

КОВАЛЬЧУК ОЛЕКСІЙ

Хмельницький національний університет

<https://orcid.org/0000-0001-9828-0941>e-mail: iosha.kovalchuk1998@gmail.com

БАРМАК ОЛЕКСАНДР

Хмельницький національний університет

<https://orcid.org/0000-0003-0739-9678>e-mail: barmako@khmnu.edu.ua

МЕТОД ІДЕНТИФІКАЦІЇ R-ПІКІВ У СИГНАЛАХ ЕЛЕКТРОКАРДІОГРАМИ

В роботі запропоновано метод ідентифікації R-піків в сигналах електрокардіограми, який включає інтеграцію знань в ЕКГ-сигнал, обробку за допомогою згорткової нейронної мережі та постобробку результатів моделі CNN для виявлення R-піків. Особливістю запропонованого методу є інтеграція знань про еталонний серцевий цикл у вхідний сигнал ЕКГ. Ідеєю використання такої інтеграції знань в ЕКГ сигнал є те, що нейромережа буде краще виявляти R-піки у ЕКГ сигналі та буде більш стійкою до артефактів сигналу.

Перевірка точності запропонованого методу відбувалася і з використанням ЕКГ сигналів із 4 баз даних та з використанням допустимої похибки в ± 25 мс. Запропонований метод показав найкращий результат на 3 із 4 наборах тестових даних, в порівнянні із його аналогами. Отримані результати підтверджують надійність та точність запропонованого методу для виявлення R-піків у ЕКГ-сигналах.

Ключові слова: медична діагностика, електрокардіограма, моніторинг ЕКГ, виявлення R-піка, інтеграція знань, глибоке навчання.

KOVALCHUK OLEKSII, BARMAK OLEKSANDER

Khmelnitskyi National University

R-PEAKS IDENTIFICATION METHOD IN ELECTROCARDIOGRAM SIGNALS

The rapid development of artificial intelligence, particularly deep learning models, has significantly expanded the spheres of its usage. One of these areas is medicine. One of the important areas of using artificial intelligence in the medical field is the processing of electrocardiograms (ECG). The ECG remains an important tool for the accurate diagnosis of cardiac pathologies in clinical practice. However, accurate processing and analysis of ECG signals, especially the identification of R-waves, remains a challenge. Inaccurate detection of R-peaks can significantly affect further analysis and diagnosis of the disease. Therefore, this study presents an improved method for detecting R-peaks in ECG signals.

The authors propose a method that includes the integration of knowledge into the ECG signal, processing of this information using a convolutional neural network, and post-processing of the CNN model results to detect R-waves. A feature of the proposed method is the integration of knowledge about the reference cardiac cycle into the input ECG signal. The idea of using such integration of knowledge in the ECG signal is that the neural network will better detect R peaks in the ECG signal with integrated knowledge and will be more resistant to changes in signal artifacts.

The accuracy of the proposed method was verified by using ECG signals from 4 databases, namely: MIT-BIH, QT, CPSC-2020, and UoG. The method was evaluated using an error of ± 25 ms using statistical metrics accuracy, precision, recall, and F1-score. The obtained statistical indicators are compared with those of existing methods. The proposed method showed the best result on 3 out of 4 test data sets compared to its analogues. Thus, the proposed method is a reliable and efficient solution for detecting R-peaks in ECG signals.

Keywords: medical diagnosis, electrocardiogram, ECG monitoring, R-peak detection, domain knowledge integration, deep learning.

Постановка проблеми у загальному вигляді

та її зв'язок із важливими науковими чи практичними завданнями

У сучасному світі стрімкий розвиток штучного інтелекту (ШІ), зокрема моделей глибокого навчання, став потужним інструментом, що змінює підходи до вирішення складних задач в різних сферах діяльності людини. Завдяки здатності обробляти великі обсяги даних та виявляти приховані закономірності, ШІ поступово стає невід'ємною частиною у багатьох галузях, включаючи медицину. В практиці лікарів для діагностування серцево-судинних захворювань використовується комплекс методів, таких як аналізи крові, стрес-тести, ехокардіограми та рентген грудної клітки, проте електрокардіографія залишається одним із ключових методів неінвазивного моніторингу та клінічної діагностики роботи серця.

Електрокардіографія, або ЕКГ, це метод вивчення роботи серця шляхом запису його електричної активності. Цей процес використовує електроди, які розміщуються на шкірі і виявляють маленькі електричні зміни, що виникають внаслідок деполяризації та реполяризації серцевих м'язів під час кожного серцевого циклу.

Стандартна ЕКГ включає 12 відведень, які отримуються за допомогою 10 електродів [1]. Це дає змогу вимірювати загальний електричний потенціал серця з 12 різних кутів. Схема типового ЕКГ-сигналу подано на рис. 1.

