

В. А. Крилова, А. В. Івашко, О. О. Петренко

Національний технічний університет «Харківський політехнічний інститут», Харків, Україна

АНАЛІЗ ВАРІАБЕЛЬНОСТІ СЕРЦЕВОГО РИТМУ ЗА ДОПОМОГОЮ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

Анотація. У статті проведено стислий огляд та аналіз існуючих алгоритмів і програмних реалізацій діагностичних систем оцінки варіабельності серцевого ритму, що засновані на методах машинного навчання. Наведено переваги використання штучної нейронної мережі для класифікації типів електрокардіографічних сигналів, що забезпечує підвищення ефективності та якості функціональної діагностики серцевої діяльності. З метою виявлення найбільш ефективного варіанта побудови нейромережних блоків для апаратно-програмного комплексу аналізу варіабельності серцевого ритму запропоновано декілька варіантів реалізації побудови нейронної мережі. Здійснено аналіз методів та алгоритмів морфологічного аналізу електрокардіограми та наведено основні етапи проектування штучної нейронної мережі у якості класифікатора розпізнавання образів - RR-інтервалів.

Ключові слова: нейрона мережа, машинне навчання, варіабельність серцевого ритму, діагностика серцевих захворювань, RR інтервал

Вступ

Використання нейронних мереж для виявлення, розпізнавання та класифікації об'єктів, зображень, сигналів в умовах сучасних цифрових технологіях знаходить все більш широке поширення в різних сферах науки і техніки. Прикладом таких задач є аналіз електрокардіограм поданих у цифровій формі, що відкриває нові можливості для оцінки стану людини за певними показниками, а також дозволяє проводити діагностичні дослідження на новому рівні у реальному масштабі часу.

Великий відсоток захворювань людей пов'язаний із серцево-судинною системою. Тим часом, значну кількість проблем та ускладнень можна запобігти з допомогою неперервного моніторингу та постійного аналізу стану, зокрема знімаючи сигнали людського тіла та вчасно обробляючи їх. Одним із методів діагностики порушень серцево-судинної системи стосовно завдань профілактичної медицини є аналіз інформації про варіабельність серцевого ритму (ВСР) [1]. Оцінка ВСР заснована на математичному аналізі динаміки змін частоти серцевих скорочень. Оцінка діяльності серцево-судинної системи здійснюється шляхом реєстрації механічних, акустичних і біоелектричних проявів серцевої діяльності, найбільш доступних для реєстрації під час наркозу. Серед показників центральної та периферичної гемодинаміки найбільшу цінність представляють параметри серцевого ритму, артеріального і венозного тиску крові, серцевого викиду. Послідовний ряд кардіоінтервалів не є випадковим, а має складну структуру, що відображає важливі параметри серцево-судинної системи. Тому аналіз структури варіабельності серцевого ритму дає важливу інформацію щодо стану вегетативної регуляції серцево-судинної системи та організму в цілому. Зростаюча за законом Мура продуктивність сучасних обчислювальних систем та їх доступність відкрила нові можливості для обробки даних – використання раніше описаних математичних методів машинного навчання та систем штучного інтелекту. Такий підхід дозволив значною мірою виключити людину з

процесу опрацювання інформації та здобувати нові дані з вже наявних.

Штучні нейронні мережі (ШНМ) є системами обробки інформації, які відрізняються від звичайних систем паралельним характером передачі інформації та наявністю процесу саморегуляції для забезпечення заданої цільової функції. Зазначені властивості сприяють їх застосуванню у медичній діагностиці електрокардіосигналу, який несе інформацію про варіабельність ритму серця.

Основною метою статті є аналіз та дослідження методів для кластеризації сигналів електрокардіограм та застосування ШНМ для вирішення завдання з аналізу та класифікації типів варіабельності серцевого ритму, що забезпечує підвищення ефективності та якості функціональної діагностики серцевої діяльності в цілому.

Аналіз існуючих та перспективних рішень. У різноманітних дослідженнях аналіз ВСР за допомогою нейронних мереж використовується для виявлення проблем у роботі серця. Запропоновано багато методів для класифікації ЕКГ, які різняться підходами, точністю, швидкістю опрацювання та іншими показниками. Класичні методи аналізу ЕКГ та проведення проб з навантаженням досягли на даний момент певної межі своїх діагностичних можливостей. У зв'язку з цим значний інтерес викликають нові методи високої роздільності для обробки ЕКГ, що дозволяють виділити та проаналізувати компоненти ЕКГ-сигналу, які несуть додаткову інформацію.

