

М. Ковальчук¹, студент
В. Харченко¹, студентка
А. Яворський¹, аспірант
І. Беда¹, аспірант
Т. Панченко¹, доцент

Класифікація ЕКГ сигналів методами машинного навчання

Київський національний університет імені
Тараса Шевченка, Україна, 03022, м.Київ,
просп. Академіка Глушкова, 4Д, 03022
e-mail: taras.panchenko@gmail.com

M. Kovalchuk¹, student
V. Kharchenko¹, student
A. Yavorskyi¹, PhD student
I. Bieda¹, PhD student
T. Panchenko¹, PhD, Associate Professor

ECG signal classification using machine learning techniques

Taras Shevchenko National University of Kyiv,
4D, Academician Glushkov ave.,
Kyiv, Ukraine, 03022
e-mail: taras.panchenko@gmail.com

Важливість аналізу електрокардіограм (ЕКГ) важко переоцінити. Ритм життя, стреси та інші фактори впливають на частоту захворювань та їх ранні прояви. Разом з тим, технологізація (цифровізація) життя та апаратно-програмних комплекси, такі як мобільні електронні кардіографи та носимі пристрої загалом, що бурхливо розвиваються останнім часом, відкривають нові можливості для швидкого аналізу стану людини за певними показниками, а також дозволяють проводити діагностику на новому рівні практично у реальному часі.

Існує багато методів для аналізу кардіограм. В даній роботі авторами запропоновано новий підхід, що ефективно розв'язує задачу аналізу ЕКГ. Дослідження базується на наборі даних PhysioNet Computing in Cardiology Challenge 2017 та MIT-BIH Arrhythmia Database. Алгоритм складається з таких етапів: фільтрація даних, локалізація R піків, передискретизація ЕКГ, визначення класу ЕКГ за допомогою ансамблю з 1D CNN та підсумкового класифікатора.

Запропонований метод показує високу точність за метрикою F_1 , тому являє собою цінність для подальших досліджень, оптимізації та впровадження.

Ключові слова: електрокардіограма, ЕКГ, класифікація ЕКГ, одновимірні згорткові нейронні мережі, 1D CNN.

The importance of electrocardiogram (ECG) analysis is difficult to overestimate. Rhythm of life, stress and other factors affect the frequency of diseases and their early appearance. At the same time, the technologization (digitalization) of life and hardware-software complexes, such as mobile electronic cardiographs and wearable devices in general, which are rapidly developing, open new opportunities for rapid analysis of human state by certain indicators, as well as allow to diagnose on the new higher level in almost real time.

There are many methods for analyzing cardiograms. In this paper, the authors propose a new approach based on an ensemble of individual classifiers, which effectively solves the problem of ECG analysis. The study is based on the PhysioNet Computing in Cardiology Challenge 2017 and the MIT-BIH Arrhythmia Database. The algorithm consists of the following stages: data filtering using moving average and Butterworth filters, R-peak localization via threshold and grouping method, ECG resampling for the better comparability, "Noisy" vs "NotNoisy" classification as the most hard-to-identify class, final classification as "Normal", "Atrial Fibrillation", "Other" using an ensemble of 1D CNN classifiers and a final classifier of selection using logistic regression, random forest or support vector machine (SVM).

The proposed method shows high accuracy by the metric F_1 , so it gives the background for further research, optimization and implementation. This way this algorithm could help to save human's life by in-time detection of problems with cardiovascular system (CVS) at early stage.

Keywords: electrocardiogram, ECG, ECG classification, one-dimensional convolutional neural networks, 1D CNN.

Статтю представила к.ф.-м.н., доц. Розора І.В.

Вступ

За статистикою Всесвітньої організації охорони здоров'я великий відсоток захворювань людей пов'язаний із серцево-судинною системою. Велику кількість проблем та ускладнень можна запобігти з допомогою неперервного моніторингу та постійного аналізу стану, зокрема знімаючи сигнали людського тіла та вчасно обробляючи їх. Одним з таких способів є аналіз серцевої діяльності в реальному часі за допомогою зчитування електрокардіограми (ЕКГ) [1].

Запропоновано багато методів для класифікації ЕКГ [2-7]. Вони різняться підходами, точністю, швидкістю опрацювання та іншими показниками ефективності.