Виявлення R-піку в ЕКГ-сигналі є основою для подальшого аналізу цього сигналу та діагностування за ним кількох серцевих патологій, включно з аритмією. Виникнення помилки під час виявлення R-піку негативно впливатиме на всі наступні етапи обробки, аналізу, класифікації такого сигналу. Тому точне виявлення R-піку є вкрай важливим для грамотного аналізу ЕКГ-сигналу та подальшої постановки правильного діагнозу на його основі.




Рис. 1. а) Ілюстрація 12 відведень ЕКГ сигналу [2]; б) ідеальний кардіоцикл ECG-сигналу (QRS-комплекс)

Аналіз досліджень та публікацій

Основний підхід до підготовки ЕКГ-сигналу для застосування в моделях глибокого навчання включає обов’язкове виділення кардіоциклів базуючись на R-піках у сигналі. Це впливає із природи ЕКГ-сигналу, а саме із його псевдоперіодичності. Тобто одиницею аналізу роботи серця за ЕКГ-сигналом є кардіоцикл (QRS-комплекс), виявлення якого полягає у знаходженні R-піка. Таким чином, точність визначення R-піків є критичною, оскільки вона впливає на якість застосування методів глибокого навчання для розв’язання задач класифікації. Існує багато методів і підходів для виявлення R-піків в ЕКГ-сигналі, ефективність яких зазвичай перевищує 99%. Проте в багатьох роботах вказується велика похибка або вона взагалі не зазначається при розрахунку статистичних показників. Наприклад, у дослідженні [3] та [4] досягнуто високої точності виявлення піків в ЕКГ-сигналі, проте допустима похибка становить ± 75 мсек. Це створює загальне вікно похибки у 150 мсек, що перевищує нормальну тривалість QRS-комплексу.

Оскільки, медична сфера вимагає максимально високої точності, то такі похибки в дослідженнях можуть бути доволі критичними. Саме тому такі науковці як B. Pott та P. W. Macfarlane [5] у своїй статті провели аналіз різних методів пошуку R-піків серед, яких згадуються такі методи як: Pan and Tompkins by Fariha et al. [6], Hamilton and Tompkins by Ahmad et al. [7], Christov by Xiong et al [8] тощо. В результаті даного дослідження автори встановили, що фактично в кожній статті повідомляється про дуже високу точність у 98% і більше, що втім може бути пояснено використанням великої допустимої похибки при розрахунку точності запропонованих методів. Автори допускають використання похибки, яка складає 100 мс або навіть більше. Тому, задача визначення R-піків із використанням якомога менших похибок залишається актуальною і потребує подальших досліджень.

Метою роботи є: Підвищення точності виявлення R-піків в ЕКГ сигналі шляхом інтеграції знань про еталонний кардіоцикл в ЕКГ сигнал.

Виклад основного матеріалу

Попри вражаючі результати існуючих методів виявлення R-піків, існують недоліки, які потрібно врахувати. Для вдосконалення існуючих підходів до виявлення R-піків у сигналах ЕКГ був запропонований метод, схема якого зображена на рис. 2.



Рис. 2. Загальна схема методу для виявлення R-піків

Особливістю запропонованого методу є інтеграція знань про еталонний серцевий цикл у вхідний сигнал ЕКГ. Гіпотеза дослідження полягає у тому, що такий інтегрований сигнал буде краще виявляти потрібну нам інформацію (R-піки), та буде більш завадостійким до артефактів сигналу.

Варто зазначити, що інтеграція знань про еталонний серцевий цикл у вхідний ЕКГ-сигнал не є новим підходом. Подібне пропонувалось у [9]. У даному дослідженні запропоновано своя варіація інтеграції знань в ЕКГ сигналі.

Для реалізації інтеграції знань використовується характерна ознака R-піка, а саме те, що R-пік має максимальне позитивне відхилення в межах кардіоциклу.

Отже, у методі, запропоновані наступні кроки перетворення інформації:

Вхідною інформацією є: 1) сигнал ЕКГ S у вигляді одномірного масиву даних та 2) та, співрозмірний з ним, масив K , який на всій довжині сигналу ініціалізується нульовими значеннями, в які, на наступних кроках, на визначених місцях, записуються знання про ідеальні піки еталонного серцевого ритму.

Крок 1. Інтеграція знань про еталонний кардіоцикл у ЕКГ-сигнал;

Крок 2. Обробка інтегрованого сигналу за моделлю глибокого навчання (CNN);

Крок 3. Постобробка результатів моделі глибокого навчання для ідентифікації R-піків.

Вихідна інформація. Заповнений масив K .

Далі детально зупинимось на особливостях кожного з наведених кроків. Для інтеграції знань в ЕКГ сигнал на *кроці 1* береться до уваги те, що в I-II і V1-V6 відведеннях ЕКГ-сигналу характерною рисою R-піка є найбільше позитивне відхилення сигналу на певній ділянці. Щоб інтегрувати знання про це в кожен сегмент сигналу ЕКГ, застосовуються кроки, зображені на рис. 3.