У роботі [2] нейронні мережі було використано для автоматичної класифікації п'яти класів аритмій серця (нормакардія, шлуночкова екстрасистоля, мерехтіння шлуночків, миготлива аритмія та блокада серця). Автори використовували лінійні та нелінійні методи аналізу ВСР для навчання нейронної мережі. Отримані результати показують, що запропоновані методи є ефективними для класифікації порушень серцевого ритму з прийнятною точністю. Поєднання лінійних та нелінійних функцій разом із використанням класифікатором підвищує ефективність процесу класифікації.

Спектральний аналіз ЕКГ, який реалізується обробкою сигналу за допомогою перетворення Фур'є, є одним з найбільш розповсюджених. Але значним недоліком такого методу є те, що частотні компоненти не можуть бути локалізовані у часі, що не дозволяє досліджувати динаміку змін частотних параметрів сигналу. При використанні цього методу, при збільшенні вікна обробки сигналу, відбувається покращення роздільності за частотою, але погіршується за часом, і навпаки. Таким чином неможливо визначити для певного моменту часу які спектральні компоненти присутні в сигналі. Для вирішення цих проблем розроблено метод вейвлет-перетворення нестационарних сигналів. У роботі [3] описується саме такий класифікатор. Автори розробили метод розпізнавання відхилень ЕКГ від норми на основі спільного застосування дискретного вейвлет-перетворення та ШНМ. Запропоновано метод аналізу та класифікації ЕКГ, що полягає у вейвлет-аналізі сигналів та нейромережевому розпізнаванні образів на основі багатошарового перцептрону.

У статті [4] наведено методику класифікації сигналів з використанням нейронної мережі зустрічного розповсюдження та розглянуто моделі для класифікації випадкових та детермінованих сигналів. Також, у роботі було проведено дослідження залежності параметрів нейронної мережі від якості розпізнавання різних видів сигналів.

У роботі [5] представлені результати дослідження нейронних мереж для розпізнавання патологічних змін електричної активності серця. Проводилося порівняння багатошарового перцептрону та модульної структури організації нейронної мережі. Автори сформували дві бази даних: патологій серця та аритмій. Дані були згруповані у кілька основних класів та поділені ще на дві незалежні частини: навчальну та тестову. Усі ваги нейромережі ініціалізуються випадковими величинами з рівномірним розподілом. Для виключення впливу випадковості на результати навчання всі дії повторюються по 3 рази для кожного значення кількості нейронів прихованого шару структури нейромережі яка досліджується. Далі проводиться багаторазове навчання ШНМ із різним обсягом прихованого шару. Дослідження показали, що підвищена чутливість до патології, низька похибка та можливість необмеженого розширення числа патологій які аналізуються, робить наведену модульну структуру, ймовірно, оптимальним вибором для вирішення задачі аналізу електрокардіосигналу.

У роботі [6] автор запропонував підхід до побудови нейронної мережі на основі багатошарового перцептрона, що дозволяє провести більш точне розпізнавання. В роботі також проведено вибір відповідного алгоритму навчання, та показано, що для мережі типу багатошаровий перцептрон забезпечується прийнятний результат при використанні методу сполучених градієнтів та класичного алгоритму зворотного розповсюдження помилки. В роботі наведено результати експериментів з перевірки працездатності та ефективності розробленої нейронної мережі на різних об'єктах природного походження.

Наведений огляд варіантів застосування ШНМ для вирішення різних науково-практичних завдань свідчить про їх широкі можливості та перспективність подальшого розвитку впровадження нейромережевих технологій там, де ставиться завдання: виявлення, розпізнавання та класифікації об'єктів, сигналів та зображень. Нейронні мережі активно вивчаються як інструмент для аналізу різноманітних біомедичних сигналів, зокрема – електрокардіограм. Виходячи з аналізу досліджень, можна зробити висновок що основним засобом аналізу ВСР з використанням машинного навчання є використання класифікаторів та багатошарових перцептронів.

