

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Кваліфікаційна наукова праця на правах рукопису

Мневець Антон Володимирович

УДК 004.8:616.12-073.7

ДИСЕРТАЦІЯ
СИСТЕМА ВИЯВЛЕННЯ СЕРЦЕВИХ АРИТМІЙ МЕТОДАМИ
МАШИННОГО НАВЧАННЯ

Спеціальність: 153 – Мікро- та наносистемна техніка

Галузь знань: 15 – Автоматизація та приладобудування

Подається на здобуття наукового ступеня доктора філософії

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

_____ А. В. Мневець

Науковий керівник: Іванушкіна Наталія Георгіївна, кандидат технічних наук, доцент

АНОТАЦІЯ

Мневець А. В. Система виявлення серцевих аритмій методами машинного навчання – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 153 «Мікро- та наносистемна техніка». – Національний технічний університет України «Київський політехнічний інститут ім. Ігоря Сікорського», МОН України, Київ, 2026.

Дисертаційна робота присвячена розробці та дослідженню методів автоматизованого виявлення серцевих аритмій на основі аналізу електрокардіографічних сигналів з використанням сучасних методів машинного навчання та нейронних мереж. Дослідження спрямоване на вдосконалення методичного та алгоритмічного забезпечення систем комп'ютерної неінвазивної діагностики серцево-судинних захворювань.

Основною задачею дисертаційного дослідження є розробка системи виявлення серцевих аритмій на ЕКГ з використанням методів машинного навчання та нейронних мереж, що забезпечує підвищення точності, чутливості та специфічності автоматизованої діагностики та прогнозування порушень ритму серця. Дослідження обумовлене потребою у підвищенні точності діагностики патологій серцево-судинної системи в умовах гетерогенності та нестачі ЕКГ даних і вдосконаленні методів виявлення низькоамплітудних ознак патологій на ЕКГ, зокрема пізніх потенціалів шлуночків та передсердь, які є критично важливими маркерами небезпечних для життя аритмій, але часто залишаються непомітними для стандартних методів аналізу.

У першому розділі проаналізовано структуру сучасних ЕКГ електрокардіографів, що пройшли значний шлях розвитку від стаціонарних 12-канальних апаратів до портативних холтер-моніторів та вбудованих систем у смарт-годинниках. Особливу увагу приділено методу, спрямованому на підвищення точності виявлення низькоамплітудних компонентів на ЕКГ,

такому як електрокардіографія високого розрізнення. Встановлено, що основним викликом у сучасній кардіодіагностиці аритмій є значна варіабельність клінічних проявів патологій, багато з яких на ранніх стадіях мають низькоамплітудні або слабо виражені ознаки на ЕКГ. Тому розвитку методів та засобів раннього виявлення та лікування серцевих аритмій останнім часом приділяється велика увага.

У другому розділі розглянуто прояви патологічної електричної активності серця на ЕКГ під час наявності різних типів аритмій та методи їх діагностування. Проаналізовано комплекс методів аналізу ЕКГ, що включає часові, частотні, нелінійні, векторні, морфологічні та комбіновані підходи. Кожен з цих методів має унікальні діагностичні можливості для виявлення окремих типів порушень серцевого ритму. Встановлено, що існуючі методи аналізу демонструють обмежену ефективність під час багатокласової діагностики, коли необхідно одночасно ідентифікувати кілька типів серцевих захворювань.

У третьому розділі виконано розробку методів попередньої обробки ЕКГ сигналів. Запропоновано удосконалений метод усереднення кардіоциклів з розбиттям на епохи та застосуванням лінійного матричного розкладання для придушення нерегулярних включень. Цей підхід продемонстрував вищу чутливість і точність виділення пізніх потенціалів порівняно з класичним усередненням. Розроблено нейромережеві моделі для фільтрації шумових фрагментів, що застосовуються для корекції результатів автоматизованих електрокардіографів та суттєво підвищують точність виявлення QRS комплексів. Розробка спеціалізованого автоенкодера для стиснення ЕКГ сигналів зі збереженням діагностичної інформації, який забезпечує формування стислого латентного вектора навіть у випадку високого ступеня стиснення стала важливим результатом.

У четвертому розділі проведено огляд методів автоматизованого аналізу ЕКГ сигналів. Розроблено метод на основі безперервного вейвлет-перетворення, який продемонстрував високу ефективність у виявленні низькоамплітудних патологічних складових ЕКГ сигналів. Створено алгоритми, засновані на аналізі форми ЕКГ сигналу, що є корисним інструментом для морфологічного опису сигналу. Для складних задач багатокласової класифікації аритмій та супутніх патологій найбільш перспективними виявилися нейромережеві методи. Розроблена класифікаційна модель сіамської нейронної мережі показала вищу середню точність порівняно зі спеціалізованою архітектурою ECGNet. Ключовою перевагою розробленої моделі є її ефективність в умовах обмежених та незбалансованих наборів даних. Для подальшого підвищення чутливості нейронних мереж до низькоамплітудних сигналів розроблено адаптивну функцію активації з властивістю стискаючого відображення, яка продемонструвала найкращі результати точності та швидкості збіжності навчання.

У п'ятому розділі досліджено можливості підвищення ефективності автоматизованого виявлення низькоамплітудних компонентів ЕКГ сигналів. Застосування сіамської нейронної мережі у вузькоспрямованій задачі виявлення пізніх потенціалів шлуночків та передсердь показали, що вони здатні забезпечити високу точність класифікації низькоамплітудних ознак. Застосування спеціалізованих архітектур нейронних мереж та вдосконалення методу вейвлет-перетворення дозволило зменшити вплив високоамплітудних складових сигналу, що маскують цільові ознаки. В результаті розроблене модифіковане вейвлет-перетворення забезпечило точнішу локалізацію низькоамплітудних структур у частотно-часовій області.

У шостому розділі описано розроблену структуру, узагальнений алгоритм функціонування та спосіб застосування у клінічних умовах системи автоматизованого аналізу ЕКГ для виявлення різних серцевих патологій,

особливо з низькоамплітудними ознаками. Запропонована структура об'єднує попередню фільтрацію та сегментацію сигналів, модифіковане вейвлет-перетворення, стиснення векторів ознак за допомогою автоенкодера, сіамську нейронну мережу для порівняльного аналізу та виявлення небезпечних для життя станів серцево-судинної системи. Розроблена система здатна функціонувати як клінічний інструмент підтримки діагностичних рішень, оскільки не лише автоматизує інтерпретацію сигналу, а й виявляє ознаки, які важко помітити використовуючи стандартний аналіз ЕКГ.

Наукова новизна отриманих результатів:

1. Розроблено комплекс класифікаційних моделей сіамських нейронних мереж, особливістю яких є використання згорткових шарів для паралельної обробки двох типів фрагментів даних: усередненого кардіоциклу з детальними морфологічними характеристиками та ЕКГ-сигналу, що відображає варіабельність серцевого ритму, а також застосування розроблених еталонних векторів ознак патологій для виявлення аритмій, супутніх патологічних станів серцево-судинної системи та пізніх потенціалів шлуночків і передсердь на ЕКГ в умовах обмеженої кількості тренувальних даних.

2. Розроблено нову адаптивну функцію активації, відмінністю якої є нелінійна залежність з властивістю стискаючого відображення, що на основі зменшення проблеми вибуху та згасання градієнтів під час застосування в послідовних шарах нейронних мереж сприяє розпізнаванню низькоамплітудних складових ЕКГ, а також за допомогою запропонованого методу виявлення «надлишкових» шарів призводить до підвищення швидкості роботи НМ без втрати точності.

3. Розроблено метод зменшення розмірності ознак ЕКГ сигналу на основі нейромережевого автоенкодера з використанням шару уваги, залишкових зв'язків та спільних ваг шарів нейронної мережі, що дає можливість створити скорочений вектор, який характеризується високим

ступенем стиснення оригінального сигналу та збереженням діагностично значущих ознак.

4. Вдосконалено метод вейвлет-перетворення для аналізу ЕКГ сигналів за допомогою введення косинусної подібності та запропонованої масштабуючої функції, особливістю якої є посилення низькоамплітудних компонентів, що дозволяє підвищити точність виявлення пізніх потенціалів передсердь та шлуночків.

Практичне значення отриманих результатів:

1. На основі запропонованих методів попередньої обробки та удосконаленого методу усереднення кардіоциклів розроблено алгоритмічне забезпечення системи, що дозволяє підвищити точність автоматизованого виявлення низькоамплітудних ознак патологій на ЕКГ, зокрема пізніх потенціалів шлуночків та передсердь (на 10-30% в результаті оцінювання показників подібності з еталонними пізніми потенціалами з амплітудою 5 мкВ).

2. Розроблено алгоритмічне забезпечення для системи виявлення аритмій на основі кластерного аналізу ЕКГ параметрів без вчителя, що дозволяє виявляти приховані групи ризику розвитку серцевої недостатності у пацієнтів та небезпечні для життя стани функціонування серця.

3. Розроблено підхід до використання згорткових нейронних мереж для виявлення помилково детектованих або зашумлених кардіоциклів, що дає можливість видаляти спотворені фрагменти ЕКГ сигналу та підвищувати точність виявлення пізніх потенціалів шлуночків і передсердь на 19% на основі аналізу показника подібності динамічної трансформації часової шкали в порівнянні з використанням класичного ЕКГ детектора.

4. Запропоновано алгоритми виділення діагностично значущих ознак із використанням послідовності методів попередньої обробки ЕКГ сигналів,

які ґрунтуються на аналізі коливальних процесів кардіоциклів за допомогою вейвлет-перетворення, що дозволяє забезпечити виявлення тахіаритмій і патологічних форм QRS-комплексів.

5. Розроблено структуру, алгоритм функціонування та спосіб застосування в клінічних умовах системи виявлення серцевих аритмій на ЕКГ, особливістю якої є використання розроблених методів машинного навчання, попередньої обробки сигналів та моделей нейронних мереж, що дає можливість ранньої діагностики аритмій та супутніх патологій.

Ключові слова: мікроелектронні системи, машинне навчання, частотна характеристика, глибоке навчання, класифікація, пізні потенціали, електрокардіограма, адаптивні методи, мода, нейронні мережі, аналіз ЕКГ, аналіз медичних даних.

ABSTRACT

Anton Mnevets. Cardiac arrhythmia detection system using machine learning methods – Qualification scientific work on manuscript rights.

Dissertation for the degree of Doctor of Philosophy in specialty 153 "Micro- and nanosystem engineering". – National Technical University of Ukraine "Ihor Sikorsky Kyiv Polytechnic Institute", MES of Ukraine, Kyiv, 2026.

The dissertation work is devoted to the development and investigation of methods for automated detection of cardiac arrhythmias based on the analysis of electrocardiographic signals using modern machine learning methods and neural networks. The research is aimed at improving the methodological and algorithmic support of computer-based non-invasive diagnostic systems for cardiovascular diseases.

The main task of the dissertation research is the development of a system for detecting cardiac arrhythmias on ECG using machine learning methods and neural networks, resulting in improved accuracy, sensitivity, and specificity of automated diagnosis and prediction of heart rhythm disorders. The research is prompted by the need to improve the accuracy of diagnosing pathologies of the cardiovascular system under conditions of heterogeneity and insufficiency of ECG data, as well as to improve methods for detecting low-amplitude pathological features on ECG signals, in particular ventricular and atrial late potentials, which are critically important markers of life-threatening arrhythmias but often remain unnoticed by standard analysis methods.

In the first chapter, the structure of modern ECG electrocardiographs is analyzed, which have a significant path of development from stationary 12-channel devices to portable Holter monitors and embedded systems in smartwatches. Special attention is paid to the method aimed at increasing the accuracy of detecting low-amplitude components on ECG, such as high-resolution electrocardiography. It is established that the main challenge in modern cardiac arrhythmia diagnostics is the

significant variability of clinical manifestations of pathologies, many of which at early stages have low-amplitude or weakly expressed ECG features. Therefore, considerable attention has recently been paid to the development of methods and tools for early detection and treatment of cardiac arrhythmias.

In the second chapter, the manifestations of pathological electrical activity of the heart on ECG in the presence of various types of arrhythmias and the methods of their diagnosis are considered. A complex of ECG analysis methods is analyzed, which includes time-domain, frequency-domain, nonlinear, vector, morphological, and combined approaches. Each of these methods has unique diagnostic capabilities for detecting specific types of heart rhythm disorders. It is established that existing analysis methods demonstrate limited effectiveness during multiclass diagnostics, when it is necessary to simultaneously identify several types of disorders.

In the third chapter, the development of ECG signal preprocessing methods is carried out. An improved method of cardiac cycle averaging with division into epochs and the application of linear matrix decomposition to suppress irregular inclusions is proposed. This approach demonstrated higher sensitivity and accuracy in isolating late potentials compared to classical averaging. Neural network models for filtering noisy fragments were developed, which are applied to correct the results of automated electrocardiographs and significantly increase the accuracy of QRS complex detection. The development of a specialized autoencoder for compressing ECG signals while preserving diagnostic information, which ensures the formation of a compact latent vector even in the case of a high degree of compression is an important result.

In the fourth chapter, a review of methods for automated ECG signal analysis is carried out. A method based on continuous wavelet transform is developed, which demonstrated high effectiveness in detecting low-amplitude pathological components of ECG signals. The algorithms based on the analysis of ECG shape, which is a useful tool for morphological description of the signal is created. For

complex tasks of multiclass classification of arrhythmias and accompanying pathologies, neural network methods turned out to be the most promising. The developed Siamese neural network classification model showed higher average accuracy compared to the specialized ECGNet architecture. A key advantage of the developed model is its effectiveness under conditions of limited and unbalanced datasets. To further increase the sensitivity of neural networks to low-amplitude signals, an adaptive activation function with a compressive mapping property was developed, which demonstrated the best results in accuracy and training convergence speed.

In the fifth chapter, the possibilities of increasing the effectiveness of automated detection of low-amplitude ECG signal components are investigated. The application of a Siamese neural network to the narrowly focused task of detecting ventricular and atrial late potentials showed, that they are capable of providing high accuracy in the classification of low-amplitude features. The application of specialized neural network architectures and improvements to the wavelet transform method made it possible to reduce the influence of high-amplitude signal components that mask the target features. As a result, the developed modified wavelet transform ensured more accurate localization of low-amplitude structures in the time-frequency domain.

In the sixth chapter, the developed structure, generalized algorithm for the functioning and the application of the automated ECG analysis system in clinical settings for the detection of various cardiac pathologies, including those with low-amplitude features, are described. The proposed structure combines signal preprocessing and segmentation, modified wavelet transform, compression of feature vectors using an autoencoder, a Siamese neural network for comparative analysis and detection of life-threatening conditions of the cardiovascular system. The developed system is capable of functioning as a clinical decision support tool, since it not only automates signal interpretation but also detects features that are difficult to notice using standard ECG analysis.

Scientific novelty of the obtained results:

1. A complex of classification models based on Siamese neural networks has been developed, the peculiarity of which is the use of convolutional layers for parallel processing of two types of data fragments: an averaged cardiocycle with detailed morphological characteristics and an ECG signal reflecting heart rate variability, as well as the application of developed reference feature vectors of pathologies for the detection of arrhythmias, accompanying pathological conditions of the cardiovascular system, and ventricular and atrial late potentials on ECG under conditions of a limited amount of training data.

2. A new adaptive activation function has been developed, the peculiarity of which is a nonlinear dependence with a compressive mapping property, which, by reducing the problem of gradient explosion and vanishing when applied in successive layers of neural networks, contributes to the recognition of low-amplitude ECG components, and, also by the proposed method for detecting “redundant” layers, leads to an increase in the speed of neural network operation without loss of accuracy.

3. A method for reducing the dimensionality of ECG signal features based on a neural network autoencoder using an attention layer, residual connections, and shared weights of neural network layers has been developed, which makes it possible to form a reduced feature vector characterized by a high degree of compression of the original signal while preserving diagnostically significant features.

4. The wavelet transform method has been improved by introducing a scaling function and cosine similarity, which makes it possible to increase the accuracy of detecting low-amplitude pathological features on ECG.

Practical significance of the obtained results:

1. Based on the proposed preprocessing methods and the improved cardiac cycle averaging algorithm, algorithmic support of the system has been developed,

which makes it possible to increase the accuracy of automated detection of low-amplitude pathological features on ECG, in particular ventricular and atrial late potentials (by 10–30% as a result of evaluating similarity measures with reference late potentials with an amplitude of 5 μV).

2. Algorithmic support for an arrhythmia detection system based on unsupervised cluster analysis of ECG parameters has been developed, which makes it possible to identify hidden risk groups for the development of heart failure and life-threatening conditions of cardiac function.

3. An approach to the use of convolutional neural networks for detecting erroneously detected or noisy cardiac cycles has been developed, which makes it possible to remove distorted ECG signal fragments and increase the accuracy of detecting ventricular and atrial late potentials by 19% based on the analysis of the similarity measure of dynamic time warping compared to the use of a classical ECG detector.

4. Algorithms for extracting diagnostically significant features using a sequence of ECG signal preprocessing methods have been proposed, which makes it possible to ensure the detection of tachyarrhythmias and pathological forms of QRS complexes.

5. The structure, algorithm of functioning and technique of application in clinical conditions of a cardiac arrhythmia detection system have been developed, the feature of which is the use of the developed machine learning methods, signal preprocessing techniques, and neural network models, which enables early diagnosis of arrhythmias and accompanying pathologies.

Keywords: microelectronic systems, machine learning, frequency response, deep learning, classification, late potentials, electrocardiogram, adaptive techniques, mode, neural networks, ECG analysis, medical data analysis.

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ

Статті, в яких опубліковані основні результати дисертації:

[1] A. V. Mnevets and N. H. Ivanushkina, “The method of preprocessing of ECG signals for detection of atrial and ventricular late potentials,” *Microsystems Electronics and Acoustics*, vol. 28, no. 2, 2023, doi: <https://doi.org/10.20535/2523-4455.mea.281741>, ISSN 2523-4455. *(Особистий внесок здобувача: Розробка та тестування методу попередньої обробки ЕКГ сигналів для виявлення пізніх потенціалів передсердь та шлуночків, а також створення набору даних для тестування методу. Внесок співавторів: Н. Г. Іванушкіна – постановка наукової задачі, наукове керівництво, теоретичний супровід.)*

[2] A. V. Mnevets and N. G. Ivanushkina, “Neural networks detection of low-amplitude components on ECG using modified wavelet transform,” *Visnyk NTUU KPI Seriya – Radiotekhnika Radioaparatabuduvannia*, no. 97, pp. 46–57, 2024, doi: <https://doi.org/10.20535/radap.2024.97.46-57>, ISSN 2310-0389. *(Особистий внесок здобувача: Модифікація методу вейвлет перетворення для ЕКГ сигналу, а також розробка методу застосування модифікованого вейвлет перетворення для виявлення пізніх потенціалів передсердь та шлуночків. Внесок співавторів: Н. Г. Іванушкіна – координація виконання етапів наукової роботи, наукове керівництво, теоретичний супровід.)*

[3] A. Mnevec and N. Ivanushkina, “Neural network autoencoder model for forming reduced vector characteristics of ECG signals,” *Bulletin of Kyiv Polytechnic Institute Series Instrument Making*, vol. 69, no. 1, pp. 93–105, 2025, doi: [https://doi.org/10.20535/1970.69\(1\).2025.331920](https://doi.org/10.20535/1970.69(1).2025.331920), ISSN 2663-3450. *(Особистий внесок здобувача: Розробка архітектури мережевого автоенкодера, та тестування його роботи на основі публічних наборів даних. Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису, наукове покращення тексту.)*

[4] A. V. Mnevets and N. H. Ivanushkina, "Siamese neural network's models for cardiac arrhythmia classification in the conditions of shortage of training ECG signals," *Microsystems Electronics and Acoustics*, vol. 30, no. 2, 2025, doi: <https://doi.org/10.20535/2523-4455.mea.325111>, ISSN 2523-4455. (*Особистий внесок здобувача: Розробка та тестування моделі сіамської нейронної мережі для виявлення серцевих аритмій та супровідних патологій, розробка вектора ознак патологій, формування тренувального набору. Внесок співавторів: Н. Г. Іванушкіна – визначення наукової проблеми та формування цілей дослідження, наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.*)

[5] А. В. Мневець and Н. Г. Іванушкіна, «Класифікація низькоамплітудних компонент ЕКГ за допомогою адаптивних функцій активації нейронних мереж», *Вісті вищих учбових закладів. Радіoeлектроніка*, vol. 67, no. 12, pp. 719–732, 2024, doi: <https://doi.org/10.20535/s0021347024120021>, ISSN 1934-8061. (*Особистий внесок здобувача: Аналіз існуючих функцій активації і розробка власної функції активації для зменшення впливу явищ вибуху та згасання градієнтів, а також розробка методу оцінювання надлишковості шарів нейронних мереж на основі адаптивних функцій активації. Внесок співавторів: Н. Г. Іванушкіна – постановка проміжних завдань та коригування дослідницької стратегії, наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.*)

[6] V. Kaverinskiy, I. Chaikovsky, A. Mnevets, T. Ryzhenko, M. Bocharov, and K. Malakhov, "Scalable clustering of complex ECG health data: Big data clustering analysis with UMAP and HDBSCAN," *Computation*, vol. 13, no. 6, Art. no. 144, 2025, doi: <https://doi.org/10.3390/computation13060144>, ISSN 2079-3197. (*Особистий внесок здобувача: Обрахунок ЕКГ параметрів, та попередня обробка сигналів з набору даних об'ємом 14863 спостережень. Внесок співавторів: В. Каверінський – формулювання концепції та методології*

дослідження, розробка програмного забезпечення, проведення експериментальних досліджень, підготовка тексту та візуалізацій; І. Чайковський – співавторство концепції, надання ресурсів, валідація результатів, наукове керівництво та проєкту, залучення фінансування; Т. Риженко – надання ресурсів і участь у редакційному опрацюванні матеріалу; М. Бочаров – редакційне доопрацювання, адміністративний супровід та залучення фінансування; К. Малахов – розробка програмного забезпечення, валідація результатів та редакційне опрацювання тексту.)

Праці, що засвідчують апробацію матеріалів дисертації:

[1] N. Ivanushkina та A. Mnevets, “Detection of Erroneously Selected Cardiac Cycles Using Neural Networks”, у 2024 IEEE 42nd Int. Conf. Electron. Nanotechnol. (ELNANO), Kyiv, Ukraine, 13–16 трав. 2024. IEEE, 2024, с. 406–411, doi: [10.1109/ELNANO63394.2024.10756903](https://doi.org/10.1109/ELNANO63394.2024.10756903). (Особистий внесок здобувача: Створення обширної бази даних помилково детектованих QRS комплексів, розробка та тестування нейромережевої архітектури для виявлення помилково виділених кардіоциклів на ЕКГ. Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.)

[2] А. В. Мневєць, Н. Г. Іванушкіна і К. О. Іванько, «Застосування сіамських нейронних мереж для підвищення точності виявлення серцево-судинних захворювань за нестачі тренувальних даних,» Матеріали 5-ї Міжнар. наук.-техн. конф., 28–29 листоп. 2024 р., Нац. техн. ун-т «Харків. політехн. ін-т» [та ін.], Харків, 2024. [Електронний ресурс]. Доступно: <https://repository.kpi.kharkov.ua/handle/KhPI-Press/84178> (Особистий внесок здобувача: Розробка моделі сіамської нейронної мережі для виявлення пізніх потенціалів передсердь та шлуночків, створення бази даних з наявними пізніми потенціалами для тестування розробленої архітектури. Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід,

редакційне доопрацювання рукопису; К. О. Іванько – наукове рецензування та аналіз отриманих результатів.)

[3] O. Shulyak, A. Mnevets та V. Lagutin, “Grouping Training Samples To Increase The Validity Of Recognition Algorithm Solutions”, у 2022 IEEE 41st Int. Conf. Electron. Nanotechnol. (ELNANO), Kyiv, Ukraine, 10–14 жовт. 2022. IEEE, 2022, doi: [10.1109/elnano54667.2022.9927020](https://doi.org/10.1109/elnano54667.2022.9927020). *(Особистий внесок здобувача: Розробка програмного забезпечення для автоматизованого опису кардіоциклів за допомогою системи ізоліній, формування класифікаційного алгоритму на основі міри схожості, та оцінювання результатів класифікації. Внесок співавторів: О. Шуляк – розробка концепції, планування дослідження; В. Лагутін – редакційне доопрацювання рукопису.)*

[4] А. В. Мневець і Н. Г. Іванушкіна, «Виявлення ознак тахіаритмій шляхом вейвлет-аналізу електрокардіосигналів,» Тези доповідей IV Міжнар. наук.-техн. конф. «Автоматизація, електроніка, інформаційно-вимірювальні технології: освіта, наука, практика», м. Харків, Нац. техн. ун-т «Харків. політехн. ін-т», 2022., doi: [10.5281/zenodo.7750728](https://doi.org/10.5281/zenodo.7750728). *(Особистий внесок здобувача: Розробка методів виявлення ознак тахіаритмій на основі вейвлет аналізу електрокардіосигналу, розробка коефіцієнту наявності ознак тахіаритмій. Внесок співавторів: Н. Г. Іванушкіна – постановка проміжних завдань та коригування дослідницької стратегії, наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.)*

[5] А. В. Мневець, Н. Г. Іванушкіна, «Спосіб автоматизованого аналізу електрокардіографічних сигналів», патент України на корисну модель № 161727, Україна, груд. 25, 2025. Дата звернення: 4 січ. 2026 [Онлайн]. Доступно: <https://sis.nipo.gov.ua/uk/search/detail/1891912/> *(Особистий внесок здобувача: Розробка основних положень способу. Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід.)*

ЗМІСТ

ПЕРЕЛІК ОСНОВНИХ УМОВНИХ ПОЗНАК ТА СКОРОЧЕНЬ.....	20
ВСТУП	23
РОЗДІЛ 1 ОСНОВНІ ПРИНЦИПИ ТА ЗАСОБИ ЕЛЕКТРОКАРДІОГРАФІЇ. 31	
1.1 Генезис та реєстрація ЕКГ сигналу	31
1.2 Сучасні електрокардіографічні засоби	32
1.2.1 Структурна схема сучасного електрокардіографа	33
1.2.2 Стаціонарні електрокардіографічні системи	34
1.2.3 Портативні електрокардіографічні системи.....	34
1.2.4 Вбудовані ЕКГ системи.....	35
1.2.5 «Розумні» електрокардіографи.....	35
Висновки до розділу 1	36
РОЗДІЛ 2 ОБГРУНТУВАННЯ ТА РОЗВИТОК ПІДХОДІВ ДО СТВОРЕННЯ МЕТОДІВ РАННЬОЇ ДІАГНОСТИКИ СЕРЦЕВИХ АРИТМІЙ.....	37
2.1 Причини виникнення аритмій та методи аналізу ЕКГ, що використовуються для їх виявлення	37
2.2 Прояви електричної активності серця під час аритмій та сучасні методи їх діагностики.	40
2.3 Прояви електричної активності серця за наявності супутніх патологій серця, що виникають в результаті аритмій	41
2.4 Прояви аритмій на ЕКГ, що мають низькоамплітудні або слабо виражені ознаки та сучасні методи їх діагностування.....	42
Висновки до розділу 2	43
РОЗДІЛ 3 МЕТОДИ ПОПЕРЕДНЬОЇ ОБРОБКИ ЕКГ СИГНАЛІВ	44

3.1 Видалення перешкод з ЕКГ сигналу за допомогою методу усереднення кардіоциклів	44
3.2 Сегментація та видалення зашумлених ділянок ЕКГ сигналів за допомогою нейромережових технологій.....	59
3.3 Стандартизація та реструктуризація ЕКГ сигналу за допомогою нейромережового автоенкодера	70
Висновки до розділу 3	82
РОЗДІЛ 4 МЕТОДИ АВТОМАТИЗОВАНОГО АНАЛІЗУ ЕКГ СИГНАЛІВ .	84
4.1 Методи обробки ЕКГ сигналів на основі класичних алгоритмів.....	84
4.2 Методи машинного навчання для виявлення патологічних ЕКГ сигналів	92
4.3 Нейромережові методи для виявлення аритмій на ЕКГ сигналах	98
Висновки до розділу 4	125
РОЗДІЛ 5 ВИЯВЛЕННЯ НИЗЬКОАМПЛІТУДНИХ КОМПОНЕНТІВ НА ЕКГ СИГНАЛАХ.....	127
5.1 Виявлення низькоамплітудних компонентів на ЕКГ за допомогою сіамських нейронних мереж.....	127
5.2 Виявлення низькоамплітудних проявів аритмій на ЕКГ за допомогою модифікованого Вейвлет перетворення	130
Висновки до розділу 5	150
РОЗДІЛ 6 СИСТЕМА ВИЯВЛЕННЯ СЕРЦЕВИХ АРИТМІЙ.....	151
6.1 Розробка структури та алгоритму функціонування системи для виявлення аритмій серця.....	151
6.2 Алгоритм функціонування та спосіб застосування системи в клінічних умовах.....	158

Висновки до розділу 6	163
ЗАГАЛЬНІ ВИСНОВКИ.....	164
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	167
ДОДАТКИ	190

ПЕРЕЛІК ОСНОВНИХ УМОВНИХ ПОЗНАК ТА СКОРОЧЕНЬ

АЦП – аналого-цифровий перетворювач

БВП – безперервне вейвлет-перетворення; англ. Continuous Wavelet Transform, CWT

Гц –герц

дБ –децибел

ЕКГ – електрокардіографія

ЕКГ ВР – електрокардіографія високого розрізнення

мВ –мілівольт

мкВ –мікровольт

НМ – нейронна мережа

ППП – Пізні потенціали передсердь

ППШ – Пізні потенціали шлуночків

ЦСП – центральний сигнальний процесор

АСС – англ. Accuracy; точність класифікації

AF – англ. Atrial Fibrillation; фібриляція передсердь

CNN – англ. Convolutional Neural Network; згорткова нейронна мережа

DTW – англ. Dynamic Time Warping; алгоритм динамічної трансформації часової шкали

ELU – англ. Exponential Linear Unit; експоненціальний лінійний вузол

EMD – англ. Empirical Mode Decomposition; емпіричне модове розкладання

FA – англ. Factor Analysis; факторний аналіз

FN – англ. False Negative; хибно негативне передбачення

FNR – англ. False Negative Rate; частота хибно негативних передбачень

FP – англ. False Positive; хибно позитивне передбачення

FPR – англ. False Positive Rate; частота хибно позитивних передбачень

fs – англ. sampling frequency; частота дискретизації

HDBSCAN – англ. Hierarchical Density-Based Spatial Clustering of Applications with Noise; Ієрархічна просторова кластеризація на основі щільності з шумом

HRV – англ. Heart Rate Variability; варіабельність серцевого ритму

LR – англ. Logistic Regression; логістична регресія;

NMF – англ. Non-negative Matrix Factorization; невід’ємна матрична факторизація

PCA – англ. Principal Component Analysis; аналіз головних компонент

PLU – англ. Parametric Linear Unit; параметричний лінійний вузол

PReLU – англ. Parametric ReLU; параметрична функція ReLU

PSAECG – англ. P-Signal-Averaged ECG; електрокардіографія з усередненням сигналів за піком P

PVC – англ. Premature Ventricular Contraction; передчасне шлуночкове скорочення

QRS – QRS комплекс; комплекс деполяризації шлуночків

ReLU – англ. Rectified Linear Unit; випрямлений лінійний вузол

RF – англ. Random Forest; випадковий ліс

SAECG – англ. Signal-Averaged ECG; електрокардіографія з усередненням сигналів

SGD – англ. Stochastic Gradient Descent; стохастичний градієнтний спуск

Sigmoid – англ. sigmoid function; сигмоїдна функція

SNR – англ. Signal-to-Noise Ratio; співвідношення сигнал/шум

STFT – англ. Short-Time Fourier Transform; короткочасне перетворення Фур'є

SVD – англ. Singular Value Decomposition; розкладання матриці за сингулярними значеннями

Tanh – англ. hyperbolic tangent; гіперболічний тангенс

TN – англ. True Negative; істинно негативне передбачення

TNR – англ. True Negative Rate; специфічність

TP – англ. True Positive; істинно позитивне передбачення

TPR – англ. True Positive Rate; чутливість

UMAP – англ. Uniform Manifold Approximation and Projection; апроксимація і проєкція однорідного багатовиду

SVM – англ. Support Vector Machine; метод опорних векторів

ВСТУП

Актуальність теми. У світі спостерігається зростання рівня серцево-судинних захворювань, що спричинено поєднанням демографічних та поведінкових факторів. Важливу роль відіграють також надлишкова маса тіла, артеріальна гіпертензія, цукровий діабет і психосоціальний стрес. На поширення серцево-судинних хвороб впливають і екологічні фактори, зокрема забруднення повітря, яке за даними Всесвітньої організації охорони здоров'я щороку спричиняє мільйони передчасних смертей від серцево-судинних захворювань [1]. У країнах з низьким і середнім рівнем доходу ситуація ускладнюється обмеженим доступом до своєчасної діагностики та лікування, відсутністю ефективних програм профілактики та недостатнім рівнем фінансування систем охорони здоров'я. Це підтверджує сталість високого рівня смертності і на початку 2020-х років [2].

У світовій практиці для аналізу цих тенденцій застосовуються масштабні епідеміологічні проекти, наприклад Global Burden of Disease (GBD), спрямовані на всебічну оцінку рівня захворюваності та смертності шляхом аналізу показників поширеності хвороб, частоти летальних випадків, рівня інвалідності та впливу факторів ризику на рівні населення. Дослідження на основі даних GBD прогнозують подальше зростання поширеності серцево-судинних захворювань. Упродовж наступних десятиліть очікується збільшення кількості пацієнтів на 90%, а рівень смертності може зрости з приблизно 20,5 млн у 2025 році до близько 35,6 млн у 2050 році. Ця динаміка підкреслює необхідність посилення глобальних програм профілактики, ранньої діагностики та лікування, що у свою чергу вимагає активного розвитку інноваційних технологій у кардіології.

Своєчасна діагностика серцево-судинної системи є одним із ключових етапів у профілактиці, виявленні та лікуванні серцево-судинних захворювань. Більшість сучасних методів дослідження виконуються неінвазивно, що дозволяє мінімізувати ризики для пацієнта та забезпечити швидке отримання

результатів. Водночас актуальним залишається питання зменшення вартості електрокардіографічних досліджень і автоматизації процесів аналізу, адже саме доступність є визначальним чинником для країн із низьким рівнем доходу.

Науковий прогрес у галузі цифрової медицини, біоінженерії та інтелектуальних інформаційних систем відкриває нові можливості для вдосконалення методів діагностики. Зокрема, розвиток методів автоматизованого аналізу ЕКГ дозволяє виявляти приховані ознаки патологій на ранніх стадіях, підвищуючи ефективність лікування та знижуючи ризик ускладнень. Значні перспективи у цій сфері пов'язані з використанням машинного навчання та глибоких нейронних мереж, які здатні аналізувати великі масиви даних та виявляти складні закономірності, що залишаються непоміченими з використанням стандартного аналізу ЕКГ сигналів.

Тому, **актуальність** створення системи виявлення аритмій серця на основі методів машинного навчання визначається необхідністю вирішення проблеми підвищення точності ранньої діагностики та прогнозування порушень серцевого ритму, які мають високу частоту появи і можуть викликати тяжкі ускладнення, а також недосконалістю технічного та інформаційно-алгоритмічного забезпечення кардіологічних систем для діагностики серцевих аритмій.

Зв'язок роботи з науковими програмами, планами, темами. Напрямок досліджень пов'язаний з науковою тематикою і темами навчального процесу кафедри електронної інженерії факультету електроніки Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського». Дослідження виконувалися у зв'язку з науково-дослідною та дослідно-конструкторською роботою № 0124U002264 «Виявлення небезпечних для життя аритмій методами цифрової обробки електрокардіосигналів» 01.02.2024-01.12.2025, у якій автор брав участь у

визначенні мети дослідження, постановці задачі, аналізі літературних джерел, розробці методів обробки ЕКГ сигналів, формуванні наукових звітів та виступів на конференціях.

Впровадження. Результати роботи над дисертацією, а саме аналіз та розробка нейромережових технологій були впроваджені в рамках педагогічної практики на каф. ЕІ з 18 по 31 грудня 2023р, а саме в процесі проведення занять за розкладом – лекції №12-14 на тему «Нейронні мережі» та лабораторної роботи №5 на тему «Нейронні мережі» в групі ДМ-31мп. А також за результатами досліджень під час роботи над дисертацією, було розроблено «Спосіб автоматизованого аналізу електрокардіографічних сигналів», за яким було зареєстровано патент на корисну модель № 161727.

Об’єкт дослідження: Сигнали електричної активності серця.

Предмет дослідження: Методи обробки та класифікації електрокардіографічних сигналів в нормі та з наявними патологіями серцевих аритмій.

Мета дослідження: Метою дослідження є розробка системи виявлення серцевих аритмій на ЕКГ з використанням методів машинного навчання, в основу якої покладено створення моделей нейронних мереж, вдосконалення методів попередньої обробки сигналів, виділення ознак патологій, зменшення розмірності даних, що забезпечує підвищення точності, чутливості й специфічності, а також пришвидшення автоматизованої діагностики серцевих аритмій в умовах клінічного застосування з обмеженою кількістю ЕКГ сигналів.

Завдання дослідження:

1. Вдосконалити методи попередньої обробки сигналу ЕКГ для виявлення низькоамплітудних ознак патологій серцево-судинної системи, зокрема пізніх потенціалів шлуночків та передсердь.

2. Розробити моделі нейронних мереж для попередньої обробки ЕКГ сигналів з метою підвищення точності виявлення низькоамплітудних ознак на ЕКГ.
3. Розробити моделі нейронних мереж для виявлення аритмій та супутніх патологій на ЕКГ в умовах нестачі тренувальних даних.
4. Вдосконалити методи виявлення патологій на ЕКГ, а також низькоамплітудних ознак за рахунок розробки нових адаптивних функцій активації нейронних мереж.
5. Розробити метод зменшення розмірності ознак на основі нейромережевого автоенкодера для пришвидшення процесу класифікації ЕКГ методами машинного навчання.
6. Розробити алгоритми виділення ознак патологій з ЕКГ сигналу для підвищення точності виявлення аритмій методами машинного навчання та нейронних мереж.
7. Розробити структурну схему та алгоритм функціонування системи виявлення серцевих аритмій на ЕКГ з використанням розроблених методів машинного навчання та моделей нейронних мереж.

Методи дослідження: електрокардіографія високого розрізнення; аналіз головних компонент; програмування на мові Python; графічна візуалізація числових даних; вейвлет аналіз; короткочасне перетворення Фур'є; методи фільтрації сигналу; методи детекції QRS комплексів; методи проектування нейронних мереж; методи скорочення розмірності даних; методи оцінювання точності класифікації; методи оцінювання подібності сигналів; методи обробки сигналів; методи векторкардіографії; статистичні методи; методи роботи з базами даних;

Наукова новизна отриманих результатів:

1. Розроблено комплекс класифікаційних моделей сіамських нейронних мереж, особливістю яких є використання згорткових шарів для паралельної обробки двох типів фрагментів даних: усередненого кардіоциклу з детальними морфологічними характеристиками та ЕКГ-сигналу, що відображає варіабельність серцевого ритму, а також застосування розроблених еталонних векторів ознак патологій для виявлення аритмій, супутніх патологічних станів серцево-судинної системи та пізніх потенціалів шлуночків і передсердь на ЕКГ в умовах обмеженої кількості тренувальних даних.

2. Розроблено нову адаптивну функцію активації, відмінністю якої є нелінійна залежність з властивістю стискаючого відображення, що на основі зменшення проблеми вибуху та згасання градієнтів під час застосування в послідовних шарах нейронних мереж сприяє розпізнаванню низькоамплітудних складових ЕКГ, а також за допомогою запропонованого методу виявлення «надлишкових» шарів призводить до підвищення швидкості роботи НМ без втрати точності.

3. Розроблено метод зменшення розмірності ознак ЕКГ сигналу на основі нейромережевого автоенкодера з використанням шару уваги, залишкових зв'язків та спільних ваг шарів нейронної мережі, що дає можливість створити скорочений вектор, який характеризується високим ступенем стиснення оригінального сигналу та збереженням діагностично значущих ознак.

