning algorithms for the construction of mathematical models of multimodal data classification problems. *JCPPE*, 11(2), 1–11. <https://doi.org/10.23939/jcpee2021.02.001>
8. Boyko, N. (2023). Study of multimodal identification algorithms using modern methods and tools of multivariate analysis. *Journal of China University of Geosciences*, 48(6), 31–44. <https://doi.org/10.3799/dqkx.2023.8118>
9. Alay, N., & Al-Baity, H. H. (2020). Deep learning approach for multimodal biometric recognition system based on the fusion of iris, face, and finger vein traits. *Sensors*, 20(19), 5523. <http://doi.org/10.3390/s20195523>
10. Cherrat, E., Alaoui, R., & Bouzahir, H. (2020). Convolutional neural networks approach for multimodal biometric identification system using the fusion of fingerprint, finger-vein, and face images. *PeerJ Computer Science*, 6, e248.

- <http://doi.org/10.7717/peerj-cs.248>
11. Kaytoue, M., Kuznetsov, S. O., & Napoli, A. (2011). Mining gene expression data with pattern structures in Formal Concept Analysis. *Information Sciences*, 181(10), 1989–2001.
 12. Kress, G. (2010). *Multimodality: A social semiotic approach to contemporary communication*. London: Routledge.
 13. Obiedkov, S. A., & Roth, C. (2002). Comparing performance of algorithms for generating concept lattices. *Journal of Experimental and Theoretical Artificial Intelligence*, 14(2-3), 189–216.
 14. Khaleghi, B. et al. (2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, 14(1), 28–44.
 15. Xie, L. et al. (2013). Multimodal joint information processing in human machine interaction: recent advances (guest editorial). *Multimedia Tools and Applications*, 1–5.
 16. Stathaki, T. Image fusion: algorithms and applications, Elsevier, 2008. ISBN: 978-0-12-372529-5
 17. Mitchell, H. B. Data fusion: concepts and ideas, Springer, 2nd edition, 2012.
 18. Vychodil, V. (2014). On minimal sets of graded attribute implications. *Information Sciences*, 277, 852–866. <https://doi.org/10.1016/j.ins.2014.02.116>.
 19. Adali, T. et al. (2013). Special Section on Multimodal Biomedical Imaging: Algorithms and Applications. *IEEE Trans. Multimedia*, 15.
 20. Kuznetsov, S. O. (2007). On stability of a formal concept. *Annals of Mathematics and Artificial Intelligence*, 49(1–4), 101–115. <https://doi.org/10.1007/s10472-007-9053-6>.
 21. Poelmans, J., Kuznetsov, S. O., Ignatov, D. I., & Dedene, G. (2013). Formal Concept Analysis in knowledge processing: A survey on models and techniques. *Expert Systems with Applications*, 40(16), 6601–6623. <https://doi.org/10.1016/j.eswa.2013.05.007>.
 22. Jewitt, C. (2008). Multimodal discourses across the curriculum. In M. Martin-Jones, A. M. de Mejía & N. H. Hornberger (Eds.), *Encyclopedia of Language*

- and Education* (2nd ed., Vol. 3, pp. 1098–1108). Springer.
https://doi.org/10.1007/978-0-387-30424-3_84
23. Ganter, B., & Wille, R. (1999). *Formal Concept Analysis: Mathematical Foundations*. Berlin: Springer-Verlag.
 24. Bezemer, J., & Kress, G. (2015). *Multimodality, Learning and Communication: A social semiotic frame*. London: Routledge.
<https://doi.org/10.4324/9781315687537>
 25. Hao, X., Yao, Y., & Li, Z. (2018). Integrating formal concept analysis with tensor models for medical signal analysis: Applications to ECG and EEG data. *Journal Name*, 45(2), 123–135.
 26. Debes, Ch. et al. (2014). Hyperspectral and LiDAR data fusion: Out- come of the 2013 GRSS data fusion contest. *IEEE J. Sel. Topics Appl. Earth Observations Remote Sens.*, 7.
 27. Cardoso, J.-F. (2021). The three easy routes to independent component analysis; contrasts and geometry. *Proc. ICA 2001*, (San Diego, CA, Dec. 2001), 1–6.
 28. Adali, T. et al. (2014). Diversity in independent component and vector analyses: Identifiability, algorithms, and applications in medical imaging. *IEEE Signal Process. Mag.*, (May 2014), Special Issue: Source Separation and its Applications.
 29. Jolliffe, I. T. (2002). *Principal Component Analysis* (2nd ed.). New York: Springer-Verlag. <https://doi.org/10.1007/b98835>.
 30. Alparone, L. et al. (2006). Data fusion contest: Fusion of panchromatic and multispectral images. *Proc. IGARSS*, (Jul. 2006), 3814–3815.
 31. Acar, E. et al. (2013). Understanding data fusion within the frame- work of coupled matrix and tensor factorizations. *Chemometrics and Intelligent Laboratory Systems*, 129, 53–63.
 32. Şimşekli, U. et al. (2013). Optimal weight learning for coupled tensor factorization with mixed divergences. *Proc. EUSIPCO*, (Marrakech, Morocco, Sep. 2013).

33. Correa, N. M. et al. (2010). Canonical correlation analysis for data fusion and group inferences. *IEEE Signal Process. Mag.*, 27 (4), 39–50.
34. Correa, N. M. et al. (2010). Multiset canonical correlation analysis for the fusion of concurrent single trial ERP and functional MRI. *NeuroImage*, 50(4), 1438–1445.
35. Lipianina-Honcharenko, K., Komar, M., Madarash, R., Novosad, S., Zhabiuk, V., Mykhalchuk, N., Koshytskyi, K., Lendiuk, D., Melnyk, N., Telikhovskyi, O. (2024). Design of an Intelligent System for Enhancing Urban Social Resilience. *Eastern-European Journal of Enterprise Technologies*, 6(13 (132)), 48-63. <http://doi.org/10.15587/1729-4061.2024.317717>.
36. Sui, J. et al. (2012). A review of multivariate methods for multimodal fusion of brain imaging data. *Journal of Neuroscience Methods*, 204 (1), 68–81.
37. Kovaleva, V., Bukhteeva, I., Kit, O. Y., & Nesmelova, I. V. (2020). Plant defensins from a structural perspective. *International Journal of Molecular Sciences*, 21(15), 1–23. <http://doi.org/10.3390/ijms21155307>
38. Kumar, G., & Jeyakumar, V. (2022). Multimodal, Multianatomical, and Multidimensional Medical Image Retrieval System. *Authorea*, 22. <http://doi.org/10.22541/au.167169946.63655650/v1>
39. Komar, M., Savenko, O., Sachenko, A., Lendiuk, T., Lipianina-Honcharenko, K. Hladiy, G., Vasylykiv, N. (2022). Evaluation the Efficiency of Information Technology of Big Data Intelligence Analysis and Processing. *COLINS-2022: 6th International Conference on Computational Linguistics and Intelligent Systems*, 3171, 1087–1096.
40. Lu, L., Mao, J., Wang, W., Ding, G., & Zhang, Z. (2020). A study of personal recognition method based on EMG signal. In *IEEE Transactions on Biomedical Circuits and Systems*, 14(4), 681–691. <http://doi.org/10.1109/TBCAS.2020.3005148>
41. Bezemer, J., & Kress, G. (2015). *Multimodality, Learning and Communication: A social semiotic frame* (1st ed.). London: Routledge. <https://doi.org/10.4324/978131568753>

42. Maiti, D., Basak, M., & Das, D. (2024). Multimodal Biometric Integration: Trends and Insights from the Past quinquennial. *International Journal of Computing and Digital Systems*, 16(1), 189–198.
43. Nawal, S. H., Noria, T., & Abdelkader, I. K. M. (2024). Behavioral biometrics to detect fake expert profiles during negotiation. *Multimedia Tools and Applications*, 1–20. Springer International Publishing. <https://doi.org/10.1007/s11042-024-18644-8>
44. Wang, C., Shakhovska, N., Sachenko, A., Komar, M. (2020). A New Approach for Missing Data Imputation in Big Data Interface. *Information Technology and Control*, 49(4), 541-555. <https://doi.org/10.5755/j01.itc.49.4.27386>
45. Pandey, P., Raghav, Y. Y., Gulia, S., Aggarwal, S., & Kumar, N. (2024). Supervised and Unsupervised Learning Techniques for Biometric Systems. *Supervised and Unsupervised Data Engineering for Multimedia Data*, 263–299. Wiley. <https://doi.org/10.1002/9781119786443.ch12>
46. Kress, G., & van Leeuwen, T. (1996). *Reading images: The grammar of visual design*. London: Routledge.
47. Pereira, T. M., Conceição, R. C., Sencadas, V., & Sebastião, R. (2023). Biometric recognition: A systematic review on electrocardiogram data acquisition methods. *Sensors*, 23(3), 1507. <https://doi.org/10.3390/s23031507>
48. Derevyanchuk, O., Hu, Zh., Balovsky, S., Holub, S., Kravchenko, H., Sapsai, I. (2025). Complex of Specialized Methods of Educational Data Mining for the Training of Vocational Education Teachers. *International Journal of Modern Education and Computer Science (IJMECS)*, 17 (1), 28-46. <https://doi.org/10.5815/ijmeecs.2025.01.03>
49. Holub, S., Salapatov, V. (2025). Application of Predicates for Building the Program Models. In: Kazymyr, V., et al. Mathematical Modeling and Simulation of Systems. *MODS 2024. Lecture Notes in Networks and Systems*, 1391. Springer, Cham. https://doi.org/10.1007/978-3-031-90735-7_23
50. Rajakumar, G., & Ananth Kumar, T. (2022). Design of advanced security system

- using vein pattern recognition and image segmentation techniques. *Advance Concepts of Image Processing and Pattern Recognition. Transactions on Computer Systems and Networks*, 213–225. Springer Singapore. https://doi.org/10.1007/978-981-16-9324-3_12
51. Rajasekar, V., Predić, B., Saracevic, M., Elhoseny, M., Karabasevic, D., Stanujkic, D., & Jayapaul, P. (2022). Enhanced multimodal biometric recognition approach for smart cities based on an optimized fuzzy genetic algorithm. *Scientific Reports*, 12(1), 1–11. <http://doi.org/10.1038/s41598-021-04652-3>
 52. Reel, P. S., Reel, S., Pearson, E., Trucco, E., & Jefferson, E. (2021). Using Machine learning approaches for multiomics data analysis. A review. *Biotechnology Advances*, 49. <https://doi.org/10.1016/j.biotechadv.2021.107739>
 53. O'Halloran, K. L. (2008). *Systemic functional-multimodal discourse analysis (SF-MDA): Constructing ideational meaning using language and visual imagery*. *Visual Communication*, 7(4), 443–475. <https://doi.org/10.1177/1470357208096210>
 54. Safavipour, M. H., Doostari, M. A., & Sadjedi, H. (2022). A hybrid approach to multimodal biometric recognition based on feature-level fusion of face, two irises, and both thumbprints. *Journal of Medical Signals and Sensors*, 12(3), 177–191. http://doi.org/10.4103/jmss.jmss_103_21
 55. Sardinha, T. B., & Pinto, M. V. (2019). Multi-Dimensional Analysis: Research Methods and Current Issues. *Bloomsbury Academic*. <https://doi.org/10.5040/9781350023857>
 56. Shoumy, N. J., Ang, L. M., Seng, K. P., Rahaman, D. M., & Zia, T. (2020). Multimodal Big data effective analytics: A Comprehensive survey using text, audio, visual and physiological signals. *Journal of Network and Computer Applications*, 149, 102447. <https://doi.org/10.1016/j.jnca.2019.102447>
 57. Prykhodko, S. B., & Trukhov, A. S. (2025). Keystroke dynamics recognition using nine-variate prediction ellipsoid for normalized data. *Radio Electronics, Computer Science, Control*, (1), 96–105. <https://doi.org/10.15588/1607-3274->

2025-1-9

58. Soleymani, S., Torfi, A., Dawson, J., & Nasrabadi, N. M. (2018). Generalized bilinear deep convolutional neural networks for multimodal biometric identification. In *25th IEEE International Conference on Image Processing (ICIP)*, 763–767. <http://doi.org/10.1109/ICIP.2018.8451532>
59. Zhao, F., Zhang, C., & Geng, B. (2024). Deep Multimodal Data Fusion. *ACM Computing Surveys*, 56(9), 1 –36. <https://doi.org/10.1145/3649447>
60. Tanveer, H., Adam, M. A., Khan, M. A., Ali, M. A., & Shakoor, A. (2023). Analyzing the Performance and Efficiency of Machine Learning Algorithms, such as Deep Learning, Decision Trees, or Support Vector Machines, on Various Datasets and Applications. *The Asian Bulletin of Big Data Management*, 3(2), 126–136. <https://doi.org/10.62019/abbdm.v3i2>.
61. Wei, J., Huang, H., Wang, Y., He, R., & Sun, Z. (2022). Towards more discriminative and robust iris recognition by learning uncertain factors. *IEEE Transactions on Information Forensics and Security*, 17, 865–879. <http://doi.org/10.1109/TIFS.2022.3154240>
62. Wu, Z., Wu, X., Zhu, Yu., Zhai, J., Yang, H., Yang, Z., Wang, C., & Sun, J. (2022). Research on Multimodal Image Fusion Target Detection Algorithm Based on Generative Adversarial Network. *Wireless Communications and Mobile Computing*, 2022(1), art. ID 1740909. <https://doi.org/10.1155/2022/1740909>.
63. Андреев, А. С. (2021). Особливості створення семантичних мереж. Automation and development of electronic devices (ADED-2021), Part 2, 89-92.
64. Рогущина, Ю.В., Гладун, А.Я. (2022). Використання онтологічних знань для багатокритеріального співставлення складних інформаційних об'єктів. *Проблеми програмування*, 3-4, 249-259.
65. Закон України № 2297–VI «Про захист персональних даних» (2010). Відомості Верховної Ради України, 2010, № 23, ст. 186.
66. Наказ МОЗ України № 587 «Деякі питання ведення Реєстру медичних записів, записів про направлення та рецептів в електронній системі охорони

- здоров'я» (2020, 28 лютого). База даних “Законодавство України” / Верховна Рада України. Отримано з даних законодавчої бази.
67. Prykhodko, S. B., Prykhodko, N. V., & Koltsov, A. V. (2024). A nonlinear regression model for early loc estimation of open-source kotlin-based applications. *Radio Electronics, Computer Science, Control*, (1), 85. <https://doi.org/10.15588/1607-3274-2024-1-8>.
 68. Prykhodko, S. B., Shutko, I. S., & Prykhodko, A. S. (2022). A nonlinear regression model to estimate the size of Web apps created using the cakephp framework. *Radio Electronics, Computer Science, Control*, (4), 129–139. <https://doi.org/10.15588/1607-3274-2021-4-12> (Web of Science Core Collection).
 69. Prykhodko, S. B., & Trukhov, A. S. (2024). Face recognition using the ten-variate prediction ellipsoid for normalized data based on the box-cox transformation. *Radio Electronics, Computer Science, Control*, (2), 82. <https://doi.org/10.15588/1607-3274-2024-2-9>.
 70. Prykhodko, S. (2024). Evaluating Quality of Software Systems by the Confidence and Prediction Intervals of Regressions for RFC, CBO and WMC Metrics. *WSEAS Transactions on Systems*, 23, 322-330. <https://doi.org/10.37394/23202.2024.23.36>.
 71. Prykhodko, S. B., Pukhalevych, A. V., Prykhodko, K. S., & Makarova, L. M. (2022). Nonlinear regression models for estimating the duration of software development in Java for PC based on the 2021 ISBSG data. *Radio Electronics, Computer Science, Control*, (3), 144. <https://doi.org/10.15588/1607-3274-2022-3-14>
 72. Norris, S., & Jones, R. H. (2005). *Discourse in action: Introducing mediated discourse analysis*. London: Routledge.
 73. Субботін С.О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень: Навчальний посібник. – Запоріжжя: ЗНТУ, 2018. 341 с.

74. Якименко, Д., Катаєва, Є. (2022). Методи та засоби інтелектуального аналізу текстових документів. *Вісник Черкаського державного технологічного університету*, 43–52. <https://doi.org/10.24025/2306-4412.2.2022.259408>.
75. Afriwardani, P., Jumadi, J., Pribadi, F. (2023). Development of Interactive Physics E-Book to Reduce Student Misconception. *Jurnal Penelitian Pendidikan IPA*, 9, 2018-2024. <https://doi.org/10.29303/jppipa.v9i4.1854>.
76. Alay, N., Al-Baity, H. (2020). Deep Learning Approach for Multimodal Biometric Recognition System Based on Fusion of Iris, Face, and Finger Vein Traits. *Sensors*, 20. <https://doi.org/10.3390/s20195523>.
77. Al-Obaydy, W., Ibrahim, N., Hashim, H., Najm, Y., Jalal, A. (2022). Document classification using term frequency-inverse document frequency and K-means clustering. *Indonesian Journal of Electrical Engineering and Computer Science*, 27, 1517-1524. <https://doi.org/10.11591/ijeecs.v27.i3.pp1517-1524>.
78. An, X., Zeng, H., Yang, W. (2016). Fault diagnosis of a wind turbine rolling bearing using adaptive local iterative filtering and singular value decomposition. *Transactions of the Institute of Measurement and Control*, 39. <https://doi.org/10.1177/0142331216644041>.
79. Aryan, Ch.K., Durai, R., Vincent, Ch., Vincent, P., Durai, M. (2017). Enhanced diffie-hellman algorithm for reliable key exchange. *IOP Conference Series: Materials Science and Engineering*, 263, 042015. <https://doi.org/10.1088/1757-899X/263/4/042015>.
80. Asghari, S., Nematzadeh, H., Akbari, E., Motameni, H. (2023). Mutual information-based filter hybrid feature selection method for medical datasets using feature clustering. *Multimedia Tools and Applications*, 1-23. <https://doi.org/10.1007/s11042-023-15143-0>.
81. Baltrusaitis, T., Ahuja, Ch., Morency, L.-P. (2017). Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. <https://doi.org/10.1109/TPAMI.2018.2798607>.