Методи дослідження

Як було вказано, ВСР є одним з найбільш опрацьованих та інформативних показників вегетативної активності. В основі багатьох систем скринінгу серця лежать алгоритми морфологічного аналізу ЕКГ: визначення положення R зубця і розташованих поруч Q- і S-зубців, які разом утворюють QRS комплекс (рис. 1).

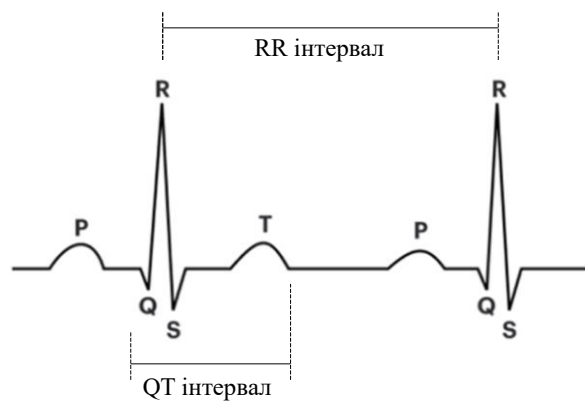


Рис. 1. RR інтервал на кардіограмі

Варіабельність серцевого ритму визначається як природні зміни інтервалів між серцевими скороченнями нормального ритму серця [7], які називаються RR (за позначенням R зубців) інтервалами. Іншими словами, це ступінь коливань тривалості інтервалів між синусовими комплексами, які зумовлені впливами відділів вегетативної нервової системи, а також гуморальними чинниками, навколо середнього рівня.

Дослідження варіабельності ґрунтується на вимірюванні інтервалів часу між R зубцями електрокардіограм та побудови на їх основі ритмограми з подальшим її аналізом за допомогою різних математичних методів. Непостійність інтервалу між кардіоциклами знаходиться у межах деякої середньої величини, що є оптимальною для обраного функціонального стану організму.

Через це варіабельність визначають у статичних станах організму, бо при будь-якій її зміні, частота серцевих скорочень починає теж змінюватись, підлаштовуючись під новий функціональний рівень – виникає перехідний процес, під час якого починають працювати системи, що не пов'язані з регулюванням ВСР організму.

Основні методи аналізу варіабельності серцевого ритму [7]:

1. **Статистичний метод** засновано на аналізі змін RR-інтервалів, а також на порівнянні показників, що дають кількісну оцінку варіабельності. При їх використанні кардіоінтервалограма роздивляється як сукупність послідовних проміжків часу – інтервалів RR. Статистичні дані включають SDNN, SDANN, RMSSD, pNN50, СКО (середньоквадратичне відхилення) та CV (коефіцієнт варіації).

2. **Геометричний метод** відображає розподіл RR – інтервалів. Метод використовує варіаційну пульсограму, за довжиною якої відкладаються значення RR – інтервалів, а по висоті – частота потрібних кардіоінтервалів (рис. 2). Суть геометричного методу (побудова гістограми) полягає у визначенні закону розподілу кардіоінтервалів як випадко-

вих величин. При цьому будується крива розподілу кардіоінтервалів (гістограма) та визначаються її основні характеристики:

- мода – значення кардіоінтервалу що зустрічається найбільш часто у даному динамічному ряді;
- варіаційний обсяг X – різниця між максимальним та мінімальним значенням RR – інтервалів. Відображає ступінь варіативності значень кардіоінтервалів у динамічному ряду що вивчається;
- триангуляційний індекс варіабельності серцевого ритму – загальна кількість RR-інтервалів, поділених на висоту гістограми всіх RR-інтервалів. Цей показник малочутливий до різного роду помилок, що виникають при поділі комплексів QRS на нормальні і ненормальні.

Тим самим знижуються вимоги до якості запису ЕКГ і її аналізу.




