УДК 004.8 **DOI: 10.15330/itee.2026.4.07**

Ю.І. ПЕТРИНЯК, аспірант, І.Б. ПІРКО, канд. фіз.-мат. наук,

КЛАСИФІКАЦІЯ СЕРЦЕВИХ РИТМІВ НА ОСНОВІ АУДІОСИГНАЛІВ МЕТОДАМИ ГЛИБОКОГО НАВЧАННЯ

Вступ

Ритмічність серцевих скорочень, чистота тонів роботи клапанів серця є важливими діагностичними характеристиками стану здоров'я людини. Порушення частоти та сили серцевих скорочень може бути ознакою розвитку серйозних захворювань.

Зростаюча кількість захворювань серцево-судинної системи вимагає швидкої та якісної діагностики. Виявлення аномалій у звуках серцевого ритму відіграє важливу роль у діагностиці та прогнозуванні серцево-судинних захворювань. Використання цифрового стетоскопа та гарнітури для запису серцевих звуків на мобільний пристрій забезпечує зручність та доступність методів діагностики серцевих захворювань і може стати хорошим допоміжним методом діагностики для лікаря.

У сучасній медицині широко використовуються методи аналізу та моніторингу серцевого ритму з метою виявлення аномалій та покращення діагностики захворювань серця. При цьому технології машинного навчання дозволяють автоматизувати аналіз серцевих аудіозаписів, що допомагає у виявленні відхилень, підвищує ефективність роботи лікарів-кардіологів, забезпечуючи більш ранню діагностику захворювань та знижуючи ймовірність ускладнень у пацієнтів. Впровадження цифрових технологій дозволяє зменшити навантаження на лікарів, сприяє коректному вибору схем терапії та покращенню результатів лікування.

Популярні методи класифікації звукових сигналів серця можна розділити на дві категорії: методи, що базуються на машинному та глибокому навчанні. Найбільш популярними є дослідження, де використовується класифікація тонів серця за двома класами – нормальним та аномальним. Також є дослідження, де використовується класифікація за трьома класами.

Розглянуті методи показують, що, порівняно з традиційними методами, підходи глибокого навчання з використанням одновимірних нейронних мереж та рекурентних нейронних мереж більш ефективні та точні [1]. Також було розроблено деякі гібридні мережі глибокого навчання. Найбільш типові інтегровані методи ґрунтуються на моделях, які поєднують мережі CNN та RNN.

У [2,3] відзначено, що автоматична класифікація серцевих звуків є складною проблемою, яка відображається в сегментації тонів серця та отриманні ознак із відповідних результатів сегментації. У цих роботах використовувалися класичні моделі машинного навчання для класифікації звуків серця, такі як метод опорних векторів, дерево рішень, k-найближчих сусідів.

У роботі [4] класифікували звуки роботи серця на нормальні та два типи аномальних на підставі третього та четвертого тонів серця. Запропонована методологія дозволила отримати точність 87,5 % та 95 % для багатокласових даних (три класи) та 98 % для завдань бінарної класифікації (нормальні та ненормальні). Були розглянуті алгоритми методу опорних векторів, градієнтного підсилення та алгоритм випадковий ліс.

У роботах авторів [5, 6] спроби підвищити точність діагностики призвели до розробки моделі згорткової нейронної мережі (CNN) та модель LSTM, яка класифікує тони серця на 3 класи: нормальні, шуми та артефакти. Характеристики отримуються за допомогою Mel-Frequency Cepstral Coefficients (MFCC). Клас шумів свідчить про наявність серйозної проблеми. Показано, що модель здатна досягти точності 96,5 % для тестового набору даних.

У роботі [7] розглянуто класифікацію звукового сигналу серця за декількома ознаками: нормальна категорія та чотири патологічні. Для отримання ознак використовувався частотний

кепстральний коефіцієнт (MFCCs) та дискретне вейвлет-перетворення. Для класифікації використовувався алгоритм методу опорних векторів (SVM), глибока нейронна мережа (CNN). Авторами було отримано точність 96 % з використанням комбінації ознак дискретного вейвлет-перетворення та MFCC та їх навчання за допомогою SVM-класифікатора.

У дослідженнях [8,9] представлено автоматичний аналіз ЕКГ, що базується на цифровій обробці сигналів, що включає фільтрацію, перетворення Фур'є та аналіз частотно-часових рядів. Ці методи дозволяють суттєво прискорити процес діагностики і тому все частіше застосовуються у клінічних умовах.