4. Вдосконалено метод вейвлет-перетворення для аналізу ЕКГ сигналів за допомогою введення косинусної подібності та запропонованої масштабуючої функції, особливістю якої є посилення низькоамплітудних компонентів, що дозволяє підвищити точність виявлення пізніх потенціалів передсердь та шлуночків.

Практичне значення отриманих результатів:

1. На основі запропонованих методів попередньої обробки та удосконаленого методу усереднення кардіоциклів розроблено алгоритмічне забезпечення системи, що дозволяє підвищити точність автоматизованого виявлення низькоамплітудних ознак патологій на ЕКГ, зокрема пізніх потенціалів шлуночків та передсердь (на 10-30% в результаті оцінювання показників подібності з еталонними пізніми потенціалами з амплітудою 5 мкВ).
2. Розроблено алгоритмічне забезпечення для системи виявлення аритмій на основі кластерного аналізу ЕКГ параметрів без вчителя, що дозволяє виявляти приховані групи ризику розвитку серцевої недостатності у пацієнтів та небезпечні для життя стани функціонування серця.
3. Розроблено підхід до використання згорткових нейронних мереж для виявлення помилково детектованих або зашумлених кардіоциклів, що дає можливість видаляти спотворені фрагменти ЕКГ сигналу та підвищувати точність виявлення пізніх потенціалів шлуночків і передсердь на 19% на основі аналізу показника подібності динамічної трансформації часової шкали в порівнянні з використанням класичного ЕКГ детектора.
4. Запропоновано алгоритми виділення діагностично значущих ознак із використанням послідовності методів попередньої обробки ЕКГ сигналів, які ґрунтуються на аналізі коливальних процесів кардіоциклів за допомогою вейвлет-перетворення, що дозволяє забезпечити виявлення тахіаритмій і патологічних форм QRS-комплексів.
5. Розроблено структуру, алгоритм функціонування та спосіб застосування в клінічних умовах системи виявлення серцевих аритмій на ЕКГ, особливістю якої є використання розроблених методів машинного навчання, попередньої обробки сигналів та моделей нейронних мереж, що дає можливість ранньої діагностики аритмій та супутніх патологій.

Особистий внесок здобувача. Дисертаційна робота є узагальненням результатів досліджень опублікованих у працях [3-13]. У наукових працях, що виконано у співавторстві здобувачеві належить: у [3] – розробка архітектури мережевого автоенкодера, та тестування його роботи на основі публічних наборів даних; у [4] – розробка та тестування моделі сіамської нейронної мережі для виявлення серцевих аритмій та супровідних патологій, розробка вектора ознак патологій, формування тренувального набору; у [5] – розробка та тестування методу попередньої обробки ЕКГ сигналів для виявлення пізніх потенціалів передсердь та шлуночків, а також створення набору даних для тестування методу; у [6] – модифікація методу вейвлет перетворення для ЕКГ сигналу, а також розробка методу застосування модифікованого вейвлет перетворення для виявлення пізніх потенціалів передсердь та шлуночків; у [7] – аналіз існуючих функцій активації і розробка власної функції активації для зменшення впливу явищ вибуху та згасання градієнтів, а також розробка методу оцінювання надлишковості шарів нейронних мереж на основі адаптивних функцій активації; у [8] – Обрахунок ЕКГ параметрів, та попередня обробка сигналів з набору даних об'ємом 14863 спостережень; у [9] – створення обширної бази даних помилково детектованих QRS комплексів, розробка та тестування нейромережевої архітектури для виявлення помилково виділених кардіоциклів на ЕКГ; у [10] – розробка моделі сіамської нейронної мережі для виявлення пізніх потенціалів передсердь та шлуночків, створення бази даних з наявними пізніми потенціалами для тестування розробленої архітектури; у [11] – розробка програмного забезпечення для автоматизованого опису кардіоциклів за допомогою системи ізоліній, формування класифікаційного алгоритму на основі міри схожості, та оцінювання результатів класифікації; у [12] – розробка методів виявлення ознак тахіаритмій на основі вейвлет аналізу електрокардіосигналу, розробка коефіцієнту наявності ознак тахіаритмій; у [13] – Розробка основних положень способу;

Апробація результатів дисертації. Наукові результати, що наведено в дисертації доповідалися на IV та V міжнародних науково-технічних конференціях «Автоматизація, електроніка, інформаційно-вимірювальні технології: освіта, наука, практика» (м. Харків, 2022 р., 2024 р.), а також на 41 та 42 Міжнародних науково-технічних конференціях IEEE «Electronics and Nanotechnology» (ELNANO-2022, ELNANO-2024, м. Київ), також за результатами досліджень було отримано патент України на корисну модель № 161727.

Публікації. За результатами досліджень опубліковано 11 наукових праць, у тому числі 4 статті у наукових фахових виданнях України з одним співавтором, 1 стаття у фаховому виданні України категорії «А», що індексується у базі Web of Science Core Collection, 1 стаття у періодичному науковому фаховому виданні, що індексується у базах Scopus та/або Web of Science Core Collection кuartилію (Q2), у 4 збірниках наукових праць міжнародних конференцій, а також в 1 патенті України на корисну модель.

Структура й обсяг роботи. Дисертація включає вступ, 6 розділів, висновки та список використаних джерел, що налічує 144 найменувань. У роботі наведено 50 ілюстрацій та 18 таблиць. Загальний обсяг дисертації становить 166 сторінок тексту.

Автор висловлює велику подяку к.т.н., доценту каф. ЕІ, ФЕЛ, КПІ Іванушкіній Наталії Георгіївні за наукові консультації, к.т.н., доценту каф. ЕІ, ФЕЛ, КПІ Іванько Катерині Олегівні за допомогу в проведенні досліджень, к.мед.н., провідному науковому співробітнику Інституту кібернетики ім. В.М. Глушкова НАН України Чайковському Іллі Анатолійовичу за залучення до міжнародних наукових робіт, а також усьому колективу кафедри електронної інженерії ФЕЛ, КПІ за всебічну підтримку та сприятливу наукову атмосферу.

РОЗДІЛ 1 ОСНОВНІ ПРИНЦИПИ ТА ЗАСОБИ ЕЛЕКТРОКАРДІОГРАФІЇ

1.1 Генезис та реєстрація ЕКГ сигналу

Електрокардіографія (ЕКГ) – це метод реєстрації електричної активності серця, що виникає внаслідок збудження та відновлення (деполяризації і реполяризації) клітин міокарда [14]. Форма ЕКГ сигналів, зареєстрованих за допомогою 3-х стандартних відведень відповідно до трикутника Ейнтховена [15] наведена на рис. 1.1. а.




Рис. 1.1. Приклад електрокардіографічного сигналу (а) та фрагмент кардіоциклу з виділенням характерних піків і інтервалів (б)

На типовому кардіоциклі (рис. 1.1. б) можна виділити зубець Р (деполяризація передсердь), комплекс QRS (деполяризація шлуночків), зубець Т (реполяризація шлуночків), а також інтервали PR, QT і сегмент ST, які несуть діагностичну інформацію про послідовність та тривалість електрофізіологічних процесів у міокарді.

Для детального клінічного аналізу застосовується 12-канальна ЕКГ, яка включає шість відведень кінцівок і шість грудних, що дозволяє оцінювати серце у фронтальній, горизонтальній та сагітальній площинах [16]. У наукових дослідженнях використовується система відведень Франка, яка належить до

векторкардіографії [17]. Вона дозволяє оцінювати тривимірний електричний вектор серця у трьох взаємно перпендикулярних площинах і візуалізувати петлі деполяризації та реполяризації. Перетворення сигналу ECG([12×1]) у систему відведень Франка можна реалізувати за допомогою матриці P([12×3]):

$$XYZ_{[3 \times 1]} = ECG_{[12 \times 1]} \cdot P_{[12 \times 3]},$$

Проекції X(t), Y(t), Z(t) дозволяють обчислити результуючий вектор R(t).

Електрокардіографія високого розрізнення (ЕКГ ВР) – це метод, що передбачає реєстрацію електричних потенціалів серця з високою частотою дискретизації та підвищеним співвідношенням сигнал/шум. Мета даного методу полягає у виявленні низькоамплітудних проявів патологій, наприклад пізніх потенціалів шлуночків (ППШ) та передсердь (ППП), які відображають зони сповільненого проведення у міокарді. Розвиток методів вимірювання пізніх потенціалів передсердь і шлуночків є актуальною технічною проблемою, оскільки забезпечує можливість виявлення електрофізіологічних ознак шлуночкових та передсердних тахіаритмій на ранніх стадіях [18].

Оскільки одиничний кардіоцикл містить значну кількість шумів, для підвищення точності застосовується метод усереднення кардіоциклів. Спочатку здійснюється виділення опорної точки, найчастіше піку R у складі QRS-комплексу, після чого окремі цикли синхронізуються за цією точкою. Далі виконується усереднення 200-300 кардіоциклів, що забезпечує зниження рівня шуму у $\sqrt{N}$ разів, де N – кількість кардіоциклів, що усереднюються. У результаті формується усереднений кардіоцикл, який відображає реальну електричну активність міокарда з високою точністю.

1.2 Сучасні електрокардіографічні засоби

Сьогодні існує велика кількість електрокардіографів, які розрізняються за типом застосування, медичним призначенням, та технічною реалізацією.

1.2.1 Структурна схема сучасного електрокардіографа

На рис. 1.2. зображено структурну схему сучасного приладу для реєстрації ЕКГ [19].




Рис. 1.2. Структурна схема електрокардіографа

Сучасний електрокардіограф (рис.1.2) має модульну структуру, що забезпечує повний цикл обробки сигналу від реєстрації до відображення результатів. Сигнал з електродів спочатку проходить через блок захисту від розрядів та дефібриляції, після чого потрапляє до інструментального підсилювача, який забезпечує високе підсилення та ефективно придушує синфазні перешкоди. Мультиплексор дозволяє обробляти багато відведень через обмежену кількість каналів АЦП, зберігаючи необхідну точність оцифрування сигналу. Аналого-цифровий перетворювач перетворює сигнал у цифровий код, а цифровий сигнальний процесор виконує фільтрацію, розраховує діагностичні параметри та готує дані для відображення.

Для зберігання інформації використовується енергонезалежна пам'ять. До складу апарату входять також детектор від'єднання електрода, детектор імпульсів кардіостимулятора, дисплей та панель керування. Для зовнішнього зв'язку використовуються дротові та бездротові інтерфейси.

1.2.2 Стаціонарні електрокардіографічні системи

Стаціонарні ЕКГ системи призначені для медичних закладів. Вони мають багатоканальний вхід для реєстрації 12 стандартних відведень. Обчислювальний блок реалізований на мікроконтролерах або системах на чіпі (ARM, RISC-V) [20]. Також подібні системи дозволяють реалізувати спеціалізовані протоколи передачі даних, наприклад HL7 [21]. Відповідно до стандарту IEC 60601-1 [22], застосовується подвійна або посилена ізоляція між мережевими колами та пацієнтом.

Елементна база включає спеціалізовані AFE-чіпи (наприклад, Analog Devices ADAS1000, Texas Instruments ADS1298) [23], що інтегрують інструментальні підсилювачі, АЦП та додаткові функції. Системи відповідають стандартам IEC 60601-2-25 (діагностичні ЕКГ), IEC 60601-2-27 (монітори ЕКГ), а також вимогам електромагнітної сумісності згідно з IEC 60601-1-2 [24]. Інтеграція в інфраструктуру лікарні здійснюється через стандарти IEEE 11073 та DICOM [25].

1.2.3 Портативні електрокардіографічні системи

Портативні ЕКГ системи призначені для тривалого моніторингу поза лікарнею та включають холтерівські монітори, та смартфон-залежні пристрої. Вони характеризуються мінімальною кількістю каналів (1-3) та оптимізованою схемотехнікою з низьким енергоспоживанням. Апаратна реалізація базується на спеціалізованих чіпах (Analog Devices AD8232, TI ADS1292/1293) [26, 27], що інтегрують підсилювачі, фільтри, АЦП та функції попередньої обробки сигналів. Обробка сигналу виконується мікроконтролерами з низьким енергоспоживанням (AVR, PIC, ESP32, STM32) [28].

Зв'язок реалізований через Bluetooth Low Energy, Wi-Fi або локальне зберігання даних [29]. Класичні холтерівські монітори записують дані у внутрішню пам'ять, тоді як сучасні системи використовують телеметрію для

передачі епізодів на центральні станції. Пристрої типу AliveCor KardiaMobile, CardioSecur Active [30, 31] реалізують спрощену схему з передачею даних на смартфон для подальшого аналізу.

1.2.4 Вбудовані ЕКГ системи

Вбудовані електрокардіографічні системи інтегруються в побутові гаджети та імплантовані пристрої. Смарт-годинники (Apple Watch Series 4 [32], Samsung Galaxy Watch [33]) реалізують одноканальну ЕКГ за допомогою двох електродів з частотою дискретизації 256 Гц. Технології ear-ECG досліджуються для моніторингу через навушники [34]. Імплантовані системи (кардіостимулятори, монітори типу Medtronic Reveal LINQ [35]) характеризуються низьким енергоспоживанням та спеціалізованими інтерфейсами зв'язку. Вони відповідають вимогам біосумісності та стійкості до зовнішніх впливів.

1.2.5 «Розумні» електрокардіографи

Сучасні «розумні» ЕКГ системи поєднують традиційну апаратну базу з технологіями штучного інтелекту та інтернету речей (Internet of Things, IoT). Реалізація включає як локальну обробку на пристроях, так і хмарні рішення (наприклад, AliveCor KardiaAI [36, 37]).

Технічна реалізація вимагає продуктивних обчислювальних модулів, надійних каналів зв'язку з шифруванням [38] та потужних систем зберігання даних. Такі системи забезпечують цілодобовий моніторинг, швидке виявлення аритмій та масштабованість обслуговування пацієнтів.

Висновки до розділу 1

На основі огляду сучасних технологій отримання ЕКГ сигналів можна визначити наступне:

1. Електрокардіографія є фундаментальним методом діагностики, що базується на реєстрації сигналів електричної активності серця, які виникають внаслідок скоординованої роботи його провідної системи.

2. Сучасні технології реєстрації ЕКГ сигналів пройшли значний шлях розвитку від стаціонарних 12-канальних апаратів до портативних холтер моніторів, вбудованих систем у смарт-годинниках та навіть імплантованих пристроїв. Будова сучасних електрокардіографів базується на комбінованих схемотехнічних рішеннях, електронні компоненти сигнального тракту яких мають нанорозміри та реалізують багатофункціональні системи на чіпі, що дозволяє не лише точніше фіксувати сигнал, але й виконувати його попередній аналіз, та швидше інтегруватися в медичну інфраструктуру.

3. Особливу перспективу відкривають методи, спрямовані на підвищення інформативності ЕКГ, такі як електрокардіографія високого розрізнення та векторкардіографія. Математичні методи дають можливість представляти багатоканальний сигнал з високим відношенням сигнал/шум у різних системах відведень, зберігаючи його діагностичну цінність.

4. Електрокардіографія залишається фундаментальним інструментом діагностики, однак має суттєві обмеження, пов'язані з чутливістю до артефактів, індивідуальною мінливістю пацієнтів та складністю інтерпретації складних випадків. Для подолання цих недоліків необхідно виконати розробку спеціалізованих методів для попередньої обробки сигналів, покращення методів машинного навчання та вдосконалення адаптивних алгоритмів виявлення ознак патологій.

РОЗДІЛ 2 ОБГРУНТУВАННЯ ТА РОЗВИТОК ПІДХОДІВ ДО СТВОРЕННЯ МЕТОДІВ РАННЬОЇ ДІАГНОСТИКИ СЕРЦЕВИХ АРИТМІЙ

2.1 Причини виникнення аритмій та методи аналізу ЕКГ, що використовуються для їх виявлення

Аритмії можуть виникати у будь-якому віці, та мати як епізодичний, так і хронічний характер [39, 40]. Сучасна діагностика аритмій на ЕКГ використовує такі основні методи аналізу: часові, частотні, нелінійні, векторні, морфологічні та комбіновані.

Часові методи, найпоширеніші та найпростіші для інтерпретації, базуються на вимірюванні інтервалів (PR, QRS, QT, RR) та оцінці варіабельності серцевого ритму [40, 41]. Ключові показники включають: SDNN (Standard Deviation of Normal-to-Normal intervals, стандартне відхилення NN інтервалів), RMSSD (Root Mean Square of Successive Differences, квадратний корінь із середнього квадрата різниці послідовних інтервалів), NN50 та pNN50 (абсолютна кількість та відсоток пар інтервалів, що відрізняються більш ніж на 50 мс) [42]. Геометричні індикатори, такі як HTI (Heart rate variability Triangle Index, індекс трикутника BCP) та TINN (Triangular Interpolation of NN interval N histogram, трикутна інтерполяція гістограми) стійкі до викидів [43], а для довготривалих сигналів використовують SDANN (Standard Deviation of the Average NN intervals, стандартне відхилення середніх значень NN інтервалів) та SDNNi (Standard Deviation of NN intervals, індекс стандартного відхилення) [42]. Динамічні реакції оцінюють за допомогою показника турбулентності ритму (HRT, Heart Rate Turbulence) [44]. Для підвищення стійкості застосовують нормовані індекси CVNN (Coefficient of Variation of NN intervals, Коефіцієнт варіації NN інтервалів), CVSD (Coefficient of Variation of SD, Коефіцієнт варіації послідовних різниць), MAD (Mean Absolute Deviation, Середнє абсолютне

відхилення), IQR (Inter Quartile Range, Міжквартильний діапазон) [45]. Точність аналізу вимагає ретельної попередньої обробки сигналу та детекції опорних точок (P, Q, R, S, T).

Частотні методи перетворюють часові дані у частотну область, відображаючи регуляторні впливи нервової системи серця. В аналізі варіабельності ритму виділяють декілька діапазонів частот. HF (high frequency, високі частоти) (0.15-0.4 Гц) відображають вагусний дихальний контроль, LF (low frequency, низькі частоти) (0.04-0.15 Гц) - барорефлекторну активність, VLF (very low frequency, ультранизькі частоти) (0.01-0.04 Гц) - метаболічні впливи. Використовують перетворення Фур'є, авторегресійні моделі, періодограми Ломба-Скаргла та вейвлет-розклади [46]. Для аналізу форми ЕКГ сигналу застосовують спектральні оцінювачі, що дозволяє виявляти частотні ознаки патологій.

Нелінійні методи оцінюють складність і структуру регуляції ритму. Кореляційна ритмографія [47] візуалізує короткострокові та довгострокові флуктуації. Фрактальний аналіз виявляє масштабну організацію ритму, а ентропійні методи вимірюють ступінь його регулярності. Ці підходи дозволяють оцінити адаптаційні резерви серцево-судинної системи.

Векторні методи розглядають електричну активність серця в тривимірному просторі. Векторкардіографія, що ґрунтується на перетворенні ЕКГ у проекції на вісі X, Y, Z, дозволяє аналізувати петлі QRS та T. Ключовим параметром є просторовий кут QRS-T, збільшення якого свідчить про підвищений ризик аритмій [17]. Цей підхід підвищує чутливість до патологічних змін порівняно зі стандартною ЕКГ.

Морфологічні методи зосереджені на безпосередньому аналізі форми кардіоциклу для розпізнавання патологічних патернів. Вони дозволяють ідентифікувати ішемічні зміни ST-T, фрагментацію QRS, синдроми Вольфа-Паркінсона-Уайта (СВПУ) та Бругада. Автоматичне виявлення морфологічних

характеристик є складною задачею через варіабельність сигналу, що потребує застосування алгоритмічних методів та машинного навчання.

Комбіновані методи інтегрують різні типи показників для підвищення чутливості та специфічності діагностики. Наприклад, стратифікація ризику шлуночкових аритмій після інфаркту міокарда може включати морфологічні маркери реполяризації, векторні параметри (кут QRS-T) та метрики вегетативної регуляції (SDNN, RMSSD, LF/HF, ентропія). Таке поєднання дає більш точний прогностичний результат.

Хоча описані методи ефективні для виявлення одиничних патологій, розробка автоматизованих систем детекції аритмій є значно складнішою. Часові методи чутливі до якості попередньої обробки та артефактів. Частотні підходи вимагають складної інтерпретації. Нелінійні методи залежать від довжини сигналу та параметрів аналізу. Векторні підходи спираються на коректність перетворень і розташування електродів. Морфологічні методи уразливі до варіабельності форми хвиль і можуть давати хибнопозитивні результати. Комбіновані підходи покликані компенсувати слабкі місця окремих методів, але потребують ретельного налаштування для уникнення впливу корельованих ознак та забезпечення узгодженості між різними етапами аналізу.

Отже, для ефективного багатокласового аналізу необхідні підходи, здатні інтегрувати ознаки з різних рівнів сигналу. Перспективними є методи машинного навчання, які дозволяють створювати єдиний класифікаційний простір. Однак класичні алгоритми машинного навчання вимагають великих розмічених наборів даних, що обумовлює потребу у подальшому вдосконаленні методів для роботи в умовах обмеженої кількості тренувальних даних.

2.2 Прояви електричної активності серця під час аритмій та сучасні методи їх діагностики.

У медичній теорії та практиці виконується класифікація великої кількості ритмічних порушень, які відрізняються за механізмами виникнення та клінічними проявами. Тому для діагностики аритмій важливо використовувати систему класифікації, яка здатна точно описувати особливості патологічних станів [48].

Для проведення досліджень в межах даної роботи були обрані основні типи аритмій, які найчастіше зустрічаються у клінічній практиці та потребують чіткого й ефективного диференціювання.

Аритмії серця прийнято класифікувати за механізмами їх виникнення. Одним з таких механізмів є порушення автоматизму синусового вузла, до яких відносять синусову аритмію, синусову тахікардію та синусову брадикардію. Окрему категорію становлять екстрасистолії, що являють собою передчасні позачергові скорочення серця, серед яких виділяють передсердну та шлуночкову екстрасистолії, а також бігемінію. До іншої групи належать надшлуночкові аритмії, що виникають у передсердях або в атріовентрикулярному вузлі. Важливе місце серед них займає надшлуночкова тахікардія, зокрема її пароксизмальна форма, для якої характерний раптовий початок і припинення нападу прискореного серцебиття. Важливе місце займають порушення провідності, які виникають в атріовентрикулярному вузлі чи системі пучка Гіса, зокрема AV-блокади та блокади ніжок пучка Гіса. Окрему категорію складають синдроми передчасного збудження шлуночків, зокрема синдром Вольфа-Паркінсона-Уайта, що характеризується наявністю додаткових провідних шляхів між передсердями та шлуночками. Нарешті, виділяють порушення реполяризації, які відображаються у зміні тривалості часових показників електрокардіограми, зокрема інтервалів PR та QT.

2.3 Прояви електричної активності серця за наявності супутніх патологій серця, що виникають в результаті аритмій

Для якісного виявлення патологій серцево-судинної системи важливим є виявлення не лише аритмій, а й станів, що створюють умови для їх виникнення. Аналіз супровідних патологій має практичне значення, оскільки допомагає пояснити походження порушень ритму та прогнозувати їх повторення [49].

Окремою категорією є гіпертрофічні зміни, що виникають від хронічного перевантаження серця та проявляються збільшенням маси міокарда і характерними значеннями амплітуд на ЕКГ у разі гіпертрофії правого чи лівого шлуночків. Такі зміни створюють передумови для ектопічної активності. Важливими також є ознаки перевантаження передсердь, які на ЕКГ можуть проявлятися малопомітними змінами конфігурації зубця Р та підвищують ризик передсердних аритмій. Ішемічні зміни міокарда можуть мати неспецифічний характер або локалізуватися у антеролатеральних, нижніх, інферолатеральних чи антеросептальних відведеннях та часто залишаються нерозпізнаними через слабку вираженість ознак. До більш виражених структурних уражень належать інфарктні зміни, що класифікуються за локалізацією, та аневризматичні зміни, які розвиваються після інфаркту і характеризуються стійким підвищенням сегмента ST. Крім того, виділяють пізні потенціали передсердь та шлуночків, які є маркерами електричної нестабільності та зазвичай невидимі на стандартній ЕКГ. Патології, що досліджувались, можна розділити на гіпертрофічні, пов'язані з перевантаженням передсердь, ішемічні, інфарктні, аневризматичні та наявність пізніх потенціалів, що потребують використання та вдосконалення сучасних методів аналізу. [48, 49, 50, 51].

2.4 Прояви аритмій на ЕКГ, що мають низькоамплітудні або слабо виражені ознаки та сучасні методи їх діагностування.

Деякі серцеві патології мають низькоамплітудні або слабо виражені ознаки на ЕКГ, через що навіть досвідченому лікарю буває складно їх розпізнати, особливо за наявності шумів та артефактів.

Слабо виражені зміни під час аритмій (рис. 2.1) часто спостерігаються у разі блокади AV-вузла першого ступеня та подовженні PR і QT інтервалів, коли основні прояви обмежуються зміною тривалості проведення імпульсу або незначними варіаціями зубця Т. Блокади лівої передньої та задньої гілок пучка Гіса проявляються переважно відхиленням електричної вісі серця. Неспецифічні ішемічні зміни ST-T під час аневризми шлуночка часто мають мінімальну вираженість і важко диференціюються на стандартній ЕКГ. Ознаки перевантаження передсердь у вигляді змін зубця Р також можуть бути ледь помітними. Особливо складними для виявлення є пізні потенціали передсердь та шлуночків, які мають надзвичайно низьку амплітуду та потребують спеціальної обробки сигналу, але мають високу прогностичну значимість [50, 51].




Рис. 2.1. Низькоамплітудні та малопомітні ознаки патологій на ЕКГ: а – подовжений PR інтервал, б – подовжений QT інтервал, в – комплекс rS у відведенні aVF, г – вираженіші зубці q та R у відведенні I, д – підвищення сегмента ST з атипичною низькоамплітудною хвилею Т, е – ППШ у відведенні V1, ж – розщеплений зубець Р, з – високий і загострений зубець Р

Висновки до розділу 2

На основі проведеного огляду методів діагностики стану серцево-судинної системи в нормі та у разі виникнення патологічних процесів встановлено:

1. Сучасна діагностика серцевих аритмій та супутніх патологій ґрунтується на комплексі методів аналізу ЕКГ, що включає часові, частотні, нелінійні, векторні, морфологічні та комбіновані підходи. Кожен з цих методів має унікальні діагностичні можливості для виявлення специфічних відхилень на ЕКГ, які відображають як структурні зміни міокарда та порушення провідної системи так і електролітні розлади та вроджені вади серця.

2. Основним викликом у сучасній кардіодіагностиці є значна варіабельність клінічних проявів патологій. Багато з них, особливо на ранніх стадіях, мають низькоамплітудні або слабо виражені ознаки на ЕКГ, що ускладнює їх надійне виявлення традиційними методами. До таких складних для діагностики станів належать початкові ішемічні зміни, пізні потенціали, окремі типи блокад та ранні прояви гіпертрофії камер серця.

3. Існуючі методи аналізу ЕКГ сигналів, хоча й ефективні для виявлення окремих патологій, але демонструють обмежену ефективність багатокласової діагностики, коли необхідно одночасно ідентифікувати кілька типів порушень серцевої діяльності. Складність інтеграції різних рівнів аналізу, чутливість до якості сигналу та необхідність адаптації до варіабельності ЕКГ даних обумовлюють потребу в розробці нових підходів.

4. Перспективним напрямом подолання цих обмежень є методи машинного навчання, які здатні інтегрувати часові, частотні, та морфологічні характеристики ЕКГ в єдиний класифікаційний простір. Такі підходи можуть забезпечити більш точну та надійну багатокласову діагностику, особливо для виявлення слабо виражених патологій, своєчасне виявлення яких має велике клінічне значення.

РОЗДІЛ 3 МЕТОДИ ПОПЕРЕДНЬОЇ ОБРОБКИ ЕКГ СИГНАЛІВ

3.1 Видалення перешкод з ЕКГ сигналу за допомогою методу усереднення кардіоциклів

Електрокардіографічний сигнал, що реєструється на поверхні тіла, через малу амплітуду дуже вразливий до численних джерел спотворень [52]. Перешкоди можуть виникати на межі електрод-шкіра, через недосконалість аналогового тракту приладу, внаслідок м'язового тремору або наявності імплантованих пристроїв, а також від зовнішніх електричних полів. Наявність таких перешкод не лише маскує діагностичні ознаки, але й може створювати патерни, помилково інтерпретовані як патології. На рис. 3.1. представлено частотний внесок різних типів перешкод, що можуть спотворювати ЕКГ сигнал.




Рис. 3.1. Частотна характеристика шумових перешкод на ЕКГ

Ефективне пригнічення перешкод є критично важливим етапом попередньої обробки, оскільки безпосередньо впливає на точність всіх подальших етапів аналізу. Якісна фільтрація забезпечує коректну сегментацію, детекцію комплексів QRS, розпізнавання хвиль Р і Т, а також обчислення варіабельності серцевого ритму.

Аналіз ранніх патологічних змін міокарда потребує виявлення низькоамплітудних компонентів ЕКГ, таких як пізні потенціали [53].

Для проведення дослідження був змодельований штучний сигнал ЕКГ (рис. 3.2) з наявними пізніми потенціалами, нерегулярними включеннями, та іншими перешкодами, що можуть вносити негативний вклад в розрахунок усередненого кардіоциклу.




Рис. 3.2. Моделювання тестового ЕКГ сигналу: а – склад модельного сигналу, б – результуючий модельний сигнал [5]

Тривалість сигналів пізніх потенціалів дорівнювала 28 мілісекунд, та мала наступний частотний склад:

$$\text{ПП}(t) = a_1 \sin(2\pi f_1 t) + a_2 \sin(2\pi f_2 t) + a_3 \sin(2\pi f_3 t),$$

$$\text{де } f_1 - 78 \text{ Гц}, f_2 - 116 \text{ Гц}, f_3 - 102 \text{ Гц}, a_1 : a_2 : a_3 = 5 : 12 : 2.$$

Дані частотні характеристики пізніх потенціалів було обрано з урахуванням електрофізіологічних особливостей порушення роботи провідної системи серця людини [54]. Також на модельний сигнал накладено Гаусівський шум, таким чином, що результуюче відношення сигнал/шум дорівнює 40 дБ.

Додатково на модельний ЕКГ сигнал накладено нерегулярну високоамплітудну компоненту, яка може імітувати прояви артефакту руху, екстрасистоли, стимуляцію водія ритму, або іншого подібного артефакту на ЕКГ, що може спричинити негативний вклад в усереднений сигнал. Форма даної компоненти описується згідно моделі нелінійного спотворення, що є

окремим випадком підходів Вольтерри та Гаммерштайна, у яких вихід сигналу описується як сума лінійної та нелінійної частин [55]:

$$y = x + \left(x^{\frac{1}{10}}\right),$$

де x – вісь часу $\in [0:1]$, y – значення амплітуди компоненти.

На модельному сигналі, тривалість нерегулярної компоненти дорівнює 70 мс. На рис. 3.2. б видно, як нерегулярна компонента накладається на ППП в другому кардіоциклі, що спотворює форму сигналу, та може спричинити негативний вплив в результуючий усереднений сигнал.

До отриманого сигналу з наявним високочастотним шумом, пізними потенціалами, дрейфом ізолінії та високоамплітудними нерегулярними включеннями було застосовано класичні методи попередньої обробки сигналу, а саме видалення дрейфу базової лінії (0,15-0,3 Гц); видалення артефакту дихання (0,25-0,5 Гц) [16]; видалення синфазної перешкоди електромережі (50, 60 Гц) та другої гармоніки (100, 120 Гц) [56]; видалення високочастотних компонентів, частотний склад яких лежить за межами частотного діапазону корисного сигналу (150 Гц);

Розбиття ЕКГ сигналу на окремі кардіоцикли проводилось у декілька етапів (рис. 3.3). На першому етапі здійснювалось виявлення положення R-піків, після чого виконувались поділ ЕКГ на окремі кардіоцикли та формування наборів кардіоциклів (епох). Для виявлення R піків було обрано детектор «kalidas2017» [57]. Для визначення часових меж для виділення кардіоциклу з ЕКГ сигналу було проаналізовано розподіл RR-інтервалів, і на основі значення моди цього розподілу оцінено оптимальні інтервали до та після R-піку, необхідні для коректної сегментації сигналу зі збереженням діагностично значущих ознак. Для тестового сигналу, початок кардіоциклу встановлювався на 0,3 секунди раніше часової мітки піку R. Кінець кардіоциклу, навпаки встановлювався на 0,5 секунди після виявленого піку R.




Рис. 3.3. Накопичення виявлених кардіоциклів модельного ЕКГ сигналу з наявністю та відсутністю перешкод: а – кардіоцикли сигналу без перешкод, б – кардіоцикли з наявними перешкодами [5]

На рис. 3.3. а можна побачити, що під час сегментації чистого ЕКГ сигналу, було отримано чітко накладені один на одного кардіоцикли. В результаті наявності варіабельності ритму можна спостерігати відхилення Р, Т зубців від центрального положення, і як наслідок, розбіжність в положенні ППІІ та ППІІІ. Причому, розбіжність ППІІІ менша, через те, що усереднення ведеться за R піком (Signal-Averaged ECG, SAECG). Для зменшення розбіжності положення ППІІІ було застосовано усереднення за Р піком (P-Signal-Averaged ECG, PSAECG).

Після накладання шуму, та нерегулярної високоамплітудної компоненти (рис. 3.3. б), точність виділення кардіоциклів значно зменшилась. По-перше, попередня обробка сигналу не дозволила значно зменшити рівень Гаусівського шуму, адже амплітуда та частотний склад такого шуму може накладатися на корисний сигнал ППІІІ та ППІІ. По-друге, високоамплітудна нерегулярна компонента, що була додана до сигналу, не може бути ефективно видалена класичними методами попередньої обробки через частотний склад. Наявність даних похибок призвела до помилкового виявлення низькоамплітудних складових. В свою чергу, реальний R зубець, який накладається на усереднений кардіоцикл в помилковому місті, сам стає перешкодою.

Для зниження негативного впливу нерегулярних компонентів на корисний сигнал, покращення існуючих методів усереднення кардіоциклів і можливості подальшого застосування підходів до виділення пізніх потенціалів, запропоновано вдосконалення методу усереднення, блок-схему якого наведено на рис.3.4.




Рис. 3.4. Блок-схема методу усереднення кардіоциклів на основі виділення головних векторів SVD розкладу матриць епох кардіоциклів [5]

Принцип роботи методу полягає у послідовній обробці сигналу ЕКГ. Спочатку з оригінального сигналу виділяється близько 300 кардіоциклів. Ця сукупність циклів розбивається на епохи, кожна з яких містить по n кардіоциклів, причому виділення епох відбувається з перекриттям у m кардіоциклів між попередньою та наступною епохами. Для кожної такої епохи формується матриця, де стовпці складаються з відліків окремих кардіоциклів. Отримана матриця обробляється методом лінійного розкладання, зокрема сингулярному розкладанню (SVD). На завершальному етапі найбільш інформативні компоненти з кожної епохи, які представлено правими сингулярними векторами з найбільшими сингулярними значеннями, усереднюються, що дозволяє сформувати результуючий вектор, який являє собою усереднений кардіоцикл із значно зменшеним впливом шумів та артефактів.

Цей метод зменшує вплив варіабельності ритму та випадкових артефактів, дозволяючи аналізувати дані більш якісно. Для обробки може використовуватись різні алгоритми матричної факторизації, наприклад аналіз

головних компонент (PCA), невід'ємна матрична факторизація (NMF), факторний аналіз (FA).

Запропонований метод орієнтований на виділення низькоамплітудних регулярних компонентів, таких як пізні потенціали, саме в першому сингулярному векторі (головній компоненті). Це дозволяє уникнути впливу менш регулярних шумових компонентів, хоча в деяких дослідженнях пізні потенціали виявляються у другому чи третьому сингулярному векторі [58]. Для максимізації ймовірності попадання цільових компонентів у перший вектор використовується поділ на епохи кардіоциклів. Чутливість методу регулюється через вибір розміру епохи (n) та ступеня перекриття (m), що забезпечує надійність виявлення.

На рис. 3.5. розглянуто виділення усередненого кардіоциклу з пізніми потенціалами різними методами. Результати усереднення порівнювались з еталоном (рис. 3.5. б).




Рис. 3.5. Побудова усередненого кардіоциклу різними методами: а – кардіоцикли штучного ЕКГ сигналу з перешкодами, б – еталонний кардіоцикл з наявними пізніми потенціалами, в – головний вектор SVD розкладу однієї епохи, г – усереднений кардіоцикл, д – усереднений кардіоцикл побудований на основі запропонованого методу, 0 – ППШ на еталонному кардіоциклі, 1, 2, 3 – артефакти на усередненому кардіоциклі, 4, 5, 6 – артефакти на головному векторі однієї епохи, 7 – ППШ для усереднення за допомогою запропонованого методу [5]

Для формування еталонного кардіоциклу (рис. 3.5. б), було сформовано штучний кардіоцикл без наявних перешкод, потім на нього було накладено сигнали ППШ та ППП за тим самим алгоритмом, що і для сигналів з перешкодами.

Аналіз усередненого кардіоциклу класичним методом (рис. 3.5. г) показує, що хоча усереднення придушило більшість проявів неточного виділення кардіоциклів (рис. 3.5. а), та високоамплітудних нерегулярних компонентів, водночас загальна форма сигналу залишилась незмінною, однак на формі сигналу спостерігається спотворення зубця R (рис. 3.5. 1) через наявність сукупності нерегулярних компонентів, що були помилково виділені детектором, як R пік. Також спостерігається спотворення форми пізніх потенціалів (рис. 3.5. 2), через наявність нерегулярної високоамплітудної компоненти, а також інших шумів на цій ділянці під час усереднення кардіоциклів. Крім того спостерігається спотворення форми Т хвилі (рис. 3.5. 3). Через високу кількість перешкод, та як наслідок помилкового детектування положення R піку, на формі Т хвилі усередненого сигналу спостерігаються відмінності від еталона. Як наслідок, проявляються морфологічні зміни на тих місцях, де їх не має бути. Аналізуючи головний вектор SVD розкладу однієї епохи (рис. 3.5. в), можна побачити що в головному векторі виділилися високоамплітудні нерегулярні компоненти (рис. 3.5. 4, 6), але їх амплітуда значно нижча за перешкоди, що відображені в оригінальному сигналі. Прояв цих компонентів в одній епосі, може пояснюватись потраплянням декількох високоамплітудних перешкод в цю епоху. Також в результаті виділення головного вектора в одній епосі було спотворено ППШ (рис. 3.5. 5), але ці спотворення є набагато нижчими ніж у випадку усередненого кардіоциклу. Спотворення морфології Т хвилі також не спостерігається. Варто зазначити, що результати на (рис. 3.5. в) були отримані з епохи розміром всього 30 кардіоциклів, що є значним покращенням в порівнянні з сигналом усередненим класичним методом. Найкращий результат було отримано за

допомогою запропонованого методу (рис. 3.5. д). На отриманому усередненому кардіоциклі, проявів високоамплітудної нерегулярної компоненти майже не спостерігається, також морфологія найбільш схожа з еталонним кардіоциклом. Крім того, ділянка кардіоциклу з пізніми потенціалами (рис. 3.5. 7) була виділена найкраще з найменшими спотвореннями відносно еталонного кардіоциклу.

Також було розраховано метрики, для дослідження якості виділення низькоамплітудних регулярних компонентів (пізніх потенціалів). До сигналу що досліджується було застосовано методи підвищення якості виділення пізніх потенціалів, а саме фільтрація у вузькому частотному діапазоні (40-240 Гц), та звуження зони інтересу до сегмента ST для виділення ППШ (рис. 3.6. а), та сегмента PQ – для виділення ППП (рис. 3.6. б):




Рис. 3.6. Порівняння з еталоном ППШ та ППП після усереднення: а – ППШ в еталонному та усередненому ЕКГ сигналі, б – ППП в еталонному та усередненому ЕКГ сигналі [5]

Для оцінювання розбіжності між еталонним сигналом та сигналом після усереднення було використано косинусну подібність (3.1) та коефіцієнт кореляції Пірсона (3.2):

$$\text{CosSim}_{A,B} = \frac{A \times B}{\|A\| \times \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \times \sqrt{\sum_{i=1}^n B_i^2}} \quad (3.1)$$

де A, B – n -мірні вектори, а $\|A\|, \|B\|$ – Евклідові норми векторів (A, B) , в просторі дійсних чисел.

$$r_{pearson} = \frac{\sum_{i=1}^n (A_i - \bar{A}) \times \sum_{i=1}^n (B_i - \bar{B})}{\sqrt{\sum_{i=1}^n (A_i - \bar{A})^2 \times \sum_{i=1}^n (B_i - \bar{B})^2}}, \quad (3.2)$$

де A, B – n -мірні вектори що порівнюються, $\bar{A} = \frac{1}{n} \sum_{i=1}^n A_i$, $\bar{B} = \frac{1}{n} \sum_{i=1}^n B_i$.

