

Аналіз використання активаційних вейвлет - функцій у вейвлет - нейронних мережах категоризації серцевих скорочень ЕКГ

Ігор Думин¹, Адріан Наконечний²

¹ магістр, аспірант, кафедра КСА, Національний університет «Львівська політехніка», вул. С.Бандери 12, 79013, Львів, e-mail: ihor.r.dumyn@lpnu.ua

² д.т.н., професор, завідувач кафедри, кафедра КСА, Національний університет «Львівська політехніка», вул. С.Бандери 12, 79013, Львів, e-mail: adrnakon@gmail.com

Точна та автоматизована класифікація серцевих скорочень на електрокардіограмі (ЕКГ) є фундаментальною для діагностики та лікування серцево-судинних захворювань (ССЗ), однак вона залишається складним завданням через комплексність і варіабельність сигналів ЕКГ [1]. У цьому дослідженні розглядається ефективність використання різних вейвлет-функцій, зокрема Морле, мексиканського капелюха, Габора, Шеннона та Гаусса, як функцій активації в архітектурі вейвлет-нейронної мережі (WNN) для класифікації серцевих скорочень ЕКГ [3]. Використання загальнодоступного набору даних, отриманого з баз даних MIT-BIH Arrhythmia та PTB Diagnostic ECG, зокрема зосередження на 5-класовій категоризації аритмії на основі стандарту Асоціації з удосконалення медичної апаратури (AAMI) [5]. Ключові висновки вказують на відмінності в продуктивності різних функцій вейвлет-активації, підкреслюючи потенційні переваги використання притаманних властивостей частотно-часової локалізації вейвлетів для фіксації дискримінаційних морфологічних особливостей у ритмах ЕКГ [7]. Дана робота підкреслює перспективність використання функцій активації на основі вейвлетів для підвищення точності та надійності моделей глибокого навчання в програмах обробки біомедичних сигналів, зокрема аналізі ЕКГ.

Ключові слова: електрокардіограма (ЕКГ), класифікація серцевих скорочень, вейвлет-нейронна мережа (WNN), вейвлет-перетворення, MIT-BIH, глибоке навчання, обробка біомедичних сигналів.

1. Вступ

1.1. Аналіз ЕКГ і значення автоматичної категоризації серцевих скорочень

Відомо, що електрокардіограма (ЕКГ) є наріжним каменем у клінічній кардіології, забезпечуючи неінвазивне вікно в електричну активність серця [1]. Генерована циклами деполяризації та реполяризації клітин серцевого м'яза, форма хвилі ЕКГ складається з різних компонентів, включаючи зубець Р (деполяризація передсердь), комплекс QRS (деполяризація шлуночків) і зубець Т (реполяризація шлуночків), кожен з яких відображає специфічні фізіологічні події в рамках серцевого циклу [1]. Аналіз цих форм сигналів дозволяє клініцистам оцінювати серцевий ритм, виявляти порушення провідності та діагностувати широкий спектр серцево-судинних захворювань (ССЗ), які залишаються основною причиною смертності у всьому світі.

Серед найбільш критичних застосувань ЕКГ є виявлення та класифікація аритмій – порушень серцевого ритму або морфології скорочень [4]. Аритмії можуть

вказувати на серйозні захворювання та бути причиною інсульту або раптової серцевої смерті [4]. Традиційно інтерпретація ЕКГ базується на візуальному огляді підготовленими кардіологами або техніками. Однак цей ручний процес за своєю суттю займає багато часу, трудомісткий і потребує значного досвіду [1]. Крім того, суб'єктивність і варіабельність між спостерігачами можуть вплинути на послідовність діагностики, особливо при аналізі довготривалих амбулаторних записів ЕКГ (наприклад, холтерівське моніторування), які можуть містити десятки тисяч серцевих скорочень [4].

Отже, існує потреба в надійних, точних та ефективних автоматизованих системах для категоризації серцебиття ЕКГ [1]. Такі системи мають полегшити навантаження на клініцистів, зменшити затримки діагностики, покращити узгодженість інтерпретації, полегшити широкомасштабні програми скринінгу та, зрештою, покращити допомогу пацієнтам завдяки своєчасному втручання [4]. Тому розробка ефективних автоматизованих методів є важливою сферою досліджень у обробці біомедичних сигналів і обчислювальній кардіології.

