

Д. А. Милосердов¹
О. К. Колесницький¹

МЕТОД КЛАСИФІКАЦІЇ ЕЛЕКТРОКАРДИОГРАМ ІЗ ЗАСТОСУВАННЯМ СПАЙКІНГОВИХ НЕЙРОННИХ МЕРЕЖ

¹Вінницький національний технічний університет

Розроблено метод класифікації ЕКГ з використанням SNN для розпізнавання серцевої недостатності. Розглянуто актуальність проблеми, переваги SNN над традиційними мережами, аналіз основ SNN, особливостей ЕКГ та архітектури моделі. Метою дослідження є створення теоретичної бази для енергоефективної моделі. Структура статті охоплює теоретичні основи, особливості класифікації, запропоновану архітектуру, аналіз переваг та висновки.

У розділі теоретичних основ спайкінгових нейронних мереж описуються біологічні моделі нейронів, такі як Leaky integrate-and-fire математичне моделювання динаміки спайків через диференціальні рівняння, типи мережі liquid state machine. Модель Leaky integrate-and-fire балансує біологічну правдоподібність з обчислювальною ефективністю, дозволяючи обробку темпоральних патернів ЕКГ з низьким енергоспоживанням.

Особливості класифікації ЕКГ за допомогою спайкінгових нейронних мереж включають аналіз структури сигналу, проблеми шуму, варіабельності та реального часу обробки. Спайкінгові нейронні мережі можуть використовувати різні підходи навчання: STDP, градієнтні методи та апроксимацію. Це забезпечує стійкість до артефактів та високу точність, як показано в розглянутих роботах.

Запропонована архітектура моделі складається з трьох шарів: вхідного (кодування ЕКГ у спайки за допомогою Leaky integrate-and-fire), резервуарного (1000 нейронів з рекурентними зв'язками та балансом збуджувальних/гальмівних синапсів) та вихідного (декодування для 5 класів через підрахунок спайків). Теоретичний аналіз стійкості базується на динамічних системах, забезпечуючи ефективність для носимих пристроїв.

Аналіз переваг підкреслює енергоефективність та біомімікрію спайкінгових нейронних мереж порівняно з іншими, виклики обчислювальної складності та перспективи в клінічній практиці, зокрема, в телемедицині та персоналізованій діагностиці.

Ключові слова: спайкінгові нейронні мережі, нейронні мережі, часові ряди, ЕКГ, Leaky integrate-and-fire neuron, класифікація часових рядів.

Вступ

Проблема класифікації ЕКГ-сигналів є актуальною через зростання кількості пацієнтів з серцевими захворюваннями та необхідність у портативних пристроях для моніторингу в реальному часі. Традиційні методи аналізу ЕКГ, такі як візуальна інтерпретація лікарями, є суб'єктивними та трудомісткими, що призводить до помилок у 20...30 % випадків, особливо у разі виявлення рідкісних аритмій. Автоматизовані системи на основі штучного інтелекту дозволяють підвищити точність до 95 % і більше, зменшуючи навантаження на медичний персонал.

У контексті низькоенергетичних пристроїв, таких як носимі гаджети (наприклад, смарт-годинники), класифікація ЕКГ повинна бути енергоефективною та здатною до обробки даних у реальному часі. Дослідження показують, що традиційні нейронні мережі, як конволюційні (CNN) чи рекурентні (RNN), споживають значну обчислювальну потужність, через що вони не придатні для вбудованих систем з обмеженими ресурсами [1], [2]. Спайкінгові нейронні мережі (SNN) [3], що виникли як результат вивчення біологічних процесів мозку, пропонують альтернативу, забезпечуючи низьке енергоспоживання завдяки асинхронній обробці спайків [4].