На вхід методів усереднення з використанням аналізу головних компонент (Principal Component Analysis, PCA), сингулярного розкладу (Singular Value Decomposition, SVD) та факторного аналізу (Factor Analysis, FA) було подано штучний сигнал з нерегулярною високоамплітудною складовою, Гаусівським шумом, таким, що результуюче відношення сигнал/шум дорівнював 30 дБ. Частота серцевих скорочень складала 80 ударів на секунду зі стандартним відхиленням ± 2 удари на секунду. Параметри запропонованого методу усереднення було встановлено на формування епох із 30 кардіоциклів із перекриттям в 15 кардіоциклів, усереднення відліків головних векторів з епох кардіоциклів відбувалося за допомогою середнього арифметичного. Значення показників подібності були розраховані для виділення ППШ та ППП з амплітудою 1-40 мікрівольт з кроком в 5 мікрівольт.

В результаті були отримані графіки значень показників подібності пізніх потенціалів після застосування різних методів усереднення та еталону, в залежності від амплітуди пізніх потенціалів (рис. 3.7). Оскільки метрики кореляції Пірсона та косинусної подібності продемонстрували близькі результати, на графіках їхні криві збігаються. З отриманих графіків показників подібності видно, що запропонований метод за низьких амплітуд пізніх потенціалів проявляє себе набагато точніше ніж звичайне усереднення кардіоциклів. За амплітуди ППП в 1 мікрівольт, показник подібності для запропонованого методу на основі SVD, на 10% вище, ніж для усередненого сигналу (рис. 3.7. б), на 20% вищий для методу на основі FA (рис. 3.7. г), та майже на 30% вищий з використанням PCA (рис. 3.7. в). Дана тенденція спостерігається і на показниках подібності для пізніх потенціалів шлуночків.




Рис. 3.7. Порівняння показників подібності виділених ППП та ППШ з еталоном в залежності від їх амплітуди та методу усереднення: а – показники подібності ППШ та ППП на основі методу класичного усереднення, б – показники подібності ППШ та ППП для запропонованого методу на основі SVD, в – показники подібності ППШ та ППП для запропонованого методу на основі PCA, г – показники подібності ППШ та ППП для запропонованого методу на основі FA [5]

Крім того, запропонований метод є більш чутливим, оскільки за низьких амплітуд пізніх потенціалів його показники подібності на 10-20 % вищі, ніж у класичного усереднення. Навіть за амплітуди пізніх потенціалів в 1 мкВ, коли сигнал не має подібності з еталоном, метод на основі факторного аналізу продемонстрував коефіцієнт подібності близько 0.25. За амплітуд понад 10-15 мкВ чутливість обох методів вирівнювалась, однак запропонований підхід зберігав кращі показники. У разі обробки ЕКГ сигналів запропонованим методом, для отримання усередненого кардіоциклу з оригінального сигналу, який містив близько 300 кардіоциклів, найвищу якість виділення ППП та ППШ вдалося досягти використовуючи розмір епохи (n) – 25-30 кардіоциклів та перекриття(m) – 10-15 кардіоциклів.

Для тестування запропонованого методу усереднення, на основі реальних ЕКГ сигналів було розроблено базу даних з наявними пізніми потенціалами на основі публічного набору даних [59] «PTB Diagnostic ECG

Database Version: 1.0.0». Ця база включає 549 ЕКГ високого розрізнення тривалістю близько 115 секунд від 294 суб'єктів з розрядністю квантування в 16 біт, та частотою дискретизації кожного відведення – 1000 Гц. Ця база даних налічує 148 пацієнтів з інфарктом міокарда, 18 пацієнтів з кардіоміопатією, та серцевою недостатністю, 14 пацієнтів з різними типами аритмій, 7 пацієнтів з гіпертрофією серця, а також 52 здорових волонтера без наявних порушень серцево-судинної активності. Ці патології, можуть супроводжуватися наявністю низькоамплітудних ППШ та ППП, на основі яких може бути побудована тестова база даних з наявними пізніми потенціалами. Окрім 12 стандартних відведень, дана база також включає ортогональні відведення Франка (X, Y, Z).

Використання розробленої бази даних дало можливість скористатися методом виділення пізніх потенціалів на основі методу, що є загальноприйнятим Європейським товариством кардіологів, Американською кардіологічною асоціацією та Американським коледжем кардіологів [60]. Даний метод базується на побудові векторної амплітуди на основі трьох проекцій ЕКГ серця з ортогональних відведень Франка, та обрахунку на її основі необхідних параметрів кардіоциклу для виявлення наявності пізніх потенціалів [61]. Згідно літературних джерел [61, 62] для ППШ характерними є наступні параметри векторної амплітуди: тривалість QRS комплексу > 114 мс, середньоквадратична напруга останніх 40 мс (RMS40) < 20 мікрівольт, сумарна тривалість ділянок QRS комплексу з напругою < 40 мікрівольт (LAS) > 38 мс. В свою чергу, для ППП: тривалість Р зубця (PWD) > 115 мс, середньоквадратична напруга останніх 20 мс Р хвилі (RMS20) < 2.2 мікрівольт. Наявність пізніх потенціалів фіксується, якщо задовольняються хоча б два з трьох умов для ППШ, та обидві умови, для ППП [62]. Отже, на основі даної методики оцінювання пізніх потенціалів було отримано тестову базу даних, в якій присутні 137 ЕКГ сигналів з наявними ППШ, 47 ЕКГ сигналів з наявними

ППП, 14 ЕКГ сигналів з наявними ППП та ППШ, 351 ЕКГ сигнал без наявних пізніх потенціалів.

Для тестування методів попередньої обробки було розроблено класифікаційні моделі на основі методу опорних векторів (Support Vector Machine, SVM), класифікатору випадкового лісу (Random Forest, RF), логістичної регресії (Logistic Regression, LR), та методу к-найближчих сусідів (K-neighbor).

У розробленому методі усереднення використовувався розмір епохи $n = 25$ кардіоциклів, перекриття $m = 10$ кардіоциклів, виділення головного вектора (кардіоциклу) відбувалося на основі методу SVD, усереднення головних векторів відбувалося на основі середнього арифметичного по кожному відліку отриманих головних векторів. Для обраних класифікаційних моделей, було розраховано систему ознак, які можуть характеризувати наявність пізніх потенціалів в часовому, та частотному представленні. Набір ознак було розраховано на основі одного з існуючих підходів до виявлення пізніх потенціалів за допомогою машинного навчання [63]. Основою для розрахунку набору ознак є векторна амплітуда (VM), яка визначена для 12 стандартних відведень (I, II, III, V1, V2, V3, V4, V5, V6) за формулою:

$$VM = \sqrt{\sum_{k=1}^N X_k^2(t)},$$

де $X_k(t)$ – миттєве значення сигналу в k -му відведенні у момент часу t , k – номер відведення, N – загальна кількість відведень, використаних у розрахунку.

З метою навчання класифікаційної моделі, для кожного ЕКГ сигналу, що досліджувався було сформовано набір з 5 ознак для класифікації ППШ, та набір з 3 ознак для класифікації ППП. Для ППШ, відповідно до [63], за графіком векторної амплітуди було розраховано: затримку між піком R та

точкою j (точка переходу зубця S в сегмент ST) в мс; значення середньоквадратичної напруги останніх 40 мс (RMS40) QRS комплексу в мікрівольтах; сумарна тривалість ділянок QRS-комплексу, де амплітуда сигналу менша за 40 мкВ, у мілісекундах; відношення енергії сигналу в частотно-часовому представленні, отриманому за допомогою короткочасного перетворення Фур'є (STFT), у часовому інтервалі ППШ до енергії QRS-комплексу в частотному діапазоні 55-300 Гц; відношення енергії сигналу у спектрі STFT протягом 80 мс після завершення QRS-комплексу до енергії QRS-комплексу в частотному діапазоні 55-300 Гц. Для ППП було розраховано наступні ознаки: затримка між вершиною R піку і кінцем хвилі R ; середньоквадратична напруга останніх 20 мс R хвилі (RMS20) в мікрівольтах; відношення енергії сигналу у частотно-часовому представленні, отриманому за допомогою короткочасного перетворення Фур'є (STFT), протягом 80 мс після завершення R -хвилі до енергії самої R -хвилі в частотному діапазоні 55–300 Гц. Класифікаційні моделі тренувалися для передбачення норми та патології, а саме на ЕКГ сигналах з наявними пізніми потенціалами, та без них. Також було видалено викиди, що лежали за межами трьох стандартних відхилень, та замінено модою відповідної ознаки у вибірці. Після чого було проведено зменшення найбільшого за розміром класу до розміру меншого методом випадкового відбору спостережень, щоб отримати відношення розміру класів 1:1. Останнім кроком підготовки даних, було виконано стандартизацію даних за допомогою алгоритму «Robust Scaler», який є стійким до викидів [64]. Після попередньої обробки до алгоритмів машинного навчання було подано 141 ЕКГ сигнал норми та патології для ППШ після класичного усереднення, 138 сигналів норми та патології після запропонованого методу усереднення, а також 42 і 46 сигналів для ППП після класичного та запропонованого методу усереднення, відповідно. За отриманими результатами обчислювалась кількість істинно позитивних (True Positive, TP), істинно негативних (True Negative, TN), хибно позитивних (False Positive, FP), та хибнонегативних (False Negative, FN) результатів, а також

статистичні метрики точності класифікаційних моделей, а саме, ймовірність здійснення помилки першого роду (False Positive Rate, FPR), ймовірність здійснення помилки другого роду (False Negative Rate, FNR), чутливість (True Positive Rate, TPR), специфічність (True Negative Rate, TNR), та загальна точність (Accuracy, ACC) за формулами:

$$TPR = \frac{TP}{TP + FN}; TNR = \frac{TN}{TN + FP}; FPR = \frac{FP}{FP + TN};$$

$$FNR = \frac{FN}{FN + TP}; ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

Отже, під час дослідження впливу запропонованого методу попередньої обробки ЕКГ сигналу на результати класифікації було отримано таблиці 3.1 та 3.2.

Таблиця 3.1 Порівняння результатів класифікації сигналів з наявними ППШ на основі класичного усереднення та запропонованого методу

Класифікацій на модель	Метод	FPR	FNR	TPR	TNR	ACC
SVM	Класичний	0,45	0,19	0,81	0,55	0,67
	Запропонований	0,35	0,14	0,86	0,65	0,74
RF	Класичний	0,28	0,35	0,65	0,72	0,69
	Запропонований	0,16	0,36	0,64	0,84	0,75
LR	Класичний	0,45	0,19	0,81	0,55	0,67
	Запропонований	0,29	0,23	0,77	0,71	0,74
K-neighbor	Класичний	0,21	0,35	0,65	0,79	0,73
	Запропонований	0,13	0,45	0,55	0,87	0,74

Таблиця 3.2 Порівняння результатів класифікації сигналів з наявними ППП на основі методу класичного усереднення та запропонованого методу

Класифікацій на модель	Метод	FPR	FNR	TPR	TNR	ACC
SVM	Класичний	0,55	0,33	0,67	0,45	0,53
	Запропонований	0,17	0,57	0,43	0,83	0,68
RF	Класичний	0,55	0,00	1,00	0,45	0,65
	Запропонований	0,25	0,43	0,57	0,75	0,68
LR	Класичний	0,55	0,50	0,50	0,45	0,47
	Запропонований	0,17	0,57	0,43	0,83	0,68
K-neighbor	Класичний	0,36	0,50	0,50	0,64	0,59
	Запропонований	0,17	0,57	0,43	0,83	0,68

З аналізу таблиць 3.1 та 3.2 можна побачити, що точність класифікації є вищою для запропонованого методу усереднення, ніж для усереднення класичним методом. Дані не були провалідовані фахівцями, тому набір містить помилкові мітки класів, однак його якості достатньо для оцінки розробленого методу попередньої обробки сигналів. Для ПППШ точність вища на 5% в середньому, та для ПППІ на 12% в середньому. Зменшити частку хибно-негативних передбачень можна за рахунок адаптивного налаштування параметрів розміру епохи (n) та перекриття (m). Крім того, аналізуючи показник FPR, можна зробити висновок, що ймовірність здійснення помилки першого роду також є меншою із використанням запропонованого методу усереднення, на 12% для ПППШ і на 31% для ПППІ. Це вказує на те, що запропонований метод є стійкішим до перешкод (ПППІ та ПППШ), що могли проявитися на усередненому кардіоциклі.

3.2 Сегментація та видалення зашумлених ділянок ЕКГ сигналів за допомогою нейромережових технологій

Якісний аналіз ЕКГ вимагає точної ідентифікації серцевих подій, що можуть варіюватися від короткочасних (початок/кінець хвиль деполяризації) до тривалих епізодів (апное, ішемія, аритмії). Сегментація особливо важлива для довготривалого моніторингу, оскільки дозволяє структурувати сигнал на інтервали з різною серцевою активністю та вилучати шумові епізоди. Наприклад, під час наявності апное аналізують криву дихання отриману з ЕКГ (ECG-derived respiration, EDR), яка стає рівною під час зупинки дихання [65].

Порогові та фільтраційні методи, зокрема алгоритм Пана-Томпкінса [67], є швидкими та ефективними для детекції R-піків, але чутливими до шуму і морфологічних змін, тоді як частотно-часові методи дозволяють аналізувати локальні спектральні зміни, проте потребують значних обчислювальних ресурсів. Морфологічні та статистичні алгоритми ефективні для виявлення екстрасистол, але залежать від якості шаблонів, а стохастичні моделі, зокрема приховані Марківські моделі [66, 68], дозволяють описувати часову динаміку переходів між станами серцево-судинної системи. Методи машинного навчання включають класичні алгоритми та глибоке навчання, яке забезпечує високу точність за наявності великих розмічених наборів даних, тоді як гібридні системи поєднують різні підходи, наприклад попередню детекцію QRS алгоритмом Пана-Томпкінса з подальшою класифікацією нейронною мережею.

Помилки у визначенні положень R-піків призводять до хибного розрахунку діагностичних показників, таких як варіабельність серцевого ритму. Надійні детектори, як алгоритми Пана-Томпкінса [67] та Гамільтона [69], залишаються фундаментом для подальшого аналізу, хоча сучасні підходи все частіше використовують методи машинного навчання для підвищення точності та стійкості до артефактів [70].

У деяких випадках через патології, або за наявності високочастотних шумів навіть удосконалені методи можуть хибно ідентифікувати QRS-комплекси (рис. 3.8).




Рис. 3.8. Приклад хибного визначення серцевих циклів на ЕКГ сигналі у випадку фібриляції передсердь [9]

Найпростіший спосіб зменшення впливу шумів полягає в автоматизованому визначенні та видаленні шумових фрагментів із сигналу ЕКГ на початковому етапі обробки. Однак цей підхід непридатний для коротких фрагментів, де кожен цикл має діагностичне значення, оскільки видалення навіть невеликих фрагментів можуть призвести до втрати важливої інформації. Визначення шуму на ЕКГ є складною задачею. Деякі алгоритми використовують автокореляційний аналіз [71], але вони можуть помилково класифікувати екстрасистоли, та подібні патології як шум. Статистичні методи [72] вимагають тривалих записів для репрезентативності, а емпіричні підходи [73] часто обмежені конкретними типами перешкод. Моделі глибокого навчання [74] пропонують кращу стійкість до шумів і точність визначення QRS-комплексів, але стабільний і перевірений детектор поки відсутній. Через морфологічну різноманітність кардіоциклів, розрізнення між реальними сигналами та шумом залишається складною задачею.

Для вирішення цієї проблеми запропоновано модель на основі згорткової нейронної мережі, як відрізняє справжні кардіоцикли від шумових перешкод. Цей підхід дозволяє надійно виявляти навіть атипові кардіоцикли та відкидати шумові компоненти, що підвищує стійкість системи та точність аналізу QRS-комплексів. З метою отримання фрагментів ЕКГ сигналу для дослідження було використано кілька відкритих баз ЕКГ з анотованими QRS-комплексами. До

використаних джерел належать наступні бази даних: Bruno University of Technology ECG Quality Database [75]; the 4th China Physiological Signal Challenge 2021 Database [76]; fantasia Database [77]; long Term AF Database [78]; MIT-BIH Noise Stress Test Database [79]; MIT-BIH Arrhythmia Database [80]; MIT-BIH Long-Term ECG Database [81]; T-Wave Alternans Challenge Database [82].

Для отримання шумових фрагментів використовувалися бази: CU Ventricular Tachyarrhythmia Database [83]; MIT-BIH Arrhythmia Database; MIT-BIH Noise Stress Test Database; Brno University of Technology ECG Quality Database (BUT QDB).

Ці бази містять анотовані сигнали ЕКГ від 1 до 12 відведень тривалістю від 10 секунд до 24 годин. Кожен сигнал було анотовано кардіологами. Анотації баз даних містять положення R-піків комплексів QRS, тип кожного серцевого циклу, а також події на ЕКГ, що вказують на початок і кінець аритмій, небезпечних для життя станів і шумових фрагментів, придатних для подальших досліджень. Додатково до сигналів був доданий штучний Гаусівський шум амплітудою від 0,1 до 1 мВ, а також шумові складові у частотних діапазонах 1-30 Гц і 1-100 Гц. Для моделювання м'язового шуму та електродермальної активності використовувався алгоритм з відкритої бібліотеки NeuroKit2 [84, 85].

Щоб навчити алгоритм виявляти серцеві цикли навіть за наявності базового шуму, і забезпечити більш точне розрізнення шумового сигналу з відсутністю ЕКГ, до частини сигналів було додано штучний шум та низькочастотний дрейф ізолінії (baseline drift), щоб досягти співвідношення сигнал/шум (SNR) у межах 20-90 дБ.

Після попередньої підготовки та сегментації сигналів, отриманих з [75-77, 79-81] була сформована база даних, яка містить 13 712 521 нормальних

серцевих циклів і 678 641 циклів з наявними патологіями різних типів, такі як передчасні шлуночкові скорочення (PVC), передсердні екстрасистоли.

Для побудови навчальної вибірки комплекси QRS було вирізано у вікні тривалістю $\pm 0,5$ с відносно положення R-піку, тобто тривалість кожного фрагмента становила 1 секунду. Такі фрагменти використовувалися для навчання нейронної мережі. У сигналах отриманих з [75, 79, 80, 83], що містили лише шум, створювалися помилкові мітки R піків із кроком 0,4-0,6 с, що відповідало серцевому ритму 100-150 уд/хв, на основі яких також формувалися фрагменти сигналу тривалістю 1 секунда. Щоб зберегти різноманітність типів і форм серцевих циклів, вибірку з реальними кардіоциклами було зменшено шляхом випадкового видалення QRS-фрагментів із усіх доступних даних. У результаті було отримано навчальний набір, що складався з 2 163 975 фрагментів сигналу з комплексами QRS та 432 795 шумових фрагментів.

Перед подачею даних на вхід нейронної мережі, фрагменти сигналів проходили процедуру попередньої обробки за блок-схемою (рис. 3. 9).




Рис. 3.9. Блок-схема попередньої обробки даних для формування тренувального набору нейронної мережі [9]

Процедура попередньої обробки включала локалізацію QRS комплексів, усунення дрейфу базової лінії, амплітудну нормалізацію за типовим рівнем R-піків (середнім, медіанним або модальним значенням залежно від характеристик сигналу), сегментацію сигналу на кардіоцикли та передискретизацію кожного сегмента до 64 відліків.

Для моделей нейронних мереж, що були розроблені для класифікації кардіоциклів застосовувався оптимізатор стохастичного градієнтного спуску (Stochastic Gradient Descent, SGD). Швидкість навчання (Learning Rate) встановлювалася на рівні 0,005, коефіцієнт інерції (momentum factor) – 0,9, розмір навчальної міні-вибірки (batch size) – 100 фрагментів .

Найпростішою, та найменш обчислювально-затратною моделлю для задачі відсікання шумових фрагментів ЕКГ є підхід на основі повнозв'язних шарів НМ. Розроблену архітектуру НМ на основі повнозв'язних шарів можна відобразити блок-схемою (рис. 3.10.):




Рис. 3.10. Модель повнозв'язної нейронної мережі для класифікації серцевих циклів [9]

Модель містить 64 вхідні нейрони, що відповідає кількості відліків сигналу на вході. Кожен вхідний нейрон пов'язаний з 40 нейронами прихованого шару. Коефіцієнти 40 нейронів прихованого повнозв'язного шару проходять через шар нормалізації міні-вибірки для підвищення стабільності та швидкості навчання. Функція лінійної ректифікації (Rectified Linear Unit, ReLU) була обрана як функція активації прихованого шару. Другий прихований шар містить 20 нейронів на виході, також з активацією ReLU. Останній шар складається з одного нейрона, який має сигмоїдну функцією активації (Sigmoid).

Через нерівномірність класів у тренувальних даних (QRS-комплексів і шумових фрагментів у співвідношенні 5:1) модель може помилково позначати шум як корисний сигнал, що призводить до зростання частоти хибнопозитивних рішень (FPR) та потрапляння у локальний мінімум з точністю близько 80%. Для усунення цього ефекту було розроблено функцію

втрата, спрямовану на зниження FPR та уникнення локальних мінімумів, яка описується формулою:

$$\mathcal{L} = \sum_{i=1}^n |true_i - pred_i| \cdot \sum_{i=1}^n |\max [-1\gamma(true_i - pred_i), -1(true_i - pred_i)]|$$

У цій функції втрат другий множник відповідає за підвищену чутливість до хибнопозитивних результатів. Чим більше хибнопозитивних оцінок, тим вищим є штраф у функції втрат $\mathcal{L}$, відповідно, більша загальна втрата. У формулі $pred_i$ – відображає значення, передбачене моделлю, $true_i$ – еталонне значення, що отримане з анотованої бази даних. Змінна n – відображає розмір міні-вибірки, а γ – коефіцієнт, що визначає силу штрафу за хибнопозитивні прогнози. Якщо $\gamma = 0$, штраф максимальний, а якщо $\gamma = 1$, то штраф відсутній. У навчанні моделей значення γ встановлювалося на рівні 0.1.

Іншим підходом до реалізації методу, з метою покращення узагальнювальної здатності моделі у задачі класифікації серцевих циклів та шумів, а також для підвищення точності класифікації, була розроблена архітектура, на основі згорткової нейронної мережі, яка наведена на рис. 3.11




Рис. 3.11. Архітектура згорткової нейронної мережі для класифікації QRS-комплексів [9]

Фрагмент ЕКГ сигналу паралельно подається на кластер із трьох типів згорткових шарів, кожен із яких має власний розмір ядра (kernel size). Це забезпечує виділення ознак із сигналу на трьох рівнях деталізації для значень ядер згортки $\in [4, 8, 16]$. Параметри кроку згортки (stride) та заповнення (padding) підібрано так, щоб забезпечити баланс між роздільною здатністю та ефективністю виділення ознак сигналу. Для трьох паралельних шарів застосовано такі значення параметрів: крок $\in [2, 4, 8]$, заповнення $\in [1, 2, 4]$. Після застосування першого кластера, сигнали з кожного паралельного згорткового шару надходять до другого кластера згорткових шарів. Другий кластер формує низьковимірні ознаки однакового розміру (1×4) після чого перетворюються у одновимірний масив після проходження блоків об'єднання та розгортки. У послідовно з'єднаних повнозв'язних шарах поступово зменшується кількість нейронів, виділяючи найбільш релевантні ознаки для визначення типу кардіоциклу.

Проектування архітектур нейронних мереж, що досліджувались, здійснювалося поетапно з урахуванням принципів ієрархічного виділення ознак та стабілізації процесу навчання. Оптимізація структури виконувалася на основі аналізу динаміки функції втрат, кривих навчання та розподілу градієнтів з подальшим коригуванням конфігурації шарів і їх параметрів для підвищення збіжності та узагальнювальної здатності моделі.

Для досліджуваних моделей використання класичної функції втрат, такої як бінарна крос-ентропія призвело до потрапляти в локальні мінімуми під час навчання. Застосування спеціально розробленої функції втрат суттєво покращило навчання. Під час її використання точність досягла 95% вже на п'ятій епосі тренування, та показник FPR показав значно кращі результати як для повнозв'язної так і для згорткової архітектури.

Отже, після навчання протягом 200 епох найкращі результати навчання були отримані саме із застосуванням розробленої функції втрат. В результаті для повнозв'язної нейронної мережі вдалося досягти точності 98% з FPR = 4%. В свою чергу, для згорткової нейронної мережі вдалося отримати точність класифікації 99% та зберегти низьке значення FPR у межах 0,6-1%.

Для оцінювання стабільності навчання розроблених моделей НМ застосовано 5-кратну крос-валідацію, результати якої наведено в табл. 3.3 Крос-валідація виконувалася на сформованій навчальній вибірці із використанням блокового розбиття, під час якого фрагменти сигналу з однаковою довжиною поділялися на послідовні блоки відповідно до порядку їх формування з оригінального сигналу, що дозволяло зменшити потрапляння морфологічно подібних фрагментів одночасно до навчальної та тестової підвибірок.

Таблиця 3.3 Результати 5-кратної крос-валідації для повнозв'язної та згорткової нейронних мереж із застосуванням розробленої функції втрат

Номер ітерації	Повнозв'язна НМ			Згорткова НМ		
	Чутл.	Спец.	Загальна точність	Чутл.	Спец.	Загальна точність
1	97,39	92,94	96,65	99,11	97,01	98,76
2	92,66	94,77	93,01	98,73	98,29	98,65
3	98,47	93,63	97,67	98,84	98,11	98,72
4	90,92	97,75	92,05	98,97	96,72	98,60
5	97,74	98,50	97,87	98,62	98,52	98,61
Середнє	95,44	95,52	95,45	98,85	97,73	98,67

Для перевірки ефективності моделей у реальних умовах було проведено тестування на задачі виявлення хибно визначених серцевих циклів, отриманих за допомогою автоматизованих QRS-детекторів. З публічної бази “Long Term AF Database” [78] було обрано фрагмент ЕКГ тривалістю 1000 секунд, який містив м’язові шуми та артефакти руху, що впливають на точність визначення QRS-комплексів. За допомогою кількох поширених детекторів було визначено положення QRS-комплексів. Позиції автоматично визначених комплексів порівнювалися з еталонними розмітками, отриманими лікарями. Наступним кроком автоматично визначені комплекси фільтрувалися за допомогою розроблених моделей. Якщо відстань між піками R та анотаціями лікарів не перевищувала 0,1 с, то кардіоцикл вважався визначеним правильно.

Таблиця 3.4 Точність виявлення QRS комплексів за допомогою різних алгоритмів до та після фільтрації розробленим методом на основі повнозв’язної та згорткової нейронних мереж

Назва детектора	Точність детекції	Точність після фільтрації повнозв’язною НМ	Точність після фільтрації згортковою НМ
Pan-Tompkins	83,27	85,19	90,21
Hamilton2002	87,74	92,91	93,90
Kalidas2017	92,71	96,56	97,14
Engzeemod	25,21	94,05	94,17

Аналіз таблиці 3.4 показав, що використання розробленої нейронної мережі суттєво підвищує точність визначення QRS-комплексів у сигналах з шумом. За результатами аналізу спостерігається збільшення точності від 2% (для Pan-Tompkins) до 70% (для Engzeemod). В свою чергу, згорткова нейронна

мережа продемонструвала вищу швидкість навчання та обробки даних ніж повнозв'язна модель.

Однією з потенційних сфер застосування розробленої нейронної мережі є фільтрація зашумлених кардіоциклів під час усереднення сигналів у методі ЕКГ високого розрізнення (High-Resolution ECG) [87, 88], що використовується для виявлення низькоамплітудних патологічних компонентів. Наявність шумів у таких сигналах може призводити до діагностичних похибок і погіршення якості їх виявлення.

Для перевірки ефективності запропонованого алгоритму в задачі покращення виявлення низькоамплітудних компонентів, було використано фрагмент сигналу тривалістю 2 хвилини з відкритої бази даних “T-Wave Alternans Challenge Database”. Пізні потенціали розташовувалися на відстані 0,035 с після R-піку кожного серцевого циклу. Їх положення моделювалися як суперпозиція потенціалів дії, що поширюються від певної кількості різних клітин. Процес поширення потенціалів дії відтворювався на основі моделі паралельної провідності [62].

Положення QRS-комплексів визначалися з використанням автоматизованого детектора QRS на основі алгоритму Пана-Томпкінса [67], після чого вони фільтрувалися від шумів за допомогою запропонованого алгоритму.

Далі QRS-комплекси до та після фільтрації усереднювалися, а сигнал пізніх потенціалів виділявся з отриманих усереднених серцевих циклів і порівнювався з еталоном за метрикою Dynamic Time Warping [89]. Чим нижче значення цієї метрики, тим більшою є подібність виділених пізніх потенціалів та еталону. Результати аналізу наведено в таблиці 3.5.

З аналізу таблиці можна визначити, що фільтрація серцевих циклів від шуму на основі запропонованої моделі дає змогу підвищити точність виділення низькоамплітудних компонентів сигналу.

Застосування розробленого методу може бути ефективним у поєднанні з іншими методами, зокрема з удосконаленими способами усереднення серцевих циклів [5], що дозволяє покращити ідентифікацію пізніх потенціалів.

Таблиця 3.5 Значення метрики подібності DTW між виділеними пізніми потенціалами та еталонними потенціалами з використанням класичного усереднення та усереднення з фільтрацією за запропонованим методом

Метрика подібності	Значення метрики після детекції R піків	Значення метрики після фільтрації повнозв'язною НМ	Значення метрики після фільтрації згортковою НМ	Значення метрики після виявлення QRS комплексів за допомогою лікаря
Відстань DTW	0,72	0,61	0,58	0,52

Крім того, було графічно порівняно якість усереднення серцевих циклів, отриманих різними методами. Результати графічного порівняння зображені на рисунку 3.12.




Рис. 3.12. Порівняння усереднених кардіоциклів з наявними пізніми потенціалами: а – усереднений кардіоцикл, отриманий за R-піками автоматизованого детектора ЕКГ, б – усереднений кардіоцикл після обробки кардіоциклів запропонованою моделлю НМ, в – усереднений кардіоцикл, визначений за R-піками, що були виявлені лікарями [9]

Порівняння усереднених серцевих циклів, отриманих різними методами, ілюструє, що сигнали, оброблені запропонованою моделлю нейронної мережі, мають форму, значно ближчу до усередненого сигналу, побудованого за QRS-комплексами, визначеними лікарями. В свою чергу, усереднений кардіоцикл побудований за допомогою міток автоматизованого ЕКГ детектора демонструє більшу варіабельність та наявність шумових артефактів, які виникають через похибки автоматизованого виявлення R-піків. Це призводить до зсувів у вирівнюванні окремих кардіоциклів, спотворення морфології QRS-комплексу та втрати чутливості до низькоамплітудних компонентів, зокрема пізніх потенціалів шлуночків.

3.3 Стандартизація та реструктуризація ЕКГ сигналу за допомогою нейромережевого автоенкодера

Стандартизація ЕКГ сигналу шляхом нормалізації амплітуди та його передискретизація дозволяє усунути несуттєві варіації QRS-комплексу, підвищити стабільність ознак і зменшити ризик перенавчання [90]. Реструктуризація сигналу, зокрема сегментація та зменшення розмірності, робить дані більш придатними для навчання нейронних мереж. Наприклад гарні результати демонструє метод PCA який формує обмежену кількість головних компонентів [91]. Нейромережеві підходи, зокрема автоенкодери [92], формують компактне латентне представлення, однак можуть втрачати низькоамплітудні діагностичні ознаки. Для зменшення цього ефекту застосовують регуляризацию та варіаційні автоенкодери [93], хоча для ЕКГ сигналів із високою індивідуальною мінливістю та рівнем шуму стабільність їх роботи залишається обмеженою.

Для вирішення цих проблем було розроблено спеціалізовану архітектуру автоенкодера (рис.3.13).




Рис. 3.13. Розроблена архітектура автоенкодера для отримання скороченого вектора ознак ЕКГ сигналу [3]

Розроблена архітектура автоенкодера має низку вдосконалень порівняно з класичним підходом і спрямована на отримання стислого вектора ознак ЕКГ сигналу, який максимально зберігає діагностично важливу інформацію в латентному просторі. Основою побудови моделі є симетричний автоенкодер. Крім того, в архітектурі використовуються згорткові шари [94] та шари уваги [95], що дозволяють забезпечити ефективне виділення частотно-часових залежностей у сигналі.

Початковим шаром розробленої архітектури є згортковий шар, на який подається оригінальний сигнал, після обробки якого формується 30 матриць результуючих ознак, які є результатами згортки. Завдяки використанню зміщення ядра згортки, більшого за одиницю, розмірність отриманих векторів зменшується у 4 рази. Наприклад, якщо на вхід подається 12-канальний ЕКГ сигнал тривалістю 1 секунда з частотою дискретизації 500 Гц (тобто 12×500 відліків), то після першого згорткового шару утворюються 30 векторів ознак довжиною 125 відліків кожен. Після цього сигнал проходить через три послідовні повнозв'язні шари, які поступово зменшують кількість параметрів до латентного простору, розміром 160 коефіцієнтів. На етапі декодування симетричні шари відновлюють сигнал до первинної розмірності. У такий спосіб зберігається повна симетрія шарів енкодера та декодера, включаючи

вагові коефіцієнти (спільні ваги). Повнозв'язні шари з параметрами $M \times N$, дублюються шарами $N \times M$, де M – кількість вхідних нейронів (або розмірність вхідного вектора, що подається на шар), N – кількість вихідних нейронів (або розмірність вектора, який виходить із шару). В свою чергу згортковий шар дублюється шаром транспонованої згортки, що повертає просторову структуру сигналу, втрату якої спричинило попереднє стиснення.

Для запобігання неоднорідності розподілу вагових коефіцієнтів у парних шарах енкодера та декодера використано спільні ваги. Це забезпечує узгоджене навчання обох частин автоенкодера, зменшує ризик перенавчання декодера та сприяє виявленню найважливіших характеристик ЕКГ сигналу.

Для підвищення стабільності навчання та покращення збіжності моделі в блоці енкодера застосовано залишкові зв'язки [96], які поєднують виходи попередніх шарів з поточними значеннями. Додатково використовуються шари вибору максимальних значень для відбору значущих ознак зі значень залишкових зв'язків та виходів шарів.

Особливістю архітектури є використання шару уваги (Attention Layer), який аналізує взаємозв'язок між виходом енкодера (Рис. 3.13. Q) і вхідними ознаками після згортки (Рис. 3.13. K, V). Цей механізм створює адаптивний зворотний зв'язок, що дозволяє моделі фокусуватися на найбільш релевантних частинах сигналу, покращуючи точність аналізу. Додатково шар уваги виступає у ролі регуляризації, знижуючи вплив шумів та підвищуючи стійкість до перенавчання. Його вихід комбінується із залишковими зв'язками, проходить нормалізацію та формує остаточний латентний вектор, який передається до декодера або використовується як стисле представлення ознак оригінального ЕКГ сигналу. Для збільшення кількості інформативних ознак, додатково формується об'єднаний вектор ознак, який включає коефіцієнти латентного вектора (1×160) та вагові коефіцієнти натренованих шарів автоенкодера (1×80) отримані за допомогою шару вибору максимальних значень.

Однак точність навчання можна ще підвищити, якщо автоенкодер буде виділяти ознаки орієнтуючись на існуючі класи патологій ЕКГ. Для реалізації цього підходу, до архітектури розробленого автоенкодера було додано повнозв'язний шар класифікації без функції активації. Використання подібного комбінованого метода навчання нейронної мережі забезпечує формування стислого латентного вектора, який одночасно відображає як морфологічну структуру сигналу, так і ознаки, релевантні для діагностичної класифікації. У цьому випадку функція втрат має комбінований характер:

$$Loss = \alpha MSE + \beta CE,$$

де: α, β – вагові коефіцієнти функцій втрат, що використовуються для реконструкції сигналу та класифікації, CE – перехресна ентропія, MSE – середньоквадратична помилка [97].

Регулюючи коефіцієнти α, β , можна змінювати ваги похибок реконструкції сигналу або класифікації патологій. У ході дослідження найкраще співвідношення між точністю відновлення сигналу та класифікації було досягнуто для значень параметрів $\alpha = 0,1$ та $\beta = 0,9$ на основі оцінки перехресної ентропії та середньоквадратичної помилки [97]. Використовуючи такий підхід можливо створювати скорочені вектори ознак, орієнтовані на конкретні діагностичні завдання, наприклад налаштувати на підвищену чутливість до ППШ і ППП або інших патологій.

Крім того, використовуючи декодер у поєднанні з латентним простором, можна відтворити форму початкового сигналу, що робить архітектуру придатною не лише для формування векторів ознак, а й для стиснення ЕКГ даних зі збереженням діагностичної цінності.

Створений автоенкодер був спроектований таким чином, щоб із оригінального ЕКГ сигналу розмірністю 12×500 відліків (12 ЕКГ відведень довжиною 500 відліків) формувався стиснений вектор ознак довжиною 1×240 відліків (рис. 3.14). На (рис. 3.14 а, б) показано 1 з 12 відведень для наочності.

Використання такого латентного вектора дозволяє досягти коефіцієнта стиснення 25, що забезпечує ефективне зменшення розмірності без суттєвих втрат у якості відновлення.




Рис. 3.14. Кодування та реконструкція сигналу за допомогою розробленої моделі автоенкодера: а – оригінальний ЕКГ сигнал, б – реконструйований сигнал, в – латентний вектор ознак, отриманий за допомогою енкодера [3]

Для перевірки ефективності розробленого методу зменшення розмірності ЕКГ в реальних умовах було використано дві нейромережеві моделі. Першою НМ було обрано повнозв'язну класифікаційну нейронну мережу (рис. 3.15). Така архітектура є класичним прикладом штучної нейронної мережі, яка може бути використана для порівняльних досліджень. Ця нейронна мережа складається з послідовно з'єднаних повнозв'язних шарів.




Рис. 3.15. Архітектура нейронної мережі, що була обрана для тестування автоенкодера [3]

Другою обраною моделлю для тестування була спеціалізована НМ для класифікації ЕКГ сигналів, архітектура якої наявна в загальному доступі “Multi-ECGNet” (ECGNet) [98]. На відміну від першої обраної мережі, вона реалізує вдосконалену згорткову архітектуру з оптимізованими, полегшеними операціями, що зменшують кількість параметрів і водночас зберігають високу точність аналізу. Ключовою особливістю ECGNet є вбудований механізм уваги, який динамічно визначає, які відведення ЕКГ є найбільш інформативними, та автоматично змінює їхню вагу під час навчання. Це дозволяє мережі враховувати як часові залежності, так і залежності між відведеннями ЕКГ сигналу. Завдяки цьому модель здатна виконувати мультикласову класифікацію, виявляючи до 55 різних типів аритмій одночасно, що робить її придатною для комплексного аналізу ЕКГ у медичних дослідженнях. Для оцінювання якості роботи згорткової нейронної мережі було використано декілька відомих методів зменшення розмірності даних, з якими порівнювалась розроблена нейронна мережа автоенкодера.

Першим методом було обрано зниження частоти дискретизації. Початковий сигнал мав частоту дискретизації 500 Гц. Якщо врахувати, що найвищі частоти корисних компонентів становлять близько 150 Гц, то, згідно з теоремою Найквіста [99], для коректного відтворення таких компонентів достатньо частоти 300 Гц. Для порівняння було проведено передискретизацію сигналу до 300 Гц, 150 Гц і 75 Гц. Це дозволило оцінити вплив різного ступеня стиснення на точність класифікації. У результаті сигнал було стиснуто приблизно у 1,7, 3,3 та 6,7 разів відповідно, де коефіцієнт стиснення визначається за формулою:

$$K_{\text{стис}} = \frac{N_{\text{поч}}}{N_{\text{скор}}},$$

де $N_{\text{поч}}$, $N_{\text{скор}}$ – кількість відліків в початковому сигналі, та скороченому сигналі після стиснення.