Дане дослідження використовує набір даних PhysioNet / Computing in Cardiology Challenge 2017 [2,8], широко відомий для досліджень та розробки алгоритмів аналізу ЕКГ. Розглянуто декілька підходів та запропоновано комбінований метод аналізу, що спирається на 1D-згорткові нейронні мережі (CNN) та класифікатори для прийняття рішення. Запропонований метод робить висновок про кардіограму щодо відхилень у ній, а саме – наявності аритмії. Також відділяються надто зашумлені кардіограми та інші типи аритмій (без розподілу).

Порівняння з іншими методами [3] наведено наприкінці статті. Отримані авторами результати є адекватними та мають високе значення основної метрики аналізу якості таких методів – F_1 . Це робить метод придатним до подальшого впровадження та використання у зв'язці з мобільним кардіографом, подальшого дослідження та застосування.

Вхідні дані

Для розробки та тестування алгоритмів використовувався набір кардіограм з датасету PhysioNet / Computing in Cardiology Challenge-2017 [2]. Датасет містить в собі 8528 однополюсних ЕКГ-сигналів, записаних за допомогою пристрою AlivCor з частотою 300 Гц. Кожен із записів був позначений експертом,

одним з чотирьох класів: нормальний синусовий ритм, миготлива аритмія, інший вид ритму або зашумлена кардіограма, які позначалися як "N", "AF", "O" та "~" відповідно. Відсоткове співвідношення кожного класу та приклади ЕКГ показано в таблиці 1 та на рис. 1.

Таблиця 1. Співвідношення кардіограм різних класів в наборі даних PhysioNet / Computing in Cardiology Challenge 2017 [2]

Клас	N (Normal)	AF (Atrial Fibrillation)	O (Other)	~ (Noise)
Кількість	5076	758	2415	279
Відсоток	59.5%	8.9%	28.3%	3.3%




Рис. 1. Приклади ЕКГ з набору даних PhysioNet / Computing in Cardiology Challenge 2017 [2]

Огляд методу

Було розроблено модель, призначену для класифікації ЕКГ на чотири класи: нормальний ритм, миготлива аритмія, інші захворювання, зашумлена ЕКГ ("Normal", "Atrial Fibrillation", "Other", "Noisy" [2]). В основі моделі лежать 5 одновимірних згорткових нейронних мереж (CNN). Перед подачею даних нейронній мережі виконується попередня обробка ЕКГ, а саме: фільтрація, локалізація R піків (рис. 2), «розрізання» ЕКГ на менші частини і передискретизація. Після класифікації

«розрізаних» частин окремо, результати об'єднуються і обирається кінцевий клас для всієї ЕКГ. Було досліджено різні варіанти вибору кінцевого класу, а саме: зважений максимум ймовірностей за допомогою логістичної регресії, випадкових дерев та методу опорних векторів.




Рис. 2. Структура циклу ЕКГ та R піки

На першому кроці відділяємо зашумлені ЕКГ від інших. З проведених дослідів, цей клас гірше піддається класифікації, тому попередньо відокремлюємо такі кардіограми від решти. Для цього ЕКГ «розрізається» на частини по три секунди та кожна частина класифікується за допомогою CNN окремо (структура мережі подана далі). Розрізання ЕКГ необхідне для більш швидкого навчання нейронною мережею, адже проміжок (кількість даних) стає меншою, а кількість даних для навчання за обмеженої вибірки – більше. Складність класифікації полягає в тому, що деякі ЕКГ можуть суміщати кілька типів (класів фінальної класифікації) одночасно. Наприклад, одна частина ЕКГ – нормальна, а інша – зашумлена.

Наступний крок полягає у фільтрації ЕКГ, де ми застосовуємо рухоме середнє і фільтр Баттерворта [11]. Далі застосовуємо алгоритм знаходження R піків. На останньому кроці «розрізаємо» ЕКГ на частини, кожна з яких має кілька RR циклів, класифікуємо кожен частину, використовуючи CNN, і поєднуємо результати для всієї ЕКГ.

