

DOI: [https://doi.org/10.25140/2411-5363-2025-3\(41\)-203-210](https://doi.org/10.25140/2411-5363-2025-3(41)-203-210)

УДК 004.042

**Дмитро Андрійович Милосердов<sup>1</sup>, Олег Костянтинівич Колесницький<sup>2</sup>**<sup>1</sup>аспірант кафедри комп'ютерних наук

Вінницький національний технічний університет (Вінниця, Україна)

E-mail: [dagger.dager@gmail.com](mailto:dagger.dager@gmail.com). ORCID: <https://orcid.org/0009-0001-5216-3552>. ResearcherID: [OHT-7832-2025](https://orcid.org/0009-0001-5216-3552)<sup>2</sup>кандидат технічних наук, професор кафедри комп'ютерних наук

Вінницький національний технічний університет (Вінниця, Україна)

E-mail: [kolesnytskiy@vntu.edu.ua](mailto:kolesnytskiy@vntu.edu.ua). ORCID: <https://orcid.org/0000-0003-0336-4910>. ResearcherID: [H-7551-2018](https://orcid.org/0000-0003-0336-4910)

## МЕТОД ПОПЕРЕДНЬОЇ ОБРОБКИ СИГНАЛУ ЕКГ ДЛЯ КЛАСИФІКАЦІЇ ЕЛЕКТРОКАРДІОГРАМ ЗА ДОПОМОГОЮ СПАЙКІНГОВИХ НЕЙРОННИХ МЕРЕЖ

На основі математичних підходів з обробки послідовностей у роботі було представлено новий метод попередньої обробки сигналу ЕКГ для його подальшого використання у задачі класифікації. Описано послідовність виконання таких операцій, як ресемпльовання та ретаймінг сигналу, його нормалізація та додаткові операції, що потрібні для повної обробки. Метод було протестовано та наведено позитивні результати моделювання у вигляді сигналу, що характеризує удар серця зі збереженими Р, Т хвилями та QRS-комплексом, але з нормалізованою амплітудою до [0,1] та стандартною тривалістю сигналу протягом одного запису.

**Ключові слова:** мінімаксна нормалізація; ресемпльовання; ЕКГ; інтерполяція; спайкінгові нейронні мережі.

Рис.: 2. Табл.: 4. Бібл.: 5.

**Актуальність теми дослідження.** У контексті стрімкого розвитку біомедичних технологій, де інтеграція штучного інтелекту з аналізом фізіологічних сигналів стає ключовим фактором для ранньої діагностики серцево-судинних патологій, які, за даними Всесвітньої організації охорони здоров'я, залишаються провідною причиною смертності у світі, постає нагальна необхідність удосконалення методів препроцесингу даних, таких як сигнали електрокардіограм. Ці методи потрібні для забезпечення їхньої сумісності з передовими нейромережевими архітектурами, зокрема спайкінговими нейронними мережами [1]. Вони імітують біологічні процеси передачі інформації через спайки, тим самим підвищуючи ефективність обчислень у реальному часі та зменшуючи енергоспоживання систем, призначених для портативних медичних пристроїв. Ця актуальність посилюється тим, що традиційні методи обробки ЕКГ-сигналів, часто обмежені варіативністю часових інтервалів між серцевими ударами та амплітудними коливаннями, не повною мірою враховують специфіку спайкінгових нейронних мереж (spiking neural network, SNN) [2], які вимагають стандартизованих вхідних потоків для оптимального навчання [3]. Це може призводити до зниження точності класифікації аритмій та уповільнення процесів автоматизованої діагностики, особливо в умовах використання загальнодоступних баз даних на кшталт MIT-BIH [4], де записи характеризуються різною тривалістю та шумовими артефактами, накопиченими під час амбулаторного моніторингу. Таким чином, розробка інноваційних підходів до трансформації цих сигналів не лише відповідає сучасним тенденціям у біомедичній інформатиці, але і сприяє переходу від реактивної до превентивної медицини, де алгоритми штучного інтелекту, натхненні нейрофізіологією, дозволяють прогнозувати потенційні ризики на основі аналізу реального часу. Вони тим самим інтегруються у ширший спектр задач, пов'язаних із персоналізованою охороною здоров'я та телемедициною, де точність та швидкість обробки даних визначають ефективність втручань.