Наступним методом, що використовувався для порівняння був метод перетворення 12-канальної ЕКГ у систему ортогональних відведень Франка за допомогою лінійних перетворень. Ще один підхід полягав у побудові результуючого вектора сигналу на основі проєкцій даних ЕКГ на вісі X, Y, Z. Цей метод дає змогу оцінити, яка частка діагностичної інформації втрачається за допомогою лінійного стиснення сигналу. Крім того, як альтернативний лінійний метод, застосовувався аналіз головних компонент (РСА). Він був обраний для порівняння з перетворенням у систему Франка. Хоча РСА може частково спотворювати морфологічну структуру ЕКГ, цей метод зберігає найбільшу дисперсію даних у просторі головних власних векторів з меншою розмірністю. Для тестування після проведення РСА аналізу було залишено три головні компоненти, що забезпечують достатню інформативність сигналу. Для перевірки ефективності методів зменшення розмірності даних та аналізу векторів ознак ЕКГ було використано відкриту базу «PTB-XL, a large publicly available electrocardiography dataset» [100]. Вона містить понад 22 тисячі електрокардіограм у 12 стандартних відведеннях і охоплює більш ніж 70 різних патологічних станів серцево-судинної системи. Для проведення порівняльного аналізу були обрані патології, діагностика яких потребує використання всіх 12 каналів ЕКГ: синдром Вольфа-Паркінсона-Уайта (СВПУ); задній лівий фасцикулярний блок (ЗЛФБ); гіпертрофія лівого шлуночка (ГЛШ); повна блокада лівої ніжки пучка Гіса (ПБЛНПГ); різні форми інфаркту міокарда, включаючи латеральний (ЛІМ), задньо-латеральний (ЗЛІМ) і нижній (НІМ); різні варіанти ішемії, включаючи ішемію нижньо-латеральної (ІНЛДМ), передньо-латеральної (ІПЛДМ), нижньої (ІНДМ) та передньо-септальної (ІПСДМ) ділянок міокарда, а також гострий інфаркт міокарда (ГІМ).

Додатково до цього списку було включено стани, що вимагають точного аналізу низькоамплітудних компонентів, зокрема (ППП) та (ППШ). Для моделювання таких сигналів до бази даних було додано штучно згенеровані

пізні потенціали дії, накладені на нормальні ЕКГ сигнали. Процес їх поширення імітувався за допомогою моделі паралельних провідностей [62]. До тренувального набору також були включені сигнали класу «норма», що дозволило сформувати збалансований набір даних для оцінювання здатності моделі розрізняти нормальні та патологічні класи ЕКГ сигналів. Показником, який відображає кількість інформації, що збереглася в сигналі після проведення процедури зменшення розмірності було обрано точність класифікації вищеописаними класифікаційними моделями. Результат порівняння зменшення розмірності ЕКГ сигналу за допомогою розробленого автоенкодера та інших розповсюджених методів зменшення розмірності ЕКГ сигналу наведено в таблиці 3.6:

Таблиця 3.6 Порівняння показників точності класифікації обраних патологій з використанням різних методів зменшення розмірності ЕКГ сигналу

Обрані методи скорочення розмірності даних	EcgNet	Повнозв'язна мережа	Ступінь стиснення
Оригінальний сигнал	75%	75%	1
Зменшення ЧД до 300 Гц	73%	75%	1,67
Зменшення ЧД до 150 Гц	71%	73%	3,33
Розроблений енкодер	68%	78%	25
Зменшення ЧД до 75 Гц	67%	72%	6,67
Сигнал в системі Франка	64%	70%	4
Застосування <i>PCA</i> [3]	59%	65%	4
Результуючий вектор за системою відведень Франка	56%	61%	12

Результати аналізу таблиці порівняння показали, що найвищу точність класифікації обидві нейромережеві моделі демонструють під час роботи з повними 12-канальними ЕКГ сигналами без попереднього стиснення. Під час використання зниження частоти дискретизації спостерігалось поступове зниження точності класифікації зі зменшенням частоти. Отже, після зниження частоти з 500 до 300 Гц точність зменшилась на 0-2%, за подальшого зниження частоти дискретизації до 150 Гц, точність знижується на 2-4%, а якщо продовжувати знижувати частоту до 75 Гц зниження точності спостерігається на рівні 3-8%. Це пояснюється втратою високочастотних компонентів, які містять важливу діагностичну інформацію.

Ще гірші результати показали методи, що передбачають лінійні перетворення для зменшення розмірності. Для РСА зафіксовано падіння точності на 10-16%, тоді як з використанням ортогональної системи Франка, точність знизилась на 5-11%. Це зниження пов'язане з втратою часової деталізації сигналу серця, необхідної для коректного визначення локальних патологій. Метод побудови результуючого вектора ознак на основі ортогональних відведень Франка показав ще суттєвіше погіршення, де точність класифікації знизилася на 14-19%, що свідчить про значну втрату інформації під час обробки сигналу.

Для обох протестованих архітектур (EcgNet і повнозв'язної нейронної мережі) використання скороченого вектора ознак побудованого на основі розробленого автоенкодера дало більш високу точність класифікації у разі найвищого ступеня стиснення. Для EcgNet точність класифікації знизилась лише на 2% від точності з використанням повнорозмірного сигналу, тоді як для повнозв'язної НМ, навпаки, спостерігалось зростання точності на 3%. Такий результат свідчить, що розроблений вектор ознак не лише зберігає

діагностичну інформацію, а й може підвищувати розрізняльну здатність моделей у задачах класифікації.

Отже, НМ із використанням розробленого скороченого вектора ознак продемонструвала найкращий баланс між рівнем стиснення та точністю класифікації. Результати підтверджують, що навіть у разі високого ступеня стиснення даних ЕКГ розроблений автоенкодер зберігає важливі діагностичні ознаки. Більш детальні результати класифікації з використанням скороченого вектора ознак порівняно з моделями, що працювали із 12-канальними ЕКГ, наведено у таблицях 3.7 та 3.8:

Згідно з аналізом результатів класифікації патологій для мережі EcgNet середня точність класифікації зменшилась із 75 % до 68 % (на 7 %). Однак зміни були нерівномірними, наприклад, для класу ЗЛІМ точність підвищилась із 58 % до 75 %, а для ППП – із 86 % до 88 %. Водночас для класів ІНДМ, ГІМ точність зменшилась відповідно з 77 % до 40 % та на 7 %. Для деяких класів, зокрема ПБЛНПГ та ППЛДМ, зміни практично відсутні. Зниження або підвищення точності класифікації з використанням скороченого вектора ознак пояснюється особливостями архітектури НМ. Для EcgNet, яка побудована на згорткових шарах, модель орієнтується насамперед на виявлення локальних закономірностей у багатоканальних сигналах ЕКГ. Тому під час стиснення вхідних даних мережа може зберігати або навіть покращувати результати для тих класів, де патологія має чітко визначені морфологічні ознаки.

Для повнозв'язної нейронної мережі точність класифікації змінюється також нерівномірно. У середньому точність зростає приблизно на 6 %. Найбільше покращення спостерігається для таких класів, як ЗЛФБ (+17 %), ППШ (+28 %), ППСДМ (+13 %), тоді як зниження зафіксовано лише для ІНЛДМ (–16 %) та ЛІМ (–2 %).

Таблиця 3.7 Порівняння результатів класифікації з використанням 12 каналної ЕКГ та скороченого вектору ознак, побудованого на її основі за допомогою нейронної мережі EcgNet

Патолог. група	EcgNet					
	Початковий сигнал			Скорочений вектор ознак		
	Точ.	Чутл.	Спец.	Точ.	Чутл.	Спец.
ЗЛФБ	0.92	0.84	0.98	0.72	0.58	0.99
СВПУ	0.88	0.76	0.99	0.88	0.78	0.99
ЛІМ	0.83	0.58	0.93	0.63	0.46	0.93
ІНДМ	0.77	0.53	0.96	0.40	0.37	0.97
ІНЛДМ	0.40	0.13	0.99	0.43	0.27	0.98
ІПСДМ	0.57	0.13	0.99	0.57	0.40	0.97
ЗЛІМ	0.58	0.45	0.99	0.75	0.75	0.98
ПБЛНПГ	0.93	0.90	0.99	0.93	0.89	0.99
ІПЛДМ	0.84	0.71	0.88	0.67	0.48	0.90
ГІМ	0.66	0.33	0.97	0.59	0.30	0.97
ІПП	0.86	0.73	0.92	0.88	0.51	0.93
ІППШ	0.90	0.83	0.98	0.83	0.67	0.94
ГЛШ	0.73	0.70	0.89	0.55	0.41	0.95
НОРМА	0.87	0.78	0.92	0.80	0.77	0.94
НІМ	0.56	0.27	0.98	0.63	0.35	0.96

Таблиця 3.8 Порівняння результатів класифікації з використанням 12 каналної ЕКГ та скороченого вектору ознак, побудованого на її основі за допомогою повнозв'язної нейронної мережі

Патолог. група	Повнозв'язна модель					
	Початковий сигнал			Скорочений вектор ознак		
	Точ.	Чутл.	Спец.	Точ.	Чутл.	Спец.
ЗЛФБ	0.78	0.60	0.99	0.95	0.87	0.99
СВПУ	0.96	0.84	0.99	0.98	0.88	0.99
ЛІМ	0.92	0.58	0.93	0.94	0.58	0.90
ІНДМ	0.7	0.40	0.96	0.67	0.58	0.91
ІНЛДМ	0.43	0.17	0.97	0.27	0.33	0.96
ІПСДМ	0.67	0.40	0.99	0.80	0.13	0.99
ЗЛІМ	0.68	0.67	0.99	0.70	0.68	0.99
ПБЛНПГ	0.89	0.88	0.99	0.86	0.86	0.99
ІПЛДМ	0.71	0.47	0.93	0.73	0.50	0.90
ГІМ	0.61	0.33	0.90	0.70	0.36	0.96
ІПП	0.73	0.39	0.94	0.83	0.43	0.94
ІППШ	0.69	0.34	0.94	0.97	0.89	0.99
ГЛШ	0.52	0.31	0.94	0.72	0.37	0.97
НОРМА	0.88	0.72	0.94	0.94	0.94	0.95
НІМ	0.66	0.33	0.97	0.70	0.42	0.96

З табл. 3.7, 3.8, видно, що точність повнозв'язної мережі є вищою. Це пояснюється тим, що згорткова мережа EcgNet краще працює з ЕКГ. Натомість латентний вектор містить більш агреговані ознаки. З використанням цих даних мережа EcgNet може втрачати свою ефективність віддаючи перевагу повнозв'язній архітектурі, яка може краще виявляти нелінійні залежності. Отримані результати свідчать, що повнозв'язна модель краще узагальнює закономірності у компактному просторі ознак. Стиснення знижує рівень шуму, усуває малозначущі патерни й тим самим зменшує ризик перенавчання, підвищуючи здатність моделі до узагальнення. Крім того, помітне підвищення точності класифікації для таких класів, як ППШ та ППП, демонструє ефективність моделі у розпізнаванні сигналів із низькоамплітудними та високочастотними складовими. Це пояснюється тим, що скорочений вектор ознак мінімізує вплив випадкового високочастотного шуму.

Висновки до розділу 3

На основі проведеного аналізу та в ході роботи над створенням нових методів попередньої обробки ЕКГ-сигналів було встановлено, що:

1. Ефективне пригнічення різноманітних перешкод, таких як дрейф ізолінії, мережеві перешкоди, м'язовий тремор та високоамплітудні нерегулярні компоненти, є критично важливим етапом обробки ЕКГ сигналів, оскільки безпосередньо впливає на точність всіх подальших діагностичних процедур.

2. Вдосконалений метод усереднення кардіоциклів орієнтований на збереження морфології низькоамплітудних компонентів за рахунок розбиття сигналу на епохи кардіоциклів з перекриттям на основі алгоритмів зменшення розмірності ознак (SVD, PCA, FA) продемонстрував вищі показники точності виділення пізніх потенціалів порівняно з класичним усередненням, особливо в умовах дуже низьких амплітуд сигналу. Даний метод може бути реалізований

в якості апаратного модуля обробки, або доданий в алгоритмічне забезпечення сигнальних процесорів, що є частиною систем на чіпі для реєстрації та попередньої обробки ЕКГ сигналів.

3. Розроблені нейромережеві моделі на основі повнозв'язних та згорткових архітектур дали можливість підвищити стійкість аналізу ЕКГ в умовах шуму шляхом видалення спотворених фрагментів ЕКГ сигналу. Використання спеціально розробленої функції втрат дозволило досягти високої точності класифікації та мінімізувати кількість хибнопозитивних передбачень. Запропоновані реалізації нейронних мереж для аналізу дозволили проектувати апаратні реалізації розглянутого підходу, як в умовах портативних мікропроцесорних так і на основі високопродуктивних обчислюваних систем. Застосування цих моделей покращило точність виявлення низькоамплітудних компонентів під час побудови усереднених кардіоциклів.

4. Розроблений метод зменшення розмірності ознак ЕКГ сигналу на основі нейромережевого автоенкодера має властивість стиснення ЕКГ сигналів зі збереженням діагностичної інформації. Комбінована архітектура автоенкодера з механізмом уваги та залишковими зв'язками забезпечила формування скороченого латентного вектора, який ефективно відображає як морфологію сигналу, так і ознаки, релевантні для класифікації патологій. Незважаючи на високий ступінь стиснення ($K_{\text{стис}} = 25$), використання цього вектора ознак дозволило не тільки зберегти, але в окремих випадках і підвищити точність класифікації різних серцевих патологій порівняно з методами лінійного зменшення розмірності. Застосування розробленого автоенкодера у складі апаратного модуля попередньої обробки ЕКГ дозволить паралельно з вихідним сигналом отримувати компактне представлення з мінімальною втратою діагностичних ознак, що може бути дуже корисним для реалізації більш продуктивних систем виявлення ЕКГ патологій на основі машинного навчання.

РОЗДІЛ 4 МЕТОДИ АВТОМАТИЗОВАНОГО АНАЛІЗУ ЕКГ СИГНАЛІВ

4.1 Методи обробки ЕКГ сигналів на основі класичних алгоритмів

Методи обробки ЕКГ сигналів на основі класичних алгоритмів – це методи, що реалізуються у вигляді послідовності обчислювальних процедур, заснованих на математичних алгоритмах цифрової обробки сигналів для автоматизованої діагностики серцевої діяльності шляхом виявлення ключових елементів кардіоциклу (Р, QRS, Т) та оцінювання їх характеристик.

Геометричний аналіз сигналу з використанням методів диференціювання дозволяє знайти точки зміни кривизни (точки перегину) сигналу [101]. Наприклад, апроксимація сумою Гауссових функцій, дозволяє моделювати патології на кшталт роздвоєння зубця Р. Для згладжування сигналу ЕКГ використовують фільтри Савіцького-Голея [102]. Стійкіші до шумів методи базуються на вейвлет-перетворенні. Кореляційний аналіз порівнює сигнал із еталоном, а метод головних компонент (РСА) виявляє приховані закономірності. Фазово-просторовий аналіз [103] будує портрет, що описує динаміку серцевої активності.

В рамках дослідження був розроблений алгоритм виявлення тахіаритмій [12], зокрема синдрому Вольфа-Паркінсона-Уайта (СВПУ) (рис. 4.1). Ця серцева патологія, що викликає передзбудження шлуночків, проявляється на ЕКГ як дельта-хвиля і підвищує ризик виникнення небезпечних аритмій.

Окремої уваги потребують фібриляція передсердь і миготлива аритмія, що можуть розвиватися на фоні СВПУ [104]. Для них є типовими висока частота електричної активності передсердь (приблизно 6–12 Гц) і поява дрібних хвиль (f-хвиль) на ЕКГ, які відображають хаотичну деполяризацію міокарда передсердь.




Рис. 4.1. Аналіз фрагменту QRS комплексу з наявністю та відсутністю дельта-хвилі: а – сегмент PR-R в нормі, б – розрахунок перегинів характеристичної лінії масштабних коефіцієнтів вейвлет перетворення для сегмента PR-R в нормі, в – скейлограма безперервного вейвлет перетворення, для сегмента PR-R в нормі, г – сегмент PR-R з наявною дельта-хвилею, д – розрахунок перегинів характеристичної лінії масштабних коефіцієнтів вейвлет перетворення для сегмента PR-R з дельта-хвилею, е – скейлограма безперервного вейвлет перетворення, для сегмента PR-R з дельта-хвилею [12]

Покладений в основу алгоритму [12] підхід спирається на безперервне вейвлет-перетворення (БВП) та формування характеристичної лінії масштабних коефіцієнтів, як інтегрального індикатора сигналу, що подається на вхід. Для отримання характеристичної лінії спершу виконується БВП із материнським вейвлетом Рікера [105]. Кількість масштабів, що було обрано, – дорівнює 8 з кроком 1, а частота дискретизації сигналу для аналізу складала 500 Гц. На отриманій скейлограмі видно, як у випадку наявності дельта-хвилі на вейвлет розкладі наявний характерний пік інтенсивності масштабних коефіцієнтів розкладу.

Далі за отриманою скейлограмою для кожного моменту часу обчислюється середнє арифметичне значень масштабних коефіцієнтів на перших восьми масштабах, утворюючи характеристичну лінію масштабних

коефіцієнтів. Особливість цієї кривої полягає в тому, що вона прибирає відхилення ізолінії сигналу та робить перегини в обраному частотному діапазоні більш виразними. Наявність дельта-хвилі відображається на формі масштабної характеристики і у часовому вікні виникає додатковий локальний максимум, що призводить до збільшення кількості перегинів на характеристичній лінії. У наведеному прикладі спостерігається шість перегинів у випадку наявності дельта-хвилі (Рис. 4.1 д), в той час, як для сигналу без наявних патологій спостерігається лише 4 перегини (Рис. 4.1 б).

Щоб надійно підрахувати перегини та зменшити вплив шумових флуктуацій, до характеристичної лінії застосовується фільтр ковзного середнього з тривалістю вікна $fs/20$ відліків, де fs – частота дискретизації фрагменту ЕКГ, що досліджується. Для підвищення точності аналізу тривалість вікна можна адаптивно змінювати на основі параметрів ЕКГ сигналу, що аналізується. Варто відмітити, що для точності порівняння до характеристичної лінії застосовується фільтр з нульовою фазою [106]. У фільтрі, що застосовується, нульова фаза зберігає часові позиції особливостей кардіоциклу, а згладжування пригнічує високочастотні коливання. Після фільтрації підраховується кількість перетинів між кривою, що була отримана після фільтрації, та початковою характеристичною лінією. Цей числовий показник використовується як проста та стійка міра складності локальної морфології ЕКГ сигналу.

Для кількісного оцінювання ступеня коливального процесу (зокрема для f-хвилі) доцільно ввести характеристичний коефіцієнт:

$$C = n_{TP \cap TP_h} \cdot STD(TP - TP_h),$$

де $n_{TP \cap TP_h}$ – кількість перегинів початкового сигналу (перетинів відрізка сигналу сегмента TP та його характеристичного вектора масштабних коефіцієнтів TP_h), $STD(TP - TP_h)$ – стандартне відхилення сигналу, отриманого після віднімання характеристичної лінії TP_h з сигналу відрізка TP .

В свою чергу, графічно процес отримання $n_{TP \cap TP_h}$, $STD(TP - TP_h)$ показано на рисунку 4.2.




Рис. 4.2. Процес отримання характеристичного коефіцієнту перегинів для інтервалу TP QRS комплексу: а – обрахунок перетинів сигналу сегмента TP з характеристичною лінією масштабних коефіцієнтів за наявності f-хвилі, б – віднімання характеристичної лінії з сигналу відрізка TP для обрахунку стандартного відхилення скорегованого сигналу за наявності f-хвилі, в – обрахунок перетинів сигналу сегмента TP з характеристичною лінією масштабних коефіцієнтів для ЕКГ в нормі, г – віднімання характеристичної лінії з сигналу відрізка TP для обрахунку стандартного відхилення скорегованого сигналу для ЕКГ в нормі [12]

Порівняння значень обрахованого характеристичного коефіцієнта C для оцінювання ефективності виявлення f-хвилі можна виконати, аналізуючи таблицю 4.1.

Таблиця 4.1 Результати обрахунку характеристичного коефіцієнта

Форма сегменту TP	$n_{TP \cap TP_h}$	$STD(TP - TP_h)$	C
TP в нормі	4	0,0142	0,0566
TP за наявності f-хвилі	6	0,0552	0,3312

Отримані значення характеристичного коефіцієнта C демонструють чітке розділення норми і патології і свідчать про високу стабільність алгоритму в задачі виявлення дельта-хвилі та f-хвилі. Висока розбіжність значень

характеристичного коефіцієнта C (0,0566 та 0,3312) означає, що детектор, побудований на основі даного алгоритму, буде стійким до шуму й варіацій сигналу.

Але, не дивлячись на це, розроблений алгоритм може мати низку обмежень. По-перше, він чутливий до вибору материнського вейвлета й масштабів (значення кількості масштабів, що дорівнює 1–8 може бути неоптимальним для інших частот дискретизації і типу відведень). По-друге, необхідно адаптивно обирати вікно згладжування ковзного середнього, адже за встановленого занадто високого або низького значення можна знизити точність виявлення клінічно значущих перегинів сигналу.

Також в рамках дослідження було вдосконалено інший алгоритм виявлення нетипових форм QRS комплексів на основі аналізу системи ізоліній [107], який передбачає поділ навчальної вибірки на кластери сигналів за схожістю їхніх морфологічних характеристик [11] (рис. 4.3).



Рис. 4.3. Блок-схема алгоритму виявлення нетипових форм QRS комплексів

На першому етапі обробки було проведено розділення ЕКГ сигналу на кардіоцикли. Після виявлення піку R була виконана сегментація кожного кардіоциклу шляхом вирізання фрагмента сигналу в діапазоні $[-50:+70]$ відліків від положення R піку. В результаті початковий ЕКГ сигнал був розділений на сегменти кардіоциклів тривалістю 120 мс.

Початковим сигналом для аналізу є ЕКГ сигнал з частотою дискретизації $f_s = 1000$ Гц, в якому наявні патологічні кардіоцикли різних типів. В процесі дослідження ЕКГ сигналів було проаналізовано наступні типи кардіоциклів: тип N (Normal beat) – нормальний синусовий комплекс, який відповідає стандартному скороченню серця без патологічних відхилень; тип A (Atrial premature beat) – передсердний екстрасистолічний комплекс, що виникає внаслідок передчасного імпульсу з передсердь; тип V (Ventricular premature beat) – шлуночковий екстрасистолічний комплекс, спричинений передчасним імпульсом із шлуночків.

Отримані фрагменти були відфільтровані смуговим фільтром Баттерворта 4-го порядку в діапазоні 0,5 – 80 Гц для видалення низькочастотного дрейфу ізоїнії та високочастотного шуму, що може спотворити процес обрахунку характеристики форми.

Відфільтрований сигнал був центрований відносно 0 та нормалізований в діапазоні амплітуд $[-1:1]$ за допомогою Z-нормалізації, що можна описати за допомогою наступної формули:

$$x_{\text{норм}} = \frac{x - \mu}{\sigma},$$

де: μ – середнє значення сигналу, σ – його стандартне відхилення

Після отримання підготовленого сигналу, для нього розраховується система ізоїній [107], яка характеризує форму ЕКГ сигналу. Для розрахунку рівнів ізоїній спочатку задається кількість ізоїній n (в даному випадку $n = 14$), а також їх порядки (тобто 2 ізоїнії для 1-го порядку, 4 – для 2-го порядку, 8 – для 3-го порядку). Для побудови ізоїнії першого порядку визначаються діапазони значень сигналу від 0 до мінімального та від 0 до максимального значення сигналу. В середині цих діапазонів обчислюється значення ізоїній за формулами:

$$L_1 = \frac{1}{2}(L_0 + x_{min}), L_2 = \frac{1}{2}(L_0 + x_{max}),$$

де: L_1, L_2 – розраховані рівні ізоліній першого порядку, x_{min}, x_{max} – мінімальні та максимальні значення сигналу, L_0 – ізолінія нульового порядку, тобто 0.

Отримані ізолінії поділяють амплітудну шкалу сигналу на 4 частини і в межах кожної частини відбувається такий самий розрахунок формуючи $L_3 - L_6$, як ізолінії другого порядку. В свою чергу, отримані ізолінії ділять амплітудну шкалу на ще більше частин, в межах яких розраховуються ізолінії старших порядків.

Чим більша кількість порядків ізоліній, що обраховано, тим більш точно вони описують форму QRS комплексу. Розташування розрахованих ізоліній на площині амплітуд отриманих кардіоциклів наведено на рис. 4.4.




Рис. 4.4. Типи кардіоциклів, форма яких описана системою ізоліній [11]

На основі отриманих амплітудних значень ізоліній будується характеристика форми, яка визначається шляхом впорядкування цих значень у порядку зростання та їх подальшого графічного представлення (рис.4.5).




Рис. 4.5. Характеристика форми системи ізоліній[11]

За допомогою сформованої системи ізоліній можна формувати кластери, наприклад, за значеннями скалярного добутку між характеристиками форми різних кардіоциклів. Для реалізації модифікованого алгоритму для кожної групи з N, A, V типами було відібрано по декілька еталонних форм кардіоциклів з патологією, шляхом усереднення меншої кількості кардіоциклів з кожної групи (рис. 4.6).




Рис. 4.6. Побудова однієї еталонної форми для кардіоциклів різних типів [11]

Порівняння отриманих характеристик форм кардіоциклів з обраними еталонними формами кардіоциклів дозволило розділити початковий набір даних на класи N, A, V шляхом аналізу значень скалярного добутку. За допомогою даного алгоритму вдалося отримати точність розпізнавання кардіоциклів на рівні 79,57% (табл. 4.2), що точніше ніж розділення на класи з використанням лише однієї еталонної форми для кожного типу (78,76%) [11].

Таблиця 4.2 Результати оцінки точності алгоритму з використанням еталонних форм патологічних кардіоциклів.

Результат класифікації алгоритму	Тип кардіоциклу			Специфічність %
	N	A	V	
N	93	42	0	68,90
A	31	82	3	70,69
V	0	0	121	100
Чутливість %	75	66,13	97,58	79,57

Даний алгоритм є чутливим до якості попередньої нормалізації, а артефакти, залишковий шум і відмінності форми кардіоциклів можуть спричиняти зсув ізоліній і спотворення опису форми. Через спосіб побудови ізоліній, дрібні морфологічні деталі згладжуються, а зі збільшенням довжини аналізованого фрагмента точність знижується. Таким чином, алгоритм не є універсальним і є придатним лише для обмеженого діапазону патологій.

4.2 Методи машинного навчання для виявлення патологічних ЕКГ сигналів

Машинне навчання як напрям штучного інтелекту, використовує алгоритми, здатні навчатися на даних та самостійно формувати правила прийняття рішень без прямого їх алгоритмічного опису. Найпоширенішим типом є навчання з учителем [108], яке ґрунтується на використанні розмічених даних. Іншим підходом є навчання без вчителя [109], де модель працює з нерозміченими даними, самостійно виявляючи закономірності, групуючи схожі сигнали або виділяючи аномалії. Комбінованим підходом є

самонавчання, яке передбачає початкове навчання моделі на розмічених даних з подальшим самостійним призначенням орієнтовних міток для нерозмічених даних і продовженням тренування [110]. Метод псевдоміток додає нерозмічені дані до навчальної вибірки, якщо впевненість моделі в їхньому прогнозі перевищує заданий поріг, наприклад, 90% [111]. Генеративний підхід використовує такі моделі, як варіаційні автоенкодери (VAE) або генеративно-змагальні мережі (GAN), для відтворення структури ЕКГ та генерації нових навчальних даних або синтетичних аномалій [112]. Архітектура «вчитель-учень» полягає в тому, що одна модель генерує псевдомітки для нерозмічених даних, а інша навчається на них, причому їхні ролі можуть змінюватися для стабілізації процесу навчання [113].

У рамках дослідження «Scalable Clustering of Complex ECG Health Data: Big Data Clustering Analysis with UMAP and HDBSCAN» було проведено експериментальну перевірку можливостей методів машинного навчання без учителя для виявлення прихованих структур у багатовимірних параметрах ЕКГ. Метою було визначити латентні підтипи та ризикові профілі, що відображають різні рівні схильності до серцевої недостатності та інших патологій [8]. Для цього застосовано масштабований підхід до кластеризації даних, так звана масштабована кластеризація даних (Scalable Data Clustering), яка поєднує метод зменшення розмірності уніфікованого наближення та метод проєкції геометричного простору (Uniform Manifold Approximation and Projection UMAP) з ієрархічною щільнісною кластеризацією (Hierarchical Density-Based Spatial Clustering of Applications with Noise HDBSCAN).

Для проведення порівняння методів машинного навчання було обрано два публічних набори даних. Перший набір містить 14 863 сигнали та відображає дані клінічно здорових осіб без серцево-судинних патологій (набір “Norm”). Другий набір включає 8 220 сигналів і представляє пацієнтів, госпіталізованих до кардіологічної клініки з діагнозом серцевої недостатності (набір “Patients”).

Для кожного із наборів було розраховано по 153 ознаки. Ознаки для дослідження було розраховано за допомогою хмарного сервісу, який може визначати широкий спектр параметрів електрокардіосигналу. Можливості даного сервісу дозволяють одночасно розраховувати велику кількість часових, частотних, комплексних морфологічних, векторних і нелінійних ознак. Такий підхід здатен забезпечити багатовимірний опис сигналу, що дозволяє виявляти приховані закономірності та відмінності навіть між близькими за формою ЕКГ сигналами. Для надійності розрахунку, всі 153 ознаки було приведено до єдиної шкали за допомогою (Universal ECG Scoring System UECG) – уніфікованої системи оцінювання ЕКГ, розробленої в Інституті кібернетики ім. В.М. Глушкова НАН України [114].

Першим етапом для підвищення якості кластерного аналізу було необхідно виконати зменшення розмірності даних. З цією метою до отриманої вибірки даних було застосовано метод уніфікованого відображення апроксимації та проекції (Uniform Manifold Approximation and Projection, UMAP) та зменшено розмірність простору розрахованих параметрів до двовимірною. Наступним етапом було проведено кластеризацію за допомогою алгоритму ієрархічної густини кластеризації на основі просторових сполучень (Hierarchical Density-Based Spatial Clustering of Applications with Noise, HDBSCAN). В результаті вдалося отримати декілька чітко відокремлених, щільно згрупованих кластерів. Параметри алгоритмів було налаштовано таким чином, щоб отримати мінімальну кількість точок, що не ввійшли до жодного з кластерів. У дослідженні порівнювалися два типи метрик відстаней, а саме евклідову та манхеттенську відстані [115].

Після вибору параметрів кластерного аналізу було проведено експеримент із навчанням моделі кластерного аналізу HDBSCAN на наборі даних здорових осіб (Norm) та подальшою її проекцією на вибірку пацієнтів із серцевою недостатністю (Patients) (рис. 4.7). Параметри моделі були налаштовані для виділення кластерів з чіткими межами [8]. Такий підхід

дозволив виявити структурні відмінності між групами та визначити потенційні латентні групи ризику. У зворотному експерименті модель навчалася на даних групи пацієнтів і проєктувалася на набір “Norm”, що дало змогу перевірити стабільність кластерної структури та взаємну відповідність виявлених груп (рис. 4.8).




Рис. 4.7. Результати кластеризації за допомогою UMAP+HDBSCAN та евклідової метрики: а – кластери отримані під час навчання на наборі “Norm”, б – кластери отримані після проєкції на набір “Patients” [8]

На рисунку видно два чітко відокремлені кластери у двовимірному просторі, що демонструють відмінності між групами здорових осіб (Norm) та осіб з серцевою недостатністю (Patients). На графіках (рис. 4.7 а, б) видно, що один із кластерів, що розташований у правій частині простору відповідає більшій кількості здорових осіб, тоді як інший (лівий кластер) включає пацієнтів з потенційними відхиленнями серцевої діяльності.




Рис. 4.8. Результати кластеризації за допомогою UMAP, HDBSCAN та евклідової метрики: а – кластери, які отримано під час навчання на наборі “Patients”, б – кластери, які отримано після проєкції на набір “Norm” [8]

У зворотному експерименті модель, навчена на даних пацієнтів із серцевою недостатністю, застосовувалася до вибірки «Norm». У результуючій вибірці «Patients» утворилися три кластери зі значеннями параметрів для норми, патології, та проміжними. Під час проєкції на здорову вибірку структура частково зберіглася. Перший кластер став щільнішим і зайняв більшу частину простору, другий кластер значно скоротився, а третій практично зник. Це означає, що пацієнти з найвиразнішими патологіями (другий кластер) мають унікальні показники ЕКГ, які практично не властиві клінічно здоровим особам. Отже другий кластер ідентифікує групу високого серцевого ризику, а перший – низького або помірного ризику.

За результатами досліджень було розроблено алгоритмічне забезпечення на мові програмування Python [84], для подальшого впровадження в системи аналізу та обробки ЕКГ сигналів.

Первинні набори даних містили по 153 параметри для кожного ЕКГ сигналу, однак під час етапу попередньої статистичної обробки було виявлено кілька десятків ознак (приблизно 10–15 % від загальної кількості), що не несли

діагностичної інформації. Наприклад, частина параметрів мала нульову дисперсію або постійні значення в усіх випадках, тому їх було вилучено з подальшого аналізу автоматично.

Після цього було проведено оцінювання інформативності решти показників. Для цього застосовували t-тест Стьюдента порівняння середніх, аналіз стандартних відхилень і коефіцієнт зсуву моди [8], який характеризується відношенням різниці між модами розподілів ознаки в групах «Norm» і «Patients» до середнього за модулем значення цих мод. За цими критеріями частину ознак було визначено як малоефективні, адже вони не демонстрували статистично значущих відмінностей між групами.

У результаті багатоступеневого статистичного аналізу було виокремлено приблизно 25-30 ознак що мали найвищу здатність до розділення груп «Norm» і «Patients». До них увійшли як традиційні амплітудно-часові характеристики ЕКГ, так і складні інтегральні показники, отримані в межах «Universal Scoring System» [114]. Серед них кут α -QRS у фронтальній площині (Alpha QRS Angle in the Frontal Plane), аналіз флуктуацій з виключенням тренду (Detrended Fluctuation Analysis, DFA), потужність високочастотного діапазону (High-Frequency Power, HF), зміщення сегмента ST у різних відведеннях (ST Dislocation), співвідношення амплітуд R/S та Q/R (R/S та Q/R Ratios), нормалізована амплітуда зубця T (T Amplitude Normalized), загальна спектральна потужність (Total Power), середньоквадратичне відхилення послідовних різниць інтервалів (RMSSD), стандартне відхилення всіх NN-інтервалів (SDNN) та потужність дуже низькочастотного спектра (Very-Low-Frequency Power, VLF), та інші показники варіабельності серцевого ритму. Саме вони формували основу простору, у якому алгоритм HDBSCAN зміг виділити 3-5 кластерів із чіткими межами. Однак така кількість кластерів свідчить, що поточна модель не забезпечує достатньої роздільної здатності для побудови багатокласової класифікації, яка могла б однозначно ідентифікувати широкий спектр підтипів серцевих аритмій.

4.3 Нейромережеві методи для виявлення аритмій на ЕКГ сигналах

Повнозв'язні мережі (рис.4.9), як найпростіший тип нейронних мереж, застосовуються переважно для попередньо обчислених числових ознак ЕКГ, але їх ефективність обмежена для роботи з довгими сигналами, де важливо аналізувати амплітудно-часову структуру.




Рис. 4.9. Структура повнозв'язної нейронної мережі

Навчання коефіцієнтів нейронів відбувається шляхом мінімізації функції втрат, яка являє собою міру відхилення між прогнозом моделі та реальними еталонними даними. Основою обчислень у кожному нейроні є зважена сума вхідних сигналів, яка описується формулою:

$$S = \sum_{i=1}^n w_i x_i + b,$$

де x_i – вхідні значення, w_i – вагові коефіцієнти нейрона, b – параметр нейрона, який дозволяє зсунути поріг активації та робить модель більш стійкою до вхідних значень різного масштабу, що підвищує гнучкість і точність апроксимації.

Отримана сума S передається на функцію активації $f(s)$, яка визначає ступінь збудження нейрона у відповідь на вхідний сигнал. Функції активації забезпечують нелінійність мережі та дають змогу моделі відображати складні залежності [116].

Під час навчання ваги w_i і зміщення b оновлюються за допомогою алгоритму градієнтного спуску, який обчислює градієнти функції втрат відносно кожного параметра та поступово змінює їх у напрямку зменшення похибки. Розмір кроку оновлення ваг визначається параметром швидкості навчання (learning rate). На практиці часто використовуються вдосконалені варіації градієнтного спуску, під назвою “Adam”, “RMSprop”, “Adagrad” [117], які автоматично підлаштовують швидкість навчання для кожного параметра.

Існують різні нейромережеві методи для виявлення аритмій на ЕКГ, зокрема згорткові НМ [118] ефективно аналізують морфологію ЕКГ, автоматично виявляючи комплекси QRS і зубці Р та Т, тоді як рекурентні мережі, зокрема LSTM і GRU [118], дозволяють вивчати часову динаміку сигналу, але мають високі обчислювальні вимоги. Більшість цих обмежень усувають трансформери з механізмом уваги [118], однак їхня обчислювальна складність обмежує роботу з довгими сигналами та невеликими вибірками. Сіамські нейронні мережі використовують дві ідентичні підмережі (рис. 4.10) для перетворення ЕКГ сигналів у вектори, схожість яких оцінюється за метриками відстані, демонструють кращі результати за обмежених навчальних вибірок і саме тому були обрані як базова архітектура для розробки методу виявлення аритмій та супутніх патологій на ЕКГ [10].




Рис. 4.10. Архітектура класичної сіамської нейронної мережі [10]

Для тренування сіамської нейронної мережі використовувалася база даних «РТВ-XL» [59], що містить приблизно 22 тисячі 10-секундних ЕКГ сигналів у 12 відведеннях. З 70 наявних патологій для дослідження було відібрано 18 типів аритмій та 19 супутніх захворювань, включаючи інфаркт міокарда та фібриляцію передсердь. Висока роздільна здатність та частота дискретизації зареєстрованих сигналів (16 біт, 500 Гц) забезпечила можливість аналізу ЕКГ для виявлення пізніх потенціалів (ППП та ППШ).

Сигнали з ППП та ППШ були синтезовані штучно шляхом накладання згенерованих потенціалів дії на нормальну ЕКГ з використанням моделі паралельних провідностей [62]. Через нерівномірний розподіл даних між класами, де деякі патології мали менше 200 спостережень, було застосовано аугментацію даних. Вона включала додавання гармонійного шуму, дрейфу ізолінії та фізіологічних артефактів з унікальними параметрами для кожного спостереження. Для класів із понад 1500 спостережень використовувалася фільтрація за допомогою НМ для видалення зашумлених сигналів [9].

На початку дослідження з метою попередньої обробки ЕКГ сигналів, дані з дванадцяти каналів оброблялися за допомогою низькочастотного фільтра Баттерворта п'ятого порядку з частотою зрізу 150 Гц. Для усунення низькочастотних перешкод було застосовано високочастотний фільтр Баттерворта третього порядку з частотою зрізу 0,5 Гц. Крім того, перешкоди зумовлені впливом синфазної складової електромережі в сигналах ЕКГ були ефективно видалені за допомогою цифрових загороджувальних фільтрів другого порядку, налаштованих на частоти зрізу 50 та 60 Гц з коефіцієнтом добротності $Q = 50$. Усі сигнали піддавалися фазово-нейтральній фільтрації, що забезпечувала збереження фазової структури сигналу без спотворень. Загальна частотна характеристика каскаду запропонованих фільтрів наведена на рис. 4.11, б. Для зменшення розмірності даних було застосовано перетворення 12-ти каналної ЕКГ в систему відведень Франка (X, Y, Z) [17], а також розрахунок характеристичного вектора $R(t)$. На одному з фінальних

етапів було здійснено нормалізацію отриманих результуючих векторів шляхом масштабування сигналів відносно середньої амплітуди R-піків для кожного спостереження. На фінальному етапі обробки для кожного результуючого вектора ЕКГ сигналу довжиною 5000 відліків, було побудовано усереднений кардіоцикл довжиною 500 відліків та тривалістю одна секунда (рис. 4.11, а). Часові межі виділення QRS-комплексу відносно R-піку визначалися на основі аналізу моди розподілу RR-інтервалів, що дозволяло зберігати діагностично значущі ознаки під час сегментації.




