

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
Харківський національний університет імені В. Н. Каразіна  
Факультет радіофізики, біомедичної електроніки та комп'ютерних систем

«До захисту»  
Завідувач кафедри фізичної і  
біомедичної  
електроніки та комплексних  
інформаційних технологій  
Д.ф.-м.н., доцент кафедри фізичної і  
біомедичної  
електроніки та комплексних  
інформаційних технологій

\_\_\_\_\_ Сергій БЕРДНИК  
“\_\_\_” \_\_\_\_\_ 20\_\_ року

**ДИПЛОМНА РОБОТА МАГІСТРА**

**«Нейромережевий аналіз електрокардіографічного сигналу»**

Науковий керівник  
к.т.н., доц.

\_\_\_\_\_ Ольга ВЕЛИЧКО

Виконав студент групи РЕ-61  
Спеціальності:  
153 Мікро- та наносистемна техніка  
освітньо-професійна програма «Фізична  
та біомедична електроніка»

\_\_\_\_\_ Володимир СВІЧКАРЬОВ

Харків 2023

# МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

Харківський національний університет імені В.Н.Каразіна

Факультет Радіофізики, біомедичної електроніки та комп'ютерних систем

Кафедра ФБМЕ та КІТ

Спеціальність 153 Мікро- та наносистемна техніка

Освітньо-професійна програма Фізична та біомедична електроніка

Рівень вищої освіти другий (магістерський)

**ЗАТВЕРДЖУЮ**

**Завідувач кафедри**

\_\_\_\_\_

\_\_\_\_\_

підпис  
ініціали, прізвище  
“ ”

\_\_\_\_\_ 20\_\_ року

## **З А В Д А Н Н Я НА ДИПЛОМНУ РОБОТУ**

СВІЧКАРЬОВ Володимир Віталійович

(прізвище, ім'я, по батькові студента)

1. Тема роботи НЕЙРОМЕРЕЖЕВИЙ АНАЛІЗ ЕКГ СИГНАЛУ

керівник роботи \_\_\_\_\_

( прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від “ \_\_\_ ” \_\_\_\_\_ 20\_\_ року № \_\_\_\_\_

2. Строк подання студентом роботи

3. Перелік питань, які потрібно розробити:

*3.1 Провести медико-технічне обґрунтування роботи (актуальність, загальні поняття про електрокардіографію, провести аналітичний огляд сучасних методів аналізу ЕКГ, визначити їх переваги та недоліки).*

3.2 Розробити блок аналізу ЕКГ на базі нейронної мережі (обґрунтувати вибір типу мережі, визначити її характеристики, розробити архітектуру).

3.3. Програмна реалізація блоку аналізу ЕКГ.

3.4 Провести чисельні експерименти на тестових сигналах (<https://physionet.org/about/database/>).

#### 4. План роботи

№ з/п	Назви етапів роботи
1.	Аналіз технічного завдання
2.	Огляд медико-технічної літератури
3.	Медико-технічне обґрунтування
4.	Розробка блоку аналізу ЕКГ
5.	Розробка алгоритмічного забезпечення
6.	Проведення чисельних експериментів
7.	Оформлення пояснювальної записки
8.	Підготовка до захисту

5. Дата видачі завдання \_\_\_\_\_

**Студент**

\_\_\_\_\_

\_\_\_\_\_

підпис

ініціали, прізвище

**Керівник роботи**

\_\_\_\_\_

\_\_\_\_\_

підпис

ініціали, прізвище

## РЕФЕРАТ

Свічкарьов В.В.. Нейромережевий аналіз електрокардіографічного сигналу. Кваліфікаційна робота магістра. Харківський національний університет імені В.Н.Каразіна, 2023, 78 с., 29 рис., 43 джерел.

Об'єкт дослідження – електрокардіографічний сигнал с порушеннями ритму серця.

Предмет дослідження – аналіз електрокардіограми для виявлення порушення ритму серця в режимі реального часу.

Мета роботи – для побудови нейремередвого класифікатору для виявлення фібриляції передсердь у сигналах ЕКГ.

Методи дослідження: штучні нейронні мережі рекурентного типу.

Результати дослідження: обгрунтовано застосування рекурентних нейронних мереж (RNN) з пам'яттю для автоматичного розпізнавання хвиль ЕКГ, походження ЕКГ сигналу виявилось ключовим етапом, а його елементи (P-, QRS-, та Т-хвилі) є основою для діагностики та моніторингу різноманітних патологій. Розроблен пакет програм у середовищі MatLab для побудови класифікатору для виявлення фібриляції передсердь у сигналах ЕКГ за допомогою штучної нейронної мережі Long Short-Term Memory.

Результати роботи можуть бути застосовані при розробці кардіологічних біотехнічних систем, орієнтованих на роботу в режимі реального часу.

## ABSTRACT

Svichkarev V.V.. Neural network analysis of electrocardiographic signal. Master's thesis. V. N. Karazin Kharkiv National University, 2023, 78 p., 29 figures, 43 sources.

Object of study - electrocardiographic signal with heart rhythm disturbances.

The subject of the study is the analysis of electrocardiograms to detect heart rhythm disturbances in real time.

Purpose: to build a neural network classifier for detecting atrial fibrillation in ECG signals.

Research methods: artificial neural networks of recurrent type.

Research results: the use of recurrent neural networks (RNN) with memory for automatic recognition of ECG waves is substantiated, the origin of the ECG signal has turned out to be a key stage, and its elements (P-, QRS-, and T-waves) are the basis for diagnosing and monitoring various pathologies. A package of programs in MatLab was developed to build a classifier for detecting atrial fibrillation in ECG signals using an artificial neural network Long Short-Term Memory.

Goten results can be used for the real time cardiac biotechnical systems design.

## ЗМІСТ

ВСТУП.....	7
1. МЕДИКО-ТЕХНІЧНЕ ОБҐРУНТУВАННЯ.....	9
1.1 Провідна система серця. Походження ЕКГ .....	9
1.2 Елементи ЕКГ сигналу, область застосування ЕКГ .....	14
1.3 Відведення для реєстрації .....	23
1.4 Огляд існуючих методів автоматичного розпізнавання хвиль ЕКГ .....	27
2 РЕКУРЕНТНІ НЕЙРОННІ МЕРЕЖІ.....	33
2.1 Рекурентні нейронні мережі з пам'яттю .....	33
2.2 Мережі Елмана .....	36
2.3 Мережі Гопфілда .....	39
2.4 Довга короткочасова пам'ять.....	41
2.5 Двонаправлена довга короткочасова пам'ять .....	44
3 КЛАСИФІКАЦІЯ СИГНАЛІВ ЕКГ ЗА ДОПОМОГОЮ МЕРЕЖ ДОВГОТРИВАЛОЇ КОРОТКОЧАСНОЇ ПАМ'ЯТІ.....	45
3.1 Опис експериментальних даних .....	45
3.2 Завантаження та дослідження даних.....	48
3.3 Підготовка даних для навчання.....	51
3.4 Навчання класифікатора на основі необроблених сигналів..	52
3.5 Визначення архітектури мережі LSTM .....	54
3.6 Навчання LSTM-мережі .....	56
3.7 Покращення продуктивності за допомогою вилучення ознак	60
3.8 Нормалізація даних .....	65
3.9 Модифікація архітектури мережі LSTM .....	66
3.10 Навчання LSTM-мережі з частотно-часовими характеристиками .....	67
ВИСНОВКИ.....	70
ПЕРЕЛІК ДЖЕРЕЛ.....	72

## ВСТУП

Згідно зі статистичними даними Всесвітньої організації охорони здоров'я щодо серцево-судинних захворювань, у світі близько 17 мільйонів смертей щорічно пов'язані з патологією серця і судин. Приблизно 80% цих смертей відбуваються в країнах з низьким і середнім рівнем доходу, де на медичне обслуговування одного жителя витрачається 15-20 доларів на рік. Лише кожна третя держава має програму з боротьби із серцево-судинними захворюваннями. Як правило, кошти вкладаються в дорогі процедури та лікувальні втручання. При цьому не залишається грошей для профілактики, що має величезний потенціал, на популяційному рівні. В Україні частка (%) смертей від захворювань системи кровообігу до загальної кількості померлих на 100 тис. осіб за останні 15 років неухильно зростає і становить, за оцінками експертів, понад 65 %. Ці дані свідчать про те, що необхідно вдосконалювати та оновлювати наявне медичне обладнання. Сучасні вимоги до автоматизованих систем діагностики такі, щоб мінімізувати помилки, зумовлені суб'єктивними факторами [1].

Відомо, що електрокардіограма - один із найскладніших сигналів, який під час автоматичного розшифрування та аналізу викликає найбільше труднощів і помилок. Це пояснюється також і тим, що форма сигналу сильно змінюється не тільки в різних відведеннях, а й при патологіях. Тому, на сьогоднішній день, завдання автоматичного розпізнавання елементів ЕКГ залишається як і раніше актуальним.

Діагностика серцево-судинної системи людини належить до числа найважливіших завдань кардіології. Основні причини

смертності людей у працездатному віці пов'язані із серцево-судинними захворюваннями. Цим зумовлена необхідність розробки та вдосконалення засобів моніторингу для об'єктивного оцінювання та прогнозування стану серцево-судинної системи. На даний момент електрокардіограма (ЕКГ) є найпоширенішим методом діагностики роботи серцево-судинної системи людини. Автоматичний аналіз електрокардіосигналу являє собою досить складну теоретичну проблему. Це насамперед пов'язано з фізіологічним походженням сигналу, яке зумовлює його недетермінованість, різноманітність, мінливість, непередбачуваність, нестационарність і схильність до численних видів перешкод. Комп'ютерний аналіз ЕКГ дедалі частіше застосовується в кардіологічній практиці. Водночас наявні комп'ютерні системи не забезпечують необхідної достовірності результатів діагностики. Така ситуація насамперед зумовлена помилками під час розпізнавання інформативних фрагментів ЕКГ, що відображають окремі стадії електричного збудження передсердь і шлуночків серця. Актуальним є питання підвищення точності методів аналізу ЕКГ шляхом морфологічного дослідження окремих елементів сигналу, таких як комплекс QRS. Шляхом застосування до нього різних видів аналізу і побудови, таким чином, залежності даних сигналу з наявністю будь-яких проблем у серцево-судинній системі.

Дипломну роботу присвячено питанням створення комп'ютерної підсистеми оброблення ЕКГ-аналізу, орієнтованої на роботу із сигналами, що не пройшли попереднього оброблення або містять перешкоди, зумовлені недоліками вимірювального пристрою.

## 1. МЕДИКО-ТЕХНІЧНЕ ОБҐРУНТУВАННЯ

### 1.1 Провідна система серця. Походження ЕКГ

Провідна система серця складеться из 2 вузлів та пучка Гіса. Синусовий вузол починає генерацію імпульсів. Анатомічно він розташовується в зоні правого передсердя. До основних функцій синусового вузла входить автоматизм, що дозволяю генерувати відповідну кількість імпульсів протягом 60 с. Вважається, що нормальний синусовий ритм міститься у межах 60-80 імпульсів на хвилину[1].




Рисунок 1.1 - Провідна система серця:

1 – синусово-передсердний вузол; 2 – передсердно-шлуночковий; 3 - передсердно-шлуночковий пучок; 4 - мережа волокон ніжок передсердно-шлуночкового пучка в стінці шлуночків; 5 - ніжки передсердно-шлуночкового пучка; 6 - міжшлуночкова перегородка; 7 - нижня порожниста вена; 8 - верхня порожниста вена; 9 - правий і 10 - лівий шлуночки; 11 - праве і 12 - ліве передсердя; 13 - передсердно-шлуночкові клапани [1].

При спонтанній генерації порушується нормальний ритм серця, внаслідок чого виникає деполяризація волокон во всіх відділах серця. Вважається, що функція автоматизму забезпечується синусовим вузлом, який при найбільшому автоматизмі називають автоматичним центром першого порядку. Збільшення та зменшення ритму, мабуть, відбуваються під впливом адренергічних і холінергічних впливів, обумовлених в основному зміною концентрації  $Ca^{2+}$ , наприклад, зниження концентрації позаклітинного кальцію призводить до збільшення автоматизму синусового вузла. Через особливості реєстрації ЕКГ, сигнал не відображає даних про процеси, що протікають у синусовому вузлі. Через тисячні долі секунди хвиля збудження передається по нервовим шляхам до правого, а трохи пізніше, і до лівого передсердь. Ці процеси відповідають хвилі Р на ЕКГ. По передсердях збудження поширюється не радіально, а переважно по трьох внутрішньовузлових шляхах, що з'єднує синусовий вузол з атріовентрикулярним вузлом.

Існує три нервових шляхи, що передають імпульси від синусового вузла до атріовентрикулярного. Через їх різну довжину виникають затримки у збудженні та послідовним скороченням передсердь.

Можна вважати, що хвиля збудження охоплює всю товщину стінок передсердь. Швидкість проходження становить 1 м/с. Відомо, що тканина міокарду, що належить до передсердь, містить деяку кількість клітин, які мають спроможність генерувати електричні імпульси для генерації ритму [1].

Від синусового вузла сигнал збудження передається до атріовентрикулярного вузла, або вузла Ашоффа-Тавари. Він

розташований у нижній частині правого передсердя праворуч від міжпередсердної перегородки біля гирла коронарного синуса, вдаючись у перегородку між передсердями та шлуночками. Його довжина 5 мм, товщина 2мм. Так само, як в синусовому вузлі, в ньому в основному є два види клітин - Р і Т. Від вузла направляються волокна на всі боки. Нижня частина вузла, тоншаючи, переходить в пучок Гіса.

На рівні атріовентрикулярного вузла хвиля збудження значно затримується. Це обумовлено електрофізіологічними особливостями провідної тканини атріовентрикулярного вузла. Швидкість проведення збудження по ній варіює від 5 до 20 см/с. Проходження збудження по атріовентрикулярному вузлу триває в середньому 0,08с [1].

Внаслідок сповільненої провідності і тривалого рефрактерного періоду атріовентрикулярний вузол виконує свою основну функцію фільтрує відповідні до нього імпульси. Крім того, він затримує проведення імпульсів. Через наявність повільних каналів  $Ca^{2+}$ , імпульс від кардіоміоциту має рефрактерний період, протягом якого клітина не спроможна реагувати (проводити або збуджуватись) на зовнішній електричний стимул. В цей час клітина вважається замкненою через неактивні канали  $Ca^{2+}$ , під час чого здійснюється конформація каналів. Після завершення їх відновлення, розпочинається процес деполяризації шлуночків. Саме довготривалий характер потенціалу дії кардіоміоцитів досягається синхронне скорочення клітин [2].

