ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

Кваліфікаційна наукова праця на правах рукопису

КОВАЛЬЧУК ОЛЕКСІЙ ВОЛОДИМИРОВИЧ

УДК: 004.8

ДИСЕРТАЦІЯ

МЕТОДИ ВИЯВЛЕННЯ ПАТОЛОГІЙ ЗА СИГНАЛОМ ЕЛЕКТРОКАРДІОГРАМИ ЗАСОБАМИ ПОЯСНЮВАЛЬНОГО ШТУЧНОГО ІНТЕЛЕКТУ

122 Комп'ютерні науки

12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

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

____О. В. Ковальчук

Науковий керівник: Бармак Олександр Володимирович, доктор технічних наук, професор

Хмельницький – 2025

АНОТАЦІЯ

Ковальчук О. В. Методи виявлення патологій за сигналом електрокардіограми засобами пояснювального штучного інтелекту. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії з галузі знань 12 Інформаційні технології за спеціальністю 122 Комп'ютерні науки. – Хмельницький національний університет, Хмельницький, 2025.

Дисертаційна робота присвячена розв'язанню науково-прикладної задачі виявлення серцевих патологій аритмій за сигналом електрокардіограми (ЕКГ) з використанням методів пояснювального штучного інтелекту. Під пояснювальним штучним інтелектом розуміють використання засобів та методів, спрямованих для інтерпретації результатів, які генерує нейронна мережа.

У межах дослідження розроблено методи обробки, класифікації патологій аритмій на ЕКГ та інтерпретації результатів класифікації. Застосування розроблених методів дасть можливість створити важливий інструмент для клінічної практики, який сприятиме ранньому виявленню патологій аритмій та дозволить лікарям більш впевнено ухвалювати рішення завдяки зрозумілим і пояснювальним результатам класифікації ЕКГ.

На сьогодні існує багато інструментів, які допомагають лікарям попереджати або виявляти проблеми в роботі серця. Одним з найбільш поширених засобів є електрокардіографія, яка надає можливість графічно реєструвати електричні явища з тіла люди, які виникають у серцевому м'язі під час його роботи. Криву, яку отримують в результаті фіксації такої активності, називають електрокардіограмою. У процесі аналізу ЕКГ лікарі-кардіологи звертають увагу на характерні зміни форми, інтервалів і амплітуд хвиль, що вказують на можливі патології в роботі серця. Кожна хвиля та інтервал на ЕКГ-сигналі відображають певні фази серцевого циклу, за якими лікарі оцінюють стан серцевого м'яза. Однак для точного діагностування кардіологам необхідно мати «натреноване око», щоб виявляти навіть мінімальні відхилення в ЕКГ-профілі, які можуть вказувати на серйозні порушення, такі як ішемія, аритмія або порушення провідності.

Оскільки існує багато типів можливих відхилень ЕКГ від норми та великі за обсягом ЕКГ-записи (такі, як холтери), то процес їх аналізу може бути затратним за часом та з імовірними помилками, а невчасно або неправильно поставлений діагноз може мати фатальні наслідки для пацієнтів. Саме тому для вирішення зазначених проблем актуальним є застосування методів та підходів штучного інтелекту.

Об'єктом дослідження є процес виявлення патологій аритмій на електрокардіограмі засобами глибокого навчання з подальшою інтерпретацією отриманих результатів.

Предметом дослідження є методи та засоби глибокого навчання для виявлення патологій аритмій на електрокардіограмі.

Метою дослідження є покращення точності класифікації патологій аритмій на електрокардіограмі засобами глибокого навчання з подальшою інтерпретацією отриманих результатів за допомогою ознак, що використовуються у медичній практиці.

У дисертаційній роботі розроблено новий метод ідентифікації R-зубців на ЕКГсигналі, який відрізняється від існуючих використанням моделі глибокого навчання з двома вхідними сигналами – ЕКГ-сигналом та, синхронним з ним, сигналом з прогнозованим розташуванням R-зубців, що дало змогу підвищити точність ідентифікації.

У дисертаційній роботі удосконалено метод класифікації патологій аритмій на ЕКГ-сигналі, який відрізняється від відомих використанням тріади кардіоциклів, що дозволяє сформувати контекстну інформацію виникнення кардіоциклу, для подальшої класифікації вдосконаленою архітектурою моделі глибокого навчання, що дозволило збільшити кількість патологій для розпізнавання та підвищити точність класифікації.

У дисертаційній роботі вперше розроблено метод інтерпретації результатів класифікації патологій аритмій, отриманих з ЕКГ-сигналу за моделями глибокого навчання, що дало змогу подати результати класифікації за ознаками, що використовуються у медичній практиці.

Практичне значення отриманих результатів полягає в доведенні теоретичних результатів дисертаційної роботи до реалізації та у безпосередньому використанні їх у відповідних медичних установах.

Реалізована інформаційна система на основі методів пошуку R-зубців та класифікації ЕКГ-сигналу на наявність патологій аритмій забезпечують користувачу прогнози наявності патологій аритмій 9 підтримуваних класів для всіх виявлених кардіоциклів, що несе рекомендаційних характер та пришвидшує роботу лікаря в аналізі ЕКГ-сигналу.

Реалізована інформаційна система включає використання методу інтерпретації рішень класифікації патологій аритмій, отриманих за моделями глибокого навчання, дозволяє подати лікарю результати класифікації за ознаками, що використовуються у медичній практиці. Такий підхід робить рішення моделей глибокого навчання більш доступними для лікаря, забезпечуючи довіру до отриманих результатів.

Реалізована інформаційна система класифікації патологій аритмій та інтерпретації результатів класифікації базується на клієнт-серверній архітектурі, що дозволяє виконувати всі обчислення на віддаленому сервері з потужним обладнанням, тоді як клієнт здійснює лише передачу даних, отримання та візуалізацію результатів, що дає можливість використовувати систему в невеликих клініках з обмеженими обчислювальними ресурсами.

Результати дисертаційної роботи впроваджено: у медичному лікувальнодіагностичному центрі «Сіліція-Сіті+» (довідка про впровадження); ТОВ «АЙ ТІ ХУТ» (довідка про впровадження); у навчальному процесі Хмельницького національного університету (акт впровадження); при виконанні держбюджетної теми Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980) (Додаток Б).

Ключові слова: медична діагностика, електрокардіограма, моніторинг ЕКГ, виявлення R-зубця, класифікація ЕКГ, інтерпретація результатів класифікації, пояснювальний штучний інтелект, глибоке навчання.

SUMMARY

Kovalchuk O. Methods for detecting pathologies from the electrocardiogram signal using explainable artificial intelligence. – Manuscript copyright.

Thesis on competition of scientific degree of Doctor of Philosophy by specialty 122 Computer Science. – Khmelnytskyi National University, Khmelnytskyi, 2025.

The dissertation is devoted to solving the scientific and applied problem of detecting cardiac arrhythmias from an electrocardiogram (ECG) signal using explainable artificial intelligence methods. Explainable artificial intelligence means the use of tools and methods aimed at interpreting the results generated by a neural network.

The study developed methods for processing, classifying arrhythmia pathologies on ECG and interpreting the classification results. The application of the developed methods will make it possible to create a valuable tool for clinical practice that will facilitate the early detection of arrhythmia pathologies and allow doctors to make decisions more confidently due to clear and explainable results of ECG classification.

Nowadays, there are many tools that help doctors prevent or detect problems in the heart. One of the most common tools is electrocardiography. Electrocardiography makes it possible to graphically record electrical phenomena from the human body that occur in the heart muscle during its work. The curve obtained as a result of recording such activity is called an electrocardiogram (ECG). When analyzing an ECG, cardiologists pay attention to characteristic changes in the shape, intervals, and amplitudes of waves that indicate possible pathologies in the heart. Each wave and interval on the ECG signal reflects certain phases of the cardiac cycle, which doctors use to assess the condition of the heart muscle. However, for an accurate diagnosis, cardiologists need to have a "trained eye" to detect even minimal deviations in the ECG profile that may indicate serious disorders such as ischemia, arrhythmia, or conduction disorders.

Since there are many types of possible ECG abnormalities and large ECG recordings (such as Holter), the process of analyzing can be a time-consuming and errorprone procedure. As a result, late or incorrect diagnosis can have fatal consequences for patients. Therefore, to solve these problems, it is important to apply artificial intelligence methods and approaches.

The object of the research is the process of detecting arrhythmia pathologies on an electrocardiogram using deep learning tools with subsequent interpretation of the results.

The subject of the study is methods and tools for deep learning to detect arrhythmia pathologies on electrocardiograms.

The aim of the study is to improve the accuracy of classification of arrhythmia pathologies on an electrocardiogram using deep learning tools with further interpretation of the obtained results using features used in medical practice.

In this dissertation, a new method for identifying R-peaks on an ECG signal was developed, which differs from the existing ones by using a deep learning model with two input signals – an ECG signal and a signal with a predicted location of R-peaks synchronized with it, which made it possible to increase the identification accuracy.

In this dissertation, the method of classifying arrhythmia pathologies on an ECG signal was improved, which differs from the known ones by using the triad of cardiac cycles, which allows to form contextual information of the occurrence of a cardiac cycle, for further classification by an improved architecture of the deep learning model, which allowed to increase the number of pathologies for recognition and improve the classification accuracy.

In this dissertation, for the first time, a method was developed for interpreting the results of classification of arrhythmia pathologies obtained from an ECG signal using deep learning models, which made it possible to present the results of classification based on the features used in medical practice.

The practical significance of the obtained results is to bring the theoretical results of the dissertation to implementation and to use them directly in the medical institutions.

The implemented information system based on the method of R-peak identification and ECG signal classification for arrhythmia pathologies provides the user with predictions of arrhythmia pathologies of 9 supported classes for detected cardiac cycles, which is advisory in nature and speeds up the doctor's work in analyzing the ECG signal. The implemented information system includes the use of a method for interpreting arrhythmia pathology classification results obtained by deep learning models, allowing to present the classification results to the doctor according to the features used in medical practice. This approach makes the decisions of deep learning models more accessible to the doctor, ensuring confidence in the results.

The implemented information system for classification of arrhythmia pathologies and interpretation of classification results is based on client-server architecture. This architecture allows performing all calculations on a remote server with powerful hardware. At the same time, the client only transfers data, receives, and visualizes the results. This allows the information system to be used in small clinics with limited computing resources.

The results of the dissertation have been implemented in (Appendix B): the medical treatment and diagnostic center "Celicia City+" (certificate of implementation); IT Hoot LLC (certificate of implementation); in the educational process of Khmelnytskyi National University (implementation act); in the implementation of the "System for detecting intrusion and computer attacks in corporate networks using false attack objects and traps" state budget topic of Khmelnytskyi National University (State Budget Project No. 0124U000980).

Keywords: medical diagnostics, electrocardiogram, ECG monitoring, R-peak detection, ECG classification, interpretation of classification results, explainable artificial intelligence, deep learning.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у періодичних виданнях, включених до категорії «А»

Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних Web of Science Core Collection ma/abo Scopus:

1. Towards transparent AI in medicine: ECG-based arrhythmia detection with explainable deep learning / O. Kovalchuck et a. *Technologies*. 2025. Vol. 13, no. 1. P. 34. (<u>https://doi.org/10.3390/technologies13010034</u>) (*iндексована у наукометричних базах Scopus, Web of Science (Q1 by Scimago Journal & Country Rank)*).

Статті у наукових виданнях,

включених до Переліку наукових фахових видань України:

2. Kovalchuk O. V., Barmak O. V. Method of arrhythmia classification on ECG signal. *Optoelectronic Information-Power Technologies*. 2024. Vol. 48, no. 2. P. 34–44. (https://doi.org/10.31649/1681-7893-2024-48-2-34-44).

3. Ковальчук О. В., Бармак О. В. Метод ідентифікації R-піків у сигналах електрокардіограми. *Вісник Хмельницького національного університету*. 2024. № 6. С. 108–117. (https://doi.org/10.31891/2307-5732-2024-343-6-16).

4. Ковальчук О. В., Бармак О. В. Метод інтерпретації результатів класифікації ЕКГ методами глибокого навчання. *Проблеми моделювання та автоматизації проектування*. 2024. Т. 2, № 20. С. 120–130. (<u>https://doi.org/10.31474/2074-7888-2024-</u> 2-20-120-130).

Публікації, які засвідчують апробацію матеріалів дисертації:

5. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et a. *CEUR-WS*. 2022. Vol. 3302. P. 9–20. URL: <u>https://ceur-ws.org/Vol-3302/paper1.pdf</u> (*iндексована в наукометричній базі Scopus*).

6. A novel feature vector for ECG classification using deep learning / O. Kovalchuk et a. *CEUR-WS*. 2023. Vol. 3373. P. 227–238. URL: <u>https://ceur-ws.org/Vol-3373/paper12.pdf</u> (*iндексована в наукометричній базі Scopus*).

7. Kovalchuk O., Radiuk P., Barmak O. та Krak Iu. Robust R-peak detection using deep learning based on integrating domain knowledge. CEUR-WS. 2023. Vol. 3609. P. 1–14. URL: https://ceur-ws.org/Vol-3609/paper1.pdf (*індексована в наукометричній базі Scopus*).

8. Kovalchuk O., Radiuk P., Barmak O. та Krak Iu. ECG Arrhythmia Classification and Interpretation using Convolutional Networks for Intelligent IoT Healthcare System. *CEUR-WS*. 2024. Vol. 3736. P. 47–62. URL: <u>https://ceur-ws.org/Vol-3736/paper4.pdf</u> (*iндексована в наукометричній базі Scopus*).

Свідоцтва про реєстрацію авторського права на твір

9. А. с. 132579 Україна. Комп'ютерна програма «Класифікація ЕКГ на наявність аритмій з подальшою інтерпретацією результатів» / О. В. Ковальчук, О. В. Бармак, П. М. Радюк. 2025, URL: https://sis.nipo.gov.ua/uk/search/detail/1844354/

3MICT

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	12				
ВСТУП	13				
РОЗДІЛ 1. АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ	ДО				
ВИЯВЛЕННЯ ПАТОЛОГІЙ АРИТМІЙ ЗА СИГНАЛАМИ ЕКГ	19				
1.1. Актуальність задачі ідентифікації патологій на ЕКГ-сигналі	19				
1.2. Огляд сучасних підходів до ідентифікації патологій аритмій на					
ЕКГ-сигналі	21				
1.3. Моделі глибокого навчання для аналізу ЕКГ-сигналу	29				
1.4. Ознаки ЕКГ-сигналу, за якими приймається рішення про патологію					
аритмії у медичній практиці	30				
1.5. Постановка задачі	41				
1.6. Висновки до розділу 1	42				
РОЗДІЛ 2. МОДЕЛЬ ТА МЕТОДИ КЛАСИФІКАЦІЇ АРИТМІЇ НА	ЕКГ-				
СИГНАЛІ ЗА МОДЕЛЯМИ ГЛИБОКОГО НАВЧАННЯ З ПОДАЛЫІ	ЮЮ				
ІНТЕРПРЕТАЦІЄЮ ОТРИМАНИХ РЕЗУЛЬТАТІВ	43				
2.1. Модель процесу виявлення аритмій на ЕКГ-сигналі	43				
2.2. Метод ідентифікації R-зубців на ЕКГ-сигналах	50				
2.3. Метод класифікації аритмій на ЕКГ-сигналі	59				
2.4. Відповідальність використання штучного інтелекту в медицині	64				
2.5. Метод інтерпретації результатів класифікації патологій аритмій,					
отриманих за допомогою моделі глибокого навчання	65				
2.5.1 Загальна ідея методу	65				
2.5.2 Способи визначення ознак, що застосовуються у медичній практиці	68				
2.5.3 Відповідності між клінічними рекомендаціями та способа	МИ				
отримання ознак	71				
2.5.4 Демонстрація роботи запропонованих методів	75				
2.6. Висновки до розділу 2	81				

РОЗД	ЦЛ 3.	ІНФОРМАЦІЙНА	СИСТЕМА	ВИЯВЛЕННЯ	ПАТОЛОІ	ΓΙЙ
АРИТМІЙ ЗА ЕКГ-СИГНАЛОМ 83						
3.1.	Функціональні вимоги до інформаційної системи 83					83
3.2.	. Вимоги до апаратного забезпечення					85
3.3.	3.3. Проєктування архітектури інформаційної системи					87
3.4.	3.4. Практична реалізація інформаційної системи					92
3.5.	.5. Висновки до розділу 3 9					97
PO3Д	ЦІЛ 4.	ЕКСПЕРИМЕНТ	АЛЬНЕ ПІД	ГВЕРДЖЕННЯ	ВАЛІДНО	CTI
ЗАПІ	РОПОНОВА	АНИХ МЕТОДІВ				99
4.1.	Набори дан	их для оцінювання	запропонован	их методів		99
4.2.	Методика і	проведення експерим	ментів			101
4.3.	Результати	досліджень методу	знаходження	R-зубців на ЕК	Г-сигналі	102
4.4. Результати досліджень методу класифікації патологій аритмій на ЕКГ-						
сигна	лi					111
4.5.	Експериме	нт з клінічними дани	ИМИ			125
4.6. Інтерпретація результатів класифікації за ознаками, прийнятими у						
медичній практиці					128	
4.7.	Обмеження	и запропонованого п	ідходу			134
4.8.	Висновки д	ю розділу 4				135
ВИС	НОВКИ					137
ПЕРЕ	ЕЛІК ДЖЕР	ЕЛ ПОСИЛАНЬ				140
дод	АТОК А СП	ИСОК ПУБЛІКАЦІ	Й ЗДОБУВА	ЧА		159
дод	АТОК Б. АК	КТИ ВПРОВАДЖЕН	КНЯ			161
ДОДАТОК В. АВТОРСЬКЕ СВІДОЦТВО 165						165
ДОДАТОК Г. ВИХІДНИЙ КОД 166						166

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

– support vector machine, <i>укр</i> . метод опорних векторів			
ик			

ЧВВ – час внутрішньоподібного відхилення

ВСТУП

Актуальність роботи. Відповідно до статистики Всесвітньої організації охорони здоров'я найбільшу кількість смертей людей спричиняють серцево-судинні захворювання [1, 2]. Зокрема, у США у 2018 році понад 560 000 висновків про смерть включали аритмію як одну з причин [3]. Одним з найбільш поширених засобів є електрокардіографія, яка надає можливість графічно реєструвати електричні явища з тіла люди, які виникають у серцевому м'язі під час його діяльності. Криву, що отримується в результаті фіксації такої активності, називають електрокардіограмою (ЕКГ). Опираючись на записи ЕКГ-сигналу, лікарі інтерпретують їх за різними показниками для виявлення причин скарг пацієнтів на дискомфорт або біль у грудях, які можуть бути пов'язані із серцем [4, 5].

Оскільки існує багато типів можливих відхилень ЕКГ від норми та можливі великі за обсягом ЕКГ-записи (такі, як холтери), то процес їх аналізу може бути затратним за часом та з імовірними помилками. Саме тому для вирішення зазначених проблем застосовуються методи та підходи інформаційних технологій. Зокрема, у зв'язку з активним розвитком штучного інтелекту набули широкого використання такі інструменти, як машинне навчання (ML) і глибоке навчання (DL) для класифікації патологій на ЕКГ-сигналах.

Використання нейронних мереж глибокого навчання (CNN) у класифікації ЕКГ вже продемонструвало свою ефективність у виявленні різноманітних серцевих патологій, таких як аритмії [6, 7], міокардит [8, 9, 10] тощо. Попри значні досягнення у цій сфері, робота моделей глибокого навчання залишається «чорною скринею» для кінцевого користувача, що дуже критично для такої сфери, як медицина [11, 12, 13].

Значний внесок в обробленні ЕКГ, класифікації патологій та інтерпретації результатів класифікації зробили такі українські та іноземні вчені: Ю. Крак та А. Пашко [14, 15, 16], О. Бармак [17], С. Павлов [18], Т. Панченко [19], В. Данилов [20], М. Прімін [21], Л. Файнзільберг [22, 23], І. Чайковський [24, 25], М. Будник [26, 27], С. Коваленко [28, 29], Ch. Janiesch [30], М. Lee [31], G. Laudato [32], V. Fioravanti [33],

Z. Li [34], M. Kolhar [35], A. Akan [36], F. Liu [37], F. Sandberg [38], D. Zhang [39],C. Chen [40], R. Sassi [41].

Виходячи з наведеного, задача ідентифікації патологій аритмій на ЕКГсигналі, яка не тільки виявляє патології аритмій, але й «пояснює», чому саме такі рішення прийняті, є досить актуальною. Тому дисертаційна робота присвячена розв'язанню науково-прикладної задачі виявлення патологій аритмій за ЕКГсигналами з використанням методів пояснювального штучного інтелекту, під яким розуміється використання засобів і методів, спрямованих для інтерпретації результатів, які генерує нейронна мережа.

Зазначена науково-прикладна задача відповідає предметній області Стандарту вищої освіти України зі спеціальності 122 – Комп'ютерні науки для третього (освітньо-наукового) рівня вищої освіти, зокрема, такому об'єкту вивчення та діяльності, як «процеси обробки інформації у комп'ютерних системах».

Зв'язок роботи з науковими програмами, планами, темами. Дослідження, результати яких викладено в дисертації, виконано під час виконання окремих розділів науково-дослідної роботи за держбюджетною темою Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980). У межах проведеної науково-дослідної роботи за держбюджетною темою, автор здійснив розробку методів обробки інформації предметної галузі засобами штучного інтелекту, а також виконав оцінку отриманих результатів за ключовими метриками: Accuracy, Recall, F1-score та ROC-AUC.

Мета і задачі дослідження. Об'єкт дослідження: процес виявлення патологій аритмій на електрокардіограмі засобами глибокого навчання з подальшою інтерпретацією отриманих результатів.

Предмет дослідження: методи та засоби глибокого навчання для виявлення патологій аритмій на електрокардіограмі.

Метою дослідження є покращення точності класифікації патологій аритмій на електрокардіограмі засобами глибокого навчання з подальшою інтерпретацією отриманих результатів за допомогою ознак, що використовуються у медичній практиці.

Для досягнення поставленої мети необхідно розв'язати такі задачі:

1) провести аналіз методів, засобів та технологій для виявлення патологій аритмій на електрокардіограмі;

2) розробити метод ідентифікації R-зубців на ЕКГ-сигналі за моделлю глибокого навчання;

3) розробити метод класифікації патологій аритмій на ЕКГ-сигналі за моделлю глибокого навчання;

4) розробити метод інтерпретації отриманих результатів класифікації сигналів ЕКГ за допомогою ознак, що використовуються у медичній практиці;

5) розробити інформаційну систему для валідації запропонованих методів та провести експериментальні дослідження.

Методи дослідження. При розв'язанні поставленої науково-прикладної задачі використовувались методи аналізу та синтезу, принципи загальної теорії систем та системного аналізу, методи аналізу та моделювання систем, теоретико-множинні підходи, методи концептуального моделювання, методи емпіричного дослідження, моделі глибокого навчання.

Наукова новизна отриманих результатів полягає в наступному:

1. Розроблено новий метод ідентифікації R-зубців на ЕКГ-сигналі, який відрізняється від існуючих використанням моделі глибокого навчання з двома вхідними сигналами – ЕКГ-сигналом та, синхронним з ним, сигналом з прогнозованим розташуванням R-зубців, що дало змогу підвищити точність ідентифікації.

2. Удосконалено метод класифікації патологій аритмій на ЕКГ-сигналі, який відрізняється від відомих використанням тріади кардіоциклів, що дозволяє сформувати контекстну інформацію виникнення кардіоциклу, для подальшої класифікації вдосконаленою архітектурою моделі глибокого навчання, що дозволило збільшити кількість патологій для розпізнавання та підвищити точність класифікації;

3. Вперше розроблено метод інтерпретації результатів класифікації патологій аритмій, отриманих з ЕКГ-сигналу за моделями глибокого навчання, що дало змогу

подати результати класифікації за ознаками, що використовуються у медичній практиці.

Практичне значення отриманих результатів. Практичне значення отриманих результатів полягає в доведенні теоретичних результатів дисертаційної роботи до реалізації та у безпосередньому використанні їх у відповідних медичних установах.

Реалізована інформаційна система на основі методі пошуку R-зубців та класифікації ЕКГ-сигналу на наявність патологій аритмій забезпечують користувачу прогнози наявності патологій аритмій 9 підтримуваних класів для всіх виявлених кардіоциклів, що несе рекомендаційний характер та пришвидшує роботу лікаря в аналізі ЕКГ-сигналу.

Реалізована інформаційна система включає використання методу інтерпретації рішень класифікації патологій аритмій, отриманих за моделями глибокого навчання, дозволяє подати лікарю результати класифікації за ознаками, що використовуються в медичній практиці. Такий підхід робить рішення моделей глибокого навчання більш доступними для лікаря, забезпечуючи довіру до отриманих результатів.

Реалізована інформаційна система класифікації патологій аритмій та інтерпретації результатів класифікації базується на клієнт-серверній архітектурі, що дає змогу виконувати всі обчислення на віддаленому сервері з потужним обладнанням, тоді як клієнт здійснює лише передачу даних, отримання та візуалізацію результатів, що дає можливість використовувати систему в невеликих клініках з обмеженими обчислювальними ресурсами.

Результати дисертаційної роботи впроваджено: у медичному лікувальнодіагностичному центрі «Сіліція-Сіті+» (довідка про впровадження); ТОВ «АЙ ТІ ХУТ» (довідка про впровадження); у навчальному процесі Хмельницького національного університету (акт впровадження); при виконанні держбюджетної теми Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980) (Додаток Б).

Особистий внесок здобувача та внесок інших співавторів у спільних публікаціях. Усі наукові результати дисертаційного дослідження отримані автором

особисто. Список опублікованих праць за темою дисертації представлено в списку використаних джерел – [42–49]. У спільних публікаціях автору належать такі результати: класифікація аритмії на ЕКГ-сигналі засобами пояснювального глибокого навчання [42], метод ідентифікації R-зубців у сигналах електрокардіограми [43], метод класифікації аритмій на ЕКГ-сигналі [44], метод інтерпретації результатів класифікації ЕКГ методами глибокого навчання [45], підхід «людина у петлі» на основі МРТ та ЕКГ для діагностики в охороні здоров'я [46], класифікація ЕКГ за допомогою вектора ознак з використанням глибокого навчання [47], виявлення R-зубців на ЕКГ-сигналі із доданим синхронним сигналом можливого розташуванням R-зубців для підвищення точності виявлення за допомогою моделі глибокого навчання [48], класифікація та інтерпретація патологій аритмії на ЕКГ з використанням згорткових мереж для інтелектуальної ІоГ систем охорони здоров'я [49].

Внесок інших співавторів у спільних публікаціях: у статті [42] О. Бармак виконував концептуалізацію дослідження, огляд відомих методів та рішень, обговорення результатів дослідження, підготовку чернетки рукопису, пошук коштів на публікацію статті; Ю. Крак виконував концептуалізацію дослідження, обговорення результатів дослідження; П. Радюк разом із автором працював над методологією дослідження та опрацьовував його результати, а також виконував огляд відомих методів та рішень, підготовку чернетки рукопису; Л. Клименко була консультантом з медичних аспектів роботи; у статтях [44, 43, 45] О. Бармак виконував адміністрування та концептуалізацію дослідження, рецензування та коригування рукопису; у статті [46] П. Радюк виконував дослідження, обговорення його результатів, концептуалізацію адміністрування проєктом, підготовкою чернетки рукопису; О. Бармак та Ю. Крак виконували концептуалізацію дослідження, обговорення його результатів, рецензування та коригування рукопису; О. Ковальчук спільно з автором працював над додаванням синхронних сигналів можливого розміщення зубців для збільшення семантики ЕКГсигналу, щоб покращити виділення зубців та сегментів ЕКГ-сигналу; В. Слободзян спільно з автором працював над обробкою МРТ зображень серця для подальшої сегментації; Е. Манзюк разом з автором працював над оглядом існуючих методів та рішень, підготовкою чернетки рукопису; у статті [47] О. Бармак та Ю. Крак виконували

концептуалізацію дослідження, обговорення його результатів, рецензування та коригування рукопису; П. Радюк разом з автором працював над методологією дослідження та опрацьовував його результати, підготовкою чернетки рукопису; С. Петровський спільно з автором працював над оглядом існуючих методів та рішень; у статтях [48, 49] О. Бармак та Ю. Крак виконували концептуалізацію дослідження, обговорення його результатів, рецензування та коригування рукопису; П. Радюк спільно з автором працював над оглядом його результатів, обговорення його результатів, рецензування та коригування рукопису; П. Радюк спільно з автором працював над методологією дослідження, обговорення його результатів, рецензування та коригування рукопису; П. Радюк спільно з автором працював над методологією дослідження, аналізом його результатів, оглядом існуючих методів і рішень, а також підготовкою чернетки рукопису.

Апробація матеріалів дисертації. Основні результати дисертаційного дослідження доповідались та обговорювались на 4 міжнародних науково-технічних та науково-практичних семінарах [46, 47, 48, 49], а саме: 5th International Conference on Informatics & Data-Driven Medicine (м Ліон, Франція, 2022); IntelITSIS'2023: 4th International Workshop on Intelligent Information Technologies & Systems of Information Security (м. Хмельницький, 2023); IDDM'2023: 6th International Conference on Informatics & Data-Driven Medicine (м. Братислава, Словаччина, 2023); ICyberPhyS-2024: 1st International Workshop on Intelligent & CyberPhysical Systems (Khmelnytskyi, 2024).

Публікації. Основні результати дисертації опубліковані у 8 наукових працях (додаток А), серед яких 1 стаття – у періодичному виданні 1-го квартилю, що індексується в наукометричних базах Scopus, Web of Science [42]; 3 статті – у фахових наукових журналах України [44, 43, 45], включених на дату опублікування до переліку наукових фахових видань України категорії Б; 4 публікації, які засвідчують апробацію матеріалів дисертації (статті в матеріалах конференцій, що індексуються у наукометричній базі Scopus) [46, 47, 48, 49]; 1 свідоцтво про реєстрацію авторського права на твір [50].

Структура та обсяг дисертації. Дисертаційна робота складається з анотації, вступу, 4 розділів, висновків, списку використаних джерел із 151 найменування на 18 сторінках та 4 додатків. Загальний обсяг дисертації становить 166 сторінок, з них 127 сторінок основного тексту. Дисертація містить 64 рисунки та 19 таблиць.

РОЗДІЛ 1.

АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО ВИЯВЛЕННЯ ПАТОЛОГІЙ АРИТМІЙ ЗА СИГНАЛАМИ ЕКГ

У розділі проведено аналіз сучасних підходів до виявлення патологій аритмій на ЕКГ-сигналі; розглянуто методи ідентифікації R-зубців, класифікації патологій аритмій та інтерпретації результатів класифікації, отриманих за моделлю глибокого навчання. Також розглянуто методики для оцінки результатів, отриманих за моделями глибокого навчання для медичних систем. Окрему увагу приділено методикам оцінки точності результатів, отриманих за моделлю глибокого навчання у медичних системах. Проаналізовано основні ознаки ЕКГ-сигналу, що враховуються лікарем при ухваленні рішення про наявності патології аритмій. На основі проведеного аналізу сформульовано основні завдання дисертаційного дослідження.

1.1. Актуальність задачі ідентифікації патологій на ЕКГ-сигналі

Відповідно до статистики, яку надає Всесвітня організація охорони здоров'я, найбільшу кількість смертей людей спричиняють серцево-судинні захворювання [1, 2]. На сьогодні існує багато інструментів, які допомагають лікарям попередити або виявити проблеми в роботі серця. Одним з найбільш поширених засобів є електрокардіографія, яка дозволяє графічно реєструвати електричні явища у тілі люди, які виникають в серцевому м'язі під час його діяльності. Криву, що отримують в результаті фіксації такої активності, називають електрокардіограмою. Таким чином, ЕКГ – це запис коливань різниці потенціалів, які виникають у серці під час його збудження [4]. Стандартний запис ЕКГ складається з 12 відведень, які отримуються з 10 електродів [51]. Типова діаграма сигналу ЕКГ зображена на рис. 1.1.

Природа ЕКГ-сигналу є псевдоперіодичною. ЕКГ-сигнал складається з кардіоциклів (рис. 1.1). За виглядом кардіоциклу лікарі визначають наявність тієї чи іншої патології на ЕКГ-сигналі. Варто зауважити, що кардіоцикл виділяється оком лікаря із сигналу за R-зубцем (рис. 1.2).



Рис. 1.1. Приклад ЕКГ-сигналу, який складається з 12 відведень [52] для діагностики серцево-судинних захворювань





Варто зауважити, що існуючі датасети, у яких анотовані ті чи інші патології серця, також прив'язані до кардіоциклу. На рис. 1.2 наведені основні показники (зубці та сегменти), за якими лікар аналізує кардіоцикл на наявність певної патології. Отримані записи ЕКГ-сигналу інтерпретуються ним за наведеними показниками для виявлення причин скарг пацієнтів на дискомфорт або біль у грудях, джерелом яких може бути серце [4, 5]. Відповідно до [53], серцево-судинні захворювання поділяють на такі категорії: ішемічна хвороба серця, дисліпідемія, артеріальна гіпертензія, легенева артеріальна гіпертензія, захворювання міокарда та серцевих оболонок, набуті вади серця, порушення ритму та провідності (аритмії), серцева недостатність. Надалі в цій роботі розглядатимуться лише аритмії. Відповідно до статистики, у США в 2018 році понад 560 000 висновків про смерть включали аритмію як одну з її причин [3]. Фібриляція передсердь – найпоширеніша стійка аритмія, вражає близько 2-3 % населення, причому серед людей похилого віку цей показник ще вищий. За оцінками, зі старінням суспільства поширеність цього захворювання зросте до 12,1 мільйона в США до 2030 року і до 17,9 мільйона в Європейському Союзі до 2060 року [54].

