

В. А. КРИЛОВА, канд. техн. наук, доц., Національний технічний університет "Харківський політехнічний інститут",

А. М. МІРОШНИК, ст. викл., PhD, Харківський національний університет радіоелектроніки,

О. О. ПЕТРЕНКО, асп., Національний технічний університет "Харківський політехнічний інститут"

О. Д. ЗАЦ, асп., Харківський національний університет імені В.Н. Каразіна

БАГАТОШАРОВА АРХІТЕКТУРА НЕЙРОННОЇ МЕРЕЖІ ДЛЯ АНАЛІЗУ ЕКГ СИГНАЛІВ

В даний час, з урахуванням зростаючої кількості серцево-судинних захворювань, актуальність швидкого та точного аналізу електрокардіограм (ЕКГ) суттєво зростає. Традиційні методи аналізу ЕКГ вимагають значних тимчасових витрат та високої кваліфікації фахівців, що стимулює розробку та впровадження автоматизованих систем, здатних ефективно інтерпретувати дані ЕКГ. У статті досліджується застосування нейронних мереж для аналізу ЕКГ, що забезпечує істотне підвищення швидкості та точності діагностування. Запропоновано розробку та аналіз ефективності моделі нейронної мережі, здатної розпізнавати і класифікувати основні аритмії за даними ЕКГ. У статті представлені результати порівняння кількох архітектур нейронних мереж, включаючи згорткові та рекурентні нейронні мережі, на наборі даних ЕКГ з різними патологіями. Аналіз показав, що якщо використовувати нейронні мережі, що згортаються (CNN) показує високу точність у класифікації ЕКГ-сигналів, що забезпечує значний потенціал для клінічного застосування. Іл.: 1. Бібліогр.: 9 назв.

Ключові слова: електрокардіограма, ЕКГ-сигнал, нейронні мережі, ритмограма, статистичні характеристики ЕКГ сигналу, детектор R піків, аритмія.

Постановка проблеми та аналіз останніх досліджень.

Комп'ютеризований аналіз ЕКГ спрямовано на автоматизацію процесу діагностики. Він включає використання алгоритмів обробки сигналів визначення характеристик ЕКГ, таких як частота серцевих скорочень, інтервали QRS, ST-сегмент та інші. Автоматизований аналіз ЕКГ прискорює процес діагностики та зменшує ризик людської помилки, але може страждати від обмежень, пов'язаних із чутливістю до шумів та

© В.А. Крилова, А.М. Мірошник, О.О. Петренко, О.Д. Зац, 2025

артефактів у даних ЕКГ. Методи машинного навчання були розроблені для покращення точності та надійності аналізу ЕКГ. Ці методи дозволяють навчатися на надвеликих наборах даних для того, щоб виявити складні шаблони та закономірностей, які не очевидні для людини або традиційних алгоритмів.

Для аналізу ЕКГ-сигналів використовують різні архітектури нейронних мереж – вибір залежить від поставленої задачі. Серед методів машинного навчання особливе значення надається застосуванню згорткових нейронних мереж (CNN) і рекурентних нейронних мереж (RNN) для класифікації аритмій, визначення синдрому QT, аналіз R інтервалів та інших завдань. В статті [1] пропонується використовувати підхід до аналізу серцевої діяльності, заснований на розбитті масивів ритмограм на ділянки та в подальшому застосовувати нейронні мережі рекурентного типу з врахуванням часових залежностей. У роботі [2] запропоновано адаптивний алгоритм фільтрації, заснований на штучній нейронній мережі (ANN) для виявлення QRS комплексів. Але результативність роботи такої системи все ще дуже сильно залежить від якості вибірки даних для тренування системи.

Метою даної роботи є розробка багат шарової моделі нейронної мережі для розпізнавання, діагностики патології серцевої аритмії. Порівняння кількох архітектур нейронних мереж та аналіз ефективності запропонованої багат шарової моделі, здатної розпізнавати та класифікувати основні патології за даними ЕКГ.

Результати досліджень. Попередня обробка даних ЕКГ є критично важливим етапом у процесі аналізу за допомогою нейронних мереж, оскільки якість вихідних даних безпосередньо впливає на ефективність та точність подальшого навчання та класифікації моделей. Цей процес включає кілька ключових кроків, спрямованих на поліпшення якості даних і підготовку їх до аналізу [3].

