

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук  
(повна назва)

Кафедра Штучного інтелекту  
(повна назва)

**КВАЛІФІКАЦІЙНА РОБОТА**  
**Пояснювальна записка**

рівень вищої освіти другий (магістерський)

Інтелектуальний аналіз міографічних сигналів  
(тема)

Виконав:  
студент 2 курсу, групи СШМ-22-3  
Величко О.О.  
(прізвище, ініціали)

Спеціальність 122 Комп'ютерні науки  
(код і повна назва спеціальності)

Тип програми освітньо-наукова  
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту  
(повна назва спеціалізації)

Керівник доц. Носова Т.В.  
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри \_\_\_\_\_  
(підпис)

В.О. Філатов  
(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет \_\_\_\_\_ Комп'ютерних наук \_\_\_\_\_  
(повна назва)  
Кафедра \_\_\_\_\_ Штучного інтелекту \_\_\_\_\_  
(повна назва)  
Рівень вищої освіти \_\_\_\_\_ другий (магістерський) \_\_\_\_\_  
Спеціальність \_\_\_\_\_ 122 Комп'ютерні науки \_\_\_\_\_  
(код і повна назва)  
Тип програми \_\_\_\_\_ освітньо-наукова \_\_\_\_\_  
(освітньо-професійна або освітньо-наукова)  
Освітня програма \_\_\_\_\_ Системи штучного інтелекту \_\_\_\_\_  
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_

(підпис)

« \_\_\_\_\_ » \_\_\_\_\_ 20 \_\_\_\_ р.

**ЗАВДАННЯ**  
НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові \_\_\_\_\_ Величку Олексію Олексійовичу \_\_\_\_\_  
(прізвище, ім'я, по батькові)

1. Тема роботи \_\_\_\_\_ Інтелектуальний аналіз міографічних сигналів \_\_\_\_\_

затверджена наказом університету від 1 квітня 20 24 р. № 260Ст

2. Термін подання студентом роботи до екзаменаційної комісії 14 червня 20 24 р.

3. Вихідні дані до роботи Теоретичне дослідження рішення та опис технологій, пов'язаних із аналізом та класифікацією міографічних сигналів, робота з потоком даних для аналізу та обробки ЕМГ сигналів, практична частина роботи, включаючи вибір та реалізацію алгоритму для класифікації електроміографічних сигналів, вибір набору даних, попередня обробка даних та їх візуалізація

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

1) Огляд характеристик ЕМГ сигналів, методів їх виявлення та декомпозиції

2) Дослідження методів обробки ЕМГ сигналів

3) Аналіз методів класифікації ЕМГ сигналів

4) Розробка та порівняння різних підходів до класифікації електроміографічних сигналів, зокрема для класифікації жестів рук

5) Оцінка ефективності та точності розробленого алгоритму класифікації електроміографічних сигналів та порівняння його з класичними алгоритмами



## РЕФЕРАТ

Пояснювальна записка: 62 с., 18 рис., 1 табл., 1 дод., 15 джерел.

ЕЛЕКТРОМІОГРАФІЯ, МІОГРАФІЧНІ СИГНАЛИ, ОБРОБКА СИГНАЛІВ, ШТУЧНИЙ ІНТЕЛЕКТ, ШТУЧНІ НЕЙРОННІ МЕРЕЖІ.

Об'єкт дослідження – інтелектуальний аналіз міографічних сигналів.

Предмет дослідження – алгоритми та технології інтелектуального аналізу міографічних сигналів.

Мета роботи – розробка та оцінка алгоритмів інтелектуального аналізу міографічних сигналів з метою підвищення їх точності та ефективності.

Методи дослідження – аналіз літературних джерел для вивчення існуючих підходів та алгоритмів інтелектуального аналізу міографічних сигналів, експериментальне тестування алгоритмів на наборі даних, що містить електроміографічні сигнали, визначення та використання метрик для оцінки ефективності та точності розроблених алгоритмів, порівняння результатів різних алгоритмів з метою виявлення найбільш ефективних підходів.

## ABSTRACT

Master's thesis contains: 62 pp., 18 fig., 1 tabl., 1 ann., 15 references.

ARTIFICIAL INTELLIGENCE, ARTIFICIAL NEURAL NETWORKS,  
ELECTROMYOGRAPHY, MYOGRAPHIC SIGNALS, SIGNAL  
PROCESSING.

The object of research is the intelligent analysis of myographic signals.

The subject of research – algorithms and technologies for intelligent analysis of myographic signals.

The aim of the work is to develop and evaluate algorithms for intelligent analysis of myographic signals in order to improve their accuracy and efficiency.

Research methods include analysis of literature sources to study existing approaches and algorithms for intelligent analysis of myographic signals, experimental testing of algorithms on a dataset containing electromyographic signals, definition and use of metrics to evaluate the effectiveness and accuracy of the developed algorithms, comparison of the results of different algorithms to identify the most effective approaches.

## ЗМІСТ

Перелік умовних позначень, символів, одиниць скорочень і термінів.....	7
Вступ.....	8
1 Аналіз та обробка емг сигналів.....	12
1.1 Характеристики ЕМГ сигналів.....	12
1.2 Виявлення та декомпозиція ЕМГ сигналів .....	16
1.3 Методи обробки ЕМГ сигналів.....	20
2 Огляд алгоритмів та метрик для класифікації електроміографічних сигналів.....	29
2.1 Аналіз методів класифікації ЕМГ сигналів на основі штучних нейронних мереж .....	29
2.2 Проблеми та виклики в класифікації ЕМГ сигналів .....	39
2.3 Метрики оцінки моделі класифікації ЕМГ сигналів.....	41
3 Особливості реалізації програмного застосунку .....	44
3.1 Постановка задачі та огляд обраного датасету.....	44
3.2 Попередня обробка даних.....	46
3.3 Вибір моделі для навчання .....	48
3.4 Навчання моделі та аналіз метрик .....	51
3.5 Порівняння моделі CNN-ECA з класичними моделями машинного навчання .....	55
Висновки.....	59
Перелік джерел посилання .....	60
Додаток А Відомість кваліфікаційної роботи .....	62

## **ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ СКОРОЧЕНЬ І ТЕРМІНІВ**

ЕМГ – електроміографія;

ШІ – штучний інтелект;

CNN – Convolutional Neural Network – згорткова нейронна мережа;

DNN – Deep Neural Network – глибока нейрона мережа;

FHT – Fast Hartley Transform – швидке перетворення Хартлі;

LSTM – Long Short-Term Memory – довга короткочасна пам'ять;

RNN – Recurrent Neural Network – рекурентна нейронна мережа;

sEMG – метод поверхневої електроміографії.

## ВСТУП

Міографія – це наукова дисципліна, що вивчає електричну активність м'язів і використовується для вимірювання та аналізу міографічних сигналів. Застосування міографії розповсюджене у багатьох галузях:

- медицина: у медицині міографія використовується для діагностики різних захворювань м'язів та нервово-м'язових хвороб, таких як міопатія, невропатія та міастенія гравіс. Вона допомагає лікарям встановлювати стан м'язів, виявляти аномалії у їх функціонуванні та моніторити ефективність лікування;

- біомедична інженерія: у біомедичній інженерії міографія використовується для розробки та тестування медичних пристроїв та імплантатів, які взаємодіють з м'язами. Вона допомагає інженерам та науковцям розробляти нові методи реабілітації та фізіотерапії, а також покращувати процеси відновлення після травм та операцій;

- спорт та фітнес: у спорті міографія використовується для аналізу та вдосконалення техніки виконання вправ та рухів. Вона дозволяє тренерам та спортсменам відстежувати активність м'язів під час тренувань, виявляти слабкі та недостатньо розвинені м'язові групи та оптимізувати тренувальні програми;

- інтерфейси користувача та реаліті-ігри: у сфері інформаційних технологій міографія використовується для створення інтерактивних інтерфейсів користувача, які реагують на м'язову активність. Вона дозволяє користувачам взаємодіяти з комп'ютером, використовуючи рухи м'язів, а також створює нові можливості для реаліті-ігор та віртуальної реальності;

- біомеханіка руху: міографія може бути використана для аналізу біомеханіки руху, включаючи рухи природної ходи, розвиток нових методів фізіотерапії та реабілітації, а також оптимізацію процесів

виготовлення протезів та ортезів;

– аналіз емоційної стану: дослідження міографічних сигналів може допомогти в аналізі емоційного стану людини, виявленні емоційних реакцій та вивченні їх впливу на фізичний стан.

Ці напрямки досліджень демонструють широкий спектр можливостей застосування міографії у різних галузях науки та технологій, що відкриває нові перспективи для подальших досліджень та розвитку цієї області. Зокрема, інтелектуальний аналіз міографічних сигналів на сьогоднішній день має важливе значення в різних галузях, включаючи медицину, спорт та реабілітацію. Зростання захворювань, пов'язаних із м'язово-скелетною системою, а також збільшення популярності різних видів фізичної активності ставлять перед науковою спільнотою виклик у покращенні методів аналізу міографічних сигналів. До того ж, інтеграція інтелектуальних алгоритмів та технік аналізу даних у сучасні медичні системи може значно полегшити та покращити процес діагностики, моніторингу та лікування пацієнтів.

Проблематика дослідження полягає у наступних факторах:

– точність діагностики, тобто існуючі методи аналізу міографічних сигналів можуть бути недостатньо точними для діагностики різноманітних захворювань та порушень у роботі м'язів;

– великий обсяг даних: міографічні сигнали можуть бути великого обсягу, що може ускладнювати їхню обробку та аналіз, особливо в умовах великої кількості пацієнтів та масштабних досліджень;

– шуми та перешкоди: наявність шумів та інтерференцій у міографічних сигналах може ускладнювати їхню обробку та аналіз, що може призводити до неточностей у результаті та ускладнювати діагностику;

– ефективність алгоритмів: потреба у розробці та вдосконаленні алгоритмів інтелектуального аналізу міографічних сигналів для підвищення їхньої ефективності та точності. Сучасні методи машинного

навчання, такі як згорткові нейронні мережі та рекурентні нейронні мережі, відкривають нові можливості для розробки більш точних та ефективних алгоритмів аналізу міографічних сигналів.