Оскільки існує багато типів можливих відхилень ЕКГ від норми та великі за обсягом ЕКГ-записи (такі, як холтери), то процес їх аналізу може бути затратним за часом та з імовірними помилками. Тому для вирішення означених проблем застосовуються методи та підходи інформаційних технологій, зокрема, завдяки активному розвитку штучного інтелекту набули широкого використання такі інструменти, як машинне навчання (ML) і глибоке навчання (DL) для класифікації патологій на ЕКГ-сигналах.

Використання нейронних мереж глибокого навчання (CNN) у класифікації ЕКГ вже продемонструвало свою ефективність у виявленні різноманітних серцевих патологій, таких як аритмії [6, 7], міокардит [8, 9, 10] тощо. Попри значні досягнення у цій сфері, робота моделей глибокого навчання залишається «чорною скринею» для кінцевого користувача, що дуже критично для такої сфери як медицина [11, 12, 13].

Виходячи з наведеного, задача ідентифікації аритмії на ЕКГ-сигналі, яка не тільки виявляє патології аритмій, але й «пояснює», чому саме такі рішення прийняті, є досить актуальною. Під пояснювальним штучним інтелектом розуміють використання засобів та методів, спрямованих для інтерпретації результатів, які генерує нейронна мережа.

1.2. Огляд сучасних підходів до ідентифікації патологій аритмій на ЕКГсигналі

У підрозділі розглядаються сучасні підходи до автоматизованого аналізу ЕКГсигналів, які базуються на методах глибокого навчання. Основною причиною вибору глибокого навчання є його висока ефективність у завданнях обробки складних та великих за обсягом даних та можливістю знаходження прихованих залежностей [30], що дозволяє досягати більшої точності у діагностиці. Виділення кардіоциклів за Rзубцями є важливим етапом, оскільки правильна їх ідентифікація формує основу для подальшої класифікації та аналізу. Класифікація кардіоциклів за класами патологій аритмій дозволяє визначати конкретні типи захворювань на основі отриманих характеристик сигналу. Окремо увага приділяється інтерпретації рішень, прийнятих моделями глибокого навчання, оскільки зрозумілість та прозорість таких рішень є критично важливими для їх практичного застосування у медицині. Розгляд цих аспектів забезпечує комплексне розуміння сучасних підходів до аналізу ЕКГ-сигналів.

Виділення кардіоциклів за R-зубцями у ЕКГ-сигналі. Основний підхід до підготовки ЕКГ-сигналу для застосування в моделях глибокого навчання включає обов'язкове виділення кардіоциклів, базуючись на R-зубцях у сигналі. Це випливає із природи ЕКГ-сигналу, а саме із його псевдоперіодичності, тобто одиницею аналізу роботи серця за ЕКГ-сигналом є кардіоцикл (QRS-комплекс), виявлення якого полягає у знаходження R-зубця. Таким чином, точність визначення R-зубців є критичною, оскільки вона впливає на якість застосування методів глибокого навчання для розв'язання задач класифікації. Сьогодні існує багато методів та підходів до виявлення R-зубців, які базуються на різних методах обробки сигналів, таких як Wavelet-перетворення [55, 56, 57], перетворення Гільберта [58, 59], генетичний алгоритм [60], машинне навчання [31, 32, 33], глибоке навчання [61, 62, 63] та ін. В багатьох сучасних роботах щодо знаходження R-зубців зазначається ефективність, що перевищує 99 %. Проте, в переважній більшості робіт вказується велика похибка або вона взагалі не виявляється при розрахунку статистичних показників. Наприклад, у дослідженнях [62] та [64] досягнуто висока точність виявлення зубців в ЕКГсигналі, проте допустима похибка становить ±75 мс. Це створює загальне вікно похибки у 150 мс, що перевищує нормальну довжину QRS-комплексу.

Silva та інші [65] пропонують підхід з використанням алгоритму Турісаlіty Eccentricity Detection Anomaly (TEDA) для виявлення R-зубців. Метод працює в три етапи, а саме застосування методів фільтрації до ЕКГ, застосування алгоритму TEDA, ідентифікація R-зубців. Запропонований метод працює з точністю 95,45 % при похибці в 100 мс. В роботі [66] автори використовують ієрархічну кластеризацію та Discrete Wavelet Transformation (DWT) для пошуку R- та T-зубців. Точність визначення R-зубців складає 99.83 % при використанні похибки \pm 75 мс. У роботі [67] при виявленні QRSкомплексу, в межах якого знаходиться зубець R, використовується похибка в \pm 150 мс. Оскільки медична сфера вимагає максимально високої точності, то такі похибки в дослідженнях можуть бути доволі критичними. Саме тому такі науковці, як В. Рогт та Р. W. Macfarlane у своїй статті [68] провели аналіз різних методів пошуку зубця R, серед яких згадуються такі методи, як: Pan and Tompkins by Fariha et al. [69], Hamilton and Tompkins by Ahmad et al. [70], Christov by Xiong et al [71] тощо. В результаті цього дослідження автори встановили, що фактично в кожній статті повідомляється про дуже високу точність у 98 % і більше, що втім може бути пояснено використанням великої допустимої похибки при розрахунку точності запропонованих методів. Автори допускають використання похибки, яка складає 100 мс або навіть і більше. Тому задача визначення R-зубців з використанням якомога менших похибок залишається актуальною і потребує подальших досліджень.

Класифікація кардіоциклів за класами патологій аритмій. Наступним кроком в аналізі ЕКГ-сигналу, після виявлення у сигналі зубців R, є класифікація знайдених за R-зубцями QRC-комплексів за класами патологій. Є цілий ряд досліджень щодо застосування моделей глибокого навчання для класифікації ЕКГ-сигналу.

Ниапд та інші [72] представили систему класифікації, засновану на класифікації ЕКГ за допомогою нейронної мережі FCResNet та отримали середню точність класифікації 98.79 %. В роботі [34] розроблено 31 шарову модель ResNet для класифікації 5 типів ЕКГ з одного або двох відведень. Для одного каналу ЕКГ метод показав середні показники точності, recall та positive predictivity на рівні 99,06 %, 93,21 % та 96,76 %, відповідно. Для двоканального ЕКГ ті самі показники становлять 99,38 %, 94,54 % та 98,14 %, відповідно.

S. Bhattacharyya та інші [73] пропонують для класифікації аритмії використання ансамблів алгоритмів Random Forest та SVM із застосуванням бібліотеки TSFEL для вилучення ознак. Метод досягає точності 98,21 % для класифікації 5 класів. Автори [74] використовують SVM-класифікатор з асиметричними витратами (AS3VM), який приймає ЕКГ-сигнал спроектованого на часо-частотній площині, використовуючи перетворення Стоквелла. Авторам вдалося отримати точність в діапазоні 96,06–99,38 % та recall – 85,97–98,65 % при класифікації 4 класів ЕКГ без класу «всі інші». Yang та Wei [75] використовують комбіновані параметричні і візуальні особливості

морфології ЕКГ як вхідні дані для KNN. Заявлена точність класифікації складає 97,70 % для класифікації 5 класів (без класу «всі інші»).

Li та інші в своїй роботі [76] пропонують персоналізований метод інкрементного навчання для автоматичної класифікації 4 класів ЕКГ. Запропонований метод досягає точності 87,07 % для CPSC2018 [77] набору даних.

Автори [78] використовують каскадну модель CNN для класифікації 4 класів ЕКГ із точністю 96,2 %, а у роботі [79] автори запропонували CNN-модель, якою класифікують кардіоцикли на 5 класів з точністю 99,40 % та recall з точністю 98,78 %. Проте в обох роботах до переліку підтримуваних класів не входить клас «всі інші», що може знизити статистичні показники класифікації.

Kolhar та інші [35] використовують моделі AlexNet та Dual Branch Fusion для класифікації патологій інфаркту міокарда, блокади ніжки пучка Гіса та дизритмії. Авторам вдалося класифікувати наведені три патології з точністю до 99 %. У роботі [80] пропонується нова гібридна модель глибокого навчання, яка поєднує згорткову нейронну мережу (CNN) та двонаправлений рекурентний блок (BiGRU) з багатоголовою увагою (модель CBGM). Запропонована гібридна модель дозволила з точністю до 99,41 % класифікувати ЕКГ на 5 класів, серед яких 4 патології та норма. Авторами не враховується клас «всі інші».

Dong та Si [81] пропонують ознаку «динаміка серцебиття» для класифікації аритмій. Ознака моделює морфологічні зміни серцебиття, є більш чутливою до слабких його варіацій і відображає основні динамічні зміни протягом серцевого циклу на електрофізіологічному рівні. Тестування цього методу проводилося для 5 класів ЕКГ без використання класу «всі інші». Авторам вдалося досягти точність 99.21 %, 99,10 % precision, 98,84 % recall та 0.9897 F1-score з використанням класифікатора KNN.

Автори [82] навчили CNN-BiLSTM класифікувати п'ять типів аритмій з набору даних МІТ-ВІН. Застосування моделі показало, що вона здатна класифікувати з точністю до 98 %, 91 % – чутливості та 91 % – специфічності. Lui та інші [83] запропонували використання збірки на основі мереж LSTM та CNN, що дало можливість класифікувати ЕКГ-сигнали з точністю до 99.1 %, чутливістю – 99.3 %,

специфічністю – 98.5 %. Варто зазначити, що автори отримали такий результат при класифікації ЕКГ лише на 4 класи, не включаючи клас «всі інші».

Хи та інші [7] розробили CNN-модель, яка класифікує ЕКГ на 5 класів, включаючи клас «норма» та «всі інші». Відповідно, за допомогою запропонованого методу можна класифікувати лише 3 патології, що покриває малий набір можливих патологій.

Аlamatsaz та інші [84] пропонують метод класифікації 9 класів ЕКГ за допомогою 11-шарової СNN- та LSTM-мережі. Запропонований метод показав точність класифікації 98.24 %. Sun та інші у своїй роботі [85] пропонують модель з трьох складових: CNN, LSTM, та SE (механізм уваги каналу). Запропонована CNN-LSTM-SE-модель класифікує 5 класів ЕКГ з точністю 98,5 %, recall – 98 % та F1-score – 98 %.

В роботах Degirmenci та інші [36] і Rohmantri та інші [86] досягли високої точності класифікації, використовуючи 2D-зображення ЕКГ розміром 64×64 як вхідні дані для класифікації аритмічного серцебиття. Також існує ряд робіт щодо перетворення одновимірного сигналу на двовимірне представлення. Zhang та інші [37] використовують 2D-представлення ЕКГ у вигляді текстурованого зображення, згенерованого за допомогою методу рекурентних графіків. В роботах [87, 88] розглядається перетворення сигналу ЕКГ на скалограми з подальшою класифікацією на патології, що дало точність класифікації 95.67 % та 98.7 %, відповідно. Також використовуються спектральні перетворення сигналу в зображення. В роботі [89] завдяки використанню спектральних зображень ЕКГ вдалося отримати точність класифікації 99.11 % при класифікації ЕКГ на 8 класів. Проте не використовується клас «всі інші» застосування якого, ймовірно, погіршить результат класифікації. Автори [90] застосували спектральні зображення ЕКГ для класифікації на 2 класи (норма-патологія) та отримали точність 99.8 %.

Jat та інші [91] пропонують перетворення ЕКГ-сигналів у зображення за допомогою методів кодування, таких як градієнтне поле кутових різниць (GADF), градієнтне поле кутових сум (GASF) і марковське перехідне поле (MTF). Найвищої точності (96,71 %) було досягнуто навчанні CNN-мережі з використанням конкатенації цих трьох методів кодування зображень. Незважаючи на результати застування 2D-представлення для класифікації ЕКГ, значні обчислювальні ресурси, що вимагаються, створюють проблеми для застосування в реальному часі та використання на пристроях з обмеженою обчислювальною потужністю.

В роботі [92] Abdelhafid та інші зосередилися на класифікації аритмії ЕКГ з використанням п'яти класів без класу «всі інші». Це, ймовірно, сприяло високим показникам класифікації. Однак виключення класу «все інше» може не відображати реальну точність, оскільки ігнорує сигнали, які не відповідають попередньо визначеним категоріям. Також в цій роботі на вхід подається інформація про 1 кардіоцикл. Оскільки до переліку підтримуваних класів входить "Premature ventricular contraction", то такої кількості даних може бути недостатньо для класифікації. Зазначена патологія має ознаку «компенсаторна пауза», для визначення якої потрібні сусідні кардіоцикли.

Отже, для ефективного виявлення аритмії вкрай важливо розробити моделі DL, які могли б збалансувати точність, обчислювальну можливість і здатність класифікувати більшу кількість патологій аритмій, включаючи клас, до якого увійдуть всі випадки патологій, які не виділені в окремий клас.

Інтерпретація рішень, прийнятих за глибоким навчанням. Zhang та інші [39] представили інтерпретовану DL-модель для діагностики 12-відведень ЕКГ. Їхня робота виділяється своєю інтерпретованістю і всебічним аналізом декількох відведень, пропонуючи детальне розуміння діагностичного процесу. Однак складність їхньої моделі може перешкоджати її використанню в простіших або більш обмежених ресурсами умовах, оскільки висока інтерпретованість часто досягається ціною обчислювальної ефективності.

Singh i Sharma [93] запропонували CNN для інтерпретації та класифікації аритмій, продемонструвавши високу точність і ефективність. Однак, як і інші дослідження, вони стикаються з проблемами при застосуванні в реальному часі через обчислювальні вимоги. Крім того, в цій роботі не розглядається класифікація сигналів, які не відповідають попередньо визначеним класам, що має вирішальне значення для практичного застосування.

Zhao та інші [94] запропонували модуль пояснення часових рядів, підключений до моделі класифікації, щоб вивчити вплив ознак у кожен момент часу результату класифікації ЕКГ. Пояснювальний модуль генерує оцінки важливості на кожному часовому кроці ЕКГ, підбираючи маску збурення до навченої моделі.

Strodthoff та інші [95] показали інтерпретацію, сформовану за допомогою правила пошарового поширення релевантності (LRP) для CNN, навченого класифікувати ЕКГ. В свою чергу, Bender та інші в свої роботі [96] використали правила LRP та інтегровані градієнти. Salinas-Martinez та інші [38] використовують LRP для інтерпретації патології тріпотіння передсердь.

В роботі [97] використовується метод Partial Dependence Plot для інтерпретації результатів класифікації вазовагального зомління на основі інформації про артеріальний тиск та ЕКГ.

В таких роботах, як [98, 99, 100], розглядається інтерпретація результатів класифікації, базуючись на Grad-CAM. Застосування методу Grad-CAM показує, які області вхідного сигналу сприяли прогнозуванню, але не пояснює причиннонаслідковий зв'язок між цими областями і результатами класифікації. Для лікарів, які аналізують сигнали ЕКГ, це може бути менш корисним, оскільки не дає медичного пояснення, чому модель сфокусувалася на певній ділянці сигналу. Також у випадку застосування Grad-CAM до ЕКГ-сигналів можна отримати результат інтерпретації, в якому весь вхідний ЕКГ-сигналі буде помічений як одна важлива область.

У роботах [101, 102, 103] використовують SHAP у своєму дослідженні. За своєю особливістю, SHAP надає значення окремим ознакам (або часовим точкам), але в 1D-класифікації сигналів конкретна часова точка може бути не дуже корисною сама по собі, оскільки часто важливими є закономірності між кількома часовими точками. Наприклад, виявлення аритмії залежить від форми всього комплексу QRS, а не лише одного часового кроку. Оскільки SHAP розраховує важливість кожної часової точки вхідного сигналу, то це робить такий підхід повільним та затратним за ресурсами.

Verma в своїй роботі [104] провів дослідження та порівняння Partial Dependence Plots, SHAP, Permutation Feature Importance, Grad-CAM для інтерпретації

результатів класифікації ЕКГ. За результатами автора Grad-CAM було визнано кращим методом з чотирьох обраних методів.

Інтерпретація класифікації в роботах [105, 40, 41] базується на застосуванні методу LIME, який фокусується на локальній інтерпретації, пояснюючи передбачення для окремого сигналу шляхом аналізу впливу різних його сегментів. У випадку класифікації сигналів, LIME дозволяє оцінювати важливість груп часових точок замість окремих точок. Метод модифікує вхідний сигнал, виключаючи або змінюючи частини (наприклад, маскуючи сегменти), і оцінює вплив цих змін на передбачення моделі [106]. Однак пертурбація даних може вплинути на стабільність результатів [107], і метод також може бути ресурсозатратним, особливо для високочастотних сигналів, хоча меншою мірою, ніж SHAP.

В свою чергу, існують різні адаптації та оптимізації методу LIME. До прикладу, в роботі [108] пропонується модифікація Bootstrap-LIME (B-LIME), яка передбачає поєднання сегментації серцебиття та методів бутстрапінгу для покращення пояснення моделі з урахуванням часових залежностей між ознаками. В модифікації OptiLIME [109] передбачається оптимізація алгоритму LIME, для пошуку найкращого набору вагових коефіцієнтів для ознак у поясненні. Автори пропонують фреймворк, який автоматично знаходить найкращу ширину ядра, що максимізує стабільність, зберігаючи при цьому попередньо визначений рівень прихильності. Модифікація G-LIME [110] працює за принципом «від глобального до локального», який спочатку оцінює глобальну важливість ознак за допомогою глобального попереднього значення, а потім пояснює прогнози для кожного локального екземпляра, підбираючи лінійну модель до найважливіших ознак. Модифікація ALIME [111] пропонується для покращення нестабільності та локальної точності LIME за допомогою заздалегідь згенерованої великої кількості даних шляхом вибірки з гаусівського розподілу, а для покращення локальної точності використовується autoencoder для зважування локальної моделі. Abdullah та інші в своїй роботі [112] пропонують використання LIME разом з тепловою картою для візуального представлення прогнозів CNN-GRU.

Отже, для інтерпретації класифікації ЕКГ-сигналу, існуючі методи фокусуються на пошуку областей вхідного сигналу, які модель глибокого навчання

вважає важливими для прийняття рішень. Оскільки для класифікації патології можуть бути важливими різні ознаки, розподілені по всьому кардіоциклу. В такому випадку такі методи формують інтерпретацію, в якій показано, що весь кардіоцикл був важливим в класифікації. Проте, для лікаря виділення області ЕКГ, яка сприяла класифікації, не є достатньою інтерпретацією, оскільки він керується чіткими ознаками для класифікації ЕКГ.

1.3. Моделі глибокого навчання для аналізу ЕКГ-сигналу

Модель для пошуку R-зубців. Для пошуку R-зубців на ЕКГ-сигналі використовується мережа Encoder–Decoder. Encoder-decoder нейронні мережі широко застосовуються для задач автоматичної обробки сигналів, зокрема для виявлення R-зубців в ЕКГ, завдяки їх здатності ефективно вирішувати завдання локалізації, сегментації та класифікації сигналів [113]. Основна перевага архітектури encoder-decoder полягає у її здатності отримувати важливі характеристики вхідного сигналу, стискаючи інформацію у фазі кодування (encoder) та відновлюючи інформацію у фазі декодування (decoder).

Цей підхід дозволяє локалізувати ключові точки сигналу, навіть якщо вони зазнають впливу шуму або артефактів. На базовому рівні архітектура мережі Encoder-decoder подається так, як зображено на рис. 1.3.



Рис. 1.3. Загальна архітектура мережі Encoder-decoder [113]

При застосуванні мережі до розв'язання конкретної задачі архітектура мережі модифікується та адаптується під конкретні потреби.

Модель класифікації патологій аритмій на ЕКГ-сигналі. Для вирішення задач класифікації аритмії на ЕКГ-сигналі існують різні архітектури згорткових нейромереж. В цій роботі пропонується покращення для архітектури, запропонованої в роботі [7], початкова архітектура якої зображена на рис. 1.4.



Рис. 1.4. Архітектура згорткової нейронної мережі, запропонованої в роботі [7] для класифікації 5 класів аритмій

Вибрана архітектура мережі складається з дев'яти шарів, включаючи чотири згорткові шари, два шари subsampling, два повністю з'єднані шари та один шар Softmax.

1.4. Ознаки ЕКГ-сигналу, за якими приймається рішення про патологію аритмії у медичній практиці

У роботі, для інтерпретації отриманих рішень про патології на ЕКГ-сигналі, застосовується наступний, визначений офіційною медициною, перелік ознак.

На нормальний ЕКГ-сигнал (кардіоцикл) вказують такі ознаки (рис. 1.2)):
 наявність всіх елементів кардіоциклу (зубці та інтервали);
 QRS-комплекс нерозширений та недеформований;
 зубець Р перед кожним QRS-комплексом;
 наявність РQ-інтервалу в нормальному вигляді.

2. Для патології «Передчасне скорочення шлуночків» (Premature ventricular contraction), або як її ще називають «Шлуночкова екстрасистолія» вказують такі

ознаки (рис. 1.5): 1) відсутній зубець Р; 2) розширений QRS-комплекс; 3) QRSкомплекс з деформацією (під деформацією розуміють зміну форми QRS-комплексу – правошлуночкову екстрасистолію, якщо вона у відведенні V1 за формою нагадує блокаду лівої ніжки пучка Гіса, а також лівошлуночкову екстрасистолію, яка нагадує блокаду правої ніжки пучка Гіса); 4) наявність повної компенсаторної паузи – це наявність інтервалу між двома послідовними шлуночковими комплексами синусового ритму, між якими перебуває екстрасистолія та який дорівнює подвоєному інтервалу RR синусового ритму (компенсаторна пауза – час, що минув після екстрасистолії до виникнення нормального скорочення).





Рис.1.5. Кардіоцикл з патологією «Шлуночкова екстрасистолія»

Рис. 1.6. Кардіоцикл з патологією «Блокада лівої ніжки пучка Гіса»

3. Патологія «Блокада лівої ніжки пучка Гіса» (Left bundle branch block beat) характеризується (рис. 1.6) такими ознаками: 1) деформований та розширений QRS-комплекс, тривалість якого перевищує 120 мс; 2) глибокі, широкі зубці S у правих грудних відведеннях; 3) дискордантні зміни ST-T відносно комплексу QRS. Дискордантними змінами для ST-T є депресія або елевація сегмента ST в протилежну сторону від основного вектора (зубців R або S); 4) подовження ЧВВ у лівих грудних відведеннях.

4. Патологія «Блокада правої ніжки пучка Гіса» (Right bundle branch block beat) характеризується (рис. 1.7) такими ознаками: 1) глибокі, широкі зубці S у стандартних та лівих грудних (V5,6) відведеннях; 2) розширення та деформація QRS (rSR') у грудних (V1,2) відведеннях (має вигляд букви M); 3) депресія ST (депресією

ST сегмента є його зниження нижче ізолінії); 4) інверсія Т в правих грудних відведеннях (інверсією є протилежна від нормальної поляризація хвилі); 5) подовження часу внутрішньоподібного відхилення (ЧВВ) у правих грудних відведеннях (ЧВВ представляє період від початку комплексу QRS (зубців Q або R) до максимального відхилення комплексу QRS (як правило, вершини зубця R); у нормі ЧВВ≤0,04 с).



Рис. 1.7. Кардіоцикл з патологією «Блокада правої ніжки пучка Гіса»



Рис. 1.8. Кардіоцикл з патологією «Вставна шлуночкова екстрасистолія»

Патологія «Вставна шлуночкова екстрасистолія» (Fusion of ventricular) характеризується (рис. 1.8) такими ознаками: 1) кардіоцикл з характерними ознаками шлуночкової екстрасистолії; 2) відсутність компенсаторної паузи;
 виникає поміж кардіоциклами в нормі.

У роботі отриманий результат класифікації (віднесення до певного класу аритмій) за моделями глибокого навчання буде інтерпретуватися за допомогою наведених ознак.

Оцінка результатів, отриманих за моделями глибокого навчання для медичних систем. Застосування ШІ у задачах, пов'язаних з чутливими предметними областями (медицина, у нашому випадку), потребує більш відповідального підходу до вибору метрик оцінювання отриманих результатів за моделями глибокого навчання. Запропонований підхід має такі складові, для оцінки результатів яких потрібно запропонувати та обґрунтувати перелік метрик оцінювання отриманих результатів:

1) метрики для оцінювання якості бінарної класифікації (задача визначення зубців R);

 метрики для оцінювання якості мультикласової класифікації (задача визначення класів аритмій);

3) метрики для оцінювання якості клінічних випробувань за експертною оцінкою та оцінкою системи ШІ.

Існує цілий ряд метрик, які можна використати, щоби бути впевненим у результатах класифікації [114]: Confusion matrix, Accuracy, Precision and Recall, F-Scores, Matthews Correlation Coefficient, Cohen's Kappa, Balanced Accuracy, Precision-Recall curve, AUC: Receiver operating characteristic (ROC) curve, Gini coefficient (Gini index), Log-loss тощо. Крім наведених метрик, розглядають два види класифікації: бінарну і мультикласову. Також аналізують метрики для оцінювання якості клінічних випробувань за експертною оцінкою та оцінкою системи IIII.

Далі буде розглянуто та обрано метрики, необхідні для оцінки результатів роботи класифікатора, з урахуванням забезпечення довірчих рішень для аналізу роботи запропонованих класифікаторів у чутливій предметній області – медицині.

Методика оцінювання результатів класифікації для виявлення R-зубців. Оцінка результатів класифікації щодо виявлення R-зубців розпочинається з аналізу матриці помилок (Confusion matrix) [115] для бінарної класифікації, стосовно якої матриця матиме вигляд, зображений на рис. 1.9.

		Результат кл		
	Класи	Позитивний	Негативний	Всього
		(1)	(0)	
раний льтат	Позитивний (1)	TP	FN	Σ
Анотс	Негативний (0)	FP	TN	Σ
	Всього	Σ	Σ	Σ

Рис. 1.9. Матриця помилок для двокласової класифікації

Позначення:

– *TP* – TruePositive, коли анотованим значенням було «так», і метод класифікації визначив «так» (правильне спрацювання);

– *FP* – FalsePositive, коли анотованим значенням було «ні», а метод класифікації визначив «так» (хибне спрацювання);

– *TN* – TrueNeqative, коли анотованим значенням було «ні», і метод класифікації визначив «ні» (правильне спрацювання);

– *FN* – FalseNegative, коли анотоване значення було «так», а метод класифікації визначив «ні» (хибне спрацювання).

Використовуючи наведену вище матрицю помилок класифікації, можна отримати кілька метрик моделі бінарної класифікації, які при цьому не є взаємовиключними, доповнюють одна одну та можуть бути використані в процесі оцінювання рішення класифікації в кожному конкретному випадку.

Спочатку розглядається найбільш поширена та проста для розуміння метрика – Accuracy. Це відношення всіх правильних прогнозів до загальної кількості всіх передбачуваних зразків. У позначеннях матриці помилок класифікації (Confusion matrix) Accuracy матиме вигляд [114]:

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN}.$$
 (1.1)

Варто зазначити, що в окремих випадках метрика точності (Accuracy) може бути недостатньо інформативною. У зв'язку з цим доцільно розглянути інші метрики, які є більш чутливими до помилок класифікації. Для оцінки результатів роботи класифікаційного методу для кожного класу окремо вводяться метрики Precision та Recall [114]:

$$precision = \frac{TP}{TP + FP'}$$
(1.2)

$$recall = \frac{TP}{TP + FN}.$$
(1.3)

Precision – це частка об'єктів, які дійсно належать позитивному класу щодо всіх об'єктів, віднесених класифікатором до цього класу. Recall – це частка знайдених класифікатором об'єктів, які належать позитивному класу щодо всіх

об'єктів цього класу в тестовій вибірці [116]. Очевидно, що чим вищі Precision і Recall, тим краще. Однак, максимальні Precision і Recall недосяжні одночасно і доводиться шукати деякий баланс.

Показник F1_Score [114] об'єднує в собі інформацію про Precision і Recall методу класифікації. Міра F1 є гармонійним середнім між Precision і Recall:

$$F_1 = 2 * \frac{recall * precision}{recall + precision}.$$
 (1.4)

Показник F1_Score забезпечує здатність класифікатора передбачити певний клас.

Особливістю обрахування наведених вище показників у задачах машинного та глибокого навчання є використання, для побудови класифікаторів та для їх наступного тестування, тренувальних (навчальних) і тестових наборів даних. Тобто існуючий набір даних випадковим чином розбивається на тренувальний та тестовий.

Для оцінки стабільності класифікатора та аналізу впливу тренувальних вибірок на результати класифікації доцільно розраховувати наведені статистичні показники на різних наборах даних. Це досягається шляхом використання різних розбиттів на тренувальні і тестові набори (наприклад, 75 %/25 %, 80 %/20 % або 90 %/10 %), що дозволяє врахувати можливу варіативність результатів залежно від способу розподілу даних.

Для класифікатора розраховуються статистичні метрики на тренувальному та тестовому наборах з крос-валідацією по 7 (± 2) варіантах розбиття. В результаті буде отримано середнє значення метрик та їх стандартні відхилення (standard deviation – Std), що дасть уявлення про стабільну якість класифікації і знизить вплив вибірки на результат. При цьому особливу увагу потрібно приділити для метрики Recall, яка є основною метрикою, так як невиявлення діагнозу при його наявності є дуже негативним результатом класифікації. Якщо Recall на тестовій вибірці дає показники нижчі за 80 %, то це вважається неприйнятним для цієї задачі, і класифікатор слід змінити.

Особливу увагу слід звернути на розкид значень (стандартні відхилення). Якщо він досить великий (більше 5 % як для тренувального, так і для тестового наборів), то це вказує на істотну залежність результатів від вибірки та вимагає підвищення стабільності роботи моделі.

Одним з додаткових способів оцінити модель є AUC [117, 114] – площа (Area Under Curve) під кривою помилок (Receiver Operating Characteristic Curve). Щоб отримати цю криву, необхідно обчислити дві метрики, які також отримані з матриці помилок класифікації: рівень істиннопозитивних екземплярів (True Positive Rate, TPR), який тотожний Recall, і рівень хибнопозитивних (False Positive Rate, FPR). Своєю чергою, FPR (1.5) – частка негативних об'єктів, які помилково були класифіковані як позитивні, до всіх фактичних негативних. Чим вище FPR, тим більше негативних екземплярів класифікуються не так [114]:

$$FPR = \frac{FP}{FP + TN}.$$
(1.5)

Для об'єднання FPR і TPR в одну метрику необхідно обчислити ці метрики, а потім побудувати їх на одному графіку з осями FPR і TPR. Результуюча крива є кривою ROC, а площа під кривою є метрикою AUC ROC (рис. 1.10).



Рис. 1.10. Приклад побудованого графіка ROC-кривої для оцінки результатів класифікації

Чим вище показник AUC, тим якісніше діє класифікатор, при цьому значення 0,5 демонструє непридатність обраного методу класифікації (відповідає звичайному вгадуванню). В ідеальному випадку, коли класифікатор не робить помилок (*FPR* = 0,
TPR = 1) буде отримано площу під кривою, що дорівнює 1; в іншому випадку, коли класифікатор випадково видає ймовірності класів, *AUC-ROC* буде прагнути до 0,5, оскільки класифікатор видаватиме однакову кількість *TP* та *FP*.

Критерій AUC стійкий до незбалансованих класів і може бути інтерпретований як ймовірність того, що випадково обраний positive-об'єкт буде проранжований вище класифікатором (отримає вищу ймовірність належності до positive), ніж випадково обраний negative-об'єкт.

Методика оцінювання результатів класифікації аритмій. Коли для класифікації використовуються більше двох міток (у нашому випадку – 9 класів), то це випадок багатокласової класифікації. Оцінювання якості мультикласового класифікатора дуже схоже на бінарний випадок класифікатора, але є свої особливості. На рис. 1.11 наведено матрицю невідповідностей (confusion matrix) у випадку багатокласової класифікації [118].

		$C_0 \ldots C_{k-1}$	C_k	$C_{k+1} \ldots C_n$
результат	c_{k+1} c_n	TN	FP	TN
аний	c_k	FN	TP	FN
Анотов	$c_0 \ldots c_{k-1}$	TN	FP	TN

Результат класифікації

Рис. 1.11. Матриці помилок для багатокласової класифікації

Матриця помилок класифікації з *n* класів. При розгляді класу k ($0 \le k \le n$) можна отримати чотири різні результати класифікації: TP (true positive) – істиннопозитивний, TN (true negative) – істиннонегативний, FP (false positive) – хибнопозитивний і FN (false negative) – хибнонегативний

Рис. 1.11 ілюструє матрицю помилок класифікації для багатокласової ситуації з *n* класами. Матриця помилок класифікації дає кількість (неправильних) класифікацій для кожного класу. Точкові оцінки збираються в матрицю помилок класифікації $C \coloneqq c_{ij}$, де c_{ij} – це кількість зразків, коли клас фактично був *i*, а клас *j* оцінений. Загалом, матриця помилок класифікації надає чотири типи результатів щодо однієї цілі класифікації *k*:

1) істиннопозитивні результати (*TP*) – клас було оцінено, поки це дійсно відбувається (*c*_{*kk*})

$$TP = c_{kk}; \tag{1.6}$$

2) істиннонегативні результати (TN) – клас не оцінювався і цього не відбулося:

$$TN = \sum_{i,j \in N \setminus \{k\}} c_{ij}; \tag{1.7}$$

3) хибнопозитивні результати – помилкове спрацювання (*FP*) – клас був оцінений, але не відбувся:

$$FP = \sum_{i,j \in N \setminus \{k\}} c_{ik}; \tag{1.8}$$

4) хибнонегативні результати (FN) – клас не був оцінений, але стався:

$$FN = \sum_{i,j \in N \setminus \{k\}} c_{ki}. \tag{1.9}$$

Метрика точності (Accuracy) для багатокласової класифікації визначається як відношення кількості правильно класифікованих зразків до загальної кількості зразків [118]. Розраховується за формулою (1.10):

$$Accuracy = \frac{\sum_{i=0}^{N} c_{ii}}{\sum_{i=0}^{N} \sum_{j=0}^{N} c_{ij}}.$$
(1.10)

Для багатокласової класифікації precision, recall та F1_Score можна «усереднити» за всіма класами кількома способами. Якщо класи відрізняються за об'ємом, то при зваженому усередненні малі за кількістю класи практично ніяк не впливатимуть на результат, оскільки їх внесок в середні TP, FP, FN і TN буде незначний.

$$Precision = \frac{\sum_{i=0}^{M} Precision_i * (TP_i + FN_i)}{\sum_{i=0}^{N} \sum_{j=0}^{N} c_{ij}}$$
(1.11)

$$Recall = \frac{\sum_{i=0}^{M} Sensitivity_i * (TP_i + FN_i)}{\sum_{i=0}^{N} \sum_{j=0}^{N} c_{ij}}$$
(1.12)

$$F1_Score = \frac{\sum_{i=0}^{M} F1_Score_i * (TP_i + FN_i)}{\sum_{i=0}^{N} \sum_{j=0}^{N} c_{ij}}$$
(1.13)

У випадку із звичайним усередненням кожен клас матиме однакову вагу у підсумковій метриці:

$$Precision_{class} = \frac{TP_{class}}{TP_{class} + FP_{class}}$$
(1.14)

$$Recall_{class} = \frac{TP_{class}}{TP_{class} + FN_{class}}$$
(1.15)

$$F1_Score_{class} = \frac{2TP_{class}}{2TP_{class} + FP_{class} + FP_{class}}$$
(1.16)

Далі зупинимось на особливостях отримання критерію AUC, розглянутого вище для бінарної класифікації, при багатокласовій класифікації. Інтуїтивно зрозуміло, що для застосування критерію AUC до багатокласової класифікації можна використовувати розподіли «один клас до решти класів» або «один клас до кожного іншого класу» [119, 120].