Попередня обробка даних

До того, як дані потрапляють на вхід нейронної мережі, вони проходять передобробку і первинний аналіз. При аналізі ЕКГ дослідників цікавить періодичний PQRST комплекс (рис. 2). Для відсіювання низьких частот використовуємо рухоме середнє, яке віднімаємо від результату. Для очищення сигналу від шумів використовуємо низькочастотний фільтр Баттерворта [11]. На рис. 3 показано результат застосування побудованого фільтру Баттерворта на дуже зашумленій ЕКГ.

Для покращення точності нейронної мережі вирівнюємо дані по R-R циклах. Для цього необхідно в автоматичному режимі локалізувати QRS комплекс. Автори пропонують алгоритм знаходження R піків, який складається з наступних кроків (рис. 4):

1. Трансформація сигналу за формулами (1), (2), (3), наведеними нижче. Цей крок допомагає виділити різкі зміни в амплітуді, характерні лише для QRS комплексу. Також на даному кроці R-піки, напрямлені вниз, перевертаються догори.
2. Виділення потенційних R піків. На даному кроці використовується рухоме вікно, в якому виділяються точки, вищі 97 квантиля.
3. Групування потенційних R піків, якщо вони знаходяться близько один до одного, і вибір найкращого кандидата в групі.

$$UpPeak_k = \left| \min_{j=k-9, k-1} (x_j) - x_k \right| + \left| \min_{j=k+1, k+9} (x_j) - x_k \right| \quad (1)$$

$$DownPeak_k = \left| \max_{j=k-9, k-1} (x_j) - x_k \right| + \left| \max_{j=k+1, k+9} (x_j) - x_k \right| \quad (2)$$

$$Tr_k = \max(UpPeak_k, DownPeak_k) \quad (3)$$




Рис. 3. Фрагмент ЕКГ 104 після фільтрації високочастотного шуму: а – вхідна ЕКГ; б – відфільтрована ЕКГ




Рис. 4. Локалізація R піків (чорний – вхідна ЕКГ A00706, зелений – трансформована, синій – потенційні R піки, червоний – визначені R піки)

Для тестування алгоритму і підбору параметрів було використано датасет MIT-BIH Arrhythmia Database [9,10]. Він складається з 48 ЕКГ, кожна по 30 хвилин. Датасет також містить розмічені R-піки та їх класифікацію. Основними показниками якості алгоритму визначення R піків є:

- T_p – кількість правильно визначених R піків,
- F_p – кількість хибнопозитивно визначених R піків,
- F_n – кількість хибнонегативно визначених R піків,
- похибка F_d .

В таблиці 2 наведено результати порівняння з методом, запропонованим у [12] (ECG

Enhancement and R-Peak Detection Based on Window Variability).

Таблиця 2. Характеристика точності визначення R-піків у порівнянні з [12]

Запропонований алгоритм			[111]		
F_p	F_n	F_d	F_p	F_n	F_d
40	141	0.2256	244	192	0.5759

Після визначення R піків «розрізаємо» кардіограму по декілька R-R циклів. Оскільки довжина циклів може відрізняється, навіть між парами сусідніх піків, проводимо передискретизацію виділених R-R циклів так, щоб результуюча послідовність мала задану в нейронній мережі довжину.

Класифікація ЕКГ

В результаті аналізу існуючих рішень, наукових статей та здійснених авторами попередніх спроб класифікації ЕКГ було виявлено, що згорткові нейронні мережі показують одні з кращих результатів. Саме тому для

побудови моделі використовується згорткова 1D нейронна мережа (1D CNN), тобто застосовувалась одновимірна згортка. В результаті, отримано 5 різних, але дуже схожих за архітектурою, нейронних мереж. З набору даних [2] було взято ~ 91% ЕКГ для тренування та ~ 9 % як тестову вибірку. Архітектура мереж зображена на рис. 5 та рис. 6.




Рис. 5. Архітектура мережі для класифікації на зашумлені та чисті ЕКГ




Рис. 6. Архітектура мережі для класифікації ЕКГ на класи “N”, “A” та “O”

При навчанні моделі було використано оптимізатор Adam, функцію активації ReLU та Softmax для вихідного шару. В якості функції помилки використовується категоріальна крос-ентропія (categorical cross-entropy). Також для всіх згорткових шарів використовувався L2 регуляризатор. Швидкість навчання була встановлена на рівні 0.001 з використанням експоненційного згасання (Exponential Decay).