У ході роботи будуть вирішені наступні завдання:

- аналіз стану досліджень у галузі інтелектуального аналізу міографічних сигналів, зокрема проведення огляду актуальних досліджень, що стосуються інтелектуального аналізу міографічних сигналів, методів обробки, аналізу та класифікації таких сигналів;
- проведення порівняльного аналізу різних методів обробки та класифікації міографічних сигналів, зокрема, застосування згорткових та рекурентних нейронних мереж, а також методів довготривалої та короткочасної пам'яті;
- розробка та тестування моделі штучної нейронної мережі з метою класифікації жестів рук за електроміографічними сигналами;
- оцінка точності та ефективності побудованої моделі та її порівняння з класичними моделями машинного навчання.

Метою роботи є розробка та оцінка алгоритмів інтелектуального аналізу міографічних сигналів з метою підвищення їх точності та ефективності, а також вибір найбільш оптимального алгоритму та його програмна реалізація для задачі класифікації електроміографічних сигналів.

Об'єктом дослідження є інтелектуальний аналіз міографічних сигналів, а предметом – алгоритми та технології інтелектуального аналізу міографічних сигналів.

Для реалізації дослідження були використані такі методи як аналіз літературних джерел для вивчення існуючих підходів та алгоритмів інтелектуального аналізу міографічних сигналів, зокрема вивчення методів обробки міографічних сигналів та огляд алгоритмів для їх класифікації.

Після вибору оптимального методу обробки та алгоритму для класифікації міографічних сигналів, була програмно реалізовано задачу

класифікації жестів рук за електроміографічними сигналами з використанням сучасних програмних засобів, таких як TensorFlow і Keras. Після цього було оцінено ефективність та точність побудованої моделі, та порівняно її з класичними алгоритмами машинного навчання.

В майбутньому, на основі отриманих результатів можливо подальше вдосконалення розробленої моделі, шляхом її порівняння з архітектурою більш складніших моделей, порівняння її ефективності із рекурентними мережами, імплементація інших методів обробки електроміографічних сигналів.

# 1 АНАЛІЗ ТА ОБРОБКА ЕМГ СИГНАЛІВ

## 1.1 Характеристики ЕМГ сигналів

ЕМГ розшифровується як електроміографія. Це вивчення електричних сигналів м'язів. Іноді ЕМГ називають міоелектричною активністю. М'язова тканина проводить електричні потенціали подібно до того, як це роблять нерви, і назва, дана цим електричним сигналам, – потенціал дії м'язів. Поверхнева ЕМГ – це метод запису інформації, присутньої у цих потенціалах дії м'язів.

При виявленні та реєстрації сигналу ЕМГ існують дві основні проблеми, які впливають на достовірність сигналу. Перше – це співвідношення сигналу та шуму. Тобто відношення енергії в сигналах ЕМГ до енергії в сигналі шуму. Загалом шум визначається як електричні сигнали, які не є частиною бажаного сигналу ЕМГ. Інша проблема – це спотворення сигналу, що означає, що відносний внесок будь-якого компонента частоти в сигналі ЕМГ не повинен змінюватися. Два типи електродів були використані для отримання м'язового сигналу: інвазивні та неінвазивні електроди. Коли ЕМГ отримується з електродів, встановлених безпосередньо на шкірі, сигнал являє собою сукупність усіх потенціалів дії м'язових волокон, які відбуваються в м'язах, які знаходяться під шкірою. Ці потенціали дії виникають через випадкові проміжки часу. Тому в будь-який момент часу сигнал ЕМГ може бути як позитивним, так і негативним. Окремі потенціали дії м'язових волокон іноді отримують за допомогою дротяних або голкових електродів, розміщених безпосередньо в м'язі [4].

Комбінація потенціалів дії м'язів від усіх м'язових волокон одиниці руху є потенціалом дії одиниці руху, який може бути виявлений за допомогою електрода на поверхні шкіри (неінвазивний), розташованого біля цього поля, або за допомогою голкового електрода (інвазивного),

вставленого в м'яз.

Формула 1.1 показує просту модель сигналу ЕМГ:

$$x(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + w(n), \quad (1.1)$$

де  $x(n)$  – змодельований сигнал ЕМГ;

$e(n)$  – точково оброблений імпульс активації;

$h(r)$  – потенціал дії моторної одиниці (MUAP);

$w(n)$  – гауссовий білий шум із нульовим середнім значенням;

$N$  – кількість активацій моторних одиниць.

Сигнал знімається з електрода та підсилюється. Зазвичай, як перший ступінь підсилювача використовується диференціальний підсилювач. Можуть бути додані додаткові ступені підсилення. Перед відображенням або зберіганням сигнал може бути оброблений для усунення низькочастотного або високочастотного шуму чи інших можливих артефактів. Також сигнал часто випрямляється та усереднюється в певному форматі для визначення амплітуди ЕМГ.

Людське тіло в цілому електрично нейтральне; воно має однакову кількість позитивних і негативних зарядів. Але в стані спокою мембрана нервової клітини поляризована через різницю в концентрації та іонному складі по обидва боки плазматичної мембрани. Існує потенціальна різниця між внутрішньоклітинною та позаклітинною рідинами клітини. У відповідь на стимул від нейрона м'язове волокно деполяризується, оскільки сигнал поширюється вздовж його поверхні, і волокно скорочується. Ця деполяризація, супроводжувана переміщенням іонів, створює електричне поле поблизу кожного м'язового волокна. ЕМГ сигнал є потоком потенціалів дії моторних одиниць (MUAP), що відображають реакцію м'язів на нейронну стимуляцію. ЕМГ сигнал виглядає випадковим за своєю природою і зазвичай моделюється як відфільтрований імпульсний процес, де MUAP є фільтром, а імпульсний процес представляє нейронні

імпульси, часто модельовані як процес Пуассона. На рисунку 1.1 показаний процес отримання ЕМГ сигналу та декомпозиція для отримання MUAP [6].




Рисунок 1.1 – ЕМГ сигнал і декомпозиція потенціалів дії моторних одиниць (MUAPs)

Амплітуда ЕМГ сигналу становить 0-10 мВ (+5 до -5) до підсилення. ЕМГ сигнали набувають шуму під час проходження через різні тканини. Важливо розуміти характеристики електричного шуму. Електричний шум, який впливатиме на ЕМГ сигнали, можна поділити на такі типи:

- шум електронного обладнання: всі електронні пристрої генерують шум. Цей шум не можна усунути; використання високоякісних електронних компонентів може лише зменшити його;
- навколишній шум: джерелом цього типу шуму є електромагнітне випромінювання. Поверхні наших тіл постійно піддаються впливу електромагнітного випромінювання, і практично неможливо уникнути цього на поверхні Землі. Амплітуда навколишнього шуму може бути на

один або три порядки більша, ніж сигнал ЕМГ;

- артефакт руху: коли до системи вводиться артефакт руху, інформація спотворюється. Артефакт руху викликає нерегулярності в даних. Є два основні джерела артефакту руху: інтерфейс електрода та кабель електрода. Артефакт руху можна зменшити за допомогою правильного проектування електронної схеми та налаштування;

- власна нестабільність сигналу: амплітуда ЕМГ має випадковий характер. Сигнал ЕМГ залежить від частоти спрацьовування моторних одиниць, які, у більшості випадків, працюють у частотному діапазоні від 0 до 20 Гц. Цей тип шуму вважається небажаним, і його усунення є важливим.

Фактори, що впливають на ЕМГ сигнал, також можна класифікувати. Така класифікація створена для того, щоб алгоритми аналізу сигналів ЕМГ могли бути оптимізовані, а обладнання могло бути спроектоване узгодженим чином. Фактори, що впливають на сигнал ЕМГ, поділяються на три основні категорії.

Причинні фактори – це безпосередній вплив на сигнали. Причинні фактори можна розділити на дві групи:

- зовнішні, які пов'язані зі структурою та розташуванням електродів. Такі фактори, як площа поверхні виявлення, форма електрода, відстань між поверхнями виявлення електрода, розташування електрода відносно моторних точок у м'язі, розташування електрода на поверхні м'яза відносно бічного краю м'яза, орієнтація поверхонь виявлення відносно м'язових волокон, переважно впливають на сигнал ЕМГ;

- внутрішні: фізіологічні, анатомічні, біохімічні фактори виникають через кількість активних моторних одиниць, склад волокон, кровотік, діаметр волокна, глибину і розташування активних волокон та кількість тканини між поверхнею м'яза і електродом.

Проміжні фактори – це фізичні та фізіологічні явища, на які впливає один або кілька причинних факторів. Причинами цього можуть бути

аспекти смугового фільтрування електрода разом з його обсягом виявлення, накладення потенціалів дії в виявленому ЕМГ сигналі, швидкість проведення потенціалу дії, який поширюється вздовж мембрани м'язового волокна. Навіть перехресні перешкоди від сусідніх м'язів можуть викликати проміжні фактори.

Детерміновані фактори: на них впливають проміжні фактори. Кількість активних моторних одиниць, частота збудження моторних нейронів і механічна взаємодія між м'язовими волокнами мають прямий вплив на інформацію в ЕМГ сигналі і записану силу. Амплітуда, тривалість і форма потенціалу дії моторної одиниці також можуть мати вплив.

Максимізація якості ЕМГ сигналу може бути досягнута наступними способами:

- співвідношення сигнал-шум повинно містити максимально можливу кількість інформації з ЕМГ сигналу та мінімальну кількість шумових перешкод;
- спотворення ЕМГ-сигналу повинно бути мінімальним, без непотрібного фільтрування та спотворення піків сигналу.