Між атріовентрикулярним вузлом і пучком Гіса немає чіткої межі. Пучок Гіса слідує за атріовентрикулярним вузлом і має три Гілки (ножки), кожна з яких закінчується волокнами Пуркін'є, що проводять електричні імпульси до верхніх та заднебазальних

відділів шлуночків. Початкова частина пучка Гіса не має контактів з скоротливим міокардом і дуже мало чутлива до ураження коронарних артерій. Однак вона порівняно легко втягується в патологічні процеси, що відбуваються в навколишньому пучок фіброзної тканини. Потім пучок Гіса переходить в мембранну частину міжшлуночкової перегородки і досягає м'язової її частини. У складі пучка Гіса є клітини Пуркін'є, покриті мембраною з колагенової тканини. Довжина пучка Гіса близько 20 мм. Атріовентрикулярний вузол та пучок Гісу називають атріовентрикулярним з'єднанням, до функцій яких входить автоматизм, об'єднання в атріовентрикулярне з'єднання, або атріовентрикулярну область. Атріовентрикулярне з'єднання має функцію автоматизму, виробляючи 40 – 60 імпульсів в 1 хвилину. Слід зазначити, що автоматизм атріовентрикулярного вузла не доведений, проте встановлено наявність центрів автоматизму в нижніх відділах передсердя і в пучку Гіса. Клітини водія ритму в передсердях, атріовентрикулярному вузлі і в пучку Гіса називають автоматичними центрами другого порядку. Швидкість проведення імпульсів в пучку Гіса становить 1 м/с.

Пучок Гіса розділяється спочатку на дві ніжки – праву і ліву, причому ліва ніжка коротше правої. Потім пучок Гіса утворює 3 гілки (Рисунок 1.2): праву ніжку і 2 гілки лівої ніжки пучка Гіса. Гілки пучку Гіса розташовуються в зоні міжшлуночкової перегородки. Права ніжка, яка є продовженням пучка Гіса, являє собою ізольований тонкий пучок, який проходить по правій стороні міжшлуночкової перегородки і направляється до м'яза правого шлуночка. Ліва ніжка пучку Гіса поділяється на задню та передню. Через те, що розмір лівої половини серця є більшим за праву, дві гілки охоплюють саме лівий шлуночок.




Рисунок 1.2 – Пучок Гіса

Ніжки гілок Гіса звужуються за довжиною та розгладжуються, поступово переходячи у тонкі нервові волокна Пуркін'є. Це забезпечують безпосередній контакт волокон з клітинами міокарду для передачі збуджувального імпульсу. Це синусовий вузол, що володіє найбільшим автоматизмом (Автоматичний центр першого порядку). Імпульси з синусового вузла досягають нижче розташованих джерел автоматизму до того, як в них закінчиться підготовка чергового імпульсу збудження, і руйнують цей процес підготовки [2].

Не зважаючи на те, що основи методу ЕКГ були закладені ще у 1897 році, ЕКГ не тільки продовжує активно розвиватись, але й є єдиним об'єктивним методом оцінки стану серцево-судинної системи. Метод дозволяє виявляти не тільки кардіологічні захворювання, але й розкривати їх біофізичне походження та електричні механізми, що лежать в основі захворювань. Найбільш поширеним застосуванням методу стала оцінка порушень ритму серця, які не можуть бути виявлені жодним інструментальним методом, крім ЕКГ. Це обумовлено їх електричним походженням [2].

## 1.2 Елементи ЕКГ сигналу, область застосування ЕКГ

ЕКГ - це електричний сигнал, що реєструється за допомогою системи відведень. Відведення - це схема накладання електродів. В залежності від того, що реєструється, розрізняють одно- та двополярні системи відведень. Сигнал, що реєструється - проекція сумарного дипольного моменту серця на ось відведення. Через особливості анатомічних структури серця, його положенням у просторі, системи відведень розроблені таким чином, щоб забезпечити отримання максимальної за амплітудою проекції сумарного дипольного моменту серця. Будь-яка ЕКГ складається з зубців, сегментів і інтервалів, що відображають складний процес реєстрації хвилі збудження по серцю. Крива ЕКГ має характерну форму, піки і інтервали між піками позначаються латинськими буквами P, Q, R, S, T і U (Рисунок 1.3).




Рисунок 1.3 – Форма сигналу ЕКГ

Для отримання ЕКГ сигналів в системах діагностики та

моніторингу використовується безліч різних систем відведень.

Зубець Р -це передсердний комплекс. Хвиля Р обумовлена скороченням передсердь і представляє на ЕКГ результат суперпозиції двох сигналів, зареєстрованих у відведенні від правого та лівого передсердь (Рисунок 1.3). Сигнал від правого та лівого передсердь алгебраїчно сумуються, на ЕКГ виникає хвиля Р. Зубець Р при відсутності порушень, амплітуда хвилі Р у відведенні І завжди позитивна та відрізняється від 0, що є інформативною ознакою синусового ритма. За амплітудою хвиля Р відрізняється найбільшим значенням у ІІ відведенні – зазвичай найбільш висока в другому стандартному відведенні там його легше вимірювати і виявляти його тривалість. У нормі його тривалість - 0,1с. Його ж амплітуда не повинна перевищувати 2,5мм. Амплітуда хвилі Р може коливатись за значеннями, зберігаючи позитивний знак у І, ІІ та aVF відведеннях. Через особливості накладення уніполярних підсилюваних відведень, його амплітуда буде завжди негативною у aVR (при відсутності порушень) [2].




Рисунок 1.4 – Походження зубця Р в нормі

Фізіологічний стан людини може впливати на амплітуду та форму хвилі Р у відведеннях ІІІ та aVL. За формою та значенням

хвиля Р може відрізнятись від нормальної при наявності порушень. Наприклад, зміни у проведенні електричного збудження призведуть до його розщеплення, зміни амплітуди або полярності. За умови застосування чутливої техніки для реєстрації ЕКГ, на його вершині можуть виникати комплекси піків (вважається, що в нормі, відстань між ними не повинна перевищувати 0.02 с).

При аналізі ЕКГ розглядають приховані показники, одним з яких є час розповсюдження збуджувальної хвилі від початку до кінця збудження. Це показник характеризується крутизною фронту хвилі Р. Цей показник вимірюється як тривалість переднього фронту хвилі Р.

У нормі, тривалість переднього фронту хвилі Р не повинен перевищувати 0.04 с. Збудження лівого передсердя починається пізніше за праве через час, який необхідний для доставки імпульсів по нервовим волокнам. На ЕКГ високого розрізнення можна розрізнити другий пік хвилі Р, який відповідає закінченню хвилі збудження лівого передсердя. Таким чином, час від початку хвилі Р до другого її піку відповідає часу збудження лівого передсердя, який не повинен перевищувати 0.06 с у нормі [2].

Ізоелектричний інтервал PQ виникає внаслідок передачі нервового імпульсу від синусового вузла до атріовентрикулярного. Протягом цього часу, не виникає жодних деполяризацій або реполяризаційних процесів у міокарді. Його тривалість характеризує стан нервових шляхів, за якими здійснюється передача імпульсу. У той же час, збудження атріовентрикулярного вузла частково співпадає за часом з кінцевим інтервалом скорочення передсердь

Відповідно до рекомендованих методик оцінювання ЕКГ, тривалість PQ вимірюють у тих відведеннях, у яких зареєстрована його максимальна тривалість. Але сучасні автоматичні методики

аналізу ЕКГ розраховують його як середнє значення від знайдених значень з усіх відведень.

Індекс Маркруза - це співвідношення  $T_r/T_{rQ}$ . Індекс Маркруза (у нормі 1,1 - 1,6 с) застосовується для виявлення гіпертрофічних змін передсердь.

Комплекс QRS виникає внаслідок скорочення шлуночків. Він характеризується наявністю трьох зубців: двох негативних з малою амплітудою та одного позитивного, який при відсутності порушень має максимальну амплітуду. За допомогою QRS зазвичай визначають частоту серцевих скорочень. При автоматичному аналізі використовують різні типи R-детекторів. Складною задачею іноді є розрізнення зубців у складі комплексу та визначення його границі (початок та кінець комплексу). Наявність різнополярних зубців у складі QRS обумовлена особливостями скорочення різних ділянок шлуночків, а саме-порядком їх збудження. Процес розповсюджується швидко. Під час скорочення шлуночків, 80% енергії серцевого скорочення витрачається саме на скорочення шлуночків. Це пояснюється тим, що кров, що виштовхується серцем, повинна мати відповідний імпульс (швидкість), щоб бути доставленою до самих віддалених відділів серцево-судинної системи (кінцівки)

Зубець R – зазвичай основний зубець ЕКГ. Він обумовлений порушенням шлуночків його амплітуда обумовлена розташуванням електричної осі серця.

Зубець S – в основному обумовлений порушенням підстави лівого шлуночка-це не постійний зубець і він може бути відсутнім в різних відведеннях.

Реполаризація (відновлення) шлуночків відповідає на ЕКГ хвилі Т. Протягом цього часу здійснюються конформаційні

перетворення іонних каналів кардіоміоцитів, внаслідок чого клітини не реагують на зовнішній вплив.

Зубець U - невеликий позитивний зубець, що реєструється іноді між T та P наступного циклу. Зазвичай, зубець U не враховується під час аналізу через його нерегулярне походження [2]. Припускають, що зубець U пов'язаний з потенціалами, що виникають при розтягуванні м'яза серця під час періоду швидкого припливу крові до серця. Наявність різко визначеної хвилі U пов'язують з недостатком калію.

Необхідність моніторингу ЕКГ під час анестезіологічного посібника, реанімації, інтенсивної терапії та діагностики не підлягає сумніву. Сигнал ЕКГ несе великий обсяг інформації, і детальний автоматичний аналіз сигналу ЕКГ пацієнта дозволяє своєчасно виробляти сигнали тривоги, що запобігають летальний результат, а так само робити прогностичні висновки. При обробці сигналу ЕКГ, маючи в руках сучасні обчислювальні ресурси, потрібно автоматично вести аналіз форми циклу сигналу ЕКГ (кардіоциклу), тобто автоматично розпізнавати характерні сегменти і визначати їх тимчасові і амплітудні параметри [2].

Виходячи з того, що форма нормального кардіоциклу в часі змінюється повільно, а кожен поточний кардіоцикл може бути спотворений артефактами і шумами, то розпізнавати характерні сегменти має сенс за деякою усередненої формі кардіоциклу. Усереднена форма (Рисунок 1.4) кардіоциклу розраховується на основі декількох (5-20) форм кардіоциклів пройшли процедуру кореляції один з одним. Потім відібрані форми кардіоциклів усереднюються поточечно. На наступних етапах проводиться розпізнавання форми (характерних точок і сегментів) кардіоциклу [2].




Рисунок 1.5 – Усереднена форма кардіоцикла

Багато реалізації алгоритмів цього етапу засновані на попередній сегментації сигналу форми, опису отриманих сегментів і подальшого аналізу цього опису, тобто це структурні алгоритми. Крім них використовують нейронні автомати, образний аналіз, а також порівняння із заздалегідь відомими еталонами характерних сегментів форми циклу – кореляційні алгоритми.

Розглянемо процедуру розпізнавання зубців структурних алгоритмів. Спочатку за сигналом усередненого кардіоциклу отримують деяку похідну функцію, яка полегшує сегментацію сигналу. Найбільш підходящою є функція енергії сигналу або хвильове перетворення. Потім отриманий похідний від форми кардіоциклу сигнал розбивається на елементарні ділянки – зубці. Кожен зубець, є трикутником з основою (початок і кінець зубця) і вершиною. Після цього складається список всіх зубців. Потім проводиться аналіз списку зубців, і в ньому знаходяться зубці представляють характерні сегменти сигналу форми кардіоциклу (P, QRS, T). Основою для цього аналізу служить формальний опис всіх можливих варіантів характерних сегментів [2].

Так само варто згадати і про хвильовому перетворенні. Матеріалом для такого аналізу служить хвильове перетворення

сигналу форми кардіоцикла (Рисунок 1.5) де позитивні значення енергії позначені зеленим, а негативні червоним кольором. Яскравість кольору показує потужність енергії. На малюнку 1.5 показані результати хвильового перетворення-масиви енергії сигналу:

- a)  $F=2$ ,
- b)  $F=7$ ,
- c) проекції масивів всіх частот  $F=1-8$ . Тобто ми маємо 8 одновимірних масивів потужностей енергії для різних частот. З огляду на, що частота дискретизації вихідного сигналу ЕКГ 200 Гц, то отримуємо діапазон частот 50-6.25 Гц [2].

Хвильове перетворення також дуже зручно використовувати для машинного розпізнавання.

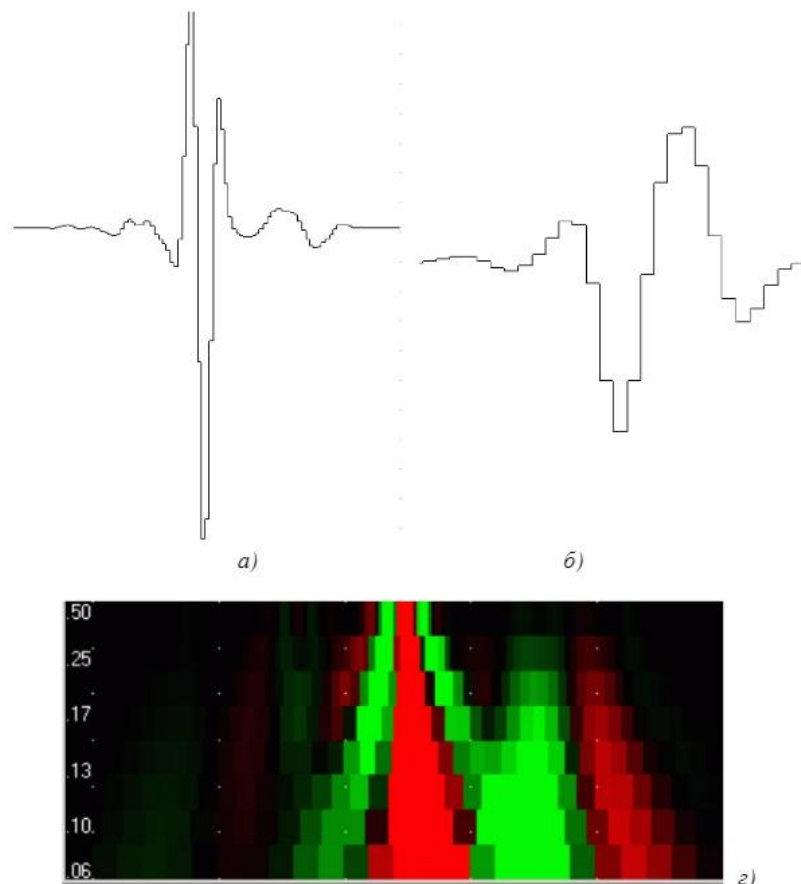


Рисунок 1.6 – Хвильове перетворення

Саме перетворення має наступну форму:

$$w_{ft} = \frac{1}{N\sqrt{2f}} \sum_{i=1}^n x_i \Psi\left(\frac{i-t}{F}\right) \quad (1.1)$$

Навчання системи розпізнавання виконується на основі інформації наданої після ручної розмітки форми кардіоциклу, тобто відомі координати положення початку і кінця сегментів P, QRS, T.