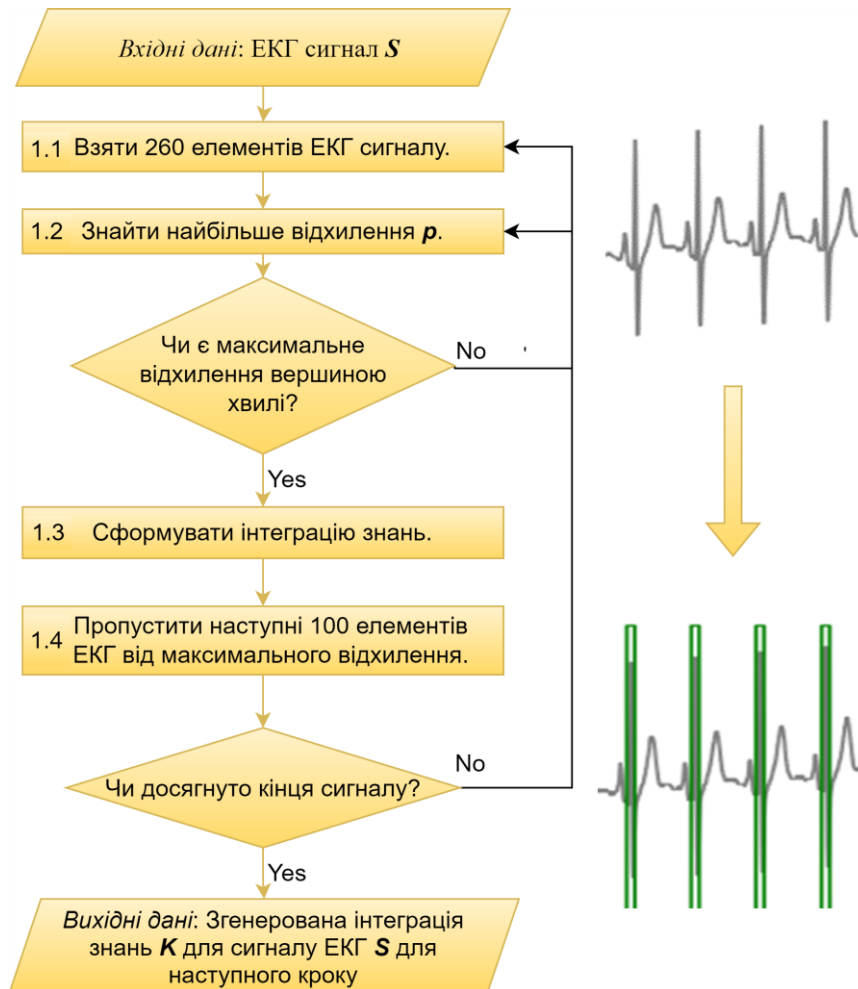


Рис. 3. Схема кроку 1 інтеграції знань про еталонний сигнал ЕКГ

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

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

Крок 1.3 передбачає заповнення масиву K знаннями. На основі ідентифікованого піку визначається його глобальний індекс i в ЕКГ-сигналі S . Далі, масив K заповнюється значенням 1 у діапазоні $[i-20, i+20]$. Цей діапазон зазвичай охоплює комплекс QRS, який включає R-пік.

Крок 1.4 має на меті уникнути пошуку нового максимального відхилення відразу після знайденого на *кроці 2* відхилення p , оскільки R-піки з'являються через певні інтервали.

Візуалізація інтеграції знань та ЕКГ-сигналу зображена на рис. 4




Рис. 4. Інтеграція знань про еталонний ЕКГ-сигнал у поточний ЕКГ-сигнал

Далі, сигнали S та K будуть разом подаватися на вхід моделі глибокого навчання, для виявлення на цих сигналах R-піку (крок 2).

За результатами аналізу існуючих робіт пошуку R-піків пропонується використання нейромережі архітектуру якої наведено в таблиці 1.

Таблиця 1

Використана архітектура Encoder-decoder моделі

Layer name	Input	Output	kernel_size	stride	padding	Scale factor
<i>Encoder</i>						
Conv1d	2	32	3	1	1	
ReLU						
MaxPool1d			2	2		
Conv1d	32	64	3	1	1	
ReLU						
MaxPool1d			2	2		
Conv1d	64	128	3	1	1	
ReLU						
MaxPool1d			2	2		
Conv1d	128	256	3	1	1	
ReLU						
MaxPool1d			2	2		
<i>Decoder</i>						
Upsample						2
Conv1d	256	128	3	1	1	
ReLU						
Upsample						2
Conv1d	128	64	3	1	1	
ReLU						
Upsample						2
Conv1d	64	32	3	1	1	
ReLU						
Upsample						2
Conv1d	32	1	3	1	1	
ReLU						
Sigmoid						

Для вимірювання значень втрат під час навчання мережі пропонується використання функції Binary Cross Entropy Loss (BCELoss). Варто зазначити, що дана функція була обрана оскільки вона є стійкою до дисбалансу класів у навчальній вибірці, що актуально для нашої задачі. У випадках, коли класи даних незбалансовані, BCELoss втрати можуть бути більш стійкими, ніж альтернативи, такі як Mean Squared Error (MSE). Це пояснюється тим, що BCELoss зосереджується на мінімізації помилки для кожної окремої вибірки, незалежно від її класу [10].