Рис. 4.11. Процес попередньої обробки ЕКГ сигналу для розробленої нейронної мережі [10]: а – блок-схема процесу попередньої обробки, б – частотна характеристика фільтра попередньої обробки сигналу ЕКГ

Отже, нормалізований результуючий вектор та сформований усереднений кардіоцикл використовувалися як вхідні дані для нейронної мережі. Такий підхід дозволяв зберігати детерміновані повторювані морфологічні компоненти ЕКГ, які отримано з тривалого фрагмента сигналу, водночас забезпечуючи можливість точного аналізу морфології кардіоциклу завдяки коротшому але більш детальному усередненому представленню.

Сіамська нейронна мережа для якісного навчання вимагає наявності еталонних зразків сигналів для кожної патології. Тому для вирішення цієї проблеми було застосовано аналіз головних компонент (РСА) (рис. 4.12).




Рис. 4.12. Формування вектору ознак за допомогою PCA: а – вектори SVD розкладу 100 усереднених кардіоциклів, б – сума перших п'яти векторів SVD розкладу [10]

Використання сіамської нейронної мережі для класифікації ЕКГ патологій дозволяє не запам'ятовувати конкретні ознаки, а навчитися виявляти схожість між сигналом, що досліджується, та еталонним вектором ознак, побудованим на основі обмеженої вибірки (рис. 4.13).




Рис. 4.13. Приклад сигналу та вектору ознак, що подаються на входи нейронної мережі: а – усереднений кардіоцикл, б – результуючий вектор ЕКГ сигналу, в – результат SVD розкладу 100 усереднених кардіоциклів з патологією, г – результат SVD розкладу 100 векторів ознак з патологією [10]

На рисунку представлено приклад сигналів, що подаються на входи сіамської нейронної мережі. Кожен сигнал складається з двох компонентів, а саме усередненого кардіоциклу (рис. 4.13 а, в), який містить детальну інформацію про морфологію кардіоциклу, а також фрагмента ЕКГ сигналу (рис. 4.13 б, г), що містить часові характеристики електричної активності серця на більш тривалому часовому інтервалі та є критично важливим для виявлення порушень ритму.

Для багатокласової класифікації аритмій та супутніх патологій була розроблена глибока сіамська нейронна мережа на основі згорткових шарів, архітектура якої наведена на рис.4.14.




Рис. 4.14. Архітектура спроектованої сіамської нейронної мережі для розпізнавання серцевих патологій [10]

Оскільки в сіамських нейронних мережах дві підмережі, що навчаються, є ідентичними, то на рисунку детально зображена архітектура тільки однієї частини (Підмережа 1). На вхід однієї підмережі подавався трансформований ЕКГ сигнал, отриманий від певного пацієнта, а на вхід іншої підмережі – сформований вектор ознак для патології, що досліджувалась. В навчанні моделі використовувалися різні вектори ознак для однієї патології. В

розглянутій нейронній мережі (Підмережа 1) різні частини вхідного вектора аналізуються двома послідовностями шарів. Перша послідовність націлена на виділення ознак з усередненого кардіоциклу.

Друга послідовність виділяє ознаки з десяти секундного вектора ЕКГ. В обох послідовностях першими шарами є згортки, що виділяють з сигналу ознаки зі ступенем узагальнення, що підвищується. В послідовності, що обробляє вектор ЕКГ, спочатку йде шар пулінгу, який скорочує кількість вхідних даних з 5000 відліків до 1000, та виконує передискретизацію з фокусуванням на максимумах. Після згорткових шарів, в обох послідовностях наявний шар розгортки (Flatten), який перетворює багатоканальний результат згортки в одноканальну послідовність для передачі на повнозв'язний шар нейронів. В обох послідовностях використовується шар відключення нейронів (Dropout), який відключає 10%-20% випадкових нейронів під час навчання та шар нормалізації міні-вибірки (batch normalization). Ці шари застосовуються для збільшення узагальнюючої здатності моделі та зменшення можливого перенавчання. Кожна послідовність завершується декількома повнозв'язними шарами, що послідовно зменшують кількість результуючих ознак.

Після проходження обох підмереж формується результуючі вектори довжиною 500 відліків, які порівнюються за допомогою дельта функції, яка оцінює відстань між векторами. Останній повнозв'язний шар, що використано після дельта функції, визначає наскільки близька є відстань між вектором ЕКГ та вектором ознак певної патології [89]. Результуюче значення останнього шару дорівнює 1, якщо відстань мала (виявлено патологію) і – 0, якщо відстань велика (шукану патологію не виявлено).

Результати навчання розробленої сіамської нейронної мережі порівнювалися з результатами навчання спеціалізованої архітектури «ECGNet» [98], яка навчалася на тому ж наборі тренувальних даних. Мережа «ECGNet» тренувалась на тих самих тренувальних даних, що і розроблена

згорткова мережа. Відмінність була лише в форматі результуючих даних. Нейронна мережа «ECGNet» повертала результат у вигляді вектора довжиною 38 відліків, де кожен відлік відповідав за певну патологію та мав значення 0 – патологія відсутня та 1 – присутня. Для кожної нейронної мережі розмір міні-вибірки (batch size) був обраний у кількості 200 спостережень, навчання тривало 100 епох. Швидкість навчання була встановлена показником $\eta=0,001$. Оцінювання якості роботи нейронних мереж виконувалося окремо для кожного класу патологій у вигляді бінарної класифікаційної задачі.

Для забезпечення коректності результатів тестові вибірки формувалися врівноваженими за кількістю зразків із наявністю та відсутністю відповідної патології. Порівняння моделей здійснювалося на однакових тестових вибірках. Середня точність моделі ECGNet склала 68% тоді як розроблена мережа показала точність 72%. Результати тренування сіамської нейронної мережі для виявлення аритмій та супутніх патологій наведено у таблицях 4.3, 4.4.

Аналізуючи табл. 4.3 і 4.4 можна зробити висновок, що майже для кожної патології розроблена нейронна мережа є більш точною ніж мережа «ECGNet». Середня точність класифікації ЕКГ патологій склала 0,68 для мережі «ECGNet» та 0,72 для розробленої сіамської нейронної мережі.

Отже запропонована сіамська архітектура може підвищити точність класифікації ЕКГ патологій. Найбільше підвищення точності серед патологій, розмір вибірки яких перевищує 1000 спостережень, склало 19% для «Блокада лівої передньої гілки», за розміру вибірки, що менше ніж 1000 – 28% для «Ішемія в антеролатеральних відведеннях» і 19% для «Латеральний інфаркт міокарда» за розміру тренувальної вибірки менше ніж 200.

Середнє покращення в точності виявлення ППШ та ППП склало 9%. Отже, розроблена архітектура також краще підходить для виявлення патологій з наявними низькоамплітудними ознаками.

Таблиця 4.3 Порівняння точності класифікації серцевих патологій за допомогою розробленої згорткової нейронної мережі та «ECGNet»

Патологія (кількість спостережень)	ECGNet/розроблена мережа
Передсердна екстрасистоія (383)	0,52 / 0,68
Фібриляція передсердь (1197)	0,73 / 0,80
Синусова аритмія (686)	0,50 / 0,60
Синусова тахікардія (888)	0,72 / 0,87
Синусова брадикардія (517)	0,64 / 0,78
Надшлуночкова аритмія (409)	0,62 / 0,77
Надшлуночкова тахікардія (149)	0,99 / 0,96
Пароксизм. надшлуночкова тахікардія (160)	0,99 / 0,96
Бігемінія, невідомого походження (167)	0,91 / 0,82
Шлуночкова екстрасистоія (920)	0,72 / 0,78
Блокада AV-вузла першого ступеня (710)	0,51 / 0,66
Повна блокада правої ніжки пучка Гіса (462)	0,64 / 0,87
Повна блокада лівої ніжки пучка Гіса (559)	0,94 / 0,88
Неповна блокада пр. ніжки пучка Гіса (757)	0,53 / 0,67
Блокада лівої передньої гілки (1038)	0,53 / 0,72
Блокада лівої задньої гілки (192)	0,60 / 0,72
Синдром Вольфа-Паркінсона-Уайта (239)	0,90 / 0,94
Подовжений PR інтервал (281)	0,51 / 0,57
Гіпертрофія лівого шлуночка (1431)	0,56 / 0,69

Таблиця 4.4 Порівняння точності класифікації серцевих патологій за допомогою розробленої згорткової нейронної мережі та «ECGNet»

Патологія (кількість спостережень)	ECGNet/розроблена мережа
Гіпертрофія правого шлуночка (141)	0,65 / 0,83
Вольт. критерії гіпертрофії лів. шлун. (655)	0,52 / 0,62
Перевантаження лівого передсердя (390)	0,51 / 0,64
Перевантаження правого передсердя (281)	0,79 / 0,86
Неспецифічна ішемія (918)	0,59 / 0,74
Ішемія в антеролатеральних відвед. (607)	0,50 / 0,78
Ішемія в нижніх відведеннях (204)	0,51 / 0,58
Ішемія в інферолатеральних відвед. (190)	0,53 / 0,56
Ішемія в антеросептальних відвед. (160)	0,51 / 0,71
Нижній інфаркт міокарда (1532)	0,51 / 0,63
Антеросептальний інфаркт міокарда (1242)	0,56 / 0,71
Передній інфаркт міокарда (336)	0,51 / 0,59
Антеролатеральний інфаркт міокарда (211)	0,54 / 0,68
Інферолатеральний інфаркт міокарда (403)	0,50 / 0,59
Латеральний інфаркт міокарда (169)	0,50 / 0,69
Подовження QT-інтервалу (348)	0,68 / 0,87
Зміни ST-T під час аневризми шлун. (142)	0,86 / 0,87
Пізні потенціали передсердь (800)	0,50 / 0,58
Пізні потенціали шлуночків (800)	0,50 / 0,60

Варто зазначити, що точність класифікації ППШ та ППП складає близько 60 %. Таку точність можна пояснити тим, що інші патології в вибірці мають більш виражені ознаки, які більше впливають на вагові коефіцієнти нейронної мережі. Для розв'язання цієї проблеми необхідно додатково використовувати методи виділення низькоамплітудних компонентів ЕКГ. Крім того, серед отриманих результатів, були наявні класи патологій, точність класифікації яких була низькою, як з використанням розробленої нейронної мережі, так і за допомогою «ECGNet». Низька точність класифікації проявляється переважно під час виявлення інфаркту та ішемічної хвороби серця. Для детектування подібних патологій необхідно аналізувати амплітуди піків QRS комплексів в різних відведеннях. Розрахунок результуючого вектора ЕКГ за тривимірним представленням XYZ згладжує просторові відмінності піків, що ускладнює виявлення подібних патологій. Слід зазначити, що в табл. 4.3, 4.4 представлено патології, для яких навіть за умов обмеженого розміру вибірки спостерігається висока точність класифікації. Це переважно стани, що характеризуються вираженими порушеннями ритму, зокрема «Надшлуночкова тахікардія». Наявність чітко окреслених електрокардіографічних ознак робить такі патології легше ідентифікованими нейронною мережею, що сприяє підвищенню точності їх діагностики.

Ще одним підходом до вдосконалення нейромережових методів може бути використання адаптивних функцій активації, які дають можливість збільшити чутливість моделей до низькоамплітудних змін і в результаті збільшити точність розпізнавання різнорідних патологій на ЕКГ. Функції активації є невід'ємною частиною нейронних мереж, оскільки вони вносять нелінійність, необхідну для моделювання складних залежностей у даних ЕКГ. Найпоширенішими функціями є ReLU та Sigmoid [119]. ReLU забезпечує швидке обчислення та допомагає уникнути насичення, тоді як Sigmoid зручна для бінарної класифікації, нормуючи вихід у діапазон (0;1). Однак їхній

основний недолік – схильність до згасання градієнтів у глибоких мережах та поява «мертвих» нейронів.

Для подолання цих обмежень використовують модифіковані функції активації. Експоненціальна лінійна функція (ELU) [120] зменшує ефект згасання градієнтів завдяки експоненційній характеристиці для від'ємних значень. Функція Swish [119], що має плавне згасання, менш схильна до створення «мертвих» нейронів [121]. Перспективним напрямком є функції з параметрами, що навчаються, такі як параметрична ReLU [122] та кусково-лінійна функція (PLU) [123]. Вони дозволяють мережі адаптувати параметри активації під час навчання, підвищуючи гнучкість і точність моделі, особливо під час роботи з неоднорідними даними, як-от низькоамплітудні ППП та ППШ. Дослідження [124, 125] підтверджують, що такі функції покращують точність класифікації, прискорюють збіжність і мінімізують проблеми з градієнтами. Однак навіть сучасні функції активації можуть стикатися з проблемою згасання або вибуху градієнтів під час навчання через метод зворотного поширення похибки. Це відбувається, коли градієнти стають надто малими або великими внаслідок накопичення сигналів після проходження через шари мережі, що призводить до нестабільності навчання та ускладнює збіжність моделі. З метою усунення цих ефектів було розроблено адаптивну функцію активації, яка змінює свою форму, та передавальну характеристику в процесі навчання, зменшуючи вплив насичення та різкого згасання коефіцієнтів НМ до нуля (рис. 4.15). Запропонована адаптивна функція активації описується наступною формулою:

$$f_a(x) = \begin{cases} \sigma(a_1) * -1 * x, & \text{якщо } x < 0, \\ x, & \text{якщо } 0 \leq x \leq 1, \\ \sigma(a_2) * (-x + 1) + 1, & \text{якщо } x > 1, \end{cases}$$

де $\sigma(a) = \frac{1}{1+e^{-a}}$ – параметр, що фіксує нахил прямих (які є складовими адаптивної функції активації) в межах другого та четвертого квадранту координатної площини та коефіцієнт нахилу прямої в діапазоні $[0, 1]$.

У теорії нейронних мереж як основні рекомендовані властивості функцій активації зазвичай розглядають: нелінійність; диференційовність; обмеженість похідної; обмеженість діапазону значень. Розроблена функція активації є нелінійною, оскільки не може бути зведена до лінійної функції на всій множині дійсних чисел. Це обумовлено різними коефіцієнтами нахилу на окремих інтервалах області визначення. Функція є неперервною на діапазоні дійсних чисел та диференційовною майже на всій області визначення. Недиференційовність має місце лише в точках $x = 0$ та $x = 1$, що є типовим для ReLU-подібних функцій активації. Похідна функції за модулем задовольняє умову $|f'(x)| \leq 1$, що в свою чергу задовольняє умову контрольованості масштабу похідної. Запропонована функція активації не є обмеженою за значеннями на всій множині дійсних чисел, але за межами інтервалу $[0, 1]$ функція має стискаючий характер, оскільки модуль її похідної на цих ділянках є меншим за одиницю. Унаслідок цього під час послідовного застосування функції в шарах нейронної мережі значення активацій, що виходять за межі інтервалу $[0, 1]$ поступово стискаються до цього діапазону. Отже запропонована адаптивна функція активації відповідає основним рекомендованим властивостям функцій активації та може бути використана як функція активації в нейронних мережах.




Рис. 4.15. Графік розробленої адаптивної функції активації [7]

Функцію вважають стискаючою на певному інтервалі, якщо абсолютне значення її похідної в цьому інтервалі менше одиниці. Отримана функція є стискаючою, оскільки на більшості інтервалів її похідна за модулем менша за одиницю. Зокрема, для області $x < 0$ похідна має вигляд $f'(x) = \sigma(a_1)$, а для $x > 1$ похідна має вигляд $f'(x) = \sigma(a_2)$, де $\sigma(a) \in (0; 1)$, що підтверджує властивість стиснення. В свою чергу, для області $0 \leq x \leq 1$ функція не є стискаючою, оскільки похідна має вигляд $f'(x) = 1$. Відповідно до теореми Банаха про нерухому точку [126], послідовне застосування стискаючого відображення приводить будь-яку послідовність до фіксованих точок $x_1 = 0, x_2 = 1$. Така поведінка функції забезпечує стабільність навчання нейронної мережі та зменшує ймовірність виникнення проблем згасання або вибуху градієнтів.

Для дослідження впливу активаційних функцій, що навчаються, на результати класифікації ЕКГ сигналів, було використано повнозв'язні нейронні мережі. Для побудови та тестування архітектур нейронних мереж було обрано декілька типів адаптивних активаційних функцій, а саме [7]: узагальнена логістична функція; функція «ReLU» зі зсувом; параметрична функція «ReLU»; кусково-лінійна функція; власна розроблена функція активації.

У якості тестової вибірки для проведення дослідження було використано базу даних “PTB-XL: a large publicly available electrocardiography dataset” [59] а також сигнали ЕКГ з наявними ППП та ППШ, що відповідали класам «Наявність ППП» та «Наявність ППШ». Сигнали для тренування були отримані шляхом додавання штучно змодельованих пізніх потенціалів дії до сигналів ЕКГ з бази даних, які належали до класу норми. Формування процесу поширення потенціалів дії здійснювалося з урахуванням моделі паралельних провідностей [62]. Загальний обсяг тренувальної вибірки становив 3500 спостережень, серед яких близько 750 містили ППП та 750 – ППШ. Оцінювання точності здійснювалось на основі матриці невідповідностей

(Confusion matrix). До основних метрик належать чутливість (sensitivity), специфічність (specificity), точність (accuracy).

Нейронна мережа, що використовувалась для тестування адаптивних функцій активації, наведена на рисунку 4.16.




Рис. 4.16. Архітектура нейронної мережі для тестування адаптивних функцій активації [7]

Створена для тестування нейронна мережа складається з чотирьох повнозв'язних шарів (Dense), архітектуру яких подано на рис. 4.16. Після кожного з цих шарів розташована адаптивна функція активації, параметри якої підлягають навчанню. Після другого прихованого шару додано шар нормалізації міні-вибірки (Batch Normalization), який забезпечує стабільність і прискорює процес оновлення градієнтів під час тренування. Завдяки цьому вирівнюється розподіл даних між епохами, що допомагає уникнути різких змін значень вагових коефіцієнтів і покращує збіжність моделі. Для запобігання перенавчанню застосовується шар виключення (Dropout), який випадковим чином деактивує частину нейронів у процесі навчання. На вхід мережі подавався усереднений кардіоцикл тривалістю 1 с, а завданням було

визначення наявності пізніх потенціалів (позначення: 1 – наявні, 0 – відсутні). Для тестування було створено дві окремі класифікаційні моделі, перша навчалася виявляти ППШ, а друга – ППП.

Оновлення коефіцієнтів під час навчання адаптивної функції активації здійснювалося не для кожного нейрона окремо, а для всього шару одночасно. Це призводило до більш виражених змін у параметрах активації, оскільки вони враховували вплив градієнтів від усіх нейронів шару в сукупності. Нижче описано процес оновлення коефіцієнтів адаптивної функції активації під час навчання.

Функція активації, що навчається, може бути представлена узагальненою логістичною функцією:

$$y = \sigma(x_k) = \frac{1}{1 + e^{-a(x_k - b)}},$$

де x_k – вхідне значення функції активації, y – значення функції активації, a – параметр, що навчається та визначає крутизну функції, b – параметр, що навчається, визначає зсув функції по вісі x_k .

Тоді у процесі зворотного поширення помилки з використанням градієнтів помилок, параметри a , b на кожній ітерації j оновлюються наступним чином:

$$a_{j+1} = a_j - \eta \frac{\partial E}{\partial a_j}, \quad b_{j+1} = b_j - \eta \frac{\partial E}{\partial b_j},$$

де η – швидкість навчання, $\frac{\partial E}{\partial a}$, $\frac{\partial E}{\partial b}$ – градієнти помилок за параметрами a , b .

Градієнти помилок на кожній ітерації j за параметрами a та b можна розрахувати за наступними формулами:

$$\frac{\partial E}{\partial a_j} = \sum_{i=1}^N \frac{\partial E}{\partial y_i} * \frac{\partial y_i}{\partial a_j}, \quad \frac{\partial E}{\partial b_j} = \sum_{i=1}^N \frac{\partial E}{\partial y_i} * \frac{\partial y_i}{\partial b_j},$$

де $N = M \times B$, M – кількість нейронів у шарі що навчається, B – розмір міні-вибірки під час тренування.

На рис. 4.17 подано результати побудови кривих навчання нейронних мереж, побудованих для класифікації сигналів ЕКГ у нормі та з наявними низькоамплітудними компонентами (ППШ, ППП). В результаті порівняння сигмоїдних функцій активації (рис. 3. а) можна побачити, що функція активації, що навчалась, показала більш різке падіння функції втрат «Huber Loss» [127] в діапазоні від 10 до 60 епохи. Під час наближення до останньої дев'яностої епохи втрати двох функцій активації стають близькими. Більша швидкість збіжності нейронної мережі з функцією активації, що навчається, також описується площами під кривою навчання, що занесено в таблицю 4.5.




Рис. 4.17. Криві навчання нейронної мережі під час розпізнавання ПППШ із використанням адаптивних та непараметричних функцій активації: а – порівняння сигмоїдальних функцій активації, б – порівняння лінійних і кусково-лінійних функцій [7]

Таблиця 4.5 Порівняння впливу функцій активації на точність та швидкість тренування нейронної мережі для розпізнавання ППШ

Функція активації	Точн. ППШ	Чутл. ППШ	Спец. ППШ	Площ. ППШ
Сигмоїдна функція	92,68	92,91	92,12	3,19
Узагальнена логістична функція	93,18	93,24	93,14	2,93
Функція «ReLU»	91,41	90,88	93,01	2,46
Функція «ReLU» зі зсувом	92,93	93,24	92,21	2,14
Параметрична функція «ReLU»	91,90	92,23	90,91	2,40
Кусково-лінійна функція	92,91	94,93	86,87	5,24
Розроблена функція	94,68	94,59	94,95	2,44

У табл. 4.5 та 4.6 подано узагальнені результати впливу різних функцій активації на точність навчання нейронної мережі. Ці показники розраховувалися окремо для задач виявлення ППШ і ППП після завершення 90 епох навчання. Отримані результати свідчать, що узагальнена логістична функція активації демонструє менше значення площі під кривою навчання, ніж класична сигмоїдна функція, що не навчається. Це вказує на швидшу збіжність нейронної мережі під час використання адаптивного варіанта функції. Аналогічно встановлено, що ReLU зі зсувом і параметрична ReLU (PReLU) мають нижчі значення площі під кривою навчання, ніж стандартна ReLU, що пояснюється кращою адаптацією до низькоамплітудних сигналів ЕКГ.

Таблиця 4.6 Порівняння впливу функцій активації на точність та швидкість тренування нейронної мережі для розпізнавання ППШ

Функція активації	Точн. ППШ	Чутл. ППШ	Спец. ППШ	Площ. ППШ
Сигмоїдна функція	90,38	95,61	74,75	4,01
Узагальнена логістична функція	91,39	97,64	72,73	3,68
Функція «ReLU»	89,87	96,28	70,71	4,44
Функція «ReLU» зі зсувом	91,65	96,96	75,76	3,44
Параметрична функція «ReLU»	90,63	96,96	71,72	4,22
Кусково-лінійна функція	91,14	98,31	69,70	4,31
Розроблена функція	91,68	95,55	79, 83	3,16

Порівняльний аналіз результатів класифікації показав, що узагальнена логістична функція забезпечує вищу точність класифікації, ніж звичайна сигмоїдна функція, як для ППШ, так і для ППП. Водночас ReLU зі зсувом і PReLU демонструють перевагу над класичною ReLU у розпізнаванні обох типів пізніх потенціалів. Крім того, аналіз результатів, наведених у таблицях, показав, що використання запропонованої адаптивної функції активації забезпечує меншу площу під кривою навчання (Площ. ППП), що свідчить про швидшу збіжність нейронної мережі. Також застосування цієї функції дозволило отримати найвищі показники точності класифікації для виявлення патологій типу ППШ та ППП.

Додатково було проведено аналіз впливу архітектури та глибини нейронної мережі на ефективність навчання функцій активації. З цією метою тестову модель було модифіковано шляхом додавання додаткових шарів (рис.4.18).




Рис. 4.18. Архітектура нейронної мережі з наявними «надлишковими» шарами для тестування адаптивних функцій активації [7]

На рис. 4.18 червоним кольором позначено області мережі, де під час навчання спостерігається уповільнене накопичення градієнтів, що було виявлено під час аналізу процесу навчання архітектури нейронної мережі з наявними «надлишковими» шарами. Виходячи з цього, шари 1a-1b на рис. 4.18 можуть бути замінені одним шаром 1г або, за потреби, повністю вилучені, не погіршуючи загальної ефективності моделі.

Зміна швидкості накопичення градієнтів також впливає на швидкості зміни адаптивних функцій активації, та відповідно може відобразитися на швидкості зміни їх форми (рис. 4.19):




Рис. 4.19. Порівняння форм узагальнених логістичних функцій активації після навчання шарів нейронних мереж різної архітектури: а – модель без «надлишкових» шарів, б – модель із додатковими «надлишковими» шарами [7]

На рис. 4.19 а видно, що за відсутності «надлишкових» шарів активаційні функції різних шарів нейронної мережі демонструють суттєву відмінність між собою. Якщо розглядати кожен шар окремо, то на рис. 4.19 б видно, що адаптивна функція активації шару 1а помітно відрізняється від функції попереднього шару 1. Водночас між шарами 1а і 1б, а також 1б і 1в, спостерігається мінімальна різниця у формах активаційних функцій. Починаючи з шару 1г, знову фіксується виражена відмінність між кривими.

Подібна поведінка функцій активації (рис. 4.19 б) узгоджується з особливостями архітектури моделі з «надлишковими» шарами (рис. 4.18). Основний висновок полягає в тому, що наявність «надлишкових» шарів зумовлює менші зміни активаційних функцій між сусідніми шарами, тобто мережа оновлює свої коефіцієнти повільніше.

Слід зазначити, що надлишковість шару нейронної мережі з використанням адаптивних функцій активації визначається не лише стабільністю його функції активації, а й сукупним впливом на розподіл результуючих даних. Якщо параметри активаційних функцій у сусідніх шарах змінюються незначно, це може свідчити про те, що такі шари виконують схожі перетворення інформації. Водночас навіть за незмінних параметрів

активаційної функції окремого шару, результуючий розподіл даних може зазнавати змін унаслідок адаптації попередніх шарів під час тренування. Тому для визначення надлишковості шару доцільно аналізувати зміни параметрів функції активації в динаміці. Отже, якщо в архітектурі нейронної мережі присутні «надлишкові» шари, які не вносять суттєвих змін у розподіл коефіцієнтів нейронних мереж, то вони виконують подібні перетворення або додають лише незначні зміни. Такі шари майже не впливають на варіацію вхідного сигналу, що можна наближено описати аналітичним рівнянням:

$$y = g(x; \theta_a) \approx x,$$

де g – адаптивна функція активації шару, θ_a – параметри функції активації, що навчаються, x – вхідні дані, y – результуючі дані.

Тоді градієнт помилки E за параметрами θ_a обраховуються наступним чином:

$$\frac{\partial E}{\partial \theta_a} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial \theta_a}$$

З цього випливає, що якщо шар є «надлишковим», то результуючі дані y можна представити як:

$$y = x + \varepsilon(x; \theta_a),$$

де $\varepsilon(x; \theta_a)$ – характеризує малу зміну входу x під час повторного оновлення параметрів функції активації θ_a в результаті процедури навчання нейронної мережі.

Тоді y майже не залежить від θ_a , отже $\frac{\partial y}{\partial \theta_a} \rightarrow 0$ і відповідно $\frac{\partial E}{\partial \theta_a} \rightarrow 0$, що в свою чергу призведе до повільної динаміки оновлення параметрів адаптивних активаційних функцій.

Оскільки за збільшення кількості шарів, оцінка надлишковості за графіками функцій активації стає малоефективною, тому для кількісної оцінювання надлишковості адаптивних активаційних функцій було запропоновано характеристичний коефіцієнт (коефіцієнт надлишковості шару нейронної мережі):

$$C_{var}^{cof_n} = \alpha * \frac{|cof_{n(i)} - cof_{n(i-1)}|}{\max \Delta_{cof_n}} + \beta * \frac{|cof_{n(i)} - cof_{n(0)}|}{\max \Delta_{cof_n}},$$

де $C_{var}^{cof_n}$ – коефіцієнт надлишковості шару нейронної мережі, $cof_{n(i)}$ – значення коефіцієнту надлишковості функції n на поточному шарі, $cof_{n(i-1)}$ – значення коефіцієнту функції n на попередньому шарі НМ, $cof_{n(0)}$ – значення коефіцієнту функції n на початковому етапі навчання, $\max \Delta_{cof_n}$ – максимальне абсолютне відхилення n на всіх шарах НМ що аналізуються, α, β – вагові коефіцієнти, що визначають вклад складових рівняння.

У наведеній формулі коефіцієнта надлишковості параметр $cof_{n(i)}$ означає значення n -го параметра функції активації на i -му шарі нейронної мережі. Індекс n відповідає конкретному параметру функції, що навчається, наприклад, a або b для узагальненої логістичної функції, чи коефіцієнтам нахилу для параметричної ReLU. Якщо виникає необхідність аналізувати «надлишковість» шару одразу за декількома коефіцієнтами адаптивної функції активації, то в такому випадку може бути застосоване середнє арифметичне коефіцієнтів $C_{var}^{cof_n}$, обраховане за кожним параметром функції активації окремо. Індекс i визначає номер шару в структурі мережі. Коефіцієнт надлишковості $C_{var}^{cof_n}$ обчислюється не на кожній ітерації навчання, а після завершення тренування або у визначені контрольні моменти (наприклад, після кожної епохи). Такий підхід дозволяє оцінити внесок кожного шару у адаптацію моделі до вхідних даних після закінчення навчання.

Перший доданок у формулі характеризує зміну параметра функції активації між поточним і попереднім шарами, тоді як другий – відображає відхилення поточних значень параметрів від початкових. Коефіцієнти α та β використовуються для регулювання ваги цих складових.

У ході дослідження було визначено, що значення вагових коефіцієнтів $\alpha = 0,6$ і $\beta = 0,4$, забезпечують найкращий результат. Ці значення було отримано шляхом варіювання вагових коефіцієнтів у діапазоні від 0,1 до 0,9 під час оцінок надлишковості шарів НМ. Перевірку ефективності запропонованого

коефіцієнта виконано на нейронній мережі з «надлишковими» шарами (рис. 4.22), результати занесено в табл. 4.7.

Таблиця 4.7 Оцінка значень коефіцієнтів надлишковості шарів нейронної мережі та точності класифікації ППШ із використанням адаптивних функцій активації

Функція активації	Шар1	Шар 1а	Шар 1б	Шар 1в	Шар 1г	Шар 2	Шар 3	Шар 4	Точн. ППШ
Узагальне на логістична функція	0,06	0,363	0,176	0,09	0,099	0,24	0,821	0,534	92,67
Функція «ReLU» зі зсувом	0,343	0,240	0,099	0,100	0,087	0,358	0,593	0,525	92,93
Параметрична функція «ReLU»	0,633	0,397	0,051	0,093	0,088	0,319	0,609	0,307	90,40
Кусково-лінійна функція	0,217	0,166	0,099	0,086	0,081	0,094	0,443	0,303	88,89
Розроблена функція	0,783	0,476	0,087	0,066	0,071	0,011	0,547	0,463	93,69

На наступному етапі із архітектури, що зображена на рис. 4.22, було видалено шари, для яких коефіцієнт не перевищував значення $C_{var}^{cof_n} \leq 0,1$.

Після цього показники були повторно розраховані. У таблиці 4.8 наведено результати розрахунку, символом «X» позначено вилучені «надлишкові» шари.

Таблиця 4.8 Оцінка значень коефіцієнтів надлишковості шарів нейронної мережі та точності класифікації ППШ після виключення «надлишкових» шарів

Функція активації	Шар1	Шар 1а	Шар 1б	Шар 1в	Шар 1г	Шар 2	Шар 3	Шар 4	Точн. ППШ
Узагальне на логістична функція	0,631	0,352	0,191	X	X	0,183	0,582	0,344	92,40
Функція «ReLU» зі зсувом	0,593	0,312	X	X	X	0,416	0,454	0,527	93,94
Параметрична функція «ReLU»	0,782	0,324	X	X	X	0,658	0,643	0,452	92,68
Кусково-лінійна функція	0,151	0,373	X	X	X	X	0,465	0,223	91,38
Розроблена функція	0,552	0,400	X	X	X	X	0,544	0,325	93,34

Під час аналізу табл. 4.7, у якій наведено порівняння коефіцієнтів надлишковості для кожного шару нейронної мережі, виявлено, що для всіх

адаптивних функцій активації значення коефіцієнтів у шарах 1a-1г є помітно нижчими, ніж у шарах 1, 2, 3 та 4. На основі цього було визначено порогове значення $C_{var}^{cofn} = 0,1$, нижче якого шар вважається «надлишковим». Враховуючи цей поріг і розподіл отриманих показників, можна зробити висновок, що шари 1a-1г фактично виконують мінімальну роль у процесі навчання, оскільки градієнти помилок у них змінюються незначно, що призводить до повільної адаптації параметрів функцій активації. Навпаки, третій та четвертий шари мають найвищі значення коефіцієнтів надлишковості, що свідчить про їхню високу участь у процесі навчання. Для збереження розмірності вхідних і результуючих даних, шари 1 та 4 залишали без змін, а кількість нейронів у проміжних шарах були скориговані таким чином, щоб зберегти повнозв'язність структури НМ.

Порівняльний аналіз таблиць 4.7 і 4.8 показав, що після оптимізації архітектур, значення коефіцієнтів надлишковості шарів збільшилися й всюди перевищували значення ($C_{var}^{cofn} > 0,1$). У деяких шарах цей показник зріс ще більше, що свідчить про покращення здатності мережі до узагальнення та зростання ефективності окремих шарів. Водночас точність класифікації знизилася незначно (наприклад, лише на 0,27% для узагальненої логістичної функції), а в окремих випадках, зокрема під час застосування параметричної ReLU, ReLU зі зсувом або кусково-лінійної функції – підвищилась. Такий ефект можна пояснити зменшенням ступеня перенавчання та зростанням узагальнюючої здатності моделі, що стало можливим завдяки видаленню «надлишкових» шарів із структури нейронної мережі.

Також за допомогою розробленого коефіцієнту C_{var}^{cofn} було оцінено шари сіамської нейронної мережі, що була розроблена для виявлення аритмій і супутніх патологій. До архітектури сіамської нейронної мережі було залучено розроблену функцію активації, що навчається, з властивістю стискаючого

відображення. Результати обрахунку коефіцієнту надлишковості наведено на рисунку 4.20.




Рис. 4.20. Оцінка надлишковості шарів сіамської нейронної мережі, що була розроблена для виявлення аритмій і супутніх патологій [10]

На рис. 4.20 значення коефіцієнту надлишковості шару зазначено червоним кольором над кожним блоком, який позначає функцію активації, що навчається. В результаті аналізу розрахованих коефіцієнтів можна визначити, що архітектура майже не має збиткових шарів ($C_{var}^{conf_n} < 0,1$) окрім останнього шару в послідовності, що обробляє вектор ЕКГ. Цей шар має значення коефіцієнту $C_{var}^{conf_n} = 0,09$. За значенням коефіцієнту даний шар майже не змінюється в процесі навчання нейронної мережі, отже він може бути видалений з архітектури, а його нестачу зможе доповнити попередній шар. Дійсно, повторне тестування нейронної мережі показало, що відсутність даного шару майже не впливає на загальну точність моделі, в свою чергу, пришвидшуючи її роботу.

Висновки до розділу 4

В результаті роботи над розділом:

1. Встановлено, що методи обробки ЕКГ сигналів за допомогою класичних алгоритмів є фундаментальною основою для автоматизованої діагностики серцево-судинних захворювань, але потребують ретельного налаштування та характеризуються високою чутливістю до варіацій параметрів сигналу, що досліджується, та до якості його попередньої обробки. Водночас вони придатні для систем з обмеженими ресурсами і забезпечують високу швидкість під час виявлення небезпечних серцево-судинних патологій.

2. У рамках дослідження розроблено та вдосконалено низку власних підходів до аналізу ЕКГ. Зокрема, алгоритм на основі безперервного вейвлет-перетворення (БВП) продемонстрував високу ефективність у виявленні низькоамплітудних компонент ЕКГ сигналу, таких як дельта-хвиля під час наявності синдрому СВПУ та f-хвилі під час фібриляції передсердь. Окремий алгоритм, заснований на аналізі системи ізоліній, показав свою здатність до класифікації різних типів кардіоциклів (N, A, V) з точністю понад 79%, що робить його корисним інструментом для морфологічного опису сигналу, хоча його точність обмежена в умовах аналізу довгих фрагментів ЕКГ.

3. Проведено оцінку методів машинного навчання без вчителя. Це важливо тому, що для складних задач багатокласової класифікації аритмій та супутніх патологій методи обробки на основі класичних алгоритмів та машинне навчання часто виявляються недостатньо ефективними через трудомісткість побудови ознак та низьку аналітичну спроможність. Використання кластерного аналізу за допомогою методів UMAP та HDBSCAN підтвердило їхню здатність виявляти латентні структури та групи ризику на основі ЕКГ даних, проте вони не забезпечують необхідної точності для диференціації широкого спектру конкретних патологій.

4. Розроблено модель сіамської нейронної мережі, що поєднує аналіз усередненого кардіоциклу та результуючого вектора ЕКГ сигналу. Розроблена модель показала вищу середню точність (72%) порівняно зі спеціалізованою архітектурою ECGNet (68%). Ключовою перевагою розробленої НМ є її ефективність в умовах обмежених та незбалансованих наборів даних, що дуже актуально для клінічної практики. Розроблена модель може використовуватись як компонент автоматизованої системи діагностики, дозволяючи полегшити налаштовування та використання в порівнянні з класичними рішеннями.

5. Розроблено власну адаптивну функцію активації з параметрами, що навчаються, яка на основі властивості стискаючого відображення продемонструвала найкращі результати щодо підвищення чутливості НМ до низькоамплітудних ознак, точності та швидкості збіжності процесу навчання, а також допомогла мінімізувати проблеми вибуху та згасання градієнтів.

6. Розроблено коефіцієнт оцінювання надлишковості шару, який дозволяє кількісно оцінити внесок кожного шару нейронної мережі в процес навчання. Використання цього коефіцієнта дало змогу оптимізувати архітектуру мереж, видаляючи малоефективні шари без втрати точності класифікації, що веде до зменшення обчислювальних витрат та підвищення ефективності моделей.

7. На основі проведених досліджень підтверджено, що поєднання класичних методів для попередньої обробки та виділення ознак із сучасними глибокими нейронними мережами, зокрема спеціалізованими архітектурами, наприклад, сіамських мереж, є найбільш ефективним шляхом для розвитку точних, стійких і адаптивних систем автоматизованого аналізу ЕКГ. Подальша робота має бути спрямована на вдосконалення методів виділення низькоамплітудних компонентів та інтеграцію різних типів моделей у єдину систему.

РОЗДІЛ 5 ВИЯВЛЕННЯ НИЗЬКОАМПЛІТУДНИХ КОМПОНЕНТІВ НА ЕКГ СИГНАЛАХ

5.1 Виявлення низькоамплітудних компонентів на ЕКГ за допомогою сіамських нейронних мереж

Сіамські нейронні мережі продемонстрували високу ефективність у розпізнаванні широкого спектра аритмій та супутніх патологічних станів. Під час навчання на великій кількості класів, чутливість сіамських НМ до пізніх потенціалів залишалася на рівні традиційних методів аналізу [4]. Тому в рамках додаткового дослідження було проведено аналіз можливості підвищення чутливості до низькоамплітудних компонентів електрокардіосигналу, а саме ППШ та ППП шляхом навчання сіамської нейронної мережі для вирішення вузькоспеціалізованої задачі виявлення слабких проявів електричної активності серця [10] (рис. 5.1).