Така інформація може формуватися автоматизовано з використанням спеціально розробленого програмного забезпечення. Розмітку сегментів кардіоциклів повинен виробляти медичний фахівець в цій області, а краще використовувати декількох фахівців.

Для більш детального аналізу ЕКГ можуть застосовувати векторні електрокардіографи, які дозволяють отримати проєкції сумарного дипольного моменту серця на площини, що формулюються за допомогою електродів. Зареєстрований сигнал - векторна ЕКГ - має принципово іншу форму. Він складається із петель, кожна з яких відповідає хвилям звичайної ЕКГ. Їх просторова орієнтація, позиція та кути осей еліпсів, площина - є додатковими параметрами. Сучасні методики ЕКГ аналізу дозволяють розраховувати ВЕКГ за результатами звичайних ЕКГ, зареєстрованих у стандартних або додаткових відведеннях. Головним параметром, який має найбільшу інформаційну вагу є електрична ось серця, значення оцінюється як кут. Відхилення електричної осі від встановлених нормативних значень надає додаткову інформацію про стан провідної системи серця та процесам збудження клітин міокарда. Так, різке відхилення свідчить про інфаркти, ішемічні прояви або блокади

При аналізі ЕКГ зазвичай визначають початок та кінець кожної хвилі, її тривалість, амплітуду, крутизну переднього та заднього фронтів, тривалість сегментів та ізоелектричних інтервалів.

Співвідношення показників надає додатковий інструмент для розпізнавання порушень. При цьому, сучасні ардіологічні системи за замовченням мають функції оцінки варіабельності ритму серця - окремий аналіз ритму серця. Особливе значення для визначення окремих порушень має інтервал QT, нормальне значення якого розраховується за формулою Базета.

І навпаки, гіперкальціємія призводить до скорочення інтервалу QT. Провідність відбитого імпульсу з використанням інтервалу розраховується за допомогою комп'ютерної програми, що значно підвищує достовірність результатів.

Положення EOC розраховується від ізолінії в залежності від висоти зубця (зазвичай R завжди вище S), і якщо S перевищує R і вісь зміщена вправо, є порушення активності. Як і навпаки, якщо висота S у відведеннях II і III одночасно перевищує R з лівого боку правого шлуночка, підозрюють гіпертрофію лівого шлуночка.

Комплекс QRS, який утворюється при надходженні електричних імпульсів до м'язів шлуночка і визначає його активність (стандартом є відсутність патологічних зубців Q, ширина комплексу на 120 менше мілісекунди).

При відхиленні цього інтервалу говорять про блокаду (повну або часткову) ніжки пучка Гіса або про дефект провідності. Крім того, неповна блокада правої ніжки пучка Гіса є електрокардіографічним критерієм гіпертрофії правого шлуночка, а неповна блокада лівої ніжки пучка Гіса може вказувати на гіпертрофію лівого шлуночка. Сегмент ST (зазвичай розташований на ізолінії), який відображає фазу відновлення вихідного стану міокарда після повної деполяризації, та зубець T, асиметрію та його амплітуду, що характеризує висхідний процес бівентрикулярної реполяризації.

У вагітних жінок електрична вісь зміщується, тому що серце займає інше положення в грудній клітці. Також в залежності від тривалості збільшується навантаження на серце. Електрокардіограма при вагітності відображає ці зміни. Відмінний показник ЕКГ навіть у дітей. Вони «зростають» шаблонами, тому змінюються з віком. Лише після 12 років ЕКГ дитини починає наближатися до ЕКГ дорослого.




Рисунок 1.7 - ЕКГ здорової людини

### 1.3 Відведення для реєстрації

Для запису ЕКГ електроди лівої руки, правої руки та лівої ноги комбінуються, щоб отримати індиферентний електрод. Це так званий нульовий електрод. Зазвичай використовується 12 ліній (рис. 1.7). Вони об'єднані в дві групи: 6 відведень від кінцівок (осі знаходяться у фронтальній площині) і 6 грудних відведень (осі знаходяться в горизонтальній площині). Відведення від кінцівок поділяються на три біполярні відведення (стандартні відведення I, II і III) і три однополярні відведення (розширені відведення aVR, aVL і aVF).

aVF). У стандартному відведенні електроди кріпляться наступним чином: I - ліва рука і права рука, II - ліва нога і права рука, III - ліва нога і ліва рука. Посилений електрод містить активний електрод.

Для

відведення

права рука



права), для

відведення

рука (L -

відведення

нога (f) - стопа). Буква «V» в назві цих рядків означає, що вимірюється значення потенціалу (листка) під активним електродом, а буква «a» означає, що цей потенціал збільшено (посилено).



aVR -

(R -

aVL - ліва

ліва), для

aVF - ліва

Рисунок 1.8 – Шість відведень у фронтальній площині і шість в горизонтальній

Посилення досягається за рахунок того, що з нульового електрода виключають той електрод, який накладено на досліджувану кінцівку (наприклад, у відведенні aVF нульовим електродом служить об'єднаний електрод від правої руки і лівої руки).

На праву ногу завжди накладається заземлюючий електрод.

Щоб отримати грудні однополюсні відведення (Рисунок 1.8), електроди встановлюють в наступних точках:

- V1-четверте міжребер'я по правому краю грудини,
- V2-четверте міжребер'я по лівому краю грудини,
- V3-між V2 і V4,
- V4-п'яте міжребер'я по лівій середньключичній лінії;
- V5 і V6 - на тому ж рівні по вертикалі, що і V4, але, відповідно, по

передній і середній пахвовій лінії.

Індиферентним електродом служить звичайний нульовий електрод. ЕКГ в кожному відведенні являє собою проекцію сумарного вектора на вісь даного відведення. Таким чином, різні відведення як би дозволяють поглянути на електричні процеси в серці під різними кутами. Дванадцять відведень ЕКГ всі разом створюють тривимірну картину електричної активності серця; крім них іноді використовують додаткові відведення. Так, для діагностики інфаркту правого шлуночка використовують праві грудні відведення V<sub>3R</sub>, V<sub>4R</sub> та інші. Стравохідні відведення дозволяють виявити такі зміни електричної активності передсердь, які не видно на звичайній ЕКГ [2].




Рисунок 1.9 – Положення грудних електродів

Для телеметричного моніторингу ЕКГ зазвичай використовують одне, а для холтерівського - два модифікованих відведення.

Відведення Франка – формуються сімома електродами: два з них формують відведення Y і ставляться на шию і стегно; 4 електрода ставляться на рівні V міжребер'я, три з них (2, 4, 5) формують відведення X, сьомий електрод ставиться на спину і разом

з електродом 3 формує відведення Z. при холтеровському моніторингу оригінальна система накладення електродів по Франку дещо модифікується.

В обох варіантах відведення X формується білим і червоним проводами, Y - чорним і коричневим, Z - блакитним і помаранчевим.

ЕКГ по Небу – це модифікація електрокардіографічного дослідження серця, спрямованого на діагностику захворювань серцево-судинної системи. Модифікація полягає в особливостях накладення електродів на тіло обстежуваного. Для того щоб зняти ЕКГ по Небу, на грудну клітку обстежуваного накладається три електроди: перший (червоний) встановлюється в другому міжребер'ї праворуч від грудини; другий (жовтий) – в п'ятому міжребер'ї по задній пахвовій лінії зліва; третій (зелений) – п'яте міжребер'ї по серединно-ключичній лінії зліва. Така установка електродів дозволяє сформувати навколо серця нерівносторонній трикутник, сторони якого є проєкціями відведень електричної активності серця [2].

В ході ЕКГ по Небу (Рисунок 1.9) здійснюється запис трьох двополюсних відведень, які отримали буквене маркування – d (Dorsalis), a (Anterior) і I (Inferior). Зазначені відведення дозволяють зафіксувати такі зміни в міокарді, які практично не відображаються при стандартній електрокардіографії. Положення пацієнта-лежачи на спині. Точки контакту електродів обробляються фізіологічним розчином або спеціальним гелем. У приватних клініках використовуються одноразові, самоклеючі електроди. Після фіксації електродів відбувається безпосередньо запис ЕКГ. У цей момент пацієнту рекомендується розслабитися і спокійно дихати. Процес фіксації результат займає кілька хвилин. Обстеження найчастіше призначається при підозрі на заднебазальний інфаркт міокарда.

Діагностична цінність ЕКГ по Небу полягає в тому, що відведення А, D, і дозволяють зафіксувати патологічні зміни в тих ділянках міокарда, які не фіксуються при стандартній ЕКГ. Наприклад, відведення D найбільш інформативно при вогнищевих змінах в задній стінці лівого шлуночка, відведення а – при зміні в переднебокової стінці, відведення І дозволяє зафіксувати вогнища ішемії в нижніх відділах переднебокової стінки лівого шлуночка.




Рисунок 1.10 - Відведення по Небу

#### **1.4 Огляд існуючих методів автоматичного розпізнавання хвиль ЕКГ**

Автоматичний аналіз електрокардіосигналу являє собою досить складну теоретичну проблему. Це в першу чергу пов'язано з фізіологічним походженням сигналу, який обумовлює його недетермінованість, різноманітність, мінливість, непередбачуваність, нестаціонарність і схильність до численних видів перешкод. Комп'ютерний аналіз ЕКГ все частіше застосовується в кардіологічній практиці. У той самий момент існуючі комп'ютерні системи не забезпечують достатньої надійності у висновках діагностики. Ця проблема переважно пов'язана з помилками виявлення інформативних фрагментів ЕКГ, які відображають окремі етапи електричного збудження передсердь і шлуночків серця.

Актуальним є питання підвищення точності методів аналізу ЕКГ шляхом коректного визначення часових параметрів сигналу [3].

Програмне забезпечення має основне значення при побудові системи електрокардіографії високої роздільної здатності. Саме алгоритмічне і програмне забезпечення визначають функціональні можливості діагностики і в значній мірі правильність постановки діагнозу в цілому.

Можна виділити наступні загальні проблеми, властиві багатьом діагностичним системам ЕКГ високої роздільної здатності:

- складність обліку під час автоматичного аналізу ЕКГ відомостей, що не містяться в самій ЕКГ, але обов'язково (часто неявно) враховуються лікарем при інтерпретації ЕКГ;
- діагностичні помилки. Залежно від реалізації, система може бути схильна робити цілком певні помилки (гіпер або гіподіагностика певної групи ЕКГ - висновків) або взагалі не виявляти будь-яку електрокардіографічну патологію. Ймовірно, що поліпшення діагностики одного класу порушень може призвести до погіршення показників в інших класах;
- незручний користувальницький інтерфейс.

Виходячи з проведеного аналізу існуючих програмних засобів автоматичного аналізу ЕКГ, виявлені основні можливості, якими повинна володіти програма, що забезпечує аналіз і інтерпретацію сигналу ЕКГ:

- завантаження ЕКГ-сигналу і відображення його на екрані;
- розпізнавання характерних елементів ЕКГ;
- розміщення маркерів вузлових точок сигналу;
- автоматичне і ручне вимірювання інтервалів ЕКГ;
- вимірювання інформативних параметрів;

- аналіз варіабельності серцевого ритму;
- подання результатів аналізу в графічній формі;
- інтерпретація результатів аналізу інформативних параметрів;
- автоматичне формування інтерпретаційного повідомлення.

Під делінеаризацією ЕКГ-сигналу розуміється визначення в часі розташування характерних точок сигналу (зубців P, Q, R, S, T і меж зубців QRS, P, T). Періодичний характер ЕКГ-сигналу та його спектральних компонентів здебільшого виникають у відомих і розпізнаваних діапазонах частот, що робить ЕКГ хорошим кандидатом для багаторівневого розкладання за допомогою вейвлет-перетворення. Таким чином, алгоритм делінеаризації сигналу ЕКГ базується на математичному апараті вейвлет-аналізу. Біортогональний вейвлет «bior1.5» був обраний як материнський вейвлет. Масштабна функція цього вейвлета та графік вейвлет-функції показані на рисунку 1.10[3].




Рисунок 1.11 – Графіки Скейлінг та Вейвлет функцій

Вейвлет представляє собою симетричну функцію з компактним носієм, яка є першою похідною від скейлінг-функції та

має один нульовий момент. Ці характеристики роблять його особливо зручним для аналізу сигналу ЕКГ. У процесі багаторівневого розкладання сигналу (Рисунок 1.11) обчислюються коефіцієнти апроксимації "A<sub>j</sub>", що відображають згладжений сигнал, і коефіцієнти деталізації "D<sub>j</sub>", що характеризують високочастотні коливання сигналу. Вейвлет-перетворення з одним нульовим моментом можна розглядати як багаторівневий диференціальний оператор 1-го порядку для згладженого сигналу. У цьому контексті максимуми модуля вейвлет-перетворення відповідають максимумам модуля першої похідної згладженого сигналу. Точки перетину вейвлет-перетворення з нулем відображають положення локальних мінімумів і максимумів згладженого сигналу. Таким чином, точки перетину вейвлет-перетворення з нулем на першому масштабі відповідають положенням локальних екстремумів аналізованого сигналу. [3].




Рисунок 1.12 – Процес уточнення піків

Можлива з'ява значного числа нульових перетинів неподалік

від бажаного максимуму сигналу можлива через наявність перешкод. Оскільки кількість нульових перетинів зменшується при збільшенні масштабу, використовується підхід, де послідовно обчислюються перетини вейвлет-перетворення з нульовим значенням, просуваючись від великого масштабу до меншого. Це дозволяє відкинути шуми і артефакти. Інформація про локальні максимуми, мінімуми та точки перетину з нулем на різних масштабах використовується для ідентифікації значущих точок сигналу. На першому етапі визначається положення QRS-комплексів, а потім здійснюється пошук Q- і S-хвиль, встановлення меж QRS-комплексу та використання критеріїв для виключення шумів і артефактів.

У сучасний час існує безліч методів виділення і розпізнавання, які можна поділити на 5 основних груп в залежності від підходу: а) Алгоритми аналізу ЕКГ у часовій області. б) Алгоритми, що ґрунтуються на частотно-часових, включаючи нелінійні, перетворення сигналу ЕКГ. с) Алгоритми, які використовують нейромережеві моделі. d) Синтаксичні методи. e) Комбіновані алгоритми.

Алгоритми групи а базуються на застосуванні різних процедур, таких як лінійна фільтрація, використання фільтрів високої і низької частоти та нелінійних перетворень, включаючи інтегрування сигналу в ковзному вікні. Положення R-зубця визначається пороговим детектором рівня сигналу, значення якого можуть бути фіксованими або обчислюваними адаптивно.