«Один клас до решти класів» ("One vs Rest") означає, як випливає з назви, оцінку багатокласових моделей шляхом порівняння кожного класу з усіма іншими одночасно. У цьому випадку береться один клас і розглядається як «позитивний» клас, а всі інші – як «негативний». Таким чином, вихід багатокласової класифікації скорочується до бінарної класифікації і тому для оцінки можна використовувати AUC бінарної класифікації.

«Один клас до кожного іншого класу» ("One vs One") означає, що замість того, щоб порівнювати кожен клас з іншими, порівнюються всі можливі двокласові комбінації набору даних. Наприклад, для 3 класів обрано комбінацію "Class1 проти Class2" як перший. Тепер, коли проблема бінарна, також можна використовувати ті самі показники, які використовуються для бінарної класифікації. Слід зауважити, що "Class1 проти Class2" відрізняється від "Class2 проти Class1", тому слід враховувати обидва випадки. Через це в наборі даних 3 класів буде отримано 6 варіантів, а в наборі даних 4 класів – 12 варіантів. Подібно до попереднього випадку, усі показники можуть бути усереднені для отримання остаточної оцінки роботи моделі. **Методика оцінювання клінічних випробувань за експертною оцінкою та оцінкою системи ШІ.** Типовою для задач класифікації в предметній області медицини є ситуація, коли навчений на спеціальних датасетах класифікатор у кінцевому результаті потребує тестування на реальних даних [121]. Реальними даними є інформація з конкретних історій хвороб, яка анотована (віднесена до певних класів) одним або двома експертами. Перед проведенням тестувань необхідно оцінити результат анотування тестової вибірки експертами [122]. Крім того, наведену нижче метрику можна використовувати для оцінювання результатів класифікації (розглянути анотований датасет і прийнятті за цим датасетом рішення класифікатора).

Отже, буде використано коефіцієнт Каппа Коена (K) – статистичний показник, який використовують для вимірювання надійності між експертами для якісних елементів. Зазвичай вважають, що це надійніший показник, ніж простий розрахунок відсотка узгодженості, оскільки K враховує можливість випадкового збігу. Ця метрика часто використовується для перевірки надійності декількох експертів. Важливість надійності експерта полягає у тому, що він відображає ступінь, до якого дані, зібрані в дослідженні, є правильним поданням вимірюваних змінних величин. Отже, у класичному варіанті коефіцієнт Каппа Коена підраховує узгодженість рішень двох експертів, кожен з яких класифікує N об'єктів на M взаємовиключних категорій [122]. Обраховується за формулою (1.17):

$$K = \frac{p_0 - p_e}{1 - p_e},\tag{1.17}$$

де p₀ – емпірична ймовірність згоди на присвоєння класу будь-якій вибірці (спостерігається співвідношення збігів);

p_e – очікувана угода, коли обидва експерти призначають мітки випадковим чином (коефіцієнт домовленості).

Значення коефіцієнта Каппа Коена – це число від –1 до 1. Оцінки вище 0,8, як правило, вважаються хорошою узгодженістю; 0 або нижче означає відсутність згоди (практично випадкові мітки).

Тобто, очікується, що є два незалежні експерти, або експерт та класифікатор, причому категорії під класифікацією будуть незалежними, взаємовиключними та вичерпними. Для забезпечення цих умов перший оцінювач інтерпретується як запропонований класифікатор. Іншим експертом є набір міток перевірки. Хоча, за термінологією Коена, не існує «правильних» чи «неправильних» суджень, в нашому випадку результати, які отримав другий експерт, вважаються «істинними».

Як і наведені вище метрики оцінки для класифікаторів, розрахунок коефіцієнта Каппа Коена спирається на матрицю помилок. На відміну від обчислення загальної точності, коефіцієнт Каппа Коена враховує дисбаланс у розподілі класів для набору даних перевірки.

Розраховується матриця помилок класифікації для окремого завдання класифікації в межах клінічних досліджень. Через N позначають загальну кількість об'єктів, тоді розрахувати необхідні значення для коефіцієнта Каппа Коена, можна за такими формулами (1.18) [122]:

$$p_{0} = \frac{TP + TN}{N}, \qquad R_{cond} = \frac{(TP + FP) * (TP + FN)}{N}, \qquad (1.18)$$
$$p_{e} = \frac{R_{cond} + R_{norm}}{N}, \qquad R_{norm} = \frac{(TP + FP) * (TN + FN)}{N}.$$

У таблиці 1.1 наведені можливі трактування значень коефіцієнта Каппа Коена [122]. Таблиця 1.1

Можливі інтерпретації діапазонів значень коефіцієнта Каппа Коена

Значення коефіцієнта Каппа Коена	Інтерпретація
0	Немає узгодження
0,1–0,2	Незначне узгодження
0,21–0,4	Справедливе узгодження
0,41–0,6	Помірна узгодженість
0,61–0,8	Істотна узгодженість
0,81–0,99	Майже ідеальне узгодження
1	Ідеальне узгодження

1.5. Постановка задачі

Проведений аналіз підтвердив актуальність науково-прикладної задачі для підвищення точності класифікації патологій аритмій на ЕКГ-сигналі засобами

глибокого навчання з подальшою інтерпретацією отриманих результатів за допомогою ознак, що використовуються у медичній практиці. Для досягнення зазначеного необхідно вирішити такі задачі:

1) провести аналіз методів, засобів та технологій для виявлення патологій аритмій на електрокардіограмі;

2) розробити метод ідентифікації R-зубців на ЕКГ-сигналі за моделлю глибокого навчання;

3) розробити метод класифікації патологій аритмій на ЕКГ-сигналі за моделлю глибокого навчання;

4) розробити метод інтерпретації отриманих результатів класифікації сигналів ЕКГ за допомогою ознак, що використовуються у медичній практиці;

5) розробити інформаційну систему для валідації запропонованих методів та провести експериментальні дослідження.

1.6. Висновки до розділу 1

У розділі розглянуто огляд сучасних підходів до ідентифікації патологій аритмій на ЕКГ-сигналі. Розглянуто:

– виділення зубців R у кардіоциклах;

- класифікації кардіоциклів за класами патологій аритмій;

– інтерпретації рішень, отриманих за допомогою моделей глибокого навчання.

Виявлені певні протиріччя в розглянутих джерелах, які сформували мету та завдання дослідження.

Проведено аналіз моделей глибокого навчання, які застосовуються для обробки ЕКГ-сигналу, а саме їхній вплив на точність ідентифікації аритмії.

Розглянуто основні ознаки ЕКГ-сигналу, які використовуються у медичній практиці при ухваленні рішення щодо наявності патології аритмії.

Наведені методики оцінювання результатів, отриманих за моделями глибокого навчання, рішень, за якими у роботі буде проводитись оцінка.

РОЗДІЛ 2.

МОДЕЛЬ ТА МЕТОДИ КЛАСИФІКАЦІЇ АРИТМІЇ НА ЕКГ-СИГНАЛІ ЗА МОДЕЛЯМИ ГЛИБОКОГО НАВЧАННЯ З ПОДАЛЬШОЮ ІНТЕРПРЕТАЦІЄЮ ОТРИМАНИХ РЕЗУЛЬТАТІВ

У цьому розділі розглядаються модель та методи, з яких складається підхід до класифікації патологій аритмій на ЕКГ-сигналі. Запропонований підхід складається з трьох методів. Першим є метод пошуку R-зубців ЕКГ-сигналу, який базується на додаванні синхронного сигналу з можливим розташуванням R-зубців в ЕКГ-сигналі з подальшою обробкою мережею encoder-decoder. Другий метод відповідає за безпосередню класифікацію за наявності аритмії на ЕКГ-сигналі. Особливістю цього методу є те, що підхід до формування вхідного зразка для класифікації, який включає сусідні кардіоцикли, є важливим для розширення діагностичних можливостей моделі. Сформований вхілний зразок класифікується на приналежність до одного із 9 класів патологій аритмій за допомогою моделі глибокого навчання. Третій метод призначений для інтерпретації класифікованих за моделями глибокого навчання патологій аритмій. Особливістю методу є те, що він формує інтерпретацію класифікації за ознаками, що використовуються у медичній практиці.

2.1. Модель процесу виявлення аритмій на ЕКГ-сигналі

У роботі запропоновано підхід до виявлення патологій порушення діяльності серця, пов'язаних з розладом ритмічності, послідовності та сили скорочень серцевого м'яза (аритмій), за ЕКГ-сигналами засобами ШІ з подальшою інтерпретацією отриманих результатів за ознаками, які використовуються у медичній практиці. Запропонований підхід дозволяє виявляти на ЕКГ-сигналі такі патології аритмій:

1) норма;

2) шлуночкова екстрасистолія;

- 3) цикл з кардіостимулятором;
- 4) блокада правої ніжки пучка Гіса;
- 5) блокада лівої ніжки пучка Гіса;
- 6) передсердна екстрасистолія;
- 7) вставна шлуночкова екстрасистолія;
- 8) поєднання стимульованого та нормального ритму;
- 9) все інше.

З урахуванням наведених вище обмежень (перелік патологій), для дослідження (тренування моделей глибокого навчання) буде використовуватися набір даних, у якому містяться саме зазначені патології аритмій.

На рис. 2.1 зображено загальну схему запропонованого підходу, особливостями якого є ряд припущень, які дозволять покращити точність виявлення порушень діяльності серця (аритмій) за аналізом сигналу електрокардіограми моделями глибокого навчання з подальшою інтерпретацією отриманих рішень за допомогою ознак, що використовуються у медичній практиці.



Рис. 2.1. Загальна схема запропонованого підходу

до класифікації аритмії за допомогою пояснювального штучного інтелекту

Особливостями запропонованого підходу є таке:

– для підвищення точності ідентифікації R-зубців запропоновано додавати на вхід моделі глибокого навчання, яка буде натренована на виявлення R-зубців, два вхідні канали: 1) вхідний ЕКГ-сигнал; 2) синхронний йому сигнал, на якому вказані місця прогнозованого розташування R-зубців;

– для підвищення здатності моделі глибокого навчання виявляти та аналізувати приховані залежності у вхідному сигналі пропонується подавати на вхід

моделі глибокого навчання не один кардіоцикл, а використовувати тріаду кардіоциклів, що дозволяє врахувати контекстну інформацію між послідовними циклами (тобто до кожного кардіоциклу додавати ще попередній та наступний кардіоцикли); гіпотеза подання вхідного сигналу у такому вигляді полягає у тому, що для деяких патологій, з точки зору медичної практики, недостатньо враховувати один кардіоцикл для прийняття правильного рішення, а потрібно також мати інформацію про те, що відбувалося «до» та «після» поточного кардіоциклу;

– окрім прийнятих за моделлю глибокого навчання рішень, пропонується подавати ці рішення як комбінацію прийнятих у медичній практиці ознак, які підтверджують або не підтверджують отримані моделлю глибокого навчання рішення.

Реалізувати наведений підхід пропонується за допомогою декомпозиції основної задачі (виявлення порушень діяльності серця (аритмій) за аналізом ЕКГсигналу засобами глибокого навчання) на менші, взаємопов'язані, але більш прості завдання (див. рис. 2.1).

Далі наведено параметри моделі (відображення) процесу обробки інформації, для розв'язання задачі дослідження:

- *S* – ЕКГ-сигнал:

$$S = \{s_1, s_2, \dots, s_N\},$$
 (2.1)

де s_i , i = 1, 2, ..., N — значення амплітуди електричного сигналу, виміряного у певний момент часу для певного відведення; значення з дискретою 400 відліків за секунду з 11-бітною роздільною здатністю в діапазоні 10 мВ; N — розмірність відрізка ЕКГ-сигналу;

– К – «штучний» сигнал (синхронний сигналу S (2.1)), який містить прогнозовані позиції можливого розташування R-зубців:

$$K = \{k_1, k_2, \dots, k_N\},\tag{2.2}$$

де $k_i \in \{0,1\}, i = 1,2, ..., N - у$ позиції, в якій можливе розташування R-зубця та у 20-ти позиціях до цього та 20-ти позиціях після цього $-k_i = 1$, в іншому випадку, $k_i = 0$.

Псевдокод заповнення множини К:

Вхідна інформація: множина S.

Ініціалізація: $k_i = 0, i = 1, 2, ..., N$.

Крок 1. 3 множини S беруться 260 елементів.

Крок 2. $p = index max(s_i)$ з проміжку у 260 елементів.

Крок 3. $k_i = 1, j = p - 20, ..., p + 20.$

Крок 4. Якщо елементи множини S ще не закінчились, то із зсувом у p + 100 елементів перходимо до кроку 1, в іншому випадку – закінчуємо.

Вихідна інформація: множина К.

– *M*₁ – модель глибокого навчання типу трансформера з кодувальнодекодувальною архітектурою для визначення R-зубців у множині *S*:

$$M_1 = \{Enc, Dec\},\tag{2.3}$$

де

$$Enc = \{enc_1, enc_2, \dots, enc_N, \}, enc_i =$$

$$(Conv1D, ReLU, MaxPool1D), i = 1, 2, \dots, N,$$

$$(2.4)$$

де *Conv*1*D* – згортковий шар;

ReLU – передавальний шар;

MaxPool1D – шар субдискретизації (пулінгу):

```
Conv1D = (input, output, kernel, stride, padding), (2.5)
```

де *input* – кількість вхідних ознак;

output – кількість різних ознак, які згортковий шар навчається розпізнавати;

kernel – розмірність ядра згортки;

stride – кількість позицій, на яку ядро згортки зсувається за вхідними даними на кожному кроці;

padding – кількість додаткових елементів (зазвичай нулів), що додаються до країв вхідних даних;

ReLU – передавальна функція, яка «вбудована» у згортковий шар:

$$MaxPool1D = (kernel, stride), \tag{2.6}$$

де kernel – розмірність ядра пулінгу:

stride – крок, з яким з яким зсувається вікно пулінгу.

У задачі виявлення R-зубців, *Enc* (2.4) (енкодер) для врахування особливостей виявлення має такий вигляд:

$$N = 4,$$

$$enc_{1} = ((2,32,3,1,1), f(x) = max(0,x), (2,2)),$$

$$enc_{2} = ((32,64,3,1,1), f(x) = max(0,x), (2,2)),$$

$$enc_{3} = ((64,128,3,1,1), f(x) = max(0,x), (2,2)),$$

$$enc_{4} = ((128,256,3,1,1), f(x) = max(0,x), (2,2)).$$

Декодер (2.3) має такий вигляд:

$$Dec = \{dec_1, dec_2, \dots, dec_N, \}, dec_i = (Upsample, Conv1D, ReLU), i = (2.7)$$

1,2, ..., N,

де Upsample – модуль, який використовується для збільшення роздільності вхідних даних;

*Conv*1*D* – згортковий шар;

ReLU – передавальний шар:

$$Upsample = (scale_factor), \tag{2.8}$$

де *scale_factor* – визначає, наскільки масштабувати просторові розміри вхідних даних.

У задачі виявлення R-зубців, *Dec* (2.7) (декодер) для врахування особливостей виявлення має такий вигляд:

$$N = 3,$$

$$dec_1 = ((2), (256, 128, 3, 1, 1), f(x) = max(0, x)),$$

$$dec_2 = ((2), (128, 64, 3, 1, 1), f(x) = max(0, x)),$$

$$dec_3 = ((2), (64, 32, 3, 1, 1), f(x) = max(0, x));$$

– *DS*_{pk} – набір даних для тренування моделі глибокого навчання *M*₁ для виявлення R-зубців:

$$DS_{pk} = \{dsk_1, dsk_2, \dots, dsk_N\}, dsk_i = (frgS, \{Pk\}), i = 1, 2, \dots, N,$$
(2.9)

де *frgS* – фрагмент сигналу;

Pk — множина індексів $Pk = \{pk_1, pk_2, ...\}$, які відповідають R-зубцям у сигналі frgS;

– Р – множина індексів сигналу S, які відповідають позиціям, на яких розташовані R-зубці.

Зауважимо, що у сигналі S (тобто на ЕКГ-сигналі), наявність чи відсутність патології у медичній практиці визначається за ознаками, які притаманні кардіоциклу. Знаючи розміщення R-зубця на ЕКГ-сигналі, ми фактично знаємо розташування кардіоциклу (сигнал праворуч чи ліворуч від R-зубця). Як правило, у суміжних дослідженнях, в існуючих розмічених датасетах, патологія (чи її відсутність) помічається для кожного кардіоциклу. Однак у медичній практиці лікарі при визначенні тієї чи іншої патології звертають увагу і на сусідні кардіоцикли. Для деяких патологій це є дуже важливим. Тому особливістю запропонованого підходу є те, що і в навчальному датасеті, і при тренуванні моделі глибокого навчання, пропонується подавати на вхід тріаду кардіоциклів: по центру — кардіоцикл, в якому визначається, чи присутня патологія та кардіоцикли, які передують та слідують з ним. Виходячи з цього, наведемо відповідні подання моделі та набору даних:

- *M*₂ – модель глибокого навчання з кодувально-класифікаційною архітектурою для класифікації патологій:

$$M_2 = \{Enc, Cls\},\tag{2.10}$$

де

$$Enc = \{enc_1, enc_2, \dots, enc_N, \}, enc_i =$$
(2.11)

(Conv1D, ReLU, BatchNorm1D, MaxPool1D), i = 1, 2, ..., N,

де *Conv1D* – згортковий шар;

ReLU – передавальний шар;

BatchNorm1D – шар пакетної нормалізації;

MaxPool1D – шар субдискретизації (пулінгу):

$$BatchNorm1D = (input, kernel, stride).$$
(2.12)

У задачі класифікації патологій, *Enc* (2.11) (енкодер), з врахуванням тріади кардіоциклів, має такий вигляд:

N = 5,

$$enc_1 = ((1,64,5,3,1), f(x) = max(0,x), (64,0,0), (0,0)),$$

 $enc_2 = ((64, 64, 5, 2, 1), f(x) = max(0, x), (64, 0, 0), (1, 2)),$ $enc_3 = ((64, 128, 3, 1, 1), f(x) = max(0, x), (128, 1, 2), (0, 0)),$ $enc_4 = ((128, 128, 3, 2, 1), f(x) = max(0, x), (128, 0, 0), (0, 0)),$ $enc_5 = ((128, 256, 3, 1, 1), f(x) = max(0, x), (256, 0, 0), (0, 0)),$ Класифікатор (2.10) має такий вигляд:

$$Cls = \tag{2.13}$$

(Linear, ReLU, BatchNorm1D, DropOut, Linear, ReLU, Linear),

де Linear – повністю зв'язаний (щільний) шар;

ReLU – передавальний шар;

BatchNorm1D – шар пакетної нормалізації;

DropOut – шар для регуляризації, який використовується для запобігання перенавчанню шляхом відкидання (обнулення) деяких нейронів під час навчання:

$$Linear = (input, output), \tag{2.14}$$

$$DropOut = (probability), \tag{2.15}$$

де probability – задає ймовірність відкидання нейронів під час навчання.

Для задачі класифікації патологій, *Cls* (2.13) (класифікатор), з врахуванням тріади кардіоциклів, має такий вигляд:

$$Cls = ((3584,300), f(x) = max(0, x), (300,0,0), (0.68), (300,150), f(x) = max(0, x), (128,9));$$

– *DS_{pt}* – набір даних для тренування моделі глибокого навчання *M*₂ для класифікації патологій аритмій:

$$DS_{pt} = \{dst_1, dst_2, \dots, dst_N\}, dst_i = (frgS, Pt), i = 1, 2, \dots, N,$$
(2.16)

де *frgS* – фрагмент сигналу, який складається з 3 кардіоциклів, середній з яких містить розмічену патологію,

Pt – номер патології, *Pt* ∈ {1,2, ...,9}:

1 – норма;

2 – шлуночкова екстрасистолія;

3 – цикл з кардіостимулятором;

4 – блокада правої ніжки пучка Гіса;

5 – блокада лівої ніжки пучка Гіса;

6-передсердна екстрасистолія;

7 – вставна шлуночкова екстрасистолія;

8 – поєднання стимульованого та нормального ритму;

9-все інше.

Вхідною інформацією підходу є фрагмент ЕКГ-сигналу, отриманий з пристроїв реєстрації (електрокардіографів, холтерів тощо). ЕКГ-сигнал подається вигляді (2.1).

Варто зауважити, що інформація з пристроїв реєстрації за іншою структурою, приводиться до потрібного вигляду нескладними алгоритмічними перетвореннями.

Завдання 1 призначене для виявлення на вхідному сигналі R-зубців (див. рис. 1, б). Потреба у цьому випливає з того, що на вхід нейромережі потрібно подавати співставні фрагменти сигналів. Одним із способів такої співставності є розбиття сигналу на фрагменти, у яких по центру розміщений зубець R.

Завдання 2 призначене для класифікації патологій, які вказують на аритмії. Класифікуються фрагменти сигналу, які отримуються за інформацією про зубець R.

Завдання 3 призначене для інтерпретації отриманих результатів класифікації. Тобто рішення, прийняте моделлю глибокого навчання, пояснюється за допомогою ознак, зрозумілих лікарю.

Вихідною інформацією запропонованого підходу є класифікований ЕКГсигнал та інтерпретація прийнятого рішення при класифікації кожного кардіоциклу.

Для розв'язання наведених завдань пропонуються відповідні методи, які будуть далі розглянуті у розділі.

2.2. Метод ідентифікації R-зубців на ЕКГ-сигналах

З наведеного у розділі 1 огляду зрозуміло, що попри вражаючі результати методів виявлення R-зубців, існують недоліки, які потрібно враховувати. Для

вдосконалення існуючих підходів до виявлення R-зубців у сигналах ЕКГ був запропонований метод, схема якого зображена на рис. 2.2.



Рис. 2.2. Схема методу виявлення R-зубця в аналізі ЕКГ

Головною особливістю запропонованого підходу є використання двох вхідних сигналів – ЕКГ-сигналу та, синхронного з ним, сигналу з прогнозованим розташуванням R-зубців. Гіпотеза дослідження полягає у тому, що така інтеграція додаткового сигналу дозволить поліпшити виявлення R-зубців на ЕКГ-сигналі за рахунок особливості операції згортки, а також зробить метод більш завадостійким до артефактів сигналу.

Варто зазначити, що додавання синхронного сигналу у вхідний ЕКГ-сигнал не є новим підходом. Подібне пропонувалось у роботі [123]. У цьому дослідженні запропонована своя варіація додавання синхронного сигналу в ЕКГ-сигналі.

Для реалізації запропонованого методу, а саме – формування синхронного сигналу, використовується ключова характеристика зубця R, а саме те, що зубець R має максимальне позитивне відхилення у межах кардіоциклу.

Метод складається з трьох основних етапів, які реалізують поступове перетворення інформації:

Вхідною інформацією ϵ : 1) ЕКГ-сигнал S (2.1), який є основним джерелом інформації; 2) співрозмірна з S множина K (2.2), яка ініціалізована нульовими значеннями, в які на наступних кроках, на визначених місцях, записується можливе місцезнаходження R-зубців у серцевому ритмі.

Крок 1. Додавання множини *К*, яка відображає можливе місцезнаходження Rзубця в вхідному ЕКГ-сигналі, що допомагає моделі глибокого навчання виділяти зубці R. Крок 2. Обробка інтегрованого сигналу за моделлю глибокого навчання (CNN). ЕКГ-сигнал (S) з доданим синхронним сигналом (K) подається на вхід нейронної мережі, яка аналізує його та шукає характерні ознаки R-зубців.

Крок 3. Постобробка результатів моделі глибокого навчання для ідентифікації зубців R.

Вихідна інформація. Заповнена множина К.

Далі детально зупинимось на особливостях кожного з наведених кроків.

Відомо, що в I–II і V1–V6 відведеннях ЕКГ-сигналу характерною рисою Rзубця є найбільше позитивне відхилення сигналу на певній ділянці. Щоб сформувати додатковий синхронний сигнал для ЕКГ-сигналу застосовуються кроки, зображені на рис. 2.3.

На *кроці 1.1* з ЕКГ-сигналу береться сегмент із 260 елементів. Ця кількість елементів визначена експериментально і є достатньою для покриття кардіоциклу.

На кроці 1.2 проводиться попередня ідентифікація R-зубця, тобто визначення максимального позитивного відхилення *p* в отриманому сегменті сигналу. Виявлене максимальне відхилення перевіряється для прийняття рішення про вершину хвилі. Якщо відхилення не збільшується ліворуч і не зменшується праворуч, то знайдене відхилення не знаходиться на вершині хвилі, і процес повертається до попереднього кроку для обробки наступної частини сигналу. Якщо перевірка пройшла успішно, процес переходить до наступного кроку.

Крок 1.3 передбачає заповнення множини К знаннями. На основі ідентифікованого зубця визначається його глобальний індекс *i* в ЕКГ-сигналі S. Далі множина К заповнюється значенням 1 у діапазоні [i–20, i+20]. Цей діапазон зазвичай охоплює комплекс QRS, який включає R-зубець.

Крок 1.4 має на меті уникнути пошук нового максимального відхилення відразу після знайденого на кроці 2 відхилення р, оскільки R-зубці з'являються через певні інтервали.



Рис. 2.3. Схема Кроку 1 методу виявлення R-зубців, що формує синхронний сигнал із можливим розташуванням R-зубців

У результаті застосування наведеного кроку 1 до ЕКГ-сигналу формується синхронний сигнал, візуалізація якого наведена на рис. 2.4.



Рис. 2.4. Візуалізація накладання синхронного сигналу з можливим розташуванням зубців R (зелений графік) на вхідний ЕКГ

Далі сигнали *S* та *K* будуть разом подаватися на вхід моделі глибокого навчання для виявлення на цих сигналах R-зубців (крок 2). За результатами аналізу існуючих підходів до визначення R-зубців у ЕКГ-сигналі засобами згорткових нейронних мереж [62, 64, 69, 70] запропоновано використання encoder-decoder нейромережі, оскільки такий тип мережі є одним з найбільш підходящих для завдання виявлення R-зубців на ЕКГ-сигналі завдяки своїй здатності ефективно обробляти послідовності даних, виявляти важливі ознаки. Фінальна архітектура нейромережі наведена в таблиці 2.1.

Таблиця 2.1

Тип шару	Bvin	Buvin	Kornol	Strido	Podding	Scale factor		
тип шару	DХIД	D ИХІД	size	Struc	1 auung	Scale lactor		
Encoder								
Conv1d	2	32	3	1	1			
ReLU								
MaxPool1d			2	2				
Conv1d	32	64	3	1	1			
ReLU								
MaxPool1d			2	2				
Conv1d	64	128	3	1	1			
ReLU								
MaxPool1d			2	2				
Conv1d	128	256	3	1	1			
ReLU								
MaxPool1d			2	2				
			Decod	er				
Upsample						2		
Conv1d	256	128	3	1	1			
ReLU								
Upsample						2		
Conv1d	128	64	3	1	1			
ReLU								
Upsample						2		
Conv1d	64	32	3	1	1			
ReLU								
Upsample						2		
Conv1d	32	1	3	1	1			
ReLU								
Sigmoid								

Використана apxiteктура encoder-decoder моделі для пошуку зубців R

Вибір саме такої архітектури базувався на таких міркуваннях:

1) Encoder частина мережі поступово зменшує розмірність вхідного ЕКГсигналу, водночас виділяючи ознаки за допомогою згорткових шарів та операцій максимального об'єднання (Max Pooling). Такий поступовий процес виділення ознак дозволяє моделі захоплювати як дрібні деталі, так і більш широкі патерни в ЕКГсигналі. Враховуючи різкий і чіткий характер зубця R, можливість захоплювати дрібні та широкі патерни забезпечить більш точну ідентифікацію;

2) накладання декількох згорткових шарів дозволяє мережі «вивчити» ієрархічне подання вхідного ЕКГ-сигналу. Початкові згорткові шари фіксують базові патерни, такі як краї, тоді як більш глибокі шари вивчають більш складні особливості, такі як форми та морфологію сигналу;

3) шари MaxPooling в Encoder частині зменшують розмірність ознак (feature map), тим самим зменшуючи обчислювальну складність і знижуючи ризик перенавчання. Таке зменшення розмірності є життєво важливим для обробки та узагальнення прихованих знань про вхідний ЕКГ-сигнал;

4) шари збільшення роздільності в частині декодера мережі відновлюють сигнал до його початкової розмірності, полегшуючи локалізацію зубців R. Цей процес гарантує, що виявлені зубці правильно вирівнюються з фактичними зубцями вхідного сигналу ЕКГ, тим самим підвищуючи точність виявлення;

5) використання Sigmoid функції активації в останньому шарі мережі добре підходить для задач бінарної класифікації. Обмежуючи вихідні значення між 0 і 1, мережа розрізняє наявність (1) і відсутність (0) R-зубців у сигналі ЕКГ.

Вимірювання значень втрат під час навчання мережі пропонується за допомогою функції Binary Cross Entropy Loss (BCELoss), яка використовується для вимірювання помилки між цільовими значеннями класу та вхідними ймовірностями в задачах бінарної класифікації. В основі розрахунку помилки за допомогою BCELoss лежить така формула [124]:

$$l_i = -w_i [x_i \cdot \log y_i + (1 - x_i) \cdot \log(1 - y_i)], \qquad (2.17)$$

де x_i – фактична мітка класу для *i*-х вхідних даних. Параметр може мати значення лише 1 або 0, оскільки застосовується лише в бінарній класифікації;

y_i – ймовірність передбачена моделлю для *i*-х вхідних даних (ймовірність може набувати значення в межах від 0 до 1);

w_i – необов'язковий параметр для встановлення ваги ручного перемасштабування для входу і. Значення за замовчуванням дорівнює 1.

Переваги функції втрат BCELoss полягають у тому, що вона відображає середню розбіжність між передбаченими ймовірностями та істинними мітками. Ідеальний прогноз має втрату 0, тоді як більші значення вказують на зростаючу неточність. Ця інтуїтивна інтерпретація дозволяє легко зрозуміти, як працює модель, і відстежувати її прогрес під час навчання.

На відміну від таких показників, як точність, втрата BCELoss є неперервною функцією. Це дозволяє проводити більш плавну оптимізацію за допомогою градієнтних методів, таких як Stochastic Gradient Descent (SGD), що призводить до більш ефективних процесів навчання.

Варто зазначити, що функція втрат BCELoss є стійкою до дисбалансу класів. У випадках, коли класи даних незбалансовані, BCELoss втрати можуть бути більш стійкими, ніж альтернативи, такі як Mean Squared Error (MSE). Це пояснюється тим, що BCELoss зосереджується на мінімізації помилки для кожної окремої вибірки, незалежно від її класу.

Імплементація цієї функції широко подана в більшості бібліотек глибокого навчання, що робить її доступним засобом і дозволяє легко інтегрувати у власні рішення. Це полегшує порівняння та відтворюваність результатів у різних проєктах і дослідженнях [125, 126].

Для оптимізації в процесі навчання запропоновано використати алгоритм Adaptive Moment Estimation (Adam) [127]. Наведений алгоритм оптимізації зазвичай використовується в машинному та глибокому навчанні для навчання нейронних мереж. Він поєднує в собі ідеї двох інших популярних алгоритмів оптимізації: Root Mean Square Propagation (RMSprop) і Momentum. Основною метою Adam є надати метод адаптації швидкості навчання для кожного параметра окремо [127]. До переваг цього алгоритму відносяться: – Adam поєднує в собі переваги оптимізації за Momentum та RMSprop. RMSprop-метод допомагає оптимізатору продовжувати рух у правильному напрямку, тоді як RMSprop адаптує швидкість навчання для кожного параметра окремо на основі їхніх історичних градієнтів;

 – Adam динамічно налаштовує швидкість навчання для кожного параметра під час тренування. Ця адаптивність допомагає ефективно орієнтуватися в просторі параметрів і прискорює збіжність;

 – ефективне використання пам'яті за рахунок збереження середнього значення градієнтів та квадратів градієнтів, що дозволяє ефективно використовувати пам'ять.
 Це середнє значення використовується для оновлення параметрів моделі, зменшуючи необхідність зберігати всі минулі градієнти;

– імплементація Adam присутня в усіх широко використовуваних бібліотеках глибокого навчання [128, 129].