Першим етапом класифікації було визначення зашумлених кардіограм. Для цього ЕКГ розділялись на частини по 3 секунди з різними зсувами. В результаті їх розділено на класи “Noisy”, “NotNoisy”. Саме для цієї класифікації брались чисті дані без використання фільтрів, щоб не спотворювати результат. Отримана точність нейронної мережі $F_p = 0,6167$ (рис. 7).

Наступним етапом класифікації була розробка ще 3 нейронних мереж для виявлення кардіограм, що мають нормальний ритм, аритмію та інший тип ритму, а саме для наступних бінарних класифікацій: “N” - “NotN”, “AF” - “NotAF”, “O” - “NotO”, а також розробка мережі для класифікації

на 3 класи: “N”, “AF”, “O” (“Normal”, “Atrial Fibrillation”, “Other”). Для цього ЕКГ розділялись на частини по кілька RR циклів з різними зсувами.




Рис. 7. Графік точності нейронної мережі протягом навчання “Noisy” - “NotNoisy”

На виході з нейронних мереж отримано ймовірності b_N, b_A, b_O для бінарних класифікаторів і t_N, t_A, t_O для тернарного

класифікатора. Щоб поєднати результати різних нейронних мереж введено зважені ймовірності наступним чином:

$$w_N = b_N \sqrt{t_N}, b_A = b_A \sqrt{t_A}, b_O = b_O \sqrt{t_O}.$$

Остаточний клас обирався на основі найбільшої зваженої ймовірності. Також проведено класифікацію на основі випадкових дерев, методу опорних векторів і логістичної регресії. Для цього використано бібліотеку SKLearn в Python. Всі параметри, окрім min_samples_leaf = 100 для випадкових дерев, обирались класифікаторами автоматично.

Кожний з методів навчався на кортежах з 6, 9 та 21 параметрів. Кортежі параметрів склалися наступним чином:

$$(b_N, b_A, b_O, t_N, t_A, t_O) \\ (b_N, b_A, b_O, t_N, t_A, t_O, w_N, w_A, w_O) \\ (b_N, b_A, b_O, t_N, t_A, t_O, w_N, w_A, w_O, b_N^2, b_A^2, b_O^2, t_N^2, t_A^2, t_O^2, \\ \sqrt{b_N b_A}, \sqrt{b_N b_O}, \sqrt{b_A b_O}, \sqrt{t_N t_A}, \sqrt{t_N t_O}, \sqrt{t_A t_O})$$

Таблиця 4. Значення метрики F_1 для різних моделей підсумкового класифікатора

Назва методу	Кількість параметрів	F_{1n}	F_{1a}	F_{1o}	F_1	F_1 валідація
Maximal w_x	6	0.8975	0.8531	0.7485	0.8330	0.8243
Logistic regression	6	0.9031	0.8676	0.7672	0.8460	0.8194
Logistic regression	9	0.9028	0.8709	0.7674	0.8470	0.8219
Logistic regression	21	0.9042	0.8715	0.7733	0.8497	0.8195
Random forest	6	0.9037	0.8728	0.7674	0.8480	0.8246
Random forest	9	0.9050	0.8686	0.7718	0.8485	0.8225
Random forest	21	0.9050	0.8690	0.7740	0.8493	0.8173
SVM	6	0.9048	0.8735	0.7682	0.8489	0.8205
SVM	9	0.9023	0.8705	0.7619	0.8449	0.8262
SVM	21	0.9022	0.8712	0.7632	0.8455	0.8278

Кращі результати класифікації виділено жирним шрифтом у таблиці. Отже, точнішу класифікацію по окремих класах переважно дає метод випадкових дерев (Random Forest), як і у [6], а кращі загальні результати підсумкового класифікатора дає метод опорних векторів (SVM), хоч і з невеликою перевагою.