82. Bamidele, A., Jimoh, R., Ogundokun, R., Misra, S., Abikoye, O. (2022). Big Data Analytics of IoT-Based Cloud System Framework. *Smart Healthcare Monitoring Systems*. https://doi.org/10.1007/978-3-030-80821-1_9.
83. Arjun, B.C., Prakash, H.N. (2020). Feature Level Fusion of Seven Neighbor Bilinear Interpolation Data Sets of Finger Vein and Iris for Multimodal Biometric Recognition. *International Journal of Advanced Trends in Computer Science and Engineering*, 9, 1531-1536. <https://doi.org/10.30534/ijatcse/2020/95922020>.
84. Beegum, M., Sivanandan, A. (2023). Synonym Insensitive Searching: A Novel Synonym Weighted-Vector Space Model for Document Retrieval. <https://doi.org/10.1109/ICCSC56913.2023.10142977>.
85. Carvalho, N., Sant'anna, S. Bins, (2021). Esa Unclassified for Official Use Polinsar. Riemannian Principal Direction Divisive Partitioning for PolSAR image clustering. <https://doi.org/10.13140/RG.2.2.14516.78725>.
86. Chen, B., Chen, X., Fafa, Z., Bin, X., Wenrong, F., Wenlong, L. (2022). Integrated early fault diagnosis method based on direct fast iterative filtering decomposition and effective weighted sparseness kurtosis to rolling bearings. *Mechanical Systems and Signal Processing*, 171, 108897. <https://doi.org/10.1016/j.ymssp.2022.108897>.
87. Chen, F., Wang, X., Zhu, Y., Yuan, W., Hu, Y. (2023). Time-frequency Transformer with shifted windows for journal bearing-rotor systems fault diagnosis under multiple working conditions. *Measurement Science and Technology*, 34. <https://doi.org/10.1088/1361-6501/acd2f3>.
88. Daga, A., Fasana, A., Garibaldi, L., Marchesiello, S., Moshrefzadeh, A. (2021). Fast Computation of the Autogram for the Detection of Transient Faults. https://doi.org/10.1007/978-3-030-64908-1_44.
89. Deekshit, K., Rao, M., Rao, R. (2020). Fault Indexing Parameter Based Fault Detection in Induction Motor via MCSA with Wiener Filtering. *Electric Power Components and Systems*, 48, 2048-2062. <https://doi.org/10.1080/15325008.2021.1910376>.

90. Desmedt, Y., King, B., Schoenmakers, B. (2008). Revisiting the Karnin, Greene and Hellman Bounds, 183-198. https://doi.org/10.1007/978-3-540-85093-9_18.
91. Конвенція Ради Європи № 108 «Про захист осіб у зв'язку з автоматизованою обробкою персональних даних» (28 січня 1981). *Законодавча база України / Верховна Рада України*. Отримано з бази даних закону (доступ 31 серпня 2025 року)
92. El-Rahiem, B., Abd El-Samie, F., Amin, M. (2022). Multimodal biometric authentication based on deep fusion of electrocardiogram (ECG) and finger vein. *Multimedia Systems*, 28. <https://doi.org/10.1007/s00530-021-00810-9>
93. Er-Raoudi, M., Diany, M., Aissaoui, H., Mabrouki, M. (2021). Application of the Reassigned Smoothed Pseudo Wigner-Ville Distribution in Gear Defect Diagnosis. *Mapta Journal of Mechanical and Industrial Engineering (MJMIE)*, 4, 21-29. <https://doi.org/10.33544/mjmie.v4i2.148>.
94. Frank, A., Dalenogare, L., Ayala, N. (2019). Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production Economics*, 210. <https://doi.org/10.1016/j.ijpe.2019.01.004>.
95. Gandhi, A., Adhvaryu, K., Poria, S., Cambria, E., Hussain, A. (2022). Multimodal Sentiment Analysis: A Systematic review of History, Datasets, Multimodal Fusion Methods, Applications, Challenges and Future Directions. *Information Fusion*, 91. <https://doi.org/10.1016/j.inffus.2022.09.025>.
96. Gao, J., Li, P., Chen, Z., Zhang, J. (2020). A Survey on Deep Learning for Multimodal Data Fusion. *Neural Computation*, 32, 1-36. https://doi.org/10.1162/neco_a_01273.
97. Ge, G., Siddique, A., Zhang, J. (2023). Inconsistent CT NSCLC radiomics associated with feature selection methods, predictive models and related factors. *Physics in medicine and biology*, 68. <https://doi.org/10.1088/1361-6560/acce1c>.
98. Gialampoukidis, I., Moumtzidou, A., Liparas, D., Tsikrika, T., Vrochidis, S., Kompatsiaris, I. (2017). Multimedia retrieval based on non-linear graph-based fusion and partial least squares regression. *Multimedia Tools and Applications*, 76, 1-21. <https://doi.org/10.1007/s11042-017-4797-4>.

99. Srivastava, N., & Salakhutdinov, R. (2012). *Multimodal learning with Deep Boltzmann Machines*. In *Advances in Neural Information Processing Systems 25* (pp. 2222–2230). Curran Associates.
100. Greenacre, M., Groenen, P., Hastie, T., Iodice D'Enza, A., Markos, A., Tuzhilina, E. (2022). Principal component analysis, 2, 100. <https://doi.org/10.1038/s43586-022-00184-w>.
101. Grevenitis, K., Psarommatis, Foivos, R., Alice, X.W., Tourkogiorgis, I., Milenkovic, J., Cassina, J., Kiritsis, D. (2019). A hybrid framework for industrial data storage and exploitation. *Procedia CIRP*, 81, 892-897. <https://doi.org/10.1016/j.procir.2019.03.221>.
102. Guan, Y., Shi, J., Liang, M., Necsulescu, D. (2018). Gearbox fault diagnosis via generalized velocity synchronous Fourier transform and order analysis. *Transactions of the Canadian Society for Mechanical Engineering*, 43, <https://doi.org/10.1139/tcsme-2018-0098>.
103. Hailu, T., Abdulkadir, T. (2023). MultiDMet: Designing a Hybrid Multidimensional Metrics Framework to Predictive Modeling for Performance Evaluation and Feature Selection. <https://doi.org/10.21203/rs.3.rs-3111777/v1>.
104. Hamaide, V., Glineur, F. (2021). Unsupervised Minimum Redundancy Maximum Relevance Feature Selection for Predictive Maintenance: Application to a Rotating Machine. *International Journal of Prognostics and Health Management*, 12. <https://doi.org/10.36001/ijphm.2021.v12i2.2955>.
105. Han, J. et al. (2021). Semantic networks for engineering design: A survey. *Proceedings of the Design Society*, 1, 2621–2630.
106. He, B., Bai, K.-J. (2020). Digital twin-based sustainable intelligent manufacturing: a review. *Advances in Manufacturing*, 9. <https://doi.org/10.1007/s40436-020-00302-5>.
107. Heller, S., Spiess, F., Schuldt, H. (2023). A tale of two interfaces: vitivr at the lifelog search challenge. *Multimedia Tools and Applications*, 1-25. <https://doi.org/10.1007/s11042-023-15082-w>.

108. Hou, Ya., Zhou, Ch., Tian, Ch., Wang, D., He, Weiting, H., Wenjun, W., Peng, W.D. (2022). Acoustic feature enhancement in rolling bearing fault diagnosis using sparsity-oriented multipoint optimal minimum entropy deconvolution adjusted method. *Applied Acoustics*, 201, 109105. <https://doi.org/10.1016/j.apacoust.2022.109105>.
109. Hua, Ju., Li, Ch. (2018). Distributed Outlier-Robust Bayesian Filtering for State Estimation. *IEEE Transactions on Signal and Information Processing over Networks*, 11. <https://doi.org/10.1109/TSIPN.2018.2889579>.
110. Hung, M., Hsiao, M. (2022). Application of Adaptive Neural Network Algorithm Model in English Text Analysis. *Computational Intelligence and Neuroscience*. <https://doi.org/10.1155/2022/4866531>.
111. Jain, D., Beniwal, P. (2022). Review Paper on Noise Cancellation using Adaptive Filters, 11, 241-244.
112. Jain, P., Lapata, M. (2023). Conversational Semantic Parsing using Dynamic Context Graphs.
113. Karami, M., Mariun, N., Kadir, Z., Norhisam, M. Mohd, R., Mohd, A. (2021). Motor Current Signature Analysis-based Non-invasive Recognition of Mixed Eccentricity Fault in Line Start Permanent Magnet Synchronous Motor. *Electric Power Components and Systems*, 49, 133-145. <https://doi.org/10.1080/15325008.2021.1937386>.
114. Kaya, K., Selçuk, A., Tezcan, Z. (2006). Threshold Cryptography Based on Asmuth-Bloom Secret Sharing. *Information Sciences: an International Journal*, 177, 935-942. https://doi.org/10.1007/11902140_97.
115. Li, H., Yan, W., Shuo, L.Ju., Cui, Yu. (2023). Text classification on heterogeneous information network via enhanced GCN and knowledge. *Neural Computing and Applications*, 35. <https://doi.org/10.1007/s00521-023-08494-0>.
116. Li, J., McClellan, Ju., Gao, G., Huo, D. (2023). Expression- and splicing-based multi-tissue transcriptome-wide association studies identified multiple genes for estrogen receptor-negative breast cancer. *Cancer Research*, 83, 5225-5225. <https://doi.org/10.1158/1538-7445.AM2023-5225>.

117. Liu, Ch., Li, Y., Zhou, G., Shen, W. (2018). A sensor fusion and support vector machine based approach for recognition of complex machining conditions. *Journal of Intelligent Manufacturing*, 29. <https://doi.org/10.1007/s10845-016-1209-y>.
118. Lu, W., Jiang, W., Zhang, N., Xue, F. (2021). A Deep Learning-Based Text Classification of Adverse Nursing Events. *Journal of Healthcare Engineering*. <https://doi.org/10.1011/2021/9800114>.
119. Ma, B., Wang, K., Hu, Yu. (2023). Finger vein recognition based on bilinear fusion of multiscale features. *Scientific Reports*, 13. <https://doi.org/10.1038/s41598-023-27524-4>.
120. Maharjan, S., Maharjan, N., Maharjan, N., Tuladhar, S., Shah, K. (2022). Visual Cryptography based on Shamir's secret sharing (VCSSS) and its comparison with Caesar Cipher Algorithm for Image Encryption. *SCITECH Nepal*, 16, 69-74.
121. Mileo, A., Wang, P., Smeaton, A. (2014). Semantically Enhancing Multimedia Lifelog Events. https://doi.org/10.1007/978-3-319-13168-9_17.
122. Mishra, A., Mohapatro, M. (2019). An IoT framework for Bio-medical sensor data acquisition and machine learning for early detection. *International Journal of Advanced Technology and Engineering Exploration*, 6, 112-125. <https://doi.org/10.19101/IJATEE.2019.650027>.
123. Mourtzis, D., Vlachou, K., Milas, N. (2016). Industrial Big Data as a Result of IoT Adoption in Manufacturing. *Procedia CIRP*, 55, 290-295. <https://doi.org/10.1016/j.procir.2016.07.038>.
124. Navigli, R. (2012). The automatic construction, evaluation and application of a wide-coverage multilingual semantic network. *Artificial Intelligence*, 193, 217–250.
125. Nielsen, E., Goldwater, Sh., Steedman, M. (2023). Prosodic features improve sentence segmentation and parsing. <https://doi.org/10.48550/arXiv.2302.12165>.
126. Noui, L. (2023). A Novel Method for the Analysis of Privacy of Shamir's Scheme. <https://doi.org/10.13140/RG.2.2.36797.84967>.

127. Omotosho, L., Kazeem, I., Yusuf, A., Oyeniyi, J. (2021). An enhanced multimodal biometric system based on convolutional neural network. *Journal of Engineering Studies and Research*, 27, 73. <https://doi.org/10.29081/jesr.v27i2.276>.
128. Özbey, C., Altınok, H., Demirezen, M. (2022). A Novel Probabilistic Framework for Modeling Spelling Errors by Term Length and Frequency. <https://doi.org/10.1109/IISEC56263.2022.9998097>.
129. Ozcan, M., Konuk, B., Yeşilçimen, M. (2022). Big Data Analytics in Industry 4.0. https://doi.org/10.1007/978-981-19-2012-7_8.
130. Panchal, P., Dhiman, R. (2023). Machine learning techniques for electroencephalogram based brain-computer interface. *A systematic literature review*, 28. <https://doi.org/10.1016/j.measen.2023.100823>.
131. Pandor, R., Mocan, M. (2023). The Importance of e-Book Platforms in Education. *Scientific Bulletin of the Politehnica University of Timișoara Transactions on Engineering and Management*, 5, 14-19. <https://doi.org/10.59168/GERC8467>.
132. Peng, H., Long, F., Ding, Ch. (2005). Feature Selection Based On Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. *IEEE transactions on pattern analysis and machine intelligence*, 27, 1226-38. <https://doi.org/10.1109/TPAMI.2005.159>.
133. Pisa, I., Morell, A., Vilanova, R., Lopez Vicario, J. (2021). Industrial Control under Non-Ideal Measurements: Data-Based Signal Processing as an Alternative to Controller Retuning. *Sensors*, 21, 1237. <https://doi.org/10.3390/s21041237>.
134. Qaisar, F., Shahab, H., Iqbal, M., Sargana, H., Qayyum, M. (2023). Recent Trends in Cloud Computing and IoT Platforms for IT Management and Development: A Review. *Pakistan Journal of Engineering and Technology*, 6, 98-105. <https://doi.org/10.51846/vol6iss1pp98-105>.
135. Rabi, J. B., Jawahar, R. (2019). Analysis of vibration signal responses on pre induced tunnel defects in friction stir welding using wavelet transform and empirical mode decomposition. *Defence Technology*, 15. <https://doi.org/10.1016/j.dt.2019.05.014>.

136. Randall, R.B. (2004). Unsupervised noise cancellation for vibration signals: Part I - Evaluation of adaptive algorithms. *Mechanical Systems and Signal Processing*, 18, 89-101. [https://doi.org/10.1016/S0888-3270\(03\)00012-8](https://doi.org/10.1016/S0888-3270(03)00012-8).
137. Randall, R. (2021). Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace Applications, Second Edition. <https://doi.org/10.1002/9781119477631>.
138. Sahal, R., Ali, M. I., Breslin, J. (2020). Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case. *Journal of Manufacturing Systems*, 54, 138-151. <https://doi.org/10.1016/j.jmsy.2019.11.004>.
139. Said, Z., Sharma, P., Nhung, Q., Bora, B., Lichtfouse, E., Khalid, H.M., Luque, R., Nguyen, X. P., Hoang, A. (2023). Intelligent approaches for sustainable management and valorisation of food waste. *Bioresource Technology*, 377, 128952. <https://doi.org/10.1016/j.biortech.2023.128952>.
140. Salau, A., Jain, Sh. (2019). Feature Extraction: A Survey of the Types, Techniques, Applications, 158-164. <https://doi.org/10.1109/ICSC45622.2019.8938371>.
141. Santos, M., Oliveira e Sá, J., Andrade, C., Lima, F., Costa, E., Costa, C., Martinho, B., Galvão, J. (2017). A Big Data system supporting Bosch Braga Industry 4.0 strategy. *International Journal of Information Management*. <https://doi.org/10.1016/j.ijinfomgt.2017.07.012>.
142. Santoso, H., Lubis, A., Darta, A. (2021). Utilization of Asmuth-Bloom Algorithm In Data Security Using Secret Sharing Protocol. *International Journal of Information System and Technology*, 5, 400. <https://doi.org/10.30645/ijistech.v5i4.158>.
143. Sehri, M., Dumond, P., Bouchard, M. (2023). University of Ottawa constant load and speed rolling-element bearing vibration and acoustic fault signature datasets. *Data in Brief*, 49. <https://doi.org/10.1016/j.dib.2023.109327>.

144. Shajalal, M., Atabuzzaman, M., Baby, M., Karim, R., Boden, A. (2023). Textual Entailment Recognition with Semantic Features from Empirical Text Representation. https://doi.org/10.1007/978-3-031-33231-9_12.
145. Jaimes, A., & Sebe, N. (2007). *Multimodal human–computer interaction: A survey*. *Computer Vision and Image Understanding*, 108(1–2), 116–134. <https://doi.org/10.1016/j.cviu.2006.10.019>.
146. Soleymani, S., Dabouei, A., Kazemi, H., Dawson, J., Nasrabadi, N.M. (2018). Multi-Level Feature Abstraction from Convolutional Neural Networks for Multimodal Biometric Identification, 3469-3476. <https://doi.org/10.1109/ICPR.2018.8545061>.
147. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929-1958.
148. Sun, Y., Xu, W., Yu, X., Gao, Ju. (2023). VT-BPAN: Vision Transformer-based bilinear pooling and attention network fusion of RGB and skeleton features for human action recognition. <https://doi.org/10.21203/rs.3.rs-2627627/v1>.
149. Szczepaniuk, H., Szczepaniuk, E. (2022). Assessment of it Systems Architecture in the Context of Big Data Processing for Smart Cities Development. *Journal of Security and Sustainability Issues*, 12, 139-158. <https://doi.org/10.47459/jssi.2022.12.12>.
150. Tian, Y., Gao, F., Wu, P. (2021). Intelligent Diagnosis of Equipment Health Based on IOT and Operation Large Data Analysis. *Journal of Physics: Conference Series*, 1992, 042070. <https://doi.org/10.1088/1742-6596/1992/4/042070>.
151. Tiong, L., Kim, S., Ro, Y. (2020). Multimodal facial biometrics recognition: Dual-stream convolutional neural networks with multi-feature fusion layers. *Image and Vision Computing*, 102, 103977. <https://doi.org/10.1016/j.imavis.2020.103977>.
152. Oviatt, S. (1999). Ten myths of multimodal interaction. *Communications of the ACM*, 42(11), 74–81.