Під час обробки ЕМГ сигналу аналізуються лише позитивні значення. Коли виконується напівхвильова ректифікація, всі негативні дані відкидаються, а позитивні дані зберігаються. Під час повнохвильової ректифікації використовується абсолютне значення кожної точки даних. Зазвичай для ректифікації віддають перевагу повнохвильовій ректифікації.

## 1.2 Виявлення та декомпозиція ЕМГ сигналів

Точне виявлення дискретних подій у sEMG (наприклад, зміна фази в патерні активності, пов'язаної з початком швидкого моторного відгуку) є важливим питанням в аналізі моторної системи. Було запропоновано кілька методів для визначення моментів увімкнення та вимкнення м'язів.

Найпоширенішим методом для визначення моторних подій з ЕМГ сигналів є візуальна перевірка тренуваними спостерігачами. «Метод одинарного порога», який порівнює ЕМГ сигнал із фіксованим порогом, є найбільш інтуїтивно зрозумілим і поширеним комп'ютерним методом для визначення часу початку активності м'язового скорочення. Ця техніка базується на порівнянні виправлених сигналів з амплітудним порогом, значення якого залежить від середньої потужності фонових шумів. Однак цей підхід загалом є незадовільним, оскільки отримані результати сильно залежать від вибору порогу. Такий метод часто базується на занадто евристичних критеріях і не дозволяє користувачу незалежно налаштувати ймовірність виявлення та ймовірність хибної тривоги. У «методі одинарного порога» співвідношення між ймовірністю виявлення  $P_{dk}$  та ймовірністю  $P_\gamma$ , тобто між тим, що зразок шуму перевищить поріг  $\gamma$ , визначається рівнянням 1.2.

У 1984 році Вінтер зауважив, що цей підхід загалом є незадовільним, оскільки він сильно залежить від вибору порогу. Щоб подолати проблему «одинарного порогу», Борнато та ін. у 1998 році запропонували метод «подвійного порогового виявлення». Детектори з подвійним порогом перевершують одинарні пороги, оскільки вони забезпечують вищу ймовірність виявлення. Детектори з подвійним порогом дозволяють користувачеві застосовувати зв'язок між хибною тривоною та ймовірністю виявлення з більшою ступінню свободи, ніж одинарні пороги. Користувач може налаштувати детектор відповідно до різних оптимальних критеріїв, таким чином адаптуючи його продуктивність до характеристик кожного конкретного сигналу та застосування.

Сигнал sEMG, записаний під час добровільних динамічних скорочень, може вважатися процесом Гаусса зі середнім значенням, рівним нулю,  $s(t) \in N(0, \sigma_s)$ , модульованим м'язовою активністю та спотвореним незалежним адитивним шумом Гаусса зі середнім значенням, рівним нулю,  $n(t) \in N(0, \sigma_n)$ . Якщо ймовірність виявлення дорівнює  $P_d$ , то

метод подвійного порогу визначається рівнянням 1.3.

$$P_d = \sum_{k=r_0}^m (k)^m P_{dk}^k (1 - P_{dk})^{m-k}. \quad (1.2)$$

Робота детектора з подвійним порогом визначається параметрами: порогом  $r_0$  і довжиною вікна спостереження  $m$ . Їх значення обираються таким чином, щоб мінімізувати ймовірність хибної тривоги та максимізувати ймовірність виявлення  $P_d$  для кожного конкретного співвідношення сигнал/шум. У 2004 році Ланьї та Адлер встановили, що метод подвійного порогу, запропонований Борнато, є складним та вимагає великих обчислювальних ресурсів, а також не є дуже чутливим. Ланьї та Енді запропонували новий алгоритм, заснований на методі подвійного порогу, який є більш чутливим, стабільним та ефективним з меншими обчислювальними витратами.

Для конкретних застосувань, крім точності виявлення, швидкість алгоритму може бути важливою. Алгоритми з високим часом обробки не підходять для онлайн виявлення. Одним з недоліків методу Борнато та ін. є те, що для максимізації ймовірності виявлення при фіксованій ймовірності хибної тривоги другий поріг має дорівнювати одиниці. Другий поріг фіксується під час виявлення, що фактично перетворює детектор з подвійним порогом на детектор з одинарним порогом. Цей метод не потребує кроку відбілювання сигналу, який потрібен був раніше. Процес відбілювання сигналу займає багато часу на його обчислення. Крім того, процес відбілювання сигналу знижує ймовірність сигналу, що може призвести до пропуску частини інтервалу активації. Методи, запропоновані Ланьї та Адлером, забезпечують швидке та більш надійне виявлення активації м'язів.

Сигнали ЕМГ є суперпозицією активностей кількох моторних одиниць. Необхідно декомпонувати ЕМГ сигнал, щоб виявити механізми, пов'язані з контролем м'язів і нервів. Було розроблено різні методи для

декомпозиції ЕМГ сигналів. Декомпозиція ЕМГ сигналу проводилась за допомогою підбору хвильового спектра та аналізу головних компонент хвильових коефіцієнтів. За словами Цзяньцзюна та ін., більше ніж один потенціал однієї моторної одиниці реєструється одночасно, накладаючись один на одного, особливо під час сильного м'язового скорочення. Однак, у 1997 році вони розробили метод, використовуючи хвильове перетворення для класифікації потенціалів моторних одиниць та розкладу ЕМГ сигналів на складові потенціали цих моторних одиниць. Особливістю цього методу є те, що він вимірює подібність хвильових форм потенціалів моторних одиниць з хвильової області. Цей метод базується на підборі спектрів у хвильовій області. Метод підбору спектрів іноді вважається більш ефективним, ніж методи підбору хвильових форм, особливо коли перешкоди спричинені високочастотним шумом. Метод, розроблений для розкладу багатокомпонентних ЕМГ сигналів, складається з чотирьох окремих процедур: процедури очищення сигналу від шуму, процедури виявлення сплесків, процедури класифікації сплесків і процедури розділення (декомпозиції) сплесків.

За словами Даніеля та ін., лише хвильові коефіцієнти низькочастотних смуг є важливішими для диференціації характеристик потенціалів дії, ніж високочастотні смуги. Ця концепція є суб'єктивною і була розроблена емпірично. Експериментальні результати Ріє Ямада та ін. у 2003 році показали, що високочастотна інформація, яка не була врахована, також є важливою для класифікації потенціалів моторних одиниць. Щоб подолати суб'єктивний критерій вибору ознак, вони запропонували інший метод, використовуючи аналіз головних компонент для хвильових коефіцієнтів. Алгоритм розкладу складається з чотирьох етапів обробки: сегментація, хвильове перетворення, аналіз головних компонент та кластеризація. Перевага цього методу полягає в тому, що він не потребує ручного вибору коефіцієнтів і враховує всю частотну інформацію [10].

### 1.3 Методи обробки ЕМГ сигналів

Для обробки ЕМГ сигналів застосовуються різні методи, які дозволяють отримати про нього якусь додаткову інформацію, недоступну в початковому вигляді.

Серед різноманітних перетворень сигналів найбільш поширеним є перетворення Фур'є (ПФ). Більшість сигналів, з якими ми маємо справу у практиці, подані у часовій області, що означає, що сигнал є функцією від часу. Таким чином, коли відображається сигнал на графіку, одна з координат (незалежна) відображає час, а інша (залежна) – амплітуду. Це дає представлення сигналу у часово-амплітудному просторі. Однак, для багатьох завдань обробки сигналу це представлення не є найкращим. У багатьох випадках найбільш значуща інформація схована у частотній області сигналу. Частотний спектр є набором частотних (спектральних) компонент, які відображають наявність певних частот у сигналі. Дуже часто інформація, яка не помітна у часовому представленні сигналу, стає очевидною у його частотному представленні.

Крім ПФ, існує безліч інших часто використовуваних перетворень сигналу. До них належать перетворення Гільберта, віконне ПФ, розподіл Вігнера, перетворення Уолша, вейвлет-перетворення та багато інших. Кожне з цих перетворень має свою область застосування, переваги та недоліки. Для того, щоб використовувати перетворення Фур'є, сигнал повинен бути стаціонарним, тобто всі його частотні складові мають бути присутніми у будь-який момент часу. Однак багато сигналів не відповідають цій вимозі. Тому на практиці цілком можлива ситуація, коли у двох різних за формою сигналів частотні спектри дуже схожі.

Оскільки перетворення Фур'є не дозволяє визначити, коли у складі сигналу була та чи інша частота, то було придумане віконне перетворення Фур'є (ВПФ). Суть методу полягає у розбитті нестационарного сигналу на «підінтервали стаціонарності», тобто відрізки, протягом яких

сигнал вважається стаціонарним. Для кожного з цих інтервалів проводиться перетворення Фур'є, і отримані спектри об'єднуються. Першою важливою проблемою у методі є визначення цих інтервалів стаціонарності. Зазвичай, чим коротші вікна використовуються, тим ширший спектр отримується [8].

Однак, намагаючись отримати вузький спектр, є ризик взяти перетворення Фур'є від настільки довгого інтервалу існування сигналу, що на ньому він може бути нестаціонарним. Ця проблема відома як принцип неозначеності Гейзенберга, що в контексті перетворення Фур'є означає, що неможливо отримати часово-частотне представлення сигналу з довільною точністю. Тобто не можна точно визначити для довільного моменту часу, які саме спектральні компоненти присутні у сигналі. Єдине, що можна визначити, це часові інтервали, протягом яких в сигналі існують певні частоти. Ця проблема відома як проблема роздільної здатності. Проблема роздільної здатності перетворення Фур'є пов'язана з шириною віконної функції, яка використовується. Вейвлет-перетворення є одним із найпоширеніших видів кратномасштабного аналізу. Такий аналіз розглядає сигнал на різних частотах і з різною роздільною здатністю одночасно, тобто кожна спектральна складова не аналізується окремо, як у випадку з ВПФ. КМА є ефективним, коли сигнал має високочастотні компоненти короткої тривалості і протяжні низькочастотні компоненти, саме такого виду сигнали є найбільш поширеними. На рисунку 1.2 відображений такого виду сигнал та його вейвлет-перетворення.