Методи глибокого навчання стали добрим підходом для класифікації серцевих аномалій, що відповідають різним патологіям серця. Але все одно є проблеми, які полягають у недостатності даних, неефективності навчання та недостатньо потужних моделях, тому завдання виявлення аномалій серцебиття методами машинного навчання залишається актуальним до сьогодні [10].

Метою роботи є розробка методики на основі алгоритмів машинного навчання для виявлення серцево-судинних захворювань шляхом класифікації акустичних сигналів, що генеруються під час роботи серця.

Матеріали та методи дослідження.

Для дослідження обрано набір даних Classifying Heart Sounds, що містить 813 аудіофрагментів серцевих ритмів тривалістю від 1 до 30 секунд. У наборі представлені записи як здорових пацієнтів, так і осіб з аномаліями серцебиття, які розподілені за чотирма категоріями.

Категорія Normal визначає нормальне серцебиття.

Категорія Murmur описує записи звуків серця з характерними шумами, які можуть вказувати на патологію.

Категорія Extrasystole містить записи з додатковими скороченнями серця, відмінністю яких є відсутність звичайного серцевого тону і наявність додаткових або пропущених ударів.

Категорія Artefact характеризується наявністю сторонніх звуків, не пов'язаних із серцевою діяльністю, таких як мова, музика, шум.

Важливо, що дані були зібрані в реальних ситуаціях і можуть містити шуми різних типів, що значно розширює застосовність підходу. Відмінності між звуками серця, що відповідають різним серцевим симптомам, також можуть бути складними для поділу. Успіх у класифікації цієї форми даних потребує надійних класифікаторів.

Звукові хвилі різних видів роботи серця представлені на рисунку 1.

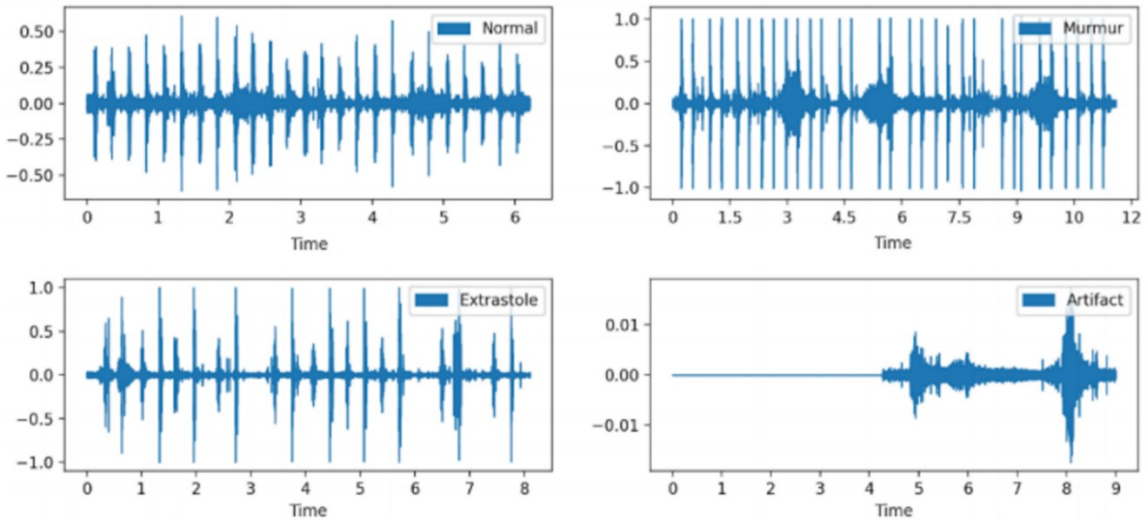


Рис. 1. Звукові сигнали серця.

Аналіз графіку нормального скорочення серця показує, що він характеризується рівномірним розподілом амплітуд та сталістю часових інтервалів між звуковими хвилями. Графік шумів серця виглядає менш впорядкованим, з багатьма додатковими звуковими хвилями, що виникають між основними ударами. Екстрасистолічні звуки виділяються вищою амплітудою і нерівномірністю інтервалів, що може свідчити про пропуски серцебиття. Графік артефактів наочно демонструє зашумлені дані, які можуть виникнути під час неправильного запису. Спектрограми аудіосигналів представлені на рисунку 2.