Далі отриманий вихід моделі глибокого навчання потрібно подати у вигляді масиву даних тієї самої розмірності, що й вхідний масив, у якому на потрібних місцях відносно вхідного масиву розташовані мітки, які відповідають R-зубцям.

З кроку 2 отримується вихід нейромережі encoder-decoder CNN, який є масивом того самого розміру, що і вхідний масив із сигналом ЕКГ. Приклад вихідних даних мережі CNN показано червоною лінією на рис. 2.5.

Крок 3 методу призначений для обробки виходу моделі CNN *P* для перетворення його в індекси, які відповідають R-зубцям вхідного сигналу. Загальну схему кроку 3 зображено на рис. 2.6.

На кроці 3.1 відбувається фільтрація вхідних даних *P* на основі заздалегідь визначеного порогу, щоби забезпечити врахування лише релевантних точок даних. Ця порогова фільтрація допомагає виключити менш значущі прогнози і зосередитися на відхиленнях, які, ймовірно, вказують на знаходження R-зубців. Експериментально, у дослідженні, цей поріг встановлено на рівні 0,1.



Рис. 2.5. Приклад вихідних даних з encoder-decoder CNN моделі для пошуку R-зубців: *a* – вихід моделі; *б* – вихід моделі, накладений на вхідний сигнал ЕКГ

Після того, як дані відфільтровані на *кроці 3.2*, алгоритм шукає наступне відхилення, що далі розглядається як можлива позиція R-зубця. Для точного індексу R-зубця, на *кроці 3.3–3.4* розглядається діапазон з 70 послідовних елементів прогнозу (еквівалентний 175 мс), починаючи зі знайденого відхилення. У вибраному діапазоні визначається значення з найвищою ймовірністю передбачення. Індекс, за яким знаходиться найбільше значення передбачення зберігається у вихідному масиві К (*крок 3.5*). Цей масив накопичує індекси всіх виявлених значущих точок протягом усього процесу.



Рис. 2.6. Схема кроку постобробки для визначення індексів R-зубців, передбачених нейромережею

Крок 3.6 пропускає елементи, які були розглянуті на попередніх кроках, щоб алгоритм повторно не обробляв ці значення. Виконання алгоритму продовжується, доки не буде досягнуто кінця даних у вхідному масиві *P*.

Після завершення алгоритму вихідна множина К містить повний список індексів, які відповідають R-зубцям ЕКГ-сигналу, що визначені моделлю CNN.

2.3. Метод класифікації аритмій на ЕКГ-сигналі

Для вдосконалення існуючих підходів до класифікації ЕКГ-сигналів (за умови класифікації патологій аритмій) запропоновано метод, схематично зображений на рис. 2.7.



Рис. 2.7. Схема методу класифікації ЕКГ-сигналу для виявлення патологій аритмій

З аналізу відомих піходів, огляд яких наведений у розділі 1, випливає, що у переважній більшості робіт, вхідним зразком для нейромережі є один кардіоцикл. Проте, для правильної ідентифікації патологій, які розглядаються, з точки зору лікаря, недостатньо враховувати один кардіоцикл для прийняття правильного рішення — потрібно мати інформацію про те, що відбувалося «до» та «після» поточного кардіоциклу. Тому запропоновано вхідний зразок-кардіоцикл доповнювати сусідніми кардіоциклами. Це є особливістю зазначеного методу і очікується, що це дозволить моделі глибокого навчання виявляти додаткові приховані залежності в ЕКГ-сигналі, що сприятиме більш якісно ідентифікувати патології, що розглядаються.

Основними елементами методу є:

– Вхідною інформацією методу є ЕКГ-сигнал та індекси зубців R, визначені у попередньому методі;

- Крок 1. Підготовка вхідних зразків ЕКГ-сигналу;

- Крок 2. Класифікація за моделлю глибокого навчання;

- Вихідна інформація. Класифікований за патологіями ЕКГ-сигнал.

Далі розглядаються особливості реалізації наведених кроків.

На кроці 1 методу відбувається процес попередньої обробки та підготовки вхідних зразків (фрагментів) для класифікації. Вхідний сигнал розбивається на фрагменти загальною довжиною 700 відліків. Запропонована довжина фрагмента була обрана емпірично таким чином, щоб фрагмент включав 3 кардіоцикли (Rзубці), а саме: попередній, поточний (як основний об'єкт класифікації) та наступний. У вхідному фрагменті сигналу поточний кардіоцикл розміщується таким чином, щоб завжди бути в центрі фрагмента. Приклади вхідних фрагментів ЕКГсигналів зображені на рис. 2.8.

На *кроці 2* методу проводиться класифікація сформованого зразка за допомогою вдосконаленої архітектури нейромережі. У роботі запропоноване вдосконалення архітектури нейромережі, наведеної у роботі [7] для схожої задачі класифікації з навчанням за тим самим датасетом, але з іншим виглядом вхідних зразків. Авторами [7] заявлені числові результати роботи за overall ассигасу оf 99.43 %. Проте класифікувались не всі наявні у зазначеному датасеті патології.



Рис. 2.8. Приклади вхідного фрагмента ЕКГ-сигналу в нормі (*a*) та з патологією (б) для класифікації СNN моделлю

Отже, виходячи з того, що запропоноване нове подання вхідного сигналу та розширена кількість патологій для отримання якісних результатів класифікації запропоновано ряд вдосконалень архітектури нейромережі.

Зважаючи на те, що подання вхідного зразка у наведеному вище вигляді, з одного боку, буде враховувати приховані залежності з трьох кардіоциклів, а з іншого – буде збільшено кількість класів для класифікації, потрібно змінити архітектуру нейромережі з врахуванням цієї особливості. Пропонується додати ще один

згортковий шар як для розширення можливості нейромережі виділяти більшу кількість характерних ознак, так і успішно класифікувати за цими ознаками більшу кількість класів. Додатковий згортковий шар сприяє дотриманню та поглибленню ієрархічного підходу до навчання мережі, коли верхні шари фокусуються на простих та загальних ознаках, тоді як нижні шари, включно з нещодавно доданим, вивчають більш складні ознаки [130]. Також додатковий шар є необхідним для підтримки обробки більшої кількості класів та збільшеного об'єму вхідних даних. Більша кількість класів та збільшений розмір вхідних даних часто містить більше ознак та варіацій сигналу, які може розпізнати додатковий згортковий шар. Оскільки пропонується розширення діапазону класів для класифікації (дев'ять замість п'яти), то є критично важливим можливість CNN розрізняти більш дрібні деталі в ЕКГсигналах. Це означає, що патології, які можуть мати схожі характеристики, можна розрізнити більш чітко завдяки такому розширеному виділенню ознак.

Виходячи з того, що додавання ще одного згорткового шару суттєво збільшать і так невелику обчислювальну складність, пропонується модифікувати архітектуру нейромережі додаванням шарів Batch Normalization після кожного згорткового шару та після першого лінійного шару. Пакетна нормалізація (Batch Normalization) – це метод, який використовується для прискорення та стабільності навчання штучних нейронних мереж шляхом нормалізації вхідних даних шарів за рахунок повторного центрування і масштабування [131]. Додавання цього шару дає можливість нормалізувати активації по кожному каналу в партії (batch), що запобігає різкому зростанню та спаданню активацій.

Наступним вдосконаленням було додавання Dropout шару. Потреба в додаванні Dropout шару після першого лінійного (fully connected, або dense) шару в CNN мережу полягає в зменшенні ризику перенавчання моделі та підвищенні її здатності до узагальнення [132]. Лінійні шари мають багато параметрів, особливо після згорткових шарів, коли кількість вихідних ознак значно зростає. Dropout шар допомагає уникнути цього, випадково вимикаючи частину нейронів під час тренування, що заважає моделі запам'ятовувати дані і змушує її навчатися більш стійким ознакам.

Виходячи із суттєвої зміни архітектури в процесі проєктування нейронної мережі класифікації патологій в ЕКГ-сигналі було проведено додаткову роботу зі знаходження оптимальних гіперпараметрів шарів нейронної мережі. Для оптимізації гіперпараметрів використовувались бібліотеки РуТогсh Lightning [133] та Optuna [134, 135]. Знаходження оптимальних значень проводилося для таких гіперпараметрів: kernel size, stride, dropout probability. У таблиці 2.2 наведено межі, в яких відбувався пошук оптимальних параметрів для наведених параметрів.

Таблиця 2.2

Межі пошуку оптимальних значень параметрів

Назва параметра	Мінімальне значення	Максимальне значення
Convolution kernel size	1	5
Convolution stride	1	3
Pool kernel size	1	5
Pool stride	1	3
Dropout probability	0.3	0.7

У таблиці 2.3 наведено фінальну архітектуру та оптимізовані гіперпараметри вдосконаленої (щодо згаданої у [15]) нейромережі. У наведеній таблиці синім кольором відмічені запропоновані додаткові шари для архітектури моделі.

Таблиця 2.3

Тип шару	Вхід	Вихід	Kernel size	Stride	Padding	Probability
			Encod	er		
Conv1d ReLU	1	64	5	3	1	
BatchNorm1d	64					
Conv1d ReLU	64	64	5	2	1	
BatchNorm1d	64					
MaxPool1d			1	2		
Conv1d	64	128	3	1	1	

Вдосконалена архітектура CNN нейромережі

F	ReLU							
Batch	nNorm1d	128		1	2			
Co F	onv1d ReLU	128	128	3	2	1		
Batch	nNorm1d	128						
C	onv1d	128	256	3	1	1		
F	ReLU							
Batch	nNorm1d	256						
Max	xPool1d			1	2			
	Classifier							
L	linear	3584	300					
F	ReLU							
Batch	nNorm1d	300						
Di	ropout						0.68	
L	linear	300	150					
F	ReLU							
L	linear	128	9					

2.4. Відповідальність використання штучного інтелекту в медицині

Штучний інтелект у медицині поступово стає важливим інструментом, який дозволяє значно покращити процеси діагностики і підтримки прийняття рішень. Однак його результати завжди мають допоміжний та рекомендаційний характер і не можуть бути остаточним висновком. Остаточне рішення залишається за медичним працівником, який використовує професійний досвід, стандарти й протоколи лікування та клінічну історію пацієнта. Такий підхід забезпечує баланс між технологічними інноваціями і відповідальністю лікаря, який завжди несе всю відповідальність за прийняте рішення. ШІ у цьому контексті виконує роль помічника, здатного прискорити аналіз складних даних і підтримати точність діагностики. Такий підхід гарантує, що жодна технологія не стане єдиним джерелом діагностики чи лікування.

Одним з ключових аспектів інтеграції ШІ в медицину є дотримання етичних принципів, таких як прозорість і відсутність упередженості. Алгоритми повинні працювати з точними, репрезентативними даними, щоб уникнути помилок. Водночас важливо, щоб лікарі розуміли механізми формування рекомендацій ШІ, оскільки це сприяє довірі до технології. У цьому контексті велике значення мають методи інтерпретації рішень, зроблені ШІ. Представлення результатів у вигляді

показників та ознак, що використовуються у медичній практиці, робить висновки ШІ зрозумілими для лікарів. Це також допомагає уникнути відчуття «чорної скрині», коли рекомендації ШІ виглядають непрозорими або складними для розуміння. До того ж, можливість отримувати прозорі й легко інтерпретовані результати підвищує ефективність діагностичних процесів і сприяє інтеграції нових технологій у клінічну практику. Також отримання зрозумілої інтерпретації результатів ШІ дає можливість робити чітке документування обстеження, що у разі виникнення юридичних питань дає можливість підтвердити правильність прийняття рішення.

2.5. Метод інтерпретації результатів класифікації патологій аритмій, отриманих за допомогою моделі глибокого навчання

Беручи до уваги, що розглядається дуже чутлива предметна область (медицина), а засоби, що пропонуються для розв'язання задачі відносяться до глибокого навчання (способи і параметри, за якими приймаються рішення є непрозорими («чорна скриня»)), виникає потреба в інтерпретації прийнятих рішень у зрозумілому для кінцевого користувача (лікаря) вигляді. Опис запропонованого методу наведений у такому вигляді:

- 1) загальна ідея методу;
- 2) способи визначення ознак, що застосовуються у медичній практиці;
- 3) відповідності між клінічними рекомендаціями та способами отримання ознак;
- 4) демонстрація роботи запропонованих методів.
- Далі детально зупинимось на зазначених етапах.

2.5.1 Загальна ідея методу

Загальна ідея запропонованого підходу полягає у спробі показати отримані за попереднім методом рішення за ознаками, які використовує лікар при діагностиці патологій на ЕКГ-сигналі. Це конкретні ознаки, які він може побачити на вхідному

сигналі (кардіоциклі) і які, певним чином, дозволять йому погодитись (чи не погодитись) з рішенням, прийнятим за моделлю глибокого навчання.

Варто зазначити, що попередня історія застосування різних методів класифікації ЕКГ-сигналу базувалась на визначенні класу патології саме за машинним навчанням, у якому вектори ознак складались у тому числі з наведених нижче ознак. Проте результати класифікації, отримані за цими ознаками, не були такими вражаючими, як класифікація за моделями глибокого навчання. Проте пропонується все ж визначати ці ознаки для розуміння лікарем, отримані за глибоким навчанням рішень. Тобто за наведеними нижче ознаками не проводиться класифікація як така, а вони використовуються для візуалізації прийнятих за глибоким навчанням рішень у спосіб, зрозумілий лікарю.

При прийнятті рішення про ту чи іншу патологію на ЕКГ-сигналі він розглядає ряд показників (ознак), які вказують на неї. Для кожної патології такі ознаки наперед визначені. Вони можуть всі мати місце, чи деякі можуть бути чи не бути – кінцеве рішення приймає лікар. Без втрати загальності далі розглядається схема запропонованого методу.

На рис. 2.9 наведено схему запропонованого методу для однієї ознаки. Для інших ознак схема має аналогічний вигляд. Далі розглядаються етапи запропонованого методу, зображені на рис. 2.9.

Вхідною інформацією методу є фрагмент ЕКГ-сигналу з класифікованим кардіоциклом у вигляді, в якому він подавався на вхід нейромережевого класифікатора (рис. 2.8) та клас патології, визначений цим же класифікатором.

На кроці 1 здійснюється емпіричне визначення фрагмента вхідного сигналу (зони уваги), який потенційно містить інформацію про ознаку патології. Вибір зони уваги базується на теоретичних положеннях та практичному досвіді лікарякардіолога, які стосуються специфічних особливостей аналізованої ознаки. Враховуючи псевдоперіодичний характер сигналу ЕКГ, можливо локалізувати межі зони уваги, використовуючи експертні знання лікаря-кардіолога про часові інтервали, у межах яких виникає ознака патології. Наприклад, при визначенні шлуночкової екстрасистолії розглядається ознака відсутності зубця *P*. Зоною уваги в такому випадку визначається фрагмент сигналу, що охоплює інтервал після закінчення зубця *T* попереднього кардіоциклу до комплексу QRS поточного циклу.

Метою *кроку 2* є вибір засобу (способу), за допомогою якого лікарю буде повідомлено про наявність чи відсутність ознаки на фрагменті сигналу. Вибір засобу відбувається за послідовним аналізом інформації за наступними кроками. Виконання завершується як тільки на певному кроці вдається інтерпретувати результат класифікації:

– крок 2.1 – відповідає за формування результату інтерпретації за допомогою формул або статистичних показників, зрозумілих лікарю;



Рис. 2.9. Схема методу для визначення способу,

за яким буде проведено інтерпретацію класифікованого ЕКГ

– крок 2.2 – формує інтерпретацію за візуальним поданням (різними способами) фрагменту сигналу порівняно з аналогічними фрагментами навчальної

вибірки (розміченими за двома класами: 1) патологія, що розглядається; 2) норма та всі інші патології);

– крок 2.3 – формує інтерпретацію засобами візуальної аналітики (Principal Component Analysis (PCA) [136], Multidimensional Scaling (MDS) [137], T-Distributed Stochastic Neighbor Embedding (t-SNE) [138] тощо;

– крок 2.4 – формує результат інтерпретації за допомогою моделей machine learning;

– крок 2.5 – формує результат інтерпретації за допомогою моделей deep learning;

– крок 2.6 – формує результат інтерпретації за допомогою інших методів, якими може бути доповнений запропонований підхід.

Вихідною інформацією буде висновок про присутність або відсутність розглянутої ознаки у вхідному класифікованому ЕКГ-сигналі.

2.5.2 Способи визначення ознак, що застосовуються у медичній практиці

Для реалізації *кроку 2* методу для переліку патологій, що розглядаються, пропонуються кроки (кроки 2.1–2.5 запропонованого методу) для визначення способів виявлення ознак, що застосовуються у медичній практиці, на вхідному ЕКГ-сигналі.

Для ознак, які лікар бачить на кардіоциклі (рис. 1.2) потрібно вміти визначати його основні елементи, а саме зубці, інтервали та періоди. Наявність зубця R відома ще після першого етапу обробки ЕКГ-сигналу. Базуючись на цій інформації з використанням функціоналу, інтегрованого в пакет Neurokit2 [139], пропонується пошук інших елементів карідоциклу. Пакет Neurokit2 є продовженням для Neurokit1 та забезпечує легкий доступ до процедур обробки біосигналів.

Існують ознаки, отримати які можна за допомогою статистичних показників або формул (*крок 2.1*). Наприклад, наявність компенсаторної паузи розраховується за формулами або наявність/відсутність зубця Р можна перевірити за допомогою вже згаданого пакета Neurokit2 [139]. Іншим способом є відображення на графіку кардіоциклів усіх ЕКГ-сигналів з навчальної вибірки для двох груп класів (*крок 2.2*) та класифікований кардіоцикл, який розглядається для інтерпретації. Наприклад, на рис. 2.10, *a*, зображено першу групу з ЕКГ-сигналами класу «Норма», а друга група з ЕКГ-сигналами класів, яким характерні дефекти на рівні зубця Р (шлуночкова екстрасистолія). Додатково поверх кожної групи виводиться кардіоцикл, на якому потрібно інтерпретувати ознаку. На отриманих графіках емпірично встановлюється зону уваги (фрагмент сигналу), який відповідає за ознаку, яка розглядається (на графіку зона уваги виділена прямокутником).



Рис. 2.10. Візуалізація порівняння чіткості розділення у визначеній зоні інтересу для двох класів ЕКГ: *а* – випадки без чіткого розділення;

б – випадки з помітними патернами розділення в зоні інтересу

Як показано на рис. 2.10, *а*, просте візуальне порівняння у цьому випадку не спрацьовує. Червона і синя області мають повний перетин. Тобто потрібно йти далі по кроках методу для пошуку засобу, який вирішить цю задачу. В іншому випадку

(рис. 2.10, б) перетину немає, можна впевнитись, що ознака на кардіоциклі, який аналізується (зелений графік), відноситься до ідентифікованого класу.

Якщо ознаки за попереднім візуальним аналізом мають у зоні уваги суттєвий перетин, варто скористатися *кроком 2.3*. На цьому кроці фрагменти сигналів, які знаходяться у зоні уваги (виділені прямокутником на рис. 2.10), подаються у вигляді векторів на засоби пониження розмірності (засоби візуальної аналітики): Principal Component Analysis (PCA) [136], Multidimensional Scaling (MDS) [137], T-Distributed Stochastic Neighbor Embedding (t-SNE) [138] тощо. Результат цього подання зображено на рис. 2.11.



Рис. 2.11. Результат застосування РСА до фрагментів ЕКГ в межах зони інтересу

Можна впевнитися (частково чи остаточно), що для даних ЕКГ, отриманих із зони уваги, характерне певне групування, але відсутня чітка роздільність між групами.

При існуванні певного групування з роздільністю між групами (можливо навіть з більшою ніж 2 кількістю груп) можна застосувати методи машинного навчання (для векторів, за якими робилась візуальна аналітика) для отримання класифікатора (крок 2.4). Застосування SVM з різними ядрами може розв'язати цю задачу.

У випадку повного перетину між утвореними групами в результаті застосування методів візуальної аналітики або невдалого застосування методів машинного навчання на *кроці 2.5* пропонується застосування методів глибокого навчання для інтерпретації наявності ознаки на ЕКГ-сигналі. Як і для машинного навчання, вхідною інформацією для методів глибокого навчання виступає частина ЕКГ-сигналу, отримана з визначеної зони уваги для ознаки.

Для класифікації за моделлю глибокого навчання пропонується використання нейромережі для бінарної класифікації з архітектурою, наведеною у таблиці 2.4.

Таблиця 2.4

Тип шару	Вхід	Вихід	Kernel	Stride	Padding			
			Size					
Encoder								
Conv1d	1	32	5	1	2			
ReLU								
MaxPool1d			2	2	0			
Conv1d	32	64	3	1	2			
ReLU								
Conv1d	64	128	3	1	2			
ReLU								
MaxPool1d			2	2	0			
		Classi	fier					
Linear	3584	64						
ReLU								
Linear	64	1						
Sigmoid								

Архітектура і параметри нейромережі для інтерпретації ознак

Крок 2.6 передбачений для розширення запропонованого підходу іншими способами інтерпретації ознак на ЕКГ-сигналі.

2.5.3 Відповідності між клінічними рекомендаціями та способами отримання ознак

Для методу інтепретації було запропоновано спосіб формування висновку про наявність або відсутність кожної ознаки розглянутих патологій. Далі наведено співвідношення між ознаками і способом формування висновку.

1. Нормальний ЕКГ-сигнал (кардіоцикл).

1.1.Наявність всіх елементів кардіоциклу.

Інтеграція клінічних рекомендацій: відповідно до клінічних стандартів кардіоцикл повинен містити всі обов'язкові зубці, комплекси та сегменти.

Спосіб формування висновку: використовували інструментарій NeuroKit2 для виявлення зубців на ЕКГ, на основі чого відбувається формування висновку про наявність як зубців, так і сегментів, комплексів.

1.2.QRS комплекс нерозширений і недеформований.

Інтеграція клінічних рекомендацій: у клінічних рекомендаціях зазначено, що в нормі тривалість QRS комплексу складає 120 мс.

Спосіб вимірювання: використовується згорткова нейронна мережа, навчена класифікувати QRS комплекси в нормі.

1.3.Зубець Р перед кожним QRS-комплексом.

Інтеграція клінічних рекомендацій: відповідно до стандартів перед кожним QRS комплексом повинен бути зубець Р.

Спосіб вимірювання: використовували інструментарій NeuroKit2 для виявлення зубців на ЕКГ. На основі отриманих результатів відбувається формування висновку про наявність зубця Р перед QRS.

2. Шлуночкова екстрасистолія.

2.1. Відсутність зубця Р.

Інтеграція клінічних рекомендацій: відповідно до клінічних стандартів відсутність зубця Р, що передує комплексу QRS, свідчить про шлуночкову екстрасистолію.

Спосіб формування висновку: використовували інструментарій NeuroKit2 для виявлення наявності зубця Р, забезпечуючи дотримання рекомендацій щодо точної ідентифікації зубця Р.

2.2. Розширений та деформований комплекс QRS.

Інтеграція клінічних рекомендацій: у клінічних рекомендаціях зазначено, що при шлуночковій екстрасистолії спостерігаються розширені QRS (≥120 мс).

Способи вимірювання: використовується згорткова нейронна мережа, навчена на даних, анотованих згідно з цими рекомендаціями, для виявлення розширених QRS.
2.3. Повна компенсаторна пауза.

Інтеграція клінічних рекомендацій: повна компенсаторна пауза після шлуночкової екстрасистолії є критерієм, коли сума інтервалів RR «до» і «після» екстрасистолії дорівнює подвоєному нормальному інтервалу RR.

Спосіб вимірювання: відповідно до клінічних рекомендацій для визначення присутності компенсаторної паузи можна застосувати формулу:

$$RR_{prev} + RR_{next} \approx 2 \times RR_n$$

де RR_{prev} – інтервал між R-зубцями до екстрасистолії; RR_{next} – інтервал між Rзубцями після екстрасистолії; RR_n – інтервал між зубцями в нормі.

3. Блокада правої ніжки пучка Гіса.

3.1. Перевірка на розширений та деформованих QRS.

Інтеграція клінічних рекомендацій: у клінічних рекомендаціях зазначено, що при блокаді правої ніжки пучка Гіса спостерігаються розширені QRS-комплекси (≥120 мс). Також присутня деформація, яка називається RsR.

Спосіб формування висновку: використовується згорткова нейронна мережа, навчена на даних, анотованих згідно з цими рекомендаціями, для виявлення розширених та деформованих QRS-комплексів;

3.2. Наявність депресії ST.

Інтеграція клінічних рекомендацій: відповідно до клінічних рекомендацій зазначено, що при блокаді правої ніжки пучка Гіса відбувається поява косонизхідної депресії ST.

Спосіб формування висновку: використовується згорткова нейронна мережа, навчена класифікувати наявність або відсутність депресії ST.

4. Блокада лівої ніжки пучка Гіса.

4.1. Перевірка на розширений та деформованих QRS.

Інтеграція клінічних рекомендацій: у клінічних рекомендаціях зазначено, що при блокаді правої ніжки пучка Гіса спостерігаються розширені (≥120 мс) та деформовані QRS-комплекси.

Спосіб формування висновку: використовується згорткова нейронна мережа, навчена для підтвердження або спростування ознаки про розширений та деформований QRS-комплекси.

4.2. Дискордантні зміни ST-Т відносно комплексу QRS.

Інтеграція клінічних рекомендацій: дискордантними змінами для ST-T є депресія або елевація сегмента ST в протилежну сторону від основного вектора (зубця R або S).

Спосіб формування висновку: використовується згорткова нейронна мережа, навчена класифікувати наявність або відсутність дискордантних змін ST-T;

4.3. Продовжений ЧВВ.

Інтеграція клінічних рекомендацій: відображає час проведення збудження від ендокардіальної до епікардіальної поверхні ділянки шлуночка, над яким розміщений електрод цього відведення. Для визначення береться період від початку комплексу QRS (зубців Q або R) до максимального відхилення комплексу QRS (як правило, вершини зубця R).

Спосіб формування висновку: відбувається розрахунок тривалості ЧВВ, базуючись на інформації про межі зубців, отримані за допомогою NeuroKit2.

5. Вставна екстрасистолія.

5.1. Кардіоцикл з характерними ознаками шлуночкової екстрасистолії.

Інтеграція клінічних рекомендацій: відповідно до клінічних рекомендацій вставна шлучнокова екстрасистолія має ознаки звичайної шлуночкової екстрасистолії, за виключенням відсутності компенсаторної паузи.

Спосіб формування висновку: використовується розглянутий вище спосіб формування висновку для шлуночкової екстрасистолії.

5.2. Відсутність компенсаторної паузи.

Інтеграція клінічних рекомендацій: відповідно до клінічних рекомендацій компенсаторна пауза не характерна для цієї ознаки.

Спосіб формування висновку: розрахунок інтервалів RR за допомогою NeuroKit2 та застосування формули $RR_{prev} + RR_{next} \neq 2 \times RR_n$ для підтвердження компенсаторної паузи.

5.3. Сусідні кардіоцикли в нормі.

Інтеграція клінічних рекомендацій: у клінічних рекомендаціях зазначено, що вставна екстрасистолія виникає між двома кардіоциклами, які є в нормі. Відповідно до клінічних рекомендацій компенсаторна пауза не характерна для цієї ознаки.

Спосіб формування висновку: базуючись на інформації про класифікацію інших кардіоциклів, відбувається визначення того, чи сусідні (відносно кардіоциклу з екстрасистолією) кардіоцикли відповідають класу «Норма».

2.5.4 Демонстрація роботи запропонованих методів

Вхідними даними для демонстрації роботи запропонованих методів є ЕКГсигнал *S*, що дозволяє застосувати до нього запропоновані методи. Приклад графіка вхідного ЕКГ-сигналу зображений на рис. 2.12.



Рис. 2.12. Візуалізація отриманого 1D-сигналу ЕКГ

Першим методом обробки застосується метод пошуку R-зубців. Відповідно до кроків цього методу відбувається формування синхронного сигналу, який відображає можливе розташування зубців R у вхідному ЕКГ-сигналі. На рис. 2.13 наведено приклад візуалізації накладання сформованих знань на ЕКГ-сигнал.



Рис. 2.13. Візуалізація накладання сформованих знань на вхідний ЕКГ-сигнал

ЕКГ-сигнал та сформовані знання передаються на encoder-decoder нейронної мережі для визначення індексів R-зубців. Обробивши вхідні дані, нейромережа повертає ймовірності, які перетворюються на індекси R-зубців. На рис. 2.14 червоними кругами позначено знайдені R-зубці для вхідного ЕКГ-сигналу.



Рис. 2.14. Візуалізація накладання

Далі дані, а саме ЕКГ-сигнали та індекси знайдених R-зубців, обробляються за допомогою методу для класифікації патологій на сигналі ЕКГ. Базуючись на індексах знайдених R-зубців, відбувається формування фрагментів ЕКГ-сигналу, які будуть класифікуватися з допомогою CNN-мережі. Приклад сформованих фрагментів показано на рис. 2.15.



Рис. 2.15. Візуалізація сформованих фрагментів для класифікації

Сформовані фрагменти передаються на нейронну мережу для класифікації на наявність патології. Відповідно до розробленого методу підтримуються класифікації ЕКГ на 9 класів, серед яких один клас – це норма. Результатом застосування CNN-мережі є визначений клас для кожного фрагмента ЕКГ-сигналу. Визначені класи для фрагментів ЕКГ об'єднуються в один перелік так, щоб відповідати всьому вхідному сигналу ЕКГ. На рис. 2.16 показано візуалізацію ЕКГ-сигналу з визначеними класами на рівні кожного кардіоциклу. В цьому випадку позначка «N» відповідає класу «Норма», а позначка «V» – класу «Шлуночкова екстрасистолія».



Рис. 2.16. Візуалізація визначених класів кожного кардіоциклу вхідного ЕКГ-сигналу

Останнім етапом обробки ЕКГ-сигналу є інтерпретація отриманих результатів класифікації. Застосування методу інтерпретації розглядатиметься для патології «Шлуночкова екстрасистолія» визначена для середнього кардіоциклу, який зображений на рис. 2.17.



Рис. 2.17. Кардіоцикл з шлуночковою екстрасистолією

Для цієї патології характерні такі ознаки:

- відсутній Р-зубець
- розширений та деформований QRS комплекс;
- наявність компенсаторної паузи.

Розглянемо ознаку «Відсутній Р-зубець». Відповідно до клінічних стандартів, відсутність зубця Р, що передує комплексу QRS, свідчить про шлуночкову екстрасистолію. Відповідно до запропонованого методу відбувається визначення зони уваги для цієї ознаки. Візуалізація визначеної ознаки зображена на рис. 2.18.



Рис. 2.18. Зона уваги для ознаки «Відсутній Р зубець»

Далі відбувається визначення підходу, за яким буде підтверджено або спростовано присутність цієї ознаки. Висновок про дану ознаку формується за допомогою використання інструменту NeuroKit2, що дозволяє визначити наявність зубців ЕКГ-сигналу, в тому числі Р-зубця.

Далі розглядатиметься ознака «Розширений та деформований QRS-комплекс». Як і для попередньої ознаки, відбувається визначення частини сигналу, яка відповідає зоні уваги для поточної патології.



Рис. 2.19. Зона уваги для ознаки «Відсутній Р-зубець»

Для пояснення поточної ознаки не можна застосувати формулу чи статистичні показники. Відповідно до кроків методу інтерпретації відбувається порівняння кардіоциклу визначеної патології та норми. Результат порівняння зображено на рис. 2.22, де розглянутий сигнал ЕКГ зображений зеленим кольором.



Рис. 2.20. Візуальне порівняння ЕКГ-сигналу із сигналами класу «Норма» (*a*) та сигналами класу «Шлуночкова екстрасистолія» (б)

Як показано на рис. 2.22, ЕКГ-сигнал в зоні уваги не має роздільності, тому далі відбувається крок із застосуванням візуальної аналітики з використанням даних ЕКГ, отриманих із зони уваги, результат якого зображено на рис. 2.21.



Рис. 2.21. Застосування візуальної аналітики

Отримавши результат візуальної аналітики, можна впевнитися, що для даних ЕКГ, отриманих із зони уваги, характерне певне групування, але відсутня чітка роздільність між групами. В такому випадку застосування методів глибокого навчання буде більш ефективним, ніж методи машинного навчання для підтвердження наявності ознаки. Тому частина сигналу, отримана із зони уваги, передається на обробку CNN мережі бінарної класифікації, яка підтверджує або спростовує наявність або відсутність ознаки.

Для ознаки «Наявність компенсаторної паузи» зона уваги має вигляд, зображений на рис. 2.22.

Рис. 2.22. Зона уваги для ознаки «Наявність компенсаторна пауза»

Варто зазначити, що компенсаторна пауза після шлуночкової екстрасистолії є критерієм, коли сума інтервалів «до» RR_{prev} і «після» RR_{next} екстрасистолії дорівнює подвоєному нормальному інтервалу RR_n . Тому для визначення присутності компенсаторної паузи застосовується формула $RR_{prev} + RR_{next} \approx 2 \times RR_n$.

2.6. Висновки до розділу 2

У цьому розділі було досліджено та сформовано теоретичні основи для підходу класифікації патологій на ЕКГ-сигналі за допомогою моделей глибокого навчання із подальшою інтерпретацією результатів за ознаками, що використовуються в медичній практиці. Розглянуто припущення, ідеї та модель процесу, що були покладені в основу розроблених та вдосконалених методів.

Розроблено новий метод ідентифікації R-зубців у ЕКГ-сигналі. Особливістю цього методу є додавання у вхідний ЕКГ-сигнал синхронного сигналу з можливим розташуванням R-зубців. Процес включає три основні етапи: 1) формування та додавання синхронного сигналу з можливим розташуванням зубців R; 2) обробка цієї інформації за допомогою CNN-моделі; 3) постобробка результатів encoderdecoder моделі для виявлення R-зубців.