Неперервне вейвлет-перетворення визначається таким чином:

$$CWT_X^\varphi(\tau, S) = \frac{1}{\sqrt{|s|}} \int x(t) \varphi \frac{t-\tau}{s} dt, \quad (1.3)$$

де  $\psi(t)$  – функція перетворення, яка називається материнським вейвлетом. Перетворений сигнал є функцією двох змінних –  $\tau$  і  $s$ , які називаються параметрами зміщення та масштабу відповідно.

Параметр зміщення відноситься до місцеположення вікна, і вікно рухається уздовж сигналу. Цей термін відноситься таким чином, до часової інформації, присутньої в результаті перетворення. Параметр масштабу – величина, яка є зворотною частоті. Масштабування, як математична операція, розширює або стискає сигнал. Великі значення масштабів відповідають розширенню сигналу, а малі – стисненню. Якщо  $f(t)$  – початкова функція, то  $f(st)$  відповідає стисненій версії  $f(t)$ , якщо  $s > 1$  і розширеній версії, якщо  $s < 1$ .

Проте у визначенні вейвлет-перетворення коефіцієнт масштабу стоїть у знаменнику, тому при  $s > 1$  сигнал буде розширюватися, а при  $s < 1$  – стискатися.

Найбільш часто використовуваними вейвлетами є вейвети Хаара, Симлета, Добеши, Коїфлетса, Гауса, Морле, Шенона, Мейера, біортогональний та зворотній біортогональний, частотний В-сплайнний, «мексиканський капелюх», «французький капелюх» та інші. На рисунку 1.3 наведені приклади деяких найбільш поширених вейвлетів з аналітичними виразами та графіками [9].

Неперервне вейвлет-перетворення вимагає великої кількості обчислень, в результаті якого виходить надмірна кількість коефіцієнтів, яка набагато перевершує кількість відліків початкового сигналу. Дискретне вейвлет-перетворення забезпечує достатньо інформації як для аналізу сигналу, так і для його синтезу, будучи разом з тим не таким затратним, як по числу операцій, так і по необхідній пам'яті. ДВП оперує з дискретними значеннями параметрів  $s$  і  $\tau$ , які задаються, як правило, у вигляді степеневих функцій:

$$a = a_0^{-m}, b = k \cdot a^{-m}, a_0 > 1, m, k \in Z, \quad (1.4)$$

де  $Z$  – множина цілих чисел;

$m$  – параметр масштабу;

$k$  – параметр зсуву.

У загальному випадку, значення  $a$  може бути довільним, але зазвичай приймається рівним 2, при цьому перетворення називається діадним вейвлет-перетворенням (рисунки 1.2–1.3).







Рисунок 1.2 – Приклад сигналу з тривалою низькочастотною компонентою та короткими високочастотними, та його вейвлет-образ

**Класичний вейвлет**


$$\psi(t) = t \cdot e^{-\frac{t^2}{2}}$$

**Вейвлет Морле**


$$\psi(t) = e^{ikt - \frac{t^2}{2}}$$

**«Мексиканський капелюх»**

$$\psi(t) = (1 - t^2) e^{-\frac{t^2}{2}}$$

**«Французький капелюх»**

$$\psi(t) = \begin{cases} 1, & |t| < 1/3, \\ -1/2, & 1/3 < |t| \leq 1, \\ 0, & |t| > 1 \end{cases}$$

**Вейвлет Хаара**

$$\psi(t) = \begin{cases} 1, & 0 \leq t < 1/2, \\ -1/2, & 1/2 \leq t < 1, \\ 0, & t < 0, t \geq 1 \end{cases}$$




Рисунок 1.3 – Найбільш поширені вейвлети з аналітичними виразами та графіками

Швидке перетворення Хадамара (ФНТ) належить до родини дискретних ортогональних перетворень і широко використовується для обробки зображень та сигналів.

Перетворення Хадамара відображає дійсні послідовності у дійсні

послідовності частотної області. Його можна використовувати замість перетворення Фур'є для згортання сигналів, розгортання сигналів, кореляції сигналів і знаходження спектру потужності. Також з перетворення Хадамара можна отримати перетворення Фур'є.

Коли оброблювані послідовності є дійсними, перетворення Фур'є створює комплексні послідовності, у яких половина інформації є надлишковою. Перевага використання перетворення Хадамара замість перетворення Фур'є полягає в тому, що перетворення Хадамара використовує вдвічі менше пам'яті для отримання тієї ж інформації, яку дає швидке перетворення Фур'є (FFT). Крім того, ФНТ обчислюється на місці і є таким же ефективним, як перетворення Фур'є. Недоліком ФНТ є те, що розмір вхідної послідовності має бути ступенем числа 2.

Перетворення Хадамара функції  $x(t)$  визначається як:

$$x(t) = \int_{-\infty}^{\infty} x(t) \cdot \text{cas}(\omega t) dt, \quad (1.5)$$

де  $\text{cas}(x) = \cos(x) + \sin(x)$ .

Якщо  $Y$  представляє вихідну послідовність перетворення Хадамара, отриману за допомогою ФНТ, тоді  $Y$  отримується шляхом дискретної реалізації інтегралу Хадамара:

$$Y_k = \sum_{i=0}^{n-1} x_i \cdot \text{cas}\left(\frac{2\pi i k}{n}\right), \quad (1.6)$$

для  $k = 1, 2, \dots, n - 1$ , де  $n$  – кількість елементів у  $X$ .

$X$  є вхідною послідовністю і повинна бути ступенем числа 2. Щоб правильно обчислити ФНТ для  $X$ , кількість елементів,  $n$ , у послідовності повинна бути ступенем числа 2.  $n = 2^m$  для  $m = 1, 2, 3, \dots, 23$ . Якщо кількість елементів у  $X$  не є ступенем числа 2, то дане перетворення поверне помилку [11].

Також для обробки ЕМГ сигналів можна застосовувати

авторегресійні моделі. Авторегресійна (AR) модель часових рядів використовуються для дослідження ЕМГ сигналу. Поверхневий електрод вловлює активність ЕМГ від усіх активних м'язів у своїй близькості, тоді як внутрішньом'язовий ЕМГ є високочутливим і отримує мінімальні перехресні перешкоди від сусідніх м'язів. Таким чином, для поєднання зручності та точності існує велика потреба у розробці методики оцінювання внутрішньом'язового ЕМГ та його спектральних властивостей на основі поверхневих вимірювань. Дослідники представили сигнал сЕМГ як AR-модель з затриманим внутрішньом'язовим ЕМГ як вхідним сигналом.

Авторегресійна модель (AR) – модель часових рядів, в якій значення часового ряду в даний момент лінійно залежать від попередніх значень цього ж ряду. Авторегресійний процес порядку  $p$  визначається наступним чином:

$$X_t = c + \sum_{i=1}^p a_i X_{t-i} + \varepsilon_t, \quad (1.7)$$

де  $X_t$  – це прогнозоване значення на період  $t$ ;

$c$  – константа, зазвичай для спрощення рівняється нулю;

$a_i$  – параметри моделі, коефіцієнти авторегресії;

$\varepsilon_t$  – білий шум.

У статистичному аналізі часових рядів моделі авторегресії – ковзного середнього (ARMA) пропонують опис стаціонарного стохастичного процесу в термінах двох многочленів, одного для авторегресії, а другого – для ковзного середнього. Загальну модель ARMA було описано в 1951 році в дисертації Пітера Уїтгла «Перевірка гіпотез в аналізі часових рядів» і популяризовано в книзі Джорджа Бокса та Гвіліма Дженкінса 1970 року. Для заданого часового ряду даних  $X_t$  модель ARMA є інструментом для розуміння та передбачування майбутніх значень цього ряду. Ця модель складається з двох частин: авторегресійної, та ковзного середнього. Частина AR передбачає регресування цієї змінної за її

власними запізнюваними (тобто, минулими) значеннями. Частина *МА* передбачає моделювання члену похибки як лінійної комбінації членів похибки, що стаються в поточний момент та в різні моменти часу в минулому. На цю модель зазвичай посилаються як на модель *ARMA*( $p, q$ ), де  $p$  – порядок авторегресійної частини, а  $q$  – порядок частини ковзного середнього. Позначення *AR*( $p$ ) стосується авторегресійної моделі порядку  $p$ . Модель ковзного середнього можна представити наступним чином:

$$X_t = \mu + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}, \quad (1.8)$$

де  $X_t$  – це прогнозоване значення на період  $t$ ;

$\mu$  – математичне сподівання;

$\alpha$  – дійсні числа, авторегресійні коефіцієнти;

$\theta_i$  – дійсні числа, коефіцієнти змінного середнього;  $\varepsilon_t$  – білий шум.

Підхід авторегресійного інтегрованого ковзного середнього (*ARIMA*) до часових рядах полягає в тому, що в першу чергу оцінюється стаціонарність ряду. Різними тестами виявляються наявність поодиноких коренів і порядок інтегрованості часового ряду (зазвичай обмежуються першим або другим порядком). Далі, при необхідності, (якщо порядок інтегрованості більше нуля) ряд перетворюється взяттям різниці відповідного порядку і вже для перетвореної моделі будується деяка *ARMA*-модель, оскільки передбачається, що отриманий процес є стаціонарним, на відміну від вихідного нестаціонарного процесу.

Модель *ARIMA*( $p, d, q$ ) для нестаціонарного часового ряду  $X_t$  має вигляд:

$$\Delta^d X_t = c + \varepsilon_t + \sum_{i=1}^p a_i \Delta^d X_{t-1} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}, \quad (1.9)$$

де  $X_t$  – це прогнозоване значення на період  $t$ ;

$c$  – константа, зазвичай для спрощення рівняється нулю;

$a_i$  – параметри моделі, коефіцієнти авторегресії;

$\Delta^d$  – оператор різниці часового ряду порядку  $d$  (послідовне взяття  $d$  раз різниць першого порядку – спочатку від тимчасового ряду, потім від отриманих різниць першого порядку, потім від другого порядку і т.д.);

$\varepsilon_t$  – білий шум.

