
МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

УДК 004.8

О. В. КОВАЛЬЧУК, О. В. БАРМАК

МЕТОД КЛАСИФІКАЦІЇ АРИТМІЙ НА ЕКГ-СИГНАЛІ

*Хмельницький національний університет, Інститутська 11, Хмельницький, 29016, Хмельницький,
Україна, e-mail: losha.kovalchuk1998@gmail.com*

Анотація. У статті запропоновано вдосконалений метод класифікації аритмій на основі згорткової нейронної мережі (CNN), застосованої до сигналів ЕКГ. Для покращення якості класифікації сигнали ЕКГ було розбито на фрагменти, що містять три кардіоцикли, з поточним кардіоциклом у центрі. Вдосконалена архітектура CNN включала додавання шарів пакетної нормалізації, додаткового згорткового шару та шару відсіювання, що сприяло підвищенню точності моделі. Окрім цього, було проведено оптимізацію гіперпараметрів. Модель навчалася на базі даних MIT-BIH Arrhythmia Database для класифікації дев'яти класів ЕКГ. Досягнута середня точність 99,26% підтверджує ефективність запропонованого методу в діагностиці різних типів аритмій.

Ключові слова: медична діагностика, електрокардіограма, класифікація ЕКГ, штучний інтелект, згорткові нейронні мережі

Abstract. This paper proposes an improved arrhythmia classification method based on a convolutional neural network (CNN) applied to ECG signals. To improve the quality of classification, ECG signals were split into fragments containing three cardiac cycles with the current cardiac cycle in the center. The improved CNN architecture includes the addition of batch normalization layers, an additional convolutional layer, and a dropout layer, which improves the model's accuracy. In addition, hyperparameters were optimized for new CNN architecture. The model was trained data of the MIT-BIH Arrhythmia Database to classify nine classes of ECG. The achieved average accuracy of 99.26% confirms the effectiveness of the proposed method in diagnosing various types of arrhythmias

Keywords: medical diagnosis, electrocardiogram, ECG classification, artificial intelligence, convolutional neural networks

DOI: 10.31649/1681-7893-2024-48-2-34-44

ВСТУП

Стрімкий розвиток штучного інтелекту відкриває нові можливості в багатьох галузях, включаючи медицину, де він стає потужним інструментом для діагностики та лікування захворювань. Однією з ключових сфер, де штучний інтелект продемонстрував значний прогрес, є автоматична класифікація серцевих патологій за сигналами електрокардіограми (ЕКГ). ЕКГ є одним із найважливіших інструментів для виявлення серцево-судинних захворювань. Використання алгоритмів машинного навчання та глибокого навчання для автоматичної обробки й класифікації ЕКГ сигналів дозволяє досягти високої точності діагностики, підвищити ефективність аналізу та скоротити час на виявлення патологій в роботі серця. У цій статті пропонується вдосконалення методу класифікації патологій роботи серця за ЕКГ сигналами.

1. ОГЛЯД ЛІТЕРАТУРИ

Завдання класифікації патологій в роботі серця на основі ЕКГ сигналу не є новим для інформаційних технологій і вже існує ряд методів та підходів для її вирішення. Автори [1] навчили CNN-BiLSTM класифікувати п'ять типів аритмій з набору даних MIT-BIH. Застосування моделі показало, що модель здатна класифікувати з точністю 98%, 91% чутливості та 91% специфічності. Lui та інші [2] запропонували використання збірки на основі LSTM та CNN мереж, що дало можливість класифікувати ЕКГ сигнали з точністю 99.1%, чутливістю 99.3%, специфічністю 98.5%. Варто зазначити що автори отримали такий результат при класифікації ЕКГ лише на 4 класи та не включаючи клас «все інше»

Xu та ін. [3] розробили CNN класифікатор, який класифікує ЕКГ на п'ять класів, включаючи клас «норма» та «всі інші». Відповідно за допомогою запропонованого методу можна класифікувати лише 3 патології, що покриває малий набір можливих патологій.

В роботах Degirmenci та ін. [4] і Rohmantri та ін. [5] досягли високої точності класифікації, використовуючи 2D зображення ЕКГ розміром 64x64 як вхідні дані для класифікації аритмічного серцебиття. Також існує ряд робіт із перетворенням одновимірний сигнал у двовимірне представлення як спектограми, скалограми. До таких робіт відносяться [6, 7, 8, 9]. Незважаючи на результат, значні обчислювальні ресурси, що вимагаються, створюють проблеми для застосування в реальному часі та використання на пристроях з обмеженою обчислювальною потужністю. Також в наведених роботах не використовується клас «всі інші», застосування якого, ймовірно, погіршить результат класифікації.