Алгоритми групи б базуються на ряді процедур попередньої обробки ЕКГ з використанням різних частотно-часових перетворень, таких як локальне перетворення Фур'є, перетворення Карунена-Лоєва, дискретне вейвлет-перетворення. При використанні вейвлет-перетворення використовуються різні базові вейвлет-функції, іноді з

використанням зворотного зв'язку для корекції параметрів.

Алгоритми групи с використовують нейромережеві методи для аналізу морфології та класифікації елементів ЕКГ. Нейромережеві моделі дозволяють ефективніше адаптуватися до нестационарного характеру ЕКГ.

Групу d складають синтаксичні алгоритми, які представляють аналізований сигнал у вигляді послідовності примітивів, визначених спеціальними правилами (граматиками).

Групу e складають різноманітні комбінації методів, зазвичай є синтезом алгоритмів груп b і c або b і a. Поєднання цих підходів дозволяє досягти максимальної чутливості - 99,9% на тестових добірках ЕКГ, але вимагає значних обчислювальних ресурсів.

## 2 РЕКУРЕНТНІ НЕЙРОННІ МЕРЕЖІ

### 2.1 Рекурентні нейронні мережі з пам'яттю

Розглянемо такі речення:

“Джон і Грант разом пишуть книгу. Їм дуже сподобалося її писати.”

Людський розум легко визначить сенс займенників у другому реченні. Ви без зусиль зрозумієте, що займенник “їм” у другому реченні відноситься до авторів, а “її” - до книги, яку вони написали. Це легке завдання для вас, але дуже складне для нейронної мережі.

Згортковий класифікатор емоційного забарвлення, який ми створили у попередньому розділі, міг розглядати кожне слово в контексті всього лише двох сусідніх з кожного боку від нього. За такого невеликого вікна ця нейронна мережа не мала можливості зрозуміти, на що можуть посилатися займенники “їм” або “її”. Людський мозок здатен на це, тому що наші думки обертаються навколо одна одної, і ми постійно повертаємося до більш ранніх із них, щоб зрозуміти поточний контекст. У цьому розділі описана ідея рекурентних нейронних мереж, призначених саме для цього: в їхню структуру вбудовані цикли, які забезпечують збереження інформації з плином часу [4].




Рисунок 2.1 - Схематична діаграма рекурентної нейронної мережі

На рис. 2.1 показано узагальнену структуру рекурентної нейронної мережі (RNN). Фіолетова лінія ліворуч позначає петлю, якою інформація передається між кроками в мережі. Для кожного входу, так само як у повнозв'язаній мережі, є свій нейрон. Це видно на рис. 2.1 праворуч, де зображено структуру RNN у розгорнутому вигляді. Кожному слову в реченні відповідає свій рекурентний модуль (для стислості тут показано тільки перші чотири слова). Однак кожен модуль отримує додатковий вхід від попереднього, завдяки чому мережа може передавати інформацію з більш ранніх кроків у послідовності. У випадку, показаному на рис. 2.1, кожне слово представлено як окремий часовий крок, тож мережа здатна зрозуміти, що книжку писали “Джон” і “Грант”, і пов'язати ці поняття зі словом "they", що йде далі в цій послідовності [5].

Рекурентні нейронні мережі мають вищу обчислювальну складність на етапі навчання, ніж мережі прямого поширення, такі як повнозв'язані та згорткові мережі, які ми використовували до цього. Як показано на рис. 2.2, мережі прямого розповсюдження включають етап зворотного розповсюдження вартості в напрямку від вихідного шару до вхідного. Якщо мережа містить рекурентний шар (наприклад, SimpleRNN, LSTM або GRU), тоді вартість має поширюватися у зворотному напрямку не тільки від вихідного шару до вхідного, а й назад за часовими кроками рекурентного шару (від пізніших часових кроків до більш ранніх).

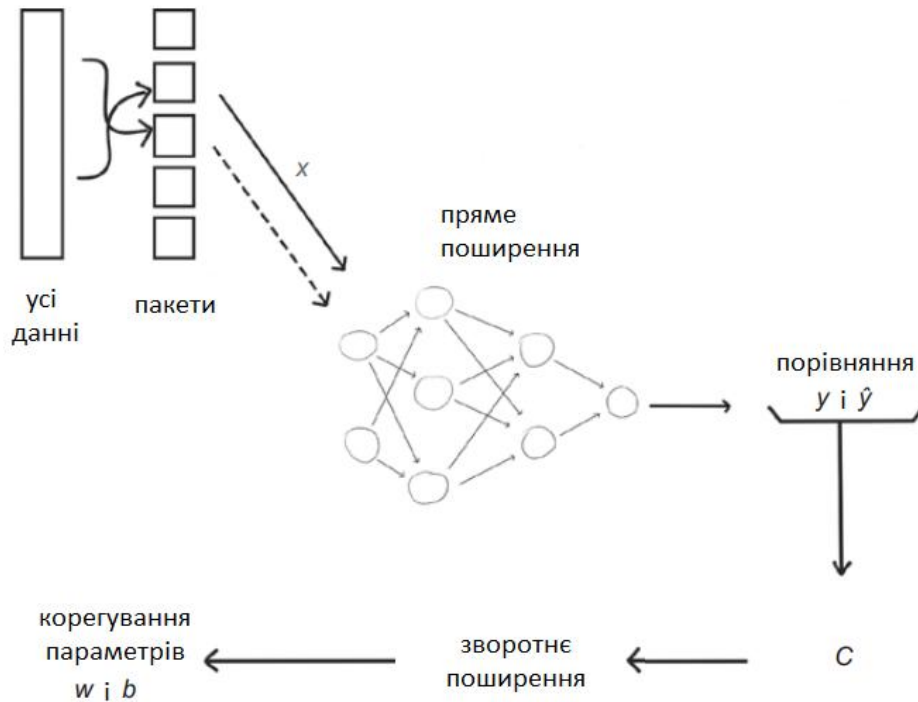


Рисунок 2.2 - Загальна схема процесу навчання нейронної мережі методом стохастичного градієнтного спуску. Увесь набір даних переміщується і розбивається на пакети. Кожен пакет передається через мережу; результат  $\hat{y}$  порівнюється з істинним  $y$  і обчислюється вартість  $C$ ; на етапі зворотного поширення обчислюються градієнти і коригуються параметри  $w$  і  $b$  моделі. Наступний пакет (позначений пунктирною стрілкою) поширюється вперед і так далі, поки всі партії не пройдуть мережею. Після передачі всіх партій завершується одна епоха, і процес починається знову з перемішування набору навчальних даних [4].

Зверніть увагу, що так само, як загасає градієнт під час зворотного поширення від пізніших прихованих шарів до більш ранніх (див. рис. 2.3), він загасає і під час зворотного поширення від пізніших часових кроків у рекурентному шарі до більш ранніх. Через це пізніші часові кроки сильніше впливають на результат, ніж більш ранні [5].




Рисунок 2.3 - Швидкість навчання глибокої мережі з п'ятьма прихованими шарами в різні епохи. П'ятий прихований шар, який найближче до виходу  $\hat{u}$ , навчається на порядок швидше, ніж третій

## 2.2 Мережі Елмана

Мережа Елмана - це структура, що складається з двох шарів, де прихований шар включає динамічний зворотний зв'язок. Це дозволяє врахувати історію спостережуваних процесів та збирати інформацію для розробки ефективної стратегії управління. Використання мереж Елмана розглядається в системах управління рухом об'єктів, у виробництві систем технічного зору та інших контекстах.

### 2.2.1 Архітектура мережі

Мережа Елмана представляє собою типову двошарову

структуру із зворотнім зв'язком від виходу до входу першого шару (рис. 2.4):

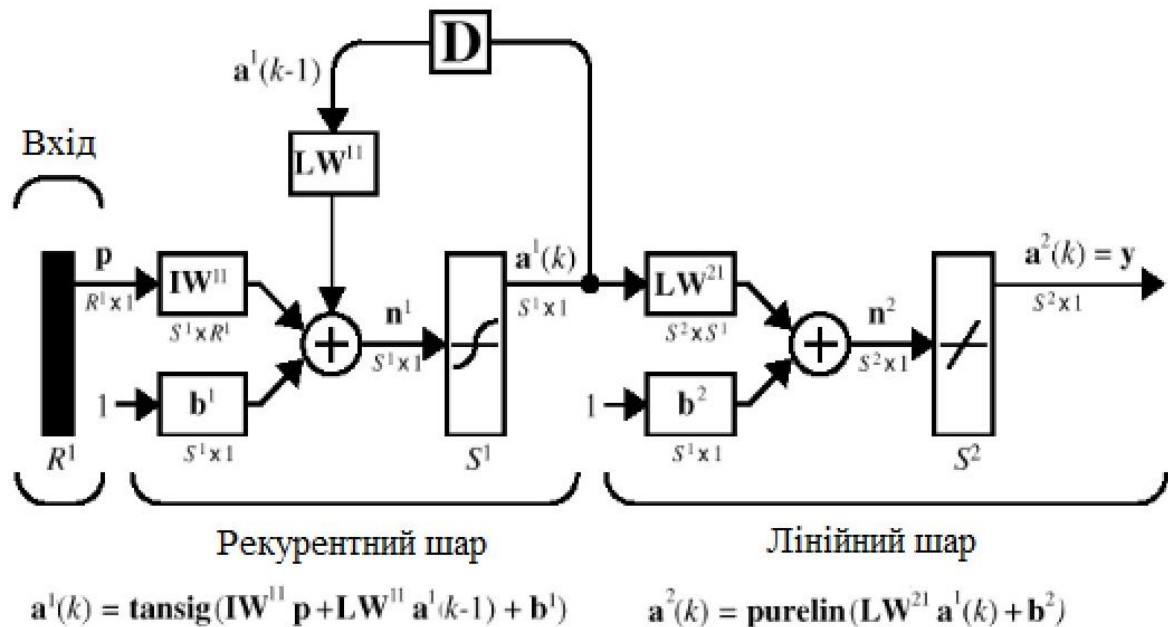


Рисунок 2.4 -Архітектура мереж Елмана [7]

Функції активації, які часто використовують у мережі Елмана, це *tansig* для прихованого рекурентного шару і *purelin* для лінійного шару. Таке поєднання дозволяє найточніше апроксимувати функції з обмеженим числом точок розриву. Головним вимогам до мережі є наявність достатньої кількості нейронів у прихованому шарі для ефективною апроксимації складних функцій.

Структурна схема мережі Елмана передбачає створення динамічного опису її рекурентного шару у вигляді системи рівнянь стану.

$$\begin{aligned} \mathbf{n}^1(k) &= \mathbf{LW}^{11} \mathbf{a}^1(k-1) + \mathbf{IW}^{11} \mathbf{p} + \mathbf{b}^1, \quad \mathbf{a}^1(0) = \mathbf{a}_0^1; \\ \mathbf{a}^1(k) &= \text{tansig}(\mathbf{n}^1(k)). \end{aligned} \quad (2.1)$$

Ця матрична форма рівнянь стану, яка включає рекурентний шар, відзначає та підкреслює назву досліджуваних нейронних

мереж [7].

Другий, лінійний шар є безінерційним і описується такими виразами:

$$\begin{aligned} n^2(k) &= \mathbf{LW}^{21} \mathbf{a}^1(k) + \mathbf{b}^2; \\ \mathbf{a}^2(k) &= \text{purelin}(\mathbf{n}^2(k)). \end{aligned} \quad (2.2)$$

### 2.2.2 Навчання мережі

Для навчання мережі Елмана можуть бути використані як процедура адаптації, так і процедура навчання, реалізовані за допомогою функцій `adapt` і `train` відповідно.

У процесі процедури адаптації на кожному кроці виконуються такі дії:

- моделювання мережі при поданні повного набору векторів входу та обчислення помилки мережі;
- обчислення наближеного градієнта функціоналу помилки щодо ваг і зміщень методом зворотного поширення помилки;
- настройка ваг з використанням функції налаштування, яку обирає користувач.

У процесі процедури навчання на кожному циклі виконуються такі дії:

- моделювання мережі при поданні послідовності вхідних сигналів, порівняння з цільовими виходами та обчислення помилки;
- обчислення наближеного градієнта функціоналу помилки щодо ваг і зміщень методом зворотного поширення помилки;
- настройка ваг з використанням функції налаштування, яку обирає користувач.

Мережі Елмана, через присутність зворотного зв'язку в рекурентному шарі, не завжди забезпечують високу точність розв'язання, оскільки обчислення точного градієнта функціоналу стає складним завданням [7].

### 2.3 Мережі Хопфілда

Цільовий вектор можна розглядати як набір характерних ознак об'єкта. Створюючи рекурентну мережу, у якій положення рівноваги збігається з цим цільовим вектором, можна отримати асоціативну пам'ять. Кожний вхід приводить мережу в рівноважний стан, дозволяючи асоціювати вхід із конкретним об'єктом. Таким чином, мережі Хопфілда належать до класу рекурентних нейронних мереж, які володіють властивістю збіжності до стійкої рівноваги, або атрактора, за кінцеву кількість тактів.

Процес проектування мережі Хопфілда передбачає створення рекурентної мережі з численними точками рівноваги, призначеними для того, щоб мережа при введенні початкових умов зрештою приходила у стан спокою в одній із цих точок. Властивість рекурентності полягає в тому, що вихід мережі подається назад на вхід. Очікується, що вихід встановиться в одній з точок рівноваги.

Метод синтезу мережі Хопфілда ґрунтується на побудові системи лінійних диференціальних рівнянь першого порядку, заданої в замкнутому гіперкубі простору станів, яка має розв'язки у вершинах цього гіперкуба. Ця модифікована мережа Хопфілда є спрощеною у порівнянні з класичною, але легше розуміється та проектується, і вважається більш доступною для реалізації [7].

### 2.3.1 Архітектура мережі

Архітектура модифікованої мережі Гопфілда представлена на рис. 2.5.:

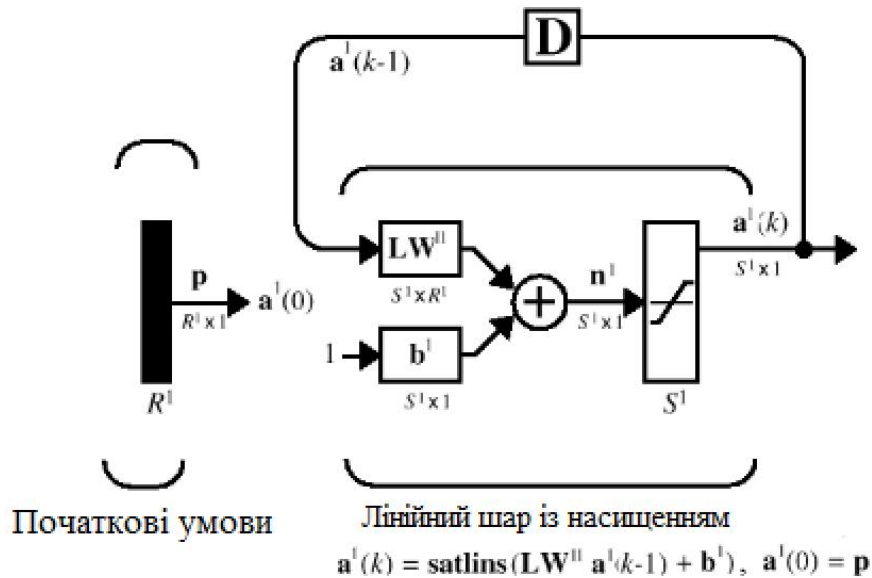


Рисунок 2.5 - Архітектура мереж Гопфілда

Вхід  $p$  встановлює значення початкових умов. У мережі застосовується лінійна функція активації з насиченням  $\text{satlins}$ , яка описується наступним чином:

$$a = \text{satlins}(n) = \begin{cases} -1, & n < -1; \\ n, & -1 \leq n \leq 1; \\ 1, & n > 1. \end{cases} \quad (2.3)$$

Ця мережа може бути промодельована з одним або великою кількістю векторів входу, які визначаються як початкові умови. Після визначення початкових умов мережа генерує вихід, який за допомогою зворотного зв'язку подається на вхід. Цей процес повторюється багато разів до тих пір, поки вихід не встановиться в положення рівноваги. Очікується, що кожен вектор виходу зрештою збіжиться до однієї з точок рівноваги, найближчої до вхідного сигналу [7].