**Постановка проблеми.** Для спайкінгових нейронних мереж [5], що базуються на нейроморфних принципах та специфічних методах навчання для задач класифікації потрібен стандартизований масив даних на вхід нейронної мережі у вигляді інваріантних до масштабу часу та амплітуди послідовностей імпульсів (просторово-часових паттернів) [3] для найкращого результату навчання. Тому потрібно розробити оновлений метод попередньої обробки сигналу ЕКГ та перетворення його на просторово-часові патерни імпульсів, які будуть інваріантними до масштабу часу та амплітуди сигналу ЕКГ.

**Виділення недосліджених частин загальної проблеми.** При проектуванні систем для розпізнавання серцевої недостатності у роботах [6-8] було запропоновано різні методи модуляції трансформування та кодування вхідного сигналу до нейронних мереж. Але для використання у спайкінгових нейронних мережах [9], що базуються на резервуарі, ці методи не використовувалися через їх нестандартизований вигляд, що робить навчання спайкінгових нейронних мереж важчим та знижує фінальні показники точності.

**Метою статті** є розробка та детальний опис методу трансформації сигналів ЕКГ з бази даних МІТ-ВІН у стандартизовані масиви даних з нормалізованими значеннями в діапазоні [0,1] без втрати корисного навантаження сигналу.

**Виклад основного матеріалу.** У межах розробленого методу здійснено ресемплінг до частоти дискретизації 500 Гц мінімаксу нормалізацію та стискання або розтягування до визначеної середньої довжини сигналу даних електрокардіограми (ЕКГ) з бази даних МІТ-ВІН, де варіабельність сигналів ЕКГ зумовлена як індивідуальними фізіологічними особливостями суб'єктів спостереження, так і артефактами апаратного реєстрування, що ускладнює подальшу стандартизацію для навчання спайкінгових нейронних мереж. Початковим етапом первинної обробки даних постає систематичний прохід по анотаційному файлу (.atr), який, як бінарний репозиторій маркованих подій серцевої активності, забезпечує точну ідентифікацію R-піків QRS-комплексів без потреби в повторній детекції на сирих сигналах, тим самим мінімізуючи обчислювальні витрати та підвищуючи надійність ритмічних оцінок для уніфікації циклів. Дані в МІТ-ВІН мають дискретизацію 360 Гц та включають у себе стандартизований формат .atr, що включає заголовок (212 байтів з метаданими, такими як базова частота та типи анотацій) та послідовність записів (по 6 байтів на подію: 2 байти для часової мітки в семплах, 2 для коду анотації та 2 для підтипу), дозволяючи ефективно ітерувати події за допомогою бібліотек на кшталт WFDB у Python-середовищі, де, з одного боку, парсинг заголовка ініціалізує контекст (`base_time = 0`, `sample_rate = 360`), а з іншого – фільтрація анотацій витягує удари, розподілені на 5 множин, відповідно до класифікації ААМІ (Association for the Advancement of Medical Instrumentation) [6], що показано в таблиці 1.

Таблиця 1 – Класифікація ААМІ для R-R інтервалів з .atr файлів МІТ-ВІН

AAMI Classes	Symbol	MIT-BIH Classes
Normal	N	N, L, R
Supraventricular Ectopic Beat	SVEB	e, j, A, a, J, S
Ventricular Ectopic Beat	VEB	V, E
Fusion	F	F
Unknown Beat	Q	/, f, Q

Джерело: розроблено авторами.

Отримані часові мітки R-піків слугують основою для обчислення послідовних R-R дистанцій  $d_i = t_i + t_{i-1}$ , з подальшим усередненням.

$$\bar{d} = \frac{1}{N} \sum_{i=0}^{N-1} d_i$$

Для наочності наведено таблицю 2 з прикладами усереднених значень інтервалів R-R для вибраних записів.

Таблиця 2 – Приклади усереднених інтервалів R-R для вибраних записів бази МІТ-ВІН

Ідентифікатор запису	Кількість ударів (N)	Середній R-R інтервал $d^-$ (с)
100	2273	0,79
101	1873	0,96
103	2090	0,86
200	2790	0,64
208	3004	0,59

Джерело: розроблено авторами.