В роботі Abdelhafid та ін. [10] зосередилися на класифікації аритмії ЕКГ з використанням п'яти класів без класу «всі інші». Це, ймовірно, сприяло високим показникам класифікації. Однак виключення класу "все інше" може не відображати реальну точність, оскільки ігнорує сигнали, які не відповідають попередньо визначеним категоріям. Також в даній роботі на вхід подається інформація про 1 кардіоцикл. Оскільки до переліку підтримуваних класів входить "Premature ventricular contraction", то такої кількості даних може бути не достатньо для класифікації. Дана патологія має ознаку "компенсаторна пауза", для визначення якої потрібні сусідні кардіоцикли.

Отже, для ефективного виявлення аритмії вкрай важливо розробити моделі DL, які могли б збалансувати точність, обчислювальну можливість і здатність класифікувати більшу кількість патологій включаючи клас до якого увійдуть всі випадки патологій які не виділені в окремий клас [15-19].

Метою дослідження є: підвищення точності класифікації сигналів ЕКГ для розширеного набору можливих класів.

2. ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

Для вдосконалення існуючих підходів до класифікації ЕКГ-сигналів (за умови класифікації патологій аритмій) запропоновано метод, схематично зображений на рис. 1.

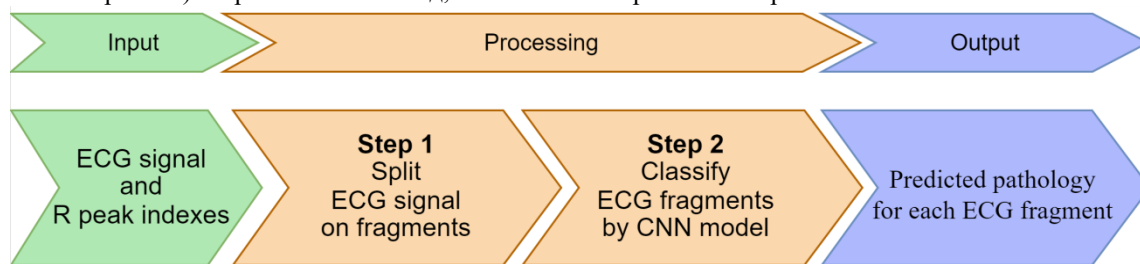


Рисунок 1 – Схема методу класифікації ЕКГ-сигналу за патологіями аритмій

З аналізу відомих підходів випливає, що у переважній більшості робіт, вхідним зразком для неймережі є один кардіоцикл. Але, для правильної ідентифікації патологій які розглядаються, з точки зору лікаря, не достатньо враховувати один кардіоцикл для прийняття правильного рішення, а потрібно також мати інформацію про те, що відбувалося до та після поточного кардіоциклу. Тому авторами запропоновано вхідний зразок-кардіоцикл доповнювати сусідніми кардіоциклами. Це є особливістю даного методу, і, на думку авторів, дозволить моделі глибокого навчання виявляти додаткові приховані залежності у ЕКГ-сигналі, що дозволить більш якісно ідентифікувати патології, що розглядаються.

Вхідною інформацією методу є ЕКГ-сигнал та індекси попередньо визначених R піків. На *кроці 1* методу відбувається процес попередньої обробки та підготовки вхідних зразків (фрагментів) для класифікації. Вхідний сигнал розбивається на фрагменти загальною довжиною 700 відліків.

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

Запропонована довжина фрагменту була обрана емпірично, таким чином, щоб фрагмент включав 3 кардіоцикли (R-піки), а саме: попередній, поточний (як основний об'єкт класифікації) та наступний. У вхідному фрагменті сигналу, поточний кардіоцикл розміщується таким чином, щоб завжди бути в центрі фрагмента. Приклади вхідних фрагментів ЕКГ-сигналів зображені на рис.2.




Рисунок 2 – Приклади подання вхідного фрагменту ЕКГ-сигналу

На *кроці 2* методу проводиться класифікація сформованого зразка за допомогою вдосконаленої архітектури нейромережі. У роботі запропоноване вдосконалення архітектури нейромережі, наведеної у [3] для схожої задачі класифікації з навчанням за тим же набором даних, але з іншим виглядом вхідних зразків. Авторами у [3] заявлені числові результати роботи за overall accuracy of 99.43%. Проте класифікувались не всі наявні у зазначеному наборі даних патології. В табл. 1 наведена вдосконалена архітектура нейромережі, де основні запропоновані зміни виділені окремим кольором.