Динамічна модель рекурентного шару модифікованої мережі Гопфілда описується:

$$\mathbf{a}^1(k) = \text{satlins}(\mathbf{LW}^{11} \mathbf{a}^1(k-1) + \mathbf{b}^1), \quad \mathbf{a}^1(0) = \mathbf{p}. \quad (2.4)$$

При детальному аналізі вказаного співвідношення можна переконатися, що матриця ваг є еквівалентною перехідній матриці динамічної системи, а вектор зсувів відповідає вектору передачі одиничного входу. Ці елементи необхідно сформулювати, якщо задано точки рівноваги системи  $t$  у вершинах гіперкуба.

## 2.4 Довга короткочасова пам'ять

Прості архітектури RNN можна використовувати, тільки якщо відстань між інформацією та контекстом, у якому вона необхідна, невелика (менше ніж 10 часових кроків). Однак якщо для розв'язання завдання потрібно враховувати ширший контекст (що часто має місце в завданнях NLP), краще використовувати рекурентні шари іншого типу: комірки довгої короткочасової пам'яті (Long Short-Term Memory, LSTM) [6].

Базова структура шару LSTM схожа на структуру простих рекурентних шарів, показану на рис. 2.1. Шари LSTM так само приймають послідовності вхідних даних (наприклад, лексеми з документа природною мовою), а також вхідні дані з попереднього моменту часу. Різниця лише в тому, що в кожній комірці в простому рекурентному рівні (наприклад, SimpleRNN()) є єдина функція активації, як-от  $\tanh$ , що перетворює вхідні дані комірки RNN на вихідні. Осередки в шарі LSTM, навпаки, мають набагато складнішу структуру, як показано на рис. 2.7.

Є кілька ключових моментів: Перший - стан комірки, що

перетинає LSTM у верхній її частині на рис. 2.7. Зверніть увагу, що стан комірки не проходить через будь-які нелінійні функції активації - він зазнає лише незначних лінійних перетворень і просто передається від комірки до комірки. Ці два лінійні перетворення (множення і додавання) є точками, в яких осередок у шарі LSTM може додати інформацію в стан для передання в наступний. У будь-якому разі перед додаванням інформації в стан комірки виконується сигмоїдна активація (позначена на малюнку буквою  $\sigma$ ). Оскільки сигмоїдна активація дає в результаті значення від 0 до 1, вона діє як вентиль, який визначає, чи буде нова інформація (з поточного часового кроку) додана у стан комірки чи ні [4].

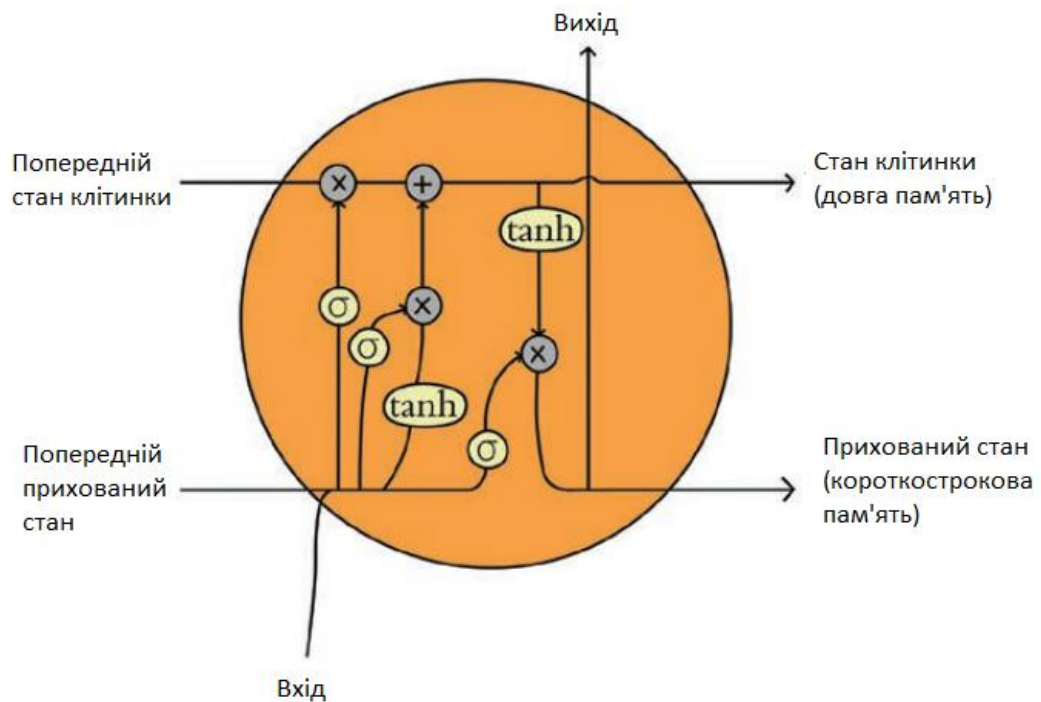


Рисунок 2.7 - Схематична діаграма LSTM

Нова інформація на поточному часовому кроці - це просте об'єднання вхідних даних для поточного часового кроку і прихованого стану з попереднього часового кроку [4].

Це об'єднання може бути включено в стан комірки лінійно або

після нелінійної активації, але як би там не було, саме сигмоїдний вентиль ухвалює рішення про об'єднання інформації.

Коли LSTM визначить, яку інформацію додати в стан комірки, інший сигмоїдний вентиль вирішить, чи буде інформація з поточного входу додано в кінцевий стан комірки. У результаті вийде вихід для поточного часового кроку. Зверніть увагу, що той самий вихід, але під іншою назвою ("прихований стан") передається наступній комірці LSTM (що представляє наступний часовий крок у послідовності), де об'єднується зі входом наступного часового кроку. Після цього процес повторюється, і кінцевий стан комірки (поряд із прихованим станом) передається в комірку, що представляє наступний часовий крок [6].

Ось як ще можна описати суть LSTM:

- Стан комірки дає змогу інформації зберігатися по всій довжині послідовності, у кожному часовому кроці в цій комірці LSTM. Це - довга пам'ять LSTM.
- Прихований стан аналогічний до рекурентних з'єднань у простій рекурентній мережі і відіграє роль короткочасової пам'яті LSTM.
- Кожна комірка представляє конкретну точку в послідовності даних (наприклад, конкретну лексему в документі природною мовою).
- На кожному часовому кроці ухвалюють кілька рішень (із використанням сигмоїдних вентилів) про відповідність інформації на цьому конкретному часовому кроці локальному (прихований стан) і глобальному (стан комірки) контекстам.
- Перші два вентиля визначають, чи належить інформація з поточного часового кроку до глобального контексту (стану комірки) і як її буде об'єднано в цей потік.
- Кінцевий вентиль визначає, чи належить інформація з поточного

часового кроку до локального контексту (необхідність її додавання у прихований стан, який роздвоюється і подається на вихід поточного часового кроку).

## **2.5 Двонаправлена довга короткочасова пам'ять**

Комірки з двонаправленою довгою короткочасовою пам'яттю (або Bi-LSTM) - це різновид комірок зі звичайною довгою короткочасовою пам'яттю. Якщо останні передбачають зворотне поширення тільки в одному напрямку (як правило, назад за часовими кроками, наприклад від кінця відкликання до початку), то осередки з двонаправленою довгою короткотерміновою пам'яттю реалізують зворотне поширення в обох напрямках (назад і вперед за часовими кроками) через деякий одновимірний вхід. Цей додатковий напрямок зворотного поширення подвоює обчислювальну складність, але якщо для вашого застосунку точність має першорядне значення, то такий підхід цілком виправданий: осередки Bi-LSTM часто використовують у сучасних застосунках NLP, тому що вони здатні виявляти шаблони до і після даної лексеми у вхідному документі та підвищувати ефективність моделі [4].

## 3 КЛАСИФІКАЦІЯ СИГНАЛІВ ЕКГ ЗА ДОПОМОГОЮ МЕРЕЖ ДОВГОТРИВАЛОЇ КОРОТКОЧАСНОЇ ПАМ'ЯТІ

### 3.1 Опис експериментальних даних

Конкурс PhysioNet/CinC Challenge 2017 має на меті заохотити розробку алгоритмів для класифікації на основі одного короткого запису відведення ЕКГ (тривалістю від 30 до 60 секунд), чи показує запис нормальний синусовий ритм, фібриляцію передсердь (ФП), альтернативний ритм або ж запис занадто зашумлений, щоб його можна було класифікувати.

Існують різні типи серцевих аритмій, які можна класифікувати:

- 1) Походженням: передсердна аритмія, миготлива аритмія або шлуночкова аритмія;
- 2) Частота: тахікардія ( $> 100$  уд/хв у дорослих) або брадикардія ( $< 60$  уд/хв у дорослих);
- 3) Механізм: автоматизм, повторний вхід, тригерний;
- 4) AV-провідність: нормальна, уповільнена, блокована;
- 5) Тривалість: нетривала (менше 30 с) або тривала (30 с або довше);

ФП визначається як "тахіаритмія, що характеризується переважно некоординованою активацією передсердь з подальшим погіршенням механічної функції передсердь" Американським коледжем кардіологів (ACC), Американською асоціацією серця (AHA) та Європейським товариством кардіологів (ESC) [13]. ФП є найпоширенішою стійкою серцевою аритмією, що зустрічається у 1-2% загальної популяції [14] і асоціюється зі значною смертністю та захворюваністю через зв'язок з ризиком смерті, інсульту, госпіталізації, серцевої недостатності та ішемічної хвороби серця тощо [15]. За оцінками, понад 12 мільйонів європейців і північноамериканців страждають на ФП, і її поширеність, ймовірно,

потроїться в найближчі 30-50 років [16]. Що ще важливіше, частота виникнення ФП зростає з віком, з менш ніж 0,5% у віці 40-50 років до 5-15% у віці 80 років [17].

Незважаючи на масштабність цієї проблеми, виявлення ФП залишається проблематичним, оскільки вона може мати епізодичний характер. Детектори ФП можуть належати до однієї з двох категорій: методи, що базуються на аналізі передсердної активності, або методи, що базуються на аналізі шлуночкової реакції. Детектори ФП на основі аналізу передсердної активності базуються на аналізі відсутності зубців Р або наявності фібриляторних зубців f в інтервалі TQ. Опубліковані методи для цього включають: нейронну мережу ехо-стану, виявлення на основі відсутності Р-хвилі (РWA), аналіз середньої кількості f-хвиль, додаток для кардіомонітора, що базується на Р-хвилях, вейвлет-ентропію та вейвлет-енергію [24]. Детектори ФП на основі аналізу передсердної активності можуть досягти високої точності, якщо записані ЕКГ-сигнали мають низький рівень шумового забруднення і високу роздільну здатність, але, як правило, непропорційно страждають від шумового забруднення. На відміну від цього, аналіз відповіді шлуночків ґрунтується на передбачуваності інтервалів між ударами ("RR-інтервалів") комплексів QRS в ЕКГ. Інтервали RR походять від найбільш очевидної великої амплітуди в ЕКГ, R-зубця, виявлення якого може бути набагато більш стійким до шуму. Тому цей підхід може бути більш придатним для автоматичного виявлення ФП в режимі реального часу [25]. Опубліковані методи включають: Аналіз графіків Пуанкаре, аналіз графіків Лоренца, аналіз кумулятивних функцій розподілу, порогове значення медіани абсолютного відхилення (MAD) RR інтервалів, гистограма першої різниці RR інтервалів, мінімум виправленої умовної ентропії

послідовності RR інтервалів, 8-тактовий детектор нерівномірності RR інтервалів з ковзним вікном, символічна динаміка та ентропія Шеннона [33], ентропія вибірки RR інтервалів, нормована нечітка ентропія RR-інтервалів [37].

Варто зазначити, що детектори ФП, які поєднують як передсердну активність, так і відповідь шлуночків, можуть забезпечити покращену продуктивність за рахунок об'єднання незалежних даних з кожної частини серцевого циклу. Такі підходи до виявлення включали: Марковське моделювання інтервалу RR у поєднанні з варіабельністю інтервалу PR та мірою подібності морфології P-хвилі, а також метод нечіткої логічної класифікації, який використовує поєднання нерегулярності інтервалу RR, відсутності P-хвилі, наявності f-хвилі та рівня шуму [39]. Варто також зазначити, що багатовимірні підходи, засновані на машинному навчанні, які поєднують декілька з вищезазначених окремих ознак, також можуть забезпечити покращене виявлення ФП [40; 41].

Попередні дослідження щодо класифікації ФП, як правило, обмежені в застосуванні, оскільки 1) проводилася лише класифікація нормальних ритмів і ритмів ФП, 2) хороші результати були показані на ретельно відібраних, часто чистих даних, 3) не використовувався окремий не вибірковий набір тестових даних або 4) використовувалася лише невелика кількість пацієнтів. Достовірно виявити ФП за одним коротким відведенням ЕКГ досить складно, а широка таксономія ритмів робить це особливо важким завданням. Зокрема, багато ритмів, не пов'язаних з ФП, мають нерегулярні інтервали RR, які можуть бути схожими на ФП. У цьому челленджі ми розглядаємо всі аномальні ритми, не пов'язані з ФП, як один клас і вимагаємо від учасника класифікувати їх як 1) нормальний

синусовий ритм, 2) ФП, 3) інший ритм або 4) занадто шумний для класифікації.

