

DOI: 10.20535/1970.69(1).2025.331920

УДК 616.12-073.7

МОДЕЛЬ НЕЙРОМЕРЕЖЕВОГО АВТОЕНКОДЕРА ДЛЯ ФОРМУВАННЯ
СКОРОЧЕНИХ ВЕКТОРІВ ОЗНАК ЕКГ СИГНАЛІВ

Мневєць А.В., Іванушкіна Н. Г.

Національний технічний університет України «Київський політехнічний інститут
імені Ігоря Сікорського», Київ, УкраїнаE-mail: amnevec-ee22@iit.kpi.ua, niva-ee@iit.kpi.ua

У статті розглянута актуальна проблема вдосконалення моделей нейронних мереж для класифікації серцево-судинних патологій шляхом стиснення інформації, яка міститься в електрокардіографічних (ЕКГ) сигналах. Через активне впровадження штучного інтелекту в медичну діагностику в роботі зосереджено увагу на створенні скороченого вектора ознак ЕКГ сигналів, що дозволяє зменшити обсяг тренувальних даних без втрати важливої інформації. Дослідження присвячено розробці моделі автоенкодера зі спеціалізованою архітектурою, яка поєднує згорткові та повнозв'язні шари, шари уваги, залишкові зв'язки та симетричну структуру зі спільними вагами. Такий підхід дозволяє не лише стискати вхідний багатоканальний сигнал, але й формувати латентний простір, з якого можна відновити сигнал або використовувати його як вектор ознак для класифікації. В архітектурі моделі автоенкодера виконано поєднання латентного представлення та вектору вагових коефіцієнтів шарів у єдиний скорочений вектор, що одночасно містить інформацію як про форму, так і про структуру ознак ЕКГ сигналу. Навчання моделі відбувалося з використанням комбінованої функції втрат, яка дозволяє балансувати між якістю реконструкції сигналу та точністю класифікації. Для тестування моделі було використано низку альтернативних методів скорочення розмірності: зниження частоти дискретизації; перетворення до ортогональних відведень Франка; обчислення результуючого вектора; метод головних компонент (РСА). Усі методи були протестовані на базі даних РТВ-XL, яка містить 12-канальні ЕКГ-записи з широким спектром патологій. Для оцінки ефективності скороченого вектора ознак застосовано дві моделі – згорткову нейронну мережу EcgNet і повнозв'язну мережу з двома прихованими шарами. Аналіз результатів показав, що в середньому точність класифікації з використанням скороченого вектора знижується лише на 2 % для EcgNet і збільшується на 3–6 % для повнозв'язної мережі, що свідчить про збереження діагностичної інформації навіть у разі значного коефіцієнту стиснення сигналу зі значенням 25. Водночас, традиційні методи зменшення розмірності, такі як РСА або переведення в ортогональну систему відведень, демонструють суттєве погіршення якості класифікації (до –16 %). Зменшення частоти дискретизації до 75 Гц хоча дозволяє суттєво знизити обсяг даних, однак, також веде до втрати високочастотної інформації, критичної для виявлення ішемій та аритмій. Особливу увагу приділено пізнім потенціалам шлуночків (ППШ) та передсердь (ППП), що мають низькоамплітудну і високочастотну природу. Сформований скорочений вектор ознак забезпечив збереження інформативних характеристик цих класів, що відобразилось у підвищенні точності їх класифікації порівняно з традиційними методами зменшення розмірності. З огляду на це, розроблений скорочений вектор ознак демонструє здатність до збереження діагностичної інформації за умов суттєвого зменшення розмірності даних ЕКГ, що дозволяє досягти балансу між обчислювальною ефективністю, точністю класифікації та універсальністю застосування. Отримані результати свідчать про те, що використання запропонованого скороченого вектора ознак може бути перспективним рішенням для компактних і продуктивних систем автоматизованого аналізу ЕКГ, в мобільних, або обмежених за обчислювальними ресурсами системах, а також дає можливість пришвидшити розробку та тестування нових нейромережових моделей для діагностики.

Ключові слова: електрокардіографія; автоенкодер; пізні потенціали шлуночків; пізні потенціали передсердь; стиснення даних.

Вступ

Штучні нейронні мережі (НМ) широко впроваджуються в різні галузі медицини, зокрема для обробки біомедичних сигналів і зображень. Вони демонструють високі результати діагностики під час аналізу радіологічних знімків, електроенцефалограм та електрокардіограм, а також під час виявлення небезпечних для життя кардіологічних станів [1]. Такі результати зумовлені здатністю НМ ефективно узагальнювати інформацію та працювати з необробленими даними, мінімізуючи необхідність проекту-

вання ознак. Сучасні архітектури НМ реалізують механізми автоматичного виділення релевантних ознак, що дозволяє зосередитися на підготовці якісних навчальних вибірок і вдосконаленні нейромережових архітектур [2].

Крім того, сучасні мережі оснащені засобами контролю перенавчання, зокрема спеціалізованими функціями втрат, які дозволяють регулювати співвідношення хибнопозитивних і хибнонегативних рішень, а також впливати на розподіл вихідних значень застосовуючи різноманітні шари активації [3].

Архітектурні рішення, такі як механізми уваги, рекурентні блоки, довга короткочасна пам'ять (Long Short-Term Memory, LSTM) чи блок керованої рекурентної мережі (Gated Recurrent Unit, GRU), забезпечують обробку часових залежностей та реалізують механізми внутрішньої пам'яті, що підвищує стійкість моделі до варіативності вхідних даних [4]. В свою чергу, механізм уваги дає змогу моделі акцентувати обчислювальні ресурси на ділянках сигналу з найбільшою кількістю діагностичної інформації, а рекурентні структури ефективно фіксують довготривалі часові патерни.

Штучні НМ особливо перспективні для задач класифікації біомедичних сигналів, зокрема ЕКГ, що характеризуються складною структурою та великою кількістю можливих патологій. Традиційне формування векторів ознак для кожної патології потребує високої точності виділення ключових елементів кардіоциклу, що складно реалізувати в умовах клінічної практики. Натомість НМ здатна створювати внутрішній набір ознак у процесі навчання, що спрощує її розробку та підтримку.

Однак, аналіз повнорозмірних ЕКГ-сигналів, особливо багатоканальних, вимагає значних обчислювальних ресурсів. На відміну від вектора зі 100 обчислених ознак, повноцінна 12-канальна ЕКГ містить тисячі відліків, кожен з яких має потенційне діагностичне значення. Наприклад, діагностика задньо-базальної ішемії потребує аналізу відведень V7–V9, а гіпертрофія правого шлуночка – V1–V3. Як наслідок, зменшення кількості каналів або частоти дискретизації може призводити до втрати критичної інформації.

З метою зменшення обчислювального навантаження під час тренування та використання НМ застосовуються різні методи зменшення розмірності даних. Найпростішим методом є зниження частоти дискретизації, однак такий підхід супроводжується втратою високочастотних компонентів, які можуть містити ознаки ішемії, аритмій або порушень провідності [5]. Використання згорткових шарів дозволяє скорочувати розмірність вхідного сигналу шляхом навчання фільтрів, що виявляють локальні патерни, проте для виявлення складних патологій потрібна велика кількість ядер згортки, що не завжди знижує кількість обчислень [6].

Рекурентні архітектури забезпечують послідовну обробку, проте характеризуються високою обчислювальною складністю, схильністю до проблеми затухання/вибуху градієнтів, що потребує додаткових засобів стабілізації. Альтернативні методи, такі як метод головних компонент (Principal Component Analysis, PCA) [7] або стохастичне сусіднє вбудовування з t-розподілом (t-distributed Stochastic Neighbor Embedding, t-SNE) [8], дозволяють здійснити лінійне або нелінійне зниження розмірності, однак вони не враховують часову структуру сигналу, що веде до зменшення кількості діагностичних ознак.