Наприклад, у роботі [5] D. Mohammad демонструє використання SNN для виявлення аномалій у серцевому ритмі, підкреслюючи їхню ефективність в обробці часових послідовностей. Аналогічно, автори [6] пропонують фреймворк на основі нейронів типу Leaky integrate-and-fire (LIF) [7] для

класифікації ЕКГ, досягаючи високої точності за низького енергоспоживання. У огляді [1] Н. Choi та ін. аналізують методи класифікації ЕКГ на базі SNN для низькоенергетичних середовищ, зазначаючи переваги в портативних пристроях. Ці дослідження підкреслюють необхідність подальшого розвитку SNN для інтеграції у клінічну практику, особливо в умовах обмежених ресурсів, як у країнах, що розвиваються, зокрема, Україну, де доступ до високотехнологічного обладнання обмежений.

До того ж пандемія COVID-19 посилила потребу в дистанційному моніторингу серцевої активності, оскільки вірус часто викликає кардіальні ускладнення. Автоматизована класифікація ЕКГ може інтегруватися в телемедицину, дозволяючи лікарям оперативно реагувати на відхилення. Таким чином, актуальність проблеми полягає не лише в медичному, але й у соціально-економічному аспекті, сприяючи зменшенню витрат на охорону здоров'я [8].

Спайкінгові нейронні мережі (SNN) [9] імітують біологічні нейрони, обробляючи інформацію через дискретні спайки, на відміну від традиційних штучних нейронних мереж (ANN), які використовують безперервні активації. Ця особливість забезпечує вищу енергоефективність, оскільки обчислення відбуваються лише під час генерації спайку, зменшуючи енергоспоживання на 1—2 порядки порівняно з CNN чи RNN [2], [10].

У контексті класифікації ЕКГ SNN краще справляються з темпоральними даними завдяки природній обробці часових послідовностей [11]. Наприклад, у [2] Z. Yan та ін. демонструють енергоефективну класифікацію ЕКГ за допомогою SNN, досягаючи точності 98 % за низького споживання енергії. На відміну від ANN, які вимагають великих наборів даних для навчання, SNN можуть використовувати такі біологічно подібні механізми: пластичність, яка залежна від часу спайків (STDP), для адаптації з меншою кількістю зразків [12].

Ще одна перевага — стійкість до шуму. ЕКГ-сигнали часто містять артефакти від руху чи електромагнітних перешкод, і SNN, завдяки спайковому кодуванню, фільтрують шум ефективніше, ніж традиційні мережі [13], [14]. У [10] Z. Yan та ін. пропонують гібридну архітектуру SpagrowSNN для класифікації ЕКГ, яка оптимізує апаратне забезпечення для низькоенергетичних пристроїв. Загалом, SNN пропонують біомімікрію, що робить їх перспективними для біомедичних застосувань, де важлива інтеграція з людським організмом.

Метою дослідження є теоретична розробка спайкінгової нейронної мережі для класифікації електрокардіограм, з акцентом на енергоефективність та обробку в реальному часі. Для досягнення мети поставлено такі завдання:

- проаналізувати біологічні та математичні основи SNN, зокрема моделі нейронів та кодування інформації;
- розглянути особливості ЕКГ-сигналів та їхню класифікацію за допомогою SNN;
- запропонувати архітектуру моделі на базі рідинного стану машини (liquid state machine, LSM);
- визначити перспективи застосування в клінічній практиці та напрями подальших досліджень.

Ці завдання спрямовані на створення теоретичної бази для майбутніх імплементацій, сприяючи розвитку нейроморфних технологій у медицині [8], [15].

Результати дослідження

Теоретичні основи спайкінгових нейронних мереж

Спайкінгові нейронні мережі є третім поколінням нейронних мереж, яке імітує біологічні процеси передачі інформації в мозку через дискретні імпульси, або спайки. На відміну від традиційних штучних нейронних мереж, де інформація кодується в безперервних значеннях активації, SNN фокусуються на темпоральній динаміці, через що вони ефективні для обробки часових послідовностей, таких як біомедичні сигнали. Теоретичні основи SNN базуються на біологічних моделях нейронів, математичному описі їхньої динаміки та способах організації мереж. Розглянуто ключові аспекти, необхідні для розуміння застосування SNN у класифікації електрокардіограм.