153. Tyagi, Sh., Chawla, B., Jain, R., Srivastava, S. (2021). Multimodal biometric system using deep learning based on face and finger vein fusion. *Journal of Intelligent & Fuzzy Systems*, 42, 1-13. <https://doi.org/10.3233/JIFS-189762>.
154. Van Beeumen, R., Michiels, W., Meerbergen, K. (2015). Linearization of Lagrange and Hermite interpolating matrix polynomials. *IMA Journal of Numerical Analysis*, 35, 909-930. <https://doi.org/10.1093/imanum/dru019>.
155. Verma, A., Arvind, P., Sarangi, S., Kumar, Ja., Anumeha, Dr. (2022). Detection of Broken Rotor Bar Fault in an Induction Motor Employing Motor Current Signature Analysis. https://doi.org/10.1007/978-981-16-9239-0_39.
156. Vogt, L., Kuhn, T., Hoehndorf, R. (2023). Semantic Units: Organizing knowledge graphs into semantically meaningful units of representation. <https://doi.org/10.13140/RG.2.2.13742.59203>.
157. Volpe, G., Mangini, A., Fanti, M.P. (2022). An Architecture Combining Blockchain, Docker and Cloud Storage for Improving Digital Processes in Cloud Manufacturing. *IEEE Access*, 10. <https://doi.org/10.1109/ACCESS.2022.3194264>.
158. Vyskočil, J., Douda, P., Novak, P., Wally, B. (2023). A Digital Twin-Based Distributed Manufacturing Execution System for Industry 4.0 with AI-Powered On-The-Fly Replanning Capabilities. *Sustainability*, 15, 6251. <https://doi.org/10.3390/su15076251>.
159. Wan, Z., Tian, F., Zhang, Ch. (2023). Sheep Face Recognition Model Based on Deep Learning and Bilinear Feature Fusion. *Animals*, 13, 1957. <https://doi.org/10.3390/ani13121957>.
160. Wang, Ch., Huang, Zh., Wan, Yu., Wei, Ju., Zhao, Ju., Wang, P. (2022). FuAlign: Cross-lingual entity alignment via multi-view representation learning of fused knowledge graphs. *Information Fusion*, 89. <https://doi.org/10.1016/j.inffus.2022.08.002>.
161. Wang, D., Li, Y., Jia, L., Song, Ya., Wen, T. (2022). Attention-Based Bilinear Feature Fusion Method for Bearing Fault Diagnosis. *IEEE/ASME Transactions on Mechatronics*, 1-11. <https://doi.org/10.1109/TMECH.2022.3223358>.

162. Wang, X., Zhao, G., Liu, Yu., Yang, Sh. (2021). Uncertain Nonlinear Process Monitoring Using Interval Ensemble Kernel Principal Component Analysis. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 25, 101-109. <https://doi.org/10.20965/jaciii.2021.p0101>.
163. Wang, Ya., Dong, J., Wang, B. (2022). Feature Matching Optimization of Multimedia Remote Sensing Images Based on Multiscale Edge Extraction. *Computational Intelligence and Neuroscience*, 1-7. <https://doi.org/10.1155/2022/1764507>.
164. Wang, Zh., Yang, J., Guo, Yu. (2022). Unknown fault feature extraction of rolling bearings under variable speed conditions based on statistical complexity measures. *Mechanical Systems and Signal Processing*, 172, 108964. <https://doi.org/10.1016/j.ymssp.2022.108964>.
165. Watanabe, S., Yamana, H. (2022). Overfitting measurement of convolutional neural networks using trained network weights. *International Journal of Data Science and Analytics*, 14, 1-18. <https://doi.org/10.1007/s41060-022-00332-1>.
166. Weng, X. (2022). Construction of a Multimedia-Assisted Teaching System for English Courses in a Multimodal Sensing Environment. *Journal of Sensors*, 1-10. <https://doi.org/10.1155/2022/3775658>.
167. Wenming, C., Feng, W., Lin, Q., Cao, G., He, Zh. (2020). A Review of Hashing Methods for Multimodal Retrieval. *IEEE Access*, 1-1. <https://doi.org/10.1109/ACCESS.2020.2968154>.
168. Willner, A., Gowtham, V. (2020). Toward a Reference Architecture Model for Industrial Edge Computing. *IEEE Communications Standards Magazine*, 4, 42-48. <https://doi.org/10.1109/MCOMSTD.001.2000007>.
169. Xu, J., Mayer, W., Zhang, H., He, K., Feng, Z. (2022). Automatic Semantic Modeling for Structural Data Source with the Prior Knowledge from Knowledge Base.
170. Xu, X., Guo, J., Ye, P., Zhang, W. (2023). Approximation Properties of the Vector Weak Rescaled Pure Greedy Algorithm. *Mathematics*, 11, 2020. <https://doi.org/10.3390/math11092020>.

171. Yan, R., Dang, D., Gao, H., Wu, Ya., Yu, W. (2023). A novel word-graph-based query rewriting method for question answering. *Data Technologies and Applications*. <https://doi.org/10.1108/DTA-05-2022-0187>.
172. Yang, Q., Chen, X., He, Zh., Chang, L. (2022). Survey on Deep Learning Based Fusion Recognition of Multimodal Biometrics. https://doi.org/10.1007/978-3-031-20233-9_52.
173. Yuhas, B., Sejnowski, T. (1989). Integration of Acoustic and Visual Speech Signals Using Neural Networks. *Communications Magazine, IEEE*, 27, 65 - 71. <https://doi.org/10.1109/35.41402>.
174. Zhang, G., Zhang, Y., Chen, Yu., Zhang, H., Zheng, Yu. (2023). Multi-granularity feature utilization network for cross-modality visible-infrared person re-identification. *Soft Computing*, 1-14. <https://doi.org/10.1007/s00500-023-08321-7>.
175. Zhang, Q., Sun, Z., Hu, W., Chen, M., Guo, L., Qu, Yu. (2019). Multi-view Knowledge Graph Embedding for Entity Alignment, 5429-5435. <https://doi.org/10.24963/ijcai.2019/754>.
176. Zhang, Yu., Peng, Ch., Wang, Q., Song, D., Li, K., Zhou, S. (2023). Unified Multi-Modal Image Synthesis for Missing Modality Imputation.
177. Zhao, Zh., Anand, R., Wang, M. (2019). Maximum Relevance and Minimum Redundancy Feature Selection Methods for a Marketing Machine Learning Platform.
178. Calhoun, V. D., & Sui, J. (2016). *Multimodal fusion of brain imaging data: A key to finding the missing link(s) in complex mental illness*. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, 1(3), 230–244. <https://doi.org/10.1016/j.bpsc.2015.12.005>.
179. Візнюк, І., Буглай, Н., Куцак, Л., Поліщук, А., Киливник, В. (2021). Використання штучного інтелекту в освіті. *Modern Information Technologies and Innovation Methodologies of Education in Professional Training Methodology Theory Experience Problems*, 59, 14–22. <https://doi.org/10.31652/2412-1142-2021-59-14-22>

180. Денесяк, О., Паламарчук, Є. (2021). Комплексна система прокторінгу в інформаційних технологіях аналізу контексту в системах оцінювання знань. *Вісник Вінницького політехнічного інституту*, 6, 93–99. <https://doi.org/10.31649/1997-9266-2021-159-6-93-99>
181. Мар'єнко, М., Коваленко, В. (2023). Штучний інтелект та відкрита наука в освіті. *Фізико-математична освіта*, 38, 1, 48–53. <https://doi.org/10.31110/2413-1571-2023-038-1-007>
182. Мел. Висота звуку. Режим доступу: <https://uk.wikipedia.org>
183. Піжук, О. І. (2019). Штучний інтелект як один із ключових драйверів цифрової трансформації економіки. *Економіка, управління та адміністрування*, 3(89).
184. Поворознюк Р. В., Антонова В. (2018). Протистояння людей та машин: еволюція машинного перекладу на прикладі передопераційних інструкцій. *Мовні і концептуальні картини світу*, 2. С. 138-143.
185. Стрюк, О. С., Кондратенко, Ю. П. (2023). Методи прикладного застосування генеративних змагальних мереж при обробці графічних даних *Stuc. Intelekt*, 28(3), 154-161.
186. Agarwal, A. (2021). Evaluate Generalisation & Robustness of Visual Features from Images to Video. <https://doi.org/10.13140/RG.2.2.33887.53928>.
187. Agrawal, A., Rao, M., Sahu, A., Chennupati, G., Stolcke, A. (2023). Learning When to Trust Which Teacher for Weakly Supervised ASR.
188. Aktay, S. (2022). The Usability of Images Generated by Artificial Intelligence (AI) in Education. *International technology and education journal*, 6(2), 51–62.
189. Aurpa, T. T., Rifat, R., Ahmed, Md Sh., Anwar, Md. A.. (2022). Reading comprehension based question answering system in Bangla language with transformer-based learning. *Heliyon*, 8, e11052. <https://doi.org/10.1016/j.heliyon.2022.e11052>.
190. Bahatti L., Bouattane O., Ech-Chhibat M., Zaggaf M. (2016). An Efficient Audio Classification Approach Based on Support Vector Machines. *International*

- Journal of Advanced Computer Science and Applications, 7, 205-211.
<https://doi.org/10.14569/IJACSA.2016.070530>
191. Balamurali B.T., Chen J., Herremans D., Priyadarshinee P., Clarke C., Lin, C., Hee H. (2022). A Gaussian mixture classifier model to differentiate respiratory symptoms using phonated /ɑ:/ sounds.
 192. Brima, Yu., Krumnack, U., Pika, S., Heidemann, G. (2024). Understanding Self-Supervised Learning of Speech Representation via Invariance and Redundancy Reduction. *Information*, 15, 114. <https://doi.org/10.3390/info15020114>.
 193. Burgess, A. (2018). The Executive Guide to Artificial Intelligence. How to identify and implement applications for AI in your organization. *Springer International Publishing*, 3.
 194. Duan, H., Shen, W., Min, X., Tu, D., Long, T. Wang, J., Zhai, G. (2023). Masked Autoencoders as Image Processors.
 195. Duan, Sh., Wu, L., Liu, A., Chen, X. (2023). Alignment-Enhanced Interactive Fusion Model for Complete and Incomplete Multimodal Hand Gesture Recognition. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*. <https://doi.org/10.1109/TNSRE.2023.3335101>.
 196. Tomashevskyi, V., Yatsyshyn, A., Pasichnyk, V., Kunanets, N., Rzheuskyi, A. (2020) Data Warehouses of Hybrid Type: Features of Construction. *Advances in Computer Science for Engineering and Education II*. ICCSEEA 2019. Advances in Intelligent Systems and Computing, 938. Springer, Cham. https://doi.org/10.1007/978-3-030-16621-2_30
 197. Gholami, Sh., Scheppke, L., Kshirsagar, M., Wu, Yu., Dodhia, R., Bonelli, R., Leung, I., Sallo, F., Muldrew, A., Jamison, C., Petö, T., Lavista F. J., Weeks, W., Friedlander, M., Lee, A. (2024). Self-Supervised Learning for Improved Optical Coherence Tomography Detection of Macular Telangiectasia Type 2. *JAMA ophthalmology*. <https://doi.org/10.1001/jamaophthalmol.2023.6454>.
 198. Greenfield D. (2019). Artificial intelligence in medicine: Applications, implications and limitations. Retrieved from Harvard University. Access at:

- <http://sitn.hms.harvard.edu/flash/2019/artificial-intelligence-inmedicine-applicationsimplications-andlimitations>.
199. Guo, H., Xie, F., Kang, J., Xiao, Yu., Wu, X., Meng, H. (2023). QS-TTS: Towards Semi-Supervised Text-to-Speech Synthesis via Vector-Quantized Self-Supervised Speech Representation Learning.
 200. Han, M., Zhan, Y., Luo, Y., Hu, H. Su, K., Du, B. (2023). Textual Enhanced Adaptive Meta-Fusion for Few-Shot Visual Recognition. *IEEE Transactions on Multimedia*, 1-11. <https://doi.org/10.1109/TMM.2023.3295731>.
 201. Inui, T. (2018). The Free-energy Principle: A Unified Theory of Brain Functions. *The Brain & Neural Networks*, 25, 123-134. <https://doi.org/10.3902/jnns.25.123>.
 202. Литвин, В. В., Висоцька, В. А., Досин, Д. Г., Гірняк, М. Г. (2015). Розроблення методів та засобів побудови інтелектуальних систем опрацювання інформаційних ресурсів з використанням онтологічного підходу. *Вісник Національного університету "Львівська політехніка"*. Серія Інформаційні системи та мережі, №832, 295-315
 203. Vladov, S., Yakovliev, R., Vysotska, V., Lytvyn, V., Romanchuk, R. (2025). Hybrid Networks Training Method Based on Distributed and Parallel Computing Technology. In *Lecture Notes in Data Engineering, Computational Intelligence, and Decision-Making, Volume 2: 2024 International Scientific Conference "Intelligent Systems of Decision-Making and Problems of Computational Intelligence"*, *Proceedings*, 244, 3). Springer Nature.
 204. Jammalamadaka, S., Cherukuri, A., (2024). Insights into Quantum Support Vector Machine. <https://doi.org/10.21203/rs.3.rs-4465421/v1>
 205. Jiang, L., Yang, Z., Shi, Sh., Golyanik, V., Dai, D., Schiele, B. (2023). Self-supervised Pre-training with Masked Shape Prediction for 3D Scene Understanding.
 206. Khan, A., Rauf, Z., Sohail, A., Khan, A., Asif, H., Asif, A., Farooq, U. (2023). A survey of the vision transformers and their CNN-transformer based variants. *Artificial Intelligence Review*, 56, 1-54. <https://doi.org/10.1007/s10462-023-10595-0>.

207. Yakovyna, V., Shakhovska, N. & Szpakowska, A. (2024). A novel hybrid supervised and unsupervised hierarchical ensemble for COVID-19 cases and mortality prediction. *Sci Rep*, 14, 9782. <https://doi.org/10.1038/s41598-024-60637-y>.
208. Li, X., Ge, Y., Yi, K., Hu, Z., Shan, Y, Duan, L.-Y. (2022). mc-BEiT: Multi-choice Discretization for Image BERT Pre-training. https://doi.org/10.1007/978-3-031-20056-4_14.
209. Kaminskyi, R., Kunanets, N., Rzhewskyi, A., Khudiyi, A. (2018). Methods of Statistical Research for Information Managers. *IEEE 13th International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT)*, Lviv, Ukraine, 127-131. doi: 10.1109/STC-CSIT.2018.8526588.
210. Nafi, Th., Haque, E., Farhan, F., Rahman, A. (2022). High Accuracy Swin Transformers for Image-based Wafer Map Defect Detection. *International Journal of Engineering and Manufacturing*, 12, 10-21. <https://doi.org/10.5815/ijem.2022.05.02>.
211. Ni, Ju., Wang, L., Gao, H., Qian, K., Zhang, Ya., Chang, Sh., Hasegawa-Johnson, M. (2022). Unsupervised Text-to-Speech Synthesis by Unsupervised Automatic Speech Recognition. <https://doi.org/10.13140/RG.2.2.19818.18884>.
212. Pressé, S., Sgouralis, I. (2023). Hidden Markov Models. <https://doi.org/10.1017/9781009089555.011>
213. Qin, Y., Ye, Yu., Zhao, Yu., Wu, J., Zhang, H., Cheng, K., Li, K. (2023). Nearest Neighboring Self-Supervised Learning for Hyperspectral Image Classification. *Remote Sensing*, 15, 1713. <https://doi.org/10.3390/rs15061713>.
214. Rodriguez Herrejón J., Reyes-Archundia E., Gutierrez Gneccchi J., Patino A.M., Olivares Rojas J. (2024). Detection of counterfeit images using SIFT and PNN. *Global Journal of Engineering and Technology Advances*, 20, 171-178. <https://doi.org/10.30574/gjeta.2024.20.1.0134>
215. Shakhovska, N., Yakovyna, V., Mysak, M., Mitoulis, S.-A., Argyroudis, S., & Syerov, Y. (2024). Real-Time Monitoring of Road Networks for Pavement

- Damage Detection Based on Preprocessing and Neural Networks. *Big Data and Cognitive Computing*, 8(10), 136. <https://doi.org/10.3390/bdcc8100136>
216. Setiawan, W., Wahyudin, A., Widiyanto, G. (2017). The use of scale invariant feature transform (SIFT) algorithms to identification garbage images based on product label, 336-341. <https://doi.org/10.1109/ICSITech.2017.8257135>
 217. Lypak, H., Rzhenskyi, A., Kunanets, N., Pasichnyk, V. (2018). Formation of a Consolidated Information Resource by Means of Cloud Technologies. *International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*, Kharkiv, Ukraine, 157-160. doi: 10.1109/INFOCOMMST.2018.8632106.
 218. Sun, Yu., Gao, D. Shen, X., Li, M., Nan, J., Zhang, W. (2022). Multi-Label Classification in Patient-Doctor Dialogues With the RoBERTa-WWM-ext + CNN (Robustly Optimized Bidirectional Encoder Representations From Transformers Pretraining Approach With Whole Word Masking Extended Combining a Convolutional Neural Network) Model: Named Entity Study. *JMIR Medical Informatics*. 10, e35606. <https://doi.org/10.2196/35606>.
 219. Tejankar, A., Wu, B., Xie, S., Khabsa, M., Pirsiavash, H., Firooz, H. (2021). A Fistful of Words: Learning Transferable Visual Models from Bag-of-Words Supervision.
 220. Wang, Yu., Huang, R., Song, Sh., Huang, Z., Huang, G. (2021). Not All Images are Worth 16x16 Words: Dynamic Vision Transformers with Adaptive Sequence Length.
 221. Xing, Zh., Zhu, L., Yu, L., Xing, Zh., Wan, L. (2024). Hybrid Masked Image Modeling for 3D Medical Image Segmentation. *IEEE journal of biomedical and health informatics*. <https://doi.org/10.1109/JBHI.2024.3360239>.
 222. Xue, L., Barua, A., Constant, N., Al-Rfou, R., Narang, Sh., Kale, M., Roberts, A., Raffel, C., (2022). ByT5: Towards a Token-Free Future with Pre-trained Byte-to-Byte Models. *Transactions of the Association for Computational Linguistics*, 10, 291-306. 10.1162/tacl_a_00461.