Рис. 2. Гістограма RR-інтервалів

3. **Спектральний аналіз ритму серця.** В основі методу лежить хвильова мінливість серцевого ритму, яка аналізується за допомогою перетворення Фур'є, що розбиває загальний спектр та її складові діапазони хвиль (табл. 1). Аналіз спектральної щільності потужності коливань дає інформацію щодо розподілу потужності в залежності від частоти коливань. Застосування спектрального аналізу дозволяє кількісно визначити різноманітні частотні складові коливань ритму серця та наочно графічно представити співвідношення різних компонентів серцевого ритму, що відображають активність визначених ланок регуляторного механізму. Виділяють три основних спектральних компонента, які відповідають коливанням ритму серця різної періодичності:

- High frequency (HF) – високочастотний компонент спектра, підвищується у стані спокою, під час сну, при гіпервентиляції, знижується – при фізичному навантаженні, стресі, різноманітних захворюваннях серцево-судинної системи;

- Low frequency (LF) – низькочастотний компонент спектра, у пацієнтів з тяжкою серцевою недостатністю виражена симпатична активація поєднується з істотним зниженням потужності LF;

- Very low frequency (VLF) – потужність хвиль дуже низької частоти, відображає активність повільно діючих гуморальних механізмів регуляції серцевого ритму, які зумовлюють закономірні зміни протягом тривалих проміжків часу (дні, тижні);

- Ultra Low Frequency (ULF) – ультра низькочастотні, які використовують для тривалих записів.

Таблиця 1 – Компоненти спектру

Назва компонента спектру	Частотний діапазон, Гц	Період, сек
HF	0,4-0,15	2,5-6,6
LF	0,15-0,04	6,6-25,0
VLF	0,04-0,015	25,0-66,0
ULF	Менше 0,015	Більше 66,0

4. **Метод кореляційної ритмограми** полягає у графічному відображенні послідовних пар кардіоінтервалів (попереднього та наступного) у двовірній координатній площині. При цьому по осі абсцис відкладається величина $R - R_n$, а по осі ординат – величина $R - R_{n+1}$. Графік та область точок, які отримано таким чином, є кореляційною ритмограмою або скатерограмою (scatter-розсіювання) (рис. 3).

Таким чином, метод кореляційної ритмографії більш компактно відображає лінію кардіоінтервалів, та незалежно від часу проведення дослідження – хвилини або години. Цей спосіб оцінки ВСР відноситься до методів нелінійного аналізу та є корисним для випадків, коли на фоні монотонності ритму зустрічаються рідкі та раптові порушення (ектопічні скорочення та (або) «випадіння» окремих серцевих скорочень).




Рис. 3. Скатерограма RR інтервалів – нормальний синусоїдальний ритм

Геометричні методи дозволяють оцінити фізіологічний стан людини з точки зору розпізнавання аритмій, коли методи статистичного, і спектрального аналізу варіабельності серцевого ритму малоінформативні або неприйнятні, в цьому випадку доцільно використовувати оцінку кореляційної ритмограми. Аналіз гістограми і скатерограми ритму серця є більш коректним для оцінки нестационарних процесів, які характерні для біологічних систем.

Особливості реалізації ШНМ для аналізу ВСР

Для побудови та проектування автоматизованої системи діагностики пацієнтів з серцево-судинними захворюваннями та оцінки ефективності застосування ШНМ для аналізу варіабельності серцевого ритму необхідно вирішити наступні питання.

1. Вибір та обґрунтування архітектури нейронної мережі. С початку задається кількість прихованих, вхідних та вихідних шарів та синаптичні зв'язки між нейронами. Як зазначалося вище, модель багатозарового перцептронну є найбільш широко вивченою, він складається з одного вхідного та одного вихідного шару, з одним або декількома прихованими шарами [8]. Таким чином, стандартна багатозарова нейронна мережа складається з трьох шарів вузлів, які з'єднані між собою за допомогою синаптичних ваг ω_{ij} та ω_{ik} , як зображено на рис. 4.




Рис. 4. Схема 5-3-2 багатозарової нейронної мережі

Вхідні блоки передають вхідні дані, так само як нелінійні вихідні одиниці кінцевого рівня отримують дані від кожного з блоків у прихованому шарі. Одиниці зміщення підключаються безпосередньо через вагові коефіцієнти зміщення до кожного з нейронів у прихованих і вихідних шарах. Топологія міжнейронних синаптичних зв'язків задається на етапі проектування мережі, але під час навчання та тестування системи, якщо потрібно, архітектура мережі може корегуватися.

2. Вибір функції активації нейрона мережі $f_\sigma(a)$ та алгоритмів навчання ШНМ. В якості активаційної функції кожного окремого нейрона була обрана безперервна сигмоїдальна біполярна функція [9]

$$f_\sigma(a) = \frac{1}{1 + e^{-a}}. \quad (1)$$

Цю функцію пропонується використовувати для синтезу ШНМ для аналізу ВСР.