Біологічні нейрони є основою для моделювання SNN. У живому мозку нейрон накопичує вхідні сигнали через синапси, і коли мембранний потенціал досягає порогу, генерується акційний потенціал дії — спайк, який поширюється аксоном. Для спрощення біологічних процесів використовується модель LIF, яка ігнорує деталі іонних каналів, фокусуючись на інтеграції вхідного струму з витоком:

$$\tau \frac{dV}{dt} = -V + RI_{exc},$$

де τ — часова константа, R — опір мембрани, C — ємність, V — мембранний потенціал, I_{exc} — зовнішній струм. Коли V досягає порогу V_{th} — генерується спайк, і потенціал скидається до V_{rest} . LIF є основою для багатьох SNN у біомедичних застосуваннях, оскільки балансує біологічну правдоподібність з обчислювальною ефективністю [1], [2]. У контексті ЕКГ-класифікації LIF-нейрони дозволяють моделювати темпоральні патерни, такі як QRS-комплекси, з низьким енергоспоживанням, як показано в роботах [6], [12]. Біологічна основа забезпечує стійкість до шуму, подібно до мозку, де спайки кодують інформацію асинхронно. Модель LIF може бути розширена рефракторним періодом або адаптацією, щоб краще імітувати біологічні нейрони, наприклад, додаючи змінну порогу або додатковий струм витоку. Теоретично, динаміка LIF описується як лінійна система з нелінійним порогом, що дозволяє проводити аналітичний аналіз стабільності через теорію диференціальних рівнянь.

Математичне моделювання спайків у SNN базується на диференціальних рівняннях, які описують еволюцію мембранного потенціалу з часом. Для LIF-моделі основне рівняння динаміки:

$$\frac{dV}{dt} = \frac{1}{\tau} \left(-V(t) + V_{rest} + R \sum_i w_i s_i(t) \right),$$

де $V(t)$ — потенціал у момент t ; V_{rest} — потенціал спокою; w_i — синаптичні ваги; s_i — вхідні спайки (дельта-функції).

Порогова умова: якщо $V(t) \geq V_{th}$, то генерується спайк $s(t) = \delta(t - t_f)$, де t_f — час спайку, і $V(t) = V_{reset}$ на рефракторний період t_{ref} .

У SNN спайки моделюються як події, оскільки мережі є подієво-орієнтованими. Для стохастичних моделей додається шум, наприклад, Пуассонівський процес для вхідних спайків

$$P(k) = \frac{\lambda^k e^{-\lambda}}{k!},$$

де λ — середня частота. Це покращує стійкість до варіабельності сигналів, як у ЕКГ з артефактами [2], [10]. Порогова умова забезпечує нелінійність, подібну до активаційних функцій у ANN, але з темпоральним аспектом. Теоретично, динаміка SNN може бути проаналізована через теорію динамічних систем, оцінюючи стабільність фіксованих точок для хаотичної поведінки в рекурентних мережах [15]. У класифікації ЕКГ такі моделі дозволяють точно захоплювати часові залежності, як інтервали RR, з меншим ризиком перенавчання порівняно з традиційними мережами. Для чисельного моделювання використовуються методи інтегрування Ейлера, з кроком часу dt , що забезпечує баланс між точністю та швидкістю обчислень. У біомедичних задачах, як ЕКГ, математичне моделювання дозволяє оптимізувати параметри, такі як τ або V_{th} , для підвищення чутливості до патологічних патернів.

Машина рідинних станів (Liquid State Machines, LSM) — тип резервуарного обчислення, де фіксований «резервуар» рекурентних нейронів проектує вхід у високовимірний простір, а вихідний шар навчається. Резервуар моделюється як хаотична система зі згасанням пам'яті, де стан $x(t)$ еволюціонує