1. Нормалізація, яка включає масштабування амплітуди сигналу до певного діапазону, часто до діапазону від 0 до 1 або від -1 до 1. Це забезпечує однаковість даних, спрощує навчання нейронної мережі і підвищує її здатність узагальнювати інформацію. Використовується метод Min-Max нормалізація [4], який дозволяє усунути вплив відмінностей у

масштабах ознак на роботу алгоритмів машинного навчання, зокрема нейронних мереж та класифікаторів, які чутливі до діапазону вхідних даних

$$x' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}. \quad (1)$$

2. Детектування R піків ЕКГ сигналу необхідно для визначення моментів часу, що відповідають максимуму R-зубців на електрокардіографічному сигналі. Алгоритм пошуку та формування масиву значень R піків складається з декілька етапів.

– Диференціювання використовується для посилення змін сигналу та виділення різких переходів, характерних для R-зубців

$$diff[i] = ecg[i + 1] - ecg[i]. \quad (2)$$

Диференціювання допомагає виділити круті підйоми та спади сигналу, характерні для R-зубців.

– Згладжування (ковзне середнє) застосовується для зменшення шумів та стабілізації сигналу після диференціювання

$$filtered[i] = \frac{1}{N} \sum_{j=start}^{end} diff[j] \quad (3)$$

де N – ширина вікна, а $start$ і end – межі вікна щодо поточного індексу.

– Адаптивний поріг обчислюється як сума середнього значення фільтрованого сигналу та половини стандартного відхилення

$$threshold = mean + 0,5 * stdDev. \quad (4)$$

Динамічне оновлення порога здійснюється за формулою

$$threshold = 0,875 * threshold + 0,125 * filtered[i]. \quad (5)$$

Це дозволяє враховувати зміни амплітуди сигналу в процесі аналізу.

– Пошук R піків детектуються максимумами, які вищі за поріг і знаходяться на достатній відстані один від одного (мінімальний інтервал RR). Якщо знайдено пік, який відповідає умовам, його індекс зберігається. Таким чином, метод дозволяє точно виділити R-піки навіть в умовах шумного сигналу і амплітуди, що варіюється.

3. Модуль вирівнювання періодів використовується для сегментації ЕКГ сигналу на окремі серцеві цикли (періоди), ґрунтуючись на детектованих R-піках [5, 6]. Це дозволяє виділити стійкі фрагменти для подальшого аналізу, включаючи розрахунок ознак та класифікацію. Етапи вирівнювання та виділення періодів.

- Обмеження кількості піків (режим MLP). Якщо використовується режим MLP (фіксована довжина виведення), вибирається лише перші 5 піків, щоб забезпечити стандартизоване виведення з мережі.

- Зміщення та обрізання сигналу. Для усунення початкового усунення сигнал обрізається від першого виявленого піку, щоб період розпочинався безпосередньо з нього. Це спрощує вирівнювання та подальшу обробку.

- Облік останнього періоду. Кінцева точка обрізаного сигналу визначається як передостанній R-пік плюс довжина останнього періоду. Це дозволяє зберегти цілісність останнього сегмента.

- Видалення хвоста піку. Для усунення викидів наприкінці останнього періоду використовується "хвостове" згладжування. Якщо останнє значення перевищує середнє значення останніх 100 точок у 1.5 рази, воно відсікається. Цей процес триває, доки хвіст не стабілізується.

- Формування періодів. Використовуючи скориговані індекси піків, формуються періоди у вигляді списку об'єктів класу *Segment*, де кожен сегмент представлений початком та довжиною.

4. Модуль розбиття даних на фрагменти використовується для підготовки вхідних даних для нейронної мережі, зокрема для згорткової нейронної мережі (CNN). Цей процес дозволяє виділити невеликі ділянки сигналу (вікна) з фіксованим розміром, які використовуються для отримання локальних ознак [7, 8]. На кожному кроці цикл проходить по всіх виділених періодах зі списку періодів. До кожного періоду витягується відповідний сегмент сигналу:

$$segment = signal[Start: Start + Length]. \quad (6)$$

Потім цей сегмент розбивається на підфрагменти та всі отримані фрагменти додаються до загального списку *fragments*. У розбитті періоду на фрагменти відбувається розбиття кожного періоду на невеликі підфрагменти фіксованого розміру, що перекриваються (*fragmentSize*).

$$\text{fragment}[j] = \text{period}[i : i + \text{fragmentSize}], \quad (7)$$

де i – початковий індекс фрагмента, а fragmentSize – розмір вікна фільтра.