Для стиснення сигналів ЕКГ часто використовують методи дискретного косинусного перетворення

(Discrete Cosine Transform, DCT), швидкого перетворення Фур'є (Fast Fourier Transform, FFT) та дискретного вейвлет-перетворення (Discrete Wavelet Transform, DWT) [9]. Методи DCT і FFT ефективні з погляду стиснення, але втрачають часові характеристики сигналу, а метод DWT, попри кращу локалізацію, поступається в рівні стиснення. Такі методи також потребують значних обчислювальних ресурсів, що обмежує їх використання в реальному часі або на портативних пристроях.

Отже, актуальним напрямком досліджень є створення універсального скороченого вектора ознак, здатного компактно представляти ЕКГ-сигнал з мінімальними втратами діагностичної інформації.

Метою даного дослідження є розробка спеціалізованої архітектури автоенкодера для створення універсального скороченого вектора ознак ЕКГ сигналу, який здатний зберігати інформацію про форму сигналу без значної втрати діагностичної інформації для класифікації серцево-судинних патологій.

Матеріали та методи

Дванадцятиканальна ЕКГ є основним діагностичним інструментом, який дозволяє виявити ішемічні зміни міокарду, порушення ритму, гіпертрофію камер та інші серцеві патології.

Згідно з рекомендаціями Американської кардіологічної асоціації (American Heart Association, АНА), саме 12-канальна ЕКГ вважається стандартом первинної оцінки стану серця, особливо у пацієнтів з підозрою на гострий коронарний синдром, аритмії або непритомність [10].

1) Перехід до ортогональної системи Франка

Існують більш компактні системи електрокардіографічних відведень, які забезпечують схожий рівень діагностичних можливостей, наприклад система відведень Франка [11]. На рис. 1 показано порівняння розташування електродів та просторового розміщення стандартної системи електрокардіографічних відведень, та системи відведень Франка:




Рис. 1. Просторове розміщення електрокардіографічних відведень та положення електродів, де: а – стандартна 12 – канальна система відведень; б – система відведень Франка

Електрокардіографія в дванадцяти відведеннях спеціалізується на аналізі електричної активності

серця у двох площинах – фронтальній (відведення I, II, III, aVR, aVL, aVF) та горизонтальній (V1–V6), що дозволяє оцінити стан різних ділянок міокарда. Такий підхід є стандартом для клінічної діагностики ішемічних змін, порушень ритму та провідності. Дванадцятиканальна ЕКГ дозволяє деталізувати ділянки міокарда, спрощуючи аналіз для лікарів. Однак для автоматизованих систем та НМ така надмірна кількість корельованих відведень може бути надлишковою.

Відповідно до цього, система ортогональних відведень Франка, що базується на тривимірному представленні сигналу вздовж вісей X, Y та Z може також виявитися ефективною. Вона забезпечує компактне представлення електричної активності серця, зменшуючи взаємозалежність сигналів і зберігаючи ключову діагностичну інформацію. Дослідження показують, що НМ можуть досягати високої точності в розпізнаванні кардіологічних патологій з використанням лише трьох ортогональних відведень, що дозволяє замінити 12-канальну ЕКГ [12–14].

Хоча переважна більшість електрокардіографічного обладнання орієнтована на обробку стандартної 12-канальної системи відведень, існують підходи, що дозволяють здійснювати перетворення цих відведень у тривимірну ортогональну систему Франка. Перехід до системи Франка може бути реалізований шляхом застосування лінійного перетворення, яке проектує 12-канальний сигнал у простір трьох ортогональних компонент: X, Y та Z.

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

де P – матриця лінійних перетворень.

Матриця лінійних перетворень є об'єктом досліджень та розробляється окремо для 1, 3, 12 стандартних відведень. За J. Vondrak [11] матриця лінійних перетворень наведена в таблиці 1.

Таблиця 1. Матриця лінійних перетворень ЕКГ сигналів у систему ортогональних відведень

	I	II	III	aVR	aVL	aVF
X	0.63	0.24	-0.40	-0.43	0.52	-0.08
Y	-0.24	1.07	1.30	-0.42	-0.77	1.18
Z	0.06	-0.13	-0.19	0.04	0.13	-0.16
	V1	V2	V3	V4	V5	V6
X	-0.52	0.04	0.88	1.21	2.13	0.83
Y	0.16	0.16	0.10	0.13	0.13	0.08
Z	-0.92	-1.39	-1.28	-0.60	-0.09	0.23

Маючи сигнали ЕКГ в системі відведень Франка, можна побудувати результуючий вектор $R(t)$, що містить узагальнене представлення електричної активності серця в тривимірному просторі:

$$R(t) = \sqrt{X(t)^2 + Y(t)^2 + Z(t)^2}$$

де $X(t)$, $Y(t)$, $Z(t)$ – проєкції тривимірної ЕКГ на вісі X, Y, Z.

Звідси випливає, що за допомогою подібного підходу можна створювати стандартизовані сукуп-

ності кардіографічних записів на основі вхідних даних, які представлені в різних системах відведень.

2) Метод аналізу головних компонент

За допомогою аналізу головних компонент (РСА) можна скоротити 12 відведень ЕКГ до довільної кількості головних компонент. Метод аналізу головних компонент дозволяє виявити лінійні комбінації відведень, які містять найбільшу дисперсію даних, зменшуючи розмірність вхідного сигналу без значної втрати діагностичної інформації. Для цього з кожного відведення матриці сигналів $ECG_{[12 \times 500]}$ віднято його середнє значення, після чого обчислюється коваріаційна матриця C

$$C = \frac{1}{n-1} ECG_{[12 \times 500]}^T \cdot ECG_{[12 \times 500]}$$

де n – кількість відліків ЕКГ сигналу

Власні вектори V коваріаційної матриці C визначають напрямки головних компонент, а проєкція даних у простір меншої розмірності виконується за формулою

$$Z = X \cdot V_k$$

де V_k матриця, що містить перші k головних компонент, X – центрована матриця вхідних даних.

3) Передискретизація сигналу ЕКГ

Можна скорочувати розмірність вхідних даних за допомогою зменшення частоти дискретизації, тобто зменшення кількості точок відліку сигналу за секунду. Такий підхід дозволяє зменшити обсяг даних, що передаються або обробляються, без істотної втрати діагностично значущої інформації, особливо, якщо початкова частота дискретизації значно перевищує необхідний мінімум для відтворення основних хвиль ЕКГ. Згідно з теоремою Найквиста [15], для збереження інформації про частотні компоненти ЕКГ, зокрема зубці P, QRS та T, достатньо частоти дискретизації щонайменше вдвічі більшої за максимальну частоту сигналу, яка зазвичай не перевищує 150 Гц. З огляду на це, у більшості випадків частоти 250–500 Гц є достатніми. Зниження частоти дискретизації відбувається за рахунок зменшення кількості відліків у часовому ряді, яка включає попередню низькочастотну фільтрацію, що усуває високочастотні компоненти, здатні викликати спотворення під час передискретизації.

4) Нейромережові методи зменшення розмірності

Існують нейромережові підходи до зменшення розмірності сигналу. Одним з найрозповсюдженіших підходів є використання автоенкодера – НМ, що навчається кодувати вхідний сигнал у стисле латентне представлення (вектор ознак) і відновлювати його на виході з мінімальними втратами [16].

Автоенкодер складається з двох частин: енкодера, який перетворює високорозмірний вхід x у вектор меншої розмірності z та декодера, який реконструює сигнал $\hat{x}$ з латентного простору.




Рис. 2. Блок-схема класичного автоенкодера

Навчання відбувається шляхом мінімізації функції втрат. Зазвичай у якості функції втрат для навчання використовується середньоквадратична похибка:

$$L = \|x - \hat{x}\|^2.$$

Латентний вектор автоенкодера може бути безпосередньо використаний як вхід для класифікаторів або нейромережових моделей, що значно зменшує обсяг даних і прискорює обчислення.