223. Ye, W., Liu, Ch., Chen, Yu., Liu, Y., Liu, Ch., Zhou, H. (2023). Multi-style transfer and fusion of image's regions based on attention mechanism and instance segmentation. *Signal Processing: Image Communication*, 110, 116871. <https://doi.org/10.1016/j.image.2022.116871>.
224. Zhang, B. (2022). Unsupervised English Intelligent Machine Translation in Wireless Network Environment. *Security and Communication Networks*, 2022, 1-9. <https://doi.org/10.1155/2022/8208242>.
225. Zhang, Ch., Zhang, Ch., Song, Ju., Yi, Jo., Zhang, K., Kweon, I. (2022). A Survey on Masked Autoencoder for Self-supervised Learning in Vision and Beyond. <https://doi.org/10.48550/arXiv.2208.00173>.
226. Zhang, H., Li, X., Bing, L. (2023). Video-LLaMA: An Instruction-tuned Audio-Visual Language Model for Video Understanding.
227. Zhang, M., Bohte, S. (2024). Energy Optimization Induces Predictive-coding Properties in a Multicompartment Spiking Neural Network Model. <https://doi.org/10.1101/2024.01.17.575877>.
228. Zhou, W., Shengyu, G., Zhang, L., Lou, X. (2020). Histogram of Oriented Gradients Feature Extraction From Raw Bayer Pattern Images. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 1-1. <https://doi.org/10.1109/TCSII.2020.2980557>
229. Thompson, B. (1984). Canonical correlation analysis: Uses and interpretation. *Sage University Paper Series on Quantitative Applications in the Social Sciences*. Sage.
230. Hardoon, D. R., Szedmak, S., & Shawe-Taylor, J. (2004). Canonical correlation analysis: An overview with application to learning methods. *Neural Computation*, 16(12), 2639-2664. <https://doi.org/10.1162/0899766042321814>
231. Andrew, G., Arora, R., Bilmes, J., & Livescu, K. (2013). Deep canonical correlation analysis. In *Proceedings of the 30th International Conference on Machine Learning (ICML)*, 1247-1255.
232. Yan, X., Mikolajczyk, K. (2015). Deep multi-modal canonical correlation analysis for facial expression recognition. In *Proceedings of the 2015 IEEE*

- International Conference on Computer Vision (ICCV)*, 3821-3829. IEEE.
<https://doi.org/10.1109/ICCV.2015.436>
233. Srivastava, N., & Salakhutdinov, R. (2012). Multimodal learning with deep Boltzmann machines. In *Advances in Neural Information Processing Systems (NeurIPS)*, 25, 2222-2230. Curran Associates.
 234. Wang, W., Arora, S., Livescu, K., & Bilmes, J. (2016). On deep multi-view representation learning. In *Proceedings of the 33rd International Conference on Machine Learning (ICML)*, 1083-1092. JMLR.
 235. Ganter, B., Wille, R. (1999). Formal concept analysis: Mathematical foundations. Springer. <https://doi.org/10.1007/978-3-642-59830-2>
 236. Hajian, B., Hüllermeier, E. (2012). Conceptual data analysis using fuzzy clustering. *Fuzzy Sets and Systems*, 206, 88-105.
<https://doi.org/10.1016/j.fss.2011.12.003>
 237. Cimiano, P., Hotho, A., & Staab, S. (2005). Learning concept hierarchies from text corpora using formal concept analysis. *Journal of Artificial Intelligence Research*, 24, 305-339. <https://doi.org/10.1613/jair.1617>
 238. Kodratoff, Y. (1994). Conceptual clustering for multimodal data mining. In *Proceedings of the 11th European Conference on Artificial Intelligence (ECAI)*, 531-535.
 239. Mitra, S., Acharya, T. (2007). Data mining: Multimedia, soft computing, and bioinformatics. John Wiley & Sons. <https://doi.org/10.1002/9780470119724>
 240. Graczyk, M., Lasota, T., & Trawinski, B. (2010). Multimodal conceptual data analysis for image and text recognition. *Pattern Recognition and Image Analysis*, 20(3), 383-390. <https://doi.org/10.1134/S1054661810030111>
 241. Zhang, S., Zhang, C. (2003). Association rule mining: Models and algorithms. In *Lecture notes in artificial intelligence*, 2307, 338-345. Springer.
https://doi.org/10.1007/3-540-46086-0_19
 242. Bell, D. A., Guan, J. (2013). On multimodal data mining and conceptual data analysis. In *Proceedings of the 2013 International Conference on Data Mining and Knowledge Discovery*, 12-19. <https://doi.org/10.1109/ICDMW.2013.74>

243. Baltrušaitis, T., Ahuja, C., Morency, L. P. (2019). Multimodal machine learning: A survey and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(2), 423-443. <https://doi.org/10.1109/TPAMI.2018.2798607>
244. Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828. <https://doi.org/10.1109/TPAMI.2013.50>
245. Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., Ng, A. Y. (2011). Multimodal deep learning. *Proceedings of the 28th International Conference on Machine Learning (ICML-11)*, 689-696.
246. Pang, Y., Zhang, Y., Li, J., Zhang, W. (2021). Multimodal fusion techniques in hybrid recommender systems: A survey. *Artificial Intelligence Review*, 54, 3423-3456. <https://doi.org/10.1007/s10462-020-09902-7>
247. Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., & Ng, A. Y. (2011). Deep multimodal learning for audio-visual speech recognition. *Advances in Neural Information Processing Systems*, 24, 2401-2409.
248. Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger, G., Sutskever, I. (2021). Learning transferable visual models from natural language supervision. *arXiv preprint arXiv:2103.00020*.
249. Zhou, L., Palangi, H., Zhang, L., Hu, H., Corso, J. J., Gao, J. (2020). Unified vision-language pre-training for image captioning and visual question answering. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(7), 13041-13049. <https://doi.org/10.1609/aaai.v34i07.7039>
250. Wang, H., Nie, L., Gao, X., Chua, T. S. (2016). Cross-modal retrieval using deep decomposed representation learning. *IEEE Transactions on Circuits and Systems for Video Technology*, 26(2), 417-429. <https://doi.org/10.1109/TCSVT.2015.2408892>
251. Zhou, J., Liu, J., Narayanan, A., Ye, J., Xia, Y. (2016). Multimodal tensor-based learning for multimodal data integration. *Proceedings of the 22nd ACM SIGKDD*

- International Conference on Knowledge Discovery and Data Mining*, 1105-1114.
<https://doi.org/10.1145/2939672.2939792>
252. Lu, J., Batra, D., Parikh, D., Lee, S. (2019). ViLBERT: Pretraining task-agnostic visiolinguistic representations for vision-and-language tasks. *Advances in Neural Information Processing Systems*, 32, 13-23.
 253. Mechelen, V., Smilde, A. K. (2010). A generic linked-mode decomposition model for data fusion. *Chemometrics and Intelligent Laboratory Systems*, 104(1), 83–94.
 254. Khaleghi, B. (Jan. 2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, 14(11), 28–44.
 255. Xie, L. et al. (2013). Multimodal joint information processing in human machine interaction: recent advances (guest editorial). *Multimedia Tools and Applications*, 1–5.
 256. Stathaki, T. (2008). Image fusion: algorithms and applications, *Elsevier*.
 257. Mitchell, H. B. (2011). Data fusion: concepts and ideas, *Springer, 2nd edition*.
 258. Bießmann, F. et al. (2011). Analysis of multimodal neuroimaging data, *IEEE Rev. Biomed. Eng.*, 4, 26–58.
 259. Adalı, T. et al., (2013) Special Section on Multimodal Biomedical Imaging: Algorithms and Applications. *IEEE Trans. Multimedia*, 15.
 260. Calhoun, V. D., Adalı, T. (2009). Feature-based fusion of medical imaging data. *IEEE Trans. Inf. Technol. Biomed.*, 13(5), 711–720.
 261. Rivet, B. et al. (2014). Audio-visual speech source separation. *IEEE Signal Process. Mag. Special Issue: Source Separation and its Applications*.
 262. Shivappa, S.T. et al. (2010), Audiovisual information fusion in human-computer interfaces and intelligent environments: A survey. *Proc. IEEE*, 98(10), 1692–1715.
 263. De Vos, M. et al. (2013). The quest for single trial correlations in multimodal EEG–fMRI data. In *Proc. EMBC'13*, (Osaka, Japan, Jul. 2013), 6027–6030.

264. Garibaldi, M., Zarzoso, V. (2013). Exploiting intracardiac and surface recording modalities for atrial signal extraction in atrial fibrillation. In *Proc. EMBC'13*, (Osaka, Japan, Jul. 2013), 6015–6018.
265. de Vel, V. et al. (2013). Non-EEG seizure-detection systems and potential SUDEP prevention: State of the art. *Seizure: European Journal of Epilepsy*, 22 (5), 345–355.
266. Debes, Ch. et al. (2014). Hyperspectral and LiDAR data fusion: Outcome of the 2013 GRSS data fusion contest,” *IEEE J. Sel. Topics Appl. Earth Observations Remote Sens.*, 1, 7.
267. Cardoso, J.-F. (2001). The three easy routes to independent component analysis; contrasts and geometry. In *Proc. ICA 2001*, (San Diego, CA, Dec. 2001), 1–6.
268. Adali T. et al., Diversity in independent component and vector analyses: Identifiability, algorithms, and applications in medical imaging. *IEEE Signal Process. Mag. Special Issue: Source Separation and its Applications*.
269. Kim, T. et al. (2006). Independent vector analysis: An extension of ICA to multivariate components. *Independent Component Analysis and Blind Signal Separation*, Heidelberg, 3889 of LNCS, 165–172, Springer.
270. Alparone, L. et al. (2006). Data fusion contest: Fusion of panchromatic and multispectral images, in *Proc. IGARSS*, 3814–3815.
271. Acar, E. et al. (2013). Understanding data fusion within the framework of coupled matrix and tensor factorizations. *Chemometrics and Intelligent Laboratory Systems*, 129, 53–63.
272. Simsekli, U. et al. (2013). Optimal weight learning for coupled tensor factorization with mixed divergences. *Proc. EUSIPCO*, (Marrakech, Morocco).
273. Correa, N. M. et al. (2010) Canonical correlation analysis for data fusion and group inferences. *IEEE Signal Process. Mag.*, 27(4), 39–50.
274. Correa, N. M. et al. (2010). Multi-set canonical correlation analysis for the fusion of concurrent single trial ERP and functional MRI. *NeuroImage*, 50 (4), 1438–1445.

275. Sui, J. et al. (2013). Three-way (N-way) fusion of brain imaging data based on mCCA+jICA and its application to discriminating schizophrenia. *NeuroImage*, 66, 119–132.
276. Sui, J. et al. (2012). A review of multivariate methods for multimodal fusion of brain imaging data. *Journal of Neuroscience Methods*, 204(1), 68–81.
277. Sîrghi, S., Sîrghi, A. (2020). Design for online teaching and learning in the context of digital education. *Știința culturii fizice*, 35(1), 50-54. <https://doi.org/10.52449/1857-4114.2020.35-1.08>.
278. Sulema, Ye., Dychka, I., Sulema, O. (2018). Multimodal Data Representation Models for Virtual, Remote, and Mixed Laboratories Development. *Lecture Notes in Networks and Systems, Springer Cham*, 47, 559-569.
279. Dychka, I.A., Sulema, E.S. (2020). Multimodal data representation model for a comprehensive description of observation objects. *Bulletin of the Vinnytsia Polytechnic Institute*, 1(1), 53–60. <https://doi.org/10.31649/1997-9266-2020-148-1-53-60>.
280. Boyko, N. (2016). Application of mathematical models for improvement of “cloud” data processes organization. *Mathematical Modeling and Computing: scientific journal ‘Computational problems elektotekhniki*, 3(2), 111-119. <https://doi.org/10.23939/mmc2016.02.111>.
281. Nusrat, J. S., Li-Minn, A., Kah Phooi Seng, D.M., Motiur, R., Tanveer, Z. Multimodal big data affective analytics: A comprehensive survey using text, audio, visual and physiological signals. *Journal of Network and Computer Applications*, 149, 102447. <https://doi.org/10.1016/j.jnca.2019.102447>.
282. Calvo, R., D’Mello, S. (2010). Affect Detection: An Interdisciplinary Review of Models, Methods, and Their Applications. *IEEE Transactions on Affective Computing*, 1, 18-37. <https://doi.org/10.1109/T-AFFC.2010>.
283. Scollon, R., Scollon, S. (2009). Multimodality and language: a retrospective and prospective view. *The Routledge Handbook of Multimodal Analysis*, 170–180.
284. Kunanets, N., Vasiuta, O., Boiko, N. (2019). Advanced Technologies of Big Data Research in Distributed Information Systems. *Proceedings of the 14th*

- International conference 'Computer sciences and Information technologies. (CSIT 2019)*, 71-76. <https://doi.org/10.1109/STC-CSIT.2019.8929756>.
285. Jewitt, C. (2013). Multimodal methods for researching digital technologies. *The Sage handbook of digital technology research*, 250–265.
286. Argelaguet, R., Cuomo, A.E., Stegle, O., Marioni, J. C. (2021). Computational principles and challenges in single-cell data integration. *Nature Biotechnology*, 39, 1202–1215. <https://doi.org/10.1038/s41587-021-00895-7>.
287. Peleshchyshyn, A., & Bandrovskiy, H. (2019). Informational influence in social networks: Dynamics modeling based on the system of linear equations. *2019 IEEE 14th International Conference on Computer Sciences and Information Technologies (CSIT)*, 1, 165–168. IEEE. <https://doi.org/10.1109/STC-CSIT.2019.8929731>
288. Korzh, R., Peleshchyshyn, A., Trach, O., & Tsiutsiura, M. (2019). Increasing the efficiency of the processes of formation of the informational image of the HEI. *Proceedings of the 2019 IEEE 14th International Conference on Computer Sciences and Information Technologies (CSIT)*, 2, 661–664. IEEE. <https://doi.org/10.1109/STC-CSIT.2019.8929894>
289. Strutynska, I., Kozbur, H., Dmytrotsa, L., Hlado, O., Melnyk, L., & Aleksander, M. (2019). Comparative analysis of two approaches to the clustering of respondents (Based on survey results). *Proceedings of the International Conference on Computer Modeling and Intelligent Generation of New Knowledge (CMiGIN 2019)*, 434–446. CEUR-WS. <http://ceur-ws.org/Vol-2393/paper37.pdf>
290. Trach, O., Peleshchyshyn, A., & Korzh, R. (2020). Methods for creating a team for managing a virtual community. *Proceedings of the CEUR Workshop on Information Systems and Technologies*, 83–92. CEUR-WS. <http://ceur-ws.org/Vol-2604/paper09.pdf>
291. Alkhalaf, S. (2021). A robust variance information fusion technique for real-time autonomous navigation systems. *Measurement*, 109441, 179. <https://doi.org/10.1016/j.measurement.2021.109441>.