$$x(t) = f(x(t-1), u(t)),$$

де f — нелінійна функція, $u(t)$ — вхід. LSM ефективні для часових сигналів, оскільки резервуар захоплює динаміку без навчання [1], [13]. У ЕКГ-класифікації LSM дозволяють обробляти варіабельні патерни, як аритмії, з низьким енергоспоживанням, як у [10]. Теоретично, універсальність LSM впливає з апроксимаційної властивості, подібно до RNN. Резервуар складається з випадково з'єднаних нейронів (наприклад, 80 % збуджувальних, 20 % гальмівних), з вагами, що забезпечують баланс збудження/гальмування. Динаміка LSM описується як марковський процес з короткочасною пам'яттю, де сепарація вхідних сигналів відбувається через нелінійні проекції. Навчання обмежується вихідним шаром, наприклад, через лінійну регресію на накопичених станах резервуару. У біомедичних застосуваннях LSM інтегруються з LIF-нейронами для моделювання темпоральних залежностей, як у серцевих ритмах, з перевагою в енергоефективності для носимих пристроїв [8], [12].

Особливості класифікації електрокардіограм за допомогою SNN




Рис. 1. Приклад повного набору характеристик одного серцебиття [18]

Електрокардіограма відображає електричну активність серця, реєструючи потенціали на поверхні тіла. Основна структура ЕКГ-сигналу складається з повторюваних комплексів, що відповідають серцевому циклу.

Ключовими компонентами є хвиля *P*, комплекс *QRS* та хвиля *T*. Хвиля *P* візуалізує деполаризацію передсердь, що ініціює їх скорочення. Вона зазвичай має амплітуду 0,05...0,25 мВ і тривалість 60...100 мс. Комплекс *QRS* є найвиразнішим елементом, який відображає деполаризацію шлуночків, з амплітудою до 2 мВ і тривалістю 80...120 мс. Хвиля *T* вказує на реполаризацію шлуночків, з тривалістю 150...250 мс, що показано на рис. 1.

Патологічні відхилення в структурі ЕКГ сигналізують про аритмії, ішемію чи інші порушення. Наприклад, екстрасистולי проявляються як передчасні комплекси *QRS* без попередньої хвилі *P*, тоді як фібриляція передсердь призводить до відсутності чітких хвиль *P* і нерегулярного ритму *QRS*. Блокада пучка Гіса може розширювати комплекс *QRS* понад 120 мс, а інфаркт міокарда — піднімати сегмент *ST* або інвертувати хвилю *T*. Ці відхилення часто супроводжуються змінами в амплітуді, тривалості чи морфології компонентів.




Рис. 2. Приклади різних кардіграм для ААМІ класів [17]

У контексті класифікації, розуміння цих структур є фундаментальним для виділення ознак. Дослідження показують, що SNN можуть ефективно захоплювати темпоральні патерни в ЕКГ, такі як варіації інтервалів RR (між піками R у QRS), що критично для виявлення аритмій [1], [6]. До прикладу, у роботі А. Rana та ін. (2024) підкреслюється, як спайкові моделі інтегрують і-спалахують (LIF) дозволяють класифікувати аномалії на основі динаміки хвиль QRS і T . Аналогічно, Н. Choi та ін. (2024) у огляді зазначають, що патологічні відхилення, як тахікардія чи брадикардія, вимагають врахування не лише статичних форм, але й темпоральних послідовностей, через що SNN є ідеальними для таких задач. Таким чином, структура ЕКГ слугує основою для розробки моделей, здатних розпізнавати як нормальні, так і патологічні стани з високою точністю.

Навчання спайкінгових нейронних мереж є складним через дискретну природу спайків, що ускладнює застосування стандартних градієнтних методів. Одним з ключових підходів є пластичність, залежна від часу спайків (STDP), яка імітує біологічне навчання: синаптична вага посилюється, якщо пресинаптичний спайк передує постсинаптичному, і послаблюється навпаки. У контексті ЕКГ, STDP дозволяє адаптувати мережу до темпоральних патернів, як у роботі D. Mohammad (2023), де SNN виявляють аномалії ритму [5].

Градієнтні методи, такі як зворотне поширення через час (BPTT), адаптуються для SNN шляхом апроксимації спайкової функції. Наприклад, сурогатні градієнти замінюють дельта-функцію гладкими апроксимаціями, дозволяючи оптимізацію. А. Rana та ін. (2024) застосовують це в рамках LIF-нейронів для класифікації ЕКГ, досягаючи точності понад 95 % [6]. Н. Choi та ін. (2024) в огляді описують градієнтні методи для низькопотужних середовищ, де вони поєднуються з подієво-орієнтованими обчисленнями [1].