1.2. Обмеження існуючих підходів і стандартних функцій активації в нейронних мережах

Ранні спроби автоматизованого аналізу ЕКГ часто використовували звичайні алгоритми машинного навчання, зокрема машини опорних векторів (SVM), дерева рішень і К-найближчі сусіди (KNN). Ці методи, як правило, залежать від попереднього етапу ручного виділення ознак, де використовується експертний досвід предметної області для визначення морфологічних, статистичних або частотних характеристик, які вважаються доречними для класифікації [6]. Незважаючи на досягнення певного успіху, ці підходи обмежені вибором функцій, які не можуть оптимально вловлювати складні та часто непомітні особливості, присутні в складних сигналах ЕКГ, особливо в різних групах пацієнтів і в умовах запису [1].

Поява глибокого навчання (DL) зробила революцію в задачах розпізнавання образів, включаючи аналіз ЕКГ. Такі архітектури, як згорткові нейронні мережі (CNN) і повторювані нейронні мережі (RNN), зокрема мережі довгострокової короткочасної пам'яті (LSTM), продемонстрували надзвичайний успіх завдяки автоматичному навчанню ієрархічних представлень і дискримінаційних функцій безпосередньо з необроблених або мінімально оброблених даних ЕКГ.

Важливим компонентом глибоких нейронних мереж є функція активації, яка застосовується до кожного нейрона для введення нелінійності, що дозволяє мережі вивчати складні відображення між входами та виходами. Зазвичай використовувані функції активації включають сигмоподібну, гіперболічний тангенс (Tanh), випрямлену лінійну одиницю (ReLU) та її варіанти (наприклад, Leaky ReLU, GELU) [3]. Незважаючи на широке поширення, ці функції мають характеристики, які можуть бути не ідеальними для всіх типів сигналів. Функції Sigmoid і Tanh є обмеженими та можуть страждати від проблеми зникнення градієнта під час навчання, що перешкоджає навчанню в глибоких мережах. ReLU є обчислювально ефективним і уникає зникаючих градієнтів для позитивних вхідних даних, але необмежений і може страждати від проблеми «вмирання ReLU», коли нейрони стають неактивними [10]. Більш фундаментально, ці стандартні функції активації діють глобально або є

частково-лінійними, що потенційно обмежує їх здатність ефективно представляти сигнали, такі як ЕКГ, які характеризуються локалізованими коливальними подіями, що відбуваються в різних часових масштабах [3].

1.3. Вейвлет-перетворення в обробці сигналів та вейвлет-нейронні мережі (WNN)

Частотно-часова локалізація робить Wavelet Transform (WT) надзвичайно придатним для аналізу нестационарних сигналів – сигналів, частотний вміст яких змінюється з часом – таких як ЕКГ [7]. Сигнали ЕКГ містять короткочасні високочастотні компоненти, такі як комплекс QRS, поряд із сегментами нижчої частоти, такими як зубець Т і базові коливання [2]. Можливість аналізу WT із різною роздільною здатністю дозволяє ефективно фіксувати як різкі, локалізовані події, так і більш широкі та плавні характеристики. Таким чином, WT доцільно широко використовувати при обробці ЕКГ для таких завдань, як усунення шумів, стиснення даних, а особливо виділення ознак для подальшої класифікації [7].

Визнаючи синергію між аналітичною потужністю вейвлетів і можливостями навчання нейронних мереж, була запропонована концепція вейвлетних нейронних мереж (WNN) [2]. WNN представляють клас прямої нейронної мережі, яка інтегрує теорію вейвлетів безпосередньо у свою архітектуру, як правило, використовуючи вейвлет-функції як функції активації в прихованих шарах. Ці спеціалізовані нейрони іноді називають «вевелонами» [12]. Основна ідея полягає в тому, що ці вейвлет-активації з властивими їм особливостями локалізації можуть дозволити мережі вивчати більш значущі та ефективні представлення складних нестационарних сигналів порівняно з мережами, які використовують стандартні функції активації [3].