Таблиця 1

Вдосконалена архітектура нейромережі						
Layer name	Input	Output	kernel_size	stride	padding	probability
<i>Encoder</i>						
Conv1d ReLU	1	64	5	3	1	
BatchNorm1d	64					
Conv1d ReLU	64	64	5	2	1	
BatchNorm1d	64					
MaxPool1d			1	2		
Conv1d ReLU	64	128	3	1	1	
BatchNorm1d	128		1	2		
Conv1d ReLU	128	128	3	2	1	
BatchNorm1d	128					
Conv1d ReLU	128	256	3	1	1	
BatchNorm1d	256					
MaxPool1d			1	2		
<i>Classifier</i>						
Linear ReLU	3584	300				
BatchNorm1d Dropout	300					0.68
Linear ReLU	300	150				
Linear	128	9				

Виходячи з того, що запропоноване нове подання вхідного сигналу та розширена кількість патологій, для отримання якісних результатів класифікації, запропоноване вдосконалення архітектури нейромережі включає:

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

1) Виходячи з того, що подання вхідного зразка у наведеному вище вигляді, з однієї сторони, буде враховувати приховані залежності з трьох кардіоциклів, а з іншої сторони, буде збільшено кількість класів для класифікації, потрібно змінити архітектуру нейромережі з врахуванням цієї особливості. Пропонується додати ще один згортковий шар як для розширення можливості нейромережі виділяти більшу кількість характерних ознак так і успішно класифікувати за цими ознаками більшу кількість класів.

2) Виходячи з того, що додавання ще одного згорткового шару суттєво збільшать і так не маленьку обчислювальну складність, пропонується модифікувати архітектуру нейромережі додаванням шарів Batch Normalization після кожного згорткового шару та після першого лінійного шару. Додавання даного шару дає можливість нормалізувати активації по кожному каналу в партії (batch), що запобігає різкому зростанню та спаданню активацій, що дає можливість стабілізувати процес навчання [11].

3) Додавання Dropout шару після першого лінійного шару допомагає покращити здатність нейромережі до узагальнення, підвищити її стійкість і запобігти перенавчанню.

4) Також, виходячи з суттєвої зміни архітектури, застосовується знаходження оптимальних гіперпараметрів шарів нейромережі таких як: kernel size, stride, padding, dropout probability. Отримані гіперпараметри наведені в табл. 1.

В результаті застосування запропонованої CNN мережі до вхідних фрагментів ЕКГ формується масив, який містить визначену патологію такого фрагменту.

3. РЕЗУЛЬТАТИ ТА ОБГОВОРЕННЯ

Для навчання та тестування нейронної мережі було використано ЕКГ сигнали із бази даних MIT-BIH Arrhythmia[12]. Базуючись на анотації до бази даних MIT-BIH Arrhythmia було обрано наступні класи/патології для класифікації:

1. Normal beat
2. Premature ventricular contraction
3. Paced beat
4. Right bundle branch block beat
5. Left bundle branch block beat
6. Atrial premature beat
7. Fusion of ventricular and normal beat
8. Fusion of paced and normal beat
9. Others

Оскільки MIT-BIH Arrhythmia база даних містить сигнали холтерного типу із тривалістю 30 хв, то ці сигнали було розбито на менші сигнали із довжиною 8000 елементів. Отриманий, після розбиття, набір сигналів було розділено на навчальну і тестову вибірку із співвідношенням 80/20 %. Додатково 10% навчального набору використовується як окремих валідаційний набір при навчанні мережі, який використовується для перевірки моделі в процесі навчання на предмет перенавчання (overfitting).

Навчання нейромережі відбувалось з використанням оптимізатора Adam [13] в 2 етапи. На першому етапі навчання відбувалось зі швидкістю навчання 0,001, що дало змогу досягти значення втрати 0.024269-0.019391. На другому етапі навчання відбувається із швидкістю 0,0001, що призвело до значення втрати 0.00746-0.004003. Загальна кількість епох навчання становила 17. На рис. 3 зображені приклади графіків співвідношення між training & validation loss (рис. 3 (а)) та співвідношення між training & validation accuracy (рис. 3 (б)).

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ




Рисунок 3 – Приклад графіків співвідношення між training & validation loss

На графіку співвідношення функції втрат (рис. 3 (а)) вісь абсцис відповідає за номер епохи навчання, а вісь ординат – величину втрат. В свою чергу, синя крива відображає функцію втрат для навчального набору даних, тоді як помаранчева крива показує функцію втрат для валідаційного набору. На графіку видно, що на початкових етапах навчання функція втрат швидко знижується як для навчальної, так і для валідаційної вибірки, що свідчить про ефективне навчання моделі. Далі обидві криві стабілізуються та досягають низьких показників втрат та практично співпадають, що свідчить про збіг результатів на обох вибірках. Це вказує на те, що вдалося уникнути перенавчання (overfitting).

На рис. 3 (б) зображено графік зміни точності на навчальній та валідаційній вибірці в процесі навчання моделі. Вісь абсцис відповідає за номер епохи, а вісь ординат – за точність. Синя крива показує точність класифікації для навчального набору даних, тоді як помаранчева крива відображає результати на валідаційній вибірці. На початкових етапах точність швидко зростає, досягаючи понад 95% після перших кількох епох. Після цього обидві криві стабілізуються на рівні майже 100%, що свідчить про високу якість класифікації та добру здатність моделі до узагальнення [20-22].