## 2 ОГЛЯД АЛГОРИТМІВ ТА МЕТРИК ДЛЯ КЛАСИФІКАЦІЇ ЕЛЕКТРОМІОГРАФІЧНИХ СИГНАЛІВ

### 2.1 Аналіз методів класифікації ЕМГ сигналів на основі штучних нейронних мереж

Штучні нейронні мережі є потужним інструментом для класифікації електроміографічних (ЕМГ) сигналів завдяки їх здатності обробляти складні та нелінійні дані. В останні роки ці методи знайшли широке застосування в медичних та біомедичних дослідженнях, зокрема у виявленні та класифікації патологій рухового апарату.

ШНМ, такі як багатошарові перцептрони (MLP), згорткові нейронні мережі (CNN) та рекурентні нейронні мережі (RNN), були успішно застосовані для аналізу ЕМГ сигналів (рисунок 2.1).

Багатошаровий перцептрон, будучи одним з найпростіших типів ШНМ, складається з декількох шарів нейронів, кожен з яких пов'язаний зі всіма нейронами наступного шару. MLP добре підходить для базової класифікації, але має обмежені можливості при роботі зі складними патернами ЕМГ сигналів [12].

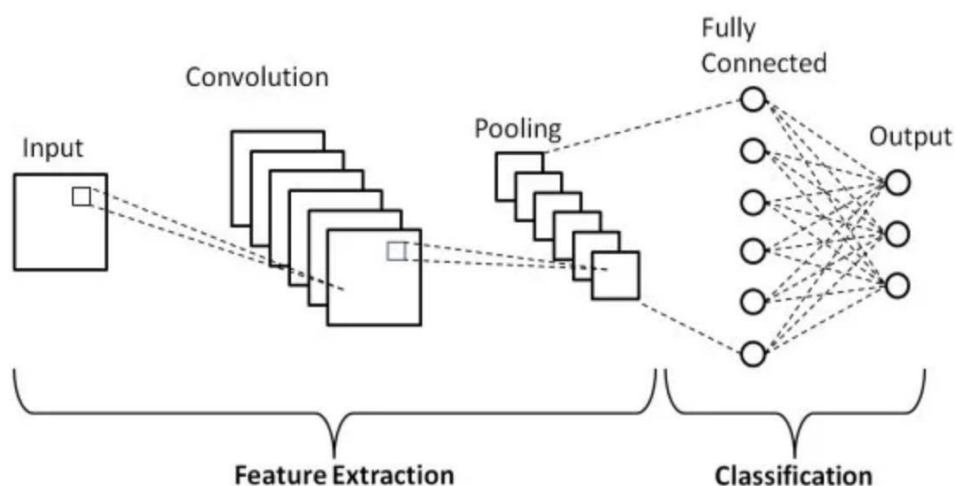


Рисунок 2.1 – Архітектура CNN

Згорткові нейронні мережі (CNN) показують високі результати при роботі з двовимірними даними, такими як зображення або часово-частотні представлення сигналів. CNN використовують згорткові та підвибіркові (subsampling) шари для автоматичного виявлення суттєвих ознак з вхідних даних. Приклади застосування CNN для класифікації ЕМГ сигналів включають використання часово-частотних спектрограм, що дозволяє ефективно виділяти особливості сигналів різних м'язових рухів.

CNN складається з таких основних компонент: конволюційні шари: основним будівельним блоком CNN є конволюційний шар. Він складається з набору фільтрів (ядр), які проходять через вхідні дані (наприклад, зображення або сигнал) і витягують ключові ознаки. Цей процес називається згорткою. Кожен фільтр навчений розпізнавати певні особливості вхідних даних, такі як контури, текстури або інші патерни.

Згортка зберігає просторовий зв'язок між пікселями, вивчаючи особливості зображення за допомогою невеликих квадратів вхідних даних. Це операція з тензорами (точковий добуток), де два тензори слугують вхідними даними, а результуючий тензор генерується як вихідний. Цей рівень застосовує плитковий підхід до фільтрації вхідного тензора з використанням невеликого вікна, відомого як ядро. Ядро визначає конкретні характеристики, які операція згортки прагне відфільтрувати, генеруючи значний відгук при виявленні потрібних ознак.

Згортковий шар обчислює точковий добуток між значенням фільтра і значеннями пікселів зображення, а матриця, сформована шляхом ковзання фільтра по зображенню, називається згорнутою ознакою, картою активації або картою ознак.

Поведінка згорткового шару в першу чергу визначається наступними основними гіперпараметрами:

- розміром ядра: визначає розмір ковзного вікна. Зазвичай рекомендується використовувати менші розміри вікон, бажано непарні значення, такі як 1, 3, 5, і іноді, рідко 7;

– кроком: параметр `stride` визначає кількість пікселів, на яку переміщуватиметься вікно ядра під час кожного кроку згортки. Зазвичай він дорівнює 1, щоб гарантувати, що жодне місце на зображенні не буде пропущено;

– заповненням (`Padding`): заповнення відноситься до техніки додавання нулів до країв зображення. Застосовуючи заповнення, ядро може повністю фільтрувати кожну позицію вхідного зображення, забезпечуючи правильну обробку навіть країв;

– кількістю фільтрів, глибиною: кількість фільтрів у шарі, що згортається, визначає кількість шаблонів або особливостей, які шар намагатиметься ідентифікувати. Іншими словами, вона регулює кількість різних характеристик або елементів, на виявленні яких буде зосереджений згортковий шар (рисунки 2.2);

– шарами підсумовування (`Pooling layers`): після конволюційних шарів зазвичай йдуть шари підсумовування, які зменшують розмірність даних, зберігаючи найважливішу інформацію. Найчастіше використовуються `max-pooling` та `average-pooling`. Вони допомагають зменшити кількість параметрів і обчислювальну складність, а також підвищують стійкість моделі до зміщень та інших варіацій у даних.

Два основні типи шарів підсумовування, які зазвичай використовуються:

– `Max Pooling`: вибирає піксель з максимальним значенням для передачі у вихідний масив;

– `Average Pooling`: обчислює середнє значення в межах рецептивного поля для передачі у вихідний масив.

Пулінг має значну перевагу в тому, що не потребує навчання жодних параметрів. Однак, ця особливість також може бути потенційним недоліком, оскільки пулінг може призвести до втрати важливої інформації. Хоча пулінг зменшує розмірність і витягує ключові особливості, існує можливість втрати важливих деталей під час цього процесу.




Рисунок 2.2 – Приклад шару макс-пулінга

Активаційні функції: після кожного конволюційного шару зазвичай застосовується активаційна функція, така як ReLU (Rectified Linear Unit), яка вводить нелінійність у модель. Це дозволяє мережі навчатися більш складним та різноманітним ознакам.

Повнозв'язні шари (Fully Connected Layers): в кінці CNN зазвичай додаються один або кілька повнозв'язних шарів, які виконують функцію класифікації або регресії. Вони з'єднані з усіма нейронами попереднього шару і використовуються для остаточної обробки витягнутих ознак та формування вихідного результату.

Його мета полягає в об'єднанні та перетворенні високорівневих ознак у кінцевий результат, такий як ймовірності класів або значення регресії, залежно від конкретного завдання. У той час як згорткові шари та шари підсумовування зазвичай використовують функції активації ReLU, повнозв'язні шари (FC) зазвичай застосовують функцію активації softmax для відповідної класифікації вхідних даних, виробляючи ймовірність від 0 до 1.

Цей шар перетворює тривимірний шар у мережі в одновимірний вектор, щоб відповідати вхідним даним для повнозв'язаного шару для класифікації. Наприклад, тензор розміром  $5 \times 5 \times 2$  буде перетворений у вектор розміром 50.

CNN навчаються за допомогою алгоритму зворотного поширення помилки (backpropagation) і оптимізаційних методів, таких як градієнтний

спуск. Під час навчання мережа коригує ваги фільтрів і нейронів, щоб мінімізувати помилку між передбаченими та фактичними результатами.

Конволюційні нейронні мережі мають великий потенціал для класифікації ЕМГ сигналів через їх здатність автоматично витягувати релевантні ознаки без необхідності попередньої обробки. Для того, щоб застосувати CNN для класифікації ЕМГ сигналів потрібно спершу підготувати дані, тобто перетворити в двовимірні форми, такі як спектрограми або часово-частотні карти, які можуть бути використані як вхідні дані для CNN [15].

CNN демонструють високу ефективність у завданнях класифікації ЕМГ сигналів і можуть значно покращити точність діагностики та контролю рухів у медичних та біомеханічних застосуваннях.

Рекурентні нейронні мережі (RNN) та їх варіанти, такі як довготривала короткочасна пам'ять (LSTM) та унітарна рекурентна мережа (GRU), добре підходять для роботи з послідовностями даних, де важлива інформація про часовий контекст. Це робить їх ідеальними для аналізу ЕМГ сигналів, які мають часову структуру. RNN дозволяють враховувати попередні стани при прийнятті рішень щодо поточного стану, що сприяє точнішій класифікації складних рухових патернів.

Рекурентні штучні нейронні мережі можуть пригадувати важливі деталі про вхідні дані, які вони отримують, завдяки своїй внутрішній пам'яті, що дозволяє їм з великою точністю передбачати, що станеться далі. Саме тому вони використовуються для обробки тексту, мови, фінансових даних, відео, аудіо та багатьох інших типів послідовних даних. У порівнянні з іншими алгоритмами, рекурентні нейронні мережі можуть глибше зрозуміти послідовність та її контекст.

Інформація в рекурентній структурі нейронної мережі циклічно передається по колу. Коли вона приймає рішення, вона враховує поточні вхідні дані, а також те, що вона дізналася з попередніх вхідних даних. Короткочасна пам'ять присутня у типових RNN. У поєднанні з LSTM вони

мають довготривалу пам'ять. Однак завдяки своїй внутрішній пам'яті рекурентна нейронна мережа може згадувати ці символи. Вона генерує вихідні дані, копіює їх, а потім подає назад у мережу. Рекурентні нейронні мережі поєднують інформацію з минулого з інформацією з теперішнього [14].