Удосконалено метод класифікації патологій аритмій за ЕКГ-сигналом. До запропонованих змін входить зміна вхідних даних для класифікації таким чином, щоб використовувати тріаду кардіоциклів, що включає попередній, поточний і наступний кардіоцикли. Такий підхід формування вхідних даних дає можливість враховувати приховані залежності між кардіоциклами, що покращує точність класифікації патологій. Сформований вхідний фрагмент для класифікації обробляється CNN-мережею з вдосконаленою архітектурою, що включає додаткові convolutional, normalization, dropout шари та оптимізацію гіперпараметрів.

Вперше розроблено метод інтерпретації результатів класифікації патологій аритмій, який є новою спробою інтерпретувати результати класифікацій за моделлю глибокого навчання до потреб лікарів шляхом інтерпретації рішень моделей з використанням ознак, що використовуються в медичній практиці. Основна ідея полягає у виділенні специфічних ознак на ЕКГ-сигналі, які лікар традиційно використовує для діагностики, та їхньому інтегруванні у процес інтерпретації результатів класифікації. Тобто, на відміну від інших засобів інтерпретації класифікації, запропонований метод не просто намагається знайти фрагмент ЕКГ, який був важливий при класифікації, а використовує лікарські ознаки як засіб візуалізації та інтерпретації, що допомагає лікарю перевіряти та аналізувати рішення, прийняті моделлю глибокого навчання.

Запропонований метод інтерпретації реалізується через послідовність кроків, кожен з яких передбачає використання різних засобів аналізу – від математичних формул і статистичних показників до сучасних методів візуальної аналітики та моделей глибокого навчання. Запропонований метод також підтримує інтеграцію додаткових аналітичних засобів, що забезпечує його універсальність та масштабованість. Вихідною інформацією методу є чітке формулювання висновків щодо наявності або відсутності розглянутої ознаки на класифікованому ЕКГ-сигналі.

Окрему увагу приділено розгляду відповідальності використання штучного інтелекту в медицині. Ключовим є те, що отримані за допомогою штучного інтелекту результати, завжди мають допоміжний та рекомендаційний характер і не можуть бути остаточним висновком. Остаточне рішення щодо діагностики залишається за медичним працівником, який спирається на свій досвід, затверджені стандарти та протоколи лікування, а також клінічну історію пацієнта.

У підсумку, запропонований підхід допомагає інтегрувати можливості сучасних технологій глибокого навчання з традиційними методами медичної діагностики. Це не лише спрощує процес прийняття рішень, але й підвищує довіру лікарів до використання автоматизованих систем у клінічній практиці.

РОЗДІЛ 3.

ІНФОРМАЦІЙНА СИСТЕМА ВИЯВЛЕННЯ ПАТОЛОГІЙ АРИТМІЙ ЗА ЕКГ-СИГНАЛОМ

У розділі розглядається проєктування та практична реалізація інформаційної системи (IC), в основу якої покладено запропонований в розділі 2 підхід. Під час проєктування системи розглянуто клієнт-серверну архітектуру та переваги її застосування для наведеної IC. Також цей розділ включає інформацію про вимоги до ЕКГ-сигналу, отриманого від кардіографа, а також розглядається використання ЕКГ-сигналу холтерного типу для обробки запропонованою системою.

3.1. Функціональні вимоги до інформаційної системи

При проєктуванні IC виділено такі основні модулі: користувацької взаємодії, попередньої обробки вхідних, ідентифікації R-зубців, класифікації патологій аритмій, інтерпретації класифікованих патологій аритмій.

Модуль користувацької взаємодії призначений для введення даних для аналізу та виведення результатів. Вимогами до модуля є:

– надання користувачу можливості вибору конкретного ЕКГ-сигналу для подальшої обробки;

– відображення отриманих результатів класифікації у вигляді графічного представлення класифікованих кардіоциклів ЕКГ;

- надання можливості змінювати масштаб, прокручувати та аналізувати сигнал;

– відображення ознак, які вдалося та не вдалося підтвердити для кожної визначеної патології аритмії;

– візуальне підсвічування зубця або сегмента ЕКГ, для якого проводилась перевірка наявності ознаки.

Модуль попередньої обробки вхідних даних призначений для приведення вхідного ЕКГ сигналу до єдиного формату, що дозволить коректну подальшу обробку та аналіз. Вимогами до модуля є: - обробка запитів від клієнтської частини IC;

- зміна частоти дискретизації сигналу до підтримуваного значення;

 – розбиття сигналу на частини підтримуваної довжини для обробки ЕКГ холтерного типу;

– нормалізація сигналу.

Модуль ідентифікації R-зубців є важливим етапом аналізу ЕКГ для класифікації кожного кардіоциклу. Вимогами до модуля є:

- формування синхронного сигналу з можливим розташуванням R-зубців;

– пошук індексів R-зубців з використанням ЕКГ-сигналу і сигналу з можливим розташуванням R-зубців;

– збереження результатів пошуку індексів R-зубців для використання в наступних модулях.

Модуль класифікації патологій аритмій аналізує виділені фрагменти ЕКГсигналу та визначає їхню відповідність класу патологій аритмій:

– розділення ЕКГ на фрагменти (тріади кардіоциклів), підтримувані класифікатором на основі інформації про знайдені R-зубці;

 визначення класу патологій аритмій для кожної виділеного фрагмента з використанням попередньо навченої згорткової нейронної мережі;

 – формування висновку про класифікацію кардіоциклів всього ЕКГ на основі класифікованих фрагментів.

Модуль інтерпретації класифікованих патологій аритмій формує інтерпретації, для роз'яснення отриманих результатів, базуючись на ознаках, що використовуються у медичній практиці:

– формування статистики про класифікований ЕКГ, що включає визначення R-R інтервалів, сегментів та зубців;

 визначення присутності відповідних ознак на класифікованому ЕКГ, що відповідають визначеному класу патології аритмії;

– формування результату інтерпретації визначених патологій аритмій.

3.2. Вимоги до апаратного забезпечення

Для ефективного навчання глибоких нейронних мереж необхідно використовувати продуктивне апаратне забезпечення, яке здатне забезпечити швидку обробку великих обсягів даних та оптимізувати роботу алгоритмів. Основними компонентами, що впливають на продуктивність, є центральний процесор (CPU), графічний процесор (GPU), оперативна пам'ять (RAM) та система зберігання даних (SSD).

Центральний процесор. Навчання глибоких нейронних мереж зазвичай більше залежить від графічного процесора, оскільки основні обчислення виконуються саме на ньому. Однак центральний процесор відіграє важливу роль у загальній продуктивності системи, особливо під час підготовки та завантаження даних, попередньої обробки, координації процесу навчання, а також взаємодії з GPU. Рекомендованим буде використання багатоядерного процесору (наприклад, Inter i5, Inter i7 тощо), оскільки використання сучасних процесорів з високою тактовою частотою і більшою кількістю ядер може покращити можливості обробки даних програмою.

Графічний процесор. При навчанні глибоких нейронних мереж використання графічного процесора значно підвищує ефективність обчислень, скорочуючи час обробки даних та оптимізації моделі. Завдяки можливості паралельного виконання великої кількості операцій, відеокарти значно швидше справляються 3 обчисленнями порівняно з центральним процесором. Рекомендований обсяг відеопам'яті для навчання нейромереж починається від 2 ГБ. Наприклад, графічні процесори NVIDIA GeForce GTX GTX 1650 або більш продуктивні аналоги забезпечують достатню потужність для базового навчання моделей машинного навчання.

Оперативна пам'ять. Для стабільної роботи програмного забезпечення рекомендується використовувати не менше 16 ГБ оперативної пам'яті. Використання такого об'єму оперативної пам'яті обумовлено потребою в навчанні та тестуванні нейронної мережі, коли необхідно завантажувати велику кількість даних. За інших умов з меншою кількістю оперативної пам'яті потрібно буде коригувати навчання на використання партій даних меншого розміру, проте потрібно враховувати те, що зменшення розміру партій даних збільшить час навчання мережі.

Накопичувач даних. Рекомендується використовувати SSD-накопичувач з мінімальним об'ємом пам'яті 256 ГБ. Накопичувачі такого типу працюють швидше за звичайні жорсткі диски, що допомагає зменшити час обробки даних при навчанні нейронної мережі та покращить загальну продуктивність системи.

Однак слід зазначити, що вказані обчислювальні потужності потрібні насамперед для етапу навчання та тестування нейронної мережі, який є найбільш ресурсомістким процесом. Після завершення навчання та отримання оптимізованої моделі її використання у практичних задачах, зокрема в клінічних умовах, потребує значно менше ресурсів. Це дозволяє застосовувати модель навіть на стандартних робочих станціях.

Для додаткового зниження вимог до апаратного забезпечення в умовах обмежених ресурсів, наприклад, у невеликих клініках, можна використовувати клієнт-серверний підхід. У цьому підході обчислення виконуються на сервері з потужним обладнанням, тоді як локальний клієнт здійснює лише передачу даних, отримання та візуалізацію результатів. Такий підхід дозволяє зменшити навантаження на локальні системи та забезпечити доступ до високоточної аналітики навіть за мінімальних локальних ресурсів. Таким чином, запропонована технологія є універсальною та придатною до впровадження в різних умовах, включаючи обмежені обчислювальні можливості клінік.

У цій роботі з метою практичної реалізації ІС для проведення експериментів використовувалась система з оперативною системою Windows 10, оснащена процесором Intel(R) Core(TM) i7-9750H з 6 фізичними ядрами та базовою тактовою частотою 2,60 ГГц. Процесор має 12 МБ кеш-пам'яті третього рівня (L3). Для оптимальної роботи використовувалась 16 ГБ оперативної пам'яті. Для апаратного прискорення використано відеокарту NVIDIA GeForce GTX 1650 Max-Q з 4 ГБ відеопам'яті GDDR5, що забезпечує достатню продуктивність для обчислювальних експериментів та обробки великих наборів даних. Всі експерименти виконано на операційній системі Windows 10 з використанням стеку програмного забезпечення

Python v.3.9.18, PyTorch v.2.0.0, Scikit-learn v.1.3.0, PyTorch Lightning v.2.1.3, Optuna v.3.5.0. Наведений перелік характеристик використаного апаратного забезпечення відповідає наведеним вище рекомендаціям.

3.3. Проєктування архітектури інформаційної системи

IC для класифікації аритмій за сигналом ЕКГ та інтерпретації результатів класифікації базується на основі підходу, запропонованого у п. 2.1. Відповідно до процедур аналізу ЕКГ-сигналів користувачами такої системи є медичні фахівці, що займаються діагностуванням аритмій за результатами електрокардіографії, а саме лікарі загальної практики та кардіологи. Вони використовують результати аналізу ЕКГ для виявлення патологій серцевої діяльності, оцінки стану пацієнта та прийняття рішень щодо подальшого лікування. Для спрощення термінології, далі в роботі кінцевий користувач інформаційної системи матиме назву «лікар».

При проєктуванні IC використовується клієнт-серверна архітектура (рис. 3.1), яка забезпечує розподіл обов'язків між клієнтською частиною для взаємодії з користувачем і серверною частиною для обробки даних. Вибір такого типу архітектури дає ряд переваг, серед яких можна виділити такі:

 розширення та зміна логіки обробки даних, класифікації, інтерпретації виконуються на сервері, що знижує потребу в оновленнях на кожному клієнтському пристрої;

– архітектура дозволяє легко розширювати функціонал, додаючи нові можливості на сервері без значних змін у клієнтському додатку;

 – ресурсозатратна обробка даних відбувається на сервері, що дозволяє клієнтському додатку залишатись ефективним при незначних обчислювальних ресурсах пристрою, де встановлений клієнтський застосунок;

 можливість інтеграції з різними типами клієнтів, наприклад, вебдодатками або мобільними пристроями, завдяки універсальності серверної частини.



Рис. 3.1.Клієнт-серверна архітектура

Клієнтська частина системи відповідає за графічну взаємодію користувача з IC. З допомогою клієнтської частини лікар завантажує ЕКГ-сигнал, отриманий з кардіографа, надсилає на обробку серверній частині та відображає результат. Очікується, що ЕКГ-сигнал отриманий з кардіографа, який відповідає IEC 60601-2-25 стандарту, прийнятий в Україні [140], та регулює вимоги до безпеки і роботи кардіографів. Відповідно до цього стандарту, пристрій записує ЕКГ відповідно до таких характеристик:

- 12 стандартних відведень з синхронним зняттям;

- ширина частотного діапазону 0,05–150 Гц;
- амплітудний діапазон сигналу 0,5 5 мВ;
- фільтрування мережевого шуму;
- фільтрування дрейфу ізолінії;

- фільтрування електроміографії.

З метою передачі обраного ЕКГ з клієнтської частини на серверну для проведення розрахунків використовується JSON, приклад якого наведено в (3.1).

```
"signal": [0.55, 0.52, ..., 0.48, 0.51],
"name": "Пацієнт 1", (3.1)
"frequency": 360
```

```
}
```

де signal – одновимірний масив з амплітудами ЕКГ-сигналу; name – назва сигналу, який передається; frequency – частота дискретизації.

На серверній частині IC обробка переданого ЕКГ-сигналу починається з модуля попередньої обробки вхідних даних. Оскільки сигнали ЕКГ можуть мати

різну дискретизацію, то першим кроком модуля є приведення частоти дискретизації сигналу до підтримуваного значення IC. Таким значенням дискретизації є 400 Гц.

Після вирівнювання частоти дискретизації відбувається розбиття ЕКГ-сигналу на фрагменти фіксованої довжини, що дозволяє ІС обробляти як звичайні ЕКГсигнали, так і сигнали ЕКГ холтерного типу. Останнім кроком модуля попередньої обробки є нормалізація фрагментів ЕКГ в межах [0, 1]. Кожний сформованих ЕКГ фрагмент обробляється за допомогою наступних модулів.



Рис. 3.2. Узагальнена схема ІС

Після модуля попередньої обробки вхідних даних, ЕКГ-сигнал потрапляє до модуля пошуку R-зубців. Модуль пошуку R-зубців базується на запропонованому методі ідентифікації R-зубців, який розглянуто в п. 2.2. Проміжними даними IC після модуля є ЕКГ-сигнали та індекси визначених R-зубців. Модель проміжних даних зображена на рис. 3.3:

RPeakDetectionResult
+ ecg_signal
+ r_peaks

Рис. 3.3. Проміжна модель даних після модуля пошуку зубців R

Далі ЕКГ-сигнал та ідентифіковані зубці R обробляються за допомогою модуля класифікації патологій аритмій. Перші два кроки цього модуля відповідають запропонованому в п. 2.3 методу, де на першому кроці вхідний сигнал розбивається на фрагменти для класифікації з використанням позицій R-зубців як орієнтирів, а на другому кроці відбувається безпосередня класифікація. Більш детальний опис згаданих кроків наведено в п. 2.3.

Оскільки класифікація на наявність патологій аритмій не відбувається одразу для всього вхідного ЕКГ, а для виділених фрагментів, то на третьому кроці модуля здійснюється постобробка результатів класифікації, яка включає в себе агрегацію результатів класифікації, що формує цілісну картину класифікації всього вхідного ЕКГ-сигналу.

Останнім модулем в ланцюжку обробки ЕКГ-сигналу є модель інтерпретації класифікованого ЕКГ на патології аритмій. На першому кроці відбувається визначення основних параметрів сигналу, таких як зубці, інтервали тощо. Визначені параметри використовуються в подальшому в цьому модулі для формування інтерпретації. На другому кроці відбувається формування інтерпретації класифікованих патологій аритмій. Відповідно до запропонованого в п. 2.5.2 методу та проведеного дослідження було визначено способи формування інтерпретації для

кожної підтримуваної ознаки патології аритмій. Схема основних класів для формування інтерпретації наведена на рис. 3.4.



Рис. 3.4. UML-схема основних класів модуля формування інтерпретації

На останньому кроці модуля відбувається агрегація всіх результатів інтерпретації та формування фінального звіту, який повертається у форматі JSON для клієнтської частини.

Додатково побудовано високорівневу схему послідовностей інформаційної системи, яка зображена на рис. 3.5.

Побудована схема послідовностей інформаційної системи демонструє взаємодію між різними компонентами системи під час обробки ЕКГ-сигналу, починаючи з моменту отримання сигналу від користувача і закінчуючи інтерпретацією результатів.



Рис. 3.5. Діаграми послідовності інформаційної системи

Далі буде розглянуто реалізовану експериментальну IC відповідно до наведеного проєктування.

3.4. Практична реалізація інформаційної системи

Цей розділ описує експериментальну інформаційну систему, яка об'єднує в собі реалізацію трьох запропонованих методів для перевірки та демонстрації їх роботи.

Серверна частина інформаційної системи реалізована з використанням монолітної архітектури. Для реалізації серверної частини обрана мова програмування Python, яка є одним з найкращих інструментів для задач, пов'язаних з аналізом даних, машинним навчанням і, зокрема, побудовою нейронних мереж. Python має низку важливих переваг, які роблять його незамінним у розробці програмного забезпечення, що використовує нейронні мережі. Однією з основних переваг є широка екосистема бібліотек та інструментів. Для роботи з нейромережами в межах заданої серверної частини основними бібліотеками були: PyTorch, scikit-learn, NumPy.

Серверний API для комунікації з клієнтом реалізований з використанням пакета FastApi. Для взаємодії з серверною частиною реалізовано набір кінцевих точок API, який дозволяє здійснювати передачу даних для аналізу, отримувати результати

класифікації та виконувати інші операції, що базуються на обчисленнях нейронних мереж.

В основі модуля класифікації покладено метод, який запропонований в цій роботі. Модуль отримає ЕКГ-сигнал від серверного АРІ для проведення класифікація на патології. Оскільки для початку класифікації важливо визначити ключові точки сигналу, такі як зубці R, то ЕКГ-сигнал передається далі до модуля, відповідального за пошук зубців R, який реалізує запропонований в цій роботі метод. Після того, як R-зубці визначені, а ЕКГ-сигнал підготовлений, модуль класифікації обробляє дані та виконує класифікацію на наявність патологій. Результати класифікації повертаються до серверного АРІ, який передає їх клієнту.

Далі на основі класифікованих даних клієнт може зробити запит на отримання інтерпретації класифікованого ЕКГ. Класифікований сигнал надсилається до серверного API, який передає його до модуля, відповідального за інтерпретацію. Цей модуль формує інтерпретацію класифікованого ЕКГ-сигналу відповідно до запропонованого методу інтерпретації. Після завершення інтерпретації результат повертається до серверного API, який передає його клієнту.

Клієнтська частина інформаційної системи реалізована з використанням С#, WPF та архітектурою MVVM. Цей додаток забезпечує графічний інтерфейс, що дозволяє взаємодіяти з інформаційною системою, обирати ЕКГ-сигнал для класифікації, переглядати результати класифікації, а також за потреби отримувати інтерпретацію для класифікованого ЕКГ. Відповідно до показаної діаграми на рис. 3.5, клієнтський додаток надсилає до серверної частини для обробки обраний користувачем ЕКГ-сигнал і після завершення аналізу отримує результати, які відображаються у зрозумілому для користувачеві вигляді.



Рис. 3.6. Стартова сторінка інформаційної системи

На стартовій сторінці додатка для користувача дається можливість обрати ЕКГсигнал для подальшого аналізу (рис. 3.6). Обраний ЕКГ-сигнал надсилається на серверну частину інформаційної системи для обробки і класифікації за допомогою запропонованих в цій роботі методів. По завершенню процесу обробки та аналізу ЕКГ-сигналу, користувач отримує результати у вигляді окремого вікна (рис. 3.7), у якому відображається інформація про кожен окремий класифікований кардіоцикл, що дає можливість детально оцінити ЕКГ-сигнал.



Рис. 3.7. Результат аналізу та класифікації ЕКГ-сигналу

Над кожним класифікованим кардіоциклом у візуалізації результатів буде відображено спеціальне позначення, яке відповідає визначеному класу цього кардіоциклу. Повний перелік позначень, що використовуються у системі, наведено в таблиці 3.1, де кожен клас супроводжується відповідним описом для спрощення інтерпретації результатів.

Таблиця 3.1

Позначення	Оригінальна назва класу	Переклад
Ν	Normal beat	Норма
V	Premature ventricular	Шлуночкова екстрасистолія
	contraction	
/	Paced beat	Стимульований кардіоцикл
R	Right bundle branch block beat	Блокада правої ніжки пучка
		Гіса
L	Left bundle branch block beat	Блокада лівої ніжки пучка
		Гіса
А	Atrial premature beat	Передсердна екстрасистолія
F	Fusion of ventricular and normal	Вставна шлуночкова
	beat	екстрасистолія
F	Fusion of paced and normal beat	Злиття шлуночкового і
		нормального кардіоциклу
NA	Others	Інше

Позначення та назва підтримуваних класів класифікації

В правій частині кожного класифікованого ЕКГ-сигналу є кнопка, після натискання на яку формується інтерпретація результатів класифікації. На рис. 3.8 показано приклад сформованої інтерпретації для обраного класифікованого ЕКГсигналу. У верхній частині вікна відображається класифікований ЕКГ-сигнал, для якого сформовано інтерпретацію. Для користувача доступна можливість збільшувати та зменшувати масштаб відображеного ЕКГ-сигналу, що дозволяє краще роздивитися сигнал лікарю.



Рис. 3.8. Приклад сформованого результату інтерпретації

Під графіком ЕКГ-сигналу відображається список з класифікованими патологіями та ознаками, за яким інтерпретується результат класифікації. Інтерпретація класифікації формується на основі ознак патології, якими користується лікар відповідної медичної практики. Якщо ознака підтверджується, то поруч з назвою ознаки відображається зелена мітка. У разі відсутності підтвердження ознаки буде показано червоний хрест.





Рис. 3.9. Відображення підтвердженої ознаки на відповідному фрагменті ЕКГсигналу: *a* – ілюструє приклад, коли ознакою є певний зубець сигналу; *б* – ілюструє приклад, коли ознака відноситься до частини сигналу (комплексу, сегмента)

Доступна можливість візуально перевірити, для якої саме частини ЕКГ-сигналу була підтверджена або спростована певна ознака. Для цього потрібно поставити мітку навпроти ознаки, яка цікавить.

Після вибору відповідна ділянка ЕКГ-сигналу буде підсвічена, що дозволяє легко ідентифікувати її на графіку (рис. 3.9). Така функція допомагає користувачу чітко зрозуміти взаємозв'язок між патологіями та ознаками для конкретного фрагмента ЕКГ-сигналу, покращуючи зручність і зрозумілість інтерпретації результатів.

3.5. Висновки до розділу 3

У цьому розділі описано основні аспекти проєктування та функціонування IC для класифікації аритмій за сигналом ЕКГ та інтерпретації результатів класифікації за ознаками, що використовуються в медичній практиці. Основою для розробки системи стали методи, запропоновані у розділі 2, що забезпечує комплексну обробку сигналів ЕКГ, зокрема їх попередню обробку, пошук R-зубців, класифікацію та інтерпретацію класифікованих патологій.

При проєктуванні IC було розглянуто функціональні вимоги до системи. На основі сформованих вимог було виділено 5 модулі, а саме: модуль користувацької взаємодії, попередньої обробки вхідних, ідентифікації R-зубців, класифікації патологій аритмій, інтерпретації класифікованих патологій аритмій.

Проєктування ІС реалізоване на базі клієнт-серверної архітектури, яка розподілити обов'язки між клієнтською дозволяє оптимально частиною, орієнтованою на взаємодію з користувачем, та серверною частиною, відповідальною обчислювальні Використання такої архітектури за процеси. забезпечує масштабованість, адаптивність та мінімізацію ресурсозатрат на клієнтських пристроях.

Під час проєктування IC було визначено, що кінцевими користувачами є лікарі загальної практики та кардіологи, для яких спроєктована інформаційна система несе рекомендаційний характер. Також розглянуто вимоги до ЕКГ-сигналу як вхідних даних IC, а також використання ЕКГ холтерного типу.

Відповідно до сформованих вимог та архітектури IC було розглянуто практичну реалізовано такої IC.

РОЗДІЛ 4.

ЕКСПЕРИМЕНТАЛЬНЕ ПІДТВЕРДЖЕННЯ ВАЛІДНОСТІ ЗАПРОПОНОВАНИХ МЕТОДІВ

У цьому розділі наведено результати експериментальних досліджень, проведених для перевірки валідності запропонованих методів обробки та аналізу електрокардіографічних ЕКГ-сигналів. Для забезпечення репрезентативності результатів використовувалося кілька широко відомих та якісних датасетів, які дозволяють охопити різні аспекти та особливості ЕКГ-сигналів.

Розділ складається з кількох підпунктів, що детально описують різні етапи валідації. Спочатку подано характеристику використаних баз даних, що є основою для навчання та тестування нейронних мереж. Далі описано процедури валідації методу знаходження зубців R та класифікації ЕКГ на наявність патологій, характерних для аритмії. Окремо розглянуто експеримент з клінічними даними, який має на меті перевірити застосування запропонованих методів з використанням ЕКГ-сигналів від реальних пацієнтів.

У розділі також розглянуто застосування методу інтерпретації класифікованих ЕКГ-сигналів на основі ознак, якими користується лікар. Наприкінці розділу представлено обмеження запропонованих підходів.

4.1. Набори даних для оцінювання запропонованих методів

Для навчання нейромережі використовувались такі набори даних:

- 1) база даних про аритмію MIT-BIH Arrhythmia Database (MIT-BIH) [141];
- 2) база даних QT Database (QT) [142];
- 3) база даних China Physiological Signal Challenge-2020 (CPSC-2020) [143];
- 4) база даних університету Глазго (UoG) [144].

База даних МІТ-ВІН – найбільш поширена база для вирішення задачі класифікації аритмії в ЕКГ-сигналі засобами ML та DL. База була створена в результат спільної роботи Beth Israel Hospital (зараз Beth Israel Deaconess Medical

Center) та МІТ. Зазначена база стала першим загальнодоступним набором тестових матеріалів для оцінки детекторів аритмії. База містить 48 записів ЕКГ тривалістю приблизно 30 хвилин, які зібрані в ході клінічних досліджень. У дослідженні взяли участь 25 чоловіків у віці від 32 до 89 років і 22 жінки у віці від 23 до 89 років. (Записи 201 і 202 належать одному і тому самому чоловікові). Частота сигналів складає 360 Гц. До кожного запису ЕКГ-сигналу є анотація, в якій описаний час виникнення певної патології, яка може вказувати на аритмію.

База даних QT – розроблена для оцінки алгоритмів, які виявляють межі фрагментів ЕКГ-сигналу. База містить 105 уривків двоканальних холтерівських записів ЕКГ. Довжина уривків складає 15 хвилин. База даних включає анотацію до сигналів ЕКГ, яка позначає зубці та межі зубців P, QRS, T та (за наявності) U.

База даних CPSC-2020 – сформована для проведення 3rd China Physiological Signal Challenge 2020, метою якого було заохотити розробку алгоритмів для пошуку передчасного шлуночкового скорочення і суправентрикулярного передчасного скорочення. Сигнали для бази даних були зібрані за допомогою переносного ЕКГ-пристрою з частотою дискретизації 400 Гц. База містить 10 записів ЕКГ в одному відведенні, зібраних у пацієнтів з аритмією. Тривалість запису складає приблизно 24 години.

База даних UoG – високоточна база даних, сформована в University of Glasgow, що містить ЕКГ з анотованими зубцями R, записаними та знятими в реалістичних умовах з 25 осіб. Запис ЕКГ відбувався протягом двох хвилин під час виконання людьми 5 різних вправ: сидіння, контрольна робота з математики на планшеті, ходіння на біговій доріжці, біг на біговій доріжці, використання ручного велосипеда. Частота дискретизації становила 250 Гц.

4.2. Методика проведення експериментів

Валідація методу знаходження R-зубців на ЕКГ-сигналі відбувається за такими кроками:

1) формування загального набору ЕКГ сигналів на основі МІТ-ВІН, QT, CPSC-2020, UoG бази даних;

2) вирівнювання частоти дискретизації сигналів до одного значення;

3) розбиття великих сигналів на менші підтримуваної довжини;

4) нормалізація амплітуд сигналів;

5) формування 7 випадкових розбиттів на тренувальні та тестові набори даних на основі ЕКГ-сигналів з МІТ-ВІН, QT, CPSC-2020 баз даних;

6) формування окремого тестового набору на основі UoG бази даних;

7) додавання синхронних сигналів з можливим розташуванням R-зубців до кожного ЕКГ-сигналу з начальної та тестової вибірки;

8) навчання моделі encoder-decode з використанням сформованих тренувальних наборів;

9) тестування і розрахунок статичних показників навченої моделі ідентифікації R-зубців з використанням навчальних та тестових наборів, сформованих з MIT-BIH, QT, CPSC-2020, UoG;

10) тестування і розрахунок статичних показників навченої моделі ідентифікації R-зубців з використанням тестового набору на основі UoG.

Валідація методу класифікації патологій аритмій на ЕКГ-сигналі відбувається за такими кроками:

1) формування набору даних з тріад кардіоциклів для класифікації патологій аритмій на ЕКГ-сигналі; використовуються дані з МІТ-ВІН; вважається, що на даному етапі сигнали мають очікувану дискретизацію та нормалізовані;

2) формування 7 випадкових розбиттів на тренувальні та тестові набори даних, які складаються із сформованих тріад кардіоциклів;

3) навчання загорткової нейронної мережі із запропонованої архітектурою;

4) тестування і розрахунок статичних показників навченої моделі класифікації аритмій з використанням навчальних та тестових наборів сформованих тріад кардіоциклів на основі МІТ-ВІН.

Валідація методу інтерпретації класифікованих патологій аритмій на ЕКГсигналі відбувається за такими кроками:

1) визначення патологій, на основі яких буде проводитися валідація методу інтерпретації;

2) визначення ознак, що використовуються в медичній практиці для визначення патологій аритмій;

3) вибір способу підтвердження присутності або відсутності ознаки на класифікованому фрагменті ЕКГ відповідно до запропонованого методу інтерпретації;

4) візуалізація та перевірка сформованих висновків про інтерпретацію класифікованого ЕКГ.

4.3. Результати досліджень методу знаходження R-зубців на ЕКГ-сигналі

Над наведеними вище наборами даних була проведена передобробка, що враховує специфіку задачі, яка розглядається. Зокрема, було видалено зразки, у яких відсутня чітка розмітка R-зубців. Наявність таких зразків у наборах даних негативно вплине на точність навчання та тестування нейронної мережі, оскільки вони створюють додаткові труднощі у визначенні цільових характеристик сигналу.

З набору МІТ-ВІН [141] виключені сигнали (наприклад, *Id*=108 та 207), анотації яких не відповідають вершині зубця. Приклад такого сигналу зображено на рис. 4.1, *а*. Ймовірно, це результат механічної помилки під час створення анотації, оскільки головною метою анотації в цій базі є позначення типу патології в кардіоциклі, а не точну позицію зубця R.

Сигнали, що належать набору даних QT [142], також були відфільтровані. З набору було видалено сигнали, що містять неповний (нестандартний) сигнал ЕКГ. Приклад такого сигналу наведено на рис. 4.1, *б*.



Рис. 4.1. Приклади сумнівних зразків ЕКГ-сигналів, які було виключено із баз даних: *а* – неправильно розмічений R-зубець; *б* – нестандартний сигнал/відведення

Враховуючи те, що сигнали у розглянутих базах даних мають різну частоту, були проведені додаткові перетворення, щоб усі сигнали мали частоту 400 Гц. Сигнали з цих наборів даних були сегментовані на фрагменти довжиною 8000 для їх подальшого використання як вхідних сигналів для нейронної мережі. Фрагменти, отримані з наборів даних 1–3, були розділені на набори для навчання та тестування у співвідношенні 80/20, відповідно.

З набору даних UoG [144] створено окремий незалежний тестовий набір сигналів. Тестовий набір включав фрагменти сигналу, записані з відведення II під час такої діяльності пацієнтів: сидіння, ходьба та математиматичний тест.

У таблиці 4.1 наведена кількість фрагментів ЕКГ-сигналів, що входять до навчального та тестового наборів.

Для навчання мережі було використано 80 % набору даних, сформованого з баз даних MIT-BIH Arrhythmia, QT i CPSC-2020.

Перший етап навчання відбувся за 45 епох зі значенням швидкості навчання в Adam – 0,001. На цьому етапі було досягнуто значення втрати 0,000821.

Назва вибірки	База даних	Кількість фрагментів сигналу
Навчальна вибірка	MIT-BIH	3312
	QT	2484
	CPSC 2020	33195
Тестова вибірка	MIT-BIH	828
	QT	712
	CPSC 2020	8299
Незалежний тестова вибірка	ECG Database – UoG	438

Розподіл фрагментів ЕКГ між різними наборами даних

На другому етапі навчання проводилося протягом 15 епох зі швидкістю навчання 0,0001, що призвело до значення втрати 0,000580. Загальний час тренування склав 82 хвилини.



Рис. 4.2. Криві втрат, отримані на навчальній та валідаційній вибірці під час навчання моделі для пошуку зубців R

В результаті навчання мережі було побудовано графік кривих функцій втрат, які розраховані на навчальній та валідаційній вибірці. Побудований графік зображено на рис. 4.2, де ось абсцис відповідає за номер епохи навчання, а ось

Таблиця 4.1

ординат – величину втрат. В свою чергу, синя крива вказує на точність класифікації для навчального набору даних, тоді як сіра пунктирна крива зображує результати, отримані на основі валідаційного набору. В нашому випадку обидві криві втрат досягають низьких показників втрат і практично збігаються, що вказує на те, що розроблена модель нейромережі була ефективно навчена і вдалось уникнути перенавчання (overfitting).