Наступним етапом, який логічно впливає з попереднього і слугує для підготовки до нормалізації амплітуд, є визначення мінімального та максимального значень сигналу для всього запису, що здійснюється шляхом сканування масиву даних, отриманого з файлів .dat бази МІТ-ВІН, де сигнал представлений як одновимірний масив напруг у мілівольтах. Обчислення  $min_s = \min(s)$  та  $max_s = \max(s)$ , де  $s$  – вектор сигналу, дозволяють встановити глобальні межі для подальшої мінімаксної нормалізації, яка застосована на рівні окремих сегментів, забезпечує перехід значень до інтервалу  $[0,1]$ , усуваючи вплив абсолютних амплітудних варіацій, зумовлених відмінностями в апаратурі запису чи фізіологічними особливостями пацієнтів. На це можуть впливати товщина шкіри чи положення електродів, і цей крок, хоча й здається простим, є суттєвим для спайкінгових нейронних мереж, оскільки в них вхідні імпульси часто кодуються через rate coding або temporal coding, де нормалізовані значення полегшують генерацію спайків із використанням моделі нейронів на кшталт leaky integrate-and-fire [10], зменшуючи шум і підвищуючи роздільну здатність моделі до дрібних морфологічних змін. Мінімальні та максимальні межі амплітуд наведено в таблиці 3, що показує варіабельність амплітудних відхилень поміж пацієнтами. Загальні межі амплітуд серед усіх записів МІТ-ВІН становить  $[-5.12, 5.115]$ .

Таблиця 3 – Межі амплітуд по записах

Рекорд	min	max	Рекорд	min	max	Рекорд	min	max
100	-2,715	1,435	113	-1,225	2,550	201	-1,315	2,045
101	-3,175	2,420	114	-2,390	1,815	202	-2,755	2,920
102	-1,660	1,375	115	-2,885	2,410	203	-4,305	3,640
103	-2,610	3,125	116	-5,120	5,115	205	-2,175	1,455
104	-1,935	1,975	117	-3,015	0,710	207	-3,955	2,285
105	-3,715	3,000	118	-3,090	2,395	208	-3,485	3,650
106	-2,065	2,570	119	-2,985	2,500	209	-1,455	1,885
107	-3,315	3,465	121	-4,450	1,400	210	-1,620	3,320
108	-3,035	2,365	122	-2,200	1,250	212	-1,855	2,545
109	-3,195	3,130	123	-3,095	2,060	213	-2,530	3,285
111	-2,820	2,375	124	-3,605	2,595	214	-2,730	2,800
112	-2,635	0,820	200	-2,695	2,380	215	-1,380	2,500

Джерело: розроблено авторами.

Далі для кожного сегменту сигналу, що відповідає інтервалу від попереднього R-піку до поточного, витягується підмасив даних, починаючи з позиції  $t_{i-1}$  до  $t_i$ , де індекси перераховуються в зразках з урахуванням оригінальної частоти, і цей сегмент, чия довжина може варіюватися від приблизно 200 до 600 зразків залежно від частоти серцебиття (наприклад, при нормальному синусовому ритмі близько 60...100 ударів на хвилину інтервал становить 0,6-1 секунду), піддається трансформації шляхом розширення або зву-

ження до середньої дистанції RR, реалізованого через лінійну інтерполяцію, яка математично описується як створення нової часової сітки з фіксованою кількістю точок, пропорційною  $RR \cdot 360$ , але з подальшим ресемплингом, де оригінальний часовий вектор  $t_{orig} = j/360$  з  $j$ -індексами зразків інтерполюється на новий вектор  $t_{new}$  з кроком, що забезпечує фіксовану тривалість, дозволяючи уникнути артефактів, таких як феномен Гібса, які могли б виникнути при фур'є-інтерполяції, і ця операція не лише стандартизує часові шкали для всіх сегментів у записі, роблячи їх порівнянними, але й полегшує інтеграцію зі спайкінговими мережами, де фіксована довжина вхідного вектора є передумовою для ефективного пакетного навчання, зменшуючи обчислювальну складність і підвищуючи швидкість інференсу в реальному часі, як це продемонстровано в симуляціях на записах типу 100 з MIT-BIH, де варіабельність RR-інтервалів сягає 10...15 %, а після трансформації дисперсія наближається до нуля, зберігаючи при цьому форму QRS-комплексу з точністю, виміряною через коефіцієнт кореляції Пірсона [11], що перевищує 0,98.