Апроксимаційні методи, як перетворення ANN-to-SNN, дозволяють переносити навчені традиційні мережі у спайкову форму, зберігаючи ефективність. Z. Yan та ін. (2021) використовують це для енергоефективної класифікації, де апроксимація зменшує втрати точності [1]. С. Y. Saw та ін. (2022) пропонують стохастичні резервуари з апроксимацією для класифікації серцебиття [2]. Теоретично, ці підходи вирішують проблему недиференційованості, але вимагають балансу між точністю та обчислювальною складністю, як у Р. Kovacs та ін. [14]. Загалом, комбінація STDP з градієнтними та апроксимаційними методами відкриває шлях до ефективного навчання SNN для ЕКГ-класифікації. Порівняння методів класифікації сигналів кардіограм за допомогою SNN подано у таблиці.

Порівняння наявних SNN-рішень для класифікації ЕКГ

Робота	Кількість класів	Точність, %	Чутливість, %	Енергоефективність	Обчислювальна складність (параметри/шари)	Апаратна реалізація	Обмеження
Rana & Kim [6]	5	93,8	92...95	1,78 $\mu\text{J}/\text{удар}$	середня (ANN-конверсія, 3 шари)	Wearable, NC-чіпи	шум, дані
Yan et al. [2]	4	97,16	96...98	0,077 Вт	низька (2 шари)	Neuromorphic (Loihi)	шум
Saw & Wong [13]	—	96,91	99,6	низька (не вказано)	низька (20 нейронів, резервуар)	Hardware-адаптивна	дані
Kovacs & Samiee [14]	2	97,16	96...98	Низька (0,077 Вт)	дуже низька (242 параметри)	Edge, neuromorphic	шум, дані
Yan SparrowSNN [10]	4	98,29	98...99	31,39 нДж/інференс	низька (3 шари, ASIC)	ASIC, Loihi	тренування
Amirshahi & Hashemi [12]	4	98	97	1,78 $\mu\text{J}/\text{удар}$	низька (2 шари, STDP)	Ultra-low power	стабільність
Banerjee et al. [15]	4	95	94	ультранизька (NC)	низька (feed-forward)	Loihi, Akida	шум, дані
Mohammad [5]	4	95	93	середня	середня (CNN-to-SNN)	Симуляція, neuromorphic	дані

Архітектура запропонованої моделі SNN для класифікації ЕКГ

Вхідний шар моделі відповідає за перетворення аналогових сигналів ЕКГ у спайкову форму, що є ключовим етапом для інтеграції з SNN. ЕКГ-сигнали, які є часовими рядами з компонентами P , QRS та T , кодуються за допомогою темпорального або частотного кодування, де амплітуда сигналу перетворюється на послідовність спайків. У запропонованій моделі використовується модель нейронів типу LIF, де потенціал мембрани накопичується залежно від вхідного струму, а спайк генерується у разі досягнення порогу.

Для кодування застосовується інтегральне представлення, де спайки генеруються на основі амплітуди сигналу. Кількість вхідних нейронів — один для одноканального ЕКГ, що зменшує складність. Параметри, такі як поріг спайку (близько 3 мВ) та часова константа (5 мс), вибираються для збереження темпоральної інформації сигналу. Такий шар дозволяє моделі адаптуватися до варіабельності ЕКГ, фільтруючи шум на ранньому етапі та перетворюючи дані в неповнозв'язну спайкову активність, готову для подальшої обробки в резервуарі.