Окрім повнозв'язних шарів, які є основним компонентом перцептрона, для зменшення розмірності вхідних даних у НМ часто використовуються згорткові шари [17]. Вони застосовують фільтри (ядра згортки), які переміщуються вздовж сигналу та виявляють локальні особливості комплексів QRS або хвиль Р і Т в ЕКГ.




Рис. 3. Порівняння методів згортки та пулінгу

Ядра згортки – це невеликі вагові матриці, які навчаються автоматично, а результати їх застосування виявляють ключові патерни сигналу. Під час використання кроку згортки більше одиниці згортка сама по собі зменшує розмірність вихідних даних. Згортка часто комбінується з такими методами, як пулінг максимальних або середніх значень (Max pooling, Average Pooling), що додатково спрощує представлення ЕКГ даних, зменшуючи розмірність і водночас зберігаючи найбільш значущу інформацію. Пулінг максимальних значень з кожного фрагмента сигналу зберігає лише найбільші значення, які пов'язані з ключовими особливостями сигналу. Пулінг середніх значень, у свою чергу, згладжує локальні варіації, обчислюючи середнє значення в межах фіксованого вікна, що дозволяє зберігати загальний тренд сигналу та зменшити вплив шумів або одиничних викидів. Такий підхід надає змогу мережі ефективно виділяти релевантні ознаки, зме-

ншувати обчислювальну складність і підвищувати стійкість до шуму та варіацій даних.

5) Механізм уваги в нейронних мережах

Сучасні дослідження також використовують шари уваги для підвищення якості аналізу ЕКГ-сигналів [18]. Механізм уваги дозволяє моделі динамічно зосереджуватися на фрагментах сигналу з найбільшою кількістю діагностичної інформації, що є особливо важливим у випадках, коли корисна інформація розподілена нерівномірно або присутній шум. На відміну від згорткових шарів з фіксованим вікном, шар уваги адаптивно призначає вагу кожному елементу послідовності, враховуючи його значущість у контексті всієї вибірки. В автоенкодерах шари уваги покращують якість латентного представлення, дозволяючи зберігати лише найрелевантніші характеристики сигналу, що у свою чергу позитивно впливає на точність подальшої класифікації. Крім того, шар уваги сприяє підвищенню стабільності навчання, зменшуючи вплив нерелевантних варіацій у даних та покращуючи узагальнюючу здатність моделі.

Архітектура шарів уваги (attention layers) базується на ідеї того, що модель може навчитися визначати, які частини вхідної послідовності є більш важливими для реалізації поставленої задачі. Найбільш поширеним і потужним варіантом реалізації є механізм масштабованої скалярної уваги (Scaled Dot-Product Attention), який лежить в основі архітектури «Трансформер» [19].

У механізмі уваги кожен вхідний вектор X перетворюється на три незалежні лінійні проєкції: запит (Query, Q), ключ (Key, K) та значення (Value, V), які виконують різні функції – відповідно, формують запит, визначають контекст для порівняння та несуть значення, що передаються на вихід. Ці проєкції обчислюються як:

$$Q = X_{n \times d} W_Q, K = X_{n \times d} W_K, V = X_{n \times d} W_V,$$

де: $X_{n \times d}$ – матриця вхідних векторів, W_Q, W_K, W_V – параметричні матриці вагових коефіцієнтів, які навчаються під час тренування моделі. Такий підхід дозволяє шару уваги адаптивно визначати важливість кожного елемента послідовності щодо інших. Схожість C між проєкціями Q та K визначається через скалярний добуток:

$$C = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right),$$

де: $\sqrt{d_k}$ – коефіцієнт масштабування, який залежить від розміру матриці $X_{n \times d}$.

Тоді вихід шару уваги R розраховується як:

$$R = C \cdot V.$$

Іноді Q може бути частиною однієї послідовності, а K та V – іншої; такий підхід називається перехресною увагою (cross-attention) і дозволяє моделі встановлювати зв'язки між різними джерелами інформації [19]. Перехресна увага може використовув-

ватися для узгодження інформації між кількома відведеннями, або між сигналом і його латентним представленням.

6) Дані для дослідження

Для тестування методів зменшення розмірності даних та аналізу отриманих векторів ознак сигналу ЕКГ було обрано базу даних «PTB-XL, a large publicly available electrocardiography dataset» [20]. Ця база містить близько 22000 ЕКГ записів у 12 відведеннях, налічуючи більше ніж 70 патологічних станів серцево-судинної системи. Наявність подібної кількості патологічних станів в базі даних дозволяє сформулювати репрезентативні вибірки для класифікації різних патологій, особливо тих, для виявлення яких необхідний аналіз окремих відведень. Тривалість кожного запису складає приблизно 10 секунд, ЕКГ записи даної бази записані з роздільною здатністю АЦП 16 біт та частотою дискретизації в 500 Гц, що дозволяє аналізувати патології, ознаками яких є високочастотні або низькоамплітудні компоненти сигналу.

Для порівняльного аналізу було обрано патології, які потребують 12-канальної ЕКГ для якісної діагностики. Наприклад, синдром Вольфа-Паркінсона-Уайта (СВПУ) характеризується наявністю дельта-хвилі, яка не завжди помітна у стандартних відведеннях. Задній лівий фасцикулярний блок (ЗЛФБ) визначається за змінами електричної осі серця, що вимагає аналізу фронтальних відведень. Гіпертрофія лівого шлуночка (ГЛШ) характеризується збільшенням амплітуди QRS-комплексу, а також порушенням реполяризації, які найчастіше виявляються у грудних відведеннях. Повна блокада лівої ніжки пучка Гіса (ПБЛНПГ) проявляється характерними деформаціями комплексу QRS, які найкраще видно у грудних відведеннях V5–V6. Локалізовані форми інфаркту міокарда – латеральний (ЛІМ), задньо-латеральний (ЗЛІМ) та нижній (НІМ) – мають специфічні електрокардіографічні зміни у відповідних групах відведень (I, aVL, VI–V6, II, III, aVF). Аналогічно, ішемія нижньо-латеральної ділянки міокарда (ІНЛДМ), а також, Гострий інфаркт міокарда (ГІМ), Ішемія передньо-латеральної ділянки міокарда (ІПЛДМ), Ішемія нижньої ділянки міокарда (ІНДМ), Ішемія передньо-септальної ділянки міокарда (ІПСДМ), як варіанти ішемії та інфарктів різної локалізації, потребують наявності 12-канальної ЕКГ, оскільки у скороченому варіанті ЕКГ їх ознаки можуть бути повністю відсутні або нерозпізнані. До обраного переліку серцевих захворювань були додані стани, для виявлення яких критично важливим є якісний аналіз високочастотних та низькоамплітудних компонент сигналу. Зокрема, пізні потенціали передсердь (ППП) та пізні потенціали шлуночків (ППШ) вимагають високої точності виявлення слабо виражених амплітудних та частотних ознак. Сигнали пізніх потенціалів були штучно додані до датасету шляхом накладання штучно згенерованих пізніх потенціалів дії на ЕКГ в нормі. Процес поширення потенціалів дії був змодельова-

ний з використанням моделі паралельних провідностей [21]. Крім того, до тренувального набору були додані сигнали класу норма (НОРМА).

7) Оцінка якості класифікації нейронних мереж

Для оцінки якості класифікації нейронних мереж використовувались показники чутливості, специфічності та загальної точності.