Для отримання статистичних показників якості класифікації, використовувались 7 варіантів випадкового розбиття наборів даних на навчальний і тренувальний набори. В таблиці 2 наведено середні статистичні показники та їх відхилення, отримані для навчальних та тестових вибірок.

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

Модель демонструє хороші результати класифікації на навчальній вибірці, про що свідчать практично ідеальні статистичні показники Precision, Recall, F1-score для всіх класів. На тестовій вибірці модель продовжує показувати хороші статистичні показники класифікації, однак в порівнянні з показниками для навчальної вибірки присутнє певне падіння значень статистичних показників. Найбільше падіння статистичних показників помітне для класів 7 і 9, що може свідчити про складність класифікації цих класів на нових даних.

Таблиця 2

Статистичні показники класифікації отриманні на навчальних та тестових вибірках

Клас	Train						Test					
	Precision		Recall		F1-score		Precision		Recall		F1-score	
	Avg	Std	Avg	Std	Avg	Std	Avg	Std	Avg	Std	Avg	Std
1	1	0	1	0	1	0	0.99	0.005	1.00	0	1.00	0
2	0.999	0.004	0.999	0.004	1	0	0.98	0.005	0.98	0.005	0.98	0.005
3	1	0	1	0	1	0	0.99	0.005	1.00	0	1.00	0.005
4	1	0	1	0	1	0	1.00	0.004	1.00	0	1.00	0
5	1	0	1	0	1	0	1.00	0	1.00	0	1.00	0
6	0.999	0.004	1	0	1	0	0.96	0.012	0.93	0.008	0.94	0.007
7	0.949	0.013	0.963	0.016	0.957	0.005	0.90	0.024	0.81	0.037	0.85	0.016
8	1	0	0.997	0.005	1	0	0.96	0.022	0.93	0.038	0.95	0.018
9	0.993	0.005	0.997	0.005	0.994	0.005	0.853	0.042	0.8	0.124	0.823	0.08

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

Причиною падіння статистичних показників для класів 7 та 9 може бути те, що сигнали такого типу представлені в меншій кількості в базі даних, що не дає можливості нейромережі повністю оволодіти знаннями про такий вид сигналів. Також варто зазначити, що показник Recall на тестовій вибірці має значення вище за 80%, що свідчить про те, що класифікатор підібраний правильно.

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

Для оцінки якості класифікації кожного класу було побудовано графіки ROC кривих [14] (рис. 4).

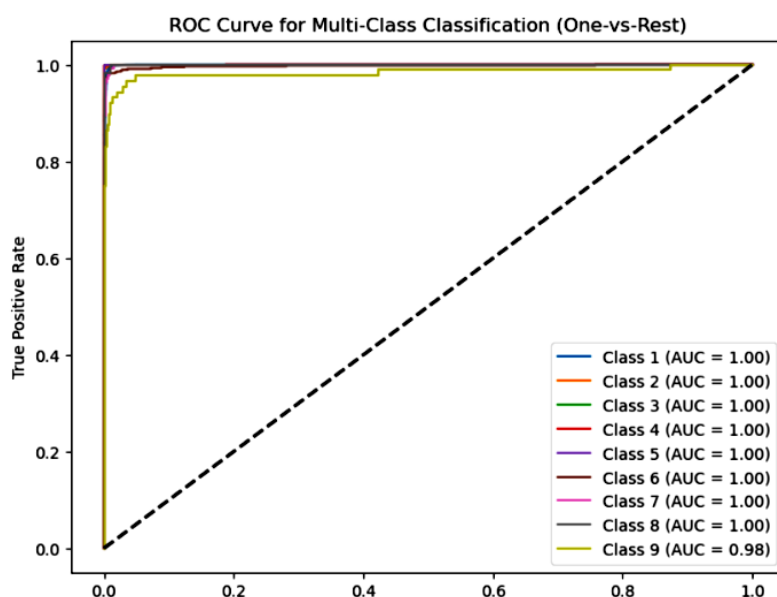


Рисунок 4 – ROC отримані за результатами класифікації на тестовій вибірці даних

ROC криві для більшості класів розташовані дуже близько до лівого верхнього кута графіка, що підтверджує високу ефективність моделі. Високі значення AUC для всіх класів (більшість з яких дорівнює 1.00) вказують на те, що модель відмінно справляється з задачами розрізнення між позитивними та негативними прикладами в усіх класах. Навіть для тих класів, де AUC трохи нижчий (клас 9), модель демонструє чудові результати.

Далі буде розглянуто порівняння запропонованого методу з існуючими. Для цього варто підвести підсумкові значення для статистичних показників запропонованого методу. Точність запропонованого методу на тестовій вибірці в середньому складає 99.26%. В таблиці 3 наведено значення макро та вагових середніх статистичних показників.