292. Cuayahuitl, H. (2020). A data-efficient deep learning approach for deployable multimodal social robots. *Neurocomputing*, 396, 587–598. <https://doi.org/10.1016/j.neucom.2018.09.104>.
293. Liu, H., Fang, T., Zhou, T., Wang, L. (2021). Towards robust human-robot collaborative manufacturing: Multimodal fusion. *IEEE Access*, 6, 74762–74771. <https://doi.org/10.1109/ACCESS.2018.2884793>.
294. Ma, M., Sun, C., Chen, X. (2018). Deep coupling autoencoder for fault diagnosis with multimodal sensory data. *IEEE Transactions on Industrial Informatics*, 14, 1137–1145. <https://doi.org/10.1109/TII.2018.2793246>.
295. Yang, Z., Baraldi, P., Zio, E. (2021). A multi-branch deep neural network model for failure prognostics based on multimodal data. *Journal of Manufacturing Systems*, 59, 42–50. <https://doi.org/10.1016/j.jmsy.2021.01.007>.
296. Al-Dulaimi, A., Zabihi, S., Asif, A., Mohammadi, A. (2019). A multimodal and hybrid deep neural network model for remaining useful life estimation. *Computers in Industry*, 108, 186–196. <https://doi.org/10.1016/j.compind.2019.02.004>.
297. Kumar, S., Kolekar, T., Patil, S., Bongale, A., Kotecha, K., Zaguia, A., Prakash, C. (2022). A low-cost multi-sensor data acquisition system for fault detection in fused deposition modelling. *Sensors*, 22, 517. <https://doi.org/10.3390/s22020517>.
298. Lu, Y., Liu, C., Wang, K. I-K., Huang, H., Xu, X. (2020). Digital Twin-driven smart manufacturing: connotation, reference model, applications and research issues. *Robotics and Computer Integrated Manufacturing*, 61, 1–14.
299. Alam, K. M., El Saddik, A. (2017). C2PS: A digital twin architecture reference model for the cloud-based cyber-physical systems. *IEEE Access*, 5, 2050–2062.
300. Redelinghuys, A. J. H., Basson, A. H., Kruger, K. A Six-Layer Digital Twin Architecture for a Manufacturing Cell. *Studies in Computational Intelligence*, 803, 412–423.
301. Boyko, N., Muzyka, M. (2021). Analysis of Multimodal Data for Classification Problems by Using Methods of Machine Learning. *2021 IEEE 8th International*

- Conference on Problems of Infocommunications, Science and Technology (PIC S&T)*, 525-534. <https://doi.org/10.1109/PICST54195.2021.9772203>.
302. Boyko, N., Tkachuk, N. (2020). Processing of Medical Different Types of Data Using Hadoop and Java MapReduce. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)*, 405-414.
 303. Ronen, E., Shamir, A. (2016). Extended functionality attacks on IoT devices: The case of smart lights. *Proceedings of the 2016 IEEE European symposium on security and privacy (SP'16)*, 3–12.
 304. Dhanda, S.S., Singh, B., Jindal, P. (2020). Lightweight Cryptography: A Solution to Secure IoT. *Wireless Personal Communications*, 112, 1947– 1980.
 305. Dutta, I. K., Ghosh, B., Bayoumi, M. (2019). Lightweight Cryptography for Internet of Insecure Things: A Survey. *Proceedings of the IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC2019)*, 0475-0481.
 306. Boyko, N. (2016). A look trough methods of intellectual data analysis and their applying in informational systems. *XIth International Scientific and Technical Conference Computer Sciences and Information Technologies (CSIT)*, 183-185. <https://doi.org/10.1109/STC-CSIT.2016.7589901>
 307. Boyko, N., Sviridova, T., Shakhovska, N. (2018). Use of machine learning in the forecast of clinical consequences of cancer diseases. *7th Mediterranean Conference on Embedded Computing (MECO)*, 1-6. Budva, (2018), doi: 10.1109/MECO.2018.8405985
 308. Boyko, N., Shakhovska, N. (2018). Prospects for Using Cloud Data Warehouses in Information Systems. *International Scientific and Technical Conference on Computer Sciences and Information Technologies, CSIT 2018*, (November 2018), *13th IEEE International Scientific and Technical Conference on Computer Sciences and Information Technologies*, (Lviv, September 2018), 2, 136 – 139. <https://doi.org/10.1109/STC-CSIT.2018.8526745>.
 309. Shakhovska, N., Boyko, N., Zasoba, Y., Benova, E. (2019). Big data processing technologies in distributed information systems. *Procedia Computer Science*,

- 10th International conference on emerging ubiquitous systems and pervasive networks (EUSPN-2019)*, *9th International conference on current and future trends of information and communication technologies in healthcare (ICTH-2019)*, 561–566. <https://doi.org/10.1016/j.procs.2019.11.047>
310. Boyko, N., Boksho, K. (2020). Application of the Naive Bayesian Classifier in Work on Sentimental Analysis of Medical Data. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)*, (Växjö, Sweden, November 19-21), 230-239.
311. Boyko, N., Mandych, B. (2020). Technologies of Object Recognition in Space for Visually Impaired People. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)*, (Växjö, Sweden, November 19-21) CEUR, 338-347.
312. Boyko, N., Hlynka, R. (2021). Application of Machine Algorithms for Classification and Formation of the Optimal Plan. *Proceedings of the 5th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2021)*, (Main Conference Lviv, Ukraine, April 22-23), 1853-1865.
313. Boyko, N., Telishevskyi, P., Kushka, B. (2021). Analysis of Recommendation System Methods for Accuracy of Predicted Estimates. *Proceedings of the 5th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2021)*, (Main Conference Lviv, Ukraine, April 22-23), 1878-1888.
314. Бойко, Н. (2021). Застосування задачі багаторукого бандита для максимізації пропускної здатності мережі. *Scientific foundations of solving engineering tasks and problems: collective monograph* – Boston : Primedia eLaunch, 292-300. <https://doi.org/10.46299/ISG.2021.MONO.TECH.II>.
315. Boyko, N., Yatskiv, M. (2021). Human Operator Stress Assessment System. *Modern Machine Learning Technologies and Data Science Workshop. Proc. 3rd International Workshop MoML&T&DS 2021*. (Lviv-Shatsk, Ukraine, June 5-6), 300-309
316. Бойко Н.І. (2015). Багатовимірне подання даних для управління ІТ-проектами. *Вісник Національного університету “Львівська політехніка”*.

- Інформаційні системи та мережі*. № 814. Львів : Видавництво Львівської політехніки, 2015. С. 387-395.
317. Boyko, N., Kulchytska, O. (2021). Analysis of tumor classification algorithms for breast cancer prediction by machine learning methods. *Modeling, control and information technologies. V International scientific and practical conference*, 29-33.
 318. Бойко, Н. (2021). Аналіз парадигми Semi-supervised learning для класифікації мультимодальних даних. *Науковий вісник Ужгородського університету. Серія «Математика і інформатика»*, 39(2), 125–144. [https://doi.org/10.24144/2616-7700.2021.39\(2\)](https://doi.org/10.24144/2616-7700.2021.39(2)).
 319. Boyko, N., Dosiak I. (2021). Analysis of Machine Learning Algorithms for Classification and Prediction of Heart Disease. *Proceedings of the 4th International Conference on Informatics & Data-Driven Medicine (IDDM 2021)*, (Valencia, Spain, November 19 – 21), 233-249.
 320. Boyko, N., Zhyhaylo, Ya. (2021). Comparison of Algorithms of Associative Rules Search Apriori and Fp-Growth for Investigation of Time Dependence of Their Execution on Database Parameters. *IEEE 16th International Conference on Computer Sciences and Information Technologies (CSIT)*, 1, 44 – 51. <https://doi.org/10.1109/CSIT52700.2021.9648732>
 321. Boyko, N., Hrynyshyn, A. (2021). Using Recurrent Neural Network to Noise Absorption from Audio Files. *Proceedings of the 2nd International Workshop on Computational & Information Technologies for Risk-Informed Systems (CITRisk 2021) co-located with XXI International Conference on Information Technologies in Education and Management (ITEM 2021)*, (Kherson, Ukraine, September 16-17), 227–240.
 322. Boyko, N., Mykhailyshyn, V. (2022). Model of Finding Associative Rules in Inhomogeneous Data of Semantic Networks. *Proceedings of The Fifth International Workshop on Computer Modeling and Intelligent Systems (CMIS-2022)*, (Zaporizhzhia, Ukraine, May 12), 58-67. <https://doi.org/10.32782/cmris/3137-5>

323. Boyko, N., Tkachyk, O. (2022). Model for Finding Frequent Sets in FP-growth for Multimodal Data. *Proceedings of The Fifth International Workshop on Computer Modeling and Intelligent Systems (CMIS-2022)*, (Zaporizhzhia, Ukraine, May 12), 126-143. <https://doi.org/10.32782/cmish/3137-11>
324. Boyko, N., Mykhailyshyn, V. (2022). Methods of Searching for Associative Rules for Inhomogeneous Data in Semantic Networks. *Proceedings of the 3rd International Workshop on Intelligent Information Technologies & Systems of Information Security* (Khmelnitskyi, Ukraine, March 23–25), 54-71.
325. Boyko, N. (2022). The Comprehensive Model of Using In-Depth Consolidated Multimodal Learning to Study Trading Strategies in the Securities Market. *ISDMCI 2022: Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making*, 149, 126–147. https://doi.org/10.1007/978-3-031-16203-9_8
326. Boyko, N. (2023). Tools for Implementing the Models and Algorithms for Processing Multimodal Data. *Computer Science and Information Technology*, 11(1), 1 – 10. <https://doi.org/10.13189/csit.2023.110101>
327. Boyko, N. (2023). Application of Adaptive and Multiplicative Models for Analysis and Forecasting of Time Series. *International Journal of Computing*, 22(2), 202-211. <https://doi.org/10.47839/ijc.22.2.3089>
328. Boyko, N., Omeliukh, R., Duliaba, N. (2023). The Random Forest Algorithm as an Element of Statistical Learning for Disease Prediction. *CITRisk'2022: 3rd International Workshop on Computational & Information Technologies for Risk-Informed Systems*, (January 12, 2023, Neubiberg, Germany), 3422, 59-73.
329. Boyko, N., Lukash, O. (2023). Methodology for Estimating the Cost of Construction Equipment Based on the Analysis of Important Characteristics Using Machine Learning Methods. *Journal of Engineering*, 2023, Article ID 8833753, 27. <https://doi.org/10.1155/2023/8833753>
330. Boyko, N., Boksho, K., Telishevskyi, P. (2022). Neural Networks: Training with Backpropagation and the Gradient Algorithm. *IEEE 9th International Conference*

- on Problems of Infocommunications, Science and Technology (PIC S&T)*, 543-550, <https://doi.org/10.1109/PICST57299.2022.10238615>.
331. Boyko, N.I., Mykhailyshyn V. Yu. (2023). K-NN's Nearest Neighbors method for classifying text documents by their topics. *Радіоелектроніка, інформатика, управління*. (Radio Electronics, Computer Science, Control. 2023. № 3), 83-97. <https://doi.org/10.15588/1607-3274-2023-3-9>
 332. Boyko, N. (2023). Models of binary classification of the semantic colouring of texts. *Innovaciencia*, 11(1), 1-23. <https://doi.org/10.15649/2346075X.3553>
 333. Boyko, N. Dosiak, I. (2023). Enhanced Classification Models for Heart Disease Prediction in Precision Medicine. *Proceedings of the 6th International Conference on Informatics & Data-Driven Medicine* (Bratislava, Slovakia, November 17-19), 265-278.
 334. Boyko, N. (2023). The model of backpropagation algorithm realization in parallel mode for big data solutions. *Journal of the Balkan Tribological Association*, 29(5), 689–704.
 335. Boyko, N. (2023). Evaluating Binary Classification Algorithms on Data Lakes Using Machine Learning. *Revue d'Intelligence Artificielle*, 2023, 37(6), pp. 1423–1434. <https://doi.org/doi.org/10.18280/ria.370606>
 336. Бойко, Н., Левицький, Б. (2023). Алгоритми тренування та оцінки моделей машинного навчання для структурованого набору даних. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 3, 3-12. <https://doi.org/10.32782/IT/2023-3-1>
 337. Boyko, N. I., Kurylo, V. (2023). Medical data classification algorithm for oncology prediction. *Systems and Technologies*, 66(2), 21-31. <https://doi.org/10.32782/2521-6643-2023.2-66.3>
 338. Boyko, N. Overview of multimodal data and its application to fake-news detection. *Jordanian Journal of Computers and Information Technology (JJCIT)*, 10(3), 281-293. <https://doi.org/10.5455/jjcit.71-1709201313>

339. Boyko, N., Kovalchuk, R. (2024). Detection of anomalies and Data Drift in a time-series dismissal prediction system. *Iraqi Journal for Computer Science and Mathematics*, 5(3), 229-251. <https://doi.org/10.30880/ijcsm.2024.05.03.12>
340. Boyko, N., Kachmaryk, V. (2024). Forecasting Stochastic Time Series using Reinforcement Learning. *International Journal of Artificial Intelligence*, 22(4), 1-28. ISSN 0974-0635
341. Boyko, N. (2024). Study of Multimodal Identification Algorithms using Modern Methods and Tools of Multivariate Analysis. *Journal of Ecohumanism*, 3(5), 99–114. <https://doi.org/10.62754/joe.v3i5.3877>
342. Бойко, Н., Черненко, А. (2024). Modern approaches to data storage: comparison of relational and cloud data warehouses using etl and elt methods. *Вісник Приазовського Державного Технічного Університету. Серія: Технічні науки*, 48, 7–19. <https://doi.org/10.31498/2225-6733.48.2024.310669>
343. Boyko, N. (2024). Data Processing and Optimization in the Development of Machine Learning Systems: Detailed Requirements Analysis, Model Architecture, and Anti-Data Drift Strategies. *Journal of Applied Data Sciences*, 5(3), 1110-1122. <https://doi.org/10.47738/jads.v5i3.278>
344. Boyko, N. (2024). Overview of Multimodal Data and Its Application to Fake-news Detection. *Jordanian Journal of Computers and Information Technology (JJCIT)*, 10(3), 281-293. <https://doi.org/10.5455/jjcit.71-1709201313>
345. Boyko, N. I., Rabotiahov, D. S. (2024). Modeling of the spread of tuberculosis by regions in Ukraine. *Radio Electronics, Computer Science, Control*, (4), 41–55. <https://doi.org/10.15588/1607-3274-2024-4-4>

ДОДАТОК А

Акти впровадження результатів дисертаційної роботи

«ЗАТВЕРДЖУЮ»
 Проректор з навчально-методичної
 роботи Львівського державного
 університету безпеки життєдіяльності,
 кандидат технічних наук, доцент,
 полковник служби цивільного захисту
 Олександр ПРИДАТКО
 « 30 » жовтня 2025 р.

АКТ

впровадження результатів дисертаційної роботи на здобуття наукового ступеня
 доктора технічних наук за спеціальністю 05.13.06 – інформаційні технології
 Бойко Наталії Іванівни
 на тему: «Методологія багатовимірної аналізу мультимодальних даних»

Комісія у складі: голови комісії – начальника кафедри інформаційних технологій та систем електронних комунікацій, к.т.н., доц., підполковника служби цивільного захисту Назарія БУРАКА та членів комісії – професора кафедри права та менеджменту у сфері цивільного захисту, д.т.н., проф., заслуженого діяча науки і техніки України, полковника служби цивільного захисту Олега ЗАЧКА, професора кафедри інформаційних технологій та систем електронних комунікацій, д.т.н., проф. Євгена МАРТИНА засвідчує, що результати дисертаційної роботи, а саме:

- розроблену методику побудови баз даних для моделювання змінного середовища проектів у сфері створення та розвитку медичних закладів на базі багатовимірної аналізу мультимодальних даних;
- створені методи обчислювального інтелекту й відповідні математичні моделі для оцінювання ефективності реалізації медичних проектів;
- алгоритми та інформаційні технології для підтримки прийняття управлінських рішень на основі адаптивно-ціннісного моделювання в багатомодальних середовищах,

впроваджені у навчальний процес Львівського державного університету безпеки життєдіяльності під час викладання лекційних і лабораторних занять із дисциплін «Інтелектуальний аналіз даних» і «Системи підтримки прийняття рішень» (спеціальність 122 «Комп'ютерні науки», бакалаврський рівень) та дисципліни «Інтелектуальні системи аналізу даних та підтримки прийняття рішень» (спеціальність 073 «Менеджмент», освітньо-наукова програма «Управління проектами», PhD рівень).

Інтеграція зазначених результатів у навчальний процес підвищує практичну орієнтацію освітніх програм і сприяє формуванню компетентностей, відповідних сучасним вимогам ринку праці.

Голова комісії

Члени комісії

Назарій БУРАК
 Олег ЗАЧКО
 Євген МАРТИН

«ПОГОДЖЕНО»
 проректор з науково-педагогічної
 роботи та якості освіти Львівського
 національного університету
 ветеринарної медицини та
 біотехнологій імені С.З. Гжицького,
 професор
 Виталий БОЯРЧУК
 2025 р.

«ЗАТВЕРДЖУЮ»
 В.о. ректора Львівського
 національного університету
 ветеринарної медицини та
 біотехнологій імені С.З. Гжицького,
 доцент
 Ігор ГУРКО
 2025 р.

АКТ про впровадження НДР у навчальний процес

Ми, що підписалися нижче, завідувач кафедри інформаційних технологій Львівського національного університету ветеринарної медицини та біотехнологій імені С.З. Гжицького, д.т.н., професор Тригуба А.М., доценти цієї ж кафедри, к.т.н. Луб П.М. та к.т.н. Падюка Р.І. з однієї сторони, а також виконавець НДР доцент кафедри системи штучного інтелекту Національного університету «Львівська політехніка» Бойко Н.І. з іншої сторони, склали цей акт про впровадження результатів завершеної науково-дослідної роботи «Методологія багатовимірного аналізу мультимодальних даних».

У навчальний процес Львівського національного університету ветеринарної медицини та біотехнологій імені С.З. Гжицького для здобувачів спеціальності 126 «Інформаційні системи та технології» першого (бакалаврського) рівня вищої освіти, які вивчають дисципліни «Моделювання систем» та «Алгоритмізація та програмування», впроваджено результати дослідження, а саме:

- теоретико-методологічні підходи до розроблення багатовимірних моделей для аналізу мультимодальних даних, що дозволяє студентам глибше розуміти, процеси побудови інформаційних моделей складних систем;
- математичні моделі та алгоритми обробки медичних даних у багатовимірних середовищах, що забезпечують набуття практичних навичок роботи з реальними даними різної природи;
- програмні засоби і методики багатокритеріального управління, орієнтовані на погоджену обробку проектних даних, що сприяє розвитку компетенцій з оптимізації складних інформаційних процесів;
- системи підтримки прийняття рішень, засновані на алгоритмах мультимодального аналізу і прогнозного моделювання, що дозволяють формувати навички розроблення інтелектуальних інформаційних систем.