Як результат, у RNN є два входи: теперішнє і недавнє минуле. Це важливо, оскільки послідовність даних надає критично важливу інформацію про те, що станеться далі, і саме тому RNN може виконувати завдання, які не під силу іншим алгоритмам.

Варто зазначити, що RNN застосовує ваги як до поточних, так і до попередніх входів. Крім того, рекурентна нейронна мережа коригує ваги з часом за допомогою градієнтного спуску та зворотного поширення (BPTT).

Типи рекурентних нейронних мереж:

- BRNN – це тип рекурентної нейронної мережі (PHM) з іншим дизайном мережі. Двонаправлені PHM (BRNN) залучають майбутні дані для підвищення точності, тоді як однонаправлені PHM використовують лише попередні вхідні дані для створення прогнозів;

- GRU (gated recurrent units): ця версія PHM схожа на LSTM, оскільки вона також спрямована на вирішення проблем короткочасної пам'яті моделей PHM. Вона використовує приховані стани замість «станів комірок» для управління інформацією і має лише два вентиля: вентиль скидання та вентиль оновлення. Вентилі скидання і оновлення, як і вентилі в LSTM, визначають, скільки і якої інформації зберігається;

- мережі довготривалої короткочасної пам'яті (LSTM) – це тип рекурентної нейронної мережі, яка розширює ємність пам'яті. Як результат, вони дуже добре підходять для навчання на основі значного досвіду, розділеного тривалими проміжками часу (рисунок 2.3).

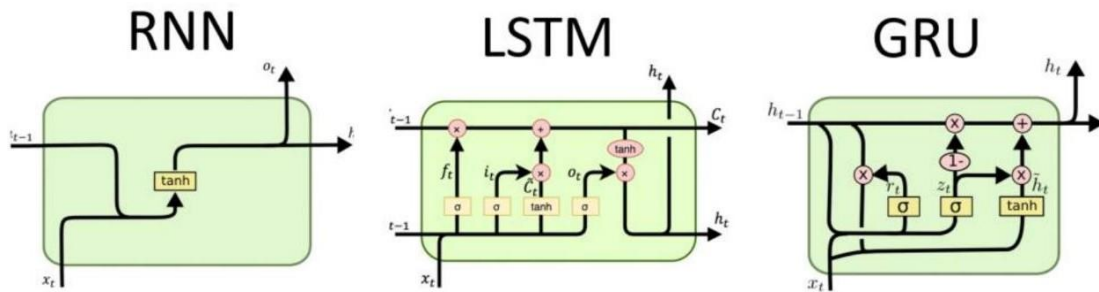


Рисунок 2.3 – Приклади архітектур рекурентних нейронних мереж

Рекурентна нейронна мережа розгортається у кілька шарів, причому зазвичай розгортка залежить від кількості слів у послідовності. Тобто при отриманні на вхід речення з  $n$  слів використовується  $n$  шарів (рисунок 2.4).




Рисунок 2.4 – Схематична діаграма типової рекурентної мережі

На рисунку представлено вище зображено схему роботи та її розгортку рекурентно нейронної мережі, де:  $x = (x_1, x_2, \dots, x_n)$  – вхідні дані, що представляють собою послідовність яка може бути опрацьована рекурентно. У даному випадку  $x_t$  – векторне представлення слова,  $t$  – поточний крок,  $s$  – при обробці кожного символу, нейронна мережа зберігає прихований внутрішній стан,  $U$  – вхідна вагова матриця,  $V$  – вихідна вагова матриця,  $W$  – вагова рекурсивна матриця, яка використовується у якості параметрів методу, по суті є вихідною матрицею

попереднього шару.

Операція на кожному кроці рекурентної нейронної мережі може бути визначена як:

$$h_t = \sigma(Ux_t + Ws_t - 1), \quad (2.1)$$

де  $\sigma$  – початкова функція;

$h_t$  – вихідні дані.

Результат роботи рекурентної нейронної мережі виглядає як:

$$o_t = \sigma(Vs_t). \quad (2.2)$$

Long short-term memory, LSTM, довга короткочасна пам'ять – одна з можливих архітектур рекурентних нейронних мереж, що була створена у 1997 році. Довга короткочасна пам'ять була вперше створена для вирішення проблеми довготривалих залежностей.

Довга короткочасна пам'ять відрізняється від традиційних рекурентних мереж тим, що не переписує збережені значення на кожному кроці.

Ефективність подібних нейронних мереж заключається в збільшенні контролю над результатами і відповідно в збільшенні контролю над помилками та їхнім уникненням, а також за рахунок комірок пам'яті дозволяє вираховувати довготривалі віддалені залежності, наприклад зв'язок між першим та останнім словом у реченні.

Нейронна мережа довгої короткочасної пам'яті має вузли довгої короткочасної пам'яті на додачу або замість інших вузлів. Вузли довгої короткочасної пам'яті пам'ятає значення довгих та коротких часових проміжків. Часто вузли довгої короткочасної пам'яті використовуються у блоках з кількох поєднаних вузлів.

Вузол довгої короткочасної пам'яті має вхідний та вихідний вентиля, забувальний вентиль та комірку пам'яті. Вхідний вентиль  $i_t$  визначає

важливість вхідних даних  $x_t$  та чи необхідно змінити стан комірки пам'яті:

$$i_t = \sigma(U_i x_t + W_i s_t + b_i). \quad (2.3)$$

Забувальний вентиль  $f_t$  визначає, чи пам'ятати чи забути попередній стан:

$$f_t = \sigma(U_f x_t + W_f s_{t-1} + b_f). \quad (2.4)$$

Тангенсна функція  $\tau_t$  грає роль функції активації:

$$\tau_t = \tan(U_\tau x_t + W_\tau s_{t-1} + b_\tau). \quad (2.5)$$

Значення комірки пам'яті отримується за формулою:

$$c_t = i_t \circ \tau_t + f_t \circ c_{t-1}. \quad (2.6)$$

Вихідний фільтр  $\sigma_t$  визначає, яку частину комірки пам'яті буде передано наступному вузлу:

$$o_t = \sigma(U_o x_t + W_o s_t + b_o). \quad (2.7)$$

Стан  $s_t$ :

$$s_t = o_t \circ \tan(c_t), \quad (2.8)$$

де  $\circ$  – добуток Адамара;

$\sigma$  – логістична функція активації вентилів  $\sigma(x) = (1 + e^{-x})^{-1}$ ;

$b$  – параметр упередження;

$W, U$  – матриці ваг.

Нульові  $s_0$  та  $c_0$  ініціалізуються перед проходженням першого вузла.

На рисунку 2.5 нижче відображена схема роботи довгої короткочасної пам'яті.

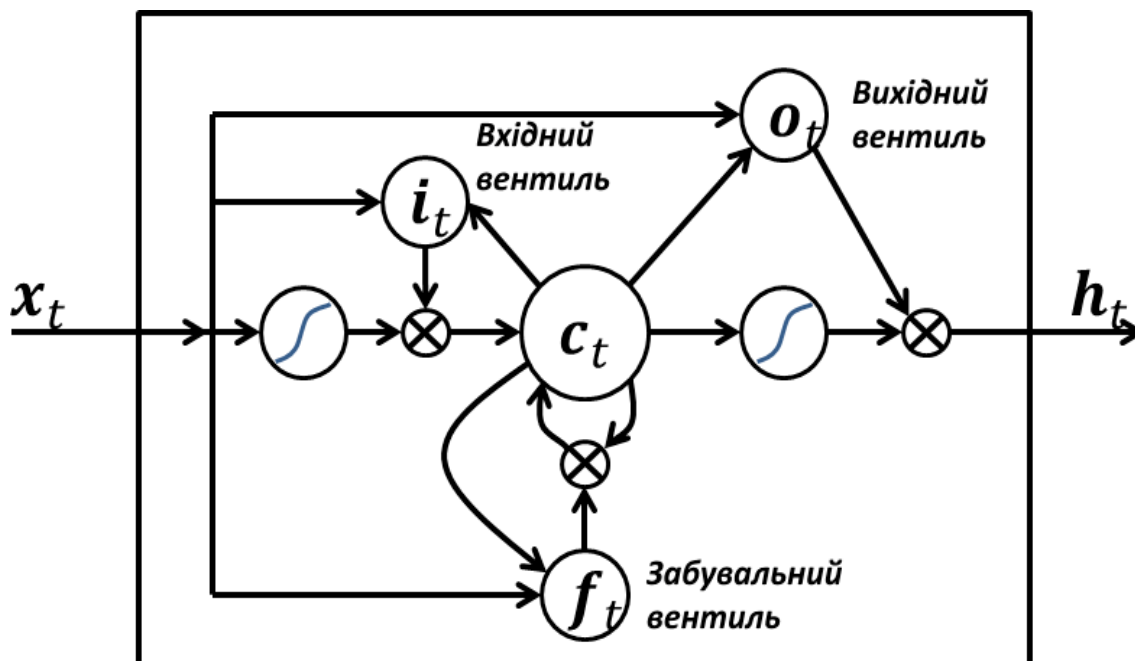


Рисунок 2.5 – Схема роботи довгої короткочасної пам'яті

Отже, CNN є спеціалізованими нейронними мережами, призначеними для обробки даних, що мають просторову структуру, таких як зображення та сигнали. Перевагами згорткових нейронних мереж є те, що вони ефективні для виявлення локальних патернів в ЕМГ сигналах, що дозволяє моделі фокусуватися на важливих характеристиках, а також забезпечують високу точність класифікації для часових рядів та сигналів, таких як ЕМГ. Однак даний тип нейронних мереж має й недоліки, такі як значні обчислювальні ресурси для тренування та оцінки, необхідність великої кількості тренувальних даних для досягнення високої точності.