### 3.2 Завантаження та дослідження даних

Робота виконується у MatLab. Для доступу та завантаження даних з бази даних розробимо скрипт скрипт ReadPhysionetData, щоб завантажити дані з веб-сайту PhysioNet і згенерувати MAT-файл (PhysionetData.mat), який містить сигнали ЕКГ у відповідному форматі. Застосовувати умовний оператор, який запускає скрипт тільки в тому випадку, якщо файл PhysionetData.mat ще не існує в поточній папці.

```
if ~isfile('PhysionetData.mat')
    ReadPhysionetData
end
load PhysionetData
```

Операція завантаження додає до робочої області дві змінні: Сигнали і Мітки. Сигнали - це масив комірок, який містить сигнали ЕКГ. Мітки - це категоріальний масив, який містить відповідні мітки істинності сигналів.

```
Signals(1:5)
ans=5×1 cell array
    {1×9000 double}
    {1×9000 double}
    {1×18000 double}
    {1×9000 double}
    {1×18000 double}
```

```
Labels(1:5)
ans = 5×1 categorical
```

N  
N  
N  
A  
A

Застосовувати функцію підсумовування, щоб побачити, скільки сигналів AFib і нормальних сигналів міститься в даних.

```
summary(Labels)
```

A 738

N 5050

Для візуалізації побудуємо гістограму довжин сигналів. Більшість сигналів мають довжину 9000 відліків.

```
L = cellfun(@length, Signals);
h = histogram(L);
xticks(0:3000:18000);
xticklabels(0:3000:18000);
title('Signal Lengths')
xlabel('Length')
ylabel('Count')
```

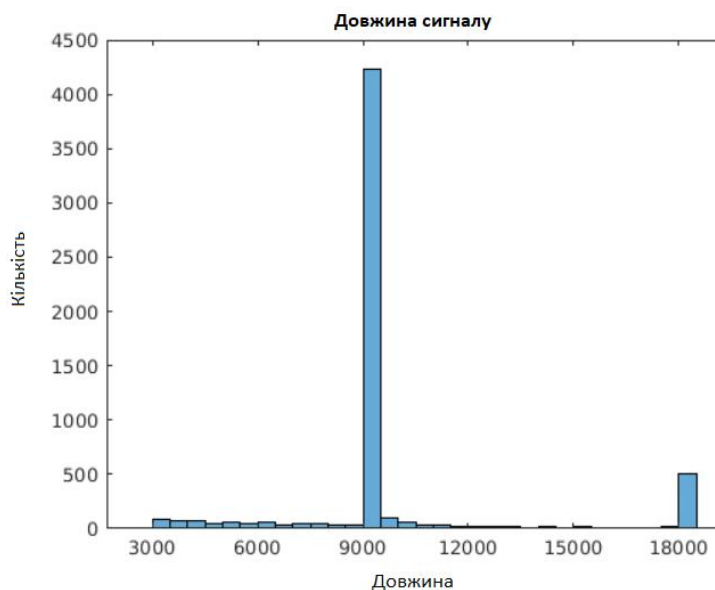


Рисунок 3.1 - Діаграма довжини сигналу

Візуалізувати відрізок одного сигналу з кожного класу. Серцебиття AFib розташовані через нерегулярні проміжки часу, тоді як нормальні серцебиття відбуваються регулярно. Сигнали серцебиття AFib також часто не мають зубця P, який пульсує перед комплексом QRS у нормальному сигналі серцебиття. На графіку нормального сигналу видно зубець P і комплекс QRS.

```

normal = Signals{1};
aFib = Signals{4};

subplot(2,1,1)
plot(normal)
title('Normal Rhythm')
xlim([4000,5200])
ylabel('Amplitude (mV)')
text(4330,150,'P','HorizontalAlignment','center')
text(4370,850,'QRS','HorizontalAlignment','center')

subplot(2,1,2)
plot(aFib)
title('Atrial Fibrillation')
xlim([4000,5200])
xlabel('Samples')
ylabel('Amplitude (mV)')

```

У даному коді створюються два графіки, на яких відображаються сигнали - один для нормального ритму, інший для мерцання передсердь. Для кожного графіка задається заголовок, встановлюється обмеження по осі X.

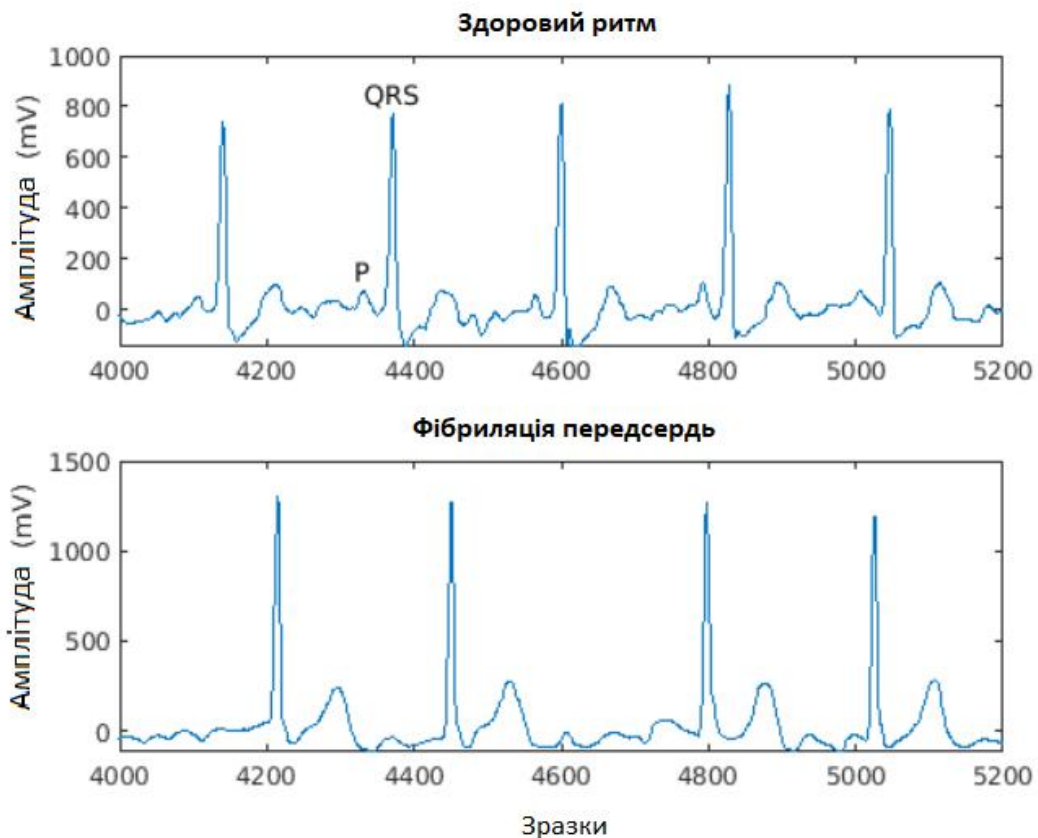


Рисунок 3.2 - ЕКГ сигнали здорового пацієнта та с фібриляцією передсердь

### 3.3 Підготовка даних для навчання

Під час навчання функція `trainNetwork` розбиває дані на міні-пакети. Потім функція додає або обрізає сигнали в одній міні-пачці, щоб всі вони мали однакову довжину. Надмірне додавання або усікання може негативно вплинути на продуктивність мережі, оскільки мережа може неправильно інтерпретувати сигнал на основі доданої або видаленої інформації.

Щоб уникнути надмірного заповнення або усічення, треба застосувати функцію `segmentSignals` до сигналів ЕКГ, щоб усі вони мали довжину 9000 відліків. Функція ігнорує сигнали з довжиною менше 9000 відліків. Якщо сигнал має більше 9000 відліків,

segmentSignals розбиває його на якомога більше сегментів по 9000 відліків і ігнорує решту відліків. Наприклад, сигнал з 18500 відліків перетворюється на два сигнали по 9000 відліків, а решта 500 відліків ігноруються. [Signals,Labels] = segmentSignals(Signals,Labels);

Можна передивитися перші п'ять елементів масиву Signals, щоб переконатися, що кожен запис тепер має довжину 9000 відліків.

```
Signals(1:5)
```

```
ans=5×1 cell array
```

```
{1×9000 double}
```

```
{1×9000 double}
```

```
{1×9000 double}
```

```
{1×9000 double}
```

```
{1×9000 double}
```

### 3.4 Навчання класифікатора на основі необроблених сигналів

Для побудови класифікатора взяти необроблені сигнали, згенеровані в попередньому розділі. Розділити сигнали на навчальний набір для навчання класифікатора і тестовий набір для перевірки точності класифікатора на нових даних.

Використовувати функцію підсумовування, щоб показати, що співвідношення сигналів AFib до сигналів Normal становить 718:4937, або приблизно 1:7.

```
summary(Labels)
```

```
A    718
```

```
N   4937
```

Оскільки близько 7/8 сигналів є нормальними, класифікатор зрозуміє, що може досягти високої точності, просто класифікуючи всі сигнали як нормальні. Щоб уникнути цього зсуву, доповнити

дані AFib дублюванням сигналів AFib у наборі даних так, щоб у ньому була однакова кількість нормальних і AFib сигналів. Таке дублювання, яке зазвичай називають передискретизацією, є однією з форм доповнення даних, що використовується в глибокому навчанні.

Розділити сигнали відповідно до їхнього класу.

```
afibX = Signals(Labels=='A');
afibY = Labels(Labels=='A');

normalX = Signals(Labels=='N');
normalY = Labels(Labels=='N');
```

Далі, використовуючи дільник, випадковим чином розділити цілі з кожного класу на навчальну та тестову множини.

```
[trainIndA,~,testIndA] = dividerand(718,0.9,0.0,0.1);
[trainIndN,~,testIndN] = dividerand(4937,0.9,0.0,0.1);

XTrainA = afibX(trainIndA);
YTrainA = afibY(trainIndA);

XTrainN = normalX(trainIndN);
YTrainN = normalY(trainIndN);

XTestA = afibX(testIndA);
YTestA = afibY(testIndA);

XTestN = normalX(testIndN);
YTestN = normalY(testIndN);
```

Тепер для навчання є 646 сигналів AFib і 4443 звичайних сигналів. Щоб досягти однакової кількості сигналів у кожному класі, взяти перші 4438 нормальних сигналів, а потім за допомогою `hermat` повторити перші 634 сигнали AFib сім разів.

Для тестування є 72 сигнали AFib і 494 сигнали Normal. Взяти перші 490 нормальних сигналів, а потім за допомогою `hermat` повторити перші 70 сигналів AFib сім разів. За замовчуванням

нейронна мережа випадковим чином перемішує дані перед навчанням, щоб переконатися, що суміжні сигнали не мають однакових міток.

```
XTrain = [repmat(XTrainA(1:634),7,1); XTrainN(1:4438)];
YTrain = [repmat(YTrainA(1:634),7,1); YTrainN(1:4438)];

XTest = [repmat(XTestA(1:70),7,1); XTestN(1:490)];
YTest = [repmat(YTestA(1:70),7,1); YTestN(1:490)];
```

Розподіл між сигналами Normal та AFib тепер рівномірно збалансований як у навчальній, так і в тестовій вибірці.

```
summary(YTrain)
```

```
  A   4438
```

```
  N   4438
```

```
summary(YTest)
```

```
  A   490
```

```
  N   490
```

### 3.5 Визначення архітектури мережі LSTM

LSTM-мережі можуть вивчати довгострокові залежності між часовими кроками даних послідовності. У цьому прикладі використовується двонаправлений LSTM-шар `bilstmLayer`, оскільки він розглядає послідовність у прямому і зворотному напрямках.

Оскільки вхідні сигнали мають по одному виміру, вказати розмір вхідних даних як послідовності розміру 1. Вказати двонаправлений LSTM-шар з вихідним розміром 100 і вивести останній елемент послідовності. Ця команда вказує двонаправленому шару LSTM розбити вхідний часовий ряд на 100 елементів, а потім готує вихід для повністю з'єднаного шару. Далі

вказати два класи, включивши повністю з'єднаний шар розміру 2, а потім шар softmax і шар класифікації.

```
layers = [ ...
    sequenceInputLayer(1)
    bilstmLayer(100, 'OutputMode', 'last')
    fullyConnectedLayer(2)
    softmaxLayer
    classificationLayer
]
```

```
layers =
    5x1 Layer array with layers:
```

1	''	Sequence Input	Sequence input with 1 dimensions
2	''	BiLSTM	BiLSTM with 100 hidden units
3	''	Fully Connected	2 fully connected layer
4	''	Softmax	softmax
5	''	Classification Output	crossentropyex

Даний блок коду створює нейронну мережу для класифікації послідовностей даних з використанням бідирекційного LSTM шару. Мережа має вхідний шар для послідовностей, бідирекційний LSTM для врахування контексту в обидва напрямки, повністю з'єднаний шар і функцію активації softmax для отримання ймовірностей класів.

Далі задати параметри навчання для класифікатора. Встановити "MaxEpochs" на 10, щоб дозволити мережі зробити 10 проходів через навчальні дані. "MiniBatchSize", рівний 150, змушує мережу розглядати 150 навчальних сигналів за один раз. Значення 'InitialLearnRate' 0.01 допомагає прискорити процес навчання. Вказати 'SequenceLength' 1000, щоб розбити сигнал на менші частини, щоб машина не вичерпала пам'ять, переглядаючи занадто багато даних за один раз. Встановити 'GradientThreshold' рівним 1, щоб стабілізувати процес навчання, не даючи градієнтам стати занадто великими. Вказати 'Plots' як 'training-progress', щоб

генерувати графіки, які показують прогрес навчання зі збільшенням кількості ітерацій. Встановити значення 'Verbose' у false, щоб приховати виведення таблиці, яка відповідає даним, показаним на графіку. Якщо ви хочете бачити цю таблицю, встановити значення 'Verbose' у true.