Таблиця 3

Середні статистичні показники класифікації 9 класу ЕКГ

	Precision	Recall	F1-score
Macro	0.96	0.94	0.95
Weighted	0.99	0.99	0.99

Серед усіх класів, підтримуваних під час класифікації, клас «Others» є менш стабільним. Це все пояснюється тим, що кардіоцикли такого класу значно менше представлені в базі даних. Також для класу «Others» характерна більша варіативність, що ще більше підкреслює проблему малої кількості сигналів даного класу. Саме це впливає на Macro показник, оскільки для нього всі класи рівноцінні незважаючи на їх кількісне представлення в вибірці. Якщо виключити з розрахунку кардіоцикли класу «Others», то статистичні показники набувають значень, які представлені в таблиці 4.

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

Таблиця 4

Середні статистичні показники класифікації ЕКГ без врахування класу «Others»

	Precision	Recall	F1-score
Macro	0.97	0.96	0.96
Weighted	0.99	0.99	0.99

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

1. Підходи, які об'єднують класи кардіоциклів в групи і класифікують кардіоцикли на приналежність до певної групи;
2. Підходи, які класифікують кожний клас кардіоциклу.

Перший тип підходів базується на рекомендації від Association for the Advancement of Medical Instrumentation (AAMI), яка полягає в групуванні класів кардіоциклів. Прикладом таких груп є: non-ectopic beat, supra ventricular ectopic beat, ventricular ectopic beat, fusion, and unknown. Використання груп дає перевагу в навчанні мережі, оскільки згрупувавши дані вдається уникнути малого розподілу даних між класами, тим самим отримати хороші статистичні результати класифікації. Але такий підхід до класифікації не завжди задовольняє потребу лікаря, оскільки для правильної діагностики лікарю важливо знати конкретну патологію кардіоциклу, а не групу до якої було віднесено патологію.

Враховуючи те, що запропонований метод не базується на ААМІ, то отримати повністю рівнозначне порівняння статистичними показниками методів на основі ААМІ не вдається. В таблиці 5 наведено порівняння статистичних показників методів класифікації ЕКГ сигналу, які базуються на ААМІ, із запропонованим в даній роботі методом. Попри те, що запропонований метод фокусується на класифікації 9 класів кардіосигналу, він здебільшого демонструє кращі результати ніж методи, які класифікують кардіосигнали на відповідність групам.

Таблиця 5

Порівняння з методами класифікації, які базуються на ААМІ

Підхід	Кількість груп	Назва показника	Значення показника	Наші показники
A. Ahmed et al [39]	4	Accuracy	0.99	0.9926
		Precision	0.93	0.96
		Recall	0.94	0.94
		F1-score	0.93	0.95
XU et al [15]	5	Accuracy	0.998	0.9926
		Precision	0.98	0.96
		Recall	0.94	0.94
		F1-score	0.96	0.95
Hassan et al [13]	5	Accuracy	0.98	0.9926
		Specificity	0.91	-
		Recall	0.91	0.94
Kumar et al [40]	5	Accuracy	0.987	0.9926
		Precision	0.989	0.96
		Recall	0.939	0.94
		F1-score	0.963	0.95
Mahmud et al [41] for signal	6	Accuracy	0.94	0.9926
		Precision	0.95	0.96
		Recall	0.90	0.94
		F1-score	0.92	0.95
Mahmud et al [41] for image	6	Accuracy	0.93	0.9926
		Precision	0.93	0.96
		Recall	0.93	0.94
		F1-score	0.93	0.95

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

В таблиці 6 наведено порівняння статистичних результатів запропонованого методу із результатами методів, які підпадають під другу категорію методів, а саме для класифікації каріоциклів на конкретні атомарні класи патологій. Оскільки, кожний такий метод може підтримувати класифікацію різного набору класів кардіоциклів, то порівняння середнього значення статистичних показників класифікації буде не рівнозначним.

Таблиця 6

Порівняння з методами класифікації ЕКГ на атомарні патології

Підхід	Кількість класів	Спільні класи	Показники	Показники для спільних класів	Наші показники для спільних класів
A. Ullah [18]	8	6	Precision	0.985	0.988
			Recall	0.977	0.984
			F1-Score	0.981	0.986
Rohmantri [17]	8	7	Precision	0.973	0.97
			Recall	0.893	0.95
			F1-Score	0.927	0.96
Degirmenci [16]	5	5	Precision	0.995	0.993
			Recall	0.997	0.997
			F1-Score	0.992	0.995
Liu [14]	4	4	Precision	-	0.993
			Recall	0.993	0.995
			F1-Score	-	0.994
HUI YANG [42]	6	6	Precision	0.991	0.988
			Recall	-	0.984
			F1-Score	0.966	0.986

Тому в таблиці 6 разом із загальними середніми статистичними показниками кожного методу наведено також і статистичні показники, які характеризують класифікацію лише спільних класів для розглянутого та запропонованого метода.