RNN використовують зворотні зв'язки для обробки послідовностей даних, що робить їх придатними для аналізу часових рядів, таких як ЕМГ сигнали. Перевагою даного типу нейронних мереж є те, що вони здатні зберігати інформацію про попередні стани сигналу, що важливо для аналізу

часових рядів. Також рекурентні нейронні мережі можуть враховувати контексті залежності в сигналах. Основними недоліками даних нейронних мереж є те, що вони вимагають високих обчислювальних витрат і часу для навчання, та використовуючи їх складно навчати довгі послідовності через проблеми з градієнтом, що затухає.

LSTM є вдосконаленням RNN, призначеним для вирішення проблеми затухаючого градієнта. Однією з її основних переваг є те, що дана нейронна мережа є ефективною на довгих послідовностях та підходить для обробки складних часових рядів, таких як ЕМГ сигнали. Основними недоліками даної нейронної мережі є те, що вона вимагає значних обчислювальних ресурсів для тренування та оцінки, також складність її налаштування через велику кількість гіперпараметрів та складну архітектуру.

Отже, кожен з розглянутих методів має свої сильні та слабкі сторони, що впливають на їх застосування для класифікації ЕМГ сигналів. Вибір конкретної архітектури нейронної мережі залежить від вимог до точності, обчислювальних ресурсів, доступності тренувальних даних та специфіки сигналів. Правильний вибір та налаштування моделі можуть значно підвищити ефективність і точність класифікації ЕМГ сигналів.

Застосування ШНМ для класифікації ЕМГ сигналів має свої виклики, зокрема потребу у великій кількості маркованих даних для навчання та високі обчислювальні витрати. Проте, з розвитком технологій і появою нових архітектур нейронних мереж, очікується подальше зростання точності та ефективності цих методів у біомедичних додатках.

Таким чином, штучні нейронні мережі відкривають нові можливості для класифікації ЕМГ сигналів, забезпечуючи високу точність і адаптивність до різноманітних біомедичних задач.

## 2.2 Проблеми та виклики в класифікації ЕМГ сигналів

Класифікація електроміографічних (ЕМГ) сигналів представляє

собою складне завдання через низку проблем та викликів, які необхідно подолати для досягнення високої точності та надійності. Основні проблеми включають в себе наступні аспекти:

- шум та артефакти: ЕМГ сигнали часто забруднені шумом та артефактами, такими як електричні перешкоди від навколишнього середовища, рухи електродів і активність інших м'язів. Це ускладнює виділення корисної інформації і може призвести до помилок у класифікації;

- нестационарність сигналів: ЕМГ сигнали є нестационарними, тобто їх характеристики змінюються з часом. Це вимагає використання адаптивних методів обробки сигналів, здатних ефективно реагувати на зміни в сигналі;

- індивідуальні відмінності: міжособові варіації у фізіології та анатомії впливають на ЕМГ сигнали, що ускладнює створення універсальних моделей класифікації. Це потребує індивідуального налаштування моделей для кожного користувача;

- нестача маркованих даних: для тренування моделей машинного навчання необхідна велика кількість маркованих даних, які важко отримати через складність та вартість експериментів з реєстрації ЕМГ сигналів. Це обмежує можливості застосування глибоких нейронних мереж, які потребують великого обсягу даних;

- високі обчислювальні витрати: обробка та класифікація ЕМГ сигналів, особливо в реальному часі, потребує значних обчислювальних ресурсів. Це вимагає оптимізації алгоритмів та апаратного забезпечення для забезпечення швидкої та ефективної обробки;

- складність валідації моделей: перевірка та валідація моделей класифікації ЕМГ сигналів є складною задачею через необхідність проведення експериментів на живих суб'єктах та врахування багатьох факторів, які можуть впливати на результати;

- розподіл даних: ЕМГ сигнали мають високу розподіленість та

низьку щільність інформації, що ускладнює процес навчання моделей. Це вимагає використання спеціальних методів для попередньої обробки та вилучення ознак з сигналів.

Подолання цих проблем вимагає розробки нових методів обробки сигналів, оптимізації існуючих алгоритмів та застосування сучасних технологій машинного навчання. Незважаючи на численні виклики, класифікація ЕМГ сигналів має великий потенціал для розвитку в медичній діагностиці, реабілітації та інших областях, що робить цю сферу досліджень надзвичайно перспективною та актуальною.

### 2.3 Метрики оцінки моделі класифікації ЕМГ сигналів

Для оцінки моделі класифікації ЕМГ (електроміографічних) сигналів використовуються різні метрики, які дозволяють оцінити її точність, ефективність та надійність.

Матриця помилок (confusion matrix) є корисним інструментом для оцінки продуктивності класифікаційної моделі. Вона показує, скільки випадків кожного класу були правильно і неправильно класифіковані моделлю. Розглянемо приклад матриці помилок для двокласової класифікації ЕМГ сигналів (таблиця 2.1).

Таблиця 2.1 – Матриця помилок матриця

	Прогноз: позитивний	Прогноз: негативний
Реальний: позитивний	True Positive (TP)	False Negative (FN)
Реальний: негативний	False Positive (FP)	True Negative (TN)

Матриця помилок матриця помилок складається з наступних елементів:

- True Positive (TP) – кількість правильно класифікованих позитивних випадків;
- False Negative (FN) – кількість позитивних випадків, які були

неправильно класифіковані як негативні;

– False Positive (FP) – кількість негативних випадків, які були неправильно класифіковані як позитивні;

– True Negative (TN) – кількість правильно класифікованих негативних випадків.

На основі матриці помилок можна розрахувати різні метрики продуктивності:

– точність (Accuracy) – частка правильних прогнозів серед усіх прогнозів:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}; \quad (2.9)$$

– чутливість (Sensitivity) або повнота (Recall) – частка правильно ідентифікованих позитивних прикладів серед усіх позитивних прикладів:

$$Recall = \frac{TP}{TP+FN}; \quad (2.10)$$

– специфічність (Specificity) – частка правильно ідентифікованих негативних прикладів серед усіх негативних прикладів:

$$Specificity = \frac{TN}{TN+FP}; \quad (2.11)$$

– точність передбачення (Precision) – частка правильних позитивних прогнозів серед усіх позитивних прогнозів:

$$Precision = \frac{TP}{TP+FP}; \quad (2.12)$$

– F1-міра (F1-score) – гармонічне середнє між точністю

передбачення і чутливістю:

$$F1 - score = \frac{2TP}{2TP+FP+FN}; \quad (2.13)$$

– ROC-крива (Receiver Operating Characteristic Curve) та AUC (Area Under the Curve) – ROC-крива відображає співвідношення між чутливістю і 1- специфічністю для різних порогів, а AUC показує загальну здатність моделі відокремлювати класи;

– Крос-валідація (Cross-validation) – метод оцінки, який використовує розбиття даних на кілька підмножин для перевірки стабільності і узагальнюваності моделі.

Ці метрики дозволяють всебічно оцінити якість роботи моделі класифікації ЕМГ сигналів і зробити висновки про її ефективність у реальних умовах [13].

### 3 ОСОБЛИВОСТІ РЕАЛІЗАЦІЇ ПРОГРАМНОГО ЗАСТОСУНКУ

#### 3.1 Постановка задачі та огляд обраного датасету

Для програмної реалізації була обрана задача розпізнавання жестів за допомогою електроміографічних сигналів, адже розпізнавання жестів має багато застосувань у медицині, інженерії та робототехніці. Це також дозволяє розробляти нові та більш природні підходи для взаємодії людини з машиною. Розпізнавання жестів рук у режимі реального часу полягає у виявленні, без відчутної затримки, певного жесту, який виконаний рукою в будь-який момент. Для реалізації поставленої задачі було обрано набір даних «EMG Data for Gestures». Цей набір даних містить необроблені електроміографічні сигнали, які були записані за допомогою браслета MYO Thalmic. Даний браслет був розміщений на передпліччях 36 учасників під час виконання статичних жестів рук. Браслет MYO Thalmic оснащений восьма датчиками, які рівномірно розташовані навколо передпліччя та які одночасно отримують міографічні сигнали. Кожен з учасників виконував дві серії рухів, кожна з яких складається з 6–7 базових жестів (рисунок 3.1). Кожен жест виконувався протягом 3 секунд з перервою в 3 секунди між жестами [2].




Рисунок 3.1 – Браслет MYO Thalmic та його розміщення на передпліччі

Кожний рядок даного набору даних містить наступну інформацію:

- часові позначки, що виміряні у мілісекундах;
- канали ЕМГ, що записують електричну активність м'язів. Всього таких каналів у датасеті 8 (рисунок 3.2).

Наступні мітки класів, які є ідентифікаторами жестів:

- 0 – непозначені дані;
- 1 – рука у спокої;
- 2 – згорнута рука в кулак;
- 3 – згин зап'ястя;
- 4 – розгин зап'ястя;
- 5 – радіальне відхилення;
- 6 – ліктьове відхилення;
- 7 – розкриття долоні (даний жест не був виконаний всіма учасниками).




Рисунок 3.2 – Візуальне представлення жестів набору даних «EMG Data for Gestures»

Набір даних «EMG Data for Gestures» містить приблизно 30000–50000 зразків на кожну з колонок, а також не містить пропущених даних.

Даний набір даних складається з різних текстових файлів, кожен з яких відповідає одній серії жестів, виконаних одним учасником.

### 3.2 Попередня обробка даних

Попередні дослідження з розпізнавання жестів показали, що витягування огинаючої з необроблених sEMG сигналів може надати цінну інформацію про активність м'язів. Огинаюча sEMG сигналів – це згладжена крива, отримана шляхом обробки сигналів, що спрощує представлення даних, знижує шум, відображає рухові дії та відіграє важливу роль у класифікації sEMG сигналів. Для отримання огинаючої зазвичай використовуються кілька методів, таких як рухоме середнє, детекція огинаючої, перетворення Гільберта тощо. У цьому дослідженні застосовується ФНТ для витягування огинаючої sEMG сигналів.