Важливість обґрунтування використання вейвлет-функцій як функцій активації в нейронних мережах, зокрема для аналізу ЕКГ, впливає з їхніх фундаментальних властивостей. Класифікація серцебиття на ЕКГ ґрунтується на виявленні тонких морфологічних варіацій у формі хвилі, тривалості та інтервалах [6]. Вейвлети, будучи локалізованими базовими функціями, які коливаються та затухають, мають характеристики, які інтуїтивно узгоджуються з природою цих особливостей ЕКГ [7]. На відміну від глобальних функцій, таких як Sigmoid або Tanh, або простої порогової поведінки ReLU, функція вейвлет-активації може вибірково реагувати на шаблони введення, які відповідають її певній формі, масштабу (тривалість/частота) і положенню (час) [3]. Включаючи вейвлети з можливістю навчання або фіксованим масштабом і параметрами трансляції в прихованих шарах мережі, WNN потенційно отримує здатність діяти як банк адаптивних вейвлет-фільтрів, навчаючись виявляти конкретні частотно-часові структури, що стосуються розрізнення різних класів пульсу [12]. Це різко контрастує зі стандартними функціями активації, у яких відсутній механізм локалізованого аналізу часової шкали [10].

1.4. Цілі дослідження та основні внески

Основною метою цієї статті є систематичне дослідження та оцінка ефективності використання різних вейвлет-функцій як функцій активації в структурі вейвлет-нейронної мережі (WNN) для завдання багатокласової категоризації серцевих скорочень ЕКГ. Класифікація відповідає загальноприйнятому стандарту ААМІ для

відображення типів серцевих скорочень, отриманих із компонента бази даних аритмії MIT-BIH та PTB Diagnostic ECG, який використовується у наборі даних [4]. Додатково виконати порівняння ефективності класифікації, досягнутої за допомогою різних сімейств функцій вейвлет-активації, щоб зрозуміти вплив властивостей вейвлетів на ефективність такого представлення [9].

2. Методика

2.1. Набір даних ЕКГ: опис і обґрунтування

В даному дослідженні використовується загальнодоступний «Набір даних категоризації серцевого ритму ЕКГ» [13]. Цей набір даних містить дві колекції сигналів серцебиття, отримані з двох добре налагоджених баз даних ЕКГ: Набір даних аритмії MIT-BIH та базу даних PTB Diagnostic ECG [13]. Об'єднаний набір даних забезпечує значну кількість зразків, придатних для навчання моделей глибокого навчання [13].

Для цього дослідження доцільно зосередитися саме на наборі даних про аритмію частина, якої отримана з бази даних про аритмію MIT-BIH. Дана підмножина містить 109 446 проб класифікованих на 5 класів відповідно до стандарту AAMI [13]. Розподіл класів за своєю суттю є незбалансованим, що відображає клінічну реальність, і включає нормальні (N), суправентрикулярні ектопічні (S), вентрикулярні ектопічні (V), злиті (F) та невідомі (Q) екстрасистолії [13].

Таблиця 1

Характеристики набору даних про аритмію (отримано з MIT-BIH, класи AAMI)

Мітка класу AAMI	опис	Загальна кількість ударів	Частота вибірки	Значень на удар
N (0)	Нормальні та пучкові блокади	~90 000 (приблизно)	125 Гц	187
S (1)	Суправентрикулярний ектопічний серцевий скорочення	~2800 (приблизно)	125 Гц	187
V (2)	Шлуночковий ектопічний серцевий скорочення	~7000 (приблизно)	125 Гц	187
F (3)	Fusion Beat	~800 (приблизно)	125 Гц	187
Q (4)	Невідомий ритм / Некласифікований	~15 (приблизно)	125 Гц	187

Важливо те, що сигнали в цьому наборі даних пройшли попередню обробку: вони сегментовані на окремі серцеві скорочення, розділені на частоті дискретизації 125 Гц, а також доповнені або обрізані до фіксованої розмірності 187 точок на серцебиття [13]. Цей стандартизований формат полегшує пряме введення в моделі нейронної мережі. Використання цього попередньо обробленого набору даних забезпечує узгодженість і дозволяє зосередитися на впливі функцій вейвлет-активації, а не на варіаціях етапів попередньої обробки.