Для отримання статистичних показників якості класифікації, використовувались 7 варіантів випадкового розбиття наборів даних на навчальний і тренувальний набори. При розрахунку статистичних показників використовується похибка в ±25 мс, тобто загальне вікно похибки складає 100 мс. В таблиці 4.2 наведені статистичні показники, розраховані з використанням тестового набору створеного на основі MIT-BIH Arrhythmia.

Таблиця 4.2

Показ-			Випадкові розбиття						C3	CB
ник		1	2	3	4	5	6	7	CJ	СБ
Accuracy	Навч.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
	Тест.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
Precision	Навч.	0.994	0.994	0.994	0.995	0.994	0.992	0.994	0.994	0.001
	Тест.	0.993	0.992	0.991	0.992	0.993	0.992	0.992	0.992	0.001
Recall	Навч.	0.991	0.991	0.991	0.992	0.991	0.987	0.991	0.991	0.002
	Тест.	0.987	0.986	0.985	0.988	0.987	0.986	0.987	0.987	0.001
F1	Навч.	0.992	0.992	0.993	0.994	0.992	0.989	0.992	0.992	0.002
	Тест.	0.989	0.989	0.988	0.990	0.990	0.989	0.989	0.989	0.001

Значення статистичних показників, отримані за набором даних МІТ

Колонки 1–7 містять значення статистичних показників Accuracy, Precision, Recall, F1, отримані для кожного випадкового розбиття набору даних МІТ на навчальну та тестову вибірки. Колонка C3 містить середні значення цих показників, розраховані для всіх випадкових розбиттів. Колонка CB відображає середнє відхилення значень статистичних показників, що характеризує їхню варіабельність між розбиттями.

У колонках 1–7 наведено значення статистичних показників Accuracy, Precision, Recall, F1, отримані для кожного випадкового розбиття набору даних МІТ на навчальну і тестову вибірки. В колонці СЗ наведено середні значення показників для всіх випадкових розбиттів. В свою чергу СВ наведено середнє відхилення значень статистичних показників.

Такий самий набір статистичних показників було розраховано з використанням тестового набору даних, сформованого з бази даних QT. Результуючі показники наведено в таблиці 4.3.

Таблиця 4.3

Показ-			Випадкові розбиття						C3	CB
ник		1	2	3	4	5	6	7		CD
Accuracy	Навч.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
	Тест.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
Precision	Навч.	0.988	0.988	0.987	0.987	0.987	0.985	0.988	0.987	0.001
	Тест.	0.979	0.981	0.980	0.984	0.978	0.979	0.977	0.980	0.002
Recall	Навч.	0.989	0.988	0.988	0.988	0.987	0.985	0.988	0.988	0.001
	Тест.	0.978	0.981	0.978	0.994	0.976	0.979	0.978	0.981	0.006
F1	Навч.	0.988	0.988	0.987	0.987	0.987	0.985	0.988	0.987	0.001
	Тест.	0.978	0.98	0.983	0.985	0.977	0.98	0.977	0.980	0.003

Значення статистичних показників, отримані за набором даних QT

Колонки 1–7 містять значення статистичних показників Accuracy, Precision, Recall, F1, отримані для кожного випадкового розбиття набору даних QT на навчальну та тестову вибірки. Колонка C3 містить середні значення цих показників, розраховані для всіх випадкових розбиттів. Колонка CB відображає середнє відхилення значень статистичних показників, що характеризує їхню варіабельність між розбиттями. Також статистичні показники було розраховано для тестового набору, сформованого з CPSC-2020 бази даних. Результати розрахунків наведено в таблиці 4.4.

Таблиця 4.4

Показ-			Випадкові розбиття						C3	CB
ник		1	2	3	4	5	6	7		CD
Accuracy	Навч.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
	Тест.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
Precision	Навч.	0.987	0.988	0.988	0.990	0.987	0.986	0.987	0.988	0.001
	Тест.	0.986	0.986	0.986	0.988	0.985	0.985	0.985	0.986	0.001
Recall	Навч.	0.996	0.996	0.996	0.996	0.996	0.995	0.996	0.996	0.000
	Тест.	0.994	0.994	0.994	0.994	0.994	0.995	0.994	0.994	0.000
F1	Навч.	0.991	0.992	0.992	0.993	0.991	0.990	0.991	0.991	0.001
	Тест.	0.990	0.989	0.990	0.990	0.989	0.989	0.989	0.989	0.001

Значення статистичних показників, отримані за набором даних CPSC-2020

Колонки 1–7 містять значення статистичних показників Accuracy, Precision, Recall, F1, отримані для кожного випадкового розбиття набору даних CPSC-2020 на навчальну та тестову вибірки. Колонка C3 містить середні значення цих показників, розраховані для всіх випадкових розбиттів. Колонка CB відображає середнє відхилення значень статистичних показників, що характеризує їхню варіабельність між розбиттями.

Значення Accuracy як для навчальних, так і для тестових наборів даних для всіх випадкових розбивок є високими, із середнім значенням близько 99,9 % для кожного набору даних. Стандартні відхилення мінімальні, що свідчить про стабільну продуктивність незалежно від розбиття набору даних. Це дає можливість зробити висновок, що модель добре узагальнює і правильно класифікує більшість випадків. Враховуючи, що точність близька до 100 %, цю модель можна вважати високоефективною для поставленої задачі. *Precision* на навчальних і тестових наборах даних також залишається високою, із середніми значеннями близькими до 99,8–99,9 % для всіх наборів даних. Невелике стандартне відхилення додатково підтверджує надійність моделі в правильному визначенні позитивних випадків без значної кількості хибних спрацьовувань. Це дуже важливо для задач, де ціна помилкових спрацьовувань є високою, що свідчить про те, що модель є не тільки точною, але й вибірковою у своїх позитивних класифікаціях.

Recall на тестових наборах даних постійно перевищує 98 %, а середній показник становить 99,1–99,2 %. Це свідчить про те, що модель ефективно охоплює майже всі релевантні випадки. Мале стандартне відхилення значень підкреслює стабільність моделі та її постійну здатність виявляти істинно позитивні результати при різних розбиттях набору даних.

Показник F1, який балансує між Precision та Recall, залишається високим для всіх наборів даних і становить у середньому 98,8–98,9 % на тестових наборах даних. Низьке стандартне відхилення вказує на те, що баланс між Precision та Recall є стабільним для різних випадкових розбивок. Така узгодженість свідчить про те, що модель зберігає свою продуктивність навіть при роботі з різноманітними даними, що робить її надійним інструментом для виконання завдань.

Аналіз статистичних показників для всіх наборів даних показує, що запропонована модель encoder-decoder забезпечує надійну та достовірну класифікацію. Мінімальне відхилення результатів на різних розбиттях вказує на те, що продуктивність моделі не залежить від конкретних даних, які використовуються, що підкреслює її стабільність та можливість узагальнювати.

Додатково проведено тестування на незалежній тестовій вибірці, сформованій на основі бази даних ECG Database – UoG. Отримані статистичні результати наведені в таблиці 4.5.
Таблиця 4.5

Показ-		Випадкові розбиття							CB
ник	1	2	3	4	5	6	7		CD
Accuracy	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
Precision	0.981	0.982	0.990	0.990	0.977	0.974	0.989	0.983	0.007
Recall	0.885	0.900	0.912	0.922	0.904	0.874	0.910	0.901	0.017
F1	0.910	0.923	0.933	0.942	0.926	0.900	0.930	0.923	0.014

Значення статистичних показників, отримані за набором даних ECG Database – UoG

Колонки 1–7 містять значення статистичних показників Accuracy, Precision, Recall, F1, отримані для кожного випадкового розбиття набору даних ECG Database – UoG на навчальну та тестову вибірки. Колонка C3 містить середні значення цих показників, розраховані для всіх випадкових розбиттів. Колонка CB відображає середнє відхилення значень статистичних показників, що характеризує їхню варіабельність між розбиттями.

Аналізуючи наведенні дані та порівнюючи їх з попередньо наведеними результатами, можна зробити такі висновки:

- *Accuracy* залишається стабільно високою в обох випадках, що вказує на те, що модель може добре узагальнювати;

- *Precision* дещо знизилася на незалежному наборі даних, що вказує на те, що хоча модель і залишається точною, проте вона стикається з більш складними завданнями класифікації;

- показник *Recall* знизився, що свідчить про те, що модель є менш чутливою до істиннопозитивних результатів для заданого набору даних. З цього можна зробити висновок про те, що цей набір даних містить сигнали ЕКГ з характеристиками, які або відсутні, або мінімально присутні в наборі для навчання;

- показник *F1* також знизився, що відображає вплив зменшення показника Recall на загальний баланс продуктивності моделі.

У таблиці 4.6 наведено отримані статистичні показники порівняно з відомими підходами, розглянутими у розділі 1, з використанням однакових тестових наборів даних. Жирним шрифтом виділено найвищі показники.

Таблиця 4.6

Порівняння статистичних показників запропонованого методу із відомими методами із використанням різних баз даних ЕКГ (MIT, QT, CPSC-2020, UoG)

Набір даних	Πίδχίδ	Accuracy	Precision	Recall	F1 Score
MIT	NeuroKit2 [139]	0,9997	0,9644	0,9340	0,9490
MIT	Rodrigues et al. [145]	0,9992	0,8322	0,9491	0,8868
MIT	Koka et al. [146]	0,9992	0,8938	0,8699	0,8817
MIT	Zahid et al. [62]	0,9999	0,9905	0,9858	0,9893
MIT	Our	0,9999	0,9921	0,9872	0,9890
QT	NeuroKit2 [139]	0,9997	0,9655	0,9410	0,9531
QT	Rodrigues et al. [145]	0,9991	0,7824	0,9427	0,8551
QT	Koka et al. [146]	0,9993	0,8866	0,8767	0,8816
QT	Zahid et al. [62]	0,9999	0,9789	0,9778	0,9783
QT	Our	0,9999	0,9803	0,9818	0,9819
CPSC-2020	NeuroKit2	0,9997	0,9514	0,9514	0,9514
CPSC-2020	Rodrigues et al. [145]	0,9989	0,7763	0,9212	0,8426
CPSC-2020	Koka et al. [146]	0,9995	0,9232	0,8972	0,9100
CPSC-2020	Zahid et al. [62]	0,9999	0,9855	0,9927	0,9891
CPSC-2020	Our	0,9999	0,9862	0,9943	0,9897
UoG	NeuroKit2 [139]	0,9998	0,9932	0,9596	0,9761
UoG	Rodrigues et al. [145]	0,9996	0,9083	0,9990	0,9515
UoG	Koka et al. [146]	0,9994	0,9194	0,8968	0,9080
UoG	Zahid et al. [62]	0,9995	0,9838	0,8666	0,9215
UoG	Our	0,9996	0,9831	0,9010	0,9239

Аналіз Ассигасу таблиці 4.6 показує, що запропонований підхід та Zahid et al. є найкращими в 3 із 4 баз даних, часто досягаючи результату 0,9999. Вони дещо випереджають інші, демонструючи вищий рівень виявлення R-зубців. NeuroKit2 також демонструє високу точність і кращий результат на UoG тестовому наборі даних.

Показник Precision ще більше підкреслює надійність запропонованого методу, особливо в базах даних МІТ, QT та CPSC-2020. Такий результат свідчить про те, що запропонований метод має високий відсоток істиннопозитивних прогнозів. NeuroKit2 є найкращим в обробці результатів в базі даних UoG, де його оцінка становить 0,9932.

Щодо Recall, то як і для Precision, запропонований метод показав найкращі результати на тестових наборах даних МІТ, QT та CPSC-2020. Rodrigues et al. I перевершує інших у базі даних UoG з майже ідеальним 0.9990 Recall значенням.

Показник F1, який є середнім гармонійним значенням Precision та Recall, демонструє збалансовану продуктивність у дослідженнях. Метод Zahid et al показав найкращі результати для набору даних МІТ. Для тестових наборів даних QT та CPSC-2020 найкращі результати показав запропонований метод. На тестовому наборі UoG найкращі показники показав NeuroKit2.

4.4. Результати досліджень методу класифікації патологій аритмій на ЕКГ-сигналі

Для навчання мережі було використано ті самі 70/80/90 % даних з бази даних MIT-BIH Arrhythmia [141], що і в попередньому пункті. В таблиці 4.7 наведено перелік класів, які було обрано для класифікації, а також кількість зразків за кожним класом. Графічно розподіл кількості зразків за класами патологій наведено на діаграмі (рис. 4.4).

N⁰	I	Клас	Кількість
1	Normal beat	Норма	65992
2	Premature ventricular contraction	Шлуночкова екстрасистолія	5949
3	Paced beat	Цикл з кардіостимулятором	6031
4	Right bundle branch block beat	Блокада правої ніжки пучка Гіса	6530
5	Left bundle branch block beat	Блокада лівої ніжки пучка Гіса	5978
6	Atrial premature beat	Передсердна екстрасистолія	2162
7	Fusion of ventricular and normal beat	Вставна шлуночкова екстрасистолія	722
8	Fusion of paced and normal beat	Поєднання стимульованого та нормального ритму	833
9	Others	Все інше	389

Розподіл обраних класів для класифікації

Навчання нейромережі відбувалось з використанням оптимізатора Adam [127] в 2 етапи. На першому етапі навчання відбувалось із швидкістю навчання 0,001, що дало змогу досягти значення втрати 0.024269–0.019391. На другому етапі навчання відбувається із швидкістю 0,0001, що привело до значення втрати 0.00746–0.004003. Загальна кількість епох навчання становила 17.



Рис. 4.3. Діаграма розподілу кількості зразків за класами патологій

На рис. 4.4 зображені приклади графіків співвідношення між training & validation loss (рис. 4.4, a) та співвідношення між training & validation accuracy (рис. 4.4, δ).



Рис. 4.4. Криві точності (б) та втрат (а), отриманих під час навчання за 18 епох моделі класифікації патологій на ЕКГ-сигналі

На графіку співвідношення функції втрат (рис. 4.4, *a*) ось абсцис відповідає за номер епохи навчання, а ось ординат – величину втрат. В свою чергу, синя крива відображає функцію втрат для навчального набору даних, тоді як помаранчева крива показує функцію втрат для валідаційного набору. На графіку видно, що на початкових етапах навчання функція втрат швидко знижується як для навчальної, так і для валідаційної вибірок, що свідчить про ефективне навчання моделі. Далі обидві криві стабілізуються та досягають низьких показників втрат і практично співпадають, що свідчить про збіг результатів на обох вибірках. Це вказує на те, що вдалося уникнути перенавчання (overfitting).

На рис. 4.4, *б*, зображено графік зміни точності на навчальній та валідаційній вибірках в процесі навчання моделі. Ось абсцис відповідає за номер епохи, а ось ординат – за точність. Синя крива показує точність класифікації для навчального набору даних, тоді як помаранчева крива відображає результати на валідаційній вибірці. На початкових етапах точність швидко зростає, досягаючи понад 95 % після перших кількох епох. Після цього обидві криві стабілізуються на рівні майже 100 %, що свідчить про високу якість класифікації та добру здатність моделі до узагальнення.

Як і для методу пошуку R-зубців, перевірка методу класифікації патологій відбувалась за допомогою 7, випадковим чином отриманих, навчальних і тестових вибірок. В таблиці 4.8 наведено середні статистичні показники та їх середні відхилення, отримані для навчальної вибірки.

Таблиця 4.8

Клас	Precision		Recall		F1-score	
	C3	CB	C3	CB	C3	CB
1	1	0	1	0	1	0
2	0.999	0.004	0.999	0.004	1	0
3	1	0	1	0	1	0
4	1	0	1	0	1	0

Статистичні показники класифікації ЕКГ для 9 підтримуваних класів на основі навчальної вибірки

5	1	0	1	0	1	0
6	0.999	0.004	1	0	1	0
7	0.949	0.013	0.963	0.016	0.957	0.005
8	1	0	0.997	0.005	1	0
9	0.993	0.005	0.997	0.005	0.994	0.005

Колонки Precision, Recall та F1 відображають середні значення (C3) та середнє відхилення (CB) відповідних статистичних показників, отриманих для кожного підтриманого класу із 7, випадковим чином отриманих, навчальних вибірок.

При перевірці методу за допомогою 7, випадковим чином отриманих, тестових вибірок було проведено аналіз матриці невідповідності. На рис. 4.5 наведено приклад матриці, отриманої з однієї з семи тестових вибірок.

	12994	6	0	0	0	14	3	0	7
~ -	- 4	986	0	0	0	0	5	0	1
ო -	0	0	1067	0	0	0	0	2	0
4 -	0	0	0	1414	0	0	0	0	1
- د	0	0	0	0	1300	0	0	0	0
9 -	- 19	0	0	1	0	387	0	0	2
~ -	. 7	4	0	0	0	0	73	0	0
φ-	- 1	0	8	0	0	0	0	151	0
ი -	. 9	1	0	3	0	1	1	3	69
	1	2	3	4	5	6	ż	8	9

Рис. 4.5. Матриця сплутувань класифікації ЕКГ

У наведеній матриці невідповідностей діагональні елементи представляють правильно класифіковані екземпляри відповідних класів, що означає точні прогнози.

Більшість елементів матриці зосереджено вздовж діагоналі, що свідчить про високу точність класифікації для більшості екземплярів ЕКГ.

З наведеної матриці видно, що недіагональних елементів дуже мало, за винятком першого рядка і першого стовпчика. Вони відповідають за клас «Норма» ритму, а такий результат пов'язаний з великою кількістю екземплярів, присутніх у класі «Норма». Також було проведено аналіз частини випадків з помилковою класифікацією. Так, серед випадків неправильної класифікації було помічено випадки, коли класифікатор класифікував правильно, але неправильною була розмітка в базі. Приклад таких сигналів показано на рис. 4.6. На рис. 4.6, *a*, показано фрагмент ЕКГ, який розмічений в базі даних як «Норма», проте був класифікований і дійсно відноситься до класу «Передсердна екстрасистолія». В свою чергу, на рис. 4.6, δ , зображено фрагмент ЕКГ-сигналу, який розмічений як «Вставна екстрасистолія», але класифікований і відноситься до класу «Норма». Ці приклади і висновки були узгоджені з лікарем кардіологом.



Рис. 4.6. Приклади сигналів з некоректною розміткою в базі

Продовжуючи розглядати приклад з помилками класифікації для класів «Норма» та «Передсердна екстрасистолія» варто зазначити, що якщо класифікатор відносить «Передсердну екстрасистолія» помилково до «Норми», це може спричинити неправильне діагностування, адже передсердні екстрасистолії можуть бути маркером серйозних серцевих патологій, таких як передсердна тахікардія або передсердна фібриляція. З іншого боку, якщо нормальний сигнал класифікується як можуть «Передсердна екстрасистолія», пацієнту рекомендувати додаткові обстеження, що призведе до зайвих витрат та можливого психологічного стресу. Ці та інші помилки класифікації з матриці сплутувань будуть помітні при застосуванні методу для інтерпретації результатів класифікації, що є важливим етичним аспектом у використанні класифікатора.

Застосування методу інтерпретації результатів класифікації зробить прийняття рішень алгоритмами доступним для пояснення, щоб суб'єкти даних, на яких поширюються такі рішення і чиї законні права будуть порушені в процесі, могли за допомогою такого пояснення зрозуміти логіку, що лежить в основі рішення, яке було прийнято проти них. Отже, необхідно інтегрувати в коди алгоритмів ШІ достатні засоби і процеси, які дозволяють пояснити процес прийняття рішень системами ШІ, які будуть використовуватися в медичній практиці.

В статті [147] наведено, що процес прийняття рішень алгоритмами повинен бути доступним для пояснення, щоб суб'єкти даних, на яких поширюються такі рішення і чиї законні права будуть порушені в процесі, могли за допомогою такого пояснення зрозуміти логіку, що лежить в основі рішення, яке було прийнято проти них. Отже, необхідно інтегрувати в коди алгоритмів ШІ достатні засоби і процеси, які дозволяють пояснити процес прийняття рішень системами ШІ, які будуть використовуватися в медичній практиці. Тому запропонований метод інтерпретації результатів класифікації патологій аритмій формує інтерпретацію на основі ознак, які використовує лікар у медичній практиці при діагностиці патологій аритмій на ЕКГ-сигналі.

Так само як і для навчальної вибірки, статистичні показники були розраховані для тестової вибірки (таблиця 4.9).

Таблиця 4.9

Статистичні показники класифікації ЕКГ

Клас	Precision		Recall		F1-score	
	C3	CB	C3	CB	C3	CB
1	0.99	0.005	1.00	0	1.00	0
2	0.98	0.005	0.98	0.005	0.98	0.005
3	0.99	0.005	1.00	0	1.00	0.005
4	1.00	0.004	1.00	0	1.00	0
5	1.00	0	1.00	0	1.00	0
6	0.96	0.012	0.93	0.008	0.94	0.007
7	0.90	0.024	0.81	0.037	0.85	0.016
8	0.96	0.022	0.93	0.038	0.95	0.018
9	0.853	0.042	0.8	0.124	0.823	0.08

для 9 підтримуваних класів на основі тестової вибірки

Колонки Precision, Recall та F1 відображають середні значення (C3) та середнє відхилення (CB) відповідних статистичних показників, отриманих для кожного підтриманого класу з 7, випадковим чином отриманих, тестових вибірок.

Для наведених статистичних даних точність класифікації на навчальній вибірці знаходиться в межах 99.90–99.92 %, а на тестовій – 99.08–99.44 %.

Модель демонструє хороші результати класифікації на навчальній вибірці, про що свідчать практично ідеальні статистичні показники Precision, Recall, F1-score для всіх класів. На тестовій вибірці модель продовжує показувати хороші статистичні показники класифікації, однак порівняно з показниками для навчальної вибірки, присутнє певне падіння значень статистичних показників. Найбільше падіння статистичних показників помітне для класів 7 і 9, що може свідчити про складність класифікації цих класів на нових даних. Причиною падіння статистичних показників для класів 7 та 9 може бути те, що сигнали такого типу представлені в меншій кількості в базі даних, що не дає можливості нейромережі повністю оволодіти знаннями про такий вид сигналів. Також варто зазначити, що показник *Recall* на тестовій вибірці має значення вищі за 80 %, що свідчить про те, що класифікатор підібраний правильно.

Низькі стандартні відхилення (менші 5 %) в навчальній вибірці вказують на те, що прогнози моделі є послідовними та стабільними на всіх навчальних даних. Підвищені стандартні відхилення на тестовому наборі є очікуваними, оскільки при використанні тестового набору даних мережа працює з новими невідомими даними, але при цьому показник середнього відхилення залишається меншим за 5 %. Особливо помітне зростання середнього квадратичного відхилення класів 7 та 9, що свідчить про певну непослідовність у роботі моделі нейромережі на нових незнайомих даних для цих класів.



Рис. 4.7. ROC-криві, отримані для мультикласової класифікації ЕКГ-сигналів за підходом «Один проти всіх»

Для оцінки якості класифікації кожного класу було побудовано графіки ROCкривих (рис. 4.7), які для більшості класів розташовані дуже близько до лівого верхнього кута графіка, що підтверджує високу ефективність моделі. Високі значення AUC для всіх класів (більшість з яких дорівнює 1.00) вказують на те, що модель відмінно справляється із задачами розрізнення між позитивними та негативними прикладами в усіх класах. Навіть для тих класів, де AUC дещо нижчий (клас 9), модель демонструє чудові результати.

Додатково для оцінки якості класифікації було побудовано ROC-криві за підходом «Один клас проти кожного іншого». Приклад таких кривих зображений на рис. 4.8.





ROC-криві та площа AUC отримані за стратегією One-vs-One в переважній більшості практично ідеальні. Для більшості комбінацій ROC-криві розташовані близько до лівого верхнього кута, що свідчить про високу ефективність моделі. Те саме стосується значення AUC, яке знаходиться в межах 0.99–1.00 та підтверджує, що модель добре справляється із задачами розрізнення між позитивними та негативними прикладами в усіх класах.

Варто зазначити, що найбільше відхилення ROC кривої від лівого верхнього кута та показником AUC із значенням 1.00–0.99 спостерігається при комбінації із класів 1 та 9 (рис. 4.8, *a*). На основі отриманих результатів можна зробити висновок, що класифікатор дещо краще розрізняє клас 1 як позитивний клас порівняно з класом 9, що відображається з незначною різницею в AUC. Така різниця може бути спричинена тим, що кількість випадків класів 1 та 9 є різною у навчальній та тестовій вибірках.

Далі буде розглянуто порівняння запропонованого методу з існуючими. Для цього варто підвести підсумкові значення для статистичних показників запропонованого методу. Точність запропонованого методу на тестовій вибірці в середньому складає 99.26 %. В таблиці 4.10 наведено значення макро та зважене середнє значення статистичних показників.

Таблиця 4.10

 Precision
 Recall
 F1-score

 Макро
 0.96
 0.94
 0.95

 Зважене
 0.99
 0.99
 0.99

Середні статистичні показники класифікації 9 типів ЕКГ

за допомогою запропонованого методу

Серед усіх класів, підтримуваних під час класифікації, клас «Others» є менш стабільним. Це все пояснюється тим, що кардіоцикли такого типу значно менше представлені в базі даних. Також для класу «Others» характерна більша варіативність, що ще більше підкреслює проблему малої кількості сигналів цього типу. Саме це впливає на Макро-показник, оскільки для нього всі класи рівноцінні, незважаючи на їх кількісне представлення у вибірці. Якщо виключити з розрахунку кардіоцикли класу «Others», то статистичні показники набувають значень, які представленні в таблиці 4.11.

Таблиця 4.11

Середні статистичні показники класифікації ЕКГ без врахування класу «Others»

	Precision	Recall	F1-score
Макро	0.97	0.96	0.96
Зважене	0.99	0.99	0.99

Для порівняння статистичних результатів з існуючими відомими підходами варто зазначити, що всі підходи можна розділити на 2 типи:

1) підходи, які об'єднують класи кардіоциклів в групи і класифікують кардіоцикли на приналежність до певної групи;

2) підходи, які класифікують кожний клас кардіоциклу.

Перший тип підходів базується на рекомендації від Association for the Advancement of Medical Instrumentation (AAMI), яка полягає в групуванні класів кардіоциклів. Це дає перевагу в навчанні мережі, оскільки згрупувавши дані, вдається уникнути малого розподілу даних між класами, тим самим отримавши хороші статистичні результати класифікації. Але такий підхід до класифікації не завжди задовольняє потребу лікаря, оскільки для правильної діагностики йому важливо знати конкретну патологію кардіоциклу, а не групу, до якої було віднесено патологію.

Враховуючи те, що запропонований метод не базується на ААМІ, то отримати повністю рівнозначне порівняння статистичними показниками методів на основі ААМІ не вдається. В таблиці 4.12 наведено порівняння статистичних показників методів класифікації ЕКГ-сигналу, які базуються на ААМІ, із запропонованим в цій роботі методом. Попри те, що запропонований метод фокусується на класифікації 9 типів кардіосигналу, він здебільшого демонструє кращі результати ніж методи, які класифікують кардіосигнали на відповідність групам.

Таблиця 4.12

Порівняння запропонованого методу класифікації ЕКГ

Підхід	Кількість	Назва	Значення	Значення показника
	груп	показника	показника	запропонованого
				методу
A. Ahmed	4	Accuracy	0.99	0.9926
et al [148]		Precision	0.93	0.96
		Recall	0.94	0.94
		F1-score	0.93	0.95
XU et al	5	Accuracy	0.998	0.9926
[7]		Precision	0.98	0.96
		Recall	0.94	0.94
		F1-score	0.96	0.95
Hassan et	5	Accuracy	0.98	0.9926
al [82]		Specificity	0.91	-
		Recall	0.91	0.94
Kumar et	5	Accuracy	0.987	0.9926
al [149]		Precision	0.989	0.96
		Recall	0.939	0.94
		F1-score	0.963	0.95
Mahmud	6	Accurancy	0.94	0.9926
et al [150]		Precision	0.95	0.96
for signal		Recall	0.90	0.94
		F1-score	0.92	0.95
Mahmud	6	Accurancy	0.93	0.9926
et al [150]		Precision	0.93	0.96
for image		Recall	0.93	0.94
		F1-score	0.93	0.95

з підходами до класифікації на основі ААМІ

У таблиці 4.13 наведено порівняння статистичних результатів запропонованого методу з результатами методів, які підпадають під другу категорію, а саме для класифікації кардіоциклів на конкретні атомарні класи патологій.

Таблиця 4.13

Порівняння запропонованого методу класифікації ЕКГ з існуючими підходами до класифікації атомарних патологій

Підхід	Кількість	Спільні	Показник	Значення	Значення
	класів	класи		показника	показника
				для спільних	запропонованого
				класів	методу для
					спільних класів
A. Ullah [18]	8	6	Precision	0.985	0.988
			Recall	0.977	0.984
			F1-Score	0.981	0.986
Rohmantri [17]	8	7	Precision	0.973	0.97
			Recall	0.893	0.95
			F1-Score	0.927	0.96
Degirmenci	5	5	Precision	0.995	0.993
[16]			Recall	0.997	0.997
			F1-Score	0.992	0.995
Liu [14]	4	4	Precision	-	0.993
			Recall	0.993	0.995
			F1-Score	-	0.994
HUI YANG	6	6	Precision	0.991	0.988
[75]			Recall	-	0.984
			F1-Score	0.966	0.986

Оскільки, кожний такий метод може підтримувати класифікацію різного набору класів кардіоциклів, то порівняння середнього значення статистичних

показників класифікації буде нерівнозначним. Тому в таблиці 4.13 наведено статистичні показники, які характеризують класифікацію лише спільних класів для розглянутого та запропонованого методу.

Враховуючи наведені дані, можна підсумувати, що запропоноване вдосконалення методу класифікації ЕКГ-сигналу, дозволяє з високою точністю класифікувати 9 типів ЕКГ-сигналу.

4.5. Експеримент з клінічними даними

Клінічні дані та їх попередня обробка. Для проведення клінічних досліджень було отримано 10 фрагментів ЕКГ-сигналів, отриманих з реальних історій хвороби пацієнтів. ЕКГ-сигнали наведені у растровому форматі. Приклад такого сигналу зображено на рис. 4.9.



Рис. 4.9. Приклад зображень ЕКГ-сигналів із історій хвороби реальних пацієнтів для клінічних досліджень

Разом із зображеннями ЕКГ-сигналів, було отримано анотацію, яка позначає наявність патології в кардіоциклах. Відповідно до анотації, отримані ЕКГ-сигнали містять 59 кардіоциклів в нормі, та 17 кардіоциклів з патологію «Передчасне скорочення шлуночків».

Для того, щоб отримання ЕКГ-сигнал з рисунків, було проведено попередню обробку самих рисунків, яка включала:

1. Видалення текстової інформації із вхідного зображення;

2. Розділення вхідного зображення на окремі фрагменти, які представляють ЕКГ-сигнал кожного каналу окремо (рис. 4.10).



Рис. 4.10. Приклад розділення зображення ЕКГ на окремі зображення за каналами

Процес отримання ЕКГ-сигналу з картинки починається з конвертації зображення у градації сірого. Далі, використовуючи OpenCV [151], зображення переводиться у бінарний формат, де всі пікселі стають або чорними, або білими. Це спрощує виявлення лінії сигналу ЕКГ, оскільки вона тепер представлена чорними пікселями на білому фоні. Координати чорних пікселів по вертикалі збираються для відтворення лінії сигналу. Ці координати перетворюються у 1D-масив, що представляє амплітуду ЕКГ-сигналу. Таким чином, зображення ЕКГ перетворюється на цифровий формат для подальшої обробки та класифікації за допомогою запропонованих методів.

Результати досліджень з клінічними даними. Спочатку клінічні випробування було проведено для методу пошуку R-зубців та підраховано показник Каппа Коена. Отримане значення становить 0.940, що знаходиться в межах діапазону 0.81–0.99, що підтверджує майже ідеальне узгодження результату роботи запропонованого методу та експертом, що анотував сигнали.

Далі клінічні випробування було проведено для методу класифікації патологій в ЕКГ-сигналі. Модель класифікації патологій на клінічній вибірці отримала значення 0.8905 для показника Каппа Коена. Це значення знаходиться в межах діапазону 0.81–0.99 та підтверджує практично ідеальне узгодження між результатом роботи класифікатора та експертом, що анотував сигнали. Також в результаті проведення клінічних досліджень класифікації було побудовано матрицю сплутувань, яка зображена на рис. 4.11.



Рис. 4.11. Матриця помилок моделі класифікації патологій для клінічних випробувань

На отриманій матриці видно, що 2 кардіоцикли були помилково класифіковані як «Блокада правої ніжки пучка Гіса» та один кардіоцикл помилково класифікований як «Норма». Всі інші кардіоцикли класифіковано правильно.



Рис. 4.12. Сформований звіт інтерпретації відповідно до критеріїв лікаря для класифікованого ЕКГ-сигналу: «Нормальний ЕКГ-сигнал»

4.6. Інтерпретація результатів класифікації за ознаками, прийнятими у медичній практиці

Інтерпретація отриманих за запропонованим вище методом результатів проводиться для кожного кардіоциклу.

Далі наведено приклади інтерпретації прийнятих рішень.



Рис. 4.13. Приклад візуального підтвердження класу «Норма» на вхідному (*a*) ЕКГ на основі ознак: *б* – ключові зубці; *в* – ключові сегменти; *г* – недеформований і нерозширений комплекс QRS

На рис. 4.13, *a*, зображений приклад вхідного ЕКГ-сигналу, який класифікований як «Нормальний ЕКГ-сигнал». Відповідно до ознак зрозумілих лікарю (для сигналів цього типу), за запропонованим методом інтерпретації, формується результат (рис. 4.12).