Вихідні значення нелінійного нейрону отримуються за формулою:

$$\varphi = f_\sigma \left\{ \left(\sum_i \omega_i x_i \right) \right\}. \quad (2)$$

Після того як вихід нейронів одного шару під'єднано до входу іншого шару - буде сформована єдина нейронна мережа.

Але, оскільки аналіз ВСР відноситься до задачі класифікації сигналів, метою яких є визначення належності певного об'єкта до відповідного класу, доцільним є використання методів та алгоритмів навчання з вчителем.

Для цього необхідно задати відповідні ваги ω_{ij} та ω_{ik} для синаптичних зв'язків, які в процесі навчання мережі будуть корегуватися в залежності від відповіді ШНМ та навчальних значень.

Вхідні дані, що використовуються для навчання мережі (далі позначені як φ_i) подаються до мережі та поширюються скрізь неї, щоб отримати результат φ_k :

$$\varphi_k = f_\sigma \left(\sum_j \omega_{jk} f_\sigma \left(\sum_i \omega_{ij} \varphi_i \right) \right). \quad (3)$$

Під час навчання цільові дані або бажаний результат t_k , який асоціюється з навчальними даними, порівнюються з фактичним результатом φ_k . Після чого коригуються ваги ω_{jk} та ω_{ij} , для того щоб мінімізувати різницю між фактичним та цільовим значенням [10]. Ця різниця (похибка) визначається протягом усього навчання шаблонів p для навчального набору як

$$E = \frac{1}{2} \sum_p \sum_k \left(f_\sigma \left(\sum_j \omega_{jk} f_\sigma \left(\sum_i \omega_{ij} \varphi_i^p \right) \right) - t_k^p \right)^2. \quad (4)$$

Квадрат похибки E може бути мінімізованим за допомогою методу градієнтного спуску. Відповідний градієнт розраховується щодо кожної ваги ω_{ij} та ω_{jk} . Рівняння оновлення ваги для прихованих та вихідних шарів наступні:

$$\omega_{jk}^{(\tau+1)} = \omega_{jk}^\tau - \eta \frac{\delta E}{\delta \omega_{jk}}, \quad (5)$$

$$\omega_{ij}^{(\tau+1)} = \omega_{ij}^\tau - \eta \frac{\delta E}{\delta \omega_{ij}}, \quad (6)$$

де η – ступінь швидкості навчання.

Середньоквадратична похибка між кожним вхідним і вихідним шаблоном, підсумована за всіма шаблонами, є критерієм, який використовується під час навчання.

3. Формування тестових та навчальних вибірок RR-інтервалів. Для тренування та тестування нейронної мережі було використано набір даних MIT-BIH Arrhythmia Database придатний для завдань обробки сигналів ЕКГ. Згідно з описом баз даних на ресурсі PhysioNet, MIT-BIH містить півгодинні уривки двоканальних амбулаторних записів ЕКГ, отриманих від суб'єктів [11]. Записи оцифровані з частотою дискретизації 360 відліків на секунду на канал з 11-бітною роздільною здатністю (діапазон 10 мВ). Окрім власне кардіограм, база містить мітки класів типів серцевого ритму. В цілому, для навчання моделі нейронної мережі доцільно використовувати набір не менше ніж з 10 тисяч коротких (на більше 5 хв.) одноканальних записів ЕКГ пацієнтів з нормальним ритмом та різними відхиленнями. Для того щоб сформувавши ці фрагменти, було обрано випадковим чином двадцять три записи із набору 24 годинних амбулаторних записів ЕКГ, які зібрані у змішаній популяції стаціонарних та амбулаторних пацієнтів, 60% та 40% відповідно. Ще двадцять п'ять записів, були відібрані з того самого набору, щоб включити менш поширені, але клінічно значущі аритмії, які не були добре представлені в попередній випадковій вибірці.