Для тестування були обрані ЕКГ сигнали з наявними ППШ та ППП. Сіамська нейронна мережа застосовувалась для розпізнавання ЕКГ в нормі, ЕКГ з наявними ППШ, ЕКГ з наявними ППП, та сигнали ЕКГ з наявними ППШ та ППП одночасно. Процес поширення потенціалів дії був промодельований на основі моделі паралельних провідностей [62].




Рис. 5.1. Сіамська нейронна мережа для виявлення ППШ та ППП: а – вектор ознак патологічного класу, б – усереднений кардіоцикл сигналу, що досліджується, в – згорткові шари нейронної мережі, г – шари розгортки, д – повнозв’язні шари нейронної мережі, е – результуючий шар [10]

Архітектура сіамської нейронної мережі, яку було спроектовано для виявлення ППІ та ППШ, мала більш спрощену архітектуру, на основі якої відбувалось оцінювання точності класифікації. Оскільки ознаки пізніх потенціалів переважно відображаються в кардіоциклі, для тренування нейронної мережі було використано лише перші 500 відліків вхідного сигналу, що відповідають усередненому кардіоциклу результуючого вектора ЕКГ. Для тренування було обрано 3200 спостережень ЕКГ, по 800 на кожний із трьох класів з патологіями та клас норми. Еталонні вектори ознак для порівняння формувалися на основі 150 випадково відібраних сигналів з патологією шляхом використання перших трьох правих сингулярних векторів SVD-розкладу, що відповідають найбільшим сингулярним значенням. Тоді тренування сіамської нейронної мережі полягало в навчанні виявлення різниці усередненого кардіоциклу що досліджувався (рис. 5. 1 б) та поданого вектору ознак (рис. 5.1 а).

Сіамська нейронна мережа містить згорткові шари (рис. 5.1 в), які формують 64 карти узагальнених ознак. Після цього отримані карти проходять через шари розгортки (рис. 5.1 г), де перетворюються у векторні представлення, що подаються на послідовність повнозв'язних шарів (рис. 5.1 д). Далі результати роботи цих шарів порівнюються шляхом формування вектора різниці між відповідними результуючими векторами ознак, після чого результат надходить до фінального шару прийняття рішення. Саме цей шар визначає ступінь подібності тестового сигналу та еталонного вектора ознак ЕКГ з патологією (рис. 5.1 е).

Для кожного класу було сформовано по 100 еталонних векторів ознак, які формувалися на основі випадкової вибірки зі 150 кардіоциклів, що містили відповідну патологію. Для тренування нейронної мережі було сформовано навчальну та тестову вибірку в пропорції 80/20%. Результати навчання сіамської нейронної мережі порівнювалися з результатами навчання спеціалізованої архітектури «ECGNet», яка навчалася на то му ж наборі

тренувальних даних. Для кожної нейронної мережі розмір міні-вибірки був обраний у розмірі 100 спостережень, навчання тривало 100 епох, критерієм якості було обрано бінарну перехресну ентропію. Результати тренування сіамської нейронної мережі наведено у таблиці 5.1.

Таблиця 5.1 Порівняння показників якості класифікації сіамської нейронної мережі та мережі «ECGNet» в задачі розпізнавання ППШ та ППП

		Норма	ППШ	ППП	ППП+ППШ
Розроблена сіамська нейронна мережа	Чутливість	0.98	0.63	0.52	0.42
	Специфічність	0.99	0.90	0.87	1.00
	Точність	0.98	0.83	0.78	0.95
ECGNet	Чутливість	0.84	0.32	0.24	0.34
	Специфічність	0.87	0.85	0.87	0.91
	Точність	0.86	0.71	0.68	0.86

З аналізу таблиці можна зробити висновок, що загальна точність класифікації для класів норма, ППШ, ППП, а також їх об'єднання є вищою порівняно з точністю, яка була досягнута після навчання спеціалізованої нейронної мережі «ECGNet». Під час оцінювання показників чутливості та специфічності було отримано, що для класів з патологією специфічність значно перевищує чутливість. Це вказує на складність розпізнавання низькоамплітудних складових сигналу нейронними мережами. Для підвищення чутливості нейронних мереж до низькоамплітудних компонентів необхідно застосовувати додаткові методи попередньої обробки даних. Це підтверджує ефективність застосування сіамської архітектури для діагностики серцево-судинних патологій, що характеризуються низькоамплітудними ознаками.

5.2 Виявлення низькоамплітудних проявів аритмій на ЕКГ за допомогою модифікованого Вейвлет перетворення

Комбінований частотно-часовий аналіз дозволяє одночасно досліджувати часові та частотні характеристики сигналу, представляючи його у вигляді тривимірної залежності між часом, частотою та амплітудою. Однак цей метод має суттєві обмеження, зокрема велику кількість коефіцієнтів, що ускладнює інтерпретацію, та неможливість одночасно досягти високої часової та частотної роздільної здатності.

Яскравим прикладом такого компромісу є короткочасне перетворення Фур'є (STFT), де сигнал розбивається на вікна з подальшим спектральним аналізом. Зменшення вікна покращує часову роздільність, але погіршує частотну, що відповідає принципу невизначеності Гейзенберга [128]. Додаткові спотворення виникають через тип віконної функції, зокрема ефект «витікання спектра», який розмиває частотну локалізацію [129]. Перетворення Вігнера-Вілла [130] теоретично може досягати майже максимальної роздільної здатності, але на практиці у складних сигналах виникають інтерференційні сигнальні складові, що спотворюють результат і роблять метод вразливим до шумів.

Для аналізу нестационарних сигналів, таких як ЕКГ, частіше застосовується безперервне вейвлет-перетворення (БВП), яке краще адаптується до змінних характеристик, але результат сильно залежить від вибору базового вейвлета. Також можлива втрата інформативних компонентів для малої кількості масштабів та експоненційне зростання обчислювальної складності під час їх збільшення, що підвищує ризик перенавчання класифікаційних моделей.

Наочно, недоліки різних частотно-часових методів в задачі виявлення низькоамплітудних пізніх потенціалів можна зобразити на рис. 5.2.




Рис. 5.2. Частотно-часове представлення комплексу QRS із ППШ та ППП: а – патологічний сигнал серцевого циклу з виділеними червоним пізніми потенціалами, б – скейлограма STFT для сигналу з патологіями, в – скейлограма перетворення Вігнера-Вілла для того ж сигналу, г – скейлограма безперервного вейвлет-перетворення (БВП), 1, 3 – орієнтовна локалізація ППП на STFT і БВП відповідно, 2, 4 – орієнтовна локалізація ППШ на STFT і БВП відповідно, 5 – прояв піка R на скейлограмі Вігнера-Вілла [6]

Для підвищення роздільності по амплітуді коефіцієнти були подані в логарифмічній шкалі, оскільки без логарифмування прояви пізніх потенціалів практично не розпізнаються. На STFT скейлограмі (рис. 5.2 б) діапазон частот пізніх потенціалів присутній, але часові межі ППШ/ППП розмиті через велике перекриття, і навіть у логарифмічній шкалі їх важко ідентифікувати. На скейлограмі Вігнера-Вілла (рис. 5.2 в) чітко проявляється лише пік R, тоді як інші компоненти QRS і пізні потенціали спотворені перехресними членами трансформації. На БВП (рис. 5.2 г) пізні потенціали мають кращу локалізацію і за часом, і за частотою, однак навіть тут їх розпізнавання ускладнене.

Основна причина такої поведінки полягає в тому, що більша частина енергії частотно-часового спектру сконцентрована на високоамплітудних компонентах сигналу, що призводить до придушення важливих низькоамплітудних ознак і потенційних проблем із згасанням градієнтів під час навчання моделей. Необхідне перетворення, здатне формувати частотно-

часове представлення з амплітудною селективністю, тобто аналізом лише тих компонентів, енергетичний рівень яких лежить у заданих межах.

Очевидними кандидатами для реалізації такого підходу є методи амплітудної декомпозиції сигналу, наприклад емпірична модова декомпозиція (Empirical Mode Decomposition, EMD), та інші [131]. Проте всі ці методи мають принципове обмеження, яке полягає в тому, що вони не дають змоги задати цільовий амплітудний діапазон, а лише розкладають сигнал на моди, які не завжди мають фізичне чи діагностичне значення. Крім того, короткотривалі пізні потенціали складно виокремити як окрему моду, особливо в умовах шуму. Тому для вирішення цих недоліків частотно-часового аналізу було досліджено можливість модифікувати вейвлет-перетворення для точнішого відображення низькоамплітудних компонентів, що здатне підвищити достовірність як візуального аналізу, так і автоматизованої обробки сигналів, зокрема нейронними мережами.

Математично процес вейвлет-перетворення можна подати у вигляді:

$$CWT(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) * \psi^*\left(\frac{t - \tau}{s}\right) dt \quad (5.1)$$

де $CWT(s, \tau)$ – коефіцієнт вейвлет-перетворення, що обчислюється, $x(t)$ – аналізований сигнал, ψ^* – комплексно спряжена функція до ψ , де ψ є материнським вейвлетом, s – масштабний коефіцієнт, τ – параметр часового зсуву, t – часова змінна.

У наведеній формулі множник $\frac{1}{\sqrt{|s|}}$ виконує роль нормувального коефіцієнта, який гарантує, що норма масштабованого та зміщеного вейвлета залишається сталою, тобто $\|\psi_{s,\tau}(t)\| = \|\psi(t)\| = 1$. Також параметр масштабу s повинен задовольняти умову $s > 0$.

У цьому дослідженні модифікація вейвлет-перетворення виконана на основі вейвлета Морле [132]. Його обрано завдяки гарній локалізації як у

часовій, так і у частотній областях, можливості точного налаштування центральної частоти та подібності його форми до ППШ і ППП. Вейвлет Морле визначається наступною формулою:

$$\psi(t) = \pi^{-\frac{1}{4}} e^{i\omega_0 t} e^{-\frac{t^2}{2}}, \quad (5.2)$$

де $\psi(t)$ вейвлет Морле як функція часу t , ω_0 – центральна частота вейвлета, яка визначає область максимальної енергетичної концентрації, $e^{i\omega_0 t}$ – комплексна експонента, що генерує синусоїдальний компонент, $e^{-\frac{t^2}{2}}$ – Гаусівське вікно, яке модулює синусоїду та забезпечує скінченну тривалість вейвлета, $\frac{1}{4}$ – нормувальний член, який вводиться для того, щоб енергія вейвлета дорівнювала 1.

Для реконструкції початкового сигналу $x(t)$ з отриманих коефіцієнтів вейвлет-перетворення $X(s, \tau)$ використовується така формула:

$$x(t) = C_\psi^{-1} \int_0^\infty \int_{-\infty}^\infty X(s, \tau) \frac{1}{\sqrt{|s|}} \tilde{\psi}\left(\frac{t-\tau}{s}\right) d\tau \frac{ds}{s^2} \quad (5.3)$$

де $x(t)$ – початковий сигнал, C_ψ^{-1} – нормувальний коефіцієнт, що залежить від вибраного вейвлета, $X(s, \tau)$ – коефіцієнти, отримані після безперервного вейвлет-розкладу сигналу $x(t)$, $\frac{1}{\sqrt{|s|}}$ – нормувальний множник, $\tilde{\psi}(t)$ – дуальна функція до $\psi(t)$, яка використовується для оберненого вейвлет-перетворення. Інтегрування виконується за двома параметрами, спочатку за часовим зсувом τ , а потім – за масштабом s .

У більшості випадків для Морле-вейвлета дуальною функцією виступає сам вейвлет [133]. Тобто під час використання вейвлета Морле обернене перетворення може виконуватись з тією ж функцією, що й пряме перетворення. Нормувальний коефіцієнт для оберненого безперервного вейвлет-перетворення може бути обчислений за формулою:

$$C_{\psi} = \frac{\int_{-\infty}^{\infty} |\hat{\psi}(\omega)|^2}{|\omega|} d\omega, \quad (5.4)$$

де $|\hat{\psi}(\omega)|$ – модуль перетворення Фур'є вейвлет-функції $\psi(t)$, ω – кутова частота, пов'язана з частотою f співвідношенням $\omega = 2\pi f$.

Для дискретної реалізації оберненого безперервного вейвлет-перетворення нормувальний коефіцієнт часто обчислюють у спрощеній формі [134]. У такому випадку формула набуває вигляду:

$$C_{\psi} = \sum (|\psi(t)|^2) \quad (5.5)$$

Таке спрощення передбачає пряме підсумовування квадратів модуля вейвлет-функції у часовій області замість інтегрування її спектра Фур'є. Отриманий вираз задає нормувальний коефіцієнт у практичному наближенні, якого достатньо для коректного відновлення початкового сигналу. Оскільки вейвлет Морле має власну центральну частоту, перехід від масштабів до частот у дискретному сигналі може бути виконано за допомогою такого співвідношення:

$$f_a = \frac{\omega_0}{2\pi a}, \quad (5.6)$$

де a – масштаб вейвлета, а ω_0 – центральна частота вейвлета Морле, виражена в [рад/с].

Однак формула перерахунку може залежати від конкретної реалізації вейвлет-перетворення. Якщо вейвлет Морле визначено не як функцію неперервного часу $\psi(t)$, а як дискретну функцію $\psi[n]$, тоді ω_0 задається у [рад/відлік]. У такому випадку формула переходу від масштабу до частоти і набуває вигляду:

$$f_a = \frac{\omega_0}{2\pi a \Delta t}, \quad (5.7)$$

де a – масштаб вейвлета, ω_0 – центральна частота вейвлета Морле у [рад/відлік], а Δt – інтервал дискретизації між відліками сигналу.

Варто зазначити, що результат вейвлет-перетворення значною мірою залежить і від вибору системи масштабів (рис. 5.3).




Рис. 5.3 Частотна характеристика вейвлета Морле за різних систем масштабування: а – для лінійної шкали масштабів, б – для логарифмічної шкали масштабів [6]

На рис. 5.3 наведено порівняння розподілу частотної характеристики вейвлета Морле залежно від обраної системи масштабів. Для зручності візуалізації вісь частот подано у логарифмічному масштабі. Перший графік (рис. 5.3 а), побудований з використанням лінійної шкали масштабів ($s = n, n \in [0: N]$), демонструє значне накладання спектрів у низькочастотній області та більш виражені відстані на високих частотах. Для формування більш рівномірного розподілу спектральних складових доцільно використовувати логарифмічну систему масштабів.

$$s_k = s_{min} * r^k, k \in [0, N - 1], \quad (5.8)$$

де s_k – логарифмічний масштаб, s_{min} – мінімальне значення масштабу, r – коефіцієнт масштабування.

Якщо відомі найбільший s_{max} та найменший s_{min} масштаби, в межах яких необхідно виконати масштабування вейвлета, то для заданої кількості масштабів N коефіцієнт масштабування можна обчислити за формулою:

$$r = \left(\frac{s_{max}}{s_{min}} \right)^{\frac{1}{N-1}} \quad (5.9)$$

У разі дискретного перетворення максимальна частота вейвлета обмежується частотою дискретизації й відповідно до теореми Найквіста–Шеннона дорівнює $\frac{f_s}{2}$. Водночас мінімальна частота визначається тривалістю сигналу та залежить від масштабу вейвлета. Мінімальна частота вейвлет-перетворення може бути подана як:

$$f_{max} = \frac{1}{T_{\text{сигналу}}} = \frac{f_s}{N_{\text{відліків}}},$$

де f_s – частота дискретизації, а $N_{\text{відліків}}$ – кількість відліків сигналу.

Крім того, мінімальна та максимальна частоти можуть задаватися виходячи з фактичного спектрального діапазону сигналу. Використовуючи співвідношення (5.6) та (5.7), можна визначити мінімальний і максимальний масштаб, які за формулами (5.8) та (5.9) перетворюються на рівномірно розподілену логарифмічну послідовність масштабів.

Для тестування методів, що розроблялися, були використані такі бази даних: «MIT-BIH Arrhythmia Database» [80] – обрана завдяки наявності анотованих кардіоциклів та інших подій серцевого ритму; «Paroxysmal Atrial Fibrillation Events Detection from Dynamic ECG Recordings» [135] – обрана через наявність 100 ЕКГ сигналів здорових осіб тривалістю понад 3 хвилини та з високою частотою дискретизації, що складає 500 Гц.

В основі безперервного вейвлет-перетворення для аналізу сигналів можуть використовуватися метричні функції подібності, зокрема кореляція Пірсона [136] та косинусна подібність [137]. Для оцінювання якості

виокремлення ознак на основі запропонованих методів були використані поширені архітектури глибоких нейронних мереж, зокрема: ResNet, DenseNet, MobileNet v2, MobileNet v3, ShuffleNet, ResNeXt-50 [138].

Оскільки основою безперервного вейвлет-перетворення (5.1) є операція крос-кореляції, а отримані коефіцієнти БВП фактично відображають ступінь кореляції між початковим сигналом та масштабованим і зсунутим у часі материнським вейвлетом [139], то для подальшого опрацювання ці коефіцієнти було відфільтровано за допомогою спеціальної коригувальної функції f_{scale}

$$CWT(s, \tau) = \int_{-\infty}^{\infty} x(t) * \psi' * \left(\frac{t - \tau}{s} \right) * f_{scale}(x(t), \psi'(t - \tau)/s) dt, \quad (5.10)$$

де $f_{scale}(x(t), \psi'(t - \tau)/s)$ – масштабуюча функція, що залежить як від поточного значення сигналу $x(t)$, так і від значення модифікованого вейвлета $\psi'(t)$, зміщеного на τ та масштабованого коефіцієнтом s . $\psi'(t)$ – модифікований вейвлет, амплітуда якого нормується до цільового рівня A , тобто до амплітуди, яку потрібно виділити в сигналі.

Основна ідея такого масштабування полягає у порівнянні амплітуди кожного фрагмента сигналу з амплітудою модифікованого вейвлета ψ' , що має цільову амплітуду A . Якщо амплітуди сигналу, що досліджується та скануючого вейвлета є співставними, масштабуюча функція f_{scale} підсилює значення коефіцієнта $CWT(s, \tau)$. Якщо ж амплітуди суттєво відрізняються, відповідні коефіцієнти значно зменшуються або обнуляються.

Для реалізації даного масштабування модифікований вейвлет $\psi'(t)$ може бути визначений такою формулою:

$$\psi'(t) = A \times \frac{\frac{1}{\sqrt{|s|}} \psi((t - \tau)/s)}{\max(|\frac{1}{\sqrt{|s|}} \psi((t - \tau)/s)|)}, \quad (5.11)$$

де A – цільова амплітуда, а $\psi((t - \tau)/s)$ – материнський вейвлет, масштабований фактором s і зсунутий у часі на τ . Як функцію f_{scale} у (10) можна використати, наприклад, таке відображення:

$$f_{scale}(a, b) = \left(\frac{\min(|a|, |b|)}{\max(|a|, |b|)} \right)^q, \quad (5.12)$$

де a та b – значення, що порівнюються, а q – коефіцієнт чутливості (quality factor), який визначає інтенсивність зростання функції залежно від ступеня подібності між a та b . Передавальна характеристика такої функція показана на рис. 5.4. Розроблена функція є модифікацією відомих нормалізованих відносних мір, яка була адаптована для оцінювання амплітудної подібності ЕКГ сигналів, з введенням керованого параметра чутливості.




Рис. 5.4. Залежність функції f_{scale} від відношення a/b для різних значень коефіцієнта чутливості q [6]

Як показано на графіці передавальної функції (рис. 5.4), зі збільшенням відношення a/b від одиниці значення масштабної функції f_{scale} зменшується. Параметр q визначає швидкість спадання цієї функції. Зі зростанням q смуга допустимих амплітудних співвідношень звужується, тобто область значень, у якій коефіцієнт залишається ненульовим, стає вузькою. Чим ближчими за значенням амплітуди порівнюваних компонентів, то вищим буде значення f_{scale} . Графік є симетричним відносно нуля, тобто має однаковий вигляд і для від'ємних значень a/b . Для точнішого контролю робочого діапазону цільових

амплітуд можна застосовувати інші типи «віконних» функцій. Наприклад, якщо необхідно виділити компоненти сигналу в діапазоні 5-20 мВ, можна задати цільову амплітуду $A = 10$ мВ і застосувати прямокутне вікно у межах $a/b \in [0,5:2]$. У такому випадку всі складові сигналу поза межами 5-20 мВ будуть пригнічені модифікованим БВП. Щоб мінімізувати спотворення, спричинені жорсткими межами прямокутного вікна, можна замість нього використати інші функції, зокрема вікно Тьюкі [140].

Варто зазначити, що модифіковане вейвлет-перетворення, у якому використовується амплітудна масштабуюча функція та нормований вейвлет $\psi'(t)$, не зберігає властивості лінійності та ортонормованості, притаманні класичному безперервному вейвлет-перетворенню. Унаслідок цього частина інформації про сигнал втрачається на етапі прямого перетворення. Тому розглянуті формули зворотного перетворення не відновлюють повністю початковий сигнал, а забезпечують його наближене відтворення з урахуванням застосованого масштабування.

Для відновлення сигналу з урахуванням впливу масштабної функції можна використати стандартну формулу оберненого вейвлет-перетворення (5.3). Однак оскільки в оберненому перетворенні застосовується немодифікований вейвлет, а в прямому – масштабований ψ' , вплив модифікованого вейвлета в зворотному перетворенні можна компенсувати за допомогою наступного виразу:

$$x(t) = C_{\psi}^{-1} \int_0^{\infty} \int_{-\infty}^{\infty} \frac{X'(s, \tau) \max|\psi|}{A\sqrt{|s|} c(s, \tau)} \frac{1}{\sqrt{|s|}} \tilde{\psi}\left(\frac{t - \tau}{s}\right) \frac{d\tau ds}{s^2}, \quad (5.13)$$

де $x(t)$ – початковий сигнал, C_{ψ}^{-1} – нормувальний коефіцієнт вейвлета, $X'(s, \tau)$ – коефіцієнти, отримані після модифікованого БВП сигналу $x(t)$ (5.10), $\frac{1}{\sqrt{|s|}}$ – нормувальний множник, $\max|\psi|$ – максимум материнського вейвлета, що використовується у прямому перетворенні, $\tilde{\psi}$ – дуальний вейвлет ($\tilde{\psi} = \psi$),

$c(s, \tau)$ – значення масштабуючої функції, отриманої під час прямого перетворення $(\int_{-\infty}^{\infty} f_{scale}(x(t), \psi'_{s,\tau}(t)) dt)$. Для відображення результатів фільтрації за амплітудою на рис. 5.5, г, е, було використано $c(s, \tau)=1$.

Для тестування запропонованого вдосконалення БВП (рис. 5.5) було створено два штучних тестових сигнали. Перший з них (рис. 5.5 в) являє собою послідовність із трьох різних синусоїдальних компонентів. Перша компонента являє собою синусоїду з частотою 30 Гц та амплітудою 1 мВ, на яку накладено високочастотний шум. Це призводить до спотворення форми сигналу та його розширення у частотній області.




Рис. 5.5. – Безперервне вейвлет-перетворення та реконструкція сигналу, отримані із застосуванням модифікованого БВП (5.10):

а – часо-частотне представлення коефіцієнтів БВП для комбінованого синусоїдального сигналу, б – часо-частотне представлення сигналу одного серцевого циклу з ППШ та ППП, в – комбінований синусоїдальний тестовий сигнал, г – результат модифікованого оберненого перетворення (5.13) для синусоїдального сигналу, д – сигнал серцевого циклу з ППП та ППШ, е – результат модифікованого оберненого перетворення (5.13) для сигналу серцевого циклу з ППШ та ППП [6]

Друга компонента – це синусоїда зі змінною частотою в діапазоні 1-10 Гц та амплітудою 1 мВ. Така складова є нестационарною в частотній області. Третя компонента – синусоїда з частотою 30 Гц та малою амплітудою ≈ 0.025 мВ, що імітує низькоамплітудний сигнал у присутності високоамплітудних складових.

Частота дискретизації тестового сигналу становила 500 Гц, а загальна тривалість приблизно 1,7 с. Низькоамплітудна компонента сигналу мала амплітуду, що приблизно у 40 разів менша за інші його складові. Через це основна енергія спектра скейлограми класичного вейвлет-перетворення припадала на високоамплітудні компоненти, а низькоамплітудна складова залишалась візуально невидимою.

Застосування модифікованого БВП (5.10) дало змогу суттєво підвищити масштабну роздільну здатність низькоамплітудної компоненти на скейлограмі (рис. 5.5 а), а також збільшити її амплітуду під час оберненого перетворення (5.13) (рис. 5.5 г). Для модифікованого перетворення, показаного на рис. 5.5 а, було використано вейвлет Морле з $\omega_0 = 6$ рад/відлік, лінійну систему із 50 масштабних коефіцієнтів в діапазоні від 10 до 200, цільову амплітуду $A = 0,025$ у (5.11) та коефіцієнт чутливості $q = 5$ для (5.12). Під час аналізу відновленого сигналу (рис. 5.5 г), а також скейлограми (рис. 5.5 а), можна помітити, що високоамплітудні компоненти були пригнічені недостатньо і в інтервалі 0,5-1,25 с. присутні залишкові коливання. Ці флуктуації, ймовірно, спричинені частковим збігом амплітуди та форми між аналізованим сигналом і модифікованим вейвлетом у певному часовому інтервалі. Щоб зменшити цей ефект, у подальшому було запропоновано ще одне додаткове вдосконалення.

Другим тестовим сигналом (рис. 5.5 д) був штучно сформований сигнал одного серцевого циклу з ППШ та ППП. Пізні потенціали являли собою суперпозицію синусоїд у частотному діапазоні 80-20 Гц та амплітудою 35 мкВ. Частота дискретизації становила 500 Гц, тривалість – близько 0.8 с. Для модифікованого БВП (5.10) використовувалася лінійна система з 50 масштабів у діапазоні $s \in [3: 200]$, цільова амплітуда $A = 0.035$ та коефіцієнт чутливості $q = 5$.

Аналізуючи коефіцієнти модифікованого БВП (рис. 5.5 б), видно, що хоча у діапазоні 80-100 Гц присутні локальні піки, енергія інших компонентів

із більшою амплітудою пригнічується недостатньо. Подібний ефект спостерігається і під час відновлення сигналу (рис. 5.5 е), хоча у ділянці розташування ППШ та ППП присутні помітні пульсації, чітке відокремлення пізніх потенціалів не досягається. Різниця між результатами для двох тестових сигналів пояснюється тим, що синусоїдальний сигнал (рис. 5.5 в) значно ближчий за формою до вейвлета Морле. Крім того, і вейвлет Морле і тестовий сигнал осцилюють симетрично відносно нуля, що забезпечує краще співпадіння амплітуд і, відповідно, вищі коефіцієнти модифікованого перетворення. Натомість у сигналі з пізніми потенціалами (рис. 5.5 д) амплітуди різних компонентів сигналу зміщені нерівномірно відносно нуля, тому на масштабну функцію впливає нерівномірність сигналу і відповідно функція не виділяє потрібні компоненти належним чином. У такому випадку для більш чіткого виявлення низькоамплітудних компонентів потрібен підхід, менш чутливий до зміни амплітуди.

Щоб мінімізувати спотворення, пов'язані зі зсувом амплітуди аналізованого сигналу під час модифікованого вейвлет-перетворення, замість крос-кореляції у процедурі БВП може бути використана косинусна подібність:

$$CWT_{cos}(s, \tau) = \frac{\int_{-\infty}^{\infty} x(t) * \psi'_{s,\tau}(t) dt}{\sqrt{\int_{-\infty}^{\infty} |x(t)|^2 dt} \sqrt{\int_{-\infty}^{\infty} |\psi'_{s,\tau}(t)|^2 dt}}, \quad (5.14)$$

де $x(t)$ – аналізований сигнал, $\psi'_{s,\tau}(t)$ – модифікований вейвлет (5.11), $\psi'_{s,\tau}(t)$ – його комплексно-спряжена форма.

У такому випадку результат вейвлет-перетворення визначає міру косинусної подібності між аналізованим сигналом та модифікованим материнським вейвлетом, зсунутий у часі та масштабований відповідним коефіцієнтом. Тоді масштабуюча функція f_{scale} застосовується у такому вигляді:

$$CWT_{mod}(s, \tau) = \frac{\int_{-\infty}^{\infty} x(t) \psi'_{s,\tau}{}^*(t) f_{scale}(x(t) - correct_{s,\tau}(t), A) dt}{\sqrt{\int_{-\infty}^{\infty} |x(t)|^2 dt} \sqrt{\int_{-\infty}^{\infty} |\psi'_{s,\tau}(t)|^2 dt}} \quad (5.15)$$

де $x(t)$ – сигнал, що аналізується, $\psi'_{s,\tau}(t)$ – модифікований вейвлет, визначений у (5.11), $\psi'_{s,\tau}{}^*(t)$ – його комплексно-спряжена форма, f_{scale} – масштабуюча функція, наведена у (5.12), A – цільова амплітуда компонентів, що виділяються, $correct(t)$ – коригувальна функція, що компенсує зміщення фрагментів сигналу відносно нульового рівня.

На прикладі фрагмента штучного нестационарного сигналу була побудована узагальнена схема обчислень CWT_{mod} з використанням коригувальної функції $correct(t)$ (рис. 5.6):




Рис. 5.6. Обчислення модифікованого безперервного вейвлет-перетворення (БВП) з коригувальною складовою: а – обчислення коефіцієнтів на основі модифікованої вейвлет-функції ψ' , б – приклад побудови скейлограми за отриманими коефіцієнтами, в – приклад обчислення коефіцієнтів модифікованого БВП без застосування коригувальної функції, г – приклад обчислення коефіцієнтів модифікованого БВП із використанням коригувальної функції [6]

Оскільки вейвлет Морле моделюється Гауссівською огибаючою (5.3), а 99,7% площі під кривою Гаусса зосереджено в межах $\pm 3\sigma$, це дозволяє

визначити ефективну тривалість вейвлета у секундах або відліках, обрізати його та порівнювати лише з фрагментом сигналу відповідної довжини. Запропоноване покращення обчислення модифікованого БВП для дискретного сигналу ґрунтується саме на цьому підході. На рис. 5.6 а показано, як скануючий вейвлет послідовно зміщується вздовж аналізованого сигналу, і на кожній ітерації обчислюється значення CWT_{mod} . На основі отриманих коефіцієнтів будується фрагмент скейлограми для заданого масштабу s (рис. 5.6 б). Також на рис. 5.6 в і рис. 5.6 г продемонстровано вплив коригувальної функції на результат обчислення коефіцієнтів. На рис. 5.6 в видно, що низькочастотний дрейф ізолінії спотворює фрагмент сигналу, зміщуючи його відносно нульового рівня. На рис. 5.6 г подано результат застосування коригувальної функції, яка нівелює вплив дрейфу ізолінії, завдяки чому порівняння сигналу та вейвлета стає коректнішим згідно запропонованого підходу. У найпростішому випадку застосування коригувальної функції призводить до віднімання середнього значення фрагмента сигналу на кожній ітерації, роблячи його симетричним відносно нуля.

Відновлення сигналу з урахуванням проведеної модифікації вейвлет перетворення (5.15) може мати наступний вигляд:

$$x_{mod}(t) = \frac{1}{C_\psi} \int_0^\infty \int_{-\infty}^\infty \frac{CWT_{modif}(s, \tau)}{c(s, \tau)} \frac{1}{\sqrt{|s|}} \tilde{\psi}\left(\frac{t - \tau}{s}\right) \frac{d\tau ds}{s^2}, \quad (5.16)$$

де $x(t)$ – початковий сигнал, C_ψ^{-1} – нормувальний коефіцієнт вейвлета, $CWT_{modif}(s, \tau)$ – коефіцієнти, отримані після модифікованого БВП сигналу $x(t)$ (15), $\frac{1}{\sqrt{|s|}}$ – нормувальний множник, $\tilde{\psi}$ – дуальний вейвлет ($\tilde{\psi} = \psi$), $c(s, \tau) = \int_{-\infty}^\infty f_{scale}(x(t) - correct_{s,\tau}(t), A) dt$ – нормуючий множник для компенсації впливу масштабування. Для візуалізації на рис. 5.7, в, е, було застосовано $c(s, \tau) = 1$.

Для оцінювання ефективності запропонованого вдосконалення вейвлет-перетворення, побудованої на основі описаного вище алгоритму, було проведено тестування як на штучно згенерованих сигналах, так і на реальних ЕКГ сигналах з наявними ППШ та ППП. Штучний сигнал для тестування (рис. 5.7 б) було згенеровано у вигляді комплексу QRS з доданими ПППШ та ППП. Реальний сигнал для тестування було обрано з бази MIT-BIH Arrhythmia Database. На основі цього сигналу сформовано усереднений комплекс QRS з ПППШ (рис. 5.7 д) [62]. Для штучного сигналу було застосовано модифіковане БВП на основі вейвлета Морле з $\omega_0 = 6$ рад/відлік, значення цільової амплітуди обрано, як $A = 0,035$ мВ, коефіцієнт чутливості $q = 4$, а як коригувальну функцію на кожній ітерації використовувалося віднімання середнього значення сигналу. Система масштабів була логарифмічною (5.9), з 40 масштабами в частотному діапазоні 40–200 Гц.




Рис. 5.7. Модифіковане вейвлет-перетворення (5.15) та реконструкція сигналів із пізними потенціалами: а – часо-частотне представлення модифікованого БВП для штучного сигналу з ПППШ та ППП, б – штучний сигнал із ПППШ та ППП, в – реконструйований штучний сигнал, г – часо-частотне представлення модифікованого БВП для реального сигналу комплексу QRS із ПППШ, д – реальний сигнал комплексу QRS із ПППШ, е – реконструкція реального сигналу, 1, 2 – відображення ПППШ та ППП на скейлограмі, 3, 4 – прояви ПППШ та ППП на штучному сигналі та відповідні ділянки після реконструкції, 5 – прояв ПППШ на скейлограмі реального сигналу, 6, 7 – прояв ПППШ на реальному сигналі та відповідні ділянки після реконструкції [6]

Для реального сигналу застосовувалися ті ж параметри, за винятком цільової амплітуди, значення якої було встановлено як $A = 0,025$ мВ.

Аналізуючи скейлограми (рис. 5.7 а, г), отримані за допомогою модифікованого вейвлет-перетворення (5.15) можна помітити, що в ділянках частотно-часового розкладу, де розташовані пізні потенціали, формуються локальні піки спектральної потужності (рис. 5.7 1, 2, 5). Ці піки чітко відокремлені, не зливаються із сусідніми коефіцієнтами, а високоамплітудні компоненти сигналу не спотворюють представлення у цільовій зоні. Така властивість дає змогу точніше аналізувати пізні потенціали в частотно-часовій області.

Під час аналізу реконструкцій сигналу (рис. 5.7 в, е) спостерігаються виразні імпульсні фрагменти, що відповідають часовим інтервалам низькоамплітудних компонентів (рис. 5.7 б 3, 4, 7), тоді як високоамплітудні складові значно пригнічені. Для порівняння, на рис. 5.8 наведено скейлограму класичного БВП, побудовану для аналогічного сигналу з ППШ за тими самими параметрами (рис. 5.8):




Рис. 5.8. Реальний сигнал із ППШ та скейлограма, побудована за допомогою класичного БВП з використанням вейвлета Морле: а – часо-частотне представлення БВП, б – реальний комплекс QRS із ППШ [6]

У випадку класичного вейвлет перетворення основна енергія зосереджена навколо високочастотної складової R-піка, а локалізація пізніх потенціалів ускладнена та «зашумлена» за рахунок домінування коефіцієнтів від інших високо-амплітудних компонентів сигналу. Запропоноване покращення вейвлет-перетворення дає змогу виокремити коливання, які не виявляються класичним методом. Наприклад, у реконструкції на рис. 5.7 д у зоні пізніх потенціалів (рис. 5.7 б) фіксуються додаткові низькоамплітудні коливання, що не були накладені штучно (на відміну від фрагмента на рис. 5.7 7). Це може свідчити про те, що вони дійсно присутні в ЕКГ пацієнта, що використовувалася для аналізу.

Для розпізнавання двох класів сигналів (ЕКГ із ППШ та без) на основі побудованих скейлограм було використано базу Paroxysmal Atrial Fibrillation Events Detection from Dynamic ECG Recordings [135]. Із неї було відібрано сигнали нормальної 12-канальної ЕКГ. До цих сигналів штучно додавалися ППШ, аналогічно до прикладу на рис. 5.7 д. Після цього для кожного сигналу будувався усереднений серцевий цикл. Для кожного усередненого циклу з ППШ та без будувалися скейлограми як за класичним БВП, так і за модифікованим вейвлет-перетворенням. Скануючим вейвлетом був обраний вейвлет Морле з $\omega_0 = 6$ рад/відлік, система масштабів була обрана логарифмічна, 40 масштабів у діапазоні 40-200 Гц. Для модифікованого БВП цільову амплітуду встановлено $A = 0,06$ мВ, коефіцієнт чутливості $q = 2$. Як коригувальна функція $correct(t)$ використовувалося віднімання середнього значення на кожній ітерації.

У результаті було отримано по 1000 скейлограм із ППШ та без ППШ для класичного та модифікованого вейвлет-перетворення. На цих даних навчалися різні поширені архітектури нейронних мереж. Співвідношення навчальної та тестової вибірок становило 85 % / 15 %. Усі моделі навчалися з оптимізатором Adam [117], зі швидкістю навчання 0,01, розміром міні-вибірки 70 та кількістю

epoch 10. Графіки точності класифікації, які отримано під час навчання різних типів нейронних мереж наведено на рис.5.9.




Рис. 5.9 Порівняння процесу навчання різних нейронних мереж з використанням класичного та модифікованого БВП:

а – точність моделі ResNet в залежності від номеру тренувальної епохи, б – точність моделі DenseNet, в – точність моделі MobileNet v2, г – точність моделі MobileNet v3, д – точність моделі ShuffleNet, е – точність моделі ResNeXt-50. [6]

Аналіз графіків точності класифікації (рис. 5.9 а-е) показав, що вже на першій епосі точність моделей, що навчалися на основі модифікованого вейвлет-перетворення, істотно перевищує точність моделей, що навчалися на основі класичного БВП. Хоча на 10-ій епосі обидва методи дають схожу точність, у межах 1-4 епох модифікований БВП забезпечував істотно кращі результати. Крім того, деякі архітектури, навчання яких базувалося на класичному БВП, потрапляли в локальні мінімуми та припиняли навчатися (рис. 5.9 г, е), тоді як мережі, навчені на модифікованому БВП, відображали стабільний процес навчання. Це говорить про кращу збіжність моделей з використанням розробленого модифікованого вейвлет-перетворення. Крім того, отримані результати свідчать, що модифіковане вейвлет-перетворення дає змогу точніше виділяти інформативні ознаки, необхідні для класифікації сигналів. Також на основі класичного та модифікованого вейвлет перетворення

було оцінено точність, чутливість та специфічність різних класифікаційних моделей в задачі виявлення ЕКГ з наявними ППШ. Результати класифікації наведено в таблиці 5.2.

Таблиця 5.2 Порівняння точності класифікації ППШ з використанням поширених архітектур нейронних мереж, що тренувалися на даних, які отримано за допомогою модифікованого та класичного БВП.

Назва моделі	Чутливість		Специфічність		Загальна точність	
	Класич. БВП	Мод. БВП	Класич. БВП	Мод. БВП	Класич. БВП	Мод. БВП
Res Net	0.82	0.9	1	0.98	0.97	0.99
Dense Net	0.97	0.96	0.99	0.98	0.98	0.98
Mobile Net v2	0.96	0.91	0.99	0.99	0.98	0.95
Mobile Net v3	1	1	0	0.64	0.5	0.83
Shuffle Net	0.93	0.97	0.99	0.99	0.96	0.98
Resnext 50	0	0.98	1	0.94	0.5	0.96

Аналізуючи результати класифікації за показниками чутливості, специфічності та загальної точності (табл. 5.2), можна відзначити, що моделі, навчені на даних, що отримано за допомогою модифікованого БВП, у більшості випадків демонструють вищу точність порівняно з моделями, навченими на класичному БВП. Зокрема, для нейронних мереж MobileNet v3 та ResNet-50 десяти епох навчання виявилось недостатньо, щоб перевищити поріг точності у 50 % під час використання класичного БВП. Натомість для модифікованого БВП точність класифікації для цих же моделей була суттєво вищою та досягала 83 та 96 %.