Застосування зазначених результатів у навчальному процесі забезпечує підвищення якості підготовки здобувачів в вищій освіті через інтеграцію сучасних методів аналізу даних та інноваційних технологічних рішень.

Тригуба А.М.
 Луб П.М.

Бойко Н.І.
 Падюка Р.І.

“ЗАТВЕРДЖУЮ”
 Директор ДП «Бумеранг-Комфорт»
 **Юрій Мандзик**
 05 _____ 2025 р.

АКТ

впровадження результатів дисертаційної роботи на здобуття наукового ступеня
 доктора технічних наук за спеціальністю 05.13.06 – інформаційні технології
Бойко Наталії Іванівни
 на тему: «Методологія багатовимірної аналізу мультимодальних даних»

Цей акт підтверджує, що результати дисертаційної роботи Бойко Н.І. були використані для розроблення інформаційної технології для автоматизованої обробки та аналізу даних в сфері управління виробничими процесами. Створена система дозволяє інтегрувати різні типи даних, зокрема інформацію про продуктивність, витрати, час роботи обладнання та інші оперативні дані, що дозволяє забезпечити більш точне планування та контроль на підприємстві.

Основним напрямом впровадження є розробка інформаційної системи, яка забезпечує інтеграцію та аналіз даних з різних відділів підприємства, дозволяючи оперативно виявляти проблеми та прогнозувати результати в реальному часі. Це дає змогу знижувати витрати, оптимізувати використання ресурсів і зменшувати виробничі простой.

Іншим важливим напрямком є використання багатокритеріального підходу для аналізу ефективності роботи різних підрозділів, що дає можливість ухвалювати більш обґрунтовані управлінські рішення щодо оптимізації процесів і ресурсів.

Загалом, впровадження результатів дослідження дозволяє значно покращити управління підприємством, підвищити його ефективність та здатність до адаптації в умовах змінюваного ринку.

Директор ДП «Бумеранг-Комфорт»



Юрій Мандзик

“ЗАТВЕРДЖУЮ”

Директор ТОВ «ХВАК ЮНІТ»

Іван МИТРОВЦІЙ

2025 р.

№ 45795975

АКТ

впровадження результатів дисертаційної роботи на здобуття наукового ступеня
доктора технічних наук за спеціальністю 05.13.06 – інформаційні технології

Бойко Наталії Іванівни

на тему: «Методологія багатовимірного аналізу мультимодальних даних»

Цей акт підтверджує, що результати дисертаційної роботи Бойко Н.І. на тему: «Методологія багатовимірного аналізу мультимодальних даних» були використані для розроблення інформаційної технології багатовимірного аналізу даних підприємства. Створена технологія дозволяє інтегрувати різноманітні джерела інформації, забезпечуючи їх узгодженість та підвищення точності й адаптивності в процесах прийняття управлінських рішень на підприємстві. Це, в свою чергу, забезпечує підвищення ефективності роботи організацій та покращення її конкурентоспроможності.

Основним напрямом впровадження результатів дисертаційних досліджень є розробка інформаційної системи для підтримки процесів прийняття рішень в умовах обробки великих обсягів різноманітних даних. У цій системі застосовуються методи багатовимірного аналізу, що дозволяють інтегрувати дані з різних джерел – фінансових, логістичних, операційних та інших. Це дозволяє забезпечити узгодженість цих даних, а також підвищити точність і адаптивність рішень, що приймаються на основі комплексного аналізу.

Іншим важливим застосуванням є розробка методів обробки інформаційних даних, що використовують багатокритеріальний підхід. Цей підхід дозволяє забезпечити високу точність і ефективність в аналізі та прийнятті рішень, що особливо важливо для підприємства, що працює з великими обсягами даних. Розроблені методи дають змогу точно оцінювати різні аспекти діяльності підприємства та швидко адаптуватися до змінюваних умов бізнес-середовища.

Загалом, впровадження цих досліджень сприяло створенню інформаційної системи, яка інтегрує та обробляє різноманітні дані, а також надає організації необхідні інструменти для прийняття ефективних управлінських рішень. Це має велике значення для підприємства, оскільки дозволяє підвищити ефективність його роботи, знизити ризики та оптимізувати управлінські процеси.

Директор ТОВ «ХВАК ЮНІТ»



Іван МИТРОВЦІЙ


ЗАТВЕРДЖУЮ
 Директор ТОВ "ЗБАРАЖ АГРО-ТРЕЙД"
Василь ОРЕЛ
 04 2025 р.

АКТ

впровадження результатів дисертаційної роботи на здобуття наукового ступеня
 доктора технічних наук за спеціальністю 05.13.06 – інформаційні технології
 Бойко Наталії Іванівни
 на тему: «Методологія багатовимірного аналізу мультимодальних даних»

Цей акт підтверджує, що результати дисертаційної роботи Бойко Н.І. були адаптовані та впроваджені в інформаційне середовище підприємства для вдосконалення аналітичного обміну даними та оптимізації інформаційних процесів і потоків. Запропонована інформаційна технологія забезпечує інтеграцію різномірних джерел інформації, уніфікацію форматів даних, їх багатовимірний аналіз і синхронізацію в єдиному інформаційному просторі.

Впроваджені рішення дозволяють значно підвищити ефективність функціонування систем управління інформаційними потоками, зменшити час доступу до аналітичних даних, покращити точність оцінки поточних ситуацій та підтримати прийняття рішень в умовах інформаційної складності.

Методи багатокритеріального аналізу, реалізовані в межах технології, сприяли поліпшенню якості обробки інформації, узгодженню внутрішніх і зовнішніх інформаційних каналів підприємства, а також підвищенню оперативності взаємодії між структурними підрозділами.

Таким чином, результати дисертаційної роботи успішно адаптовані для розв'язання прикладних задач у сфері аналітичного обміну даними та управління інформаційними процесами, що сприяє загальному підвищенню ефективності інформаційної інфраструктури підприємства.

Директор ТОВ "ЗБАРАЖ АГРО-ТРЕЙД"


Василь ОРЕЛ


“ЗАТВЕРДЖУЮ”
 Директор ТНУЕБ «Квадро-Альянс»
Богдан БОЙКО
 “19” _____ 2025 р.

АКТ

впровадження результатів дисертаційної роботи на здобуття наукового ступеня
 доктора технічних наук за спеціальністю 05.13.06 – інформаційні технології
 Бойко Наталії Іванівни
 на тему: «Методологія багатовимірного аналізу мультимодальних даних»

Цей акт підтверджує, що результати дисертаційної роботи Бойко Н.І. на тему: «Методологія багатовимірного аналізу мультимодальних даних» були використані для розроблення інформаційної технології багатовимірного аналізу даних, яка дозволяє об'єднувати різноманітні джерела інформації, забезпечуючи їхню узгодженість та підвищення точності та адаптивності в процесах прийняття рішень на підприємстві.

Впровадження дисертаційних досліджень Бойко Н.І. полягає у наступному:

- Розроблено концептуальну модель для багатовимірного аналізу інформаційних даних, яка використовує багатовимірні формальні контексти для виявлення взаємозв'язків між різними джерелами інформації.
- Розроблено методи обробки інформаційних даних із використанням багатокритеріального підходу, що дозволяє забезпечити високу точність і ефективність аналітичних процесів на підприємстві.

Ці підходи сприяють створенню ефективної інформаційної системи для інтеграції та обробки різноманітних даних на підприємстві, що забезпечує оптимізацію прийняття рішень.

Даний акт не є підставою для взаємних фінансових розрахунків.

Директор ТНУ «Квадро-Альянс»



Богдан БОЙКО

“ЗАТВЕРДЖУЮ”
 Директор ТОВ “ІНТЕЛДІМ”
Ігор СКАЛЕЦЬКИЙ
 _____ 2025 р.
АКТ

впровадження результатів дисертаційної роботи на здобуття наукового ступеня
 доктора технічних наук за спеціальністю 05.13.06 - інформаційні технології
 Бойко Наталії Іванівни
 на тему: «Методологія багатовимірного аналізу мультимодальних даних»

Цей акт підтверджує, що результати дисертаційної роботи Бойко Н.І. були впроваджені у процес удосконалення інформаційної інфраструктури підприємства, зокрема в частині обробки, узгодження та аналітичної інтерпретації комплексних потоків даних. Розроблена інформаційна технологія дозволила сформувати єдину платформу для обміну, аналізу й візуалізації інформації з різних функціональних напрямів діяльності підприємства.

Система, створена на основі результатів дисертації, забезпечує гнучке управління інформаційними потоками, підтримує багаторівневу інтеграцію даних, дозволяє виявляти приховані взаємозв'язки між джерелами інформації та формувати оперативну аналітику для прийняття стратегічних та тактичних рішень.

Використання багатовимірних формальних контекстів і багатокритеріальних підходів дало змогу підвищити якість узагальненої інформації, що передається в межах підприємства, мінімізувати дублювання даних і покращити інформаційну прозорість організаційної структури.

Таким чином, впровадження результатів дисертаційної роботи сприяло створенню адаптивної інформаційної системи, орієнтованої на аналітичну підтримку управлінських процесів та ефективне керування інформаційними ресурсами в умовах постійної зміни зовнішніх і внутрішніх факторів підприємства.

Директор ТОВ “ІНТЕЛДІМ”



Ігор СКАЛЕЦЬКИЙ

ДОДАТОК Б

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у періодичних виданнях, включених до категорії «А» Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних Web of Science Core Collection та/або Scopus:

1. Boyko N. Application of mathematical models for improvement of “cloud” data processes organization. *Mathematical Modeling and Computing*. 2016. Vol. 3 No. 2. P. 111–119. (0,36 д.а.). DOI: <https://doi.org/10.23939/mmc2016.02.111>. ISSN 2312-9794 (індексована в наукометричній базі Scopus).
2. Boyko N. Advanced technologies of big data research in distributed information systems. *Radio Electronics, Computer Science, Control*. 2018. No. 4. P. 66–77. (0,45 д.а.). DOI: <https://doi.org/10.15588/1607-3274-2017-4-8>. ISSN 1607-3274 (індексована в наукометричній базі Web of Science (Q4 by Journal Citation Report)).
3. Boyko N. Models and algorithms for multimodal data processing. *WSEAS Transactions on Information Science and Applications*. 2023. Vol. 20. Art. No. 11. P. 87–97. (0,45 д.а.). DOI: <https://doi.org/10.37394/23209.2023.20.11>. ISSN 1790-0832 (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
4. Boyko N. Data interpretation algorithm for adaptive methods of modeling and forecasting time series. *WSEAS Transactions on Mathematics*. 2023. Vol. 22. Art. No. 43. P. 359–372. (0,6 д.а.). DOI: <https://doi.org/10.37394/23206.2023.22.43>. ISSN 1109-2769 (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).
5. Boyko N. Application of adaptive and multiplicative models for analysis and forecasting of time series. *International Journal of Computing*. 2023. Vol. 22(2). P. 202–211. (0,4 д.а.). DOI: <https://doi.org/10.47839/ijc.22.2.3089>. ISSN 1727-6209 (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
6. Vykylyuk Ya., Nevinskyi D., Boyko N. GeoCity – a new dynamic-spatial model of urban ecosystem. *J. Geogr. Inst. Cvijic*. 2023. Vol. 73(2). P. 187–203. (0,72 д.а.). DOI: <https://doi.org/10.2298/IJGI2302187V>. ISSN 2683-3867 (індексована в наукометричній базі Scopus (Q3 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробленні алгоритмів обробки геопросторових даних з використанням методів просторової кластеризації, інтерполяції та часової сегментації та становить 0,35 д.а.

7. Boyko N., Lukash O. Methodology for estimating the cost of construction equipment based on the analysis of important characteristics using machine learning methods. *Journal of Engineering*. 2023. Vol. 2023. Art. No. 8833753. P. 27. (1,2 д.а.). DOI: <https://doi.org/10.1155/2023/8833753>. ISSN 2314-4904 (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає в аналізі значущості ознак (feature importance) з метою виявлення важливих ознак; створенні програмного прототипу для вводу технічних характеристик обладнання для їх автоматичної оцінки та становить 0,85 д.а.

8. Boyko N. I., Mykhailishyn V. Yu. K-NN's nearest neighbors method for classifying text documents by their topics. *Radio Electronics, Computer Science, Control*. 2023. No. 3. P. 83–97. (0,63 д.а.). DOI: <https://doi.org/10.15588/1607-3274-2023-3-9>. ISSN 1607-3274 (індексована в наукометричній базі Web of Science (Q4 by Journal Citation Report)).

Особистий внесок автора полягає в адаптації методу найближчих сусідів (k-NN) для задач класифікації текстових документів за тематикою з урахуванням особливостей української та англійської мов та становить 0,5 д.а.

9. Boyko N. Models of binary classification of the semantic colouring of texts. *Innovaciencia*. 2023. Vol. 11(1). P. 1–23. (1 д.а.). DOI: <https://doi.org/10.15649/2346075X.3553>. E- ISSN 2346-075X (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
10. Boyko N. The model of backpropagation algorithm realization in parallel mode for big data solutions. *Journal of the Balkan Tribological Association*. 2023. Vol. 29. Issue 5. P. 689–704. (0,68 д.а.). ISSN 1310-4772. URL: <https://scibulcom.net/en/article/gfGV3mMkYgTAEk60Qczd> (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
11. Boyko N. Evaluating binary classification algorithms on data lakes using machine learning. *Revue d'Intelligence Artificielle*. 2023. Vol. 37(6). P. 1423–1434. (0,5 д.а.). DOI: <https://doi.org/10.18280/ria.370606>. ISSN 0992-499X (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
12. Vyklyuk Y., Semianiv I., Nevinskyi D., Todoriko L., Boyko N. Applying geospatial multi-agent system to model various aspects of tuberculosis transmission. *New Microbes and New Infections*. 2024. Vol. 59. P. 101417. DOI: <https://doi.org/10.1016/j.nmni.2024.101417>. (0,31 д.а.). ISSN 2052-2975 (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробленні інтеграції алгоритмів агентного моделювання з медико-статистичними даними, що дозволило врахувати поведінкові характеристики населення, мобільність і регіональні особливості, та становить 0,12 д.а.

13. Boyko N. Overview of multimodal data and its application to fake-news detection. *Jordanian Journal of Computers and Information Technology (JJCIT)*. 2024. Vol. 10. No. 03. P. 281–293. (0,54 д.а.). DOI: <https://doi.org/10.5455/jjcit.71-1709201313>. ISSN 2415-1076 (індексована в наукометричній базі Scopus (Q3 by Scimago Journal & Country Rank)).
14. Boyko N., Kovalchuk R. Detection of anomalies and Data Drift in a time-series dismissal prediction system. *Iraqi Journal for Computer Science and Mathematics*. 2024. Vol. 5. No. 3. P. 229–251. (1 д.а.). DOI: <https://doi.org/10.30880/ijcsm.2024.05.03.12>. ISSN 2788-7421. URL: <https://ijcsm.researchcommons.org/ijcsm/vol5/iss3/20> (індексована в наукометричній базі Scopus (Q2 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробці комбінованої аналітичної моделі, яка поєднує методи контролю стабільності розподілу з інструментами автоматичного виявлення аномалій, зокрема Isolation Forest і Autoencoder; визначенні критеріїв деградації моделей прогнозування при змінах у розподілах даних, та становить 0,65 д.а.

15. Boyko N., Kachmaryk V. Forecasting stochastic time series using reinforcement learning. *International Journal of Artificial Intelligence*. 2024. Vol. 22(2). P. 1–28. (1,23 д.а.). ISSN 0974-0635. URL: <http://www.ceser.in/ceserp/index.php/ijai/article/view/6991> (індексована в наукометричній базі Scopus (Q3 by Scimago Journal & Country Rank)).

Особистий внесок автора полягає у розробці методології прогнозування стохастичних часових рядів із використанням алгоритмів навчання з підкріпленням, з акцентом на адаптивність до нестабільних і непередбачуваних даних, та становить 0,8 д.а.