Окрім того, в процесі інтерполяції здійснюється перехід від оригінальної частоти дискретизації 360 Гц до 500 Гц, що обґрунтовується необхідністю спрощення калькуляції дельта-тайм у спайкінгових мережах, де часовий крок  $t$  часто встановлюється як 0,002 секунди (відповідно 500 Гц), дозволяючи точніше моделювати динаміку мембранного потенціалу в рівняннях типу

$$\tau \frac{dV}{dt} = -V + I(t),$$

де  $\tau$  – часова константа, а  $I(t)$  – вхідний струм, пропорційний нормалізованому сигналу ЕКГ, і цей ресемплинг реалізується через створення нової сітки  $t_{new}$  з подальшою інтерполяцією лінійним методом, який, на відміну від кубічного, мінімізує осциляції на піках, забезпечує монотонність і збереження монотонності функції, критично важливої для детекції патологій, таких як елевація ST-сегмента, і в контексті MIT-BIH, де записи часто містять шум від руху чи електромагнітних перешкод, що зображено на рисунку 1. Цей крок додатково сприяє фільтрації низькочастотних компонент.




Рис. 1. Результат ресемплингу та адаптації сигналу під часовий проміжок  
Джерело: розроблено авторами.

Після ресемплингу застосовується мінімаксна нормалізація для кожного трансформованого сегмента, де значення сигналу перетворюються за формулою

$$X_{norm} = \frac{X - \min(X)}{\max(X) - \min(X)}$$

з використанням глобальних  $\min(X)$  та  $\max(X)$  з усього запису, що забезпечує узгодженість нормалізації через весь датасет, уникаючи локальних спотворень, які могли б виникнути при сегментній нормалізації, і цей підхід, хоча й простий, є ефективним для спайкінгових мереж, оскільки приводить вхід до діапазону  $[0,1]$ , оптимального для порогових функцій нейронів, де поріг спайку часто встановлюється близько 1, і в результаті, як демонструє аналіз на записах МІТ-ВІН, нормалізовані сегменти показують підвищену чутливість до аномалій, з F1-score у класифікації, що зростає з 0,85 до 0,93 при використанні SNN наступної архітектури.

Нейронна мережа має 1 вхідний нейрон, що кодує оброблений сигнал у масив спайків; далі резервуар, побудований за принципом liquid state machine (LSM) 100 нейронів; вихідний шар містить 5 нейронів, згідно з класифікацією ААМІ. Пов'язані шари нейронної мережі таким чином: вхідний нейрон пов'язаний із 20 % резервуара нейронів зі збуджувальними вагами, резервуар має рекурентні зв'язки – кожен нейрон пов'язаний з випадковими 20 % нейронів резервуара, з яких 80 % синапсів має збуджувальну вагу, а інші 20 % – гальмівну; кожен нейрон так само пов'язаний з випадковими 20 % нейронів резервуара та ваги розподіляються 80%/20% збуджувальні/гальмівні.

Розподіл бази МІТ-ВІН на навчальну та тестову вибірки було виконано за наступним алгоритмом. Для кожної анотації  $R_i$  обмежувався сигнал від  $R_{i-1}$  до  $R_{i+1}$  та розподілявся до відповідного класу за ААМІ. Для сформованих множин сигналів до кожного класу випадково було обрано 80 % сигналів до навчальної вибірки та решту 20 % до тестової. Загальний обсяг вибірки 100 708 сигналів. Розподіл на навчальну та тестову: 80566/20142. Розподіл по ААМІ класам для навчальної вибірки: Normal - 71885, Supraventricular Ectopic Beat – 2421, Ventricular Ectopic Beat – 5606, Fusion – 642, Unknown Beat – 12. Розподіл по ААМІ класам для тестової вибірки: Normal – 17972, Supraventricular Ectopic Beat – 605, Ventricular Ectopic Beat – 1402, Fusion – 160, Unknown Beat – 3.