Висновки до розділу 5

В даному розділі досліджено можливості підвищення ефективності автоматизованого виявлення низькоамплітудних компонентів на ЕКГ, зокрема ППШ та ППП, які є критично важливими маркерами небезпечних для життя аритмій, але часто залишаються непомітними для стандартних методів аналізу. В результаті роботи було отримано, що:

1. Розроблений підхід до формування навчальної вибірки для сіамських нейронних мереж на ЕКГ даних з низькоамплітудними компонентами дав можливість суттєво підвищити чутливість класифікації в діапазоні від 9% до 12% залежно від класу патологій порівняно зі спеціалізованою більш розповсюдженою архітектурою «ECGNet».

2. Використання розроблених покращень методу БВП дало можливість не лише покращити точність розпізнавання, а й підвищити швидкість і стабільність навчання нейромережових моделей. Це свідчить про можливість побудови нового апаратно-програмного інструментарію для ранньої діагностики аритмій, здатного виявляти слабо виражені електрофізіологічні прояви, що раніше залишалися складними для виявлення.

3. Проведене вдосконалення методу вейвлет-перетворення за допомогою введення масштабуючої функції та косинусної подібності забезпечило точнішу локалізацію низькоамплітудних структур у частотно-часовій області, створивши умови для більш коректного подальшого аналізу та навчання класифікаційних моделей.

4. Отримані результати підтверджують практичну значущість досліджених методів і визначають перспективу їх подальшого розвитку, зокрема їх інтеграцію у програмне забезпечення апаратних платформ діагностики та адаптацію для різних типів ЕКГ сигналів.

РОЗДІЛ 6 СИСТЕМА ВИЯВЛЕННЯ СЕРЦЕВИХ АРИТМІЙ

6.1 Розробка структури та алгоритму функціонування системи для виявлення аритмій серця

Для впровадження нейромережевої діагностики аритмій потрібна інфраструктура, здатна інтегрувати ЕКГ сигнали з різних джерел – від клінічних моніторів до носимих пристроїв. Такі системи автоматизують аналіз ЕКГ, виявляючи навіть низькоамплітудні зміни, непомітні під час стандартних досліджень. Вони ефективно ідентифікують фібриляцію передсердь, шлуночкові аритмії, ішемічні зміни, блокади та синдроми на кшталт СВПУ.

Хоча алгоритми не замінюють лікаря, вони зменшують його навантаження, стандартизують оцінку ЕКГ та знижують ризик пропуску патологій. Ключовою вимогою є стабільна точність класифікації в умовах різноманітності ЕКГ сигналів в реальних умовах. Розроблені в дослідженні методи підвищують стійкість моделей до варіацій у сигналах та покращують виявлення малопомітних ознак. Їхнє комплексне впровадження здатне забезпечує підвищення надійності діагностичної системи.

Для вирішення цієї задачі було розроблено структуру комплексної системи, яка включає в себе підсистеми, що реалізують більшість розроблених методів, та націлена на ефективне застосування в реальних клінічних умовах. Ядром такої системи є обчислювальна підсистема аналізу ЕКГ на основі методів машинного навчання. Блок-схема такої підсистеми наведена на рис. 6.1.




Рис. 6.1 Блок-схема підсистеми автоматизованого аналізу ЕКГ

Запропонована блок-схема обчислювальної підсистеми, що наведена на рис. 6.1, має два основних структурних блока. Один призначений для обробки 12-канальної ЕКГ, інший для 1-канальної. Така структура здатна забезпечити рішення більшості клінічних задач оскільки 1-канальні записи характерні для портативних і носимих пристроїв, що використовуються у тривалому моніторингу пацієнтів, тоді як 12-канальна ЕКГ є стандартом для повноцінної клінічної діагностики та детального оцінювання електричної активності серця. Інші можливі формати ЕКГ, що містять 2 і більше каналів (наприклад, патч-монітори, кардіологічні реєстратори подій, домашні телемедичні системи), можуть бути алгоритмічно зведені до одного з цих двох основних режимів обробки, тобто або трактуватися як розширена 1-канальна ЕКГ, або 12-канальна за наявності достатньої кількості відведень. Така структура підсистеми забезпечує гнучкість і можливість масштабованого впровадження у широкий спектр клінічних застосувань.

Основою механізму прийняття рішень у відповідному структурному блоці системи є сіамська нейронна мережа [4], архітектурні особливості якої дають змогу формувати стійкі діагностичні передбачення навіть за умов малої кількості класів з патологіями у тренувальному наборі. На відміну від

традиційних класифікаційних моделей, сіамська мережа оперує не належністю до фіксованого набору класів, а мірою подібності між вектором ознак еталонного зразка та вектором ознак ЕКГ сигналу, що досліджується. Завдяки цьому вона здатна коректно ідентифікувати аномальні патерни навіть у випадках, коли конкретні приклади серцевої патології були відсутні в даних, використаних під час навчання, що істотно підвищує узагальнюючу здатність моделі та її придатність до реальних клінічних умов.

Для підвищення швидкості збіжності та стабільності процесу навчання сіамської нейронної мережі, а також збільшення узагальнювальної здатності в її архітектуру було інтегровано адаптивну функцію активації, розроблену в межах проведеного дослідження [7]. Застосування такої активаційної функції спрямоване на мінімізацію ефектів згасання та вибуху градієнтів, що є критичними факторами під час навчання глибоких моделей, особливо в умовах обмеженого обсягу даних, а також великої кількості класів з патологіями, які необхідно ефективно диференціювати. Отже, розроблена адаптивна активаційна функція забезпечує більш стабільне формування простору ознак і підвищує ефективність навчання в задачах порівняльного аналізу сигналів.

Крім того, за допомогою розробленого методу виявлення «надлишкових» шарів нейронної мережі на основі адаптивних функцій активації [7] було проведено покращення архітектури розробленої нейронної мережі шляхом виявлення та видалення шарів, градієнти яких оновлювались повільно та не здійснювали суттєвого внеску у формування простору ознак для порівняння. Такий підхід дав змогу зменшити кількість параметрів моделі без втрати діагностичної точності, а в окремих випадках навіть підвищити її за рахунок усунення перенавчання та надмірної кореляції між шарами.

Для забезпечення належної якості вхідних даних запропонована структура, яка окрім стандартних процедур фільтрації та нормалізації ЕКГ сигналу, містить окремі функціональні блоки для побудови усереднених

кардіоциклів та видалення зашумлених або некоректно сегментованих циклів. Блок видалення зашумлених кардіоциклів здійснює попереднє сегментування сигналу на основі алгоритму Пана-Томпкінса, після чого усуває цикли, що містять надмірний рівень шуму, значні морфологічні спотворення або артефакти, які могли бути помилково інтерпретовані як кардіоцикли. Для цього використано розроблений метод видалення помилково ідентифікованих кардіоциклів [9], який виконує функцію знешумлення та підвищує якість вибірки сегментованих фрагментів ЕКГ для формування усередненого циклу.

Формування усереднених кардіоциклів було проведено на основі методу попередньої обробки сигналу, спрямованого на покращення виявлення ППП та ППШ [5], що забезпечує формування усередненого кардіоциклу з підвищеною надійністю та зберігає низькоамплітудні періодичні компоненти ЕКГ сигналу, які мають клінічну значущість.

Для підвищення якості виявлення низькоамплітудних компонентів ЕКГ сигналу було застосовано модифіковане вейвлет-перетворення [6], яке дає змогу селективно підсилювати малопотужні періодичні компоненти сигналу з амплітудою близько 0,025 мВ. Саме в цьому діапазоні зазвичай реєструються (ППШ) та (ППП), що робить запропонований метод особливо ефективним для їхнього виявлення на фоні високоамплітудних компонентів основного ЕКГ сигналу.

Фрагмент стандартизованого та фільтрованого ЕКГ сигналу, усередненого кардіоциклу та коефіцієнтів модифікованого вейвлет-перетворення об'єднуються в вектор ознак ЕКГ сигналу, який має форму одномірного масиву у випадку аналізу 1-канальної ЕКГ, або матриці значень у випадку 12-канальної ЕКГ. Отриманий вектор ознак зберігається в локальну базу анотованих ЕКГ для подальшої обробки та інтерпретації, а також подається на нейромережевий автоенкодер [3], сформований латентний простір якого являє собою компактний вектор ознак, який здатний підвищити

точність, та підвищити швидкість роботи сіамської нейронної мережі, на яку він надходить.

Для проведення порівняння, з локальної бази даних відбирається близько 100 ЕКГ з патологією, що досліджується, та за допомогою суми перших п'яти правих головних векторів сингулярного розкладу (Σ SVD[5]) формується еталонний вектор ознак. Керування набором даних для формування еталонного вектора ознак, а також анотації і збереження нових ознак ЕКГ сигналу виконується за допомогою зовнішнього програмного блоку керування базою даних. Цей функціональний блок централізовано керує потоками даних, забезпечує збереження й оновлення наборів ознак, автоматично формує еталонні вектори та дає змогу оновлювати систему з урахуванням нових пацієнтів, класів патологій або типів ЕКГ сигналів.

Паралельно з основним трактом обробки сигнал, що пройшов стандартизацію, фільтрацію та корекцію дрейфу ізолінії, надходить до блоку алгоритмічної детекції f-хвиль. Цей блок побудований на основі розробленого алгоритму для виявлення ознак тахіаритмій [12] та призначений для автоматизованого розпізнавання фібриляції передсердь і шлуночків, що становлять безпосередню загрозу життю пацієнта. На відміну від основного блоку класифікації, цей модуль працює у режимі додаткового контролю й формує сигнал тривоги, що дає змогу своєчасно розпочати клінічне втручання та надати своєчасну невідкладну допомогу.

Результуючі сигнали структурного блоку аналізу ЕКГ, а саме значення рівня схожості з еталонним вектором ознак, а також наявність сигналу тривоги передається лікарю та пацієнту через програмні засоби, забезпечуючи можливості для інформування та подальшого прийняття рішень.

Для практичного впровадження розробленого блоку аналізу ЕКГ недостатньо лише створити програму за описаною блок-схемою підсистеми, необхідно також забезпечити узгоджену координацію даних, що надходять із

різних джерел: клінічних електрокардіографів, портативних моніторів, персональних сенсорів та інших пристроїв реєстрації сигналу. Крім того, система має містити зручний і достатньо функціональний інтерфейс як для лікарів, так і для пацієнтів, який дає можливість одночасно працювати з ЕКГ сигналами, виконувати класифікацію, переглядати результати аналізу та формувати клінічні висновки.

Таку систему доцільно реалізувати на центральному обчислювальному вузлі, наприклад серверному обладнанні, яке здатне забезпечити централізоване керування джерелами та потоками даних, координацію обладнання та узгоджену роботу програмних модулів. Такий підхід дає змогу створити надійну, захищену та керовану інфраструктуру, до якої можуть підключатися портативні пристрої, стаціонарні робочі станції та інші клієнтські термінали. Це суттєво спрощує масштабування системи, забезпечує високу стійкість та стабільну швидкодію незалежно від кількості підключених користувачів або типів ЕКГ обладнання. Блок-схема такої системи наведена на рис. 6.2.



Рис. 6.2. Блок-схема системи автоматизованого виявлення аритмій за допомогою методів машинного навчання

На вхід системи автоматизованого виявлення аритмій надходять дані з різних стаціонарних електрокардіографів, які під'єднані до серверу як через дротові, так і бездротові канали зв'язку та передають дані за допомогою

спеціалізованих протоколів обміну медичними сигналами, наприклад SCP-ECG, HL7, DICOM-ECG, або власних протоколів виробника. Після надходження сигнали обробляються блоком обробки даних електрокардіографів, де проходять етап первинної валідації, синхронізації та нормалізації формату, що забезпечує уніфіковане представлення даних незалежно від моделі пристрою, частоти дискретизації чи кількості каналів.

Така система може бути реалізована на централізованому обчислювальному вузлі, наприклад серверній частині, до якої можуть під'єднуватися різні пристрої, що наявні в лікарні, включаючи клінічне обладнання та персональні комп'ютери.

Окремим елементом системи є блок управління доступом до мережі, який поєднує контроль якості та стабільності передачі даних з багаторівневими механізмами мережевої безпеки. Передавання даних між пристроями та серверною частиною здійснюється через зашифровані канали зв'язку із застосуванням VPN-тунелювання [141], що гарантує захист трафіку навіть у середовищах, до яких можуть під'єднуватися велика кількість зовнішніх користувачів. Для бездротових підключень використовуються сучасні протоколи Wi-Fi-захисту (WPA3-Enterprise, 802.1X, EAP-TLS), що забезпечують шифрування мережі [142]. Додатковий рівень захисту блоку управління доступом до мережі реалізується через апаратно-програмний засіб фільтрації мережевого трафіку. Такий підхід унеможливорює несанкціонований доступ ззовні, мінімізує ризики мережевих атак, перехоплення трафіку та інших мережевих загроз [55].

Усі мережеві події зберігаються та аналізуються системою, що дозволяє виявляти спроби вторгнення в режимі реального часу. Отже, система одночасно відповідає вимогам медичної кібербезпеки ISO/IEC 27001 [143] та забезпечує захищену передачу даних між сервером, клінічними пристроями та мобільними клієнтами.

Керуючим блоком такої системи є блок обробки клієнтського застосунку, який синхронізує потоки даних з блоків ЕКГ аналізу, базою даних та інших структурних блоків, забезпечуючи узгоджену роботу всіх підсистем у режимі реального часу. Він відповідає за маршрутизацію запитів, збереження результатів обробки, контроль послідовності подій, а також формування структурованих відповідей для різних типів клієнтів – лікарських робочих станцій, мобільних застосунків пацієнтів та адміністративних інтерфейсів різного ЕКГ обладнання [144].

Важливим етапом додаткової обробки ЕКГ даних є блок виявлення груп ризику, який розроблений на основі сучасних підходів до високорозмірного кластерного аналізу біомедичних сигналів. Зокрема, для виявлення латентних структур у багатовимірних просторах ознак використано методологію, яку описано в дослідженні «Scalable Clustering of Complex ECG Health Data: Big Data Clustering Analysis with UMAP and HDBSCAN» [8], де поєднуються алгоритм нелінійного зниження розмірності «UMAP» з методом кластерного аналізу «HDBSCAN». Такий підхід дає змогу виявляти групи пацієнтів, патологічні патерни та спільні морфологічні ознаки ЕКГ навіть за відсутності попередніх міток, що особливо важливо у випадках, коли традиційні класифікаційні методи не дозволяють чітко розмежувати подібні стани. Застосування такого підходу дасть можливість лікарям більш надійно виявляти ознаки серцевих патологій, порівнюючи клінічні випадки та робити більш обґрунтовані діагностичні рішення.

6.2 Алгоритм функціонування та спосіб застосування системи в клінічних умовах

Алгоритм функціонування системи виявлення аритмій описує процес обробки сигналу ЕКГ, отриманого від стаціонарних електрокардіографів або портативних носимих пристроїв (рис. 6.3).

Реєстрація ЕКГ сигналу здійснюється з використанням мікроелектронних систем на чіпі, які включають мікроелектронні аналогові тракти з низьким рівнем шуму, що забезпечують стабільність вимірювань АЦП і можливість фіксації низькоамплітудних складових ЕКГ сигналу під час оцифровування. Завдяки застосуванню сучасних мікроелектронних компонентів досягається високий коефіцієнт відношення сигнал/шум, що є критичним для збереження слабо виражених патологічних ознак на ЕКГ.




Рис. 6.3. Алгоритм функціонування системи виявлення серцевих аритмій

На початковому етапі здійснюється налаштування параметрів реєстрації сигналу та попередньої обробки, що включає вибір параметрів фільтрації, нормалізації, сегментації та аналізу залежно від типу кардіографа, кількості каналів і частоти дискретизації. Такий підхід забезпечує можливість

коректного налаштування для роботи з одноканальними і багатоканальними ЕКГ записами.

Після оцифровування ЕКГ сигнал проходить етапи стандартизації, нормалізації амплітуди та корекції дрейфу ізолінії, після чого виконується попередня обробка, що включає фільтрацію та поділ на окремі кардіоцикли. Зашумлені кардіоцикли автоматично видаляються, та з отриманої вибірки формується усереднений кардіоцикл, який використовується як інформативне представлення ЕКГ сигналу, що містить низькоамплітудні ознаки.

Для підвищення чутливості системи до малопомітних патологічних ознак на ЕКГ застосовується модифіковане вейвлет-перетворення, що дозволяє селективно підсилювати низькоамплітудні компоненти ЕКГ сигналу. Отримані коефіцієнти вейвлет-перетворення разом із фрагментами стандартизованого сигналу та усередненого кардіоциклу об'єднуються у вектор ознак ЕКГ сигналу.

Крім того, для застосування сіамської нейронної мережі формується еталонний вектор ознак з цільовою серцевою патологією. Формування еталонного вектора ознак відбувається завдяки відбору анотованих ЕКГ з бази даних, керування якою здійснюється окремим функціональним блоком. Блок керування базою даних забезпечує централізоване збереження, анотацію та оновлення наборів даних окремих патологій, а також забезпечує доступ до попередньо анотованих ЕКГ записів для формування еталонних векторів ознак відповідних патологій.

Для зменшення обчислювальної складності та підвищення узагальнюючої здатності НМ, вектор ознак для аналізу та еталонний вектор ознак з патологією що досліджується, подається на нейромережевий автоенкодер, який виконує зниження розмірності та формує компактне латентне представлення. Отримані латентні вектори надходять на вхід сіамської нейронної мережі, яка здійснює порівняння вектора ознак ЕКГ

сигналу, що досліджується, зі сформованим еталонним вектором ознак. Результатом роботи сіамської мережі є оцінка ступеня подібності двох векторів, яка використовується як основний діагностичний показник.

Додатково в системі функціонує незалежний контур детекції хвиль фібриляції, що забезпечує формування сигналу тривоги в режимі реального часу. Такий контур може бути побудований на основі сучасних мікроелектронних сигнальних процесорів, що здатні забезпечити високу швидкість та надійність спрацьовування.

Додатково в системі реалізовано блок пошуку прихованих груп ризику, який використовує методи зниження розмірності та кластерного аналізу ознак ЕКГ. Цей блок дозволяє виявляти латентні групи пацієнтів зі схожими морфологічними характеристиками сигналу, вказуючи лікарю на можливі захворювання серцево-судинної системи, які можуть паралельно розвиватися у пацієнта.

Отримані результати роботи системи, а саме, оцінка схожості з еталонним вектором ознак, належність до прихованих груп ризику, та сигнал тривоги (за наявності), передаються лікарю для підтримки прийняття клінічних рішень. Після клінічної інтерпретації здійснюється перевірка факту встановлення діагнозу. У разі підтвердження діагноз передається пацієнту через клієнтське програмне забезпечення запропонованої системи, а у випадку відсутності остаточного висновку лікар починає повторний аналіз, який може передбачати коригування параметрів реєстрації сигналу та попередньої обробки або переформування еталонного вектора ознак для встановлення більш точного діагнозу.

Для застосування вищеописаної системи в клінічних умовах був розроблений спосіб, який описує послідовність використання основних етапів обробки ЕКГ сигналу, а також застосування методів машинного навчання, зокрема сіамської нейронної мережі, для допомоги лікарю в прийнятті

діагностичних рішень про наявність різних видів аритмій та супутніх патологій.

Розроблений спосіб починається з запису сигналу тривалістю 10-600 секунд у 1 або 12 відведеннях. На етапі підготовки формується тренувальна вибірка з пар «ЕКГ сигнал – еталонний вектор ознак», де еталон створюється шляхом сингулярного розкладу 100 зразків ЕКГ з цільовою серцевою патологією.

Сіамська мережа з ідентичними гілками навчається оцінювати схожість між сигналом, що досліджується, та еталоном. Після навчання початковий сигнал проходить попередню обробку, а саме фільтрацію, сегментацію на цикли, видалення зашумлених ділянок та формування усередненого кардіоциклу. Для посилення низькоамплітудних компонентів (зокрема пізніх потенціалів) застосовується модифіковане вейвлет-перетворення. Отримані ознаки стискаються автоенкодером і порівнюються з еталоном через сумарну абсолютну відстань між відповідними компонентами векторів (L1-норму) [89], а результат оцінюється сигмоїдною функцією у діапазоні [0;1].

Лікар аналізує отриману оцінку схожості з урахуванням клінічного контексту. Спосіб дозволяє виявляти як виражені, так і низькоамплітудні патології, включаючи пізні потенціали. Використання сіамської архітектури замість традиційних методів класифікації усуває залежність від фіксованого набору патологій та дозволяє аналізувати нові захворювання без перенавчання. Розроблений спосіб може бути адаптований для роботи з різними джерелами даних – від клінічних систем до портативних пристроїв.

Даний спосіб було описано на основі патенту на корисну модель № 161727 [13], який був сформований за результатами проведених досліджень.

Висновки до розділу 6

В результаті роботи над структурою та алгоритмом функціонування системи для виявлення аритмій було отримано наступні результати:

1. Узагальнено результати розробки системи автоматизованого аналізу ЕКГ, орієнтованої на виявлення як виражених, так і низькоамплітудних ознак патологій, зокрема пізніх потенціалів та аритмій.

2. Показано, що ефективне впровадження нейромережових методів у медичну практику потребує повної інфраструктури, здатної приймати, синхронізувати та обробляти дані з різних джерел: від стаціонарних 12-канальних ЕКГ систем до портативних кардіографів і телемедичних пристроїв.

3. Розроблено структуру системи, що об'єднує попередню фільтрацію та сегментацію сигналів, модифіковане вейвлет-перетворення, стиснення векторів ознак за допомогою автоенкодера, сіамську нейронну мережу для порівняльного аналізу та механізми виявлення небезпечних для життя станів серцево-судинної системи. Це забезпечує стійкість до шумів, різних частот дискретизації, нестандартних форматів ЕКГ записів та дає змогу працювати навіть із рідкісними патологіями без потреби у наявності великої кількості тренувальних даних.

4. Визначено, що розроблена система здатна функціонувати як клінічний інструмент підтримки діагностичних рішень, оскільки не лише автоматизує інтерпретацію сигналу, а й виявляє ознаки, які важко помітити в умовах стандартного аналізу.

5. Розроблено алгоритм функціонування та спосіб застосування створеної системи, який підтверджує практичну можливість масштабованого впровадження розроблених підходів для аналізу ЕКГ як у клінічних закладах, так і в телемедичних рішеннях, орієнтованих на тривале моніторування пацієнтів.

ЗАГАЛЬНІ ВИСНОВКИ

Проведене дослідження присвячено розробці системи автоматизованого виявлення серцевих аритмій на ЕКГ сигналах з використанням сучасних методів машинного навчання та нейронних мереж. У дисертації виконано теоретичне узагальнення і вирішення низки ключових наукових та практичних завдань, спрямованих на підвищення точності, чутливості, специфічності та швидкості автоматизованого виявлення аритмій на ЕКГ. Метою дослідження було створення комплексного підходу, що поєднує вдосконалені методи попередньої обробки сигналів, виділення ознак, зменшення розмірності даних та розробка нейромережевих моделей, що представляє основу інформаційно-алгоритмічного забезпечення системи виявлення аритмій для ефективного застосування в клінічних умовах.

Основні результати дисертаційної роботи:

1. Розроблено комплекс класифікаційних моделей сіамських нейронних мереж, особливістю яких є використання згорткових шарів для паралельної обробки двох типів фрагментів даних: усередненого кардіоциклу з детальними морфологічними характеристиками та ЕКГ сигналу, що відображає варіабельність серцевого ритму, а також застосування розроблених еталонних векторів ознак патологій для виявлення аритмій, супутніх патологічних станів а також пізніх потенціалів шлуночків і передсердь на ЕКГ в умовах обмеженої кількості тренувальних даних. Розроблені моделі забезпечили класифікацію 37 типів аритмій і патологій із середньою точністю 72%, що перевищує результати спеціалізованої моделі ECGNet до 23% для окремих патологій.

2. Розроблено нову адаптивну функцію активації, відмінністю якої є нелінійна залежність з властивістю стискаючого відображення, що на основі зменшення проблеми вибуху та згасання градієнтів під час застосування в послідовних шарах нейронних мереж сприяє розпізнаванню

низькоамплітудних складових ЕКГ, а також за допомогою запропонованого методу виявлення «надлишкових» шарів призводить до підвищення швидкості роботи НМ без втрати точності. Застосування даної функції забезпечило досягнення точності 94,7% у виявленні пізніх потенціалів шлуночків.

3. Розроблено метод зменшення розмірності ознак ЕКГ сигналу на основі нейромережевого автоенкодера з використанням шару уваги, залишкових зв'язків та спільних ваг шарів нейронної мережі. Отримано скорочений вектор із коефіцієнтом стиснення $K = 25$, який зберігає діагностично значущі характеристики ЕКГ.

4. Розроблено алгоритмічне забезпечення для системи виявлення груп ризику та прихованих патологічних профілів на основі кластерного аналізу ЕКГ параметрів без вчителя. Комбінація алгоритмів на основі методів машинного навчання без вчителя UMAP та HDBSCAN дозволила виявити відмінності між здоровими пацієнтами та пацієнтами з серцевою недостатністю, а також окреслити латентні групи ризику розвитку небезпечних серцевих станів.

5. Вдосконалено метод усереднення кардіоциклів ЕКГ сигналів, орієнтований на збереження морфології низькоамплітудних компонентів за рахунок розбиття на епохи та використання матричних розкладів, який забезпечив підвищення точності відтворення пізніх потенціалів передсердь і шлуночків на 10-30% порівняно з класичним методом усереднення на основі оцінювання показників подібності з еталонними пізніми потенціалами з амплітудою 5 мкВ.

6. Вдосконалено метод вейвлет-перетворення за допомогою введення масштабуючої функції та косинусної подібності, що дозволяє підвищити точність і надійність виявлення низькоамплітудних ознак патологій на ЕКГ.

7. Розроблено моделі нейронних мереж для виявлення помилково детектованих або зашумлених кардіоциклів, що дає можливість видаляти

спотворені фрагменти ЕКГ сигналу та підвищувати точність виявлення пізніх потенціалів шлуночків і передсердь на 19% на основі аналізу показника подібності динамічної трансформації часової шкали в порівнянні з використанням класичного ЕКГ детектора.

8. Запропоновано алгоритми виділення діагностично значущих ознак на ЕКГ із використанням методів попередньої обробки ЕКГ сигналів, що дозволяє забезпечити швидке та надійне виявлення тахіаритмій і патологічних форм QRS-комплексів.

9. Розроблено структуру, алгоритм функціонування та спосіб застосування в клінічних умовах системи виявлення серцевих аритмій на ЕКГ, придатної для роботи з 12-канальними стаціонарними, портативними та імплантованими ЕКГ пристроями, особливістю якої є використання розроблених методів машинного навчання, попередньої обробки сигналів та моделей нейронних мереж.

10. Результати роботи над дисертацією, а саме аналіз та розробка нейромережових технологій було впроваджено в рамках педагогічної практики на каф. ЕІ. Також за результатами досліджень було розроблено «Спосіб автоматизованого аналізу електрокардіографічних сигналів», за яким було зареєстровано патент на корисну модель № 161727.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

[1] World Health Organization, «Cardiovascular diseases (CVDs),» World Health Organization (WHO), Mar. 2021. [Електронний ресурс]. Доступно: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

[2] S. S. Virani, A. Alonso, H. J. Aparicio, E. J. Benjamin, M. S. Bittencourt, C. W. Callaway, A. P. Carson, A. M. Chamberlain, S. Cheng, F. N. Delling, M. S. V. Elkind, K. Evenson, J. F. Ferguson, D. K. Gupta, S. S. Khan, B. M. Kissela, K. Knutson, C. D. Lee, T. T. Lewis, J. Liu, M. S. Loop, P. L. Lutsey, J. Ma, J. Mackey, S. S. Martin, D. Matchar, M. E. Mussolino, S. Navaneethan, A. M. Perak, G. A. Roth, Z. Samad, G. M. Satou, E. B. Schroeder, S. H. Shah, C. M. Shay, A. Stokes, L. B. VanWagner, N-Y. Wang, and C. W. Tsao, «Heart Disease and Stroke Statistics-2021 Update: A Report From the American Heart Association,» *Circulation*, т. 143, № 8, с. e254-e743, 2021. doi: [10.1161/CIR.0000000000000950](https://doi.org/10.1161/CIR.0000000000000950).

[3] A. Mnevec and N. Ivanushkina, “Neural network autoencoder model for forming reduced vector characteristics of ECG signals,” *Bulletin of Kyiv Polytechnic Institute Series Instrument Making*, vol. 69, no. 1, pp. 93–105, 2025, doi: [https://doi.org/10.20535/1970.69\(1\).2025.331920](https://doi.org/10.20535/1970.69(1).2025.331920) , ISSN 2663-3450.

[4] A. V. Mnevets and N. H. Ivanushkina, “Siamese neural network’s models for cardiac arrhythmia classification in the conditions of shortage of training ECG signals,” *Microsystems Electronics and Acoustics*, vol. 30, no. 2, 2025, doi: <https://doi.org/10.20535/2523-4455.mea.325111>, ISSN 2523-4455.

[5] A. V. Mnevets and N. H. Ivanushkina, “The method of preprocessing of ECG signals for detection of atrial and ventricular late potentials,” *Microsystems Electronics and Acoustics*, vol. 28, no. 2, 2023, doi: <https://doi.org/10.20535/2523-4455.mea.281741>, ISSN 2523-4455.

[6] A. V. Mnevets and N. G. Ivanushkina, “Neural networks detection of low-amplitude components on ECG using modified wavelet transform,” *Visnyk NTUU KPI Seriiia – Radiotekhnika Radioaparotobuduvannia*, no. 97, pp. 46–57, 2024, doi: <https://doi.org/10.20535/radap.2024.97.46-57>, ISSN 2310-0389.

[7] А. В. Мневець and Н. Г. Іванушкіна, «Класифікація низькоамплітудних компонент ЕКГ за допомогою адаптивних функцій активації нейронних мереж», *Вісті вищих учбових закладів. Радіоелектроніка*, vol. 67, no. 12, pp. 719–732, 2024, doi: <https://doi.org/10.20535/s0021347024120021>, ISSN 1934-8061.

[8] V. Kaverinskiy, I. Chaikovsky, A. Mnevets, T. Ryzhenko, M. Bocharov, and K. Malakhov, “Scalable clustering of complex ECG health data: Big data clustering analysis with UMAP and HDBSCAN,” *Computation*, vol. 13, no. 6, Art. no. 144, 2025, doi: <https://doi.org/10.3390/computation13060144>, ISSN 2079-3197.

[9] N. Ivanushkina та A. Mnevets, “Detection of Erroneously Selected Cardiac Cycles Using Neural Networks”, у 2024 IEEE 42nd Int. Conf. Electron. Nanotechnol. (ELNANO), Kyiv, Ukraine, 13-16 трав. 2024. IEEE, 2024, с. 406-411, doi: [10.1109/ELNANO63394.2024.10756903](https://doi.org/10.1109/ELNANO63394.2024.10756903).

[10] А. В. Мневець, Н. Г. Іванушкіна і К. О. Іванько, «Застосування сіамських нейронних мереж для підвищення точності виявлення серцево-судинних захворювань за нестачі тренувальних даних», *Матеріали 5-ї Міжнар. наук.-техн. конф., 28-29 листоп. 2024 р., Нац. техн. ун-т «Харків. політехн. ін-т» [та ін.]*, Харків, 2024. [Електронний ресурс]. Доступно: <https://repository.kpi.kharkov.ua/handle/KhPI-Press/84178>

[11] O. Shulyak, A. Mnevets та V. Lagutin, “Grouping Training Samples To Increase The Validity Of Recognition Algorithm Solutions”, у 2022 IEEE 41st Int. Conf. Electron. Nanotechnol. (ELNANO), Kyiv, Ukraine, 10-14 жовт. 2022. IEEE, 2022, doi: [10.1109/elnano54667.2022.9927020](https://doi.org/10.1109/elnano54667.2022.9927020).

[12] А. В. Мневєць і Н. Г. Іванушкіна, «Виявлення ознак тахіаритмій шляхом вейвлет-аналізу електрокардіосигналів», Тези доповідей IV Міжнар. наук.-техн. конф. «Автоматизація, електроніка, інформаційно-вимірювальні технології: освіта, наука, практика», м. Харків, Нац. техн. ун-т «Харків. політехн. ін-т», 2022., doi: [10.5281/zenodo.7750728](https://doi.org/10.5281/zenodo.7750728).

[13] А. В. Мневєць, Н. Г. Іванушкіна, «Спосіб автоматизованого аналізу електрокардіографічних сигналів», патент України на корисну модель № 161727, Україна, груд. 25, 2025. Дата звернення: 4 січ. 2026 [Онлайн]. Доступно: <https://sis.nipo.gov.ua/uk/search/detail/1891912/>

[14] “When Electrolyte Meets Electrodes: Interface”, у *Electrolytes, Interfaces and Interphases*. Roy. Soc. Chemistry, 2023, с. 131–191. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1039/9781839166174-00131>

[15] А. В. de Luna, “Willem Einthoven and the ECG”, *Eur. Heart J.*, т. 40, № 41, с. 3381–3383, листоп. 2019. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1093/eurheartj/ehz721>

[16] G. Boriani та M. Vitolo, “The 12-lead ECG”, *J. Cardiovascular Medicine*, т. 20, № 7, с. 459–463, лип. 2019. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.2459/jcm.0000000000000803>

[17] J. Vondrak та M. Penhaker, “Review of Processing Pathological Vectorcardiographic Records for the Detection of Heart Disease”, *Frontiers Physiol.*, т. 13, берез. 2022. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3389/fphys.2022.856590>

[18] J. Janousek, T. Paul та H. Barta'kova', “Role of late potentials in identifying patients at risk for ventricular tachycardia after surgical correction of congenital heart disease”, *Amer. J. Cardiol.*, т. 75, № 2, с. 146–150, січ. 1995. Дата

звернення: 10 жовт. 2025. [Онлайн]. Доступно: [https://doi.org/10.1016/s0002-9149\(00\)80064-8](https://doi.org/10.1016/s0002-9149(00)80064-8)

[19] Analog Devices, “Introduction to Electrocardiographs,” Analog Devices Technical Articles, 10 трав. 2010 р. [Електронний ресурс]. Доступно: <https://www.analog.com/en/resources/technical-articles/introduction-to-electrocardiographs.html>

[20] V. Dakić, L. Mršić, Z. Kunić та G. Đambić, “Evaluating ARM and RISC-V Architectures for High-Performance Computing with Docker and Kubernetes”, Electronics, т. 13, № 17, с. 3494, верес. 2024. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/electronics13173494>

[21] A.-S. Oh, “A Study on HL7 Standard Message for Healthcare System Based on ISO/IEEE 11073”, Int. J. Smart Home, т. 9, № 6, с. 113–118, черв. 2015. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.14257/ijsh.2015.9.6.13>

[22] A. Grob, B. Biersach та J. Peck, “Risk Management And IEC 60601-1: Assessing Compliance”, Biomed. Instrum. & Technol., т. 49, s1, с. 55–59, січ. 2015. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.2345/0899-8205-49.s1.55>

[23] Analog Devices, “ADAS1000 vs ADS1298 ADC,” EngineerZone - Analog Devices, 24 черв. 2019. [Електронний ресурс]. Доступно: https://ez.analog.com/data_converters/precision_adcs/f/q-a/113065/adas1000-vs-ads-1298-adc

[24] H. Buchwald, “Lab Experiences with IEC 60601-1-2 4th Edition”, у 2018 IEEE Symp. Electromagn. Compat. Signal/Power Integrity (EMCSI), Long Beach, CA, USA, 30 лип.–3 серп. 2018. IEEE, 2018. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/emcsi.2018.8495382>

[25] A. Peck, “DICOM”, у Clark’s Essential PACS, RIS and Imaging Informatics. CRC Press, 2017, с. 85–100. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1201/9781315119823-8>

[26] M. Bravo-Zanoguera, D. Cuevas-González, M. A. Reyna, J. P. García-Vázquez та R. L. Avitia, “Fabricating a Portable ECG Device Using AD823X Analog Front-End Microchips and Open-Source Development Validation”, Sensors, т. 20, № 20, с. 5962, жовт. 2020. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/s20205962>

[27] Texas Instruments, “ADS1292 - combining the ADS1292R and the ADS1293,” TI E2E Forum - Data Converters, 8 серп. 2020. [Електронний ресурс]. Доступно: <https://e2e.ti.com/support/data-converters-group/data-converters/f/data-converters-forum/1339646/ads1292-combining-the-ads1292r-and-the-ads1293>

[28] C. U. K. B. -, “Exploring the Diverse Universe of Entrepreneurship: A Comprehensive Overview of Entrepreneurial Types and Opportunities”, Int. J. Multidisciplinary Res., т. 6, № 2, берез. 2024. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.36948/ijfmr.2024.v06i02.14133>

[29] C. Ice, S. Hazrati, and S. Kaiser-Kershaw, “Role of Bluetooth LE, RFID, and NFC in the Internet of Medical Things,” Electronic Design, 30 квіт. 2024. [Електронний ресурс]. Доступно: <https://www.electronicdesign.com/technologies/communications/iot/article/55022040/nxp-semiconductors-role-of-bluetooth-le-rfid-and-nfc-in-the-internet-of-medical-things>

[30] AliveCor, “KardiaMobile® 6L: Medical-grade, 6-lead ECG in 30 seconds,” AliveCor. [Електронний ресурс]. Доступно: <https://alivecor.com/products/kardiamobile6l>

[31] CardioSecur, “CardioSecur Active. [Електронний ресурс]. Доступно: <https://shop.cardiosecur.com/shop/cardiosecur-active-1067>

[32] D. R. Seshadri та ін., “Accuracy of the Apple Watch 4 to Measure Heart Rate in Patients With Atrial Fibrillation”, *IEEE J. Translational Eng. Health Medicine*, т. 8, с. 1–4, 2020. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/jtehm.2019.2950397>

[33] S. Abu-Alrub та ін., “Smartwatch Electrocardiograms for Automated and Manual Diagnosis of Atrial Fibrillation: A Comparative Analysis of Three Models”, *Front. Cardiovasc. Med.*, т. 9, лют. 2022. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3389/fcvm.2022.836375>

[34] V. Goverdovsky, D. Looney, P. Kidmose та D. P. Mandic, “In-Ear EEG From Viscoelastic Generic Earpieces: Robust and Unobtrusive 24/7 Monitoring”, *IEEE Sensors J.*, т. 16, № 1, с. 271–277, січ. 2016. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/jsen.2015.2471183>

[35] H. Pürerfellner, P. Sanders, E. Pokushalov, M. Di Bacco, T. Bergemann та L. R. C. Dekker, “Miniaturized Reveal LINQ insertable cardiac monitoring system: First-in-human experience”, *Heart Rhythm*, т. 12, № 6, с. 1113–1119, черв. 2015. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.hrthm.2015.02.030>

[36] A. Garcia та ін., “Lessons learned in the Apple Heart Study and implications for the data management of future digital clinical trials”, *J. Biopharmaceutical Statist.*, с. 1–15, черв. 2022. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1080/10543406.2022.2080698>

[37] L. Koltowski та ін., “Kardia Mobile applicability in clinical practice: A comparison of Kardia Mobile and standard 12-lead electrocardiogram records in 100 consecutive patients of a tertiary cardiovascular care center”, *Cardiol. J.*, січ. 2013. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.5603/cj.a2019.0001>

[38] A. HASANI та M. NIKLEKAJ, “Security of VPNs in High-Surveillance Environments - A Comparative Study of VPN Alternatives”, *INGENIOUS*, т. 5, № 1, с. 108–116, січ. 2025. Дата звернення: 10 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.58944/cwql3216>

[39] R. R. Khanal, R. M. Gajurel, and S. Shah, “Arrhythmias: Its Occurrence, Risk Factors, Therapy, and Prognosis in Acute Coronary Syndrome,” *Journal of Nepal Health Research Council*, vol. 21, no. 1, Sep. 2023, Доступно: <https://doi.org/10.33314/jnhrc.v21i1.4019>

[40] T. Newman, “Arrhythmia: Types, causes, symptoms, and treatment,” *Medical News Today*, оновлено 22 трав. 2024. Доступно: <https://www.medicalnewstoday.com/articles/8887>

[41] A. Shah, D. Singh, H. G. Mohamed, S. Bharany, A. U. Rehman, and S. Hussien, “Electrocardiogram analysis for cardiac arrhythmia classification and prediction through self-attention based auto encoder,” *Scientific Reports*, vol. 15, no. 1, p. 9230, Mar. 2025. Доступно: <https://doi.org/10.1038/s41598-025-93906-5>.