Кожна наведена ознака, відповідно до своїх критеріїв, підтверджується візуально, шляхом виділення відповідного зубця, або фрагмента сигналу. На рис. 4.13, *б*, зображено підтвердження наявності основних зубців в кардіоциклі ЕКГсигналу. В свою чергу, на рис. 4.13, *в*, показано підтвердження про наявність QT- та ST-сегментів в кардіоциклі, а на рис. 4.13, *г*, виділено фрагмент сигналу, для якого вдалося підтвердити ознаку «QRS нерозширений та недеформований». Інтерпретація інших підтримуваних класів відбувається аналогічним чином. Так для кардіосигналу (рис. 4.15, *а*) класифікованого за наявністю патології «*Блокада правої ніжки пучка Гіса*», формується результат інтерпретації, зображений на рис. 4.14.

Перевірка на розширений та деформований QRS Наявність депресії ST

Рис. 4.14. Сформований звіт інтерпретації відповідно до критеріїв лікаря для класифікованого ЕКГ-сигналу як «Блокада правої ніжки пучка Гіса»

На рис. 4.15, *б*, виділено фрагмент сигналу, для якого вдалося підтвердити наявність депресії ST-сегмента. В свою чергу, на рис. 4.15, *в*, виділено фрагмент сигналу, для якого вдалося підтвердити наявність ознаки «QRS комплекс розширений та деформований».

Попри наявність щонайменше 5 ознак, якими користується лікар для визначення патології «*Блокада правої ніжки пучка Гіса*», на рис. 4.14 наведено інтерпретацію лише двох ознак через те, що частина ознак орієнтується на такі відведення ЕКГ-сигналу, які відсутні в базі МІТ-ВІН [141]. За наявності відповідних відведень ЕКГ-сигналів, ознаки патології можуть бути інтерпретовані аналогічним до підтримуваних ознак чином.



Рис. 4.15. Приклад візуального підтвердження патології «Блокада правої ніжки пучка Гіса» на вхідному (*a*) ЕКГ на основі ознак: *б* – дискордантні зміни сегмента ST-T; *в* – розширений комплекс QRS

Для ЕКГ-сигналу, класифікованого за наявністю патології «Блокада лівої ніжки пучка Гіса» (рис. 4.15, *a*), формується результат інтерпретації, який надає розгорнуту характеристику виявлених особливостей сигналу. Усі ключові ознаки патології представлені на рис. 4.14, де детально описані параметри, що використовувалися для аналізу і підтвердження діагнозу.

Для ЕКГ-сигналу (рис. 4.17, *a*) класифікованого за наявністю патології «*Блокада лівої ніжки пучка Гіса*», формується результат інтерпретації, який надає перелік підтверджених або спростованих лікарських ознак, зображений на рис. 4.16.

Перевірка на розширений QRS 🗸 Дискордантні зміни ST-T 🗸 Подовжений ЧВВ 🗸

Рис. 4.16. Сформований звіт інтерпретації відповідно до критеріїв лікаря для класифікованого ЕКГ-сигналу як «Блокада лівої ніжки пучка Гіса»

Відповідно до сформованого результату інтерпретації на рис. 4.17, *б*, виділено фрагмент сигналу, для якого вдалося підтвердити ознаку про розширений QRS комплекс.



Рис. 4.17. Приклад візуального підтвердження патології «Блокада лівої ніжки пучка Гіса» на вхідному (*a*) ЕКГ на основі ознак: *б* – розширений QRS; *в* – дискордантні змін в ST-T; *г* – дискордантні зміни сегмента ST-T; *г* – подовжений ЧВВ

На рис. 4.17, *в*, показано фрагмент сигналу, який підтверджує наявність дискордантних змін в ST-T. Подовжений час внутрішньоподібного відхилення підтверджено на виділеному фрагменті сигналу, зображеному на рис. 4.17, *г*.

Сформований результат інтерпретації для патології «*Блокада лівої ніжки пучка Гіса*» не включає ознаку «Глибокі, широкі зубці S у правих грудних відведеннях», оскільки праві грудні відведення відсутні в базі МІТ-ВІН [141].

На рис. 4.19, *a*, показано приклад вхідного ЕКГ-сигналу, який було класифіковано як «Шлуночкова екстрасистолія». Інтерпретація патології

сформована відповідно до попередньо визначених ознак, прийнятих у медичній практиці, показана на рис. 4.18.

✓ Перевірка на розширений та деформований QRS ✓
 ✓ Відсутнійсть зубця Р ✓
 ✓ Компенсаторна пауза ✓

Рис. 4.18. Сформований звіт інтерпретації відповідно до ознак, що використовуються в медичній практиці, для класифікованого ЕКГ-сигналу як «Шлуночкова екстрасистолія»

Візуальне підтвердження ознаки «*Розширений та деформований QRS*» зображено на рис. 4.19, *б*. На рис. 4.19, *в*, виділено фрагмент сигналу, в межах якого підтверджено відсутність зубця P, а на рис. 4.19, *г*, виділено частину сигналу, де присутня компенсаторна пауза.



Рис. 4.19. Візуальне підтвердження ознак патології «Шлуночкова екстрасистолія» на вхідному (*a*) ЕКГ; *б* – розширений та деформований QRS; *в* – відсутній зубець Р;

г – компенсаторна пауза

На рис. 4.20 показано приклад вхідного ЕКГ-сигналу, який було класифіковано як «Вставна шлуночкова екстрасистолія».



Рис. 4.20. Вхідний сигнал, який було класифіковано як «Вставна шлуночкова екстрасистолія»

Відповідно до попередньо визначених клінічних ознак, що використовуються в медичній практиці, формується інтерпретація класифікованої патології. Сформований результат показано на рис. 4.21.

\checkmark	Перевірка на розширений та деформований QRS 🗸
\checkmark	Відсутнійсть Р піку 😳
~	Відсутння компенсаторна пауза 🗸
✓	Лівий кардіоцикл є нормою 🗸
~	Правий кардіоцикл є нормою 🗸
	• • • • •

Рис. 4.21. Сформований звіт інтерпретації для класифікованого ЕКГ-сигналу як «Вставна шлуночкова екстрасистолія», відповідно до ознак, що використовуються в медичній практиці

Відповідно до вказаних ознак сформовано їхнє візуальне підтвердження. Рис. 4.22, а, зображає виділений фрагмент сигналу, який використовувався для підтвердження ознаки про розширений та деформований QRS-комплекс. Зона, в якій очікується відсутній зубець Р, виділено на рис. 4.22, б. У випадку з цією патологією показано випадок, коли не вдалося підтвердити наявність ознаки, тому на рис. 4.21 біля неї стоїть відповідний червоний знак. На рис. 4.22, в, виділено частину сигналу, де визначається відсутність компенсаторної паузи. Рис. 4.22, г, показує візуальне того, екстрасистолія підтвердження шлуночкова виникає між ЩО двома кардіоциклами, які відносяться до класу «Норма».



Рис. 4.22. Приклад візуального підтвердження класу «Вставна шлуночкова екстрасистолія» на основі ознак: *а* – розширений та деформований QRS; *б* – відсутній зубець Р; *в* – відсутність компенсаторної паузи; *г* – сусідні кардіоцикли в нормі

4.7. Обмеження запропонованого підходу

Обмеження, запропонованого підходу:

По-перше, основним обмеженням запропонованого підходу є залежність від точності виявлення зубців R в ЕКГ. Хоча метод додавання синхронного сигналу з можливим розташуванням R поліпшує точність цього процесу, він все ж стикається з проблемою наявності артефактів або шуму в даних. Неточності у виявленні зубців R можуть призвести до помилок у подальшій класифікації аритмій, оскільки на основі цих зубців сегментуються кардіоцикли для аналізу. Як наслідок, артефакти сигналу або незвичні форми кардіоциклів можуть знижувати результативність

моделі, особливо в процесі клінічної практики. Одним з можливих шляхів розв'язання цієї проблеми є збільшення навчальних вибірок за рахунок доповнення їх сигналами ЕКГ, записаними за різних умов активності пацієнтів, рівнів стресу та інших впливових факторів. Це дозволить моделі ефективніше узагальнювати знання про сигнали ЕКГ, що, у свою чергу, підвищить точність виявлення зубців R.

Друге обмеження стосується кількості класів патологій, які модель здатна класифікувати. Попри високу точність у виявленні аритмій, існує ризик, що модель не враховує всі можливі патології, оскільки деякі класи можуть бути недостатньо відображені в навчальних даних. Це може спричинити невисоку здатність моделі до узагальнення на рідкісні або нестандартні випадки. Крім того, незбалансованість класів у наборі даних може призвести до переваги більш поширених патологій і зменшити точність для менш поширених, що є критичним чинником у клінічній практиці. Вирішенням цього обмеження може бути більш збалансований та репрезентативний набір даних, який включатиме достатню кількість прикладів як поширених, так і рідкісних патологій, таким чином розширюючи охоплення під час навчання.

Третє обмеження полягає у використанні МІТ-ВІН як основної бази даних з розміченими патологіями, характерними для аритмії. ЕКГ-сигнали в базі МІТ-ВІН мають лише два відведення, в той час коли стандартне ЕКГ складається з 12 відведень. Таке обмеження МІТ-ВІН не дає повноцінної можливості підготувати модель до всіх можливих варіацій ЕКГ. Відповідно для вирішення наведеного обмеження доцільно доповнити навчальну вибірку сигналами ЕКГ, записаними з 12 відведень.

4.8. Висновки до розділу 4

У цьому розділі було представлено результати експериментальних досліджень, спрямованих на підтвердження валідності запропонованих методів обробки та аналізу ЕКГ-сигналів. Окрему увагу приділено та розглянуто методиці валідації, запропонованої в цій роботі методів. Для проведення експериментів було розглянуто та використано 4 бази даних з ЕКГ-сигналами: МІТ-ВІН, QT, CPSC-2020 та UoG. Зокрема, для експериментів з пошуку R-зубців на ЕКГ-сигналі використовувались всі наведені бази даних, а для експериментів з класифікації патологій аритмій та інтерпретації класифікації використано ЕКГ-сигнали з бази даних МІТ-ВІН.

При тестуванні методу пошуку R-зубців на ЕКГ-сигналі для розрахунку метрик використовували похибку ±25 мс. Порівняння результатів з іншими підходами, які представляють сучасний стан обробки ЕКГ, продемонстрував високу продуктивність у різних метриках і базах даних. Зокрема, в базах даних МІН-ВІН, QT та CPSC-2020 запропонований підхід перевершив свої аналоги.

Тестування методу класифікації патологій на ЕКГ-сигналі показав, що загальна точність методу в середньому становить 99.26 %, що свідчить про ефективність у класифікації 9 класів ЕКГ. Оцінка методу за ROC-AUC також підтвердила ефективність методу, оскільки ROC криві для всіх класів знаходяться дуже близько до лівого верхнього кута графіка, а значення AUC для 1–8 класів дорівнює 1.0, для класу 9 дорівнює 0.98. Отримані AUC-показники підтверджують те, що CNN-модель, використана для класифікації, відмінно справляється з задачами розрізнення між позитивними та негативними прикладами в усіх класах.

Особливу увагу приділено експерименту класифікації патологій з клінічними даними, що включає реальні ЕКГ-сигнали пацієнтів. Це дозволило оцінити ефективність методів в умовах, максимально наближених до реальної клінічної практики. Модель класифікації патологій на клінічній вибірці отримала значення 0.8905 для показника Каппа Коена, що знаходиться у межах діапазону 0.81–0.99 і підтверджує практично ідеальне узгодження між результатом роботи класифікатора та експертом, що анотував сигнали.

Розглянуто застосування методу інтерпретації класифікованих ЕКГ-сигналів. Наведені експерименти показали валідність запропонованого підходу для інтерпретації класифікації відповідно до ознак, що використовуються в медичній практиці.

ВИСНОВКИ

У результаті виконання дисертаційної роботи було розв'язано актуальну науково-прикладну задачу покращення якості та точності класифікації патологій на електрокардіограмі засобами глибокого навчання з подальшою інтерпретацією отриманих результатів за допомогою ознак, прийнятих у медичній практиці.

У роботі отримано такі наукові та практичні результати:

1. На основі проведеного аналізу сучасних підходів, методів обробки, класифікації на наявність патологій та інтерпретації класифікації за ЕКГ-сигналом обґрунтовано потребу в покращенні точності класифікації патологій з подальшою інтерпретацією;

2. Розроблено новий метод ідентифікації R-зубців на ЕКГ-сигналі, який відрізняється від існуючих використанням моделі глибокого навчання з двома вхідними сигналами – ЕКГ-сигналом та, синхронним з ним, сигналом з прогнозованим розташуванням R-зубців, що дало змогу підвищити точність ідентифікації. Процес включає три основні етапи: 1) формування та додавання синхронного сигналу із можливим розташуванням зубців R, 2) обробка цієї інформації за допомогою CNN-моделі, 3) постобробка результатів encoder-decoder моделі для виявлення R-зубців. Під час тестування використовувалася похибка ±25 мс для розрахунку метрик. Порівняння з сучасними підходами виявило високу ефективність запропонованого методу, який продемонстрував кращі результати за різними метриками на базах даних MIH-BIH, QT та CPSC-2020.

3. Удосконалено метод класифікації патологій аритмій на ЕКГ-сигналі, який відрізняється від відомих використанням тріади кардіоциклів, що дозволяє сформувати контекстну інформацію виникнення кардіоциклу, для подальшої класифікації вдосконаленою архітектурою моделі глибокого навчання, що дозволило збільшити кількість патологій для розпізнавання та підвищити точність класифікації. Тестування методу показало середню точність 99.26 % у класифікації 9 класів ЕКГ. Аналіз за ROC-AUC підтвердив ефективність: значення AUC для класів 1–8 становить 1.0, а для класу 9 – 0.98. Результати свідчать про високу здатність CNN-моделі розрізняти позитивні та негативні приклади у всіх класах.

4. Вперше розроблено метод інтерпретації результатів класифікації патологій аритмій, отриманих з ЕКГ-сигналу за моделями глибокого навчання, що дало змогу подати результати класифікації за ознаками, що використовуються в медичній практиці. Основна концепція полягає у визначенні специфічних ознак ЕКГ-сигналу, які традиційно використовуються у медичній практиці для діагностики та інтеграції цих характеристик у процес інтерпретації результатів класифікації. Таким чином, на відміну від інших методів інтерпретації класифікації, запропонований підхід не лише ідентифікує значущі фрагменти ЕКГ, але й застосовує медичні ознаки для візуалізації та інтерпретації, що дозволяє лікарям більш ефективно перевіряти та аналізувати рішення, прийняті моделлю глибокого навчання.

5. Розроблені та вдосконалені методи покладено в основу експериментальної інформаційної системи, що демонструє можливості цих методів. Ця інформаційна система надає можливість класифікації обраного ЕКГ-сигналу на 9 класів для визначених кардіоциклів. Крім того, у разі необхідності, система дозволяє генерувати та візуалізувати інтерпретації для класифікованого кардіоциклу, що значно спрощує аналіз отриманих результатів.

Практичне значення отриманих результатів полягає в доведенні теоретичних результатів дисертаційної роботи до реалізації та у безпосередньому використанні їх у відповідних медичних установах.

Реалізована інформаційна система на основі методі пошуку R-зубців та класифікації ЕКГ-сигналу на наявність патологій аритмій забезпечують користувачу прогнози наявності патологій аритмій 9 підтримуваних класів для всіх виявлених карідоциклів, що несе рекомендаційних характер та пришвидшує роботу лікаря в аналізі ЕКГ-сигналу.

Реалізована інформаційна система включає використання методу інтерпретації рішень класифікації патологій аритмій, отриманих за моделями глибокого навчання, і дозволяє подати лікарю результати класифікації за ознаками, що використовуються в медичній практиці. Такий підхід робить рішення моделей глибокого навчання більш доступними для нього, забезпечуючи довіру до отриманих результатів.

Реалізована інформаційна системи класифікації патологій аритмій та інтерпретації результатів класифікації базується на клієнт-серверній архітектурі, що дає змогу робити всі обчислення на віддаленому сервері з потужним обладнанням, тоді як клієнт здійснює лише передачу даних, отримання та візуалізацію результатів, що дає можливість використовувати систему в невеликих клініках з обмеженими обчислювальними ресурсами.

Результати дисертаційної роботи впроваджено (Додаток Б): у медичному лікувально-діагностичному центрі «Сіліція-Сіті+» (довідка про впровадження); ТОВ «АЙ ТІ ХУТ» (довідка про впровадження); у навчальному процесі Хмельницького національного університету (акт впровадження); при виконанні держбюджетної теми Хмельницького національного університету «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (ДР № 0124U000980).

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ

1. Global Health Estimates: Life expectancy and leading causes of death and disability. URL: <u>https://www.who.int/data/gho/data/themes/mortality-and-global-health-</u>estimates/ghe-leading-causes-of-death (date of access: 24.11.2024).

2. The World Death Statistics 2023. URL: https://deadorkicking.com/death-statistics/worldwide/2023/ (date of access: 24.11.2024).

3. Heart Disease and Stroke Statistics–2021 Update / S. S. Virani et al. *Circulation*. 2021. Vol. 143, no. 8. URL: https://doi.org/10.1161/cir.0000000000000950 (date of access: 16.01.2025).

4. Vincent R. From a laboratory to the wearables: a review on history and evolution of electrocardiogram. *Iberoamerican Journal of Medicine*. 2022. Vol. 4, no. 4. P. 248–255. URL: https://doi.org/10.53986/ibjm.2022.0038 (date of access: 18.11.2024).

5. T. Garcia, N. Holtz, Introduction to 12-Lead ECG: The Art of Interpretation. Jones & Bartlett Learning. 2014.

6. A new approach for arrhythmia classification using deep coded features and LSTM networks / O. Yildirim et al. *Computer Methods and Programs in Biomedicine*. 2019. Vol. 176. P. 121–133, URL: https://doi.org/10.1016/j.cmpb.2019.05.004 (date of access: 28.11.2024).

7. Xu X., Liu H. ECG Heartbeat Classification Using Convolutional Neural Networks. *IEEE Access.* 2020. Vol. 8. P. 8614–8619. URL: https://doi.org/10.1109/access.2020.2964749 (date of access: 28.11.2024).

8. Dohare A. K., Kumar V., Kumar R. Detection of myocardial infarction in 12 lead ECG using support vector machine. *Applied Soft Computing*. 2018. Vol. 64. P. 138– 147. URL: https://doi.org/10.1016/j.asoc.2017.12.001 (date of access: 28.11.2024).

9. Khater H. M., Suliman A. Deep Learning-Based ECG Analysis for Myocardial Infarction Detection. 2023 15th International Conference on Innovations in Information Technology (IIT), Al Ain, United Arab Emirates, 14–15 November 2023. 2023. URL: https://doi.org/10.1109/iit59782.2023.10366419 (date of access: 28.11.2024).

10. Sahu G., Ray K. C. An Efficient Method for Detection and Localization of Myocardial Infarction. *IEEE Transactions on Instrumentation and Measurement*. 2022.

Vol. 71. P. 1–12. URL: https://doi.org/10.1109/tim.2021.3132833 (date of access: 18.11.2024).

11. Hayashi Y. Black Box Nature of Deep Learning for Digital Pathology: Beyond Quantitative to Qualitative Algorithmic Performances. *Artificial Intelligence and Machine Learning for Digital Pathology*. Cham, 2020. P. 95–101. URL: https://doi.org/10.1007/978-3-030-50402-1_6 (date of access: 19.11.2024).

12. Perturbation-Based Explainable AI for ECG Sensor Data / J. Paralič et al. *Applied Sciences*. 2023. Vol. 13, no. 3. P. 1805. URL: https://doi.org/10.3390/app13031805 (date of access: 19.11.2024).

13. Poon A. I. F., Sung J. J. Y. Opening the black box of AI-Medicine. *Journal of Gastroenterology and Hepatology*. 2021. Vol. 36, no. 3. P. 581–584. URL: https://doi.org/10.1111/jgh.15384 (date of access: 20.11.2024).

14. Isolation of Informative Features for the Analysis of QRS Complex in ECG
Signals / A. Pashko et al. *Advances in Intelligent Systems and Computing*. Cham, 2020.
P. 409–422. URL: https://doi.org/10.1007/978-3-030-54215-3_26 (date of access: 25.11.2024).

15. Electrocardiogram Classification Using Wavelet Transformations / I. Krak et al. 2020 IEEE 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET), Lviv-Slavske, Ukraine, 25–29 February 2020. 2020. URL: https://doi.org/10.1109/tcset49122.2020.235573 (date of access: 25.11.2024).

16. Krak I., Pashko A., Khorozov O., Stelia O. Physiological Signals Analysis, Recognition and Classification Using Machine Learning Algorithms. Proceedings of The Third International Workshop on Computer Modeling and Intelligent Systems (CMIS-2020), Zaporizhzhia, Ukraine, April 27 – May 1, 2020, pp. 955–965.

17. Krak I., Pashko A., Stelia O., Barmak O., Pavlov S. Selection Parameters in the ECG Signals for Analysis of QRS Complexes. *Proceedings of the 1st International Workshop on Intelligent Information Technologies & Systems of Information Security*, Khmelnytskyi, Ukraine, June 10–12, 2020, pp. 1–13. URL: <u>https://ceur-ws.org/Vol-2623/paper1.pdf</u> (date of access: 25.11.2024).

18. Application of telemedicine technologies in the military medical sphere for diagnostic, treatment and rehabilitation of military personnel / Y. O. Pylypets et al. *Optoelectronic Information-Power Technologies*. 2024. Vol. 47, no. 1. P. 166–176. URL: https://doi.org/10.31649/1681-7893-2024-47-1-166-176 (date of access: 25.11.2024).

19. Yavorskyi A., Tyshchenko B., Panchenko T. Efficient ECG Analysis with High F1 Score and Low Computation Complexity. 2021 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), Cracow, Poland, 22–25 September 2021. 2021. URL: https://doi.org/10.1109/idaacs53288.2021.9660931 (date of access: 25.11.2024).

20. Данилов В., Зарицький О. Використання методів машинного навчання для класифікації серцевих захворювань за даними ЕКГ та застосування сучасних генеративно змагальних мереж для збільшення навчальної вибірки. *InterConf.* 2022. № 14 (113). С. 472–478, URL: https://doi.org/10.51582/interconf.19-20.06.2022.050 (дата звернення: 25.11.2024).

21. Прімін М. А. Сучасні сенсорні системи та інформаційні технології в медицині, біології та техніці. Перспективи розвитку. *Visnik Nacional noi academii nauk Ukraini*. 2021. № 5. С. 46–52, URL: https://doi.org/10.15407/visn2021.05.047 (дата звернення: 25.11.2024).

22. Файнзільберг Л. С. Інтелектуальні інформаційні технології оброблення сигналів з локально зосередженими ознаками. *International Scientific Technical Journal "Problems of Control and Informatics"*. 2023. Т. 68, № 3. С. 61–73. URL: https://doi.org/10.34229/1028-0979-2023-3-7 (дата звернення: 28.11.2024).

23. Fainzilberg L. S. Restoration of a Standard Sample of Cyclic Waveforms with the Use of the Hausdorff Metric in a Phase Space. *Cybernetics and Systems Analysis*. 2003. Vol. 39, no. 3. P. 338–344. URL: https://doi.org/10.1023/a:1025749208571 (date of access: 28.11.2024).

24. Чайковський І. А., Лапшина І. Є., Файнзільберг Л. С., Секретний В. А. Аналіз ЕКГ у фазовому просторі як засіб контролю функціонального стану спортсменок, які спеціалізуються у футболі. *Спортивна медицина*. 2011, № 1–2.

C. 63–68. URL: https://fainzilberg.irtc.org.ua/files/art_63.pdf (дата звернення: 24.11.2024).

25. Чайковський І. А. Визначення емоційного стану людини за допомогою параметрів ЕКГ в одному відведенні : thesis. 2009. URL: http://essuir.sumdu.edu.ua/handle/123456789/13321 (дата звернення: 28.11.2024).

26. Budnyk V., Ryzhenko T., Budnyk M. Development and Conformity Assessment of ECG-Photometric Complex Software. *Cybernetics and Computer Technologies*. 2021. no. 3. P. 115–128. URL: https://doi.org/10.34229/2707-451x.21.3.10 (date of access: 28.11.2024).

27. Development and Certification of ECG-Pulsometric Device / T. Ryzhenko et al. 2023 IEEE 13th International Conference on Electronics and Information Technologies (ELIT), Lviv, Ukraine, 26–28 September 2023. 2023. URL: https://doi.org/10.1109/elit61488.2023.10310837 (date of access: 28.11.2024).

28. Коваленко С. О., Циганник Р. А. Аритмії, шумові явища, наявність тренду та хвильова структура серцевого ритму. Регуляторні ритми гемодинаміки та їх індивідуальні особливості у людей. С. 125–128, URL: https://eprints.cdu.edu.ua/id/eprint/5709 (дата звернення: 24.11.2024).

29. Коваленко С. О. Характеристика та теоретичні основи методів аналізу варіабельності серцевого ритму. *Український журнал медицини, біології та спорту*. 2017. № 2. С. 223–233.

30. Janiesch C., Zschech P., Heinrich K. Machine learning and deep learning. *Electronic Markets*. 2021. URL: https://doi.org/10.1007/s12525-021-00475-2 (date of access: 23.11.2024).

31. Lee M., Lee J.-H. A robust fusion algorithm of LBP and IMF with recursive feature elimination-based ECG processing for QRS and arrhythmia detection. *Applied Intelligence*. 2021. URL: https://doi.org/10.1007/s10489-021-02368-5 (date of access: 20.11.2024).

32. Identification of R-peak occurrences in compressed ECG signals / G. Laudato et al. 2020 IEEE International Symposium on Medical Measurements and Applications

(*MeMeA*), Bari, Italy, 1 June – 1 July 2020. 2020. URL: https://doi.org/10.1109/memea49120.2020.9137207 (date of access: 20.11.2024).

33. Machine learning framework for Inter-Beat Interval estimation using wearable Photoplethysmography sensors / V. B. O. Fioravanti et al. Biomedical Signal Processing and Control, 2024. Vol. 88. P. 105689. URL: https://doi.org/10.1016/j.bspc.2023.105689 (date of access: 25.11.2024).

34. Heartbeat classification using deep residual convolutional neural network from
2-lead electrocardiogram / Z. Li et al. *Journal of Electrocardiology*. 2020. Vol. 58. P. 105–112.
DOI: 10.1016/j.jelectrocard.2019.11.046 (date of access: 20.11.2024).

35. Kolhar M., Al Rajeh A. M. Deep learning hybrid model ECG classification using AlexNet and parallel dual branch fusion network model. *Scientific Reports*. 2024. Vol. 14, no. 1. URL: https://doi.org/10.1038/s41598-024-78028-8 (date of access: 24.11.2024).

36. Arrhythmic Heartbeat Classification Using 2D Convolutional Neural Networks / M. Degirmenci et al. *IRBM*. 2021. URL: https://doi.org/10.1016/j.irbm.2021.04.002 (date of access: 28.11.2024).

37. Recurrence Plot-Based Approach for Cardiac Arrhythmia Classification Using Inception-ResNet-v2 / H. Zhang et al. *Frontiers in Physiology*. 2021. Vol. 12. URL: https://doi.org/10.3389/fphys.2021.648950 (date of access: 28.11.2024).

38. Detection of Brief Episodes of Atrial Fibrillation Based on Electrocardiomatrix and Convolutional Neural Network / R. Salinas-Martínez et al. *Frontiers in Physiology*. 2021. Vol. 12. URL: https://doi.org/10.3389/fphys.2021.673819 (date of access: 24.11.2024).

39. Interpretable deep learning for automatic diagnosis of 12-lead electrocardiogram / D. Zhang et al. *iScience*. 2021. Vol. 24, no. 4. URL: https://doi.org/10.1016/j.isci.2021.102373 (date of access: 28.11.2024).

40. Interpretable Hybrid Model for an Automated Patient-wise Categorization of Hypertensive and Normotensive Electrocardiogram Signals / C. Chen et al. *Computer Methods and Programs in Biomedicine Update*. Vol. 3. 2023. URL: https://doi.org/10.1016/j.cmpbup.2023.100097 (date of access: 23.11.2024).
41. Bodini M., W Rivolta M., Sassi R. Interpretability Analysis of Machine Learning Algorithms in the Detection of ST-Elevation Myocardial Infarction. *2020 Computing in Cardiology Conference*. 2020, URL: https://doi.org/10.22489/cinc.2020.403 (date of access: 23.11.2024).

42. Towards transparent AI in medicine: ECG-based arrhythmia detection with explainable deep learning / O. Kovalchuck et a. *Technologies*. 2025. Vol. 13, no. 1. P. 34. URL: <u>https://doi.org/10.3390/technologies13010034</u> (date of access: 16.01.2025).

43. Ковальчук О. В., Бармак О. В. Метод ідентифікації R-піків у сигналах електрокардіограми. *Вісник Хмельницького національного університету*. 2024. № 6. С. 108–117. URL: https://doi.org/10.31891/2307-5732-2024-343-6-16 (дата звернення: 12.01.2025).

44. Ковальчук О. В., Бармак О. В. Метод класифікації аритмій на ЕКГсигналі. Оптико-електронні інформаційно-енергетичні технології. 2024. Т. 48, № 2. С. 34–44. URL: https://doi.org/10.31649/1681-7893-2024-48-2-34-44 (дата звернення: 24.11.2024).

45. Ковальчук О. В., Бармак О. В. Метод інтерпретації результатів класифікації ЕКГ методами глибокого навчання. *Проблеми моделювання та автоматизації проектування*. 2024. Т. 2, № 20. С. 120–130. URL: https://doi.org/10.31474/2074-7888-2024-2-20-120-130 (дата звернення: 29.01.2025).

46. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis /
P. Radiuk et al. *CEUR-WS*. 2022. Vol. 3302. P. 9–20. URL: https://ceur-ws.org/Vol-3302/paper1.pdf (date of access: 24.11.2024).

47. A novel feature vector for ECG classification using deep learning / O. Kovalchuk et al. *CEUR-WS*. 2023. Vol. 3373. P. 227–238. URL: https://ceur-ws.org/Vol-3373/paper12.pdf (date of access: 24.11.2024).

48. Kovalchuk O., Radiuk P., Barmak O. та Krak Iu. Robust R-peak detection using deep learning based on integrating domain knowledge. *CEUR-WS*. 2023. Vol. 3609. P. 1–14. URL: https://ceur-ws.org/Vol-3609/paper1.pdf (date of access: 24.11.2024).

49. Kovalchuk O., Radiuk P., Barmak O. та Krak Iu. ECG Arrhythmia Classification and Interpretation using Convolutional Networks for Intelligent IoT Healthcare System. CEUR-WS. 2024. Vol. 3736. P. 47-62. URL: https://ceur-ws.org/Vol-3736/paper4.pdf (date of access: 24.11.2024).

50. Комп'ютерна програма «Класифікація ЕКГ на наявність аритмій з подальшою інтерпретацією результатів» : а. с. 132579 Україна : CR2758130125 / О. В. Ковальчук, О. В. Бармак, П. М. Радюк. № с202409247 ; заявл. 11.11.2024 ; опубл. 13.01.2025, Бюл. № 86. 42 с. URL: https://sis.nipo.gov.ua/uk/search/detail/1844354/ (дата звернення: 28.02.2025)

51. AlGhatrif M., Lindsay J. A brief review: history to understand fundamentals of electrocardiography. Journal of Community Hospital Internal Medicine Perspectives. 2012. Vol. 2, no. 1. URL: https://doi.org/10.3402/jchimp.v2i1.14383 (date of access: 18.11.2024).

52. Електрокардіографія. https://en.wikipedia.org/wiki/Electrocardiography (дата звернення: 24.11.2024).

53. Серцево-судинні захворювання. Класифікація, стандарти діагностики та лікування / уклад.: В. М. Коваленко та ін. Київ : МОРІОН, 2016. 189 с.

Deschênes I., Fu J.-D. 54. Yang D., Multilayer control of cardiac electrophysiology by microRNAs. Journal of Molecular and Cellular Cardiology. 2022. Vol. 166. P. 107–115. URL: https://doi.org/10.1016/j.yjmcc.2022.02.007 (date of access: 16.01.2025).

55. Classification of Cardiac Signals with Automated R-Peak Detection Using Wavelet Transform Method / S. Saxena et al. Wireless Personal Communications. 2022. Vol. 123, no. 1. P. 655–669. URL: https://doi.org/10.1007/s11277-021-09151-2 (date of access: 20.11.2024).

56. Rajani Kumari L. V., Padma Sai Y., Balaji N. R-Peak Identification in ECG Signals using Pattern-Adapted Wavelet Technique. IETE Journal of Research. 2021. P. 1-10. URL: https://doi.org/10.1080/03772063.2021.1893229 (date of access: 20.11.2024).

57. Saxena S., Mahapatra P., Rizvi A. Z. Construction of wavelet using Mestimation and its Application in R-peak detection*. 2023 International Conference on Recent Advances in Electrical, Electronics & Digital Healthcare Technologies

URL:

(*REEDCON*), New Delhi, India, 1–3 May 2023. 2023. URL: https://doi.org/10.1109/reedcon57544.2023.10151449 (date of access: 28.11.2024).

58. XU W., DU F. A robust QRS complex detection method based on Shannon energy envelope and Hilbert transform. *Journal of Mechanics in Medicine and Biology*. 2022. URL: https://doi.org/10.1142/s0219519422400139 (date of access: 20.11.2024).

59. Nguyen D.-H., Nguyen M.-T., Le H.-C. An Efficient Electrocardiogram Rpeak Detection Exploiting Ensemble Empirical Mode Decomposition and Hilbert Transform. 2022 International Conference on Advanced Technologies for Communications (ATC), Ha Noi, Vietnam, 20–22 October 2022. 2022. URL: https://doi.org/10.1109/atc55345.2022.9942984 (date of access: 20.11.2024).

60. A filter design method based on evolutionary learning for R-peak detection in portable ECG testing devices / Z. Hao et al. *Biomedical Signal Processing and Control*. 2024. Vol. 88. URL: https://doi.org/10.1016/j.bspc.2023.105649 (date of access: 25.11.2024).