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

ВИСНОВКИ

В даній роботі запропоновано вдосконалення методу класифікації аритмій на основі CNN моделі, застосованого до сигналів ЕКГ. Метод передбачає розбиття ЕКГ сигналу на фрагменти таким чином, щоб включати 3 кардіоцикли, де поточний кардіоцикл знаходиться посередині. Отримані фрагменти класифікуються за допомогою CNN мережі із вдосконаленою архітектурою, яка включала додавання шарів пакетної нормалізації, додаткового згорткового шару та шару відсіювання. Додатково отримана архітектура мережі була покращена шляхом проведення оптимізації гіперпараметрів. Для навчання та тестування було використано базу даних MIT-BIH Arrhythmia Database. В результаті тестування мережі отримано високі статистичні показники accuracy, precision, recall, та F1-scores. Загальна точність моделі в середньому становить 99,26%, що свідчить про її ефективність у класифікації 9 класів ЕКГ.

СПИСОК ЛІТЕРАТУРИ

- Hassan S., Zahid M., Abdullah T., Husain K., "Classification of cardiac arrhythmia using a convolutional neuralnetwork and bi-directional long short-term memory", *Digit. Health*, 2022, pp. 1-13, doi: 10.1177/20552076221102766.
- Liu F., Zhou X., Cao J., Wang Z., Wang H., Zhang Y., "A LSTM and CNN Based Assemble Neural Network Framework for Arrhythmias Classification", *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Brighton, UK, 2019, pp. 1303-1307, doi: 10.1109/ICASSP.2019.8682299.

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

3. Xu X., Liu H., “ECG Heartbeat Classification Using Convolutional Neural Networks”, *IEEE Access*, vol. 8, pp. 8614-8619, 2020, doi: 10.1109/ACCESS.2020.2964749.
4. Degirmenci M., Ozdemir M. A., Izci E., Akan A., “Arrhythmic Heartbeat Classification Using 2D Convolutional Neural Networks”, *IRBM*, 2021, doi: 10.1016/j.irbm.2021.04.002
5. Rohmantri R., Surantha N., “Arrhythmia Classification using 2D Convolutional Neural Network”, *the International Journal of Advanced Computer Science and Applications*, pp. 201-208, 2020.
6. Ullah A., Anwar S. M., Bilal M., Mehmood R. M., “Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation”, *Remote Sensing*, 2020. doi:10.3390/rs12101685.
7. Giriprasad P., Sanjeeva reddy A., Sreehari R.V., “Automatic Classification of Cardiac Arrhythmias based on ECG Signals Using Transferred Deep Learning Convolution Neural Network”, *Journal of Physics: Conference Series, Volume 2089, 1st International Conference on Applied Mathematics, Modeling and Simulation in Engineering (AMSE)*, 2021. doi:10.1088/1742-6596/2089/1/012058.
8. Vu T. A., Huy H. Q., Khanh P. D., Huyen N. T. M., Uyen T. T. T., Huong P. T. V., “Classify arrhythmia by using 2D spectral images and deep neural network”, 2021, doi: [10.11591/ijeecs.v25.i2.pp931-940](https://doi.org/10.11591/ijeecs.v25.i2.pp931-940)».
9. Zhang H., Liu C., Zhang Z., Xing Y., Liu X., Dong R., He Y. H., Xia L., Liu F., “Recurrence Plot-Based Approach for Cardiac Arrhythmia Classification Using Inception-ResNet-v2”, *Front Physiol*, 2021, doi: 10.3389/fphys.2021.648950.