У цьому прикладі використовується адаптивний обчислювач моментів (ADAM). ADAM працює краще з ШНМ, такими як LSTM, ніж стандартний розв'язувач стохастичного градієнтного спуску з імпульсом (SGDM).

```
options = trainingOptions('adam', ...
    'MaxEpochs',10, ...
    'MiniBatchSize', 150, ...
    'InitialLearnRate', 0.01, ...
    'SequenceLength', 1000, ...
    'GradientThreshold', 1, ...
    'ExecutionEnvironment', "auto", ...
    'plots', 'training-progress', ...
    'Verbose', false);
```

### 3.6 Навчання LSTM-мережі

Навчання LSTM-мережі із заданими параметрами навчання та архітектурою шарів за допомогою trainNetwork.

```
net = trainNetwork(XTrain,YTrain,layers,options);
```

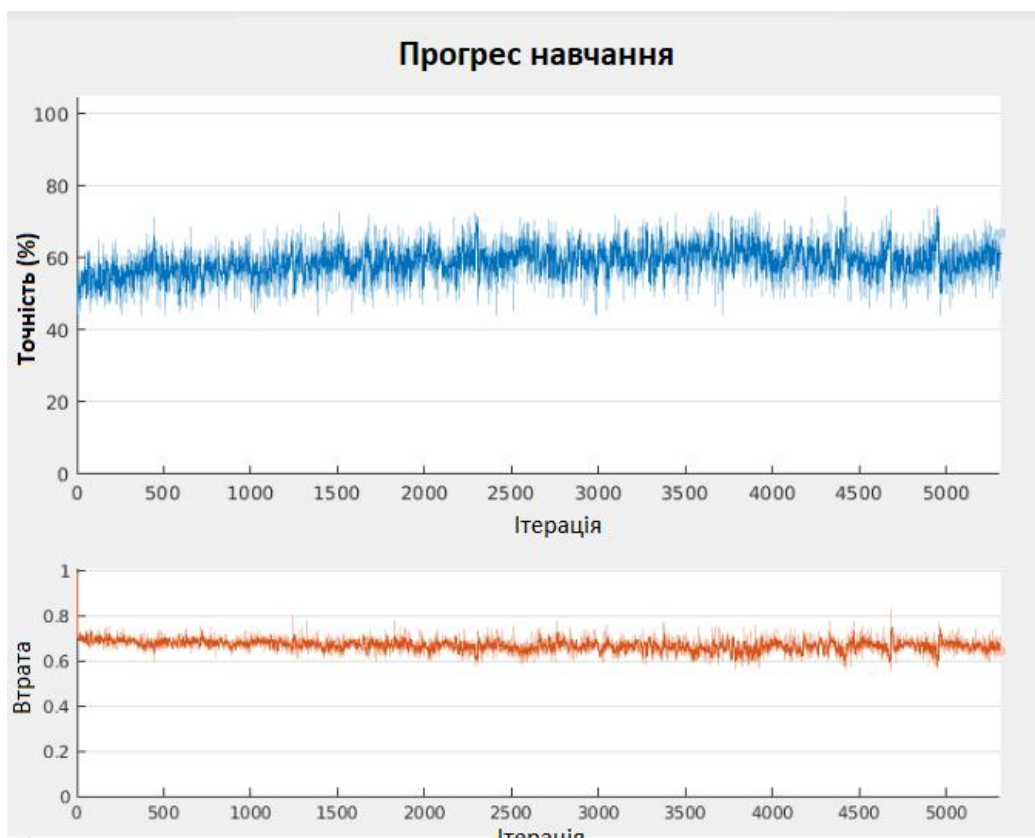


Рисунок 3.3 - Діаграми точності та втрати прогресу навчання LSTM-мережі

Верхня піддіаграма графіка "навчання-прогрес" відображає точність навчання, тобто точність класифікації на кожній міні-партії. При успішному навчанні це значення, як правило, зростає до 100%. Нижній підграфік показує втрати навчання, тобто втрати перехресної ентропії на кожній міні-партії. Коли навчання проходить успішно, це значення зазвичай зменшується до нуля.

Якщо навчання не збігається, графіки можуть коливатися між значеннями без певної тенденції до зростання чи зменшення. Таке коливання означає, що точність навчання не покращується і втрати при навчанні не зменшуються. Така ситуація може виникнути з самого початку навчання, або ж графіки можуть вийти на плато після деякого попереднього покращення точності навчання. У

багатьох випадках зміна параметрів навчання може допомогти мережі досягти збіжності. Зменшення `MiniBatchSize` або `InitialLearnRate` може призвести до збільшення часу навчання, але це може допомогти мережі краще навчатися.

Точність навчання класифікатора коливається між приблизно 50% і приблизно 60%, і наприкінці 10 епох навчання вже зайняло кілька хвилин.

### 3.6.1 Візуалізація точності навчання та тестування

Обчислити точність навчання, яка відображає точність роботи класифікатора на сигналах, на яких він навчався. Спочатку треба класифікувати навчальні дані.

```
trainPred = classify(net,XTrain,'SequenceLength',1000);
```

У задачах класифікації матриці плутанини використовуються для візуалізації роботи класифікатора на наборі даних, для яких відомі істинні значення. Цільовий клас - це істинна мітка сигналу, а вихідний клас - це мітка, присвоєна сигналу мережею. На осях позначено мітки класів, AFib (A) і Normal (N).

Застосувати команду `confusionchart` для обчислення загальної точності класифікації для прогнозів тестових даних. Вказати `'RowSummary'` як `'row-normalized'`, щоб відобразити частоту істинних і хибних спрацьовувань у зведенні по рядках. Також вказати `'ColumnSummary'` як `'column-normalized'` для відображення позитивних значень прогнозу і частоти помилкових спрацьовувань у зведенні по стовпчиках.

```
LSTMAccuracy = sum(trainPred == YTrain)/numel(YTrain)*100
```

LSTMAccuracy = 61.7283

figure

```
confusionchart(YTrain,trainPred,'ColumnSummary','column-normalized',...
               'RowSummary','row-normalized','Title','Confusion Chart for LSTM');
```




Рисунок 3.4 - Матриця помилок загальної точності класифікації для прогнозів тестових даних

Далі класифікувати дані тестування за допомогою тієї ж мережі.

```
testPred = classify(net,XTest,'SequenceLength',1000);
```

Розрахувати точність тестування та візуалізувати ефективність класифікації у вигляді матриці помилок.

```
LSTMAccuracy = sum(testPred == YTest)/numel(YTest)*100
```

LSTMAccuracy = 66.2245

```
figure
confusionchart(YTest,testPred,'ColumnSummary','column-normalized',...
               'RowSummary','row-normalized','Title','Confusion Chart for LSTM');
```




Рисунок 3.5 - Матриця помилок точності тестування

### 3.7 Покращення продуктивності за допомогою вилучення ознак

Виділення ознак з даних може допомогти покращити точність навчання та тестування класифікатора. Щоб вирішити, які ознаки вилучати, у цьому прикладі адаптовано підхід, який обчислює часово-частотні зображення, такі як спектрограми, і використовує їх для навчання згорткових нейронних мереж (CNNs).

Візуалізувати спектрограму кожного типу сигналу.

```

fs = 300;

figure
subplot(2,1,1);
pspectrum(normal,fs,'spectrogram','TimeResolution',0.5)
title('Normal Signal')

subplot(2,1,2);
pspectrum(aFib,fs,'spectrogram','TimeResolution',0.5)
title('AFib Signal')

```

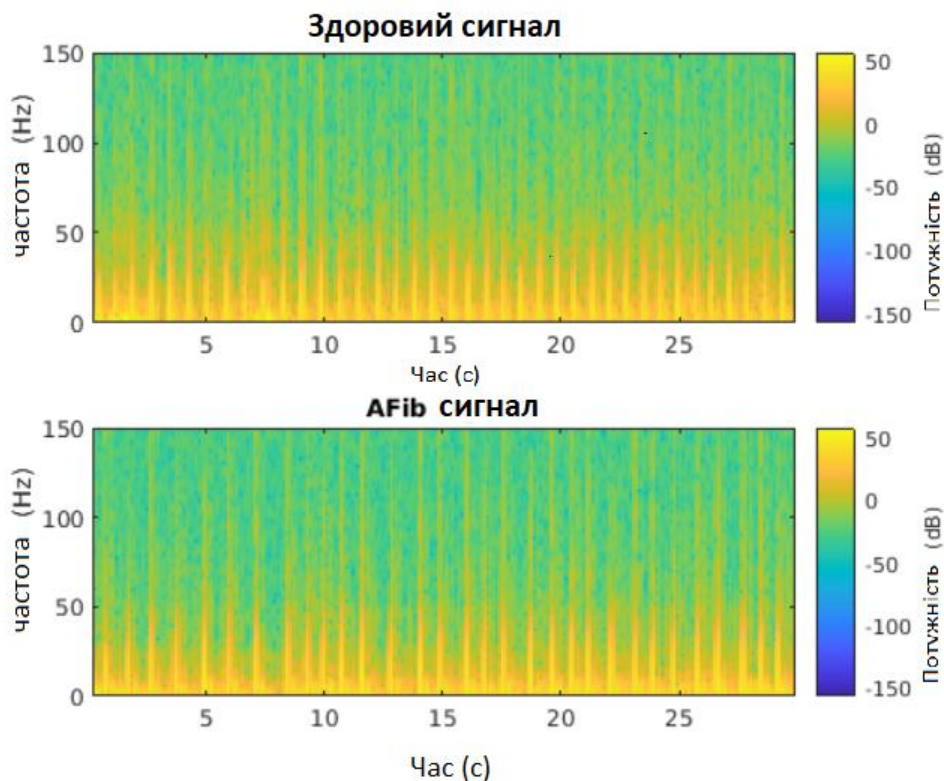


Рисунок 3.6 - Спектрограма кожного типу сигналу

Оскільки в цьому прикладі використовується LSTM замість CNN, важливо перекласти підхід так, щоб він застосовувався до одновимірних сигналів. Часово-частотні (ЧЧ) моменти витягують інформацію зі спектрограм. Кожен момент можна використовувати як одновимірну характеристику для введення в LSTM.

Розглянемо два моменти ТЧ у часовій області:

- Миттєва частота (instfreq)
- Спектральна ентропія (пентропія)

Функція `instfreq` оцінює залежну від часу частоту сигналу як перший момент спектрограми потужності. Функція обчислює спектрограму за допомогою короточасних перетворень Фур'є на часових інтервалах. У цьому прикладі функція використовує 255 часових вікон. Часові виходи функції відповідають центрам часових вікон.

Візуалізація миттєвої частоти для кожного типу сигналу.

```
[instFreqA,tA] = instfreq(aFib,fs);
[instFreqN,tN] = instfreq(normal,fs);

figure
subplot(2,1,1);
plot(tN,instFreqN)
title('Normal Signal')
xlabel('Time (s)')
ylabel('Instantaneous Frequency')

subplot(2,1,2);
plot(tA,instFreqA)
title('AFib Signal')
xlabel('Time (s)')
ylabel('Instantaneous Frequency')
```




Рисунок 3.7 - Діаграми миттєвої частоти для кожного типу сигналу

Застосувати `cellfun`, щоб використовувати функцію `instfreq` до кожної комірки в навчальному та тестовому наборах.

```
instfreqTrain = cellfun(@(x)instfreq(x,fs)',XTrain,'UniformOutput',false);
instfreqTest = cellfun(@(x)instfreq(x,fs)',XTest,'UniformOutput',false);
```

Спектральна ентропія вимірює, наскільки гострокутним є спектр сигналу. Сигнал з гостроверхим спектром, як сума синусоїд, має низьку спектральну ентропію. Сигнал з пласким спектром, як білий шум, має високу спектральну ентропію. Функція `pentropy` оцінює спектральну ентропію на основі спектрограми потужності. Як і у випадку оцінки миттєвої частоти, `pentropy` використовує 255 часових вікон для обчислення спектрограми. Часові виходи функції відповідають центрам часових вікон.

Візуалізувати спектральну ентропію для кожного типу сигналу.

```
[pentropyA,tA2] = pentropy(aFib,fs);
[pentropyN,tN2] = pentropy(normal,fs);
```

```
figure
subplot(2,1,1)
plot(tN2,pentropyN)
title('Normal Signal')
ylabel('Spectral Entropy')

subplot(2,1,2)
plot(tA2,pentropyA)
title('AFib Signal')
xlabel('Time (s)')
ylabel('Spectral Entropy')
```




Рисунок 3.8 -Діаграми спектральної ентропії для кожного типу сигналу

Використовувати `cellfun`, щоб застосувати функцію ентропії до кожної клітинки в навчальному та тестовому наборах.

```
pentropyTrain = cellfun(@(x)pentropy(x,fs)',XTrain,'UniformOutput',false);
pentropyTest = cellfun(@(x)pentropy(x,fs)',XTest,'UniformOutput',false);
```

Об'єднати ознаки таким чином, щоб кожна комірка в новому навчальному та тестовому наборах мала два виміри або дві ознаки.

```
XTrain2 = cellfun(@(x,y)[x;y],instfreqTrain,pendropyTrain,'UniformOutput',false);
XTest2 = cellfun(@(x,y)[x;y],instfreqTest,pendropyTest,'UniformOutput',false);
```

Візуалізувати формат нових входів. Кожна комірка більше не містить одного сигналу довжиною 9000 відліків, тепер вона містить дві функції довжиною 255 відліків.

```
XTrain2(1:5)
```

```
ans=5×1 cell array
```

```
{2×255 double}
{2×255 double}
{2×255 double}
{2×255 double}
{2×255 double}
```

### 3.8 Нормалізація даних

Миттєва частота та спектральна ентропія мають значення, що відрізняються майже на порядок. Крім того, середнє значення миттєвої частоти може бути занадто високим для ефективного навчання LSTM. Коли мережа навчається на даних з великим середнім значенням і великим діапазоном значень, великі вхідні дані можуть сповільнити навчання і збіжність мережі.

```
mean(instFreqN)
ans = 5.5615
mean(pentropyN)
ans = 0.6326
```

Застосувати середнє значення навчальної вибірки та стандартне відхилення для стандартизації навчальної та тестової вибірки. Стандартизація, або z-скоринг, є популярним способом покращення продуктивності мережі під час навчання.

```
XV = [XTrain2{:}];
mu = mean(XV,2);
sg = std(XV,[],2);

XTrainSD = XTrain2;
XTrainSD = cellfun(@(x)(x-mu)./sg,XTrainSD,'UniformOutput',false);

XTestSD = XTest2;
XTestSD = cellfun(@(x)(x-mu)./sg,XTestSD,'UniformOutput',false);
```

Показати значення стандартизованої миттєвої частоти та спектральної ентропії.

```
instFreqNSD = XTrainSD{1}(1,:);
pentropyNSD = XTrainSD{1}(2,:);
mean(instFreqNSD)
ans = -0.3211
mean(pentropyNSD)
ans = -0.2416
```

### 3.9 Модифікація архітектури мережі LSTM

Тепер, коли сигнали мають по два виміри, необхідно модифікувати архітектуру мережі, вказавши розмір вхідної послідовності як 2. Задати двонаправлений LSTM шар з розміром виходу 100 і виведіть останній елемент послідовності. Вказати два класи, включивши повністю зв'язний шар розміром 2, за яким слідує шар softmax і шар класифікації.

```
layers = [ ...
    sequenceInputLayer(2)
    bilstmLayer(100, 'OutputMode', 'last')
    fullyConnectedLayer(2)
    softmaxLayer
    classificationLayer
]

layers =
    5x1 Layer array with layers:

    1 '' Sequence Input           Sequence input with 2 dimensions
    2 '' BiLSTM                   BiLSTM with 100 hidden units
    3 '' Fully Connected          2 fully connected layer
    4 '' Softmax                   softmax
    5 '' Classification Output    crossentropyex
```

Вказати параметри навчання. Встановити максимальну кількість епох 30, щоб дозволити мережі зробити 30 проходів через навчальні дані.

```
options = trainingOptions('adam', ...
    'MaxEpochs',30, ...
    'MiniBatchSize', 150, ...
    'InitialLearnRate', 0.01, ...
    'GradientThreshold', 1, ...
    'ExecutionEnvironment',"auto",...
    'plots','training-progress', ...
    'Verbose',false);
```

### 3.10 Навчання LSTM-мережі з частотно-часовими характеристиками

Навчити LSTM-мережу із заданими параметрами навчання та архітектурою шарів за допомогою `trainNetwork`.

```
net2 = trainNetwork(XTrainSD,YTrain,layers,options);
```



Рисунок 3.8 - Діаграми точності та втрати прогресу навчання LSTM-мережі з частотно-часовими характеристиками

Спостерігається значне покращення точності навчання. Втрати перехресної ентропії прямують до 0. Крім того, час, необхідний для навчання, зменшується, оскільки моменти частотно-часової характеристики коротші за вихідні послідовності.