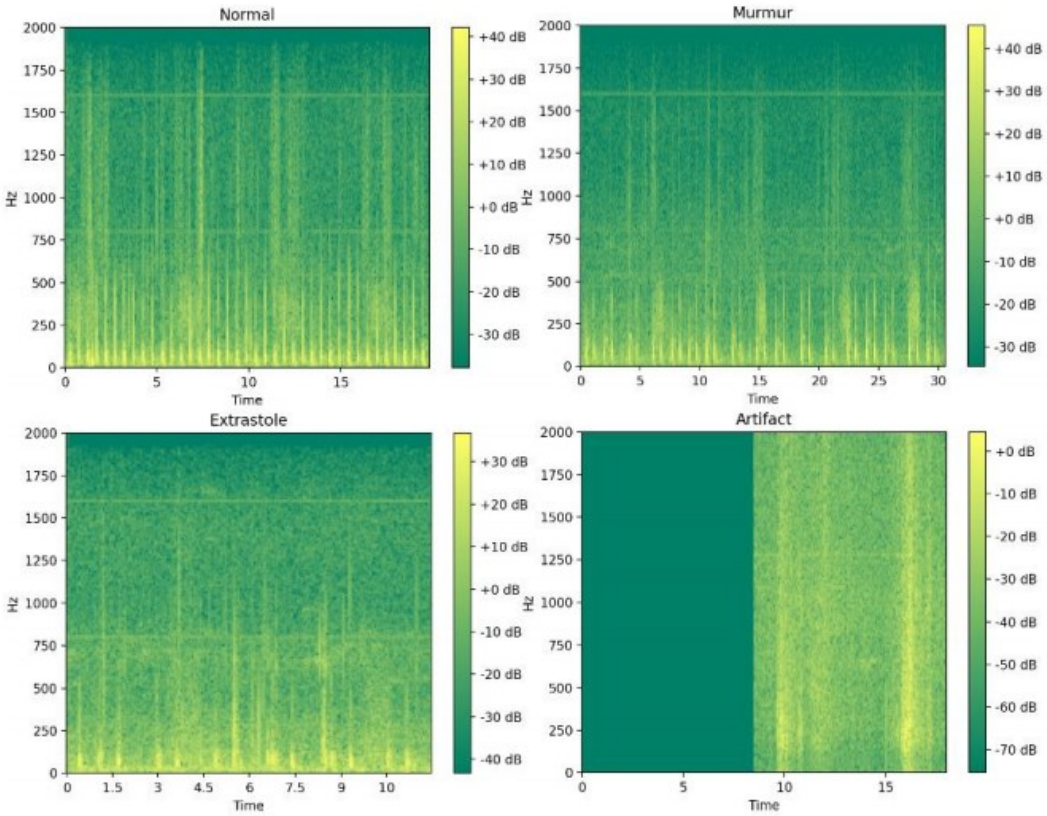


Рис. 2. Спектрограми звукових сигналів.

Спектрограми аудіосигналів, в яких амплітуда представлена жовтим кольором, дозволяють візуалізувати частотні характеристики звукових хвиль. Об’єднані записи серцевих ритмів представлені на рисунку 3.

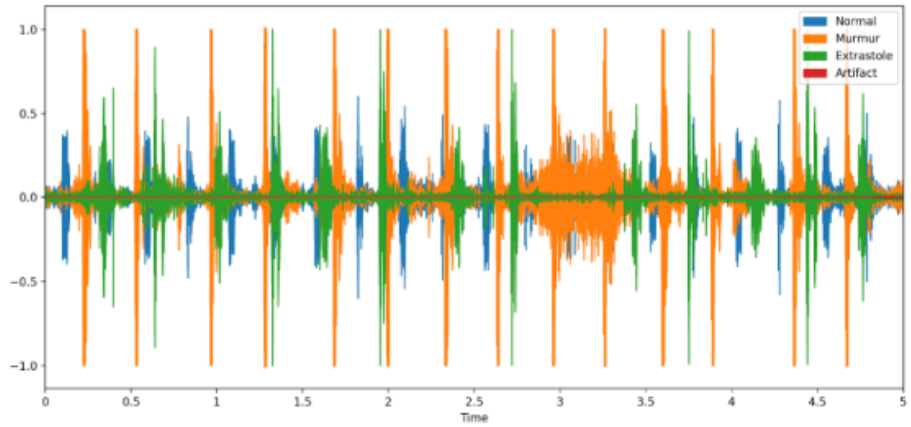


Рис. 3. Об’єднані записи серцевих ритмів.