10. Abdelhafid E., Aymane E., Benayad N., Abdelalim S., Hachem E. Y. A. M., Rachid O. H. T., Brahim B., “ECG Arrhythmia Classification Using Convolutional Neural Network”, *The International Journal of Emerging Technology and Advanced Engineering*, 2022, pp. 186-195, doi: 10.46338/ijetae0722_19
11. Yang G., Pennington J., Rao V., Sohl-Dickstein J., Schoenholz S. S., “A Mean Field Theory of Batch Normalization”, 2019, doi.org/10.48550/arXiv.1902.08129.
12. Moody G., R. Mark, “The impact of the MIT-BIH Arrhythmia Database”, *IEEE Eng in Med and Biol*, 2001, pp. 45-50, doi: 10.1109/51.932724.
13. Adaptive Moment Estimation. [Електронний ресурс]. Доступно: <https://medium.com/@nerdjock/deep-learning-course-lesson-7-4-adam-adaptive-moment-estimation-e23434850bfc>.
14. Hoo Z. H., Candlish J., Teare D., “What is an ROC curve?” *Emergency Medicine Journal*, 2017, pp. 357-359, doi: 10.1136/emmermed-2017-206735.
15. Pavlov S. V. Information Technology in Medical Diagnostics //Waldemar Wójcik, Andrzej Smolarz, July 11, 2017 by CRC Press - 210 Pages.
16. Wójcik W., Pavlov S., Kalimoldayev M. Information Technology in Medical Diagnostics II. London: (2019). Taylor & Francis Group, CRC Press, Balkema book. – 336 Pages.
17. Highly linear Microelectronic Sensors Signal Converters Based on Push-Pull Amplifier Circuits / edited by Waldemar Wojcik and Sergii Pavlov, Monograph, (2022) NR 181, Lublin, Comitet Inzynierii Srodowiska PAN, 283 Pages. ISBN 978-83-63714-80-2
18. Pavlov Sergii, Avrunin Oleg, Hrushko Oleksandr, and etc. System of three-dimensional human face images formation for plastic and reconstructive medicine // Teaching and subjects on bio-medical engineering Approaches and experiences from the BIOART-project Peter Arras and David Luengo (Eds.), 2021, Corresponding authors, Peter Arras and David Luengo. Printed by Acco cv, Leuven (Belgium). - 22 P. ISBN: 978-94-641-4245-7.
19. Інтелектуальні технології в медичній діагностиці, лікуванні та реабілітації: монографія / [С. В Павлова, О.Г. Авруніна, С.М.Злепка, Є.В.Бодяньського та ін.]; за редакцією С.Павлова, О.Авруніна. – Вінниця: ПП «ТД «Едельвейс і К», 2019. –260 с. ISBN 978-617-7237-59-3.
20. Vasyl V. Kukharchuk, Sergii V. Pavlov, Samoil Sh. Katsyv, and etc. (2021). Transient analysis in 1st order electrical circuits in violation of commutation laws”, *Przegląd elektrotechniczny*, ISSN 0033-2097, R. 97 NR 9/2021, p. 26-29, doi:10.15199/48.2021.09.05.
21. Pavlov S.V, Petruk V.G., Kolesnik P.F. (2007). Photoplethysmographic technologies of the cardiovascular control: monography, Vinnitsa: Universum-Vinnitsa, 254 p.
22. Wójcik W, Mezhiievskia I, Pavlov SV, Lewandowski T, Vlasenko OV, Maslovskiy V, Volosovych O, Kobyljanska I, Moskovchuk O, Ovcharuk V, et al. (2023). Medical Fuzzy-Expert System for Assessment of the Degree of Anatomical Lesion of Coronary Arteries. *International Journal of Environmental Research and Public Health*. 20(2):979. <https://doi.org/10.3390/ijerph20020979>.