16. Boyko N. Study of multimodal identification algorithms using modern methods and tools of multivariate analysis. *Journal of Ecohumanism*. 2024. Vol. 3(5). P. 99–114. (0,68 д.а.). DOI: <https://doi.org/10.62754/joe.v3i5.3877>. ISSN 2752-6798 (індексована в наукометричній базі Scopus).
 17. Boyko N. Data processing and optimization in the development of machine learning systems: Detailed requirements analysis, model architecture, and anti-data drift strategies. *Journal of Applied Data Sciences*. 2024. Vol. 5(3). P. 1110–1122. (0,54 д.а.). DOI: <https://doi.org/10.47738/jads.v5i3.278>. ISSN 2723-6471 (індексована в наукометричній базі Scopus (Q3 by Scimago Journal & Country Rank)).
 18. Boyko N. The comprehensive model of using in-depth consolidated multimodal learning to study trading strategies in the securities market. *Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. ISDMCI 2022. Lecture Notes on Data Engineering and Communications Technologies*. 2023. Vol. 149. P. 126–147. (0,95 д.а.). Springer, Cham. DOI: https://doi.org/10.1007/978-3-031-16203-9_8. ISSN 2367-4512, 2367-4520 (індексована в наукометричній базі Scopus (Q4 by Scimago Journal & Country Rank)).
 19. Boyko N. I., Rabotiahov D. S. Modeling of the spread of tuberculosis by regions in Ukraine. *Radio Electronics, Computer Science, Control*. 2024. Vol. 4. P. 41–55. (0,63 д.а.). DOI: <https://doi.org/10.15588/1607-3274-2024-4-4>. ISSN 1607-3274 (індексована в наукометричній базі Web of Science (Q4 by Journal Citation Report)).
Особистий внесок автора полягає у розробці математичної моделі просторово-часового поширення туберкульозу, яка враховує регіональні особливості епідеміологічної ситуації в Україні, та становить 0,4 д.а.
- Статті у наукових виданнях, включених до Переліку наукових фахових видань України:**
20. Бойко Н. І. Методи та інструменти моделювання інформаційних процесів. *Вісник Національного університету “Львівська політехніка”. Інформаційні системи та мережі*. 2014. № 805. С. 361–368. (0,31 д.а.). ISSN: 2524-065X. URL: <https://science.lpnu.ua/uk/sisn/vsi-vypusky/vypusk-805-2014/metody-ta-instrumenty-modelyuvannya-informaciy-nih-procesiv>. Фахове видання категорії Б (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
 21. Бойко Н. І. Багатовимірне подання даних для управління ІТ-проектами. *Вісник Національного університету “Львівська політехніка”. Інформаційні системи та мережі*. 2015. № 814. С. 387–395. (0,36 д.а.). ISSN: 2524-065X. URL: <https://ena.lpnu.ua/items/196e3ab0-679e-47b8-9900-5d36131482dd>. Фахове видання категорії Б (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
 22. Бойко Н. І. Еволюція побудови архітектур інформаційних систем. Перспективи розвитку “хмарної” архітектури. *Вісник Національного університету “Львівська політехніка”. Інформаційні системи та мережі*. 2015. № 832. С. 348–368. (0,9 д.а.). ISSN: 2524-065X. URL: <chrome-extension://efaidnbmninnibpcapjpcgclclefindmkaj/https://science.lpnu.ua/sites/default/files/journal-paper/2018/jun/12945/24-348-367.pdf>. Фахове видання категорії Б (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).
 23. Бойко Н. І. Аналіз парадигми Semi-supervised learning для класифікації мультимодальних даних. *Науковий вісник Ужгородського університету. Серія: Математика і інформатика*. 2021. № 39(2). С. 125–144. (0,86 д.а.). DOI: [https://doi.org/10.24144/2616-7700.2021.39\(2\).125-144](https://doi.org/10.24144/2616-7700.2021.39(2).125-144). ISSN 2616-7700. Фахове

видання категорії Б (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

24. Бойко Н. І., Шаховська Н. Б., Михайлишин В. Ю. Розроблення методу класифікації користувачів за рівнем стресостійкості з використанням модифікованої автоасоціативної нейронної мережі. *Вісник Хмельницького національного університету*. 2021. № 6(303). С. 64–68. (0,18 д.а.). DOI: <https://doi.org/10.31891/2307-5732-2021-303-6-64-68>. ISSN 2307-5732. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці методу автоматичної класифікації користувачів за рівнем стресостійкості та становить 0,1 д.а.

25. Boyko N. Research into machine learning algorithms for the construction of mathematical models of multimodal data classification problems. *Computational Problems of Electrical Engineering*. 2021. Vol. 11. No. 2. P. 1–11. (0,45 д.а.). DOI: <https://doi.org/10.23939/jcpee2021.02.001>. ISSN: 2224-0977. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

26. Бойко Н. І., Качмарик В. Побудова моделей для прогнозування часових рядів застосовуючи мережі довгострокової пам'яті. *Науковий вісник Ужгородського університету. Серія: Математика і інформатика*. 2022. Т. 40. № 1. С. 131–147. (0,72 д.а.). DOI: [https://doi.org/10.24144/2616-7700.2022.40\(1\).109-125](https://doi.org/10.24144/2616-7700.2022.40(1).109-125). ISSN 2616-7700. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробленні моделей прогнозування часових рядів на основі архітектур LSTM (Long Short-Term Memory), орієнтованих на роботу з нестабільними та нелінійними даними, та становить 0,5 д.а.

27. Boyko N., Muzyka M. Methods of analysis of multimodal data to increase the accuracy of classification. *Applied Aspects of Information Technology*. 2022. Vol. 5. No. 2. P. 147–160. (0,59 д.а.). DOI: <https://doi.org/10.15276/aait.05.2022.11>. ISSN 2617-4316. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробленні підходів до інтегрованого аналізу мультимодальних даних (текстових, числових, візуальних, сенсорних) з метою підвищення точності класифікації в складних умовах та становить 0,4 д.а.

28. Бойко Н. І., Блажевський С. Г. Методика визначення структури моделі оптимальної складності. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2022. № 2(307). С. 7–13. (0,27 д.а.). DOI: <https://www.doi.org/10.31891/2307-5732-2022-307-2-7-13>. ISSN 2307-5732. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробленні методики формування моделей із балансом між складністю та точністю, орієнтованої на задачі машинного навчання та моделювання систем, та становить 0,17 д.а.

29. Boyko N., Petrovskyi O. Methods of classification of machine learning for construction of mathematical models on multimodal DATA. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2022. № 2(307). С. 25–32. (0,32 д.а.). DOI: <https://doi.org/10.31891/2307-5732-2022-307-2-25-32>. ISSN 2307-5732. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у систематизації методів машинного навчання, що застосовуються для побудови математичних моделей на основі мультимодальних даних (текстових, числових, зображень, сенсорних сигналів), та становить 0,2 д.а.

30. Бойко Н. І., Газдюк К. П. Порівняння регресійних моделей за наявності викидів у наборі різнотипових даних. *Науковий вісник НЛТУ України*. 2023. Т. 33. № 2. С. 84–91. (0,32 д.а.). DOI: <https://doi.org/10.36930/40330212>. ISSN 5-7763-2435-1. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає в аналізі впливу викидів (аномальних значень) на точність різних регресійних моделей, побудованих на даних зі змішаними типами ознак (числові, категоріальні, порядкові), та становить 0,2 д.а.

31. Бойко Н., Левицький Б. Алгоритми тренування та оцінки моделей машинного навчання для структурованого набору даних. *Information Technology: Computer Science, Software Engineering and Cyber Security*. 2023. Вип. 3. С. 3–12. (0,4 д.а.). DOI: <https://doi.org/10.32782/IT/2023-3-1>. ISSN 2786-507X. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці та апробуванні алгоритмів навчання моделей машинного навчання на структурованих наборах даних із табличною формою представлення та становить 0,25 д.а.

32. Boyko N. I., Kurylo V. Medical data classification algorithm for oncology prediction. *Systems and Technologies*. 2023. Vol. 66(2). P. 21–31. (0,45 д.а.). DOI: <https://doi.org/10.32782/2521-6643-2023.2-66.3>. ISSN 2521-6643. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці підбору релевантних медичних ознак, включаючи біохімічні показники, історію хвороби, спадковість, демографічні дані та результати скринінгу, та становить 0,2 д.а.

33. Boyko N., Kovalchuk R. Data update algorithms in the Machine Learning System. *Computer Systems and Information Technologies*. 2023. Vol. 1. P. 6–13. (0,32 д.а.). DOI: <https://doi.org/10.31891/csit-2023-1-1>. ISSN 2710-0766. *Фахове видання категорії Б* (включене до Index Copernicus, Directory of Open Access Scholarly Resources, Google Scholar, Наукова періодика України).

Особистий внесок автора полягає у розробці алгоритму оновлення навчальної вибірки без втрати продуктивності моделі з використанням механізмів буферизації, відбору важливих зразків і контролю якості та становить 0,2 д.а.

Статті у закордонних наукових виданнях:

34. Boyko N., Slobodian P. Application of machine learning methods for enhancing the quality of medical audio recordings: Comparative analysis of classical and modern approaches. *International Journal of Computer Applications*. 2025. Vol. 186, No. 69. P. 31–43. (0,55 д.а.). DOI: <https://doi.org/10.5120/ijca2025924502>. ISSN 0975-8887 (включене до Google Scholar).

Особистий внесок автора полягає у формалізації задачі підвищення якості медичних аудіозаписів шляхом застосування методів машинного навчання, виборі та обґрунтуванні критеріїв для порівняння класичних (спектральних фільтрів) та сучасних (нейромережових автоенкодерів) підходів, а також у розробці методики оцінювання результатів за метриками SNR, PESQ та інтерпретованості для клінічного середовища, та становить 0,35 д.а.

Монографії (розділи у колективних монографіях):

35. Boyko N. Machine learning on data lake : Monograph. Beau Bassin. Mauritius : LAP Lambert Academic Publishing, 2018. 178 p. (8,09 д.а.). ISBN 13 978-613-9-83668-0.
36. Boyko N., Mochurad L. I. Modeling of discrete mathematics' problems : Monograph. Beau Bassin, Mauritius : LAP Lambert Academic Publishing, 2019. 195 p. (8,86 д.а.). ISBN 13 978-620-0-08172-8.

Особистий внесок автора полягає у дослідженні та моделюванні прикладних задач дискретної математики з акцентом на алгоритмічну реалізацію і практичне застосування в інформаційних технологіях та становить 7,5 д.а.

37. Mochurad L. I., Boyko N. I. Practical numerical methods: Algorithms and programs : Monograph. Lviv : Publishing House "Bona", 2019. 204 p. (9,27 д.а.). ISBN 978-617-7815-08-1.

Особистий внесок автора полягає у розробленні та описі чисельних методів, алгоритмів і програмних реалізацій для розв'язання прикладних задач у технічних та природничих науках та становить 7,5 д.а.

38. Mochurad L. I., Boyko N. I. Technologies of distributed systems and parallel computation : Monograph. Lviv : Publishing House "Bona", 2020. 261 p. (11,86 д.а.). ISBN 978-617-7815-25-8.

Особистий внесок автора полягає у дослідженні теоретичних засад, архітектурних рішень та практичних аспектів реалізації розподілених систем і технологій паралельних обчислень та становить 8 д.а.

39. Boyko N. Software approach to creating a layout with dynamic interfaces. *Theoretical aspects of modern engineering* : Collective monograph. International Science Group. Boston : Primedia eLaunch, 2020. P. 77–81. (0,23 д.а.). DOI: <https://doi.org/10.46299/ISG.2020.MONO.TECH.III>). ISBN 979-8-88722-619-4.
40. Boyko N. The use of cloud technologies at the open information systems. *На шляху до індустрії 4.0: Інформаційні технології, моделювання, штучний інтелект, автоматизація* : Колективна монографія. Одеса : Астропринт, 2021. С. 300–317. (0,77 д.а.). ISBN 978-966-927-702-2.
41. Boyko N. Creation of information systems using power algorithms. *Technical research and development* : Collective monograph. International Science Group. Boston : Primedia eLaunch, 2021. P. 80–85. (0,23 д.а.). DOI: <https://doi.org/10.46299/ISG.2021.MONO.TECH.I>). ISBN 978-1-63732-136-2.
42. Бойко Н. Застосування задачі багаторукого бандита для максимізації пропускної здатності мережі. *Scientific foundations of solving engineering tasks and problems* : Collective monograph. International Science Group. Boston : Primedia eLaunch, 2021. P. 292–300. (0,36 д.а.). DOI: <https://doi.org/10.46299/ISG.2021.MONO.TECH.II>). ISBN: 978-1-63848-664-0.
43. Бойко Н. І. Порівняльний аналіз моделей прогнозування часових рядів для мультимодальних даних. *Moderní aspekty vědy* : X. Díl mezinárodní kolektivní monografie. Česká republika : Mezinárodní Ekonomický Institut s.r.o., 2021. S. 187–205. (0,81 д.а.). URL: chrome-extension://efaidnbmnnnnibpcajpcgclclefindmkaj/http://expertise.odessa.ua/wp-content/uploads/2025/02/%D0%A5%D0%BE%D0%BC%D1%83%D1%82%D0%B5%D0%BD%D0%BA%D0%BE_%D0%9C%D0%BE%D1%82%D0%B8%D0%B3%D1%96%D0%BD_2021.pdf

Публікації, які засвідчують апробацію матеріалів дисертації:

44. Бойко Н. І. Технології обробки інформації у динамічних системах. *Сучасні проблеми прикладної математики та інформатики* : зб. наук. праць. Львів : Львів. нац. ун-т ім. І. Франка, 2016. С. 37–40. (0,14 д.а.). URL: <chrome->

extension://efaidnbmnnnibpcajpcgclcfndmkaj/http://apamcs.lnu.edu.ua/tmp/APAMC
S-2016.pdf

45. Boyko N. A look through methods of intellectual data analysis and their applying in informational systems. *IEEE 11th International Scientific and Technical Conference on Computer Science and Information Technologies (CSIT)*. 2016. P. 183–185). (0,09 д.а.). DOI: <https://doi.org/10.1109/STC-CSIT.2016.7589901>.

URL: <https://ieeexplore.ieee.org/document/7589901> (індексована в наукометричній базі Scopus).

46. Boyko N., Kryvenchuk Yu. Application of cloud services for processing of information flows. *Problems of Infocommunications. Science and Technology: International Scientific-Practical Conference (PIC S&T'2018)*, (Kharkiv, Ukraine, October 9–12). 2018. P. 243–247. (0,18 д.а.). ISBN: CFP18PIA-POD 978-1-5386-6612-8. URL: <https://easychair.org/publications/preprint/vSDr> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у розробленні методичного підходу до застосування хмарних сервісів для обробки інформаційних потоків у розподілених системах та становить 0,08 д.а.

47. Boyko N., Shakhovska N. Prospects for using cloud data warehouses in information systems. *IEEE 13th International Scientific and Technical Conference on Computer Science and Information Technologies (CSIT)*, (September). 2018. Vol. 2. P. 136–139. (0,18 д.а.). DOI: <https://doi.org/10.1109/STC-CSIT.2018.8526745>. URL: <https://www.sciencedirect.com/science/article/pii/S1877050919317478?via%3Dihub> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні можливостей використання технологій обробки Big Data в розподілених інформаційних системах з урахуванням специфіки хмарних сховищ даних та становить 0,08 д.а.

48. Kunanets N., Vasiuta O., Boiko N. Advanced technologies of Big Data research in distributed information systems. *IEEE 14th International Scientific and Technical Conference on Computer Science and Information Technologies (CSIT)*, (Lviv, Ukraine, September 17–20). 2019. P. 71–76. (0,23 д.а.). DOI: <https://doi.org/10.1109/STC-CSIT.2019.8929756>. URL: <https://ieeexplore.ieee.org/document/8929756> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні та узагальненні сучасних технологій обробки Big Data в умовах розподілених інформаційних систем та становить 0,11 д.а.

49. Shakhovska N., Boyko N., Zasoba Y., Benova E. Big data processing technologies in distributed information systems. *Procedia Computer Science: 10th International conference on emerging ubiquitous systems and pervasive networks (EUSPN-2019)*, 2019. P. 561–566. (0,23 д.а.). DOI: <https://doi.org/10.1016/j.procs.2019.11.047>. URL: <https://dl.acm.org/doi/10.1016/j.procs.2019.11.047> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні принципів організації розподіленої обробки великих даних (Big Data) та адаптації сучасних технологій до потреб інформаційних систем з високими вимогами до продуктивності та масштабованості та становить 0,18 д.а.

50. Boyko N., Tkachuk N. Processing of medical different types of data using Hadoop and Java MapReduce. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)*, (Växjö, Sweden, November 19–21). 2020. P. 405–414. (0,41 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcgclcfndmkaj/https://ceur-ws.org/Vol-2753/short15.pdf> (індексована в наукометричній базі Scopus)

Особистий внесок автора полягає у дослідженні та реалізації підходів до обробки різномірних медичних даних із використанням технологій Hadoop та моделі програмування MapReduce на мові Java та становить 0,35 д.а.

51. Boyko N., Dosiak I. Analysis of machine learning algorithms for classification and prediction of heart disease. *The 4th International Conference on Informatics & Data-Driven Medicine (IDDM 2021)*, (Valencia, Spain, November 19–21). 2021. P. 233–249. (0,72 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-ws.org/Vol-3038/paper15.pdf> (індексована в наукометричній базі Scopus)

Особистий внесок автора полягає у проведенні порівняльного аналізу алгоритмів машинного навчання для задач класифікації та прогнозування серцево-судинних захворювань та становить 0,55 д.а.

52. Boyko N., Hrynyshyn A. Using recurrent neural network to noise absorption from audio files. *Proceedings of the 2nd International Workshop on Computational & Information Technologies for Risk-Informed Systems (CITRisk 2021) co-located with XXI International Conference on Information Technologies in Education and Management (ITEM 2021)*, (Kherson, Ukraine, September 16–17). 2021. P. 227–240. (0,59 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-ws.org/Vol-3101/Paper15.pdf> (індексована в наукометричній базі Scopus)

Особистий внесок автора полягає у дослідженні можливостей використання рекурентних нейронних мереж (RNN) для приглушення шумів в аудіофайлах у задачах попередньої обробки звукових сигналів та становить 0,4 д.а. Автор провела аналіз джерел і типів шумів, характерних для акустичних даних, зокрема у сфері телекомунікацій та медичної акустики, та обґрунтувала доцільність застосування RNN для моделювання тимчасових залежностей у звукових сигналах.

53. Boyko N., Muzyka M. Analysis of multimodal data for classification problems by using methods of machine learning. *IEEE 8th International Conference on Problems of Infocommunications, Science and Technology (PIC S&T)*. 2021. P. 525–534. (0,41 д.а.). DOI: <https://doi.org/10.1109/PICST54195.2021.9772203>. URL: <https://ieeexplore.ieee.org/document/9772203> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні методів машинного навчання для аналізу мультимодальних даних у задачах класифікації та становить 0,2 д.а.