Для оптимізації навчання нейронних мереж пропонується алгоритм Adaptive Moment Estimation (Adam), який поєднує в собі переваги методів Momentum та RMSprop. Adam динамічно адаптує швидкість навчання для кожного параметра, що дозволяє прискорити збіжність моделі та ефективно керувати простором параметрів. Також цей алгоритм знижує потребу в пам'яті, зберігаючи лише середні значення градієнтів і їх квадратів для оновлення параметрів [11, 12].

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

Крок 3 методу призначений для обробки виходу моделі CNN, P, для перетворення його в індекси, які відповідають R-пікам вхідного сигналу. Загальну схему кроку 3 зображено на рисунку 5.

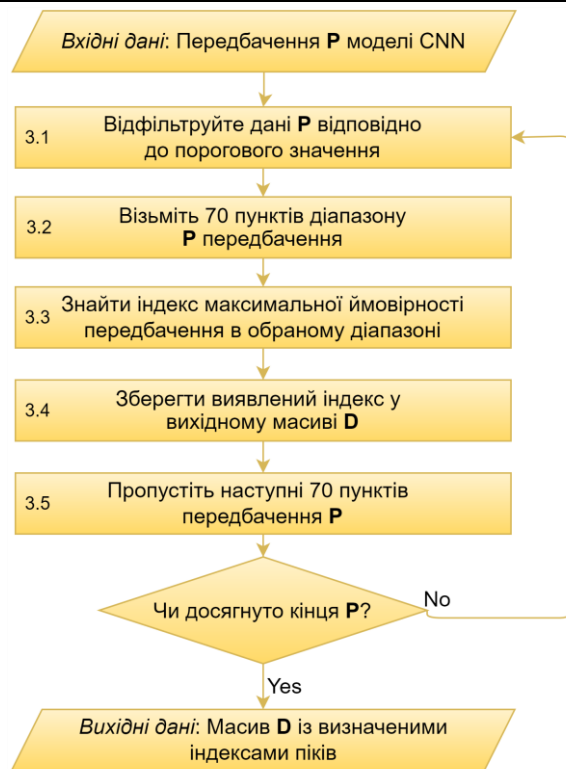


Рис. 5. Схема кроку 3 постобробки результатів нейромережі для визначення R піків

З кроку 2 нам приходить вихід нейромережі encoder-decoder CNN, який є масивом того ж розміру, що і вхідний масив із сигналом ЕКГ. Приклад вихідних даних мережі CNN показано червоною лінією на рис. 6.




Рис. 6. Вихід CNN: (а) початковий вихід CNN, (б) початковий вихід CNN, накладений на вхідний сигнал ЕКГ

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

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

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

Після завершення алгоритму вихідний масив D містить повний список індексів, які відповідають R-пікам ЕКГ сигналу, визначені моделлю CNN.

Результати та обговорення

Для нейронної мережі та перевірки точності запропонованого методу в даній роботі використовуються наступні 4 набори даних із ЕКГ сигналами:

1. MIT-BIH Arrhythmia Database (MIT-BIH) [13].
2. QT Database (QT) [14].
3. China Physiological Signal Challenge-2020 Database (CPSC-2020) [15].
4. University of Glasgow Database (UoG) [16].

Над наведеними вище наборами даних було проведено певну передобробку, пов'язану зі специфікою задачі, яка розглядається, а саме прибрані зразки у яких не чітко розмічені R-піки. Наявність у наборах даних таких зразків перешкоджатиме точному навчанню та тестуванню нейронної мережі.

З набору MIT-BIH [13] виключені сигнали (наприклад, Id=108 та 207), анотації яких не відповідають вершині піку. Приклад такого сигналу зображено на рис. 7 (а). Ймовірно це результат механічної помилки під

час створення анотації, оскільки головною метою анотації в даній базі є позначити тип патології в кардіоциклі, а не точну позицію R-піку.




Рис. 7. Приклади сумнівних зразків ЕКГ-сигналу. а) не правильно розмічений сигнал, б) не стандартний сигнал/відведення

Сигнали, що належать набору даних QT [14], також були відфільтровані. З набору було видалено сигнали, що містять неповний (нестандартний) сигнал ЕКГ. Приклад такого сигналу наведено на рис. 7 б). Враховуючи те, що сигнали у розглянутих вище базах даних мають різну частоту, були проведені додаткові перетворення, щоб усі сигнали мали частоту 400 Гц. Сигнали з цих наборів даних були сегментовані на фрагменти довжиною 8000 для їх подальшого використання як вхідних сигналів для нейронної мережі. Фрагменти, отримані з наборів даних 1-3, були розділені на набори для навчання та тестування у співвідношенні 80/20 відповідно.

З набору даних UoG [16] створено окремий незалежний тестовий набір сигналів. Тестовий набір включав фрагменти сигналу, записані з відведення II під час такою діяльності пацієнтів: сидіння, математика та ходьба.