ISSN 3083-7618 *Information Technologies and Engineering Electronics No. 4 (2026)*
eISSN 3083-7626

Комбіновані записи серцебиття (рис. 3) показують, що екстрасистоли характеризуються вищою амплітудою порівняно з нормальними звуками, а всі досліджувані типи серцебиття мають нерегулярний ритм. Відповідно до наявного набору даних задача розглядається як багатокласова класифікація аудіофайлів.

Загальна система класифікації звуків представлена на рисунку 4 і складається з трьох етапів: попередня обробка сигналу, метод отримання ознак і вибір методу класифікації.

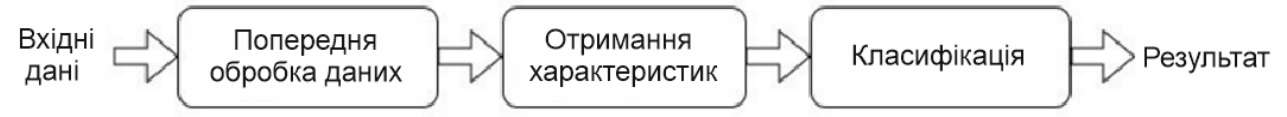


Рис. 4. Загальна схема класифікації аудіофайлів.

Попередня обробка включає очищення сигналу серцебиття, методи скорочення сигналу. Метод отримання ознак складається із завдання дискретизації сигналу, потім вилучення з отриманого сигналу різних його характеристик. Для оцінки точності в процесі контролю якості моделі, що розробляється, використовувалися такі метрики: точність (precision), повнота (recall) і F1-міра – середня гармонійна точності та повноти.

Попередня обробка аудіофайлів, що містять записи серцевих тонів, може включати різні методи і включала наступні етапи. Перший – перетворення аудіофайлів на файли з однаковою тривалістю, щоб отримати оптимальне рішення. Другий – розширення набору даних за рахунок генерації синтетичних даних. Розтягування та звуження звукового сигналу у часі з коефіцієнтами 1,2 та 0,8. Ці кроки допомогли зробити класифікатор більш стійким і правильно класифікувати серцеві ритми.

Процес отримання ознак з аудіофайлу був виконаний з використанням коефіцієнтів MFCC, де використовувалося 20 коефіцієнтів. Для отримання ознак сигнал спочатку необхідно оцифрувати. Оцифрування сигналу та отримання ознак здійснювалося за допомогою бібліотеки Librosa. Для класифікації аудіодоріжок використовувалися такі класифікатори: Random Forest, алгоритм градієнтного підсилення XGBoost, згорткова нейронна мережа і мережа LSTM.

Алгоритм Random Forest має багато параметрів, налаштування яких може суттєво вплинути на кінцевий результат. У зв’язку з цим за допомогою методу GridSearchCV було розглянуто різні комбінації параметрів та обрано один набір із кращою оцінкою. Для алгоритму градієнтного підсилення XGBoost також було знайдено найкращі параметри. Для класифікації записів серцевого ритму використовувалася гібридна нейронна мережа.

Модель класифікації серцевих ритмів була побудована на основі нейронної мережі з архітектурою CNN-LSTM. Вхідні дані проходили послідовно через три блоки згорткових шарів Conv1D, шари максимального об’єднання MaxPooling1D, шари BatchNormalization для нормалізації даних. Далі дані оброблялися двома повнозв’язними шарами Dense із Dropout для регуляризації. На виході модель надавала класифікацію у чотири класи: normal, murmur, extrasystole, artefact. Незбалансованість даних було усунуто з допомогою зважування класів. Детальна пошарова архітектура, що використовується для реалізації класифікації серцевих звуків, показана в таблиці 1.

Для цього завдання було обрано функцію softmax. Вона перетворює вектор чисел на вектор ймовірностей, де ймовірності кожного значення пропорційні відносному масштабу кожного значення у векторі. У всіх шарах використовується активаційна функція relu. Також для нейронної мережі вказана точка для ранньої зупинки контролю точності моделі на валідаційному наборі даних.

Таблиця 1. Схема нейронної мережі

Шар	Вид шару	Вхідні дані	Розмір ядра	Активаційна функція	Кількість фільтрів
0	Input Layer	(52,1)			
1	Conv1D	(52,1)	5*5	ReLU	1024
2	MaxPooling		2		
3	BatchNormalization				
4	Conv1D	(52,1)	5*5	ReLU	512
5	MaxPooling		2		
6	BatchNormalization				
7	Conv1D	(52,1)	5*5	ReLU	256
8	MaxPooling		2		
9	BatchNormalization				
10	LSTM				128
11	Dense			ReLU	64
12	Dropout				
13	Dense			ReLU	32
14	Dropout				
15	Dense			Softmax	4

Отримані результати та їх обговорення.