Чутливість являє собою здатність моделі правильно виявляти відсоток об'єктів, які були правильно класифіковані як належні до цього класу серед усіх об'єктів, які фактично до нього належать. Чутливість визначається за формулою:

$$\text{Чутливість} = \frac{TP}{TP + FN}.$$

Специфічність відображає здатність моделі правильно ідентифікувати ті випадки, що не належать до обраного класу, і визначається як:

$$\text{Специфічність} = \frac{TN}{TN + FP}.$$

У випадку багатокласової класифікації кожен клас розглядається окремо за принципом "один проти всіх", тому для кожного з них обчислюються наступні показники:

- істинно позитивні значення (*True Positive, TP*) – кількість об'єктів, які справді належать до даного класу і були правильно класифіковані як такі;
- хибно негативні значення (*False Negative, FN*) – кількість об'єктів, що належать до даного класу, але були помилково віднесені до інших класів;
- хибно позитивні значення (*False Positive, FP*) – кількість об'єктів, які не належать до даного класу, але були неправильно класифіковані як такі, що належать до нього;
- істинно негативні значення (*True Negative, TN*) – кількість об'єктів, які не належать до даного класу і були правильно класифіковані як такі, що не належать.

Тоді загальна точність розраховується за формулою:

$$\text{Точність} = \frac{\sum TP_i}{N}.$$

де: TP_i – кількість правильно класифікованих об'єктів для кожного класу, N – загальна кількість об'єктів у вибірці.

Розробка архітектури автоенкодера для отримання скороченого вектора ознак ЕКГ сигналу

Альтернативним підходом до отримання компактного представлення ЕКГ-сигналу є використання НМ для автоматичного виділення ознак з необхідною діагностичною інформацією. Поширеним архітектурним рішенням для реалізації цього методу є використання автоенкодера – моделі НМ, що стискає вхідні дані до латентного простору з меншими розмірностями, зберігаючи ключові характеристики сигналу. Отримане латентне представлення може бути безпосередньо використано як вхід до класифі-

каційних моделей, що суттєво зменшує кількість обчислень та прискорює навчання без значної втрати діагностичної інформації.

Глибокі архітектури автоенкодерів, які виявляють слабкі залежності, стискають вхідні дані до латентного простору з низькою інформаційною щільністю, який схожий на шум. Така властивість проявляється через те, що шари моделі починають запам'ятовувати локальні особливості сигналів, узагальнюючи лише мінімальні відмінності для реконструкції. Така особливість дуже корисна для генерації нових подібних зразків сигналу, але для побудови вектору ознак, який може бути застосований для класифікації це є недоліком, оскільки отримане представлення не відображає узагальненої структури класів, а лише зберігає індивідуальні особливості конкретних зразків. У результаті вектор ознак втрачає дискримінантну здатність, що ускладнює розрізнення класів у задачах класифікації. Це призводить до зниження точності моделі та погіршення узагальнення, особливо під час обробки нових даних.

Для подолання цих обмежень застосовуються методи регуляризації, збільшення розмірності латентного простору, а також варіаційні автоенкодери, які завдяки імовірнісному підходу формують більш узагальнене представлення [22]. Проте у випадку ЕКГ-сигналів, які характеризуються високою варіативністю, наявністю шумів і артефактів, навіть ці методи не завжди забезпечують достатню стабільність. Наприклад, під час надмірного узагальнення, невеликі морфологічні відмінності, що мають клінічне значення, можуть бути втрачені.

Складна просторова та часова структура ЕКГ вимагає від моделі здатності не лише стискати сигнал, а й зберігати контекстні та ритмічні взаємозв'язки. Для вирішення даної проблеми, у межах даного дослідження була розроблена спеціалізована архітектура автоенкодера, орієнтована на збереження діагностично релевантної інформації навіть за високого ступеня стиснення даних (рис. 4.)




Рис. 4. Архітектура автоенкодера для отримання скороченого вектора ознак ЕКГ сигналу

Розроблена архітектура автоенкодера на відміну від класичної має ряд покращень для отримання скороченого вектора ознак ЕКГ сигналу, що містить максимальну кількість діагностичної інформації в латентному просторі.

Основа архітектури становить симетричний автоенкодер. На перший, згортковий шар автоенкодера подається вхідний сигнал, після проходження якого, формується 30 векторів ознак. Оскільки шар має не одиничне зміщення, вихідні вектори ознак скорочуються в 4 рази. Якщо на вхід подається 12 каналний ЕКГ сигнал тривалістю 1 секунда та частотою дискретизації 500 Гц (12x500 відліків), то після проходження шару згортки отримується 30 векторів ознак довжиною 125 відліків. Після згорткового шару наявні три послідовні повнозв'язні шари, які поступово зменшують розмірність ознак до вектора розміром 160 коефіцієнтів. Наступним етапом, отримане латентне представлення за допомогою симетричних шарів розгортається у вихідний сигнал такої самої розмірності, як і вхідний. Повнозв'язні шари в розробленій архі-

тектурі розмірністю $M \times N$ віддзеркалюються шарами розмірністю $N \times M$. В свою чергу, згортковий шар віддзеркалюється шаром транспонованої згортки, який відновлює просторову розмірність, що була зменшена під час побудови латентного представлення автоенкодера.

Для уникнення неоднорідності розподілу вагових коефіцієнтів під час навчання, для симетричних шарів були використані спільні ваги. Використання спільних вагових коефіцієнтів створює умови, за яких енкодер і декодер змушені навчатися узгоджено. У такій архітектурі і енкодер, і декодер використовують одні й ті самі коефіцієнти як для виділення ознак, так і для реконструкції сигналу. Це виключає можливість надмірної пристосованості декодера до тренувальних даних та не дозволяє йому запам'ятовувати форму даних незалежно від латентного простору. У результаті модель виконує виявлення важливих характеристики вхідного сигналу.

Крім того, для покращення передачі градієнтів та стабільності навчання в блоці енкодера застосовуються залишкові зв'язки (*Residual Connections*).

Залишкові зв'язки поєднують виходи попередніх шарів зі значеннями коефіцієнтів на поточному шарі енкодера. Для врівноваження розмірності залишкових зв'язків та вагових коефіцієнтів шарів енкодера застосовуються шари пулінгу максимальних значень.

В розробленій архітектурі використовується шар уваги, який порівнює значення на виході енкодера (Q) з вхідними ознаками, що отримані на етапі згортки (K , V). Формуючи зворотний зв'язок, цей шар забезпечує адаптивне фокусування енкодера на найбільш релевантних ознаках, що сприяє більш точному аналізу вхідних даних та покращує якість навчання моделі. Крім того, шар уваги грає роль додаткового шару регуляризації, зменшуючи вплив шуму та покращуючи стійкість моделі до перенавчання. Вихід шару уваги також поєднується з послідовністю залишкових зв'язків і після застосування нормалізації коефіцієнтів утворюється вектор латентного представлення енкодера, який надходить на шар декодера та може бути використаний в якості скороченого вектора ознак.

Додані до енкодера шари покликані покращити виявлення ознак у вихідному сигналі та сформувати латентне представлення, що найкраще відображає суттєві характеристики. Але використання цих заходів не гарантує кодування всіх необхідних ознак в латентний простір, оскільки вагові коефіцієнти шарів, що навчаються, також запам'ятовують частину морфологічної інформації про сигнал.

Відповідно, можна сформувати вектор ознак з більш повним представленням релевантної інформації. Результуючий вектор ознак формується після об'єднання коефіцієнтів латентного представлення (1×160) та вагових коефіцієнтів натренованих шарів автоенкодера (1×80). Вектор вагових коефіцієнтів шарів для об'єднання формується завдяки шару пулінгу максимальних значень, використовуючи який можна регулювати довжину вектора вагових коефіцієнтів.

Тренування автоенкодера виконується шляхом мінімізації функції втрат середньоквадратичної похибки між вхідними даними та їх реконструкцією на виході декодера. Але якість навчання можна покращити не лише тренуючи НМ відтворювати вхідні дані, а й ще розрізняти патологічні класи ЕКГ сигналів. Для цього в архітектуру додано повнозв'язний шар нейронів без використання функції активації в якості класифікатора. Для реалізації класифікатора було обрано найпростішу архітектуру для того, щоб максимальна кількість діагностичних ознак виділялася саме в шарах автоенкодера.