Алгоритм використовує метод ковзного вікна з кроком в одну точку, що дозволяє зберегти локальну структуру сигналу та забезпечити високу густину даних для навчання. Фрагменти дозволяють нейромережі навчатися на коротких, локалізованих ділянках сигналу, що особливо корисно для аналізу коротких патернів та виявлення аномалій. Розбиття на вікна, що перекриваються, дозволяє значно збільшити кількість тренувальних зразків, що сприяє кращій узагальнюючій здатності моделі [9]. Незалежність фрагментів спрощує паралельну обробку та дозволяє ефективно використовувати обчислювальні ресурси. Таким чином, розбиття на фрагменти підвищує точність класифікації та дозволяє нейронній мережі ефективно навчатися на локальних особливостях ЕКГ-сигналу.

Для комплексного аналізу та класифікації відповідних підготовлених фрагментів даних необхідно застосовувати гібридну архітектуру нейронної мережі. На рис. 1 представлено багатошарова архітектура нейронної мережі розроблена для комплексного аналізу ЕКГ-сигналів з використанням безлічі вхідних даних та різноманітних навчальних шарів, що дозволяє враховувати як безпосередньо сигнали ЕКГ, так і демографічну інформацію пацієнта.

Модуль кластеризації K-Means Clustering використовується для поділу множини точок даних на k кластерів, так щоб точки всередині одного кластера були більш схожі один на одного, ніж точки з інших кластерів. У контексті обробки ЕКГ цей метод дозволяє виявити типові патерни серцевої активності та створити фільтри для виділення ознак. Основні етапи алгоритму:

- Ініціалізація центроїдів. На першому етапі вибираються k випадкових точок даних як початкових центроїдів. Цей підхід забезпечує початкове розбиття, яке потім уточнюється на наступних ітераціях.
- Прив'язка точок до найближчого центроїду. Для кожної точки в наборі даних розраховується відстань до всіх центроїдів з використанням евклідової відстані:

$$d = \sqrt{\sum_{i=1}^n (a_i - b_i)^2} . \quad (8)$$

Точка призначається в кластер з мінімальною відстанню до центроїду.

– Оновлення центроїдів: Після розподілу точок у кластери розраховується новий центроїд кожного кластера як середнє арифметичне всіх точок у кластері

$$C_j = \frac{1}{|S_j|} \sum_{x \in S_j} x, \quad (9)$$

де S_j – безліч точок, що належать кластеру j .

– Перевірка збіжності. Алгоритм завершується, якщо центроїди більше не змінюються на наступній ітерації (або досягнуто максимальної кількості ітерацій).

Таким чином, метод К-Means використовується для створення репрезентативних фільтрів, які виділяють ключові патерни активності серця, збільшуючи точність класифікатора.

Optimization (Оптимізація фільтрів). Модуль оптимізації фільтрів використовується для покращення якості класифікації шляхом видалення неінформативних фільтрів, які слабо реагують на вхідні дані. Це дозволяє скоротити кількість надлишкових ознак та підвищити ефективність моделі. Для кожного фільтра обчислюється середнє значення відгуку всіх тренувальних даних. Відгук фільтра визначається як середнє арифметичне абсолютного середнього значення і дисперсії. Цей підхід дозволяє врахувати як амплітуду сигналу, і його варіабельність. Після проходження всіх періодів відгук усереднюється. Якщо середній відгук фільтра менший за порогове значення (0,1), фільтр вважається неінформативним і видаляється. Це дозволяє позбутися шумових або слабоактивних фільтрів, які не вносять значний вклад у класифікацію. Таким чином, оптимізація фільтрів дозволяє покращити якість обробки ЕКГ, підвищуючи ефективність класифікації та скорочуючи обчислювальні витрати за рахунок видалення незначних фільтрів із відгуком менше 0,1.




Рис. 1 Архітектура нейронної мережі для аналізу ЕКГ сигналів

Модуль згортки реалізує обчислення згортки одновимірного сигналу з фільтром, що дозволяє виділити характерні патерни даних. Цей метод часто використовується в згорткових нейронних мережах (CNN) для виділення локальних ознак, наприклад, різких змін або періодичності в ЕКГ.

$$y[i] = \sum_{j=0}^{n-1} x[i + j - \frac{n}{2}] \cdot w[j], \quad (10)$$

де $x[i]$ – вхідний сигнал, $w[j]$ – фільтр (ядро), n – довжина фільтра (ядра), $y[i]$ – вихідний сигнал.