2.2. Вибір досліджуваних вейвлет-функцій

Як вже згадувалось вище, основою цієї роботи є використання вейвлет-функцій у нейронній мережі. Вейвлет-перетворення забезпечують математичну основу для аналізу сигналів у різних масштабах (частотах) і місцях (час) [7]. У контексті WNN активація прихованого нейрона обчислюється за допомогою вейвлет-функції замість стандартної активації, як-от ReLU або Sigmoid.

В основі вейвлет-аналізу лежить материнська вейвлет-функція $\psi(t)$, яка є локалізованою хвилеподібною осциляцією. Для аналізу сигналу вона масштабується та зсувається, генеруючи сімейство дочірніх вейвлетів. У контексті WNN, вихід y_j j -го нейрона («велона») прихованого шару обчислюється на основі зваженої суми входів net_j :

$$net_j = \sum_i \omega_{ij} x_i - b_j$$

де x_i – вхідний сигнал, ω_{ij} – вага зв'язку, а b_j – параметр зсуву (трансляції), що контролює положення вейвлета. Далі, зважена сума нормалізується параметром масштабу a_j (розширення), який контролює ширину вейвлета, і подається на вейвлет-функцію активації:

$$y_j = \psi\left(\frac{net_j}{a_j}\right)$$

Поведінка вейвлет-нейрону в загальній формі для шару k може бути виражена як:

$$Z^{(k+1)} = \psi(W^{(k)}Z^{(k)} + b^{(k)})$$

що демонструє нелінійне перетворення з параметризованою вейвлет-функцією. Таким чином, вихід нейрона відображає, наскільки вхідний патерн відповідає формі. Критичним вибором дизайну в WNN є те, як обробляються параметри вейвлета a і b . Вони можуть бути попередньо визначеними фіксованими гіперпараметрами для кожного нейрона, або вони можуть бути параметрами, які можна вивчати, оновлюваними під час процесу зворотного поширення разом із мережевими вагами ω_{ij} . Якщо зробити їх доступними для навчання, це дозволяє мережі адаптувати форму та положення вейвлет-активації, щоб найкраще відповідати шаблонам вхідних даних, потенційно підвищуючи гнучкість моделі, а також її складність.

Коли параметри масштабу a та трансляції b є навчуваними, їх оновлення під час тренування мережі зазвичай виконується методом градієнтного спуску. Цей підхід дозволяє мережі адаптивно налаштовувати вейвлет-фільтри для кращого виявлення значущих ознак у вхідних даних. Загальні вирази для оновлення параметрів a_j та b_j для j -го нейрона, подібні до тих, що наведені в літературі [14], мають такий вигляд:

$$a_j(t+1) = a_j(t) - \eta_a \frac{\partial L}{\partial a_j(t)}, \quad b_j(t+1) = b_j(t) - \eta_b \frac{\partial L}{\partial b_j(t)},$$

де L – функція втрат, а η_a та η_b – індивідуальні швидкості навчання для параметрів масштабу та трансляції. Такий підхід дозволяє мережі адаптивно налаштовувати вейвлет-фільтри для кращого виявлення значущих ознак. Однак, в рамках цього дослідження було прийнято рішення використовувати фіксовані параметри для функцій активації. Це дозволило спростити процес навчання та цілеспрямовано дослідити вплив саме форми різних материнських вейвлет-функцій на якість класифікації.

Різноманітний набір вейвлет-функцій було обрано для дослідження як функції активації, вибрані на основі їхніх математичних властивостей і потенційної значущості для захоплення характеристик ЕКГ[9]. Вибрані вейвлети зведені в таблицю 2.