4. Обробка ЕКГ та створення масиву нормованих RR-інтервалів. До того, як дані потрапляють на вхід нейронної мережі, вони проходять додаткову обробку і первинний аналіз. При аналізі ЕКГ, в першу чергу, важливим є періодичний QRS ком-

плекс, а саме R-зубець комплексу, є початком пульсової хвилі, тому вони дуже важливі в процесі аналізу ЕКГ, адже можна окремо визначити окремі хвилі та аналізувати їх. Оскільки QRS комплекс легко визначити за R зубцем, вікно у 0,5 секунди з обох боків зубця використовується для визначення початку кожного серцебиття та BCP можна визначити як інтервали між індексами QRS комплексів. Існує багато алгоритмів виявлення R зубця у QRS комплексі з ЕКГ, з них найбільш поширеними є алгоритм Пана і Томпкінса. Так як вхідні образи (значення R зубця) являються собою вектори різної довжини, необхідно виконати нормалізацію сигналів для приведення амплітуд у встановлений динамічний діапазон для вхідних значень нейронної мережі. Створення масиву нормованих RR-інтервалів відбувається з використанням нелінійної функції виду:

$$\tilde{x}_i = f \left(\frac{x_i - \tilde{x}_i}{\sigma_i} \right); \quad f(a) = \frac{1}{1 + e^{-a}}, \quad (7)$$

де $\tilde{x}_i = \frac{1}{p} \sum_{a=1}^p x_i^a$ –

середнє значення RR інтервалів;

$$\sigma_i^2 = \frac{1}{p-1} \sum_{a=1}^p (x_i^a - \tilde{x}_i)^2$$
 –

дисперсія.

Після такого перетворення значення RR-інтервалів розподіляються за законом, близьким до рівномірного, що теоретично має покращувати якість навчання нейронної мережі.

Далі значення RR-інтервалів підлягають математичному аналізу для отримання статистичних параметрів [12]:

- середнє значення RR-інтервалів;
- середнє значення серцевого ритму;
- стандартне відхилення величин нормальних інтервалів N-N протягом 24 год;
- стандартне відхилення різниці послідовних інтервалів N-N;
- відсоток послідовних інтервалів N-N, різниця між якими перевищує 50 мс.

Вихідним значенням методу є масив з розрахованими параметрами.

5. Визначення вихідних даних ШНМ для оцінки BCP. Вихідними даними є графіки кардіограм з позначеними R-зубцями, графік зміни довжини RR-інтервалів, а також текстові дані зі значеннями варіабельності та результатами її класифікації відповідно до відомих класів серцевого ритму та вірогідності приналежності до цього класу.

Для більш якісного навчання моделі нейронної мережі, вона потребує налаштування додаткових параметрів, які визначають також швидкість навчання, оцінку якості навчання, оптимізацію визначення та зсуву ваг нейронів. Окрім параметрів, які визначають як нейронна мережа буде працювати взагалі, потрібно також визначити, як вона буде обробляти дані, які надано для навчання. Щоб отримати якісь суттєві значення ваг нейронів, потрібно

кілька разів пройти навчання на тренувальному наборі даних (епохи). Мала кількість епох не дозволить якісно навчити перцептрон, велика – потребує великих втрат часу та обчислювальних ресурсів, а також призводить до перенавчання - ситуації коли мережа більше завчає тренувальні дані (разом з шумами), ніж фактично навчається. Для навчання перцептрон рекомендується 50 епох – подальше навчання не призводить до суттєвих змін у точності отриманої моделі.

Висновки

Нейромережевий аналіз має достатню гнучкість, забезпечує нелінійну обробку вихідних даних, має хорошу узагальнюючу здатність та можливість гнучкого навчання. Перевага застосування наведеного (модульного) варіанту нейронної мережі полягає в концентрації ресурсів кожного модуля на розпізнаванні лише одного класу, що має сприяти зменшенню ймовірності помилки та невірної висновку

для всієї системи загалом. Крім того, модульний варіант ШНМ системи дозволяє розширювати функціональні можливості шляхом збільшення кількості доступних для аналізу ВСП модулів без перенавчання всієї системи. Застосування існуючих методик знаходження оптимальної кількості нейронів у прихованому шарі для розглянутих структур ШНМ на основі забезпечення рівномірного розподілу значень чутливості, специфічності та точності по кожному класу, сприяють підвищенню ефективності роботи нейронної мережі та дають можливість вибору такого поєднання значень чутливості та точності, при яких забезпечується максимальна достовірність розпізнавання ВСП.

З метою пошуку оптимальних параметрів навчання необхідно провести додаткові експериментальні дослідження та порівняльний аналіз багатозарядного перцептрон та структури модульного варіанту ШНМ як можливих варіантів побудови системи нейромережевих блоків аналізу ВСП.