Застосування подібної, комбінованої архітектури для навчання автоенкодера дозволяє створити такий скорочений вектор ознак, який одночасно містить інформацію і про форму сигналу і про ознаки, які є важливими для кла-

сифікації ЕКГ сигналів з різними типами патологій. В такому випадку функція втрат також стає комбінованою, і має наступний вигляд:

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

де: α , β – вагові коефіцієнти, MSE – функція втрат «Середньоквадратична помилка», CE – функція втрат «Перехресна ентропія». Функції MSE та CE розраховуються як:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2,$$

де: Y_i , $\hat{Y}_i$ – істинний та передбачений елемент послідовності, n – кількість елементів послідовності.

$$CE = - \sum_{i=1}^C y_i \cdot \log(\hat{y}_i),$$

де: C – кількість класів, y_i – елемент вектора у форматі *one-hot encoding*, $\hat{y}_i$ – передбачена ймовірність для класу i .

Варіюючи вагові коефіцієнти, можна змінювати чутливість моделі до похибок реконструкції сигналу, або класифікації. В дослідженні, найкращий баланс між якістю реконструкції сигналу та класифікації було отримано використовуючи значення вагових коефіцієнтів $\alpha = 0.1$, $\beta = 0.9$.

Запропонована комбінована архітектура здатна натренувати енкодер формувати латентний простір, зберігаючи ознаки сигналів бажаного типу. Наприклад, під час тренування автоенкодера на класах ЕКГ сигналів, які містять низькоамплітудні складові, можна зробити модель більш чутливою для класифікації пізніх потенціалів шлуночків та передсердь, або інших патологій, що характеризуються низькоамплітудними компонентами. Як наслідок, можна формувати універсальні вектори ознак, які спеціалізовані під конкретну задачу. Але оскільки сформований латентний вектор також містить інформацію про форму вхідного сигналу, згенерований скорочений вектор ознак дозволяє класифікувати й інші патології, які не були залучені до навчання автоенкодера.

Крім того, використовуючи отримане латентне представлення та деко дер, можна відновити форму вхідного сигналу, що робить дану архітектуру корисною не тільки в формуванні векторів ознак для класифікації, а водночас у стисканні даних ЕКГ зі збереженням діагностичної інформації.

Тестування розробленої моделі нейромережевого автоенкодера

1) Нейромережеві архітектури для тестування

Для тестування розробленої нейромережевої моделі, а також інших методів формування скороченого вектору ознак, було обрано дві архітектури НМ.

Перша архітектура – класифікатор, побудований на повнозв'язних шарах. Така архітектура є базовою моделлю штучної НМ, яка добре підходить для порівняльного аналізу. Вона передбачає послідовне з'єднання кількох повнозв'язних шарів

із функціями активації. Така архітектура слабо враховує просторові або часові залежності в сигналі, однак дозволяє оцінити, ступінь збереження діагностичної інформації в скороченому векторі ознак для задачі класифікації. Архітектура даної мережі наведена на рис. 5.




Рис. 5. Архітектура повнозв'язної НМ для тестування

Шари цієї мережі зменшують розмірність вхідного вектора ознак до кількості навчальних класів. Вхідний шар та приховані шари використовують активаційну функцію *ReLU* для покращення збіжності та прискорення навчання моделі, а вихідний шар використовує сигмоїдну активаційну функцію, яка формує вірогідності вихідних класів.

Друга архітектура – класифікатор, спеціалізований на обробці ЕКГ-сигналів, під назвою «*Multi-ECGNet*» (*EcgNet*)[23]. Ця модель побудована на основі вдосконаленої згорткової НМ, в якій використовуються полегшені згорткові операції з меншим числом параметрів, що дає змогу знизити обчислювальну складність моделі без втрати якості аналізу сигналу. Додатково застосовується спеціальний механізм, що дозволяє моделі автоматично визначати, які канали (відведення) містять найбільше корисної інформації, і відповідно змінювати їхню вагу в процесі навчання. Такий підхід дозволяє враховувати як часові, так і міжканальні залежності у сигналі. Ця архітектура орієнтована на багатокласову класифікацію, що дає змогу одночасно виявляти до 55 типів аритмій.

2) Попередня обробка сигналів ЕКГ

До тренувальної вибірки було включено ЕКГ-сигнали з патологіями, ознаки яких можуть бути достовірно виявлені на короткому фрагменті усередненого кардіоцикла, що дозволило спростити вхідні дані. З метою прискорення обчислювального процесу для кожного 10-секундного фрагменту ЕКГ формувалася усереднений кардіоцикл тривалістю 1 секунда. Отже, результуючий датасет було сформовано з 12-ти каналних записів ЕКГ тривалістю 1 с та розмірністю 12x500 відліків.

Попередня обробка ЕКГ-сигналу була виконана шляхом фільтрації в діапазоні 0,5 –

150 Гц за допомогою фільтра Баттерворта 5-го порядку з нульовою фазою [24] для видалення дрейфу ізолінії та високочастотних завад. Крім того, синфазна завада електромережі частотою 50 Гц була видалена за допомогою режекторного цифрового фільтра з фактором якості $Q = 50$.

3) Порівняння методів побудови скороченого вектора ознак

Першим методом для порівняння було обрано зниження частоти дискретизації сигналу. Оригінальна частота дискретизації сигналу становить 500 Гц. Тоді, якщо частота високочастотних компонент сигналу становить 150 Гц, то за теоремою Найквиста для локалізації цих компонент достатньо частоти дискретизації 300 Гц. Відповідно, для порівняння передискретизацію вхідного сигналу було виконано до 300 Гц, 150 Гц, 75 Гц. Такі частоти було обрано для аналізу впливу різного ступеня стиснення сигналу на результати класифікації. В свою чергу, з використанням таких значень, вхідний сигнал стискається в 1,7, 3.3, та 6.7 разів відповідно.

Коефіцієнт стиснення розраховується за формулою:

$$comp = \frac{N_{in}}{N_{out}},$$

де: N_{in} – кількість відліків в початковому сигналі, N_{out} – кількість відліків у скороченому векторі ЕКГ, який було отримано після застосування методу скорочення розмірності даних.

Наступним методом зменшення розмірності даних було обрано переведення 12 каналної ЕКГ в ортогональну систему відведень Франка за допомогою лінійних перетворень. Такий метод дозволяє зменшити надлишковість інформації в ЕКГ сигналах, та зменшити розмірність вхідних даних в 4 рази.

Також для порівняння було використано метод обчислення результуючого вектора, отриманого за допомогою проєкції ЕКГ сигналу на вісі X, Y, Z. Цей метод було обрано для оцінки кількості діагностичної інформації, яка втрачається після зменшення розмірності сигналу за допомогою лінійних методів. З використанням результуючого вектора, розмірність вхідних даних було зменшено в 12 разів.

Крім того, аналіз головних компонент (РСА) було використано як альтернативний лінійний метод зменшення розмірності. Цей метод порівнювався з перетворенням ЕКГ в систему відведень Франка. Хоча метод РСА спотворює морфологічні особливості ЕКГ сигналу, він здатний зберегти найбільшу дисперсію даних у новому ортогональному просторі меншої розмірності (3 головних компонента). Результат роботи РСА наведено на рис. 6.

Розроблена модель автоенкодера була налаштована так, щоб з вхідних даних ЕКГ розмірністю 12x500 відліків отримувалася скорочений вектор ознак розмірністю 1x240 відліків, із яких перші 160 відліків кодують латентний простір, а останні 80

відліків становить вектор вагових коефіцієнтів шарів автоенкодера.