Таблиця 2

Досліджені властивості вейвлет-функцій

Вейвлет Сім'я/ім'я	Ключові властивості	Обґрунтування використання як функції активації
Морле	Комплекснозначний, аналітичний, відмінна частотно-часова роздільна здатність, неортогональний[11]	Ефективно фіксує інформацію про фазу та коливальні патерни, корисні для аналізу ритмічних компонентів ЕКГ.
Мексиканський капелюх (МНАТ)	Дійсна, симетрична, неортогональна[11]	Ефективний для виявлення краплеподібних особливостей або піків/екстремумів, потенційно корисний для визначення R-піків або інших чітких особливостей форми сигналу.
Гаус	Дійснозначний, антисиметричний, неортогональний [11]	Чутливий до країв або градієнтів у сигналі, потенційно корисний для виявлення різких переходів, таких як початок/зсув QRS.
Хаар	Дійснозначний, ортогональний, компактний опорний, розривний, найпростіший вейвлет [11]	Ефективний для виявлення різких змін або розривів, корисний як базовий рівень через простоту, однак може мати проблеми з гладкими сегментами ЕКГ.
Габор	Комплексне значення, мінімізує частотно-часову невизначеність продукту, локалізований [3]	Оптимальна концентрація просторової частоти, потенційно надійна для представлення локалізованих характеристик зображення/сигналу, досліджена в INR.
Шеннон (Sinc)	Реальний або комплексний, ортонормований базис, відмінна частотна локалізація, погана часова локалізація [11]	Ідеально підходить для частотно-специфічного аналізу, хоча погана локалізація часу може бути недоліком для тимчасових подій ЕКГ. Використовується в розрахунках енергії Шеннона для ЕКГ.

Наведений вибір охоплює різні властивості (дійсні/комплексні, ортогональні/неортогональні, симетричні/асиметричні, гладкість, локалізація), що дає змогу досліджувати, як дані характеристики впливають на ефективність класифікації при використанні як функції активації.

2.3. Запропонована архітектура вейвлет-нейронної мережі (WNN).

Основною архітектурою, яка використовується в цьому дослідженні, є нейронна мережа прямого зв'язку, зокрема структура багаторівневого персептрона (MLP), адаптована для включення вейвлет-активацій. MLP вибрано як базову архітектуру, оскільки вона забезпечує фундаментальну структуру для вивчення складних, нелінійних відображень вводу-виводу. Використання MLP дозволяє цілеспрямовано досліджувати вплив самої функції активації за допомогою оцінки продуктивності, коли на різних рівнях використовуються різні вейвлет-функції.

Загалом MLP забезпечує чітку базову лінію для оцінки можливостей представлення функцій, отриманих саме від активацій вейвлетів, коли вони застосовуються до сегментованих даних серцевого ритму.

Мережа складається з:

- Вхідний шар. Призначений для прийому попередньо оброблених і сегментованих векторів серцебиття ЕКГ. Кількість вхідних нейронів відповідає довжині сегмента серцебиття (наприклад, 187 нейронів для 187 зразків).
- Приховані шари. Дані шари містять нейрони, які використовують вибрані вейвлет-функції (ψ) як свої функції активації [12].
- Вихідний рівень. Цей рівень виробляє остаточні ймовірності класифікації для кожного класу пульсу ААМІ. Він містить кількість нейронів, рівну кількості класів (5 для N, S, V, F, Q). Функція активації Softmax застосовується до вихідного рівня, щоб гарантувати, що виходи представляють дійсний розподіл ймовірностей за класами.

Розміщення рівня(ів) вейвлет-активації в архітектурі мережі. Загальні конфігурації включають:

- Вейвлети у прихованому шарі. Це найбільш типова структура WNN, де один або кілька прихованих рівнів використовують вейвлет-активації, часто слідуючи за вхідним рівнем або початковими шарами зі стандартними активаціями [12]. Це дозволяє мережі вивчати початкові представлення перед застосуванням можливостей частотно-часового аналізу вейвлетів.
- Вейвлети у вхідному рівні. Найперший рівень застосовує вейвлет-активації безпосередньо до вхідного сигналу. Ця конфігурація спрямована на виконання негайної вейвлет-декомпозиції вхідних даних.
- Вейвлети на вихідному рівні. Використання вейвлетів як функції активації на останньому рівні перед виведенням класифікації менш поширене, оскільки такі функції, як Softmax, є стандартними для створення розподілу ймовірностей.

Наведене дослідження в основному зосереджене на загальному підході до використання вейвлет-функцій як активації всередині прихованих шарів з метою використання їх властивостей вилучення функцій у рамках MLP [12].

Для наочності, структура запропонованої мережі зображена на рисунку 2.3.1.




Рис. 2.3.1 Архітектура запропонованої вейвлет-нейронної мережі

Процес обробки даних у запропонованій архітектурі відбувається наступним чином. На вхідний шар подається вектор, що складається зі 187 значень, які представляють один сегментований удар серця. Далі, кожен нейрон першого прихованого шару (100 нейронів) обчислює зважену суму вхідних сигналів. До цього результату застосовується одна з досліджуваних вейвлет-функцій активації (ψ). Такий підхід дозволяє мережі на цьому етапі виділяти локалізовані в часі та частоті патерни, що є характерними для морфології сигналів ЕКГ.