Розробка моделей здійснювалася мовою Python із застосуванням бібліотек TensorFlow, Librosa, Pandas та SciPy. Після попередньої обробки аудіосигналів процес моделювання включав наступні етапи: поділ даних на навчальну та тестову вибірки, вибір архітектури моделі, налаштування параметрів моделі на навчальних даних, застосування навченої моделі для класифікації тонів серця на тестовому наборі та подальшу оцінку якості з використанням метрик точності, повноти (recall) та F1. Побудова та робота з нейромережевою моделлю представлена на рисунку 5.

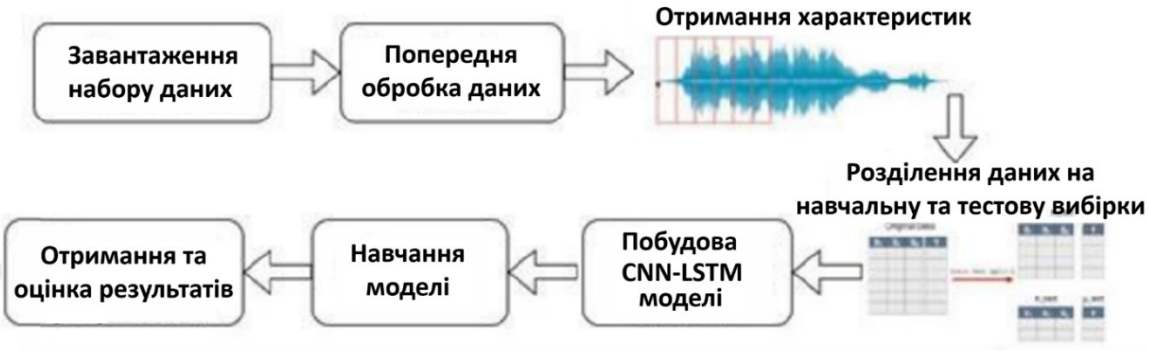


Рис. 5. Побудова моделі нейронної мережі.

Результати роботи алгоритмів приведено у таблицях 2-4.

Таблиця 2. Класифікаційний звіт за класами для алгоритму Random Forest

	Precision	Recall	F1-score
Artifact	0,59	1,0	0,74
Murmur	0,98	0,81	0,89
Extrasystole	1,00	0,28	0,43
Normal	0,93	1,0	0,96
Accuracy			0,89

Аналіз продуктивності алгоритму Random Forest виявив його неефективність щодо класів artifact та extrasystole. Низький показник recall для класу extrasystole говорить про труднощі у його виявленні, а також є проблема з класифікацією класу artifact внаслідок його поганої помітності.

Таблиця 3. Класифікаційний звіт за класами для алгоритму градієнтного підсилення

	Precision	Recall	F1-score
Artifact	0,53	1,0	0,7
Murmur	0,93	0,75	0,83
Extrasystole	1,00	0,21	0,34
Normal	0,9	0,97	0,94
Accuracy			0,85

Алгоритм градієнтного бустингу показує схожі з алгоритмом Random Forest проблеми з класами artifact і extrasystole. Незважаючи на те, що обидва алгоритми здатні виявляти наявність чи відсутність захворювання, їм складно розрізняти ці захворювання між собою.

Таблиця 4. Класифікаційний звіт за класами для нейронної мережі

	Precision	Recall	F1-score
Artifact	1,0	1,0	1,0
Murmur	0,90	0,81	0,79
Extrasystole	0,88	0,85	0,86
Normal	0,93	0,97	0,95
Accuracy			0,95

Нейронна мережа продемонструвала високу ефективність у класифікації записів серцевого ритму, особливо щодо класів artifact та extrasystole. Модель добре справляється із завданням виявлення та розрізнення різних класів серцебиття.

Ідеальні показники для класу Artefact (Precision, Recall, F1 рівні 1,0) пояснюються специфікою самого класу в датасеті. Записи артефактів містять сторонні звуки (мову, музику, побутовий шум), акустичні характеристики яких кардинально відрізняються від будь-яких серцевих тонів. Завдяки цьому клас є лінійно відокремлюваним від решти класів у просторі ознак MFCC, що й дозволяє моделі класифікувати його без помилок. Водночас слід зазначити, що клас Artefact є найменш чисельним у наборі даних, а його представники — надзвичайно однорідними за характером шуму. Тому результати для цього класу не свідчать про загальну ідеальну якість моделі, а відображають структурну особливість датасету.