Рис. 6. Перші три компоненти розкладу ЕКГ сигналу методом головних компонент

Отриманий скорочений вектор ознак містить інформацію про форму вхідного ЕКГ сигналу та про ознаки, що відображають відмінності між класами, що досліджуються. З використанням скороченого вектора ознак, коефіцієнт стиснення складає 25. Приклад реконструкції частини вхідного сигналу та скороченого вектора ознак наведено на рис. 7.




Рис. 7. Приклад роботи автоенкодера, де: а – початковий сигнал; б – сигнал, реконструйований з латентного простору; в – скорочений вектор ознак сигналу

4) Аналіз отриманих результатів

Аналіз роботи різних методів отримання скорочених векторів ознак була оцінена на основі обраних нейронних мереж для класифікації. Результати оцінки наведено в порівняльній таблиці (табл. 1).

За результатами аналізу порівняльної таблиці можна визначити, що найкращі результати класифікації для обох моделей НМ отримано з використанням вхідних 12-канальних записів ЕКГ без стиснення.

Метод зменшення частоти дискретизації показав поступове зменшення якості класифікації зі зменшенням частоти дискретизації.

Таблиця 1. Показники точності класифікації обраних моделей нейронних мереж після використання різних методів зменшення розмірності даних

Методи скорочення розмірності даних	<i>EcgNet</i>	Повнозв'язна мережа
Без стиснення	75%	75%
Ресемплінг 300 Гц	73%	75%
Ресемплінг 150 Гц	71%	73%
Розроблений енкодер	68%	78%
Ресемплінг 75 Гц	67%	72%
Перетворення у систему Франка	64%	70%
РСА [3]	59%	65%
Обчислення результуючого вектора	56%	61%

Як наслідок, після зниження частоти з 500 до 300 Гц, якість класифікації знизилась на 0-2 %. Після зменшення частоти до 150 Гц, точність впала на 2-4 %. Зниження частоти дискретизації до 75 Гц показала зменшення точності класифікації на 3-8 % від максимальної.

Ще меншу точність класифікації було отримано після переведення ЕКГ в систему відведень Франка, та зменшення розмірності за допомогою методу РСА. Зокрема, використання РСА для зменшення розмірності показало гірші результати класифікації ніж під час використання ортогональної системи відведень. В результаті чого було зафіксовано зниження точності на 10-16 % та 5-11 %, відповідно. Подібне зниження точності класифікації пояснюється тим, що під час зменшення частоти дискретизації втрачаються важливі високочастотні компоненти для класифікації, а під час зменшення кількості відведень втрачається рівень просторової деталізації різних частин серця, що необхідно для виявлення різних типів патологічних станів.

Розрахунок результуючого вектора ознак ЕКГ сигналу з використанням ортогональних відведень показує зниження точності класифікації на 14-19 %, що свідчить про майже повну втрату просторової інформації.

Для обраних моделей НМ на основі розрахованого скороченого вектора ознак було отримано зниження точності класифікації – на 2 % для мережі ECGnet та збільшення точності класифікації на 3 % для повнозв'язної НМ.

Отже, модель з використанням розробленого скороченого вектора ознак показала найбільшу точність класифікації за найбільшого ступеня стиснення даних ЕКГ. Отримані результати показують, що розроблений скорочений вектор ознак здатний не тільки зберігати діагностичну інформацію, а ще й покращувати здатність моделі розрізняти патологічні ознаки.

Для всіх методів скорочення розмірності з використанням повнозв'язної НМ були отримані кращі результати. Це пояснюється тим, що мережа EcgNet

більш налаштована на аналіз класичних багатоканальних записів ЕКГ. У свою чергу, за відсутності згорткових шарів, повнозв'язна НМ краще обробляє більш компактні розраховані вектори ознак.

Здатність обраних моделей НМ розрізнити серцеві патології з використанням розробленого скороченого вектора ознак було проаналізовано більш детально на основі порівняння результатів класифікації з моделями НМ, що використовують ЕКГ сигнали у 12 відведеннях (табл. 2).

За результатами аналізу табл. 2, маємо, що для мережі EcgNet після використання скороченого вектора ознак точність класифікації в середньому знижується з 75 % до 68 %, тобто на 7 %. Однак, ця зміна має змішаний характер. Наприклад, для класу ЗЛІМ спостерігається зростання точності з 58 % до 75 % та з 86 % до 88 % для класу ППІ. А для класу ІНДМ спостерігається зниження з 77 % до 40 %, також для класів ГІМ та НІМ спостерігається зниження точності на 7 %. У деяких випадках точність майже не змінюється, як для класів ПБЛНПГ та ПЛДМ.

Таблиця 2. Порівняння результатів точності класифікації 12 каналної ЕКГ та скороченого вектора ознак ЕКГ сигналу

Класи/Оцінки	Початковий сигнал						Сформований скорочений вектор ознак					
	EcgNet			Повнозв'язна модель			EcgNet			Повнозв'язна модель		
	Точ.	Чутл.	Спец.	Точ.	Чутл.	Спец.	Точ.	Чутл.	Спец.	Точ.	Чутл.	Спец.
ЗЛФБ	0.92	0.84	0.98	0.78	0.60	0.99	0.72	0.58	0.99	0.95	0.87	0.99
СВПУ	0.88	0.76	0.99	0.96	0.84	0.99	0.88	0.78	0.99	0.98	0.88	0.99
ЛІМ	0.83	0.58	0.93	0.92	0.58	0.93	0.63	0.46	0.93	0.94	0.58	0.90
ІНДМ	0.77	0.53	0.96	0.7	0.40	0.96	0.40	0.37	0.97	0.67	0.58	0.91
ІНЛДМ	0.40	0.13	0.99	0.43	0.17	0.97	0.43	0.27	0.98	0.27	0.33	0.96
ІПСДМ	0.57	0.13	0.99	0.67	0.40	0.99	0.57	0.40	0.97	0.80	0.13	0.99
ЗЛІМ	0.58	0.45	0.99	0.68	0.67	0.99	0.75	0.75	0.98	0.70	0.68	0.99
ПБЛНПГ	0.93	0.90	0.99	0.89	0.88	0.99	0.93	0.89	0.99	0.86	0.86	0.99
ПЛДМ	0.84	0.71	0.88	0.71	0.47	0.93	0.67	0.48	0.90	0.73	0.50	0.90
ГІМ	0.66	0.33	0.97	0.61	0.33	0.90	0.59	0.30	0.97	0.70	0.36	0.96
ППІ	0.86	0.73	0.92	0.73	0.39	0.94	0.88	0.51	0.93	0.83	0.43	0.94
ППШ	0.90	0.83	0.98	0.69	0.34	0.94	0.83	0.67	0.94	0.97	0.89	0.99
ГЛШ	0.73	0.70	0.89	0.52	0.31	0.94	0.55	0.41	0.95	0.72	0.37	0.97
НОРМА	0.87	0.78	0.92	0.88	0.72	0.94	0.80	0.77	0.94	0.94	0.94	0.95
НІМ	0.56	0.27	0.98	0.66	0.33	0.97	0.63	0.35	0.96	0.70	0.42	0.96
Загальна точність	0.75	0.58	0.96	0.72	0.50	0.96	0.68	0.53	0.96	0.78	0.59	0.96

Такий результат зумовлений особливостями згорткової архітектури EcgNet. Оскільки ця мережа фокусується на виявленні локальних патернів у багатоканальному ЕКГ сигналі, то під час стиснення вхідних даних вона може зберігати або навіть покращувати результат у тих випадках, де морфологія сигналу з патологією має чітко локалізовані ознаки. Натомість, у випадку розмитих або складних форм сигналів з патологією, наприклад, ішемії чи інфарктів, мережа втрачає важливу інформацію, що й призводить до зниження точності.