Результати

Для оцінки роботи всієї моделі класифікації використано запропоновану в PhysioNet / Computing in Cardiology Challenge-2017 метрику F_1 [2,6]:

Таблиця 3. Матриця крос-валідації

		Прогноз				
Справ- жне зна- чення	Normal	Nn	Na	No	Np	ΣN
	AF	An	Aa	$ Ao$	Ap	ΣA
	Other	On	Oa	Oo	Op	ΣO
	Noisy	Pn	Pa	$ Po$	Pp	ΣP
	Разом	Σn	Σa	Σo	Σp	

$$F_{1n} = \frac{2 Nn}{\Sigma N + \Sigma n} \quad F_{1a} = \frac{2 Aa}{\Sigma A + \Sigma a} \\ F_{1o} = \frac{2 Oo}{\Sigma O + \Sigma o} \quad F_{1p} = \frac{2 Pp}{\Sigma P + \Sigma p} \\ Final Score = F_1 = \frac{F_{1n} + F_{1a} + F_{1o}}{3}$$

Результати обчислень подано у таблиці 4.

В цілому ж точність – порівнювана з кращими відомими моделями [3-5] та навіть переважає по окремих класах.

Отже, в цілому метод може бути адаптований для інтеграції з мобільними кардіографами для подальшого впровадження та використання у сценаріях з аналізом стану ЕКГ у реальному часі.

Висновки

У даній роботі запропоновано новий метод класифікації ЕКГ, який складається з наступних етапів:

- 1) фільтрація даних (рухоме середнє і Баттерворта),
- 2) локалізація R піків,
- 3) «розрізання» ЕКГ і передискретизація,
- 4) класифікація “Noisy” - “NotNoisy”
- 5) класифікація “Normal”, “Atrial Fibrillation”, “Other” за допомогою ансамблю класифікаторів з 1D CNN та підсумкового ансамблевого класифікатора.

Список використаних джерел

1. *Панченко Т.В.* Моніторинг стану здоров'я в реальному часі за допомогою ЕКГ-аналізу / Т.В. Панченко, В.О. Будіченко // Штучний інтелект. – Київ. – 2016. – № 4 (74). – С.98-100.
2. *Clifford G.D.* AF Classification from a Short Single Lead ECG Recording: The PhysioNet – Computing in Cardiology Challenge 2017 / G.D. Clifford, Ch. Liu, B. Moody, L.H. Lehman, I. Silva, Q. Li, A.E. Johnson and R.G. Mark // Computing in Cardiology. – 2017. – P.1-4.
3. *Chen D.* Electrocardiogram Classification and Visual Diagnosis of Atrial Fibrillation with DenseECG (Preprint) / D. Chen, D. Li, X. Xu, R. Yang and S.-K. Ng // ArXiv. – 2021. – 10p.
4. *Yavorskyi A.* Efficient ECG Analysis with High F_1 Score and Low Computation Complexity / A. Yavorskyi, B. Tyshchenko, T. Panchenko // The 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS'2021). – 2021. – P. 348-352.
5. *Panchenko T.* Electrocardiogram Effective Analysis Based on the Random Forest Model with Preselected Parameters / T. Panchenko, A. Yavorskyi, Zh. Hu // Lecture Notes on Data Engineering and Communications Technologies. – 2022. – Vol. 135. – P. 137-145.
6. *Яворський А.Б.* Аналіз та обробка сигналів кардіограми у реальному часі / А.Б. Яворський // Вісник Київського національного університету імені Тараса Шевченка. Серія фізико-математичні науки. – Київ. – 2021. – Вип. 1. – С. 108–113.
7. *Yavorskii A.* ECG Analysis with High Precision and Recall / A. Yavorskii, T. Panchenko, B. Tyshchenko // In Proc.: Problems of Decision Making under Uncertainties (PDMU-2021). – Skhidnytsia, Ukraine. – 2021. – P. 78-79.
8. *Goldberger A.* PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals / A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P.C. Ivanov, R. Mark, J.E. Mietus, G.B. Moody, C.K. Peng, and H.E. Stanley // Circulation [Online]. – 2000. – # 101 (23). – P. e215–e220.
9. *Moody G.B.* A new method for detecting atrial fibrillation using R-R intervals / G.B. Moody, R.G. Mark // Computers in Cardiology. – 1983. – No. 10. – P. 227-230.
10. *Moody G.B.* The impact of the MIT-BIH Arrhythmia Database / G.B. Moody, R.G. Mark // IEEE Engineering in Medicine and Biology Magazine. – 2001. – Vol. 20, No. 3. – P. 45-50.
11. *Butterworth S.* On the Theory of Filter Amplifiers / S. Butterworth // Experimental Wireless and the Wireless Engineer. – 1930. – No. 7. – P. 536–541.
12. *Wu L.* ECG Enhancement and R-Peak Detection Based on Window Variability / L. Wu, X. Xie, Запропонований метод має високі показники точності за метрикою F_1 та ефективності застосування (точність+швидкість).