СПИСОК ЛІТЕРАТУРИ

1. Clifford G.D., Liu Ch., Moody B., Lehman L.H., Silva I., Li Q. 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.
2. Чернетченко Д.В., Мілих М.М., Луданов К.В. Апаратна реалізація імпульсної імпульсної штучної нейронної мережі для детектування параметрів електрокардіографічного сигналу (ЕКГ). Дніпропетровський національний університет ім. Олеся Гончара, Том 4, 2019 (275). DOI: 10.31891/2307-5732-2019-275-4-126-133
3. Tekeste T., Saleh H., Mohammad B., Khandoker A., Elnaggar M. A nano-watt ecg feature extraction engine in 65nm technology, IEEE Trans. on Circuits and Systems II: Express Briefs PP (99) (2017) 1–1. DOI: 10.1109/TCSII.2017.2658670.
4. Jain S., Ahirwal M., Kumar A., Bajaj V., Singh G. QRS detection using adaptive filters: A comparative study, ISA Transactions 66 (2017) 362–375. DOI: 10.1016/j.isatra.2016.09.023.
5. Лісун Ю.Б., Углев С.І. Варіабельність серцевого ритму, використання та методи аналізу. ДНУ «Центр інноваційних медичних технологій НАН України». № 4. 2020. DOI: 10.25284/2519-2078.4(93).2020.220693.
6. Karimipour M., Homaeinezhad R. Real-time electrocardiogram p-qrs-t detection delineation algorithm based on quality-supported analysis of characteristic templates, Computers in Biology and Medicine 52 (2014) 153–165. DOI: 10.1016/j.compbiomed.2014.07.002.
7. Kovalchuk M., Kharchenko V., Yavorskyi A. ECG signal classification using machine learning techniques. Bulletin of Taras Shevchenko National University of Kyiv. Series Physics & Mathematics 2022, 2 DOI: 10.17721/1812-5409.2022/2.9
8. Wu L., Xie X., Wang Y. (2021): ECG Enhancement and R-Peak Detection Based on Window Variability, “Healthcare” 2021, (Basel), 9 (2), P. 227; DOI: 10.3390/healthcare9020227.
9. Wiclaw L., Khoma Y., Fałat P., Sabodashko D., Herasymenko V. Biometric identification from raw ECG signal using deep learning techniques. In 2017 9th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS). Vol. 1. P. 129–133). DOI: 10.1109/IDAACS.2017.8095063
10. Goldberger A. L., Amaral A. N., Glass L. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research for complex physiologic signals. Circulation. 2000 Vol. 101. P. 215-220.
11. PhysioNet Content Overview URL: <https://physionet.org/about/content/>
12. Bailey J.A. et.al. Behavioral simulation and synthesis of biological neuron systems using synthesizable VHDL, Neurocomputing, Elsevier B.V., pp. 2392-2406, 2011. DOI: 10.1109/BMAS.2008.4751231.
13. Дудикевич В.Б., Хома В.В., Чекурін В.Ф., Хома Ю.В. Нормалізація сигналів ЕКГ для застосування в системах біометричної ідентифікації Інформатика, обчислювальна техніка та автоматизація. Том 30 (69) Ч. 1 № 4 2019. DOI: 10.32838/2663-5941/2019.4-1/10.

Received (Надійшла) 12.12.2023

Accepted for publication (Прийнята до друку) 07.02.2024

Heart rate variability analysis using artificial neural networks

Viktorii Krylova, Andrey Ivashko, Oleh Petrenko

Abstract. The article provides a brief review and analysis of existing algorithms and software implementations of diagnostic systems for assessing heart rate variability, based on machine learning methods. The advantages of using an artificial neural network to classify types of electrocardiographic signals are presented, which improves the efficiency and quality of functional diagnostics of cardiac activity. To identify the most effective option for constructing neural network blocks for the hardware-software complex for analyzing heart rate variability, several options for implementing the construction of a neural network have been proposed. An analysis of methods and algorithms for morphological analysis of an electrocardiogram is carried out and the main stages of designing an artificial neural network as a classifier for pattern recognition such as RR intervals are given.

Keywords: neuron, machine learning, heart rate variability, diagnosis of heart disease, RR interval.