Щоб ілюструвати практичну реалізацію, наведено табл. 4 змінених характеристик сигналу ЕКГ для запису 100 з МІТ-ВІН, для порівняння наведено результати з використанням альтернативного підходу із застосуванням Z-нормалізації [12].

Таблиця 4 – Порівняльні характеристики сегментів ЕКГ до та після трансформації для запису 100 МІТ-ВІН

Характеристика	Оригінальний сегмент	Трансформований сегмент	Z-нормалізація
Довжина (зразки)	216-470	286	216-470
Частота (Гц)	360	500	360
Амплітуда (мВ)	[-2.715, 1.435]	[0, 1]	[-1.564, 7.519]
Дисперсія RR (мс)	37-114	0	37-114
Коефіцієнт кореляції	-	0.98	інваріантний

Джерело: розроблено авторами.

Таблиця 4 підкреслює переваги методу, де фіксована довжина полегшує пакетну обробку, а нормалізація усуває масштабні ефекти, і у ширшому контексті, порівнюючи з Z-нормалізацією, яка зберігає статистичні властивості, але не обмежує діапазон.

Запропонований метод виявляється кращим для спайкінгових нейронних мереж, оскільки  $[0,1]$  ідеально сумісний з пороговими моделями, як показано в симуляціях. Також наведено рис. 2 як фінальний результат трансформації вхідного сигналу.




Рис. 2. Типовий трансформований сегмент, де видно збереження морфології з чіткими P, QRS та T-хвилями

Джерело: розроблено авторами.

Враховуючи комплексність взаємодій між часовими та амплітудними аспектами сигналу, запропонований метод з його акцентом на індивідуальну стандартизацію та інтерполяцію, не лише розв'язує проблему варіабельності в МІТ-ВІН для використання у спайкінгових нейронних мережах при мультимодальному аналізі, включаючи ЕКГ з іншими біомаркерами, і подальші дослідження можуть фокусуватися на адаптації до багатоканальних записів, де кореляція між відведеннями, такими як МЛІІ та V1, потребує багатовимірної інтерполяції. Цей підхід, інтегрований у пайплайн обробки, являє собою інноваційний внесок у біомедичну інформатику, де точність та ефективність є ключовими для переходу від лабораторних моделей до реальних медичних систем.

**Висновки.** У статті було запропоновано новий метод попередньої обробки сигналу ЕКГ для подальшого його використання у спайкінгових нейронних мережах, що налаштовані на виконання задачі класифікації електрокардіограм. Було проведено експериментальні дослідження окремих компонентів алгоритму методу та представлено проміжкові результати. Також було протестовано запропонований метод обробки сигналу ЕКГ та за результатами тестування було виявлено, що сигнал не втратив корисне навантаження характеристик удару серця: P-, T-хвиль та QRS-комплексу.

### **Заява про використання генеративного ШІ та технологій на основі ШІ в процесі написання тексту статті.**

Під час написання цього матеріалу автори використовували DeepL Translator - для перекладу окремих фрагментів тексту з англійської мови.