Згортка дозволяє виділити локальні патерни (наприклад, зубці R на ЕКГ) і отримати характеристики сигналу, такі як різкі переходи та текстурні особливості. Етапи обчислення згортки:

1. Ініціалізація параметрів згортки: розмір фільтра (kernelSize) визначається довжиною ядра згортки, половина фільтра (half) використовується для зміщення індексу, щоб центрувати ядро щодо поточної точки.

2. Обчислення згортки: для кожної точки сигналу (починаючи з позиції, зсунутої на половину фільтра) обчислюється зважена сума творів значення сигналу та відповідного коефіцієнта фільтра

$$sum = \sum_{j=0}^{n-1} signal[i + j - half] * filter[j]. \quad (11)$$

Обчислене значення записується в результуючий масив. Таким чином, модуль згортки допомагає витягти локальні характеристики сигналу, забезпечуючи стійкість до шумів та виділення важливих ознак для подальшої обробки нейромеревими модулями.

Pooling. Модуль пулінгу використовується після операції згортки для зниження розмірності даних та виділення узагальнених ознак. Це необхідно для зменшення обсягу обчислень та запобігання перенавчанню, зберігаючи при цьому ключові характеристики сигналу. Після згортки дані можуть мати високу розмірність. Пулінг дозволяє компактно подати інформацію, знижуючи надмірність. Усереднення та розрахунок дисперсії дозволяють враховувати варіабельність патернів, роблячи модель стійкішою до невеликих змін сигналу. Середнє абсолютне значення відбиває амплітудні характеристики, а дисперсія - мінливість сигналу. Це дозволяє виділити і амплітудні та текстурні ознаки. Пулінг зменшує вплив одиничних викидів, що покращує стійкість моделі. Замість великого обсягу згорнутих даних зберігаються лише усереднені показники, що прискорює навчання нейромережі. У цьому модулі використовуються два типи пулінгу:

1. Середнє абсолютне значення (Mean Abs). Це усереднення модуля значень сегмента, що дозволяє отримати узагальнену амплітуду після згортки:

$$meansAbs = \frac{1}{n} \sum_{i=1}^n |x_i|. \quad (12)$$

де x_i – значення сигналу після згортки.

Дисперсія характеризує варіативність значень у сегменті та допомагає врахувати зміну форми сигналу

$$variance = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2, \quad (13)$$

де μ – середнє значення сегмента.

Ці два показники додаються до списку ознак періоду. Таким чином, пулінг після згортки дозволяє витягти ключові характеристики сигналу, знижуючи розмірність даних та підвищуючи стійкість моделі до шумів та варіабельності.

Висновки. Архітектура нейронної мережі обрана виходячи з потреби обробки тимчасових послідовностей даних ЕКГ, які містять важливу інформацію у часовій динаміці. Поєднання згорткових нейронних мереж (CNN) і **Temporal Convolutional Network (TCN)** дозволяє ефективно отримувати як просторові, так і тимчасові ознаки даних. Для обробки ЕКГ-сигналів з довгими тимчасовими залежностями, найбільш оптимальним рішенням буде використання саме TCN, оскільки вона поєднує високу швидкість роботи, стійкість до градієнтів, що зникають, і хорошу інтерпретованість. Блок пошуку відхилень може бути виявлення аномалій, що особливо важливо під час пошуку рідких патологій чи незначних відхилень у сигналі. Включення демографічних даних дозволяє моделі враховувати індивідуальні особливості пацієнтів, що може підвищити точність діагностики.

Список літератури:

1. Горго Ю.П. Нові алгоритми аналізу серцевого ритму людини / Ю.П. Горго, Г.А. Омеляненко // Штучний інтелект. – 2017. – № 1. – С. 7-15. – Режим доступу: <http://dspace.nbuv.gov.ua/handle/123456789/132096>
2. Karimipour, M. R. Homaeinezhad, Real-time electrocardiogram p-qrs-t detection delineation algorithm based on quality-supported analysis of characteristic templates, *Computers in Biology and Medicine* 52 (2014) 153 – 165. doi: <https://doi.org/10.1016/j.compbiomed.2014.07.002>
3. Ivashko, A., Krylova, V., Petrenko, O Detection of cardiac arrhythmias using neural network-based heart rate variability analysis.. 2024 IEEE 5th KhPI Week on Advanced Technology, *KhPIWeek 2024 – Conference Proceedings*, 2024. DOI: <https://10.1109/KHPIWEEK61434.2024.10878104>
4. Крилова В. А. Аналіз варіабельності серцевого ритму за допомогою штучних нейронних мереж / Крилова В. А., Івашко А. В., Петренко О. О.// Системи управління, навігації та зв'язку. Полтава. 2024. Випуск 1 (75). С. 109-114. doi: <https://10.26906/SUNZ.2024.1.109>
5. Giulia Silveri, Marco Merlo, Luca Restivo. Novel Classification of Ischemic Heart Disease Using Artificial Neural Network. *Computing in Cardiology*, 2020, pp. 1–4, doi:10.22489/CinC.2020.312