Таблиця 2

Розподіл сигналів у використаному наборі даних.

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

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

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

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

В результаті навчання мережі було побудовано графік кривих функцій втрат розраховані на навчальній та валідаційній вибірці. Побудований графік зображено на рис. 8 де вісь абсцис відповідає за номер епохи навчання, а вісь ординат – величину втрат. В свою чергу синя крива показує на точність класифікації для навчального набору даних, тоді як сіра пунктирна крива зображує результати отримані на основі валідаційного набору. В даному випадку обидві криві втрат досягають низьких показників втрат і практично співпадають, що вказує на те, що розроблена модель нейромережі була ефективно навчена і вдалось уникнути перенавчання (overfitting).

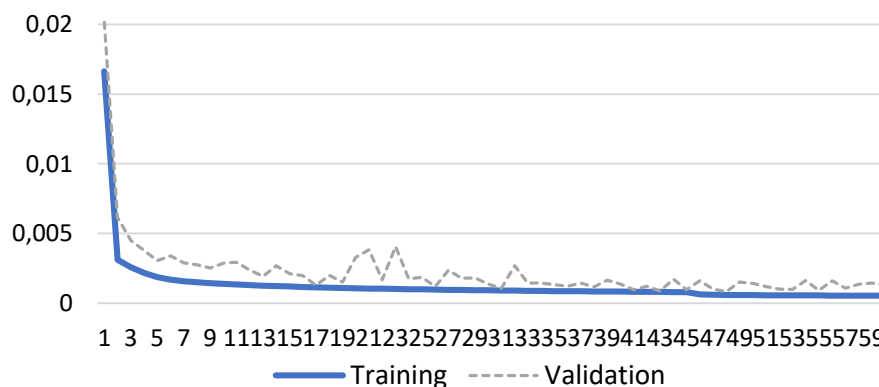


Рис. 8. Криві втрат навчальних та тестових наборів даних

Для отримання статистичних показників якості класифікації, використовувались 7 варіантів випадкового розбиття наборів даних на навчальний і тренувальний набори. Як згадувалось раніше ці набори даних сформовані з баз даних MIT-BIH Arrhythmia, QT і CPSC-2020. Таблиці 3-5 демонструють отримані показники для навчального і тестового набору з кожної бази. Для розрахунку статистичних метрик використовується допустима похибка в ± 25 мс.

Таблиця 3

Статистичні показники MIT

Показники		Випадкові розбиття							Avg	Std
		1	2	3	4	5	6	7		
Accuracy	Навч.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
	Тест.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
Precision	Навч.	0.994	0.994	0.994	0.995	0.994	0.992	0.994	0.994	0.001
	Тест.	0.993	0.992	0.991	0.992	0.993	0.992	0.992	0.992	0.001
Recall	Навч.	0.991	0.991	0.991	0.992	0.991	0.987	0.991	0.991	0.002
	Тест.	0.987	0.986	0.985	0.988	0.987	0.986	0.987	0.987	0.001
F1	Навч.	0.992	0.992	0.993	0.994	0.992	0.989	0.992	0.992	0.002
	Тест.	0.989	0.989	0.988	0.990	0.990	0.989	0.989	0.989	0.001

Таблиця 4

Статистичні показники QT

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

Таблиця 5

Статистичні показники CPSC-2020

Показники		Випадкові розбиття							Avg	Std
		1	2	3	4	5	6	7		
Accuracy	Навч.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
	Тест.	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.000
Precision	Навч.	0.987	0.988	0.988	0.990	0.987	0.986	0.987	0.988	0.001
	Тест.	0.986	0.986	0.986	0.988	0.985	0.985	0.985	0.986	0.001
Recall	Навч.	0.996	0.996	0.996	0.996	0.996	0.995	0.996	0.996	0.000
	Тест.	0.994	0.994	0.994	0.994	0.994	0.995	0.994	0.994	0.000
F1	Навч.	0.991	0.992	0.992	0.993	0.991	0.990	0.991	0.991	0.001
	Тест.	0.990	0.989	0.990	0.990	0.989	0.989	0.989	0.989	0.001

Значення Accuracy як для навчальних, так і для тестових наборів даних для всіх випадкових розбивок є високими, із середнім значенням близько 99,9% для кожного набору даних. Стандартні відхилення мінімальні, що свідчить про стабільну продуктивність незалежно від розбиття набору даних. Це дає можливість зробити висновок, що модель добре узагальнює і правильно класифікує більшість випадків. Враховуючи, що точність близька до 100%, цю модель можна вважати високоефективною для поставленої задачі.

Precision на навчальних і тестових наборах даних також залишається високою, з середніми значеннями близькими до 99,8-99,9% для всіх наборів даних. Невелике стандартне відхилення додатково підтверджує надійність моделі в правильному визначенні позитивних випадків без значної кількості хибних спрацьовувань. Це дуже важливо для задач, де ціна помилкових спрацьовувань є високою, що свідчить про те, що модель є не тільки точною, але й вибірковою у своїх позитивних класифікаціях.