Резервуарний шар, оснований на концепції LSM, є центральним елементом моделі, де відбувається проєкція вхідних спайків у високовимірний простір станів. Шар складається з великої кількості нейронів, 1000 в цьому випадку, але на відміну від стандартних LSM в цій моделі не нейрон може бути збуджувальний чи гальмівний, а тільки синапс між нейронами. Синапси будуються таким чином: кожен нейрон з LSM має синапси до 20 % нейронів з LSM, синапси розподіляються також: 80 % — збуджувальні (excitatory) та 20 % — гальмівні (inhibitory), що імітує біологічну нейронну мережу. Динаміка описується LIF-моделлю з порогом спайку близько -55 мВ та потенціалом спокою -65 мВ. Рекурентні зв'язки забезпечують нелінійну трансформацію сигналу, де кожен нейрон з'єднаний з випадковою підмножиною інших нейронів з вагами, що варіюються від позитивних до негативних.

Ваги зв'язків фіксовані та генеруються випадково, з більшими абсолютними значеннями для гальмівних синапсів, щоб підтримувати баланс активності та запобігати перезбудженню. Це створює «рідинний» стан, де темпоральні патерни ЕКГ розгортаються в унікальні траєкторії станів, полегшуючи сепарацію класів аритмій.

Вхідні спайки з першого шару надходять до 20 % нейронів резервуару з позитивними вагами, ініціюючи хвилі активності. Динаміка рекурентних зв'язків забезпечує стійкість до шумів, оскільки випадкові флуктуації гасяться гальмівними нейронами, а ключові патерни підсилюються. Через це шар ефективний для реального часу обробки, з часовими константами близько 5 мс, що відповідає швидкості ЕКГ-сигналів.

Вихідний шар моделі здійснює декодування станів резервуару та безпосередню класифікацію ЕКГ на основі спайкової активності. Шар складається з 5 нейронів що відповідає 5 класам з ААМІ (Association for the Advancement of Medical Instrumentation) класів [1], модельованих за LIF-принципом.

Синапси з резервуаром випадкові — 20 % нейронів LSM для кожного вихідного нейрона, з вагами, що балансують збудження та гальмування з розподілом 80 % — збуджувальні та 20 % — гальмівні. Архітектура нейронної мережі показана на рис. 3.




Рис. 3. Архітектура нейронної мережі

Класифікація відбувається шляхом підрахунку загальної кількості спайків та кількість спайків на кожному нейроні, де клас визначається нейроном, чия частка спайків більше ніж 90 % від загальної кількості. Навчання вихідного шару може використовувати STDP або градієнтні методи, фіксуючи ваги для адаптації до патернів аритмій. Такий шар мінімізує обчислювальні витрати, оскільки обробляється неповноз'язна нейронна мережа, і дозволяє реальну класифікацію в низькоенергетичних системах, інтегруючи біоміметичні елементи для підвищення точності. Як демонструє аналіз на записах MIT-BIH, така архітектура має підвищену чутливість до аномалій, з F1-score у класифікації, що зростає з 0,85 до 0,93 у разі використання SNN із запропонованою архітектурою. Розподіл бази MIT-BIH на навчальну та тестову вибірки виконано за таким алгоритмом. Для кожної анотації R і обмежувався сигнал від $R_i - 1$ до $R_i + 1$ та розподілявся до відповідного класу за AAMI. Для сформованих множин сигналів до кожного класу випадково вибрано 80 % сигналів до навчальної вибірки та решту 20 % — до тестової. Загальний обсяг вибірки 100708 сигналів. Розподіл на навчальну та тестову: 80566/20142. Розподіл по AAMI класам для навчальної вибірки: Normal — 71885, Supraventricular Ectopic Beat — 2421, Ventricular Ectopic Beat — 5606, Fusion — 642, Unknown Beat — 12. Розподіл по AAMI класам для тестової вибірки: Normal — 17972, Supraventricular Ectopic Beat — 605, Ventricular Ectopic Beat — 1402, Fusion — 160, Unknown Beat — 3.

Перспективи застосування SNN у клінічній практиці для класифікації ЕКГ є обнадійливими, особливо в реальному часі моніторингу. Завдяки енергоефективності, такі моделі можуть інтегруватися в імплантовані пристрої чи смарт-годинники для раннього виявлення аритмій, як фібриляція передсердь чи шлуночкові екстрасистолі. У запропонованій архітектурі з LSM, темпоральне кодування дозволяє обробляти динамічні сигнали ЕКГ з мінімальною затримкою, що критично для екстреної діагностики.