Для повнозв'язної НМ, яка базується на простішій, лінійній трансформації ознак, точність також змінюється нерівномірно, але в середньому підвищується на 6 %. Зростання точності спостерігається для більшості класів, наприклад для ЗЛФБ – на 17 %, для ППШ – на 28 %, для ІПСДМ – на 13 %, тощо. Істотне зниження помітне лише у деяких класах, наприклад, ІНЛДМ – на 16 % чи ЛІМ – на 2 %. Такі результати можуть свідчити про те, що повнозв'язна модель краще виділяє закономірності в більш компактному наборі даних. Спроще-

ний простір ознак, що сформовано в результуючому векторі, знижує ризик перенавчання за рахунок зменшення шуму та скорочення малозначущих патернів, що покращує ступінь узагальнення моделі.

Підвищення точності класифікації для таких класів, як ППШ та ППІ, свідчить про ефективність аналізу сигналів із низькоамплітудними та високочастотними компонентами. Такий результат отримано завдяки зменшенню впливу високочастотного шуму у результуючому векторі ознак. Отже, можна зробити висновок, що використання розробленого скороченого вектора ознак для класифікації:

- зменшує вимоги до обчислювальних ресурсів, що критично для мобільних діагностичних пристроїв;
- зменшує ризик перенавчання, особливо в простих повнозв'язних моделях, де надмірна кількість ознак може призводити до запам'ятовування шуму;
- підвищує стійкість до індивідуальних варіацій ЕКГ даних;

– дозволяє отримати значне стиснення ЕКГ даних зі збереженням морфологічної інформації та міжкласових відмінностей.

Крім того, використання розробленого скороченого вектора ознак та архітектури автоенкодера веде до прискорення розробки, тестування гіпотез та нейромережових архітектур. Також розроблений автоенкодер може бути корисним для стиснення, або кодування діагностичних даних ЕКГ, що може бути корисним для розробки високопродуктивного програмного забезпечення або створення обширних баз даних.

На рис. 8 представлено результати тренування розробленого автоенкодера у вигляді графіків зміни функцій втрат протягом 500 епох.




Рис. 8. Зміна показників функцій втрат під час навчання розробленого автоенкодера

З аналізу графіку на рис. 8 видно, що в процесі навчання розробленого автоенкодера перехресна ентропія, яка характеризує якість розпізнавання класів, зменшилася з 1.42 на першій епосі до 0.05 на 500-й. Одночасно з цим середньоквадратична помилка реконструкції сигналу знизилася з 0.05 до 0.003, що вказує на ефективне навчання моделі точно відтворювати вхідні дані. Таким чином, автоенкодер формує якісне внутрішнє представлення, яке не лише містить інформативні ознаки, необхідні для успішного розпізнавання класів, а й точної реконструкції сигналу, що забезпечує універсальність моделі в задачах класифікації та реконструкції, а також сприяє прискоренню навчання і підвищенню стабільності НМ.

Висновки

Розроблена архітектура автоенкодера, що поєднує згорткові шари, залишкові зв'язки, механізм уваги та симетричну структуру з використанням спільних вагових коефіцієнтів, дозволяє не лише суттєво зменшити обсяг вхідних даних (до 25 разів), але й зберегти діагностично важливу інформацію. Такий підхід сприяє досягненню високої точності класифікації, зокрема у випадку використання спрощених нейромережових архітектур. Застосування комбінованої функції втрат з регульованими ваговими коефіцієнтами дозволяє за-

безпечувати високу якість реконструкції сигналу та ефективність класифікації, забезпечуючи баланс між збереженням структурних особливостей даних і здатністю моделі розрізняти класи.

Результати дослідження продемонстрували ефективність використання розробленого скороченого вектора ознак ЕКГ сигналів для задач автоматизованої класифікації серцево-судинних патологій. Коли коефіцієнт стиснення становить 25, загальна точність класифікації з використанням скороченого вектора становить 68 % для *EcgNet* і 78 % для повнозв'язної моделі, що порівняно зі стандартною 12-канальною ЕКГ на 2 % нижче і на 3 % вище, відповідно.

Порівняно з традиційними методами зменшення розмірності, такими як *PCA* (59–65 %) та переведення у систему Франка (64–70 %), запропонована модель забезпечує значно кращі результати. Класи з низькоамплітудними компонентами показали найбільше покращення точності класифікації: ППШ – з 69 % до 97 %, ППП – з 73 % до 83 % у повнозв'язній моделі. Для класу ЗЛФБ, точність підвищилася з 78 % до 95 %, а в *EcgNet* для класу ЗЛІМ – з 58 % до 75 %. Водночас, у деяких випадках, як для класу ІНДМ в *EcgNet*, точність зменшилась із 77 % до 40 %, що вказує на залежність від особливостей архітектури. Оцінювання різних методів отримання скорочених векторів ознак показало, що порівняно з підходами до зменшення розмірності, такими як зниження частоти дискретизації, *PCA* або перехід до ортогональних відведень Франка, розроблений метод демонструє вищу стабільність, гнучкість і сумісність із різними архітектурами НМ.

У дослідженні окремо проаналізовано ефективність розпізнавання класів, пов'язаних із ППШ та ППП, які містять низькоамплітудні й високочастотні компоненти сигналу.

Результати показали, що сформований скорочений вектор ознак зберігає діагностичну інформацію, необхідну для виявлення цих типів сигналів, що підтверджується підвищенням точності класифікації ППП та ППШ порівняно з традиційними методами скорочення розмірності.

Запропонована модель автоенкодера, з використанням вбудованого класифікатора є придатною до адаптації під конкретні клінічні завдання, що робить його практично значущим інструментом для побудови як стаціонарних, так і мобільних систем діагностики.

Крім того, можливість реконструкції сигналу з отриманого латентного простору розширює потенціал застосування даної архітектури не лише як методу стиснення, а і як основи для побудови інтерпретованих і стандартизованих форматів зберігання медичних даних.

Література

- [1] Z. T. Kocsis, «Artificial Neural Networks in Medicine», *Acta Tech. Jaurinensis*, vol. 12, no. 2,