Також авторами запропонований новий метод локалізації R-піків QRS циклів кардіограм, який показав себе ефективним за метрикою точності.

Запропонована авторами модель може бути основою для наступних досліджень за рахунок нової комбінації ансамблевої структури прийняття рішення про класифікацію, а також покращень та впровадження через інтеграцію у систему «повного циклу» аналізу із застосуванням мобільних зчитувачів ЕКГ з метою попереднього виявлення відхилень у кардіограмі та швидкого попереднього діагностування.

Y. Wang // Healthcare. – Basel. – 2021. – No. 9 (2). – P. 227.

References

1. PANCHENKO, T.V., BUDICHENKO, V.O. (2016): *Real-time Health Monitoring via ECG Analysis*, "Artificial Intelligence", No. 4 (74), pp. 98-100.
2. CLIFFORD, G.D., LIU, Ch., MOODY, B., LEHMAN, L.H., SILVA, I., LI, Q., JOHNSON, A.E., MARK, R.G. (2017): *AF Classification from a Short Single Lead ECG Recording: The PhysioNet – Computing in Cardiology Challenge 2017*, "Computing in Cardiology", pp.1-4, doi: 10.22489/CinC.2017.065-469.
3. CHEN, D., LI, D., XU, X., YANG, R., NG, S.-K. (2021): *Electrocardiogram Classification and Visual Diagnosis of Atrial Fibrillation with DenseECG*, 10 p., <https://arxiv.org/pdf/2101.07535.pdf>
4. YAVORSKYI, A., TYSHCHENKO, B., PANCHENKO, T. (2021): *Efficient ECG Analysis with High F_1 Score and Low Computation Complexity*, "Proc. 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS'2021)", pp. 348-352.
5. PANCHENKO, T., YAVORSKYI, A., HU, ZH. (2022): *Electrocardiogram Effective Analysis Based on the Random Forest Model with Preselected Parameters*, "Lecture Notes on Data Engineering and Communications Technologies", Vol. 135, pp. 137-145.
6. YAVORSKYI, A. (2021): *Real-Time Analysis and Processing of Cardiogram Signals*, "Bulletin of Taras Shevchenko National University of Kyiv, Series Physics & Mathematics", No. 1, pp. 108–113.
7. YAVORSKYI, A., PANCHENKO, T., TYSHCHENKO, B. (2021): *ECG Analysis with High Precision and Recall*, "Proc. Problems of Decision Making under Uncertainties (PDMU-2021)", pp. 78-79.
8. GOLDBERGER, A., AMARAL, L., GLASS, L., HAUSDORFF, J., IVANOV, P.C., MARK, R., MIETUS, J.E., MOODY, G.B., PENG, C.K., STANLEY, H.E. (2000): *PhysioBank, Physio-Toolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals*, # 101 (23), pp. e215–e220, <https://physionet.org/content/challenge-2017>
9. MOODY, G.B., MARK, R.G. (1983): *A new method for detecting atrial fibrillation using R-R intervals*, "Computers in Cardiology", No. 10, pp. 227-230.
10. MOODY, G.B., MARK, R.G. (2001): *The impact of the MIT-BIH Arrhythmia Database*, "IEEE Engineering in Medicine and Biology Magazine", Vol. 20, No. 3, pp. 45-50.
11. BUTTERWORTH, S. (1930). *On the Theory of Filter Amplifiers*, "Experimental Wireless and the Wireless Engineer", No. 7, pp. 536–541.
12. WU, L., XIE, X., WANG, Y. (2021): *ECG Enhancement and R-Peak Detection Based on Window Variability*, "Healthcare" (Basel), 9 (2), P. 227; doi: 10.3390/healthcare9020227.

Надійшла до редколегії 14.02.2022