Виходи нейронів першого прихованого шару передаються на другий прихований шар (також 100 нейронів), де виконується аналогічна операція вейвлет-активації. Це дозволяє моделі вивчати більш складні та ієрархічні залежності в даних. Нарешті, вихідний шар, що складається з 5 нейронів, використовує функцію активації Softmax. Вона перетворює отримані на попередньому шарі значення в розподіл ймовірностей, що показує приналежність вхідного сигналу до одного з п'яти класів ААМІ (N, S, V, F, Q).

Таблиця 3

Архітектура WNN і параметри навчання

Тип параметра	Значення/налаштування
Тип мережі	WNN на базі Feed-Forward MLP
Вхідний розмір	187 (точки на сегмент серцебиття)
Прихована конфігурація рівня 1	100 нейронів, вейвлет-активація (ψ)
Прихована конфігурація рівня 2	100 нейронів, вейвлет-активація (ψ)
Конфігурація вихідного рівня	5 нейронів (класи ААМІ), активація Softmax
Оптимізатор	Адам (оцінка адаптивного моменту)
Розмір партії	128
Кількість епох	100
Функція втрати	розріджена категоріальна кросентропія

2.5. План експерименту та протокол оцінки

Стратегія навчання, валідації та тестування (фокус на парадигмі між пацієнтами): Строгий протокол оцінювання має вирішальне значення для оцінки справжньої здатності до узагальнення запропонованих моделей, особливо для клінічних застосувань. У цьому дослідженні використовується строга парадигма між пацієнтами. Це означає, що записи ЕКГ з бази даних MIT-BIH поділяються на набори для навчання, перевірки та тестування таким чином, що жоден пацієнт не з'являється більше ніж в одному наборі.

Показники оцінки ефективності:

Для оцінки ефективності багатокласової класифікації використовується комплексний набір показників, особливо з огляду на дисбаланс класів, наявний у наборі даних, нанесеному на карту ААМІ (Таблиця 1). Покладання лише на точність може ввести в оману в незбалансованих сценаріях. Наступні показники обчислюються на основі елементів матриці плутанини: Справжні позитивні (TP), Справжні негативні (TN), помилкові позитивні результати (FP) і помилкові негативні результати (FN) для кожного класу:

- Матриця плутанини. Матриця, що показує прогнозований клас порівняно з фактичним класом, візуалізує продуктивність моделі та моделі помилок для кожної категорії.
- Точність (Acc). Загальний відсоток правильно класифікованих серцевих скорочень. $Acc = (TP + TN) / (TP + TN + FP + FN)$.
- Відкликання (Rec) / Чутливість (Sen) / True Positive Rate (TPR). Частка фактичних позитивних випадків, які правильно визначено. $Rec = TP / (TP + FN)$.⁷ Вимірює повноту.
- Оцінка F1 (F1). Гармонійне середнє значення точності та запам'ятовування, що забезпечує збалансований розмір, особливо корисний для незбалансованих класів. $F1 = 2 \times (Prec \times Rec) / (Prec + Rec)$.
- Площа під кривою ROC (AUC). Площа під кривою робочих характеристик приймача (діаграма TPR проти FPR при різних порогових значеннях), що вимірює здатність моделі розрізняти класи.

Для оцінки продуктивності вейвлет-нейронної мережі (WNN) у класифікаційних завданнях найбільш інформативним параметром є F1-оцінка, зокрема макро або зважена F1-оцінка. На відміну від точності, яка може вводити в оману через незбалансовані набори даних, показник F1 балансує як точність, так і запам'ятовування, завдяки чому краще відображає здатність моделі правильно класифікувати кожен клас. Оскільки WNN часто застосовуються до часових рядів або біомедичних сигналів, таких як ЕКГ, де дисбаланс класів і витрати на неправильну класифікацію є критичними, показник F1 стає ключовим інструментом для порівняння моделей і налаштування їх параметрів.