- pp. 117–129, квіт. 2019. DOI: 10.14513/actatechjaur.v12.n2.497
- [2] S. Nurmaini та ін., «An Automated ECG Beat Classification System Using Deep Neural Networks with an Unsupervised Feature Extraction Technique», *Appl. Sci.*, vol. 9, no. 14, 2921, лип. 2019. DOI: 10.3390/app9142921
 - [3] J. Terven, D. M. Cordova-Esparza, A. Ramirez-Pedraza, E. A. Chavez-Urbiola, and J. A. Romero-Gonzalez, "Loss Functions and Metrics in Deep Learning," *arXiv preprint arXiv:2307.02694*, Oct. 2024. [Online]. Available: <https://arxiv.org/abs/2307.02694>.
 - [4] S. Saadatnejad, M. Oveisi та M. Hashemi, «LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices», *IEEE J. Biomed. Health Inform.*, vol. 24, no. 2, pp. 515–523, лют. 2020. DOI: 10.1109/jbhi.2019.2911367
 - [5] R. Huang, X. Xue, R. Xiao та F. Bu, «A Novel Method for ECG Signal Compression and Reconstruction: Down-Sampling Operation and Signal-Referenced Network», *Electronics*, vol. 12, no. 8, 1760, квіт. 2023. DOI: 10.3390/electronics12081760
 - [6] E. Abdelhafid та ін., «ECG Arrhythmia Classification Using Convolutional Neural Network», *Int. J. Emerg. Technol. Adv. Eng.*, vol. 12, no. 7, pp. 186–195, лип. 2022. DOI: 10.46338/ijetae0722_19
 - [7] S. Mann та R. Orglmeister, «PCA-Based ECG Lead Reconstruction», *Biomed. Eng. / Biomedizinische Technik*, січ. 2013. [Online]. Available: <https://doi.org/10.1515/bmt-2013-4197>
 - [8] L. van der Maaten and G. Hinton, "Visualizing Data using t-SNE," *Journal of Machine Learning Research*, vol. 9, pp. 2579–2605, Nov. 2008. [Online]. Available: <https://www.jmlr.org/papers/v9/vandermaaten08a.html>
 - [9] K. Ranjeet, A. Kumar та R. K. Pandey, «ECG Signal Compression Using Different Techniques», in *Communications in Computer and Information Science*. Berlin, Heidelberg: Springer Berl. Heidelb., 2011, pp. 231–241. DOI: 10.1007/978-3-642-18440-6_29
 - [10] S. R. Ommen et al., "2020 AHA/ACC Guideline for the Diagnosis and Treatment of Patients With Hypertrophic Cardiomyopathy: A Report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines," *Circulation*, vol. 142, no. 25, pp. e558–e631, Dec. 2020. DOI: 10.1161/CIR.0000000000000937
 - [11] J. Vondrak та M. Penhaker, «Review of Processing Pathological Vectorcardiographic Records for the Detection of Heart Disease», *Frontiers Physiol.*, vol. 13, берез. 2022. DOI: 10.3389/fphys.2022.856590
 - [12] Z. I. Attia et al., «An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction», *Lancet*, vol. 394, no. 10201, pp. 861–867, верес. 2019. DOI: 10.1016/s0140-6736(19)31721-0
 - [13] Z. Xiong, M. P. Nash, E. Cheng, V. V. Fedorov, M. K. Stiles та J. Zhao, «ECG signal classification for the detection of cardiac arrhythmias using a convolutional recurrent neural network», *Physiol. Meas.*, vol. 39, no. 9, 094006, верес. 2018. DOI: 10.1088/1361-6579/aad9ed
 - [14] Y. Liu et al., «Contrastive predictive coding with transformer for video representation learning», *Neurocomputing*, vol. 482, pp. 154–162, квіт. 2022. DOI: 10.1016/j.neucom.2021.11.031
 - [15] Z. Zeng, J. Liu та Y. Yuan, «A Generalized Nyquist-Shannon Sampling Theorem Using the Koopman Operator», *IEEE Trans. Signal Process.*, pp. 1–17, 2024. DOI: 10.1109/tsp.2024.3436610
 - [16] D. Mochamad Reza, Satria Mandala, S. M. Zaki та E. S. L. Ming, «Deep Learning Autoencoder Study on ECG Signals», *J. Nas. Tek. Elektro*, pp. 82–88, груд. 2023. DOI: 10.25077/jnte.v12n3.1117.2023
 - [17] Sharanya S, Sridhar PA, Poornakala J, Muppala Vasishta та Tharani U, «Convolution Neural Network Based Ecg Classifier», *Int. J. Res. Pharmaceutical Sci.*, vol. 10, no. 3, pp. 1626–1630, лип. 2019. DOI: 10.26452/ijrps.v10i3.1327
 - [18] Y. Huang, W. Liu, Z. Yin, S. Hu, M. Wang та W. Cai, «ECG Classification Based on Guided Attention Mechanism», *Comput. Methods Programs Biomedicine*, 108454, жовт. 2024. DOI: 10.1016/j.cmpb.2024.108454
 - [19] C.-C. Lee, C.-C. Chuang, C.-H. Yeng, E.-C. So та Y.-J. Chen, «A Cross-Stage Partial Network and a Cross-Attention-Based Transformer for an Electrocardiogram-Based Cardiovascular Disease Decision System», *Bioengineering*, vol. 11, no. 6, 549, трав. 2024. DOI: 10.3390/bioengineering11060549
 - [20] P. Wagner та ін., «PTB-XL, a large publicly available electrocardiography dataset», *Sci. Data*, vol. 7, no.1, трав. 2020. DOI: 10.1038/s41597-020-0495-6
 - [21] X. Fagan, K. Ivanko, N. Ivanushkina, «Detection of ventricular late potentials in electrocardiograms using machine learning», *Advances in Computer Science for Engineering and Education III*. Cham: Springer, pp. 487–497, 2020. DOI: 10.1007/978-3-030-55506-1_44
 - [22] Y. Liu, Y. Wang, Y. Liu, X. Zhang, and Y. Zhang, «Variational autoencoder-based neural electrocardiogram synthesis from cardiac parameters», *Digital Health*, vol. 9, pp. 1–11, січ. 2023. DOI: 10.1016/j.cvdhj.2023.12.002
 - [23] J. Cai, Y. Zhang, J. Xie, Y. Gao, J. Wu, та Y. Chen, «Multi-ECGNet for ECG Arrhythmia Multi-Label Classification», *IEEE Access*, vol. 8, pp. 110848–110858, 2020.

UDC 616.12-073.7

Anton V. Mnevets, Nataliia G. Ivanushkina*National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute», Kyiv, Ukraine***NEURAL NETWORK AUTOENCODER MODEL FOR CONSTRUCTING REDUCED FEATURE VECTORS OF ECG SIGNALS**

The paper considers the actual problem of improving neural network models for the classification of cardiovascular pathologies by compressing the information contained in electrocardiographic (ECG) signals. Due to the active implementation of artificial intelligence in medical diagnostics, the study focuses on creating a reduced ECG feature vector that allows for a significant reduction in training data volume without losing important diagnostic information. The research is dedicated to the development of an autoencoder model with a specialized architecture that combines convolutional and fully connected layers, attention layers, residual connections, and a symmetric structure with shared weights. This approach enables not only to compress the input multichannel signal but also to form a latent space from which the signal can be restored or used as a feature vector for classification. In the proposed autoencoder architecture, the latent representation is combined with the layer weight vector into a single reduced vector that contains information about both the shape and the structural features of the ECG signal. The model was trained using a composite loss function, which allows for balancing between signal reconstruction quality and classification accuracy. To evaluate the model, several alternative dimensionality reduction methods were used, including downsampling, transformation to Frank's orthogonal leads, calculation of a resultant vector, and principal component analysis (PCA). A number of alternative dimensionality reduction methods were used to test the model: reduction of the sampling frequency; transformation to Frank orthogonal derivations; calculation of the resulting vector; principal component analysis (PCA). All methods were tested on the PTB-XL dataset, which contains 12-lead ECG recordings with a wide range of cardiovascular pathologies. The effectiveness of the reduced feature vector was assessed using two models—a convolutional neural network (EcgNet) and a fully connected network with two hidden layers. The analysis of the results showed that, on average, classification accuracy using the reduced vector decreased by only 2 % for EcgNet and increased by 3–6 % for the fully connected network, indicating preservation of diagnostic information even with a high compression ratio of 25. In contrast, traditional dimensionality reduction methods such as PCA and orthogonal transformation showed a significant deterioration in classification quality (up to –16 %). While downsampling to 75 Hz significantly reduces data volume, it also leads to the loss of high-frequency information critical for detecting ischemia and arrhythmias. Particular attention is given to ventricular and atrial late potentials, which are low-amplitude and high-frequency in nature. The constructed reduced feature vector preserved the informative characteristics of these classes, resulting in improved classification accuracy compared to traditional dimensionality reduction methods. Thus, the developed reduced feature vector demonstrates the ability to retain diagnostic information under significant ECG data compression, achieving a balance between computational efficiency, classification accuracy, and application versatility. The obtained results suggest that the use of the proposed reduced feature vector may serve as a promising solution for compact and efficient systems for automated ECG analysis, particularly in mobile or computing-limited systems, while also enabling faster development and testing of new neural network models for diagnostics.

Keywords: electrocardiography; autoencoder; ventricular late potentials; atrial late potentials; data compression.*Надійшла до редакції
14 квітня 2025 року**Рецензовано
16 травня 2025 року*

© 2025 Copyright for this paper by its authors.
Use permitted under Creative Commons License Attribution 4.0 International (CC BY 4.0).