6. Arash Shokouhmand, Xinyu Jiang, Farrokh Ayazi. A Comparative Study of Heart Rate Variability Parameters Estimated from Strain Plethysmography Recordings of Radial and Finger Arteries. *IEEE 19th International Conference on Body Sensor Networks (BSN)*, 2023, pp. 1–4, doi: 10.1109/BSN58485.2023.10331009
7. T. Tekeste, H. Saleh, B. Mohammad, A. Khandoker, M. Elnaggar, A nano-watt ecg feature extraction engine in 65nm technology, *IEEE Transactions on Circuits and Systems II: Express Briefs* PP (99) (2017) 1–1. doi: 10.1109/TCSII. 2017.2658670.
8. Reaz, M. B. I., Hussain, M. S., Mohd-Yasin, F. Techniques of EMG signal analysis: detection, processing, classification and applications. *Biological Procedures Online*, 8 (1), 11–35. doi: <http://doi.org/10.1251/bpo115>
9. Chuiko, G. P., Shyian, I. A. Processing and analysis of electroneuromyograms with Maple tools. *Biomedical Engineering and Electronics*, 10. Available at: <http://biofbe.esrae.ru/pdf/2015/3/1006.pdf>

References:

1. Horho Yu.P., Omelianenko H.A. (2017) “Novi alhorytmy analizu sertsevoho rytmu liudyny”, *Shtuchnyi intelekt*.
Rezhym dostupu: <http://dspace.nbuv.gov.ua/handle/123456789/132096>
2. Karimipour, M. R. Homaeinezhad (2014) “Real-time electrocardiogram P-QRS-T detection delineation algorithm based on quality-supported analysis of characteristic templates”, *Computers in Biology and Medicine*. doi: <https://doi.org/10.1016/j.compbiomed.2014.07.002>
3. Ivashko, A., Krylova, V., Petrenko, O (2024) “Detection of cardiac arrhythmias using neural network-based heart rate variability analysis”, *IEEE 5th KhPI Week on Advanced Technology*. DOI: <https://10.1109/KHPIWEEK61434.2024.10878104>
4. Krylova V. A., Ivashko A. V., Petrenko O. O (2024) “Analiz variabelnosti sertsevoho rytmu za dopomohoiu shtuchnykh neuronnykh merezh”, *Systemy upravlinnia, navihatsii ta zviazku*. Poltava. doi: <https://10.26906/SUNZ.2024.1.109>
5. Giulia Silveri, Marco Merlo, Luca Restivo. (2020) “Novel Classification of Ischemic Heart Disease Using Artificial Neural Network”, *Computing in Cardiology*.
doi:10.22489/CinC.2020.312
6. Arash Shokouhmand, Xinyu Jiang, Farrokh Ayazi. A Comparative Study of Heart Rate Variability Parameters Estimated from Strain Plethysmography Recordings of Radial and Finger Arteries. *IEEE 19th International Conference on Body Sensor Networks (BSN)*, 2023, pp. 1–4, <http://doi.org/10.1109/BSN58485.2023.10331009>.
7. T. Tekeste, H. Saleh, B. Mohammad, A. Khandoker, M. Elnaggar (2017) “A nano-watt ecg feature extraction engine in 65nm technology”, *IEEE Transactions on Circuits and Systems II: Express Briefs* PP. doi: 10.1109/TCSII. 2017.2658670.
8. Reaz, M. B. I., Hussain, M. S., Mohd-Yasin, F. (2006) “Techniques of EMG signal analysis: detection, processing, classification and applications”, *Biological Procedures Online*, <http://doi.org/10.1251/bpo115>
9. Chuiko, G. P., Shyian, I. A. (2015) “Processing and analysis of electroneuromyograms with Maple tools”, *Biomedical Engineering and Electronics*.
<http://biofbe.esrae.ru/pdf/2015/3/1006.pdf>

Статтю представила д.т.н., проф. Національного технічного університету ім. В.Н. Каразіна М.А. Мірошник.