3. Результати

У даному випадку представлені результати експериментальної оцінки порівняння WNN з різними функціями вейвлет-активації для класифікації серцевих скорочень ЕКГ на наборі даних MIT-BIH за парадигмою між пацієнтами. Результати представлені кількісно в таблицях і візуально через матриці плутанини та ROC-криві.

3.1. Аналіз продуктивності різних функцій вейвлет-активації

Основні кількісні результати порівняння продуктивності архітектури WNN, реалізованої з різними функціями вейвлет-активації, узагальнено в таблиці 4. Тут наведені ключові показники продуктивності, включаючи загальну точність, точність для кожного класу, запам'ятовування та оцінку F1, а також макроусереднену оцінку F1, яка забезпечує збалансоване уявлення про всі класи AAMI, враховуючи дисбаланс.

Таблиця 4:

Кількісне порівняння ефективності WNN для досліджуваного набору даних (парадигма між пацієнтами)

Модель/функція активації	Загальна точність (%)	Точність (N/S/N/F/Q) (%)	Відгук (N/S/N/F/Q) (%)	F1 (N/S/N/F/Q) (%)	Макро Середнє F1 (%)	Макро Середня попередня (%)	Macro Avg Rec (%)
WNN-Морле	97,01	99,02 / 70,23 / 89,26 / 61,54 / 97,28	97,77 / 78,06 / 95,23 / 83,95 / 97,89	98,39 / 73,94 / 92,15 / 71,02 / 97,58	86,61	83,46	90,58
WNN-МН	96,91	98,96 / 68,26 / 88,61 / 66,33 / 97,33	97,73 / 79,68 / 94,54 / 80,25 / 97,45	98,34 / 73,53 / 91,48 / 72,63 / 97,39	86,67	83,90	89,93
WNN-Гаус	97,03	98,76 / 73,53 / 90,25 / 63,26 / 96,68	98,07 / 74,46 / 93,30 / 83,95 / 97,70	98,42 / 73,99 / 91,75 / 72,15 / 97,19	86,70	84,50	89,50
WNN-Хаар	91,06	96,88 / 45,72 / 71,50 / 26,57 / 86,80	93,13 / 59,53 / 79,70 / 75,93 / 90,36	94,97 / 51,72 / 75,38 / 39,36 / 88,54	69,99	65,49	79,73
WNN-Габор	96,78	98,96 / 65,48 / 90,21 / 59,47 / 96,91	97,62 / 79,14 / 93,51 / 83,33 / 97,64	98,29 / 71,66 / 91,83 / 69,41 / 97,27	85,69	82,21	90,25
WNN-Шен-нон	96,64	99,00 / 67,76 / 85,52 / 68,56 / 96,43	97,43 / 77,88 / 94,61 / 82,10 / 97,51	98,21 / 72,47 / 89,84 / 74,72 / 96,97	86,44	83,45	89,91

Результати, представлені в таблиці 4, дозволяють прямо порівняти ефективність різних вейвлет-активацій. Особлива увага приділяється макроусередненому F1-балу як основному показнику збалансованої продуктивності для всіх класів, включаючи класи меншості аритмії (S, V, F).

3.2. Візуалізація продуктивності

- **Матриця плутанини:** На рисунку 3.2.1 показано матрицю плутанини для найефективнішої моделі WNN, визначеної в таблиці 4




рис. 3.2.1 Матриця плутанини для найкращої моделі WNN-вейвлет

- **Криві ROC:** На рисунку 3.2.2 представлено криві робочих характеристик (ROC) для найкращої моделі WNN. Окремі криві будуються для кожного класу ААМІ




Рис. 3.2.2 Криві ROC для найкращої моделі WNN-вейвлет (для кожного класу).

5. Висновки

Порівняння результатів ефективності різних моделей WNN для розглянутого набору даних у міжапацієнтній парадигмі показало, що моделі з функціями активації Морле, МН та Гауса мають найвищі характеристики точності та якості класифікації. Зокрема, модель WNN-Морле показала найвищу загальну точність 97,01% із середнім значенням макроточності (83,46%) та середнім значенням макрочутливості (90,58%), що свідчить про її високий баланс у розпізнаванні різних класів. Подібні показники продемонструвала модель WNN-МН із загальною точністю 96,91% та середнім значенням макрочутливості F1 86,67%. Модель WNN-Гауса мала найкраще значення середньої макроточності для всіх моделей (84,50%), демонструючи дуже високу однорідність прогнозування за класами. Загалом, отримані результати підтверджують ефективність використання більш плавних та адаптивних вейвлет-активаційних функцій (Морле, Гаусова, МН) у класифікації біомедичних сигналів у міжапацієнтних експериментах.