Висновки

Застосування різних алгоритмів машинного навчання, включаючи Random Forest, градієнтне прискорення, глибокі нейронні мережі та архітектури CNN-LSTM, дозволило запропонувати архітектуру глибокої нейронної мережі, що показала найкращі результати 95 % точності класифікації тестового набору даних.

Модель можна покращити шляхом інтегрування її з іншими шарами мережі глибокого навчання, для протидії перенавчанню можна знизити швидкість навчання. Передбачається, що проведення експериментів з вибіркою, із спектрограмою, розширення набору даних, робота з методами для усунення дисбалансу класів також допоможе в отриманні більш точних показників алгоритму класифікації.

Список літератури

1. W. Chen, Q. Sun, X. Chen, G. Xie, and H. Wu, “Deep learning methods for heart sounds classification: A systematic review,” Entropy, vol. 23, no. 6, Art. no. 667, May 2021. doi: https://doi.org/10.3390/e23060667 .

2. W. Zhang, J. Han, and S. Deng, “Heart sound classification based on scaled spectrogram and tensor decomposition,” Expert Syst. Appl., vol. 84, pp. 220–231, Oct. 2017. doi: https://doi.org/10.1016/j.eswa.2017.05.014 .

3. J. Chen, X. Dang, and M. Li, “Heart sound classification method based on ensemble learning,” in Proc. 2022 16th IEEE Int. Conf. Signal Process. (ICSP), Beijing, China, 2022, pp. 8–13. doi: https://doi.org/10.1109/ICSP54964.2022.9778383 .

4. T. Tuncer, S. Dogan, R.-S. Tan, and U. R. Acharya, “Application of Petersen graph pattern technique for automated detection of heart valve diseases with PCG signals,” Inf. Sci., vol. 565, pp. 91–104, Jul. 2021. doi: https://doi.org/10.1016/j.ins.2021.01.088 .

5. P. Aparna, G. Jayalaxmi, and P. Vishwanath, “Heart sound classification system using deep-learning neural networks,” in Proc. 4th Int. Conf. Frontiers Comput. Syst. (COMSYS 2023), Singapore: Springer, 2024, pp. 647–658. doi: https://doi.org/10.1007/978-981-97-2614-1_46 .

6. Yaseen, G.-Y. Son, and S. Kwon, “Classification of heart sound signal using multiple features,” Appl. Sci., vol. 8, no. 12, Art. no. 2344, Nov. 2018. doi: https://doi.org/10.3390/app8122344 .

7. J. Huang, B. Chen, B. Yao, and W. He, “ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network,” IEEE Access, vol. 7, pp. 92871–92880, 2019. doi: https://doi.org/10.1109/ACCESS.2019.2928017 .

8. D. Kozłowski, “Method in the chaos – a step-by-step approach to ECG interpretation,” Eur. J. Transl. Clin. Med., vol. 1, no. 1, pp. 74–90, 2018. doi: https://doi.org/10.31373/ejtcm/92255 .

9. T. S. M. Tsang, W. P. Abhayaratna, M. E. Barnes, et al., “Prediction of cardiovascular outcomes with left atrial size: Is volume superior to area or diameter?,” J. Am. Coll. Cardiol., vol. 47, no. 5, pp. 1018–1023, Mar. 2006. doi: https://doi.org/10.1016/j.jacc.2005.08.077 .

10. A. Y. Hannun, P. Rajpurkar, M. Haghpanahi, et al., “Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network,” Nat. Med., vol. 25, no. 1, pp. 65–69, Jan. 2019. doi: https://doi.org/10.1038/s41591-018-0268-3 .

Надійшла до редколегії 19.05.2026

Відомості про авторів:

Петриняк Юрій Іванович - аспірант, кафедра комп’ютерних наук, Національний лісотехнічний університет України / Ukrainian National Forestry University, Україна; email: petrynyak.yuriy@nltu.lviv.ua; ORCID: https://orcid.org/0009-0003-0185-6695

Пірко Ігор Богданович, канд. фіз.-мат. наук, доцент, кафедра комп’ютерних наук, Національний лісотехнічний університет України / Ukrainian National Forestry University, Україна; email: pirko@nltu.edu.ua; ORCID: https://orcid.org/0009-0008-2378-2929