Поступила (received) 28.04.2025

Krylova Viktoriia Ph.D, associate professor
Department of Automation and control in technical systems
National Technical University "Kharkiv Polytechnic Institute"
Kyrpychova str., 2, Kharkiv, Ukraine, 61002
E-mail: viktoriia.krylova@khpі.edu.ua (vika_hpi@outlook.com)
Contact tel. +380502813838 ORCID ID: 0000-0002-4540-8670

Miroshnyk Anatolii senior lecturer,
Kharkiv National University of Radioelectronics
Nauki, Ave.14, Kharkiv, Ukraine, 61166, Kharkiv, Ukraine.
Tel.: (095) 82-69-640, e-mail: anatolii.miroshnyk@nure.ua
ORCID ID: 0000-0001-5702-9611

Petrenko Oleh postgraduate student
Department of Automation and control in technical systems
National Technical University "Kharkiv Polytechnic Institute"
Kyrpychova str., 2, Kharkiv, Ukraine, 61002
E-mail: Oleh.Petrenko@infiz.khpі.edu.ua (petrenko.oleg.1985@gmail.com)
Contact tel. +380969739531 ORCID ID: 0009-0003-3424-023X

Zats Oleksandr, postgraduate student
Department of Computer Science and Artificial Intelligence,
V. N. Karazin Kharkiv National University,
Svobody Sq., 6, Kharkiv, Ukraine, 61022 ORCID ID: 0000-0002-7623-9187

УДК 004.3.08

Багатошарова архітектура нейронної мережі для аналізу ЕКГ сигналу / Крилова В.А., Мірошник А.М., Петренко О.О., Зац О.Д. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2025. – № 1 (13). – С. 99 – 110.

В даний час, з урахуванням зростаючої кількості серцево-судинних захворювань, актуальність швидкого та точного аналізу електрокардіограм (ЕКГ) суттєво зростає. Традиційні методи аналізу ЕКГ вимагають значних тимчасових витрат та високої кваліфікації фахівців, що стимулює розробку та впровадження автоматизованих систем, здатних ефективно інтерпретувати дані ЕКГ. У статті досліджується застосування нейронних мереж для аналізу ЕКГ, що дозволяє значно збільшити швидкість та точність діагностики. Запропоновано розробку та аналіз ефективності моделі нейронної мережі, здатної розпізнавати і класифікувати основні аритмії за даними ЕКГ. У статті представлені результати порівняння кількох архітектур нейронних мереж, включаючи згорткові та рекурентні нейронні мережі, на наборі даних ЕКГ з різними патологіями. Аналіз показав, що використання згорткових нейронних мереж (CNN) демонструє високу точність у класифікації ЕКГ-сигналів, що забезпечує значний потенціал для клінічного застосування. Іл.: 1. Бібліогр.: 9 назв.

Ключові слова: електрокардіограма, ЕКГ-сигнал, нейронні мережі, ритмограма, статистичні характеристики, детектор R піків, аритмія.

UDC 004.3.08

Multilayer neural network architecture for ECG signal analysis / Krylova V., Miroshnyk A., Petrenko O., Zats O.D. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkov: NTU "KhPI". – 2025. – № 1 (13). – P. 99 – 110.

Currently, given the increasing number of cardiovascular diseases, the relevance of fast and accurate analysis of electrocardiograms (ECG) is growing significantly. Traditional methods of ECG analysis require significant time costs and high qualifications of specialists, which stimulates the development and implementation of automated systems capable of effectively interpreting ECG data. The article investigates the use of neural networks for ECG analysis, which allows significantly increasing the speed and accuracy of diagnosis. The development and analysis of the effectiveness of a neural network model capable of recognizing and classifying the main arrhythmias from ECG data is proposed. The article presents the results of comparing several neural network architectures, including convolutional and recurrent neural networks, on a set of ECG data with various pathologies. The analysis showed that the use of convolutional neural networks (CNN) demonstrates high accuracy in classifying ECG signals, which provides significant potential for clinical application. Fig.: 1. Bibliography: 9 titles/

Keywords: electrocardiograms, ECG-signal, neural networks, rhythmogram, statistical characteristics, R peak detector, arrhythmia.