Дослідження [8] показують потенціал комбінації ЕКГ з іншими сигналами (наприклад, PCG) у SNN для підвищення точності до 99 %, що перевищує традиційні методи. У клініці це може зменшити помилки, пов'язані з шумом, і полегшити телемедицину. Більше того, біомімікрія SNN сприяє кращій інтерпретації результатів лікарями, наближаючи до нейрофізіологічних процесів. Перспективи включають інтеграцію з AI-платформами для персоналізованої медицини, де SNN адаптуються до індивідуальних варіацій серцевого ритму. Загалом, з подоланням викликів навчання, SNN можуть революціонізувати кардіодіагностику, зменшуючи витрати та підвищуючи доступність.

Висновки

В дослідженні проаналізовано біологічні та математичні основи SNN, моделі нейронів та синапсів. Розглянуто основні характеристики ЕКГ та безпосередньо будову серцебиття та його головні ознаки. Запропоновано архітектуру спайкінгової нейронної мережі, що містить у собі 3 шари, розглянуто запропонований метод побудови зв'язків між нейронами за допомогою синапсів та перехід від традиційних «гальмівних/збуджувальних нейронів» до «гальмівних/збуджувальних синапсів». Розглянуто перспективи використання спайкінгових нейронних мереж у клінічній практиці.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] H. Choi et al., "Review on spiking neural network-based ECG classification methods for low-power environments," *Bio-med. Eng. Lett.*, 2024.
- [2] Z. Yan, J. Zhou, and W.-F. Wong, "Energy efficient ECG classification with spiking neural network," *Biomed. Signal Process. Control*, vol. 63, Art. no. 102170, 2021.
- [3] O. K. Kolesnytskyj, I. V. Bokotsey, and S. S. Yaremchuk, "Optoelectronic implementation of pulsed neurons and neural networks using bispin-devices," *Opt. Memory Neural Netw.*, vol. 19, no. 2, pp. 154-165, 2010. <https://doi.org/10.3103/S1060992X10020062>.
- [4] O. K. Kolesnytskyj, V. V. Kutsman, K. Skorupski, and M. Arshidinova, "Neurocomputer architecture based on spiking neural network and its optoelectronic implementation," in *Proc. SPIE 11176, Photon. Appl. Astron., Commun., Ind., High-Energy Phys. Exp.* 2019, Nov. 2019, Art. no. 1117609, <https://doi.org/10.1117/12.2536607>.
- [5] D. Mohammad, "Detection of abnormalities in cardiac rhythm using spiking neural networks," *M.S. thesis, Lund Univ.*, Lund, Sweden, 2023.
- [6] A. Rana and K. [incomplete author list], "Electrocardiography classification with leaky integrate-and-fire neurons in an artificial neural network-inspired spiking neural network framework," [incomplete publication details].
- [7] W. Gerstner, and W. M. Kistler, *Spiking Neuron Models: Single Neurons, Populations, Plasticity*. Cambridge, U.K.: Cambridge Univ. Press, 2002, ISBN 0-511-07817-X.
- [8] X. Li, et al., "A spiking neural network-based approach with ECG and PCG for cardiovascular disease classification," *Sensors*, 2024.
- [9] V. Kutsman, and O. Kolesnytskyj, "Dynamic handwritten signature identification using spiking neural network," *Informatyka*,

Automatyka, Pomiarы w Gospodarce i Ochronie Środowiska, vol. 11, no. 3, pp. 34–39, 2021, <https://doi.org/10.35784/iapgos.2718>.

[10] Z. Yan, et al., “SparrowSNN: A hardware/software co-design for energy efficient ECG classification,” *arXiv*: 2406.06543v1, 2024.

[11] W. Maass, “Networks of spiking neurons: The third generation of neural network models,” *Neural Netw.*, vol. 10, pp. 1659–1671, 1997, [https://doi.org/10.1016/S0893-6080\(97\)00011-7](https://doi.org/10.1016/S0893-6080(97)00011-7).