**Список використаних джерел**

1. Kolesnytskyj, O. K., Bokotsey, I. V., & Yaremchuk, S. S. (2010). Optoelectronic implementation of pulsed neurons and neural networks using bispin-devices. *Optical Memory and Neural Networks*, 19(2), 154–165. <https://doi.org/10.3103/s1060992x10020062>.
2. Kolesnytskyj, O. K., Kutsman, V. V., Skorupski, K., & Arshidinova, M. (2019, November 6). Neurocomputer architecture based on spiking neural network and its optoelectronic implementation. In *Proceedings of SPIE 11176, Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2019* (Paper 1117609). <https://doi.org/10.1117/12.2536607>.
3. Kutsman, V., & Kolesnytskyj, O. (2021). Dynamic handwritten signature identification using spiking neural network. *Informatyka, Automatyka, Pomiar w Gospodarce i Ochronie Środowiska*, 11(3), 34–39. <https://doi.org/10.35784/iapgos.2718>.
4. MIT-BIH Arrhythmia Database. (n.d.). *PhysioNet*. Retrieved August 17, 2025, from <https://www.physionet.org/content/mitdb/1.0.0/>
5. Kozemiako, V. P., Kolesnytskyj, O. K., Lischenko, T. S., Wojcik, W., & Sulemenov, A. (2013, January 11). Optoelectronic spiking neural network. In *Proceedings of SPIE 8698, Optical Fibers and Their Applications 2012* (Paper 86980M). <https://doi.org/10.1117/12.2019340>.
6. Choi, H., Park, J., Lee, J., & Sim, D. (2024). Review on spiking neural network-based ECG classification methods for low-power environments. *Biomedical Engineering Letters*. <https://doi.org/10.1007/s13534-024-00391-2>.
7. Yan, Z., Zhou, J., & Wong, W.-F. (2021). Energy efficient ECG classification with spiking neural network. *Biomedical Signal Processing and Control*, 63, 102170. <https://doi.org/10.1016/j.bspc.2020.102170>.
8. Amirshahi, A., & Hashemi, M. (2019). ECG classification algorithm based on STDP and R-STDP neural networks for real-time monitoring on ultra low-power personal wearable devices. *IEEE Transactions on Biomedical Circuits and Systems*, 13(6), 1483–1493. <https://doi.org/10.1109/tbcas.2019.2948920>.
9. Maass, W. (1997). Networks of spiking neurons: The third generation of neural network models. *Neural Networks*, 10(9), 1659–1671. [https://doi.org/10.1016/S0893-6080\(97\)00011-7](https://doi.org/10.1016/S0893-6080(97)00011-7).
10. Gerstner, W., & Kistler, W. M. (2002). *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge, UK: Cambridge University Press. <https://doi.org/10.1017/CBO9780511815706>.
11. Kent State University Libraries. (n.d.). *Pearson correlation coefficient*. Retrieved August 29, 2025, from <https://libguides.library.kent.edu/SPSS/PearsonCorr>.
12. Mulders, M. (Ed.). (2017). *2015 European School of High-Energy Physics: Bansko, Bulgaria, 02–15 September 2015*. Geneva: CERN. <https://doi.org/10.23730/CYRSP-2017-001>.

**References**

1. Kolesnytskyj, O. K., Bokotsey, I. V., & Yaremchuk, S. S. (2010). Optoelectronic implementation of pulsed neurons and neural networks using bispin-devices. *Optical Memory and Neural Networks*, 19(2), 154–165. <https://doi.org/10.3103/s1060992x10020062>.
2. Kolesnytskyj, O. K., Kutsman, V. V., Skorupski, K., & Arshidinova, M. (2019, November 6). Neurocomputer architecture based on spiking neural network and its optoelectronic implementation. In *Proceedings of SPIE 11176, Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2019* (Paper 1117609). <https://doi.org/10.1117/12.2536607>.
3. Kutsman, V., & Kolesnytskyj, O. (2021). Dynamic handwritten signature identification using spiking neural network. *Informatyka, Automatyka, Pomiar w Gospodarce i Ochronie Środowiska*, 11(3), 34–39. <https://doi.org/10.35784/iapgos.2718>.
4. MIT-BIH Arrhythmia Database. (n.d.). *PhysioNet*. Retrieved August 17, 2025, from <https://www.physionet.org/content/mitdb/1.0.0/>
5. Kozemiako, V. P., Kolesnytskyj, O. K., Lischenko, T. S., Wojcik, W., & Sulemenov, A. (2013, January 11). Optoelectronic spiking neural network. In *Proceedings of SPIE 8698, Optical Fibers and Their Applications 2012* (Paper 86980M). <https://doi.org/10.1117/12.2019340>.
6. Choi, H., Park, J., Lee, J., & Sim, D. (2024). Review on spiking neural network-based ECG classification methods for low-power environments. *Biomedical Engineering Letters*. <https://doi.org/10.1007/s13534-024-00391-2>.
7. Yan, Z., Zhou, J., & Wong, W.-F. (2021). Energy efficient ECG classification with spiking neural network. *Biomedical Signal Processing and Control*, 63, 102170. <https://doi.org/10.1016/j.bspc.2020.102170>.