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

Показник F1, який балансує між Precision та Recall, залишається високим для всіх наборів даних і становить у середньому 98,8-98,9% на тестових наборах даних. Низьке стандартне відхилення вказує на те, що баланс між Precision та Recall є стабільним для різних випадкових розбивок. Така узгодженість свідчить

про те, що модель зберігає свою продуктивність навіть при роботі з різноманітними даними, що робить її надійним інструментом для виконання завдань.

Підсумовуючи статистичні показники для всіх наборів даних показують, що запропонована CNN модель забезпечує надійну та достовірну класифікацію. Мінімальна відхилення результатів на різних розбиттях вказує на те, що продуктивність моделі не залежить від конкретних даних, які використовуються, що підкреслює її стабільність та можливість узагальнювати.

Додатково проведено тестування на незалежній тестовій вибірці сформованої на основі бази даних ECG Database – UoG. Отримані статистичні результати наведені в таблиці 6.

Таблиця 6

Статистичні показники ECG Database – UoG

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

Аналізуючи наведені дані та порівнюючи їх із попередньо наведеними результатами можна зробити наступні висновки:

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

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

- Показник Recall знизився, що свідчить про те, що модель є менш чутливою до істинно-позитивних результатів для даного набору даних. З чого можна зробити висновок те що цей набір даних містить сигнали ЕКГ з характеристиками, які або відсутні, або мінімально присутні в наборі для навчання;

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

У таблиці 7 наведено отримані статистичні показники у порівнянні з відомими підходами із використанням однакових тестових наборів даних.

Таблиця 7

Порівняння з відомими підходами

База даних	Підхід	Accuracy	Precision	Recall	F1 Score
MIT	NeuroKit2 [17]	0,9997	0,9644	0,9340	0,9490
MIT	Rodrigues et al. [18]	0,9992	0,8322	0,9491	0,8868
MIT	Koka et al. [19]	0,9992	0,8938	0,8699	0,8817
MIT	Zahid et al. [3]	0,9999	0,9905	0,9858	0,9893
MIT	Our	0,9999	0,9921	0,9872	0,9890
QT	NeuroKit2 [17]	0,9997	0,9655	0,9410	0,9531
QT	Rodrigues et al. [18]	0,9991	0,7824	0,9427	0,8551
QT	Koka et al. [19]	0,9993	0,8866	0,8767	0,8816
QT	Zahid et al. [3]	0,9999	0,9789	0,9778	0,9783
QT	Our	0,9999	0,9803	0,9818	0,9819
CPSC-2020	NeuroKit2 [17]	0,9997	0,9514	0,9514	0,9514
CPSC-2020	Rodrigues et al. [18]	0,9989	0,7763	0,9212	0,8426
CPSC-2020	Koka et al. [19]	0,9995	0,9232	0,8972	0,9100
CPSC-2020	Zahid et al. [3]	0,9999	0,9855	0,9927	0,9891
CPSC-2020	Our	0,9999	0,9862	0,9943	0,9897
UoG	NeuroKit2 [17]	0,9998	0,9932	0,9596	0,9761
UoG	Rodrigues et al. [18]	0,9996	0,9083	0,9990	0,9515
UoG	Koka et al. [19]	0,9994	0,9194	0,8968	0,9080
UoG	Zahid et al. [3]	0,9995	0,9838	0,8666	0,9215
UoG	Our	0,9996	0,9831	0,9010	0,9239

Висновки з даного дослідження і перспективи подальших розвідок у даному напрямі

Дане дослідження було зосереджене на вдосконаленні підходу до ідентифікації R-піків в ЕКГ-сигналі шляхом інтеграції знань про еталонний ЕКГ-сигнал у вхідний сигнал. Підкреслено важливість точного

виявлення R-піка, оскільки він є основою для подальшого аналізу ЕКГ-сигналу та діагностики різних серцевих патологій.

Для вдосконалення існуючих методів виявлення R-піків було запропоновано новий підхід, який інтегрує знання про референтний серцевий цикл у вхідний ЕКГ-сигнал. Процес включає три основні етапи: (i) інтеграція знань про ЕКГ-сигнал, (ii) обробка цієї інформації за допомогою CNN-моделі, (iii) постобробка результатів CNN-моделі для виявлення R-піків.

Оцінка запропонованого методу була комплексною з використанням тестових зразків МІН-ВІН, QT, CPSC-2020 та UoG. Для розрахунку метрик використовували похибку ± 25 мс. Результати порівнювали з іншими підходами, які представляють сучасний стан обробки ЕКГ. Запропонований метод продемонстрував високу продуктивність у різних метриках і базах даних. Зокрема, в базах даних МІН-ВІН, QT та CPSC-2020 запропонований підхід перевершив свої аналоги.

Майбутні дослідження можуть бути спрямовані на вдосконалення застосування ширшого набору клінічних знань для подальшої їхньої інтеграції в ЕКГ сигнал для пошуку R-піків. Також потенціал для подальшого зменшення похибки і досягнення ще більш точних результатів залишається перспективною.