[12] A. Amirshahi, and M. Hashemi, “ECG classification algorithm based on STDP and R-STDP neural networks for real-time monitoring on ultra low-power personal wearable devices,” *IEEE Trans. Biomed. Circuits Syst.*, 2019.

[13] C. Y. Saw, and Y. C. Wong, “Neuromorphic computing based on stochastic spiking reservoir for heartbeat classification,” *Jordanian J. Comput. Inf. Technol.*, vol. 08, no. 02, pp. 184–195, 2022.

[14] P. Kovacs, and K. Samiee, “Arrhythmia detection using spiking variable projection neural networks,” *Preprint*, 2023.

[15] D. Banerjee, S. Dey, and A. Pal, *An SNN based ECG classifier for wearable edge devices*, 2023.

[16] J. Wang, et al., “Building and training a deep spiking neural network for ECG classification,” *Biomed. Signal Process. Control*, 2022.

[17] Y. Xing, and L. Zhang, “Accurate ECG classification based on spiking neural network and attentional mechanism for real-time implementation on personal portable devices,” *Electronics*, vol. 11, Art. no. 1889, 2022.

[18] *Нормальна ЕКГ: зубці, сегменти, інтервали*. [Електронний ресурс]. Режим доступу: <https://therapy.odmu.edu.ua/ecg-online-course/normal-ecg-waves-intervals>.

Рекомендована кафедрою комп'ютерних наук ВНТУ

Стаття надійшла до редакції 26.09.2025.

Милосердов Дмитро Андрійович — аспірант кафедри комп'ютерних наук, e-mail: dagger.dager@gmail.com ;
Колесницький Олег Костянтинович — канд. тех. наук, доцент, професор кафедри комп'ютерних наук, e-mail: kolesnytskiy@vntu.edu.ua .

Вінницький національний технічний університет, Вінниця

D. A. Myloserdov¹
O. K. Kolesnytskyi¹

Method of Electrocardiograms Classification Using Spiking Neural Networks

¹Vinnitsia National Technical University

The article is devoted to the theoretical development of the ECG classification method using SNN for heart failure recognition. The introduction considers the relevance of the problem, the advantages of SNN over traditional networks, the goal of the study — creating a theoretical basis for an energy-efficient model — and the tasks, including the analysis of the foundations of SNN, ECG features and model architecture. The structure of the article covers the theoretical fundamentals, classification features, proposed architecture, analysis of advantages and conclusions.

The section on the theoretical fundamentals of spiking neural networks describes biological models of neurons, such as Leaky integrate-and-fire mathematical modeling of spike dynamics through differential equations, liquid state machine network types. The Leaky integrate-and-fire model balances biological plausibility with computational efficiency, allowing processing of temporal ECG patterns with low power consumption.

Features of ECG classification using spiking neural networks include signal structure analysis, noise, variability and real-time processing issues. Spiking neural networks can use different training approaches: STDP, gradient methods and approximation. This provides robustness to artifacts and high accuracy, as shown in the reviewed works.

The proposed model architecture consists of three layers: input (ECG encoding into spikes using Leaky integrate-and-fire), reservoir (1000 neurons with recurrent connections and balance of excitatory/inhibitory synapses) and output (decoding for 5 classes through spike counting). The theoretical robustness analysis is based on dynamical systems, ensuring efficiency for wearable devices.

The analysis of advantages highlights the energy efficiency and biomimicry of spiking neural networks compared to others, the challenges of computational complexity and prospects in clinical practice, including telemedicine and personalized diagnostics.

Keywords: spiking neural networks, neural networks, time series, ECG, Leaky integrate-and-fire neuron, time series classification.

Myloserdov Dmytro A. — Post-Graduate Student of the Chair of Computer Science, e-mail: dagger.dager@gmail.com ;

Kolesnytskyi Oleh K. — Cand. Sc. (Eng.), Associate Professor, Professor of the Chair of Computer Science, e-mail: kolesnytskiy@vntu.edu.ua