8. Amirshahi, A., & Hashemi, M. (2019). ECG classification algorithm based on STDP and R-STDP neural networks for real-time monitoring on ultra low-power personal wearable devices. *IEEE Transactions on Biomedical Circuits and Systems*, 13(6), 1483–1493. <https://doi.org/10.1109/tbcas.2019.2948920>.
9. Maass, W. (1997). Networks of spiking neurons: The third generation of neural network models. *Neural Networks*, 10(9), 1659–1671. [https://doi.org/10.1016/S0893-6080\(97\)00011-7](https://doi.org/10.1016/S0893-6080(97)00011-7).
10. Gerstner, W., & Kistler, W. M. (2002). *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge, UK: Cambridge University Press. <https://doi.org/10.1017/CBO9780511815706>.
11. Kent State University Libraries. (n.d.). *Pearson correlation coefficient*. Retrieved August 29, 2025, from <https://libguides.library.kent.edu/SPSS/PearsonCorr>.
12. Mulders, M. (Ed.). (2017). *2015 European School of High-Energy Physics: Bansko, Bulgaria, 02–15 September 2015*. Geneva: CERN. <https://doi.org/10.23730/CYRSP-2017-001>.

Отримано 19.09.2025

UDC 004.042

**Myloserdov Dmytro Andriyovych<sup>1</sup>, Kolesnytskyi Oleg Kostyantynovych<sup>2</sup>**<sup>1</sup>postgraduate of the Department of Computer Science

Vinnytsia National Technical University (Vinnytsia, Ukraine)

**E-mail:** [dagger.dager@gmail.com](mailto:dagger.dager@gmail.com). **ORCID:** <https://orcid.org/0009-0001-5216-3552>. **ResearcherID:** [OHT-7832-2025](https://orcid.org/0009-0001-5216-3552)<sup>2</sup>PhD in Technical Science, professor of the Department of Computer Science

Vinnytsia National Technical University (Vinnytsia, Ukraine)

**E-mail:** [kolesnytskyi@vntu.edu.ua](mailto:kolesnytskyi@vntu.edu.ua). **ORCID:** <https://orcid.org/0000-0003-0336-4910>. **ResearcherID:** [H-7551-2018](https://orcid.org/0000-0003-0336-4910)**ECG SIGNAL PRE-PROCESSING METHOD FOR ELECTROCARDIOGRAM CLASSIFICATION USING SPIKING NEURAL NETWORKS**

The medical analysis of ECG is based on visual examination by cardiologists, which is a subjective and labor-intensive process and includes the factor of human error. With the advent of analysis based on artificial intelligence systems or algorithmic data processing, systems for classifying cardiogram data have emerged. A properly pre-processed signal is a very important component in the use of neural networks for such tasks.

The analysis of studies and publications has shown that these methods have not been used for spiking neural networks based on reservoirs due to their non-standardized form, which makes training spiking neural networks more difficult and reduces the final accuracy metrics.

The purpose of the article is to develop and provide a detailed description of a method for transforming ECG signals from the MIT-BIH database into standardized data arrays with values in  $[0, 1]$  without losing the useful signal payload, as well as to present intermediate results from studies of individual components of the proposed method.

Based on mathematical approaches to sequence processing, the work presents a new method for preliminary ECG signal processing for its further use in classification tasks. The sequence of performing such operations as signal resampling and retiming, its normalization, and additional operations necessary for complete processing is described. The method has been tested, and positive modeling results are presented in the form of a signal that characterizes a heartbeat with preserved P and T waves and QRS complex, but with amplitude adjusted to  $[0, 1]$  and a standard signal length throughout one record.

The proposed signal processing approach, with its comprehensive processing that consists of combining known processing methods into the following sequence (resampling, interpolation, min-max normalization) and integrating it into the processing pipeline of a spiking neural network, represents an innovative contribution to biomedical informatics, where accuracy and efficiency are key to transitioning from laboratory models to real medical systems.

**Keywords:** minimax normalization, resampling, ECG, interpolation, signal processing, changing the signal sampling frequency, spiking neural networks.

Fig.: 2. Tables: 4. References: 5.