### 3.10.1 Візуалізація точності навчання та тестування

Класифікувати навчальні дані, використовуючи оновлену LSTM-мережу. Візуалізувати ефективність класифікації у вигляді матриці помилок.

```
trainPred2 = classify(net2,XTrainSD);
LSTMaccuracy = sum(trainPred2 == YTrain)/numel(YTrain)*100
```

```
LSTMaccuracy = 83.5962
```

```
figure
confusionchart(YTrain,trainPred2,'ColumnSummary','column-normalized',...
    'RowSummary','row-normalized','Title','Confusion Chart for LSTM');
```




Рисунок 3.9 – Матриця помилок загальної точності класифікації для прогнозів тестових даних

Класифікувати дані тестування з оновленою мережею. Побудувати матрицю плутанини, щоб перевірити точність тестування.

```
testPred2 = classify(net2,XTestSD);
```

```
LSTMAccuracy = sum(testPred2 == YTest)/numel(YTest)*100
```

```
LSTMAccuracy = 80.1020
```

```
figure
```

```
confusionchart(YTest,testPred2,'ColumnSummary','column-normalized',...  
              'RowSummary','row-normalized','Title','Confusion Chart for LSTM');
```




Рисунок 3.10 – Матриця помилок точності тестування

## ВИСНОВКИ

Діагностика серцево-судинної системи людини належить до числа найважливіших завдань кардіології. Основні причини смертності людей у працездатному віці пов'язані із серцево-судинними захворюваннями. Цим зумовлена необхідність розробки та вдосконалення засобів моніторингу для об'єктивного оцінювання та прогнозування стану серцево-судинної системи.

Відзначено важливість вивчення провідної системи серця та використання методів аналізу електрокардіографії (ЕКГ) для більш глибокого розуміння функціонального стану серцево-судинної системи. Походження ЕКГ сигналу виявляється ключовим етапом, а його елементи (P-, QRS-, та T-хвилі) стають основою для діагностики та моніторингу різноманітних патологій.

У контексті дослідження надано обґрунтування застосування рекурентних нейронних мереж (RNN) з пам'яттю для автоматичного розпізнавання хвиль ЕКГ. Довга короткочасова пам'ять і двонаправлена довга короткочасова пам'ять в RNN сприяють поліпшенню точності аналізу часових послідовностей, що важливо для ефективного визначення стану серця.

Поглиблено розглянуті існуючі методи класифікації сигналів ЕКГ з використанням мереж довготривалої короткочасної пам'яті, що вказує на перспективи цього підходу у вдосконаленні діагностики серцевих захворювань.

Розроблений пакет програм у середовищі MatLab для побудови класифікатора для виявлення фібриляції передсердь у сигналах ЕКГ за допомогою штучної нейронної мережі Long Short-Term Memory, яка дозволяє ефективно моделювати та аналізувати часові послідовності, що є критичним для точного розпізнавання змін у сигналах ЕКГ. Процедура використовує передискретизацію,

щоб уникнути зсуву класифікації, який виникає, коли намагаються виявити аномальні стани в популяціях, що складаються переважно зі здорових пацієнтів. Навчання LSTM-мережі на необроблених сигнальних даних призводить до низької точності класифікації. Навчання мережі з використанням двох часово-частотно-моментних характеристик для кожного сигналу значно покращує ефективність класифікації, а також зменшує час навчання.

## ПЕРЕЛІК ДЖЕРЕЛ

1. Місце серцево-судинних патологій у структурі захворювань українців [Електронний ресурс]. // Медпросвіта. – 2016. – Режим доступу до ресурсу: <https://medprosvita.com.ua/mesto-serdechno-sosudistyih-patologiy-strukture/>.
2. "ECG Interpretation: From Pathophysiology to Clinical Application" by Fred Kusumoto and Paul J. Wang.
3. Гайворонський І. В. Нормальна анатомія людини / І. В. Гайворонський. 2000. - 560 с.
4. Krohn, J., Beyleveld, G., & Bassens, A. (2019). *Deep Learning illustrated: A Visual, Interactive Guide to Artificial Intelligence*. Addison-Wesley Professional.
5. Гафаров Ф.М., Галімянов А.Ф. Штучні нейронні мережі та додатки.
6. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.
7. Нейронні мережі. МАТЛАБ 6./Під загальн. ред. В. Г. Потьомкіна. - М.: ДІАЛОГ-МІФІ, 2001. - 630 с. - (Пакети прикладних програм; Кн. 4). [Електронний ресурс].
8. AF Classification from a Short Single Lead ECG Recording: the PhysioNet/Computing in Cardiology Challenge, 2017. <https://physionet.org/challenge/2017/>.
9. Clifford, Gari, Chengyu Liu, Benjamin Moody, Li-wei H. Lehman, Ikaro Silva, Qiao Li, Alistair Johnson, and Roger G. Mark. "AF Classification from a Short Single Lead ECG Recording: The PhysioNet Computing in Cardiology Challenge 2017." *Computing in Cardiology (Rennes: IEEE)*. Vol. 44, 2017, pp. 1–4.

10. Goldberger, A. L., L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley. "PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals". *Circulation*. Vol. 101, No. 23, 13 June 2000, pp. e215–e220. <http://circ.ahajournals.org/content/101/23/e215.full.4572>

11. Pons, Jordi, Thomas Lidy, and Xavier Serra. "Experimenting with Musically Motivated Convolutional Neural Networks". 14th International Workshop on Content-Based Multimedia Indexing (CBMI). June 2016.

12. Wang, D. "Deep learning reinvents the hearing aid," *IEEE Spectrum*, Vol. 54, No. 3, March 2017, pp. 32–37. doi: 10.1109/MSPEC.2017.7864754.

13. Brownlee, Jason. How to Scale Data for Long Short-Term Memory Networks in Python. 7 July 2017. <https://machinelearningmastery.com/how-to-scale-data-for-long-short-term-memory-networks-in-python/>.

14. V. Fuster, L.E. Ryden, R.W. Asinger, D.S. Cannom, H.J. Crijns, R.L. Frye, J.L. Halperin, N.G. Kay, W.W. Klein, S. Lévy, R.L. McNamara, E.N. Prystowsky, L.S. Wann, D.G. Wyse, R.J. Gibbons, E.M. Antman, J.S. Alpert, D.P. Faxon, V. Fuster, G. Gregoratos, L.F. Hiratzka, A.K. Jacobs, R.O. Russell, S.C. Smith, W.W. Klein, A. Alonso-Garcia, C. Blomström-Lundqvist, G. De Backer, M. Flather, J. Hradec, A. Oto, A. Parkhomenko, S. Silber, A. Torbicki, ACC/AHA/ESC guidelines for the management of patients with atrial fibrillation: executive summary, *J Am Coll Cardiol* 38 (4) (2001) 1231–1265.

15. G.Y.H. Lip, L. Fauchier, S.B. Freedman, I. Van Gelder, A. Natale, C. Gianni, S. Nattel, T. Potpara, M. Rienstra, H. Tse, D.A. Lane, Atrial fibrillation, *Nature Reviews Disease Primers* 2 (2016) 16016.

16. A.J. Camm, P. Kirchhof, G.Y. Lip, U. Schotten, I. Savelieva, S. Ernst, I.C. Van Gelder, N. Al-Attar, G. Hindricks, B. Prendergast, H. Heidbuchel, O. Alfieri, A. Angelini, D. Atar, P. Colonna, R. De Caterina, J. De Sutter, A. Goette, B. Gorenek, M. Heldal, S.H. Hohloser, P. Kolh, J.Y. Le Heuzey, P. Ponikowski, F.H. Rutten, Guidelines for the management of atrial fibrillation: the Task Force for the Management of Atrial Fibrillation of the European Society of Cardiology (ESC), *Eur Heart J* 31 (19) (2010) 2369–2429.

17. R. Colloca. (Sup. by L. Minardi & G. D. Clifford) Implementation and testing of atrial fibrillation detectors for a mobile phone application. M.Sc. Thesis, Politecnico di Milano and University of Oxford, 2013.

18. I. Savelieva, J. Camm, Update on atrial fibrillation: part I, *Clin Cardiol* 31 (2) (2008) 55–62.

19. G.V. Naccarelli, H. Varker, J. Lin, K.L. Schulman, Increasing prevalence of atrial fibrillation and flutter in the United States, *Am J Cardiol* 104 (11) (2009) 1534–1539.

20. A. Petrėnas, V. Marozas, L. Sörnmo, A. Lukosevicius, An echo state neural network for QRST cancellation during atrial fibrillation, *IEEE Trans Biomed Eng* 59 (10) (2012) 2950–2957.

21. S. Ladavich, B. Ghoraani, Rate-independent detection of atrial fibrillation by statistical modeling of atrial activity, *Biomed Signal Process Control* 18 (4) (2015) 274–281.

22. X. Du, N. Rao, M. Qian, D. Liu, J. Li, W. Feng, L. Yin, X. Chen, A novel method for real-time atrial fibrillation detection in electrocardiograms using multiple parameters, *Ann Noninvasive Electrocardiol* 19 (3) (2014) 217–225.

23. H. Pürerfellner, E. Pokushalov, S. Sarkar, J. Koehler, R. Zhou, L. Urban, G. Hindricks, P-wave evidence as a method for

improving algorithm to detect atrial fibrillation in insertable cardiac monitors, *Heart Rhythm* 11 (9) (2014) 1575–1583.

24. R. Alcaraz, C. Vaya, R. Cervigon, C. Sanchez, J.J. Rieta. Wavelet sample entropy: A new approach to predict termination of atrial fibrillation. In: *Computing in Cardiology*, ed A Murray: IEEE) 2006, pp. 597–600.

25. J. Ródenas, M. García, R. Alcaraz, J.J. Rieta, Wavelet entropy automatically detects episodes of atrial fibrillation from single-lead electrocardiograms, *Entropy* 17 (9) (2015) 6179–6199.

26. M. García, J. Ródenas, R. Alcaraz, J.J. Rieta, Application of the relative wavelet energy to heart rate independent detection of atrial fibrillation, *Comput Methods Programs Biomed* 131 (7) (2016) 157–168.

27. M. Carrara, L. Carozzi, T.J. Moss, M. De Pasquale, S. Cerutti, M. Ferrario, D.E. Lake, J.R. Moorman, Heart rate dynamics distinguish among atrial fibrillation, normal sinus rhythm and sinus rhythm with frequent ectopy, *Physiol Meas* 36 (9) (2015) 1873–1888.

28. J. Park, S. Lee, M. Jeon, Atrial fibrillation detection by heart rate variability in Poincare plot, *Biomed Eng Online* 8 (2009) 38.

29. S. Sarkar, D. Ritscher, R. Mehra, A detector for a chronic implantable atrial tachyarrhythmia monitor, *IEEE Trans Biomed Eng* 55 (3) (2008) 1219–1224.

30. K. Tateno, L. Glass, Automatic detection of atrial fibrillation using the coefficient of variation and density histograms of RR and deltaRR intervals, *Med Biol Eng Comput* 39 (6) (2001) 664–671.

31. D.T. Linker, [Accurate, Automated Detection of Atrial Fibrillation in Ambulatory Recordings](#), *Cardiovasc Eng Technol* 2016 Jun;7(2):182-9. doi: 10.1007/s13239-016-0256-z. Epub 2016 Feb 5.

32. C. Huang, S. Ye, H. Chen, D. Li, F. He, Y. Tu, A novel method for detection of the transition between atrial fibrillation and sinus rhythm, *IEEE Trans Biomed Eng* 58 (4) (2011) 1113–1119.

33. S. Cerutti, L. Mainardi, L. Sörnmo. *Understanding atrial fibrillation: the signal processing contribution*. 2008: Morgan and Claypool Publishers).

34. A. Petrénas, V. Marozas, L. Sörnmo, Low-complexity detection of atrial fibrillation in continuous long-term monitoring, *Comput Biol Med* 65 (10) (2015) 184–191.

35. X. Zhou, H. Ding, B. Ung, E. Pickwell-MacPherson, Y.T. Zhang, Automatic online detection of atrial fibrillation based on symbolic dynamics and Shannon entropy, *Biomed Eng Online* 13 (1) (2014) 18.

36. R. Alcaraz, D. Abásolo, R. Hornero, J.J. Rieta, Optimal parameters study for sample entropy-based atrial fibrillation organization analysis, *Comput Methods Programs Biomed* 99 (1) (2010) 124–132.

37. D.E. Lake, J.R. Moorman, Accurate estimation of entropy in very short physiological time series: the problem of atrial fibrillation detection in implanted ventricular devices, *Am J Physiol Heart Circ Physiol* 300 (1) (2011) H319-H325.

38. D. DeMazumder, D.E. Lake, A. Cheng, T.J. Moss, E. Guallar, R.G. Weiss, S.R. Jones, G.F. Tomaselli, J.R. Moorman, Dynamic analysis of cardiac rhythms for discriminating atrial fibrillation from lethal ventricular arrhythmias, *Circ Arrhythm Electrophysiol* 6 (3) (2013) 555–561.

39. S. Babaeizadeh, R.E. Gregg, E.D. Helfenbein, J.M. Lindauer, S.H. Zhou, Improvements in atrial fibrillation detection for real-time monitoring, *J Electrocardiol* 42 (6) (2009) 522–526.

40. A. Petrėnas, L. Sörnmo, A. Lukoševicius, V. Marozas, Detection of occult paroxysmal atrial fibrillation, *Med Biol Eng Comput* 53 (4) (2015) 287–297.

41. J. Oster, G.D. Clifford, Impact of the presence of noise on RR interval-based atrial fibrillation detection, *J Electrocardiol* 48 (6) (2015) 947–951.

42. R. Colloca, A.E.W. Johnson, L. Mainardi, G.D. Clifford. A support vector machine approach for reliable detection of atrial fibrillation events. In: *Computing in Cardiology*, ed A Murray (Zaragoza, Spain 2013, 1047–1050.

43. Q. Li, C.Y. Liu, J. Oster, G.D. Clifford. Signal processing and feature selection preprocessing for classification in noisy healthcare data. In: *Machine Learning for Healthcare Technologies*. ed D.A. Clifton (London: The Institution of Engineering and Technology, 2016), 33-58.