[42] F. Shaffer i J. P. Ginsberg, “An Overview of Heart Rate Variability Metrics and Norms,” *Frontiers in Public Health*, vol. 5, 2017. Доступно: <https://doi.org/10.3389/fpubh.2017.00258>

[43] K. Chand, S. Chandra, and V. Dutt, “A comprehensive evaluation of linear and non-linear HRV parameters between paced breathing and stressful mental state,” *Heliyon*, vol. 10, no. 11, e32195, 2024. Доступно: <https://doi.org/10.1016/j.heliyon.2024.e32195>

[44] W. Grimm, J. Sharkova, M. Christ, R. Schneider, G. Schmidt, та B. Maisch, “Heart rate turbulence following ventricular premature beats in healthy controls,” *Annals of Noninvasive Electrophysiology*, т. 8, № 2, с. 127–131, квіт. 2003. Доступно: <https://doi.org/10.1046/j.1542-474x.2003.08206.x>

[45] Y. S. Kim, B. Lee, W. Jang, Y. Jeon, та J. D. Park, “A deep learning model for estimating sedation levels using heart rate variability and vital signs: a retrospective cross-sectional study at a center in South Korea,” *Acute and Critical Care*, т. 39, № 4, с. 621–629, лист. 2024 р. Доступно: <https://doi.org/10.4266/acc.2024.01200>

[46] B. K. Pradhan, B. C. Neelappu, J. Sivaraman, D. Kim, та K. Pal, “A Review on the Applications of Time-Frequency Methods in ECG Analysis,” *Journal of Healthcare Engineering*, т. 2023, № 1, ст. 3145483, 2023 р. Доступно: <https://doi.org/10.1155/2023/3145483>

[47] F. Figueroa та ін., “Poincaré plot analysis of ECG uncovers beneficial effects of omaveloxolone in a mouse model of Friedreich’s ataxia”, *Heart Rhythm*, січ. 2025. Доступно: <https://doi.org/10.1016/j.hrthm.2024.12.041>

[48] G. V. Naccarelli, “Electrocardiography of Arrhythmias: A Comprehensive Review,” *Circulation*, т. 126, № 13, с. e198–e198, 2012. Доступно: <https://doi.org/10.1161/CIRCULATIONAHA.112.117358>

[49] D. M. Mirvis та A. L. Goldberger, “Electrocardiography”, у *Braunwald's Heart Disease: A Textbook of Cardiovascular Medicine*. Elsevier, 2012, с. 126–167. Дата звернення: 10 жовт. 2025. Доступно: <https://doi.org/10.1016/b978-1-4377-0398-6.00013-5>

[50] C. C. Lin, “Improved frequency-domain analysis of ventricular late potentials”, у *Comput. Cardiol.*, 2005, Lyon, France, 25–28 верес. 2005. IEEE, 2005. Доступно: <https://doi.org/10.1109/cic.2005.1588141>

[51] P. Santangeli, F. Infusino, G. A. Sgueglia, A. Sestito та G. A. Lanza, “Ventricular late potentials: a critical overview and current applications”, *J. Electrocardiol.*, т. 41, № 4, с. 318–324, лип. 2008. Доступно: <https://doi.org/10.1016/j.jelectrocard.2008.03.001>

[52] P. Kher, «Signal Processing Techniques for Removing Noise from ECG Signals», J. Biomed. Eng. Res., т. 3, № 101, JScholar, 2019. Доступно: <https://doi.org/10.17303/JBER.2019.3.101>

[53] K. A. Gatzoulis та ін., “Signal-averaged electrocardiography: Past, present, and future”, J. Arrhythmia, т. 34, № 3, с. 222–229, трав. 2018. Дата звернення: 13 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1002/joa3.12062>

[54] T. Szél та C. Antzelevitch, “Abnormal Repolarization as the Basis for Late Potentials and Fractionated Electrograms Recorded From Epicardium in Experimental Models of Brugada Syndrome”, J. Amer. College Cardiol., т. 63, № 19, с. 2037–2045, трав. 2014. Дата звернення: 13 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.jacc.2014.01.067>

[55] G. Yan, S. Chen та S. Eidenbenz, “Dynamic Balancing of Packet Filtering Workloads on Distributed Firewalls”, у 2008 16th Int. Workshop Qual. Service, Enschede, The Netherlands, 2–4 черв. 2008. IEEE, 2008. Дата звернення: 3 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/iwqos.2008.30>

[56] M. Butt, N. Razzaq, I. Sadiq, M. Salman та T. Zaidi, “Power Line Interference removal from ECG signal using SSRLS algorithm”, у 2013 IEEE 9th Int. Colloq. Signal Process. its Appl. (CSPA), Kuala Lumpur, 8–10 берез. 2013. IEEE, 2013. Дата звернення: 13 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/cspa.2013.6530021>

[57] V. Kalidas та L. Tamil, “Real-time QRS detector using Stationary Wavelet Transform for Automated ECG Analysis”, у 2017 IEEE 17th Int. Conf. Bioinf. Bioeng. (BIBE), Washington, DC, 23–25 жовт. 2017. IEEE, 2017. Дата звернення: 13 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/bibe.2017.00-12>

[58] C. Guaragnella, M. Rizzi та A. Giorgio, “Marginal Component Analysis of ECG Signals for Beat-to-Beat Detection of Ventricular Late Potentials”, *Electronics*, т. 8, № 9, с. 1000, верес. 2019. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/electronics8091000>

[59] R. Bousseljot, D. Kreisler та A. Schnabel, “Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet” [Usage of the ECG signal database CARDIODAT yof PTB via the internet.], *Biomedizinische Technik/Biomed. Eng.*, с. 317–318, лип. 2009. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1515/bmte.1995.40.s1.317>

[60] G. Breithardt та ін., “Standards for analysis of ventricular late potentials using high-resolution or signal-averaged electrocardiography. A statement by a Task Force Committee of the European Society of Cardiology, the American Heart Association, and the American College of Cardiology.”, *Circulation*, т. 83, № 4, с. 1481–1488, квіт. 1991. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1161/01.cir.83.4.1481>

[61] H. Takahashi, M. Takagi, T. Yoshio, M. Yoh та I. Shiojima, “Analysis of site-specific late potentials using a novel Holter signal-averaged electrocardiography in patients with Brugada syndrome”, *Heart Rhythm*, трав. 2022. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.hrthm.2022.05.005>

[62] X. Fagan, K. Ivanko та N. Ivanushkina, “Detection of Ventricular Late Potentials in Electrocardiograms Using Machine Learning”, у *Advances in Computer Science for Engineering and Education III*. Cham: Springer Int. Publishing, 2020, с. 487–497. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: https://doi.org/10.1007/978-3-030-55506-1_44

[63] Giorgio, Rizzi та Guaragnella, “Efficient Detection of Ventricular Late Potentials on ECG Signals Based on Wavelet Denoising and SVM Classification”,

Information, т. 10, № 11, с. 328, жовт. 2019. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/info10110328>

[64] X. H. Cao, I. Stojkovic та Z. Obradovic, “A robust data scaling algorithm to improve classification accuracies in biomedical data”, BMC Bioinf., т. 17, № 1, верес. 2016. Дата звернення: 14 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1186/s12859-016-1236-x>

[65] U. Iqbal, R. Almakki, M. Usman, A. Altameem, M. Albathan та A. K. Jilani, “Methodological identification of anomalies episodes in ECG streams: a systematic mapping study”, BMC Med. Res. Methodol., т. 24, № 1, черв. 2024. Дата звернення: 16 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1186/s12874-024-02251-0>

[66] R. Huo, L. Zhang, F. Liu, Y. Wang, Y. Liang та S. Wei, “ECG segmentation algorithm based on bidirectional hidden semi-Markov model”, Comput. Biol. Medicine, с. 106081, верес. 2022. Дата звернення: 16 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.compbiomed.2022.106081>

[67] A. M. S. Ali, “Pan Tompkins Algorithm based ECG Signal Classification”, Res. J. Pharmacy Technol., т. 10, № 12, с. 4365, 2017. Дата звернення: 16 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.5958/0974-360x.2017.00802.2>

[68] B. Frénay, G. de Lannoy та M. Verleysen, “Label Noise-Tolerant Hidden Markov Models for Segmentation: Application to ECGs”, у Machine Learning and Knowledge Discovery in Databases. Berlin, Heidelberg: Springer Berl. Heidelb., 2011, с. 455–470. Дата звернення: 17 жовт. 2025. [Онлайн]. Доступно: https://doi.org/10.1007/978-3-642-23780-5_39

[69] P. Hamilton, “Open source ECG analysis”, у Comput. Cardiol. 2002. Vol. 29, Memphis, TN, USA. IEEE, б. д. Дата звернення: 17 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/cic.2002.1166717>

[70] F. Liu та ін., “Performance Analysis of Ten Common QRS Detectors on Different ECG Application Cases”, J. Healthcare Eng., т. 2018, с. 1–8, 2018. Дата звернення: 17 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1155/2018/9050812>

[71] Y. Nakai та ін., “Noise tolerant QRS detection using template matching with short-term autocorrelation”, у 2014 36th Annu. Int. Conf. IEEE Eng. Medicine Biol. Soc. (EMBC), Chicago, IL, 26–30 серп. 2014. IEEE, 2014. Дата звернення: 17 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/embc.2014.6943522>

[72] J. Rodrigues, D. Belo та H. Gamboa, “Noise detection on ECG based on agglomerative clustering of morphological features”, Comput. Biol. Medicine, т. 87, с. 322–334, серп. 2017. Дата звернення: 17 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.compbiomed.2017.06.009>

[73] P. Raphisak, S. C. Schuckers та A. de Jongh Curry, “An algorithm for EMG noise detection in large ECG data”, у Comput. Cardiol., 2004, Chicago, IL, USA. IEEE, б. д. Дата звернення: 17 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/cic.2004.1442949>

[74] Y. Xiang, Z. Lin та J. Meng, “Automatic QRS complex detection using two-level convolutional neural network”, Biomed. Eng. OnLine, т. 17, № 1, січ. 2018. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1186/s12938-018-0441-4>

[75] A. Nemcova, E. Vargova, R. Smisek, L. Marsanova, L. Smital та M. Vitek, “Brno University of Technology Smartphone PPG Database (BUT PPG): Annotated Dataset for PPG Quality Assessment and Heart Rate Estimation”, BioMed Res. Int., т. 2021, с. 1–6, верес. 2021. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1155/2021/3453007>

[76] H. Wen та J. Kang, “A comparative study on neural networks for paroxysmal atrial fibrillation events detection from electrocardiography”, J.

Electrocardiol., с. 53499, жовт. 2022. Дата звернення: 18 жовт. 2025. [Онлайн].
Доступно: <https://doi.org/10.1016/j.jelectrocard.2022.10.002>

[77] S. Modak, L. Y. Taha та E. Abdel-Raheem, “A Novel Method of QRS Detection Using Time and Amplitude Thresholds With Statistical False Peak Elimination”, IEEE Access, т. 9, с. 46079–46092, 2021. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/access.2021.3067179>

[78] L. Sun, Y. Wang, J. He, H. Li, D. Peng та Y. Wang, “A stacked LSTM for atrial fibrillation prediction based on multivariate ECGs”, Health Inf. Sci. Syst., т. 8, № 1, квіт. 2020. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1007/s13755-020-00103-x>

[79] S. Gupta, A. Mehra, N. Sarkar, M. Chotwani, M. Singhal та R. Majumdar, “Study of ECG Signals based on Gender and Heart Abnormalities”, Int. J. Comput. Complexity Intell. Algorithms, т. 1, № 1, с. 1, 2019. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1504/ijccia.2019.10026983>

[80] G. B. Moody та R. G. Mark, “The impact of the MIT-BIH Arrhythmia Database”, IEEE Eng. Medicine Biol. Mag., т. 20, № 3, с. 45–50, 2001. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/51.932724>

[81] A. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C. K. Peng та H. E. Stanley, «PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals», Circulation, т. 101, № 23, с. e215–e220, черв. 2000. [Онлайн]. Доступно: <https://doi.org/10.1161/01.CIR.101.23.e215>

[82] X. Wan, K. Yan, D. Luo та Y. Zeng, “A combined algorithm for T-wave alternans qualitative detection and quantitative measurement”, J. Cardiothoracic Surgery, т. 8, № 1, січ. 2013. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1186/1749-8090-8-7>

[83] Z. Cai, M. Yu, J. Yu, X. Han, J. Li та Y. Qu, “Life-Threatening Ventricular Arrhythmia Identification Based on Multiple Complex Networks”, *Electronics*, т. 14, № 15, с. 2921, лип. 2025. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/electronics14152921>

[84] D. Makowski та ін., “NeuroKit2: A Python toolbox for neurophysiological signal processing”, *Behav. Res. Methods*, т. 53, № 4, с. 1689–1696, лют. 2021. Дата звернення: 18 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3758/s13428-020-01516-y>

[85] D. Makowski, A. S. Te, T. Pham, Z. J. Lau та S. H. A. Chen, “The Structure of Chaos: An Empirical Comparison of Fractal Physiology Complexity Indices Using NeuroKit2”, *Entropy*, т. 24, № 8, с. 1036, лип. 2022. Дата звернення: 24 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/e24081036>

[86] “REAL TIME ELECTROCARDIOGRAM SEGMENTATION FOR FINGER BASED ECG BIOMETRICS”, у *Int. Conf. Bio-inspired Syst. Signal Process.*, Vilamoura, Algarve, Portugal, 1–4 лют. 2012. SciTePress - Sci. Technol. Publications, 2012. Дата звернення: 19 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.5220/0003777300490054>

[87] R. H. S. Selvester, “The signal-averaged high-resolution ECG”, *J. Electrocardiol.*, т. 28, с. 216–225, січ. 1995. Дата звернення: 19 жовт. 2025. [Онлайн]. Доступно: [https://doi.org/10.1016/s0022-0736\(95\)80061-1](https://doi.org/10.1016/s0022-0736(95)80061-1)

[88] I. Sadiq, A. M. Zuberi, I. Zaman, A. Hassan та T. Zaidi, “Adaptive removal of power-line interference from high resolution ECG”, *Advances Biosci. Biotechnol.*, т. 03, № 04, с. 324–326, 2012. Дата звернення: 24 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.4236/abb.2012.34047>

[89] B. Cai, G. Huang, N. Samadiani, G. Li та C.-H. Chi, “Efficient Time Series Clustering by Minimizing Dynamic Time Warping Utilization”, *IEEE Access*,

т. 9, с. 46589–46599, 2021. Дата звернення: 8 січ. 2026. [Онлайн]. Доступно: <https://doi.org/10.1109/access.2021.3067833>

[90] E. Iammarino, I. Marcantoni, A. Sbrollini, M. Morettini та L. Burattini, “Normalization of Electrocardiogram-Derived Cardiac Risk Indices: A Scoping Review of the Open-Access Literature”, *Appl. Sci.*, т. 14, № 20, с. 9457, жовт. 2024. Дата звернення: 19 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/app14209457>

[91] R. J. Martis, U. R. Acharya, K. M. Mandana, A. K. Ray та C. Chakraborty, “Application of principal component analysis to ECG signals for automated diagnosis of cardiac health”, *Expert Syst. with Appl.*, т. 39, № 14, с. 11792–11800, жовт. 2012. Дата звернення: 19 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.eswa.2012.04.072>

[92] D. Mochamad Reza, Satria Mandala, S. M. Zaki та E. S. L. Ming, “Deep Learning Autoencoder Study on ECG Signals”, *J. Nas. Tek. Elektro*, с. 82–88, груд. 2023. Дата звернення: 20 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.25077/jnte.v12n3.1117.2023>

[93] R. Nishikimi, M. Nakano, K. Kashino та S. Tsukada, “Variational Autoencoder-Based Neural Electrocardiogram Synthesis Trained by FEM-Based Heart Simulator”, *Cardiovascular Digit. Health J.*, груд. 2023. Дата звернення: 20 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.cvdhj.2023.12.002>

[94] Sharanya S, Sridhar PA, Poornakala J, Muppala Vasishta та Tharani U, “Convolution Neural Network Based Ecg Classifier”, *Int. J. Res. Pharmaceutical Sci.*, т. 10, № 3, с. 1626–1630, лип. 2019. Дата звернення: 20 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.26452/ijrps.v10i3.1327>

[95] Y. Huang, W. Liu, Z. Yin, S. Hu, M. Wang та W. Cai, “ECG Classification Based on Guided Attention Mechanism”, *Comput. Methods Programs*

Biomedicine, с. 108454, жовт. 2024. Дата звернення: 20 жовт. 2025. [Онлайн].
Доступно: <https://doi.org/10.1016/j.cmpb.2024.108454>

[96] N. Sobahi, A. Sengur, R.-S. Tan та U. R. Acharya, “Attention-based 3D CNN with residual connections for efficient ECG-based COVID-19 detection”, Comput. Biol. Medicine, т. 143, с. 105335, квіт. 2022. Дата звернення: 20 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.combiomed.2022.105335>

[97] A. Kozmin, O. Kalashev, A. Chernenko та A. Redyuk, “Semi-Supervised Learned Autoencoder for Classification of Events in Distributed Fibre Acoustic Sensors”, Sensors, т. 25, № 12, с. 3730, черв. 2025. Дата звернення: 27 груд. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/s25123730>

[98] J. Cai, W. Sun, J. Guan та I. You, “Multi-ECGNet for ECG Arrhythmia Multi-Label Classification”, IEEE Access, т. 8, с. 110848–110858, 2020. Дата звернення: 20 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/access.2020.3001284>

[99] C. Willuweit, J. Königs, C. Bockelmann та A. Dekorsy, “Instantaneous Bandwidth Estimation for Efficient Sampling of Electrocardiograms”, у 2024 IEEE 99th Veh. Technol. Conf. (VTC2024-Spring), Singapore, Singapore, 24–27 черв. 2024. IEEE, 2024, с. 1–5. Дата звернення: 20 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/vtc2024-spring62846.2024.10683579>

[100] P. Wagner та ін., «PTB-XL, a large publicly available electrocardiography dataset», Sci. Data, т. 7, № 1, трав. 2020. Дата звернення: 7 квіт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1038/s41597-020-0495-6>

[101] X. Ning та I. W. Selesnick, “ECG Enhancement and QRS Detection Based on Sparse Derivatives”, Biomed. Signal Process. Control, т. 8, № 6, с. 713–723, листоп. 2013. Дата звернення: 21 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.bspc.2013.06.005>

[102] F. Samann та T. Schanze, “An efficient ECG Denoising method using Discrete Wavelet with Savitzky-Golay filter”, *Current Directions Biomed. Eng.*, т. 5, № 1, с. 385–387, верес. 2019. Дата звернення: 21 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1515/cdbme-2019-0097>

[103] Z. Hou, Y. Dong, J. Xiang, X. Li та B. Yang, “A Real-Time QRS Detection Method Based on Phase Portraits and Box-Scoring Calculation”, *IEEE Sensors J.*, т. 18, № 9, с. 3694–3702, трав. 2018. Дата звернення: 21 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/jsen.2018.2812792>

[104] T. DENEKE та A. MÜGGE, “Atrial Fibrillation and Wolff-Parkinson-White Syndrome:”, *J. Cardiovascular Electrophysiol.*, т. 23, № 3, с. 287–289, груд. 2011. Дата звернення: 22 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1111/j.1540-8167.2011.02236.x>

[105] Y. Wang, “The Ricker wavelet and the Lambert W function”, *Geophysical J. Int.*, т. 200, № 1, с. 111–115, листоп. 2014. Дата звернення: 22 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1093/gji/ggu384>

[106] S. Hansun, V. Charles, T. Gherman та V. Varadarajan, “Hull-WEMA: a novel zero-lag approach in the moving average family, with an application to COVID-19”, *Int. J. Manage. Decis. Making*, т. 21, № 1, с. 92, 2022. Дата звернення: 22 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1504/ijmdm.2022.119582>

[107] A. Shulyak, T. Saurova, A. Shachykov, V. Sirotenko та V. Lahutin, “Modifications of recognition procedures of biomedical signals using shape characteristics for their description and in decision criteria”, у *2020 IEEE 40th Int. Conf. Electron. Nanotechnol. (ELNANO)*, Kyiv, Ukraine, 22–24 квіт. 2020. IEEE, 2020. Дата звернення: 23 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/elnano50318.2020.9088862>

[108] K. Rjoob, R. Bond, D. Finlay, V. McGilligan, S. J. Leslie, A. Rababah, A. Iftikhar, D. Guldenring, C. Knoery, A. McShane, A. Peace та P. W. Macfarlane, “Machine learning and the electrocardiogram over two decades: Time series and meta-analysis of the algorithms, evaluation metrics and applications”, *Artif. Intell. Med.*, т. 132, с. 102381, 2022. Дата звернення: 25 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.artmed.2022.102381>

[109] K. Nezamabadi, N. Sardaripour, B. Haghi та M. Forouzanfar, “Unsupervised ECG Analysis: A Review”, *IEEE Rev. Biomed. Eng.*, т. 16, с. 208–224, 2023. Дата звернення: 25 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/RBME.2022.3154893>

[110] X. Zhai, Z. Zhou та C. Tin, “Semi-supervised learning for ECG classification without patient-specific labeled data”, *Expert Syst. Appl.*, т. 158, с. 113411, 2020. Дата звернення: 25 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.eswa.2020.113411>

[111] R. Zhou, L. Lu, Z. Liu, T. Xiang, Z. Liang, D. A. Clifton, Y. Dong та Y.-T. Zhang, “Semi-Supervised Learning for Multi-Label Cardiovascular Diseases Prediction: A Multi-Dataset Study”, *IEEE Trans. Pattern Anal. Mach. Intell.*, т. 46, № 5, с. 3305–3320, 2024. Дата звернення: 25 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/TPAMI.2023.3342828>

[112] K. F. Hossain та ін., “ECG-Adv-GAN: Detecting ECG Adversarial Examples with Conditional Generative Adversarial Networks”, у 2021 20th IEEE Int. Conf. Mach. Learn. Appl. (ICMLA), Pasadena, CA, USA, 13–16 груд. 2021. IEEE, 2021. Дата звернення: 25 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/icmla52953.2021.00016>

[113] X. An, S. Shi, Q. Wang, Y. Yu та Q. Liu, “Research on a Lightweight Arrhythmia Classification Model Based on Knowledge Distillation for Wearable Single-Lead ECG Monitoring Systems”, *Sensors*, т. 24, № 24, с. 7896, груд. 2024.

Дата звернення: 25 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/s24247896>

[114] I. Chaikovsky, “Electrocardiogram scoring beyond the routine analysis: subtle changes matters”, *Expert Review of Medical Devices*, т. 17, № 5, с. 379–382, 2020. Дата звернення: 26 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1080/17434440.2020.1754795>

[115] D. F. Sendoya Losada, J. J. Soto Gómez та J. A. Zúñiga Vela, “Classification of ECG Signals Using Machine Learning Techniques”, *Academic J. Interdisciplinary Stud.*, т. 13, № 3, с. 92, трав. 2024. Дата звернення: 26 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.36941/ajis-2024-0067>

[116] О. Calin, “Activation Functions”, у *Deep Learning Architectures*. Cham: Springer Int. Publishing, 2020, с. 21–39. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: https://doi.org/10.1007/978-3-030-36721-3_2

[117] А. Tapkir, “A Comprehensive Overview of Gradient Descent and its Optimization Algorithms”, *IARJSET*, т. 10, № 11, листоп. 2023. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.17148/iarjset.2023.101106>

[118] I. D. Mienye та T. G. Swart, “A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications”, *Information*, т. 15, № 12, с. 755, листоп. 2024. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/info15120755>

[119] T. Szandała, “Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks”, у *Bio-inspired Neurocomputing*. Singapore: Springer Singapore, 2020, с. 203–224. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: https://doi.org/10.1007/978-981-15-5495-7_11

[120] D.-A. Clevert, T. Unterthiner та S. Hochreiter, “Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)”, *arXiv preprint*, листоп.

2015. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.48550/arXiv.1511.07289>

[121] B. Lairenjam, Y. S. Singh та Mahalakshmi, “Solution of ECG Inverse Problem Using Artificial Neural Network”, у Proceedings of International Conference on Computational Intelligence. Singapore: Springer Nature Singap., 2024, с. 201–214. Дата звернення: 24 листоп. 2025. [Онлайн]. Доступно: https://doi.org/10.1007/978-981-97-3526-6_17

[122] D. Yang, K. M. Ngoc, I. Shin та M. Hwang, “DPreLU: Dynamic Parametric Rectified Linear Unit and Its Proper Weight Initialization Method”, Int. J. Comput. Intell. Syst., т. 16, № 1, лют. 2023. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1007/s44196-023-00186-w>

[123] J. Inturrisi, S. Y. Khoo, A. Kouzani та R. Pagliarella, “Piecewise Linear Units Improve Deep Neural Networks”, arXiv preprint, серп. 2021. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.48550/arXiv.2108.00700>

[124] K. Biswas, S. Kumar, S. Banerjee та A. K. Pandey, “ErfAct and Pserf: Non-Monotonic Smooth Trainable Activation Functions”, Proc. AAAI Conf. Artif. Intell., т. 36, № 6, с. 6097–6105, черв. 2022. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1609/aaai.v36i6.20557>

[125] H. Chung, S. J. Lee та J. G. Park, “Deep Neural Network Using Trainable Activation Functions”, у 2024 IEEE 42nd Int. Conf. on Electronics and Nanotechnology (ELNANO), Vancouver, BC, Canada, 24–29 лип. 2016, с. 406–411. Дата звернення: 27 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/IJCNN.2016.7727219>

[126] J. Jachymski, I. Jóźwik та M. Terepeta, “The Banach Fixed Point Theorem: selected topics from its hundred-year history”, Rev. Real Acad. Cienc.

Exactas Fís. Nat. Ser. A Mat., т. 118, № 4, 2024. Дата звернення: 30 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1007/s13398-024-01636-6>

[127] S. Huang та Q. Wu, “Robust pairwise learning with Huber loss”, J. Complexity, т. 66, с. 101570, 2021. Дата звернення: 30 жовт. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.jco.2021.101570>

[128] R. Parhizkar, Y. Barbotin та M. Vetterli, “Sequences with minimal time–frequency uncertainty”, Appl. Comput. Harmon. Anal., т. 38, № 3, с. 452–468, трав. 2015. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.acha.2014.07.001>

[129] C. Su, S. Tong, P. Lin, N. Liang, Z. He та X. Yu, “Research on Spectral Leakage Suppression Method of Coherent Wind Lidar Based on Hanning Self-Convolutional Window”, Appl. Sci., т. 15, № 9, с. 4709, квіт. 2025. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/app15094709>

[130] Z. Zhang, D. Li, Y. He, Y. Chen, J. Zhang та C. Zhou, “K-Wigner Distribution: Definition, Uncertainty Principles and Time-Frequency Analysis”, IEEE Trans. Inf. Theory, с. 1, 2022. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/tit.2022.3227760>

[131] M. Lewandowski та Q. Deng, “EMD-based time-frequency analysis methods of audio signals”, Int. J. Electron. Telecommun., с. 323–329, черв. 2024. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.24425/ijet.2024.149548>

[132] M. K. Stiles, D. Clifton, N. R. Grubb, J. N. Watson та P. S. Addison, “Wavelet-Based Analysis of Heart-Rate-Dependent ECG Features”, Ann. Noninvasive Electrocardiol., т. 9, № 4, с. 316–322, жовт. 2004. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1111/j.1542-474x.2004.94566.x>

[133] S. Li, S. Ma та S. Wang, “Optimal Complex Morlet Wavelet Parameters for Quantitative Time-Frequency Analysis of Molecular Vibration”, *Appl. Sci.*, т. 13, № 4, с. 2734, лют. 2023. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/app13042734>

[134] M. J. Vrhel, C. Lee та M. A. Unser, “Fractal dimension estimation using the fast continuous wavelet transform”, у *SPIE's 1995 Int. Symp. Opt. Sci., Eng., Instrum.*, A. F. Laine та M. A. Unser, Ред. San Diego, CA. SPIE, 1995. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1117/12.217603>

[135] X. Wang, C. Ma, X. Zhang, H. Gao, G. D. Clifford та C. Liu, “Paroxysmal Atrial Fibrillation Events Detection from Dynamic ECG Recordings: The 4th China Physiological Signal Challenge 2021 (version 1.0.0)”, *PhysioNet*, 2021. RRID:SCR_007345. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.13026/ksya-qw89>

[136] J. Benesty, Jingdong Chen та Yiteng Huang, “On the Importance of the Pearson Correlation Coefficient in Noise Reduction”, *IEEE Trans. Audio, Speech, Lang. Process.*, т. 16, № 4, с. 757–765, трав. 2008. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/tasl.2008.919072>

[137] E. P. Chou та S.-M. Hsu, “Cosine similarity as a sample size-free measure to quantify phase clustering within a single neurophysiological signal”, *J. Neurosci. Methods*, т. 295, с. 111–120, лют. 2018. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1016/j.jneumeth.2017.12.007>

[138] F. Albardi, H. M. D. Kabir, M. M. I. Bhuiyan, P. M. Kebria, A. Khosravi та S. Nahavandi, “A Comprehensive Study on Torchvision Pre-trained Models for Fine-grained Inter-species Classification”, у *2021 IEEE Int. Conf. Syst., Man, Cybern. (SMC)*, Melbourne, Australia, 17–20 жовт. 2021. IEEE, 2021. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1109/smc52423.2021.9659161>

[139] H. K. Lee та Y.-S. Choi, “Application of Continuous Wavelet Transform and Convolutional Neural Network in Decoding Motor Imagery Brain-Computer Interface”, *Entropy*, т. 21, № 12, с. 1199, груд. 2019. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/e21121199>

[140] K. M. M. Prabhu, “Review of Window Functions”, у *Window Functions and Their Applications in Signal Processing*. CRC Press, 2018, с. 87–127. Дата звернення: 1 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.1201/9781315216386-3>

[141] W. Lin, “Tunneling and VPN”, у *Trends in Data Protection and Encryption Technologies*. Cham: Springer Nat. Switz., 2023, с. 149–154. Дата звернення: 3 листоп. 2025. [Онлайн]. Доступно: https://doi.org/10.1007/978-3-031-33386-6_26

[142] X. Liu, X. Meng, H. Duan, Z. Hu та M. Wang, “A Survey on Secure WiFi Sensing Technology: Attacks and Defenses”, *Sensors*, т. 25, № 6, с. 1913, берез. 2025. Дата звернення: 3 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/s25061913>

[143] M. K. Mohammed, “Examining ISO/IEC 27001 Standard”, *Eur. J. Advances Eng. Technol.*, т. 8, № 1, с. 123–128, січ. 2021. Дата звернення: 3 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.5281/zenodo.13950913>

[144] O. Debauche та ін., “RAMi: A New Real-Time Internet of Medical Things Architecture for Elderly Patient Monitoring”, *Information*, т. 13, № 9, с. 423, верес. 2022. Дата звернення: 3 листоп. 2025. [Онлайн]. Доступно: <https://doi.org/10.3390/info13090423>

ДОДАТКИ

ДОДАТОК А. Список публікацій здобувача за темою дисертації

Статті, в яких опубліковані основні результати дисертації:

[1] A. V. Mnevets and N. H. Ivanushkina, “The method of preprocessing of ECG signals for detection of atrial and ventricular late potentials,” *Microsystems Electronics and Acoustics*, vol. 28, no. 2, 2023, doi: <https://doi.org/10.20535/2523-4455.mea.281741>, ISSN 2523-4455.

Відомості: Публікація, що входить до категорії «Б» переліку наукових фахових видань України за спеціальністю дисертації.

Особистий внесок здобувача: Розробка та тестування методу попередньої обробки ЕКГ сигналів для виявлення пізніх потенціалів передсердь та шлуночків, а також створення набору даних для тестування методу.

Внесок співавторів: Н. Г. Іванушкіна – постановка наукової задачі, наукове керівництво, теоретичний супровід.

[2] A. V. Mnevets and N. G. Ivanushkina, “Neural networks detection of low-amplitude components on ECG using modified wavelet transform,” *Visnyk NTUU KPI Seriia – Radiotekhnika Radioaparatabuduvannia*, no. 97, pp. 46–57, 2024, doi: <https://doi.org/10.20535/radap.2024.97.46-57>, ISSN 2310-0389.

Відомості: Публікація, що входить до категорії «А» переліку наукових фахових видань України за спеціальністю дисертації, індексується у базі даних Web of Science Core Collection.

Особистий внесок здобувача: Модифікація методу вейвлет перетворення для ЕКГ сигналу, а також розробка методу застосування модифікованого вейвлет перетворення для виявлення пізніх потенціалів передсердь та шлуночків.

Внесок співавторів: Н. Г. Іванушкіна – координація виконання етапів наукової роботи, наукове керівництво, теоретичний супровід.

[3] A. Mnevec and N. Ivanushkina, “Neural network autoencoder model for forming reduced vector characteristics of ECG signals,” *Bulletin of Kyiv Polytechnic Institute Series Instrument Making*, vol. 69, no. 1, pp. 93–105, 2025, doi: [https://doi.org/10.20535/1970.69\(1\).2025.331920](https://doi.org/10.20535/1970.69(1).2025.331920) , ISSN 2663-3450.

Відомості: Публікація, що входить до категорії «Б» переліку наукових фахових видань України за спеціальністю дисертації.

Особистий внесок здобувача: Розробка архітектури мережевого автоенкодера, та тестування його роботи на основі публічних наборів даних.

Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису, наукове покращення тексту.

[4] A. V. Mnevets and N. H. Ivanushkina, “Siamese neural network’s models for cardiac arrhythmia classification in the conditions of shortage of training ECG signals,” *Microsystems Electronics and Acoustics*, vol. 30, no. 2, 2025, doi: <https://doi.org/10.20535/2523-4455.mea.325111> , ISSN 2523-4455.

Відомості: Публікація, що входить до категорії «Б» переліку наукових фахових видань України за спеціальністю дисертації.

Особистий внесок здобувача: Розробка та тестування моделі сіамської нейронної мережі для виявлення серцевих аритмій та супровідних патологій, розробка вектора ознак патологій, формування тренувального набору.

Внесок співавторів: Н. Г. Іванушкіна – визначення наукової проблеми та формування цілей дослідження, наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.

[5] А. В. Мневєць and Н. Г. Іванушкіна, «Класифікація низькоамплітудних компонент ЕКГ за допомогою адаптивних функцій активації нейронних мереж», Вісті вищих учбових закладів. Радіоелектроніка, vol. 67, no. 12, pp. 719–732, 2024, doi: <https://doi.org/10.20535/s0021347024120021>, ISSN 1934-8061.

Відомості: Публікація, що входить до категорії «Б» переліку наукових фахових видань України за спеціальністю дисертації.

Особистий внесок здобувача: Аналіз існуючих функцій активації і розробка власної функції активації для зменшення впливу явищ вибуху та згасання градієнтів, а також розробка методу оцінювання надлишковості шарів нейронних мереж на основі адаптивних функцій активації.

Внесок співавторів: Н. Г. Іванушкіна – постановка проміжних завдань та коригування дослідницької стратегії, наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.

[6] V. Kaverinskiy, I. Chaikovsky, A. Mnevets, T. Ryzhenko, M. Bocharov, and K. Malakhov, “Scalable clustering of complex ECG health data: Big data clustering analysis with UMAP and HDBSCAN,” *Computation*, vol. 13, no. 6, Art. no. 144, 2025, doi: <https://doi.org/10.3390/computation13060144>, ISSN 2079-3197.

Відомості: Публікація, в іноземному виданні за спеціальністю дисертації, що входить до другого квартілю (Q2) відповідно до класифікації Journal Citation Reports.

Особистий внесок здобувача: Обрахунок ЕКГ параметрів, та попередня обробка сигналів з набору даних об’ємом 14863 спостережень, наукове рецензування та редакційне доопрацювання рукопису.

Внесок співавторів: В. Каверінський – формулювання концепції та методології дослідження, розробка програмного забезпечення, проведення формального аналізу й експериментальних досліджень, підготовка первинного

тексту та візуалізацій; І. Чайковський – співавторство концепції, надання ресурсів і даних, валідація результатів, наукове керівництво та адміністративний супровід проєкту, залучення фінансування; Т. Риженко – надання ресурсів і участь у редакційному опрацюванні матеріалу; М. Бочаров – редакційне доопрацювання, адміністративний супровід та залучення фінансування; К. Малахов – розробка програмного забезпечення, валідація результатів та редакційне опрацювання тексту.

Праці, що засвідчують апробацію матеріалів дисертації:

[1] N. Ivanushkina та A. Mnevets, “Detection of Erroneously Selected Cardiac Cycles Using Neural Networks”, у 2024 IEEE 42nd Int. Conf. Electron. Nanotechnol. (ELNANO), Kyiv, Ukraine, 13–16 трав. 2024. IEEE, 2024, с. 406–411, doi: [10.1109/ELNANO63394.2024.10756903](https://doi.org/10.1109/ELNANO63394.2024.10756903).

Особистий внесок здобувача: Створення обширної бази даних помилково детектованих QRS комплексів, розробка та тестування нейромережевої архітектури для виявлення помилково виділених кардіоциклів на ЕКГ.

Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.

[2] А. В. Мневєць, Н. Г. Іванушкіна і К. О. Іванько, «Застосування сіамських нейронних мереж для підвищення точності виявлення серцево-судинних захворювань за нестачі тренувальних даних,» Матеріали 5-ї Міжнар. наук.-техн. конф., 28–29 листоп. 2024 р., Нац. техн. ун-т «Харків. політехн. ін-т» [та ін.], Харків, 2024. [Електронний ресурс]. Доступно: <https://repository.kpi.kharkov.ua/handle/KhPI-Press/84178>

Особистий внесок здобувача: Розробка моделі сіамської нейронної мережі для виявлення пізніх потенціалів передсердь та шлуночків, створення

бази даних з наявними пізними потенціалами для тестування розробленої архітектури.

Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису; К. О. Іванько – наукове рецензування та аналіз отриманих результатів.

[3] О. Shulyak, A. Mnevets та V. Lagutin, “Grouping Training Samples To Increase The Validity Of Recognition Algorithm Solutions”, у 2022 IEEE 41st Int. Conf. Electron. Nanotechnol. (ELNANO), Kyiv, Ukraine, 10–14 жовт. 2022. IEEE, 2022, doi: [10.1109/elnano54667.2022.9927020](https://doi.org/10.1109/elnano54667.2022.9927020).

Особистий внесок здобувача: Розробка програмного забезпечення для автоматизованого опису кардіоциклів за допомогою системи ізоліній, формування класифікаційного алгоритму на основі міри схожості, та оцінювання результатів класифікації.

Внесок співавторів: О. Шуляк – розробка концепції, планування дослідження; В. Лагутін – редакційне доопрацювання рукопису.

[4] А. В. Мневєць і Н. Г. Іванушкіна, «Виявлення ознак тахіаритмій шляхом вейвлет-аналізу електрокардіосигналів,» Тези доповідей IV Міжнар. наук.-техн. конф. «Автоматизація, електроніка, інформаційно-вимірювальні технології: освіта, наука, практика», м. Харків, Нац. техн. ун-т «Харків. політехн. ін-т», 2022., doi: [10.5281/zenodo.7750728](https://doi.org/10.5281/zenodo.7750728).

Особистий внесок здобувача: Розробка методів обробки ЕКГ сигналів для виявлення ознак тахіаритмій на основі вейвлет аналізу електрокардіосигналу, розробка коефіцієнту наявності ознак тахіаритмій.

Внесок співавторів: Н. Г. Іванушкіна – постановка проміжних завдань та коригування дослідницької стратегії, наукове керівництво, теоретичний супровід, редакційне доопрацювання рукопису.

[5] А. В. Мневель, Н. Г. Іванушкіна, «Спосіб автоматизованого аналізу електрокардіографічних сигналів», патент України на корисну модель № 161727, Україна, груд. 25, 2025. Дата звернення: 4 січ. 2026 [Онлайн].
Доступно: <https://sis.nipo.gov.ua/uk/search/detail/1891912/>

Особистий внесок здобувача: Розробка основних положень способу.

Внесок співавторів: Н. Г. Іванушкіна – наукове керівництво та теоретичний супровід.