54. Boyko N., Mykhailyshyn V. Model of finding associative rules in inhomogeneous data of semantic networks. *Proceedings of The Fifth International Workshop on Computer Modeling and Intelligent Systems (CMIS-2022)*, (Zaporizhzhia, Ukraine, May 12). 2022. P. 58–67. (0,41 д.а.). DOI: <https://doi.org/10.32782/cmris/3137-5>. URL: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-ws.org/Vol-3137/paper11.pdf> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у розробленні моделі виявлення асоціативних правил у неоднорідних даних, що представлені у вигляді семантичних мереж, та становить 0,2 д.а.

55. Boyko N., Mykhailyshyn V. Methods of searching for associative rules for inhomogeneous data in semantic networks. *Proceedings of the 3rd International Workshop on Intelligent Information Technologies & Systems of Information Security*, (Khmelnitskyi, Ukraine, March 23–25). 2022. P. 54–71. (0,77 д.а.). URL: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://ceur-ws.org/Vol-3156/paper1.pdf> (індексована в наукометричній базі Scopus).

Особистий внесок автора полягає у дослідженні та вдосконаленні методів пошуку асоціативних правил у неоднорідних даних, що представлені у формі семантичних мереж, та становить 0,6 д.а.

Публікації, які додатково відображають наукові результати дисертації:

56. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Твій персональний помічник» / Бойко Н. І., Гетьман С. Л. 2022. № 112320. URL: <https://sis.ukrpatent.org/uk/search/detail/1695539/>
57. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Image Translate» / Бойко Н. І., Куба М. О. 2022. № 112319. URL: <https://sis.ukrpatent.org/uk/search/detail/1695540/>
58. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Інтелектуальна система виявлення стресу на основі машинного навчання в режимі реального часу» / Бойко Н. І., Яцків М. В. 2022. № 111792. URL: <https://sis.ukrpatent.org/uk/search/detail/1695561/>
59. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Система прийняття рішень для навігації в середовищах з неповною інформацією» / Бойко Н. І. 2023. № 117954. URL: <https://sis.ukrpatent.org/uk/search/detail/1708480/>
60. Свідоцтво про реєстрацію авторського права на твір: Комп'ютерна програма «Алгоритм оптимізації гіперпараметрів при тренуванні моделей машинного навчання для покращення продуктивності їх застосування на невідомих даних» / Бойко Н. І. 2024. № 126272. URL: <https://sis.nipo.gov.ua/uk/search/detail/1810806/>

ДОДАТОК В

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ

Сформований набір даних дослідження

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	
	Patient_ID	QT_interv	RR_interv	QRS_duration	P_interv	ST_depression	HRV	Alpha_power	Beta_power	Peak_frequency	Spectral_entropy	Theta_alpha_index	Frontal_coherence	Hypointense_volume	GM_texture_tropy	GM_WM_contrast	Periventricular_intensity	Parietal_LBP	Lateral_ventricle_shape	Age	Sex	Diabetes	Hypertension	Smoking	BMI	Stroke_history	
1																											
2	Patient_1	414.90	939.94	93.25	81.38	0.06	41.52	7.77	9.57	9.97	0.88	1.00	0.48	1.89	0.59	1.70	1.26	0.31	0.73	65		1	0	0	0	25.4	1
3	Patient_2	395.85	892.46	98.55	97.09	0.10	40.93	8.74	4.44	9.50	0.91	1.11	0.64	1.97	0.50	1.85	1.04	0.28	0.73	50		1	1	1	0	33.4	0
4	Patient_3	419.43	805.96	92.08	103.80	0.10	14.09	8.12	9.43	9.83	0.85	1.02	0.71	2.05	0.41	2.21	1.34	0.28	0.61	64		1	0	1	0	21.2	0
5	Patient_4	445.69	735.31	96.92	138.32	0.12	43.40	8.90	7.53	10.71	0.61	1.23	0.68	2.76	0.45	1.79	1.08	0.27	0.76	64		1	0	0	1	25.5	0
6	Patient_5	392.98	869.82	81.06	118.35	0.03	64.66	9.57	9.41	11.28	0.78	1.56	0.71	1.40	0.53	1.53	1.35	0.40	0.55	70		1	0	0	0	15.4	1
7	Patient_6	392.98	839.35	102.13	89.97	0.13	24.52	11.67	9.55	10.57	0.68	0.97	0.58	1.32	0.68	1.31	1.15	0.37	0.63	76		1	0	0	0	28.4	0
8	Patient_7	447.38	889.52	100.01	117.29	-0.04	70.97	9.36	11.22	10.10	0.78	1.50	0.55	2.99	0.45	1.95	0.86	0.33	0.50	52		0	1	1	0	24.1	1
9	Patient_8	423.02	863.52	91.83	86.79	0.07	59.76	6.83	10.71	11.50	0.90	0.97	0.53	1.63	0.58	1.87	1.00	0.37	0.86	89		1	1	1	0	19.1	0
10	Patient_9	385.92	904.96	106.59	126.24	0.08	35.32	12.28	10.69	9.69	0.83	0.95	0.59	0.99	0.47	1.61	1.11	0.34	0.68	88		0	1	0	1	29.4	1
11	Patient_10	416.28	746.48	109.38	102.93	0.13	47.17	8.33	10.89	11.03	0.91	1.45	0.59	1.61	0.51	2.11	1.47	0.31	0.92	73		0	1	1	0	26.4	0
12	Patient_11	386.10	931.74	83.92	108.60	0.10	81.97	9.88	8.58	9.71	0.83	1.48	0.62	1.74	0.65	1.67	1.38	0.22	0.78	61		0	0	0	1	25.8	0
13	Patient_12	386.03	819.76	92.37	129.89	0.03	64.67	10.89	8.06	10.43	0.67	1.46	0.59	3.24	0.58	1.76	1.52	0.29	0.74	62		0	1	1	1	31.5	1
14	Patient_13	407.26	1007.53	92.31	90.69	0.05	50.18	10.40	9.75	9.89	0.55	0.81	0.59	2.74	0.38	1.80	1.53	0.28	0.64	84		1	1	0	0	23.9	1
15	Patient_14	342.60	731.08	90.60	89.04	0.11	45.25	12.19	9.46	9.94	0.81	1.06	0.52	2.92	0.44	1.69	1.09	0.24	0.60	62		0	0	1	0	29.6	1
16	Patient_15	348.25	973.60	108.29	101.25	0.10	51.53	10.96	7.38	9.62	0.78	1.45	0.69	2.66	0.63	1.87	1.16	0.23	0.75	55		1	0	1	0	30.2	0
17	Patient_16	383.13	819.79	98.06	125.58	0.07	39.76	8.28	8.81	11.34	0.70	1.21	0.61	2.76	0.51	2.15	1.12	0.32	0.69	89		0	1	0	1	24.7	1
18	Patient_17	369.62	734.86	97.35	87.21	0.08	7.91	14.36	7.93	9.27	0.63	0.88	0.58	1.45	0.39	1.46	1.07	0.32	0.57	56		1	0	1	1	27	1
19	Patient_18	409.43	751.61	79.96	67.52	0.13	90.84	10.39	6.29	9.26	0.73	1.34	0.53	1.84	0.42	1.95	0.83	0.24	0.55	59		1	0	1	1	33.7	1
20	Patient_19	372.76	767.97	106.35	103.23	0.07	53.11	9.71	10.58	12.12	0.78	0.99	0.47	1.21	0.57	1.85	1.20	0.26	0.60	70		0	0	0	1	23	0
21	Patient_20	357.63	842.42	87.61	118.28	0.10	57.96	11.93	8.11	10.98	0.87	1.74	0.73	1.83	0.60	1.85	0.94	0.36	0.88	47		1	1	1	1	29.2	1
22	Patient_21	443.97	852.28	100.60	128.00	0.21	48.84	10.50	12.10	7.61	0.82	1.66	0.66	2.55	0.50	2.06	1.19	0.26	0.92	47		1	1	0	1	27.2	0
23	Patient_22	393.23	742.63	102.77	103.05	0.03	35.30	10.80	4.75	9.43	0.96	1.38	0.44	2.11	0.75	1.81	1.62	0.31	0.72	82		1	1	1	1	32.1	0
24	Patient_23	402.03	797.56	113.61	103.83	0.01	46.28	14.98	6.89	8.19	0.70	1.61	0.68	3.05	0.58	1.94	1.10	0.29	0.71	79		1	0	1	1	26.9	0
25	Patient_24	357.26	1014.23	86.91	127.31	0.14	18.01	9.45	8.07	9.05	0.89	1.22	0.69	1.09	0.48	2.01	1.24	0.33	0.67	53		0	1	0	0	29.7	1
26	Patient_25	383.67	972.75	69.80	81.95	0.07	95.54	9.36	10.27	6.86	0.80	1.43	0.61	2.40	0.42	1.65	1.38	0.26	0.61	87		0	0	0	1	20.6	0
27	Patient_26	403.33	843.63	101.84	104.17	0.08	25.31	10.23	8.80	9.86	0.87	1.64	0.76	1.00	0.40	1.89	1.26	0.30	0.84	84		0	1	0	0	18.4	1
28	Patient_27	365.47	803.80	118.01	112.86	0.06	29.36	12.14	8.62	8.86	0.76	1.27	0.62	2.08	0.53	1.72	1.26	0.31	0.89	48		0	0	1	0	22.8	1
29	Patient_28	411.27	812.00	112.39	116.74	0.09	41.19	6.99	5.75	10.06	0.91	1.12	0.46	2.59	0.45	1.76	1.13	0.31	0.61	64		1	0	1	0	25.2	1
30	Patient_29	381.98	861.35	102.10	102.35	0.18	75.76	6.07	5.69	8.37	0.83	0.69	0.64	1.83	0.67	1.70	1.15	0.30	0.69	59		0	1	0	0	25.6	0
31	Patient_30	391.25	697.72	95.08	110.52	0.14	50.29	8.83	8.65	10.08	0.73	1.18	0.62	2.44	0.65	1.94	1.01	0.32	0.66	73		0	1	0	0	31.4	0
32	Patient_31	381.95	774.26	108.07	72.68	0.14	25.28	6.73	5.27	9.59	0.80	1.45	0.54	1.23	0.56	1.82	1.37	0.41	0.66	49		1	1	0	1	25.4	0
33	Patient_32	455.57	633.14	90.26	100.13	0.03	75.09	9.15	6.94	11.50	0.78	1.48	0.66	0.67	0.38	1.92	0.85	0.43	0.82	83		1	1	1	1	27.1	1
971	Patient_970	357.08	913.38	102.70	129.36	0.17	38.16	11.65	10.27	11.49	0.73	1.34	0.33	2.80	0.55	1.48	1.04	0.28	0.79	56		1	0	1	1	30.7	1
972	Patient_971	403.84	859.36	80.88	104.04	0.18	69.51	7.87	11.19	9.61	0.71	1.31	0.63	3.65	0.40	1.83	1.51	0.35	0.43	89		1	0	0	0	33.3	0
973	Patient_972	379.57	505.96	99.31	97.07	0.10	50.02	9.90	9.29	11.48	0.87	1.15	0.45	1.15	0.48	1.51	1.49	0.28	0.67	46		1	1	0	1	23.1	1
974	Patient_973	425.22	865.59	86.32	115.21	0.05	63.72	13.82	6.69	9.34	0.88	1.75	0.50	2.23	0.53	1.93	1.22	0.26	0.68	64		1	0	0	1	21.9	0
975	Patient_974	380.42	819.47	119.87	111.30	0.00	6.93	12.33	6.98	11.33	0.86	1.35	0.52	4.20	0.40	2.25	1.10	0.25	0.77	60		1	1	0	0	23.2	0
976	Patient_975	386.61	798.13	109.11	115.34	0.03	58.94	12.70	8.16	10.82	0.95	0.91	0.53	2.05	0.37	1.76	1.47	0.25	0.69	58		1	0	0	1	26.4	0
977	Patient_976	343.31	761.15	101.06	112.87	0.03	37.23	10.05	8.64	9.09	0.75	1.27	0.46	2.05	0.55	1.84	1.06	0.33	0.77	46		1	1	1	1	32.5	0
978	Patient_977	386.43	912.41	112.64	117.59	0.17	83.07	10.64	6.02	10.31	0.97	1.43	0.62	2.63	0.61	2.41	1.25	0.26	0.59	60		0	1	0	1	33.4	0
979	Patient_978	327.28	894.75	91.54	131.71	0.11	62.46	12.00	9.45	9.95	0.71	1.02	0.46	2.03	0.49	1.44	1.47	0.25	0.73	48		1	1	1	1	25.5	1
980	Patient_979	352.48	722.71	105.43	118.52	0.12	54.80	13.12	8.17	10.63	0.70	1.53	0.64	0.63	0.45	2.16	1.03	0.34	0.79	87		0	1	0	1	26.6	1
981	Patient_980	422.81	840.71	102.00	94.26	-0.01	59.73	6.10	4.57	9.78	0.62	1.31	0.82	2.91	0.52	2.12	1.37	0.32	0.55	57		1	0	1	0	22.3	0
982	Patient_981	423.57	702.83	102.64	130.44	0.04	30.03	7.37	6.14	9.69	0.76	0.50	0.47	0.40	0.51	2.06	1.30	0.35	0.95	82		0	0	1	0	27.3	1
983	Patient_982	412.76	662.04	112.72	134.61	0.14	82.47	12.62	6.99	11.37	0.75	1.29	0.57	1.67	0.52	2.19	1.19	0.33	0.82	45		1	1	1	0	26.2	0
984	Patient_983	370.99	737.33	107.32	157.28	0.11	89.83	9.45	7.85	9.90	0.85	1.08	0.35	2.97	0.25	1.88	1.00	0.26	0.70	53		0	1	0	0	26.2	0
985	Patient_984	398.57	886.24	102.89	93.15	0.09	57.86	8.66	11.78	10.83	0.82	1.36	0.57	1.71	0.39	1.63	1.06	0.30	0.62	65		0	1	1	0	31.7	0
986	Patient_985	399.89	895.31	83.45	113.64	0.13	81.81	7.49	8.48	9.77	0.68	1.48	0.66	1.45	0.42	2.13	1.26	0.31	0.68	62		0	0	0	1	28.6	0
987	Patient_986	365.25	851.31	90.40	78.77	0.18	38.62	8.89	6.32	11.67	0.76	1.26	0.67	2.70	0.52	2.14	0.92	0.25									

Таблиця В.1 – Характеристика проблем аналізу багатовимірних даних

Вид проблеми	Характеристика проблеми	Наслідки	Рішення проблеми
Проблема «прокляття розмірності»	- Зі збільшенням кількості вимірів (змінних) експоненційно збільшується обсяг простору, в якому розташовані дані. - Збільшення простору призводить до зменшення густини даних	- Методи класифікації, регресії та кластеризації можуть втрачати точність. - Різниця між близькими й далекими точками стає менш виразною, ускладнюючи аналіз відстаней (наприклад, у методах k-ближчих сусідів).	- Використання методів зниження розмірності: аналіз головних компонентів (PCA), t-SNE, UMAP . - Вибір найінформативніших змінних (фільтрація ознак). - Регуляризація моделей для боротьби з перенавчанням.
Надмірна кореляція змінних	Змінні є сильно корельованими між собою, що призведе до надлишкової інформації, яка ускладнює моделювання та інтерпретацію результатів.	- Моделі неправильно визначають важливість змінних. - У регресії, спостерігається мультиколінеарність, що призводить до нестабільності оцінок параметрів.	- Використання методів ортогоналізації змінних, наприклад, PCA. - Відбір змінних за допомогою критеріїв значущості (наприклад, методи LASSO або RIDGE-регресії).
Неповнота або шум у даних	Багатовимірні дані часто містять пропущені значення, некоректні записи або шум (значення, які відхиляються від істини через помилки вимірювань або запису).	- Зниження якості моделей через наявність нерелевантної або викривленої інформації. - Побудова алгоритмів, які можуть коректно працювати з неповними даними.	- Використання методів обробки пропусків: імпуція, видалення некоректних записів. - Фільтрація шуму за допомогою алгоритмів згладжування, наприклад, середнього ковзного вікна або медіанного фільтра. - Використання алгоритмів, стійких до шуму (наприклад, дерев рішень).
Складність візуалізації	Зі зростанням кількості вимірів візуалізація даних стає складнішою	Неможливість отримати інтуїтивного розуміння структури даних.	Використання інтерактивних візуалізацій, які дозволяють досліджувати природу багатовимірних даних.
Висока обчислювальна складність	Обробка багатовимірних даних вимагає значних обчислювальних ресурсів через високу розмірність і обсяг інформації.	- Тривалий час обробки, особливо для методів машинного навчання. - Потреба в спеціалізованому забезпеченні або хмарних обчисленнях.	- Використання розподілених обчислень (наприклад, Apache Spark). - Оптимізація алгоритмів: інкрементне навчання, методика вибору обробки даних. - Використання апаратного прискорення, наприклад, GPU чи TPU.
Інтерпретація результатів	Часто багатовимірні моделі, такі як нейронні мережі чи методи ансамблю, є "чорними ящиками", які складно інтерпретувати	Неможливість перевірити чи обґрунтувати отримані висновки.	- Використання методів інтерпретації моделей, наприклад, SHAP, LIME. - Вибір моделей із прозорою структурою (лінійна регресія, дерево рішень) для завдань, де інтерпретація критично важлива.




Рис. В.1. Архітектура моделі інтеграції моделей модальностей для багатокласової класифікації стану пацієнта на основі мультимодальних медичних даних