61. Cai W., Hu D. QRS Complex Detection Using Novel Deep Learning Neural Networks. *IEEE Access.* 2020. Vol. 8. P. 97082–97089. URL: https://doi.org/10.1109/access.2020.2997473 (date of access: 20.11.2024).

62. Robust R-Peak Detection in Low-Quality Holter ECGs using 1D Convolutional Neural Network / M. U. Zahid et al. *IEEE Transactions on Biomedical Engineering*. 2021. P. 1. URL: https://doi.org/10.1109/tbme.2021.3088218 (date of access: 20.11.2024).

63. Automatic detection of QRS complexes using dual channels based on U-Net and bidirectional long short-term memory / R. He et al. *IEEE Journal of Biomedical and Health Informatics*. 2020. P. 1. DOI: https://doi.org/10.1109/jbhi.2020.3018563 (date of access: 20.11.2024).

64. Robust R-peak detection in an electrocardiogram with stationary wavelet transformation and separable convolution / D. Yun et al. *Scientific Reports*. 2022. Vol. 12, no. 1. URL: https://doi.org/10.1038/s41598-022-19495-9 (date of access: 28.11.2024).

65. A New and Lightweight R-Peak Detector Using the TEDA Evolving Algorithm /
L. M. D. d. Silva et al. *Machine Learning and Knowledge Extraction*. 2024. Vol. 6, no. 2.
P. 736–750. URL: https://doi.org/10.3390/make6020034 (date of access: 25.11.2024).

66. Chen H., Maharatna K. An Automatic R and T Peak Detection Method Based on the Combination of Hierarchical Clustering and Discrete Wavelet Transform. *IEEE Journal of Biomedical and Health Informatics*. 2020. Vol. 24, no. 10. P. 2825–2832. URL: https://doi.org/10.1109/jbhi.2020.2973982 (date of access: 25.11.2024).

67. Bachi L., Billeci L., Varanini M. QRS Detection Based on Medical Knowledge and Cascades of Moving Average Filters. *Applied Sciences*. 2021. Vol. 11, no. 15. URL: https://doi.org/10.3390/app11156995 (date of access: 25.11.2024).

68. Porr B., Macfarlane P. W. A new QRS detector stress test combining temporal jitter and F-score (JF) reveals significant performance differences amongst popular detectors. *PLOS ONE*. 2024. Vol. 19, no. 11. URL: https://doi.org/10.1371/journal.pone.0309739 (date of access: 28.11.2024).

69. Pan J., Tompkins W. J. A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*. 1985. BME-32, no. 3. P. 230–236. URL: https://doi.org/10.1109/tbme.1985.325532 (date of access: 28.11.2024).

70. Ahmad I. QRS detection for heart rate monitoring. *International journal of electrical engineering and technology*. 2020. Vol. 11, no. 4. URL: https://doi.org/10.34218/ijeet.11.4.2020.040 (date of access: 28.11.2024).

71. Xiong H., Liang M., Liu J. A Real-Time QRS Detection Algorithm Based on Energy Segmentation for Exercise Electrocardiogram. *Circuits, Systems, and Signal Processing*. 2021. Vol. 40, no. 10. P. 4969–4985. URL: https://doi.org/10.1007/s00034-021-01702-z (date of access: 28.11.2024).

72. Accurate classification of ECG arrhythmia using MOWPT enhanced fast compression deep learning networks / J.-S. Huang et al. *Journal of Ambient Intelligence and Humanized Computing*. 2020. DOI: 10.1007/s12652-020-02110-y (date of access: 20.11.2024).

73. Arrhythmic Heartbeat Classification Using Ensemble of Random Forest and Support Vector Machine Algorithm / S. Bhattacharyya et al. *IEEE Transactions on*

Artificial Intelligence. 2021. Vol. 2, no. 3. P. 260–268. URL: https://doi.org/10.1109/tai.2021.3083689 (date of access: 20.11.2024).

74. Lekhal R., Zidelmal Z., Ould-Abdesslam D. Optimized time–frequency features and semi-supervised SVM to heartbeat classification. *Signal, Image and Video Processing*. 2020. Vol. 14, no. 7. P. 1471–1478. URL: https://doi.org/10.1007/s11760-020-01681-9 (date of access: 21.11.2024).

75. Yang H., Wei Z. Arrhythmia Recognition and Classification Using Combined Parametric and Visual Pattern Features of ECG Morphology. *IEEE Access*. 2020. Vol. 8. P. 47103–47117. URL: https://doi.org/10.1109/access.2020.2979256 (date of access: 24.11.2024).

76. A Novel Personalized Incremental Arrhythmias Classification Method for ECG Monitoring / Z. Li et al. *Fuzzy Systems and Data Mining IX*. 2023. URL: https://doi.org/10.3233/faia231099 (date of access: 25.11.2024).

77. An Open Access Database for Evaluating the Algorithms of Electrocardiogram Rhythm and Morphology Abnormality Detection / F. Liu et al. *Journal of Medical Imaging and Health Informatics*. 2018. Vol. 8, no. 7. P. 1368–1373. URL: https://doi.org/10.1166/jmihi.2018.2442 (date of access: 25.11.2024).

78. A multiclass CNN cascade model for the clinical detection support of cardiac arrhythmia based on subject-exclusive ECG dataset / C. Liotto et al. *Biomedical Engineering Letters*. 2022. URL: https://doi.org/10.1007/s13534-022-00246-8 (date of access: 21.11.2024).

79. Detection of Arrhythmia Heartbeats from ECG Signal Using Wavelet Transform-Based CNN Model / S. K. Pandey et al. *International Journal of Computational Intelligence Systems*. 2023. Vol. 16, no. 1. URL: https://doi.org/10.1007/s44196-023-00256-z (date of access: 25.11.2024).

80. A hybrid deep learning network for automatic diagnosis of cardiac arrhythmia based on 12-lead ECG / X. Bai et al. *Scientific Reports*. 2024. Vol. 14, no. 1. URL: https://doi.org/10.1038/s41598-024-75531-w (date of access: 24.11.2024).

81. Dong X., Si W. Heartbeat Dynamics: A Novel Efficient Interpretable Feature for Arrhythmias Classification. *IEEE Access*. 2023. Vol. 11. P. 87071–87086. URL: https://doi.org/10.1109/access.2023.3305473 (date of access: 21.11.2024).

82. Classification of cardiac arrhythmia using a convolutional neural network and bi-directional long short-term memory / S. U. Hassan et al. DIGITAL HEALTH. 2022. Vol. 8. URL: https://doi.org/10.1177/20552076221102766 (date of access: 17.03.2025).

83. A LSTM and CNN Based Assemble Neural Network Framework for Arrhythmias Classification / F. Liu et al. *ICASSP 2019 – 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Brighton, United Kingdom, 12–17 May 2019. 2019. URL: https://doi.org/10.1109/icassp.2019.8682299 (date of access: 28.11.2024).

84. A lightweight hybrid CNN-LSTM explainable model for ECG-based arrhythmia detection / N. Alamatsaz et al. *Biomedical Signal Processing and Control*. 2024. Vol. 90. URL: https://doi.org/10.1016/j.bspc.2023.105884 (date of access: 23.11.2024).

85. An Arrhythmia Classification Model Based on a CNN-LSTM-SE Algorithm / A. Sun et al. Sensors. 2024. Vol. 24, no. 19. P. 6306. URL: https://doi.org/10.3390/s24196306 (date of access: 24.11.2024).

 Rohmantri R., Surantha N. Arrhythmia Classification using 2D Convolutional Neural Network. *International Journal of Advanced Computer Science and Applications*.
 2020. Vol. 11, no. 4. URL:https://doi.org/10.14569/ijacsa.2020.0110427 (date of access: 28.11.2024).

87. Giriprasad Gaddam P., Sanjeeva reddy A., Sreehari R. V. Automatic Classification of Cardiac Arrhythmias based on ECG Signals Using Transferred Deep Learning Convolution Neural Network. *Journal of Physics: Conference Series*. 2021. Vol. 2089, no. 1. URL: https://doi.org/10.1088/1742-6596/2089/1/012058 (date of access: 28.11.2024).

88. Karapinar Senturk Z. From signal to image: An effective preprocessing to enable deep learning-based classification of ECG. *Materials Today: Proceedings*. 2022. URL: https://doi.org/10.1016/j.matpr.2022.10.223 (date of access: 24.11.2024).

89. Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation / A. Ullah et al. *Remote Sensing*. 2020. Vol. 12, no. 10. P. 1685. URL: https://doi.org/10.3390/rs12101685 (date of access: 28.11.2024).

90. Classify arrhythmia by using 2D spectral images and deep neural network / T. A. Vu et al. *Indonesian Journal of Electrical Engineering and Computer Science*. 2022. Vol. 25, no. 2. P. 931. URL: https://doi.org/10.11591/ijeecs.v25.i2.pp931-940 (date of access: 28.11.2024).

91. Jat T., Patil N., Bhat P. Detection of heart arrhythmia with electrocardiography. *Network Modeling Analysis in Health Informatics and Bioinformatics*. 2024. Vol. 13, no.
1. URL: https://doi.org/10.1007/s13721-024-00487-w (date of access: 24.11.2024).

92. ECG Arrhythmia Classification Using Convolutional Neural Network / E. Abdelhafid et al. *International Journal of Emerging Technology and Advanced Engineering*. 2022. Vol. 12, no. 7. P. 186–195. URL: https://doi.org/10.46338/ijetae0722_19 (date of access: 28.11.2024).

93. Singh P., Sharma A. Interpretation and Classification of Arrhythmia using Deep Convolutional Network. *IEEE Transactions on Instrumentation and Measurement*. 2022. P. 1. URL: https://doi.org/10.1109/tim.2022.3204316 (date of access: 28.11.2024).

94. An explainable attention-based TCN heartbeats classification model for arrhythmia detection / Y. Zhao et al. *Biomedical Signal Processing and Control*. 2023. Vol. 80. URL: https://doi.org/10.1016/j.bspc.2022.104337 (date of access: 23.11.2024).

95. Deep Learning for ECG Analysis: Benchmarks and Insights from PTB-XL / N. Strodthoff et al. IEEE J. Biomed. *Health Inform*. 2020. URL: https://doi.org/10.48550/arXiv.2004.13701 (date of access: 23.11.2024).

96. Analysis of a Deep Learning Model for 12-Lead ECG Classification Reveals Learned Features Similar to Diagnostic Criteria / T. Bender et al. *IEEE Journal of Biomedical and Health Informatics*. 2023. P. 1–12, URL: https://doi.org/10.1109/jbhi.2023.3271858 (date of access: 23.11.2024).

97. Classification of vasovagal syncope from physiological signals on tilt table testing / M. Ferdowsi et al. *BioMedical Engineering OnLine*. 2024. Vol. 23, no. 1. URL: https://doi.org/10.1186/s12938-024-01229-9 (date of access: 24.11.2024).

98. Interpreting Deep Neural Networks for Single-Lead ECG Arrhythmia Classification / S. Vijayarangan et al. *Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Montreal, QC, Canada, 20–24 July 2020. 2020. URL: https://doi.org/10.1109/embc44109.2020.9176396 (date of access: 28.11.2024).

99. Martono N. P., Nishiguchi T., Ohwada H. Interpreting Arrhythmia Classification Using Deep Neural Network and CAM-Based Approach. *ICCBB 2022:* 2022 6th International Conference on Computational Biology and Bioinformatics, Bali Island Indonesia. New York, NY, USA, 2022. URL: https://doi.org/10.1145/3589437.3589443 (date of access: 28.11.2024).

100. Explainable Deep Learning-Based Approach for Multilabel Classification of Electrocardiogram / G. M. et al. *IEEE Transactions on Engineering Management*. 2021.
P. 1–13. URL: https://doi.org/10.1109/tem.2021.3104751 (date of access: 22.11.2024).

101. Shobanadevi A., Veeramakali T. Classification and Interpretation of ECG Arrhythmia through Deep Learning Techniques. *Research Square Platform LLC*. 2023. URL: https://doi.org/10.21203/rs.3.rs-xyz123/v1 (date of access: 24.11.2024).

102. X-ECGNet: An Interpretable DL model for Stress Detection using ECG in COVID-19 Healthcare Workers / A. Gupta et al. 2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART), Paris / Créteil, France, 8–10 December 2021. 2021. URL: https://doi.org/10.1109/biosmart54244.2021.9677750 (date of access: 23.11.2024).

103. Intelligent Interpretation and Classification of Multivariate Medical Time Series Based on Convolutional Neural Networks / T. Xu et al. *Health Information Science*. Cham, 2022. P. 291–302. URL: https://doi.org/10.1007/978-3-031-20627-6_27 (date of access: 25.11.2024).

104. Verma S. Development of Interpretable Machine Learning Models to DetectArrhythmiabasedonECGData.arXiv.2022.DOI:https://doi.org/10.48550/arXiv.2205.02803 (date of access: 28.11.2024).

105. Meelu L., Assres G. M. Explaining Predicted Stress Levels in employed Individuals. *ICMLT 2024: 2024 9th International Conference on Machine Learning* *Technologies*, Oslo Norway. New York, NY, USA, 2024. P. 133–137. URL: https://doi.org/10.1145/3674029.3674051 (date of access: 23.11.2024).

106. Garreau D., Luxburg U. Explaining the Explainer: A First Theoretical Analysis of LIME. *23 International Conference on Artificial Intelligence and Statistics (AISTATS)*, Palermo, Italy. 2020. URL: https://doi.org/10.48550/arXiv.2001.03447 (date of access: 23.11.2024).

107. Meng H., Wagner C., Triguero I. An Initial Step Towards Stable Explanations for Multivariate Time Series Classifiers with LIME. 2023 IEEE International Conference on Fuzzy Systems (FUZZ), Incheon, Korea, Republic of, 13–17 August 2023. 2023. URL: https://doi.org/10.1109/fuzz52849.2023.10309814 (date of access: 24.11.2024).

108. B-LIME: An Improvement of LIME for Interpretable Deep Learning Classification of Cardiac Arrhythmia from ECG Signals / T. A. A. Abdullah et al. *Processes*. 2023. Vol. 11, no. 2. P. 595. URL: https://doi.org/10.3390/pr11020595 (date of access: 23.11.2024).

109. Visania G., Baglib E., Chesania F. OptiLIME: Optimized LIME Explanations for Diagnostic Computer Algorithms. *Proceedings of the CIKM 2020 Workshops*, Galway, Ireland, 19–20 October. 2020. URL: https://doi.org/10.48550/arXiv.2006.05714 (date of access: 23.11.2024).

110. G-LIME: Statistical learning for local interpretations of deep neural networks using global priors / X. Li et al. *Artificial Intelligence*. 2023. Vol. 314. URL: https://doi.org/10.1016/j.artint.2022.103823 (date of access: 24.11.2024).

111. Shankaranarayana S. M., Runje D. ALIME: Autoencoder Based Approach for Local Interpretability. *Intelligent Data Engineering and Automated Learning – IDEAL 2019.* Cham, 2019. P. 454–463. URL: https://doi.org/10.1007/978-3-030-33607-3_49 (date of access: 24.11.2024).

112. Explainable Deep Learning Model for Cardiac Arrhythmia Classification / T. A. A. Abdullah et al. 2022 International Conference on Future Trends in Smart Communities (ICFTSC), Kuching, Sarawak, Malaysia, 1–2 December 2022. 2022. URL: https://doi.org/10.1109/icftsc57269.2022.10039860 (date of access: 23.11.2024).

113. Michelucci U. An Introduction to Autoencoders. *arXiv*. 2022. URL: https://doi.org/10.48550/arXiv.2201.03898 (date of access: 23.11.2024).

114. Vujovic Ž. Đ. Classification Model Evaluation Metrics. *International Journal of Advanced Computer Science and Applications*. 2021. Vol. 12, no. 6. URL: https://doi.org/10.14569/ijacsa.2021.0120670 (date of access: 19.11.2024).

115. Fahmy Amin M. Confusion Matrix in Binary Classification Problems: A Stepby-Step Tutorial. *Journal of Engineering Research*. 2022. Vol. 6, no. 5. URL: https://doi.org/10.21608/erjeng.2022.274526 (date of access: 19.11.2024).

116. Vujovic Ž. Đ. Classification Model Evaluation Metrics. *International Journal of Advanced Computer Science and Applications*. 2021. Vol. 12, no. 6. URL: https://doi.org/10.14569/ijacsa.2021.0120670 (date of access: 25.11.2024).

117. Deep ROC Analysis and AUC as Balanced Average Accuracy, for Improved Classifier Selection, Audit and Explanation / A. M. Carrington et al. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2022. P. 1. URL: https://doi.org/10.1109/tpami.2022.3145392 (date of access: 19.11.2024).

118. Heydarian M., Doyle T. E., Samavi R. MLCM: Multi-Label Confusion Matrix.IEEEAccess.2022.Vol.10.P.19083–19095.URL:https://doi.org/10.1109/access.2022.3151048 (date of access: 19.11.2024).

119. Multiclass classification evaluation with ROC Curves and ROC AUC. URL: https://towardsdatascience.com/multiclass-classification-evaluation-with-roc-curves-and-roc-auc-294fd4617e3a (date of access: 18.11.2024).

120. Generalizing AUC Optimization to Multiclass Classification for Audio Segmentation With Limited Training Data / P. Gimeno et al. *IEEE Signal Processing Letters*. 2021. Vol. 28. P. 1135–1139. URL: https://doi.org/10.1109/lsp.2021.3084501 (date of access: 20.11.2024).

121. Evaluating artificial intelligence in medicine: phases of clinical research / Y. Park et al. *JAMIA Open.* 2020. Vol. 3, no. 3. P. 326–331. URL: https://doi.org/10.1093/jamiaopen/ooaa033 (date of access: 19.11.2024).

122. Assessing Inter-Annotator Agreement for Medical Image Segmentation / F. Yang et al. *IEEE Access.* 2023. Vol. 11. P. 21300–21312. URL: https://doi.org/10.1109/access.2023.3249759 (date of access: 19.11.2024).

123. A knowledge-based deep learning method for ECG signal delineation / J. Wang et al. *Future Generation Computer Systems*. 2020. Vol. 109. P. 56–66. URL: https://doi.org/10.1016/j.future.2020.02.068 (date of access: 28.11.2024).

124. BinaryCrossEntropyLoss.URL:https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html(dateofaccess:24.11.2024).

125. What makes binary cross entropy a better choice for binary classification than other loss functions? URL: https://datascience.stackexchange.com/questions/53400/what-makes-binary-cross-entropy-a-better-choice-for-binary-classification-than-o (date of access: 24.11.2024).

126. How to Choose Loss Functions When Training Deep Learning Neural Networks. URL: https://machinelearningmastery.com/how-to-choose-loss-functions-when-training-deep-learning-neural-networks/ (date of access: 28.11.2024).

127. Adaptive Moment Estimation. URL: https://medium.com/@nerdjock/deep-learning-course-lesson-7-4-adam-adaptive-moment-estimation-e23434850bfc (date of access: 24.11.2024).

128. Gentle Introduction to the Adam Optimization Algorithm for Deep Learning. URL: https://machinelearningmastery.com/adam-optimization-algorithm-for-deeplearning/ (date of access: 28.11.2024).

129. Adaptive Moment Estimation. Difference between Adam and SGD. URL: https://codeahoy.com/questions/ds-interview/33/ (date of access: 24.11.2024).

130. Introduction to convolutional neural networks (CNN). URL: https://www.educative.io/blog/introduction-to-convolutional-neural-networks (date of access: 24.11.2024).

131. A Mean Field Theory of Batch Normalization / G. Yang et al. *arXiv*. 2019. URL: https://doi.org/10.48550/arXiv.1902.08129 (date of access: 28.11.2024).

132. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. Journal of Machine Learning Research / N. Srivastava et al. *Journal of Machine Learning Research*. 2014. Vol. 15. P. 1929–1958, 15, 1929–1958.

133. About PyTorch Lightning. URL: https://lightning.ai/about (date of access: 24.11.2024).

134. Optuna / T. Akiba et al. KDD '19: *The 25th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, Anchorage AK USA. New York, NY, USA, 2019. URL: https://doi.org/10.1145/3292500.3330701 (date of access: 28.11.2024).

135. Optuna Repository. URL: https://github.com/optuna/optuna (date of access: 24.11.2024).

136. Kherif F., Latypova A. Principal component analysis. *Machine Learning*. 2020.
P. 209–225. URL: https://doi.org/10.1016/b978-0-12-815739-8.00012-2 (date of access: 28.11.2024).

137. Borg I., Groenen P. J. F., Mair P. Computer Programs for MDS. *Applied Multidimensional Scaling*. Berlin, Heidelberg, 2012. P. 87–107. URL: https://doi.org/10.1007/978-3-642-31848-1_9 (date of access: 28.11.2024).

138. A Preprocessing Manifold Learning Strategy Based on t-Distributed Stochastic Neighbor Embedding / S. Shi et al. *Entropy*. 2023. Vol. 25, no. 7. P. 1065. URL: https://doi.org/10.3390/e25071065 (date of access: 28.11.2024).

139. NeuroKit2: A Python toolbox for neurophysiological signal processing / D. Makowski et al. *Behavior Research Methods*. 2021. Vol. 53, no. 4. P. 1689–1696. URL: https://doi.org/10.3758/s13428-020-01516-y (date of access: 28.11.2024).

140. Про прийняття та скасування національних стандартів, прийняття змін до національних стандартів : наказ Українського науково-дослідного і навчального центру проблем стандартизації, сертифікації та якості від 18.12.2019 р. № 438. м. Київ. URL: https://zakon.rada.gov.ua/rada/show/v0438774-19 (дата звернення: 25.01.2025).

141. Moody G. B., Mark R. G. The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*. 2001. Vol. 20, no. 3. P. 45–50. URL: https://doi.org/10.1109/51.932724 (date of access: 28.11.2024).

142. A database for evaluation of algorithms for measurement of QT and other waveform intervals in the ECG / P. Laguna et al. *Computers in Cardiology 1997*, Lund, Sweden. URL: https://doi.org/10.1109/cic.1997.648140 (date of access: 28.11.2024).

143. The 3rd China Physiological Signal Challenge 2020. URL: https://paperswithcode.com/dataset/cpsc2020 (date of access: 24.11.2024).

144. Howell L., Porr B. High precision ECG Database with annotated R peaks, recorded and filmed under realistic conditions. 2018. DOI: https://doi.org/10.5525/gla.researchdata.716 (date of access: 28.11.2024).

145. Rodrigues R., Couto P. Semi-Supervised Learning for ECG Classification. 2021 Computing in Cardiology (CinC), Brno, Czech Republic, 13–15 September 2021. 2021. URL: https://doi.org/10.23919/cinc53138.2021.9662693 (date of access: 28.11.2024).

146. Koka T., Muma M. Fast and Sample Accurate R-Peak Detection for Noisy ECG Using Visibility Graphs. 2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Glasgow, Scotland, United Kingdom, 11–15 July 2022. 2022. URL: https://doi.org/10.1109/embc48229.2022.9871266 (date of access: 28.11.2024).

147. Штучний інтелект в медицині: чи загрожують інновації правам людини? URL: https://www.helsinki.org.ua/articles/shtuchnyy-intelekt-v-medytsyni-chyzahrozhuiut-innovatsii-pravam-liudyny (date of access: 5.03.2025).

148. Classifying Cardiac Arrhythmia from ECG Signal Using 1D CNN Deep Learning Model / A. A. Ahmed et al. *Mathematics*. 2023. Vol. 11, no. 3. P. 562. URL: https://doi.org/10.3390/math11030562 (date of access: 28.11.2024).

149. Fuzz-ClustNet:Coupled fuzzy clustering and deep neural networks forArrhythmia detection from ECG signals / S. Kumar et al.Computers in Biology andMedicine.2023.Vol.153.P.106511,URL:https://doi.org/10.1016/j.compbiomed.2022.106511 (date of access: 28.11.2024).

150. Ensemble Deep Learning Approach for ECG-Based Cardiac Disease Detection: Signal and Image Analysis / T. Mahmud et al. 2023 International Conference on Information and Communication Technology for Sustainable Development

(*ICICT4SD*), Dhaka, Bangladesh, 21–23 September 2023. 2023. URL: https://doi.org/10.1109/icict4sd59951.2023.10303625 (date of access: 28.11.2024).

151. Open Source Computer Vision Library. URL: https://opencv.org/about/ (date of access: 28.11.2024).

ДОДАТОК А

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Статті у періодичних виданнях, включених до категорії «А»

Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних Web of Science Core Collection ma/abo Scopus:

1. Towards transparent AI in medicine: ECG-based arrhythmia detection with explainable deep learning / O. Kovalchuck et a. Technologies. 2025. Vol. 13, no. 1. P. 34. (<u>https://doi.org/10.3390/technologies13010034</u>) (*iндексована у наукометричних базах Scopus, Web of Science (Q1 by Scimago Journal & Country Rank)*

Статті у наукових виданнях,

включених до Переліку наукових фахових видань України:

Ковальчук О. В., Бармак О. В. Метод класифікації аритмій на ЕКГ-сигналі.
 Оптико-електронні інформаційно-енергетичні технології. 2024. Т. 48, № 2. С. 34–
 44. (https://doi.org/10.31649/1681-7893-2024-48-2-34-44).

3. Ковальчук О. В., Бармак О. В. Метод ідентифікації R-піків у сигналах електрокардіограми. *Вісник Хмельницького національного університету*. 2024. № 6. С. 108-117. (https://doi.org/10.31891/2307-5732-2024-343-6-16).

4. Ковальчук О. В., Бармак О. В. Метод інтерпретації результатів класифікації ЕКГ методами глибокого навчання. *Проблеми моделювання та автоматизації проектування*. 2024. Т. 2, № 20. С. 120–130. (<u>https://doi.org/10.31474/2074-7888-2024-</u> 2-20-120-130).

Публікації, які засвідчують апробацію матеріалів дисертації:

5. Human-in-the-loop approach based on MRI and ECG for healthcare diagnosis / P. Radiuk et a. *CEUR-WS*. 2022. T. 3302. C. 9–20. URL: <u>https://ceur-ws.org/Vol-3302/paper1.pdf</u> (*iндексована в наукометричній базі Scopus*).

6. A novel feature vector for ECG classification using deep learning / O. Kovalchuk et a. *CEUR-WS*. 2023. T. 3373. C. 227-238. URL: <u>https://ceur-ws.org/Vol-3373/paper12.pdf</u> (*iндексована в наукометричній базі Scopus*).

7. Kovalchuk O., Radiuk P., Barmak O. та Krak Iu. Robust R-peak detection using deep learning based on integrating domain knowledge. CEUR-WS. 2023. Т. 3609. С. 1-14. URL: <u>https://ceur-ws.org/Vol-3609/paper1.pdf</u> (*iндексована в наукометричній базі Scopus*).

8. Kovalchuk O., Radiuk P., Barmak O. та Krak Iu. ECG Arrhythmia Classification and Interpretation using Convolutional Networks for Intelligent IoT Healthcare System. *CEUR-WS*. 2024. Т. 3736. С. 47–62. URL: <u>https://ceur-ws.org/Vol-3736/paper4.pdf</u> (*iндексована в наукометричній базі Scopus*).

Свідоцтва про реєстрацію авторського права на твір

9. А. с. 132579 Україна. Комп'ютерна програма «Класифікація ЕКГ на наявність аритмій з подальшою інтерпретацією результатів» / О. В. Ковальчук, О. В. Бармак, П. М. Радюк. 2025, URL: <u>https://sis.nipo.gov.ua/uk/search/detail/1844354/</u>.

ДОДАТОК Б. АКТИ ВПРОВАДЖЕННЯ



Лікувально-діагностичний центр «Сіліцея-СПТІ» м.Хмельницький проспект Миру, 84/1 +38(096)083-03-03 e-mail: <u>silicea.city@gmail.com</u>

ДОВІДКА

про застосування результатів наукових досліджень

за темою дисертаційної роботи

Ковальчука Олексія Володимировича

Результати дисертаційної роботи Ковальчука Олексія Володимировича за темою «Методи

виявлення патологій серця за сигналом електрокардіограми засобами пояснювального штучного

інтелекту», а саме інформаційна технологія виявлення патологій серця за сигналом

електрокардіограми була використана у вигляді експериментального рішення в роботі медичного центру «Сіліцея Сіті+» для цифрового діагностування патологій серця за сигналом електрокардіограми з

допомогою засобів комп'ютерної діагностики. Застосування здійснювалося у вигляді

комп'ютерного додатку.

Директор МЦ «Сіліцея Сіті+»

Lyneise HP J.



довідка

№

про впровадження результатів дисертаційної роботи Ковальчука Олексія Володимировича «Методи виявлення патологій за сигналом електрокардіограми засобами пояснювального штучного інтелекту»

У процесі виробничої діяльності ТОВ «АЙ ТІ ХУТ» м.Хмельницького знайшли застосування наступні результати дисертаційної роботи Ковальчука Олексія Володимировича «Методи виявлення патологій за сигналом електрокардіограми засобами пояснювального штучного інтелекту»:

 метод ідентифікації R-піків у ЕКГ сигналах із використанням моделі глибокого навчання та інтеграцією доменних знань;

 метод класифікації патологій (аритмій) на ЕКГ сигналі із застосуванням згорткової нейронної мережі;

 метод пояснення отриманих результатів класифікації сигналів ЕКГ за зрозумілими лікарю ознаками;

У ТОВ «АЙ ТІ ХУТ» зазначені результати використовуються в процесі розроблення промислового програмного забезпечення для створення інформаційних технологій у модулях обробки ЕКГ сигналів. Запропоновані в дисертації методи слугують теоретичним підгрунтям для реалізації модулів систем, які автоматизують роботу лікаря.

ВО Директора

УКРАЇНА Міністерство освіти і науки України **ХМЕЛЬНИЦЬКИЙ** НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ Ідентифікаційний код 02071234 29016 бул.Інститутська, 11, м.Хмельницький 20___p. Ns

Зав. кафедрою д.т.н, професору Олександру БАРМАКУ

Довідка

Аспірант кафедри комп'ютерних наук Ковальчук Олексій Володимирович брав участь з оплатою праці у виконанні держбюджетної теми № 2Б-2024 «Система виявлення ЗПЗ та комп'ютерних атак в корпоративних мережах з використанням хибних об'єктів атак та пасток» (номер державної реєстрації 0124U000980)

Проректор з наукової роботи

X * 13

Синник Олег СИНЮК



АКТ

про впровадження в навчальний процес результатів досліджень аспіранта Ковальчука Олексія Володимировича за темою дослідження «Методи виявлення патологій за сигналом електрокардіограми засобами пояснювального штучного інтелекту»

Результати дисертаційної роботи Ковальчука О.В., а саме, інтелектуальні методи обробки медичних сигналів (ЕКГ сигнали), використовуються в навчальному процесі при викладанні дисциплін бакалаврського рівня «Інтелектуальний аналіз даних», «Методи та системи штучного інтелекту», та магістерського рівня «Методи, засоби та алгоритми в задачах обчислювального інтелекту та комп'ютерного зору», виконанні кваліфікаційних робіт бакалаврів та магістрів спеціальності "Комп'ютерні науки".

Акт обговорений і схвалений на засіданні кафедри комп'ютерних наук (протокол № 4 від 27 листопада 2024 р.).

Зав. каф. комп'ютерних наук, д.т.н., професор Секретар кафедри КН, ст.викладач

О.В. Бармак

Т.К. Скрипник

ДОДАТОК В. АВТОРСЬКЕ СВІДОЦТВО

KTPA INH



№ 132579

Комп'ютерна програма «Класифікація ЕКГ на наявність аритмій з подальшою інтерпретацією результатів»

(вид, назва твору)

Автор (співавтори) Ковальчук Олексій Володимирович, Бармак Олександр Володимирович, Радюк Павло Михайлович

(прізвище, ім'я, по батькові (за наявності), псевдонім (за наявності))

Авторські майнові права належать спільно Ковальчук Олексій Володимирович, Бармак Олександр

Володимирович, 1 Павло Михайлович,

(прізнице, ім'я, по батькові (за наниності) фізичної особи / найменування корядичної особи, адреса)

Дата ресстрації 13 січня 2025 р.

Виконувач обов'язків Директора Державної організації «Український національний офіс інтелектуальної власності та інновяцій»

A Mang

Любов МАЙДАНИК

Радюк

ДОДАТОК Г. ВИХІДНИЙ КОД

Вихідний код, який використовувався в дослідженні, наведено в ресурсі GitHub за посиланням: <u>https://github.com/okovalchuk98/ecg_processing_research</u> (дата звернення: 17.02.2024). На наступному рисунку наведено скріншот репозиторію:

ecg_processing_research (Public)	😒 Pin	• Unwatch	1 • % Fork 0	→ Star 0 →	
🐉 main 👻 🐉 1 Branch 🚫 0 Tags	Q Go to file t Add file +	<> Code 👻	About	ŝ	
🥺 okovalchuk98 Update label inside README.md	7b91406 · now	🕓 6 Commits	No description, website, or topics provided.		
Client	Added sample of WPF desktop client for communication wit	1 minute ago	শু ষ MIT license		
EcgProcessing	Added rest server implementation for processing ECG signal	5 minutes ago	 小 Activity ☆ 0 stars ⊙ 1 watching 		
🗋 .gitignore	Added .gitignore file	yesterday			
	Initial commit	yesterday	양 0 forks		
README.md	Update label inside README.md	now	Releases		
III README III Iicense		P	No releases published Create a new release		
ECG Processing Research			Packages No packages published Publish your first package		

Основна сторінка репозиторію

У папці EcgProcessing/Notebooks розташований набір Jupyter Notebook із скриптами для навчання мережі та проведення експериментів. У папці EcgProcessing/ ecg_analyzer_rest_server розташований приклад реалізації REST сервера для обробки запитів на аналіз ЕКГ-сигналу.

У папці Client розташована імплементація прикладу клієнтського додатка для комунікації з REST-сервером для аналізу ЕКГ-сигналу.