Отримані дані свідчать про те, що включення вейвлет-функцій як одиниць активації в нейронні мережі є перспективним для автоматизованого аналізу ЕКГ. Здатність певних вейвлетів досягати високих показників, особливо для конкретних класів аритмій, вказує на те, що властиві їм можливості частотно-часового аналізу можна ефективно інтегрувати в структуру глибокого навчання, що забезпечує ефективний, альтернативний механізм для виділення та представлення ознак порівняно зі стандартними згортковими або рекурентними шарами.

Література

- [1] Sörnmo, L., & Laguna, P. (2005). *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Academic Press.
- [2] Zhang, Q., & Benveniste, A. (1992). Wavelet networks. *IEEE Transactions on Neural Networks*, 3(6), 889–898.
- [3] Saragadam, V., Hoffmann, M., & Heckel, R. (2023). WIRE: Wavelet Implicit Neural Representations. *arXiv preprint arXiv:2301.05187*.
- [4] Moody, G.B., & Mark, R.G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45–50.
- [5] Association for the Advancement of Medical Instrumentation. (2008). *ANSI/AAMI EC57:1998 (R)2008, Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms*. Arlington, VA: AAMI.
- [6] de Chazal, P., O'Dwyer, M., & Reilly, R.B. (2004). Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, 51(7), 1196–1206.
- [7] Mallat, S. (2008). *A Wavelet Tour of Signal Processing* (3rd ed.). Academic Press.
- [8] Hannun, A.Y., Rajpurkar, P., Haghpanahi, M., Tison, G.H., Bourn, C., Turakhia, M.P., & Ng, A.Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory ECGs using a deep neural network. *Nature Medicine*, 25(1), 65–69.
- [9] Parvaneh, S., Rubin, J., Babaeizadeh, S., & Xu-Wilson, M. (2019). Analyzing the performance of different wavelet families for ECG denoising using neural networks. *Sensors (Basel)*, 19(4), 824.
- [10] Fathony, R., Willomitzer, F., Kolter, J.Z., & Raskar, R. (2021). Multiplicative Filter Networks. In *International Conference on Learning Representations (ICLR)*.

- [11] Daubechies, I. (1992). *Ten Lectures on Wavelets*. Philadelphia, PA: SIAM.
- [12] Alexandridis, A., & Zaprakis, A. (2013). Wavelet neural networks: A practical guide. *Neural Networks*, 42, 1–27.
- [13] Fazeli, S. (2025). *Heartbeat*. Kaggle Dataset.
- [14] Veitch, D. (2005). Wavelet Neural Networks and Their Application in the Study of Dynamical Systems.

Analysis of the use of activated wavelet functions in wavelet neural networks for categorizing ECG cardiac reductions

Ihor Dumyn, Adrian Nakonechnyi

Accurate and automated classification of heartbeats in an electrocardiogram (ECG) is fundamental to the diagnosis and treatment of cardiovascular diseases (CVD), but it remains a challenging task due to the complexity and variability of ECG signals [1]. This study examines the effectiveness of using various wavelet functions, including Morlet, Mexican Hat, Gabor, Shannon, and Gaussian, as activation functions in a wavelet neural network (WNN) architecture for ECG heart rate classification [3]. Using a publicly available dataset obtained from the MIT-BIH Arrhythmia and PTB Diagnostic ECG databases focusing on the 5-grade arrhythmia categorization based on the Association for the Advancement of Medical Instrumentation (AAMI) standard [5]. The key findings point to differences in the performance of different wavelet activation functions, emphasizing the potential benefits of using the inherent properties of time-frequency localization of wavelets to capture discriminative morphological features in ECG rhythms [7]. This work emphasizes the prospects of using wavelet-based activation functions to improve the accuracy and reliability of deep learning models in biomedical signal processing programs, including ECG analysis.

Отримано 06.07.2025