REFERENCES

1. Hassan S., Zahid M., Abdullah T., Husain K., "Classification of cardiac arrhythmia using a convolutional neural network and bi-directional long short-term memory", *Digit. Health*, 2022, pp. 1-13, doi: 10.1177/20552076221102766.
2. Liu F., Zhou X., Cao J., Wang Z., Wang H., Zhang Y. "A LSTM and CNN Based Assemble Neural Network Framework for Arrhythmias Classification", *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Brighton, UK, 2019, pp. 1303-1307, doi: 10.1109/ICASSP.2019.8682299.
3. Xu X., Liu H., "ECG Heartbeat Classification Using Convolutional Neural Networks", *IEEE Access*, vol. 8, pp. 8614-8619, 2020, doi: 10.1109/ACCESS.2020.2964749.
4. Degirmenci M., Ozdemir M. A., Izci E., Akan A., "Arrhythmic Heartbeat Classification Using 2D Convolutional Neural Networks", *IRBM*, 2021, doi: 10.1016/j.irbm.2021.04.002
5. Rohmantri R., Surantha N., "Arrhythmia Classification using 2D Convolutional Neural Network", *the International Journal of Advanced Computer Science and Applications*, pp. 201-208, 2020.
6. Ullah A., Anwar S. M., Bilal M., Mehmood R. M., "Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation", *Remote Sensing*, 2020. doi:10.3390/rs12101685».
7. Giriprasad P., Sanjeeva reddy A., Sreehari R.V., "Automatic Classification of Cardiac Arrhythmias based on ECG Signals Using Transferred Deep Learning Convolution Neural Network", *Journal of Physics: Conference Series, Volume 2089, 1st International Conference on Applied Mathematics, Modeling and Simulation in Engineering (AMSE)*, 2021. doi:10.1088/1742-6596/2089/1/012058.
8. Vu T. A., Huy H. Q., Khanh P. D., Huyen N. T. M., Uyen T. T. T., Huong P. T. V., "Classify arrhythmia by using 2D spectral images and deep neural network", 2021, doi: [10.11591/ijeecs.v25.i2.pp931-940](https://doi.org/10.11591/ijeecs.v25.i2.pp931-940)».
9. Zhang H., Liu C., Zhang Z., Xing Y., Liu X., Dong R., He Y. H., Xia L., Liu F., "Recurrence Plot-Based Approach for Cardiac Arrhythmia Classification Using Inception-ResNet-v2", *Front Physiol*, 2021, doi: 10.3389/fphys.2021.648950.
10. Abdelhafid E., Aymane E., Benayad N., Abdelalim S., Hachem E. Y. A. M., Rachid O. H. T., Brahim B., "ECG Arrhythmia Classification Using Convolutional Neural Network", *The International Journal of Emerging Technology and Advanced Engineering*, 2022, pp. 186-195, doi: 10.46338/ijetae0722_19
11. Yang G., Pennington J., Rao V., Sohl-Dickstein J., Schoenholz S. S., "A Mean Field Theory of Batch Normalization", 2019, doi.org/10.48550/arXiv.1902.08129.
12. Moody G., R. Mark, "The impact of the MIT-BIH Arrhythmia Database", *IEEE Eng in Med and Biol*, 2001, pp. 45-50, doi: 10.1109/51.932724.
13. Adaptive Moment Estimation. [Online]. Available: <https://medium.com/@nerdjock/deep-learning-course-lesson-7-4-adam-adaptive-moment-estimation-e23434850bfc>.
14. Hoo Z. H., Candlish J., Teare D., "What is an ROC curve?" *Emergency Medicine Journal*, 2017, pp. 357-359, doi: 10.1136/emmermed-2017-206735.
15. Pavlov S. V. Information Technology in Medical Diagnostics //Waldemar Wójcik, Andrzej Smolarz, July 11, 2017 by CRC Press - 210 Pages.
16. Wójcik W., Pavlov S., Kalimoldayev M. Information Technology in Medical Diagnostics II. London: (2019). Taylor & Francis Group, CRC Press, Balkema book. – 336 Pages.
17. Highly linear Microelectronic Sensors Signal Converters Based on Push-Pull Amplifier Circuits / edited by Waldemar Wojcik and Sergii Pavlov, Monograph, (2022) NR 181, Lublin, Comitet Inzynierii Srodowiska PAN, 283 Pages. ISBN 978-83-63714-80-2
18. Pavlov Sergii, Avrunin Oleg, Hrushko Oleksandr, and etc. System of three-dimensional human face images formation for plastic and reconstructive medicine // Teaching and subjects on bio-medical engineering Approaches and experiences from the BIOART-project Peter Arras and David Luengo (Eds.), 2021, Corresponding authors, Peter Arras and David Luengo. Printed by Acco cv, Leuven (Belgium). - 22 P. ISBN: 978-94-641-4245-7.
19. Intellectual technologies in medical diagnosis, treatment and rehabilitation: monograph / [S. In Pavlova, O.G. Avrunina, S.M. Zlepka, E.V. Bodyanskyi, etc.]; edited by S. Pavlov, O. Avrunin. - Vinnytsia: PP "TD "Edelweiss and K", 2019. -260 p. ISBN 978-617-7237-59-3.
20. Vasyly V. Kukharchuk, Sergii V. Pavlov, Samoil Sh. Katsyv, and etc. (2021). Transient analysis in 1st order electrical circuits in violation of commutation laws", *Przegląd elektrotechniczny*, ISSN 0033-2097, R. 97 NR 9/2021, p. 26-29, doi:10.15199/48.2021.09.05.
21. Pavlov S.V, Petruk V.G., Kolesnik P.F. (2007). Photoplethysmographic technologies of the

МЕТОДИ ТА СИСТЕМИ ОПТИКО-ЕЛЕКТРОННОЇ І ЦИФРОВОЇ ОБРОБКИ ЗОБРАЖЕНЬ ТА СИГНАЛІВ

- cardiovascular control: monography, Vinnitsa: Universum-Vinnitsa, 254 p.
22. Wójcik W, Mezhiievska I, Pavlov SV, Lewandowski T, Vlasenko OV, Maslovskiy V, Volosovych O, Kobylianska I, Moskovchuk O, Ovcharuk V, et al. (2023). Medical Fuzzy-Expert System for Assessment of the Degree of Anatomical Lesion of Coronary Arteries. International Journal of Environmental Research and Public Health. 20(2):979. <https://doi.org/10.3390/ijerph20020979>.

Надійшла до редакції 15.07.2024 р.

БАРМАК ОЛЕКСАНДР ВОЛОДИМИРОВИЧ – д.т.н., професор, завідувач кафедри комп'ютерних наук, Хмельницький національний університет, Хмельницький, Україна,
e-mail: alexander.barmak@gmail.com

КОВАЛЬЧУК ОЛЕКСІЙ ВОЛОДИМИРОВИЧ – аспірант кафедри комп'ютерних наук, Хмельницький національний університет, Хмельницький, Україна, ***e-mail: losha.kovalchuk1998@gmail.com***

O. V. KOVALCHUK, O. V. BARMAK
METHOD OF ARRHYTHMIA CLASSIFICATION ON ECG SIGNAL
Khmelnyskyi National University