Література

1. The ECG leads: Electrodes, limb leads, chest (precordial) leads and the 12-Lead ECG [Електронний ресурс]. – Режим доступу: <https://ecgwaves.com/topic/ekg-ecg-leads-electrodes-systems-limb-chest-precordial>.
2. Perez Alday EA. Classification of 12-lead ECGs: The PhysioNet/Computing in Cardiology Challenge 2020 / A. Perez, A. Gu, A.J. Shah, C. Robichaux, A.I. Wong, C. Liu, F. Liu, A.B. Rad, A. Elol, S. Seyedi, Q. Li, A. Sharma, G.D. Clifford, M.A. Reyna // PhysioNet – 2022 – DOI: <https://doi.org/10.13026/dvyd-kd57>.
3. Zahid M. U. Robust R-Peak Detection in Low-Quality Holter ECGs Using 1D Convolutional Neural Network / M. U. Zahid, S. Kiranyaz, T. Ince, O. C. Devecioglu, M. E. H. Chowdhury, A. Khandakar, A. Tahir та M. Gabbouj // IEEE Trans. Biomed. Eng. – 2022 – Volume 69, January – P. 119–128 – DOI: 10.1109/TBME.2021.3088218.
4. Yun D. Robust R-peak detection in an electrocardiogram with stationary wavelet transformation and separable convolution / D. Yun, H.-C. Lee, C.-W. Jung, S. Kwon, S.-R. Lee, K. Kim, Y. S. Kim та S. S. Han // Sci Rep 12 – 2022 – DOI: <https://doi.org/10.1038/s41598-022-19495-9>.
5. Porr B. A new QRS detector stress test combining temporal jitter and accuracy (JA) reveals significant performance differences amongst popular detectors / B. Porr, P. W. Macfarlane // bioRxiv – 2024 - DOI: <https://doi.org/10.1101/722397>.
6. Pan J. A real-time QRS detection algorithm / J. Pan, W. J. Tompkins // IEEE Transactions on biomedical engineering – 1985 – Volume 32, March, – P. 230-236.
7. Ahmad I. QRS detection for heart rate monitoring / I. Ahmad // International Journal of Electrical Engineering and Technology – 2020 – Volume 11, June – P. 360–367, 2020.
8. Xiong M. L. H. A real-time QRS detection algorithm based on energy segmentation for exercise electrocardiogram / M. L. H. Xiong, J. Liu // Circuits Syst Signal Process – 2021 – Volume 40 – P. 4969–4985 – DOI: <https://doi.org/10.1007/s00034-021-01702-z>.
9. Wang J. A knowledge-based deep learning method for ECG signal delineation / J. Wang, R. Li, R. Li, B. Fu // Future Generation Computer Systems – 2020 – Volume 109, August – P. 56–66 – DOI: <https://doi.org/10.1016/j.future.2020.02.068>.
10. Binary Cross Entropy Loss [Електронний ресурс]. – Режим доступу: <https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>.
11. Adaptive Moment Estimation [Електронний ресурс]. – Режим доступу: <https://medium.com/@nerdjock/deep-learning-course-lesson-7-4-adam-adaptive-moment-estimation-e23434850bfc>
12. Adaptive Moment Estimation. Difference between Adam and SGD [Електронний ресурс]. – Режим доступу: <https://codeahoy.com/questions/ds-interview/33>.
13. Moody G. The impact of the MIT-BIH Arrhythmia Database / G. Moody, R. Mark // IEEE Eng in Med and Biol – 2001 – May-June – P. 45-50.
14. Laguna P. A Database for Evaluation of Algorithms for Measurement of QT and Other Waveform Intervals in the ECG / P. Laguna, R. Mark, A. Goldberger, G. Moody // Computers in Cardiology – 1997 – Volume 24 – P. 673-676 (1997).
15. The 3rd China Physiological Signal Challenge 2020 [Електронний ресурс]. – Режим доступу: <https://paperswithcode.com/dataset/cpsc2020>.
16. Howell L. High precision ECG Database with annotated R peaks, recorded and filmed under realistic conditions / L. Howell, B. Porr // University of Glasgow – 2018 – DOI: <https://doi.org/10.5525/gla.researchdata.716>.
17. Makowski D. NeuroKit2: A Python Toolbox for Neurophysiological Signal Processing / D. Makowski, T. Pham, Z. J. Lau, J. C. Brammer, F. Lespinasse, H. Pham, C. Schölzel, S. H. Annabel Chen // Behav Res – 2021 – P. 1689-1696 – DOI: <https://doi.org/10.3758/s13428-020-01516-y>.
18. Rodrigues R. Semi-supervised learning for ECG classification / R. Rodrigues, P. Couto // Computing in Cardiology (CinC) – 2021 – P. 1-4. DOI: <https://doi.org/10.23919/CinC53138.2021.9662693>.
19. Koka T. Fast and sample accurate R-peak detection for noisy ECG using visibility graphs / T. Koka, M.

References

1. The ECG leads: Electrodes, limb leads, chest (precordial) leads and the 12-Lead ECG [Elektronnij resurs]. – Rezhim dostupu: <https://ecgwaves.com/topic/ekg-ecg-leads-electrodes-systems-limb-chest-precordial>.
2. Perez Alday EA. Classification of 12-lead ECGs: The PhysioNet/Computing in Cardiology Challenge 2020 / A. Perez, A. Gu, A.J. Shah, C. Robichaux, A.I. Wong, C. Liu, F. Liu, A.B. Rad, A. Elol, S. Seyedi, Q. Li, A. Sharma, G.D. Clifford, M.A. Reyna // PhysioNet – 2022 – DOI: <https://doi.org/10.13026/dvyd-kd57>.
3. Zahid M. U. Robust R-Peak Detection in Low-Quality Holter ECGs Using 1D Convolutional Neural Network / M. U. Zahid, S. Kiranyaz, T. Ince, O. C. Devecioglu, M. E. H. Chowdhury, A. Khandakar, A. Tahir ra M. Gabbouj // IEEE Trans. Biomed. Eng. – 2022 – Volume 69, January – P. 119–128 – DOI: 10.1109/TBME.2021.3088218.
4. Yun D. Robust R-peak detection in an electrocardiogram with stationary wavelet transformation and separable convolution / D. Yun, H.-C. Lee, C.-W. Jung, S. Kwon, S.-R. Lee, K. Kim, Y. S. Kim ra S. S. Han // Sci Rep 12 – 2022 – DOI: <https://doi.org/10.1038/s41598-022-19495-9>.
5. Porr B. A new QRS detector stress test combining temporal jitter and accuracy (JA) reveals significant performance differences amongst popular detectors / B. Porr, P. W. Macfarlane // bioRxiv – 2024 - DOI: <https://doi.org/10.1101/722397>.
6. Pan J.A real-time QRS detection algorithm / J. Pan, W. J. Tompkins // IEEE Transactions on biomedical engineering – 1985 – Volume 32, March, – P. 230-236.
7. Ahmad I. QRS detection for heart rate monitoring / I. Ahmad // International Journal of Electrical Engineering and Technology – 2020 – Volume 11, June – P. 360–367, 2020.
8. Xiong M. L. H. A real-time QRS detection algorithm based on energy segmentation for exercise electrocardiogram / M. L. H. Xiong, J. Liu // Circuits Syst Signal Process – 2021 – Volume 40 – P. 4969–4985 – DOI: <https://doi.org/10.1007/s00034-021-01702-z>.
9. Wang J. A knowledge-based deep learning method for ECG signal delineation / J. Wang, R. Li, R. Li, B. Fu // Future Generation Computer Systems – 2020 – Volume 109, August – P. 56–66 – DOI: <https://doi.org/10.1016/j.future.2020.02.068>.
10. Binary Cross Entropy Loss [Elektronnij resurs]. – Rezhim dostupu: <https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>.
11. Adaptive Moment Estimation [Elektronnij resurs]. – Rezhim dostupu: <https://medium.com/@nerdjock/deep-learning-course-lesson-7-4-adam-adaptive-moment-estimation-e23434850bfc>
12. Adaptive Moment Estimation. Difference between Adam and SGD [Elektronnij resurs]. – Rezhim dostupu: <https://codeahoy.com/questions/ds-interview/33>.
13. Moody G. The impact of the MIT-BIH Arrhythmia Database / G. Moody, R. Mark // IEEE Eng in Med and Biol – 2001 – May-June – P. 45-50.
14. Laguna P. A Database for Evaluation of Algorithms for Measurement of QT and Other Waveform Intervals in the ECG / P. Laguna, R. Mark, A. Goldberger, G. Moody // Computers in Cardiology – 1997 – Volume 24 – P. 673-676 (1997).
15. The 3rd China Physiological Signal Challenge 2020 [Elektronnij resurs]. – Rezhim dostupu: <https://paperswithcode.com/dataset/cpsc2020>.
16. Howell L. High precision ECG Database with annotated R peaks, recorded and filmed under realistic conditions / L. Howell, B. Porr // University of Glasgow – 2018 – DOI: <https://doi.org/10.5525/gla.researchdata.716>.
17. Makowski D. NeuroKit2: A Python Toolbox for Neurophysiological Signal Processing / D. Makowski, T. Pham, Z. J. Lau, J. C. Brammer, F. Lespinasse, H. Pham, C. Schölzel, S. H. Annabel Chen // Behav Res – 2021 – P. 1689-1696 – DOI: <https://doi.org/10.3758/s13428-020-01516-y>.
18. Rodrigues R. Semi-supervised learning for ECG classification / R. Rodrigues, P. Couto // Computing in Cardiology (CinC) – 2021 – P. 1-4. DOI: <https://doi.org/10.23919/CinC53138.2021.9662693>.
19. Koka T. Fast and sample accurate R-peak detection for noisy ECG using visibility graphs / T. Koka, M. Muma // 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC-2022) – 2022 – P. 11-15