ФНТ є ефективною технікою обробки сигналів, що використовується для витягування аналітичних огинаючих з часових сигналів. Під час обчислювального процесу вхідний часовий сигнал спочатку перетворюється за допомогою перетворення Фур'є, щоб відобразити сигнал у частотній області. Потім ФНТ виконує фазові коригування відповідно до властивостей сигналу частотної області, в результаті чого уявна частина перетвореного сигналу відповідає огинаючій оригінального сигналу, тоді як дійсна частина відповідає миттєвій фазі сигналу. Основною перевагою ФНТ є його обчислювальна ефективність, яка дозволяє швидко та ефективно витягувати огинаючу, тим самим забезпечуючи надійну підтримку для контролю та розпізнавання sEMG сигналів.

Також був використаний метод перекривного ковзного вікна для сегментації раніше витягнутого набору даних огинаючої sEMG сигналів м'язів. Цей підхід дозволяє нам контролювати перекриття між вікнами даних, регулюючи розмір вікна та крок, і розкладати сигнали на сегменти м'язової активності для витягування ознак. Розмір вікна ( $w$ ) визначає тривалість кожного вікна. Крок ( $s$ ) визначає інтервал часу між вікнами, контролюючи їхню швидкість зсуву. Менший крок призводить до

збільшення перекриття та надає більше даних для тренування та оцінки, у такому підході сусідні вікна частково перекриваються. Сегментація на основі ковзного вікна ефективно враховує часові характеристики sEMG сигналів м'язів, підвищуючи точність та надійність системи розпізнавання жестів. Використовуючи цю техніку, витягується релевантна часова інформація з sEMG сигналів, покращуючи здатність системи ідентифікувати та розпізнавати різні жести (рисунки 3.3–3.4).

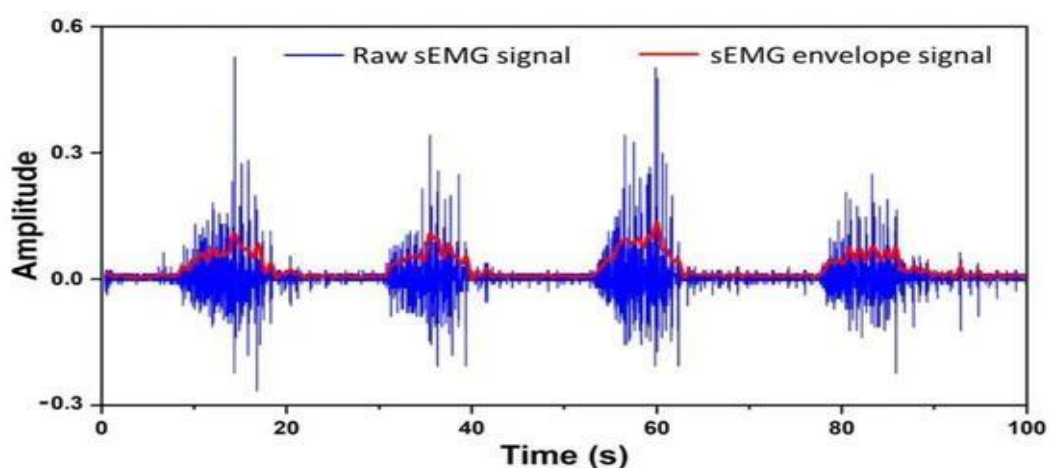


Рисунок 3.3 – Витягування сигналу огинаючої




Рисунок 3.4 – Сегментація sEMG сигналу за допомогою вікна

Враховуючи тривалість жестів та ефективне використання даних, розмір вікна був встановлений як 30 мс з кроком у 10 мс. Такий підхід до сегментації дозволив ефективно витягувати та аналізувати релевантну інформацію з набору даних. Після сегментації даних, вони були поділені на навчальний, валідаційний та тестовий набори. Зокрема, було виділено 80% набору даних для навчального набору, 10% для валідаційного та решту 10% для тестового набору. Такий розподіл дозволяє оцінити продуктивність моделі на різних наборах даних, забезпечуючи всебічну оцінку її можливостей.

### 3.3 Вибір моделі для навчання

Алгоритми глибокого навчання пропонують кілька переваг для класифікації та розпізнавання sEMG сигналів, включаючи швидке навчання, придатність для застосувань у реальному часі, високу гнучкість та здатність автоматично витягувати ознаки без ручного втручання. Хоча sEMG сигнали відносно стабільні під час спокою, вони демонструють швидкі зміни для відображення активності м'язів під час виконання жестів. Після завершення жесту зміни в sEMG сигналах припиняються, і сигнали залишаються відносно стабільними, більше не представляючи часову послідовність змін. У контексті класифікації та розпізнавання sEMG сигналів важливо зосередитися на змінах сигналу під час виконання жесту, а не на його стабільному стані. Таким чином, модель класифікації повинна приділяти увагу захопленню динамічних ознак змін жесту, а не моделюванню довготривалих послідовностей.

Рекурентні нейронні мережі (RNN), такі як LSTM, зазвичай використовуються для обробки довготривалих часових залежностей, але можуть не підходити для короткотривалих sEMG сигналів. З іншого боку, згорткові нейронні мережі (CNN) відмінно справляються з навчанням локальних ознак у часовій послідовності, демонструють кращу швидкість

навчання, ніж LSTM, і особливо підходять для обробки sEMG сигналів, зібраних з декількох м'язових каналів.

Архітектура запропонованої моделі CNN з інтегрованим механізмом уваги в основному складається з згорткових шарів і шарів механізму уваги. Зокрема, після кожного згорткового шару слідує шар нормалізації (batch normalization) і функція активації випрямленого лінійного вузла (ReLU) для прискорення збіжності та вирішення проблеми вибуху градієнта. Щоб обробляти дані каналів з різних м'язових позицій, розміри згорткових ядер у першому, другому та третьому шарах встановлені на (3, 3), (4, 3) і (5, 3) відповідно. Переміщуючи ці ядра вздовж часових та каналових вимірів, мережа може одночасно захоплювати динамічні патерни в часовій послідовності та кореляції між різними каналами. Крім того, дизайн з накладанням ядер різних розмірів дозволяє згортковим шарам поступово збільшувати своє рецептивне поле, що сприяє захопленню більш комплексних ознак (рисунок 3.5).




Рисунок 3.5 – Структура обраної моделі

Варто також зазначити, що шар механізму уваги ECA інтегрований після першого згорткового шару. Цей шар може посилювати фокус і здатність захоплення важливих ознак через адаптивний механізм розподілу ваг, що сприяє покращенню продуктивності та узагальненню моделі. На цьому етапі модель вже володіє багатими можливостями вираження ознак; проте можуть залишатися випадки надлишкових або менш релевантних ознак. Для введення більш тонкого акценту та коригування в рамках

прийняття рішень моделі, ще один шар механізму ECA інтегрований після останнього повнозв'язаного шару. Включення механізму ECA на цьому етапі спрямовує фокус моделі на ознаки, які суттєво впливають на поточне завдання класифікації жестів, тим самим покращуючи здатність моделі розрізняти складні EMG сигнали.

Крім того, для запобігання перенавчанню були включені шари випадкового відключення (dropout). Нарешті, шар softmax з кількістю вузлів, рівною кількості категорій жестів, був доданий для перетворення виходу моделі в ймовірнісний розподіл для кожного класу, що дозволяє ефективно класифікувати жести.

Крім того, включення шарів нормалізації груп (BN) і шарів випадкового відключення (dropout) усуває необхідність зниження швидкості навчання, оскільки вони можуть покращити стабільність і здатність моделі до узагальнення, сприяючи більш плавній конвергенції. Для оптимізації процесу навчання моделі використовується оптимізатор adam, який є алгоритмом оптимізації на основі градієнта, що ефективно оновлює параметри моделі з метою мінімізації функції втрат. Для функції втрат було обрано категорійну крос-ентропію, широко використовуваний метрику для багатокласових задач класифікації. Ця метрика вимірює розбіжність між прогнозами моделі та фактичними мітками і може спрямовувати оптимізацію параметрів моделі (рисунок 3.6).




Рисунок 3.6 – Структура механізму ECA

Механізм уваги є технікою машинного навчання, яка призначає різні ваги вхідним ознакам у нейронній мережі. Механізм ЕСА, використаний при побудові даної моделі, є формою механізму уваги на рівні каналів, що представляє покращену версію мереж стискання та збудження (SE-Net). Адаптивно зважуючи канал вимірювання вхідних ознак, модель може краще захоплювати важливу інформацію в сигналах жестів sEMG. Його структура зображена на рисунку 3.6, де повнозв'язний шар в оригінальній SE-Net замінено одновимірними згортковими ядрами, що робить модель легшою. Розмір одновимірного згорткового ядра визначається автоматично на основі кількості каналів, усуваючи необхідність ручних налаштувань.

### 3.4 Навчання моделі та аналіз метрик

Навіть коли знайдена підходяща архітектура, все ще необхідно шукати оптимальні параметри для покращення продуктивності алгоритму. Для покращення результатів навчання моделі було застосовано систематичний підхід до налаштування її гіперпараметрів. Для цього був досліджений кожен параметр окремо, залишаючи інші параметри незмінними, для того, щоб спостерігати конкретний вплив кожного параметра на процес навчання моделі. Після завершення кожного тесту було збережено значення гіперпараметрів, які давали найкращі результати для подальшого тестування.

Для оцінки продуктивності моделі під час фази навчання був використаний валідаційний набір після кожної епохи навчання, для того, щоб отримати уявлення про те, як модель працювала під час навчання, обчислюючи точність та інші метрики. Якщо точність моделі покращувалась, то ваги для поточної моделі були збережені. Коли досягалась попередньо визначена кількість епох, то обиралась модель з найкращою продуктивністю з валідаційного набору та був зупинений

процес навчання. Такий ітераційний підхід гарантує, що модель з найкращою продуктивністю обирається після кожної ітерації, що дозволяє отримати більш точні прогнози під час наступних фаз тестування. Остаточний набір оптимальних параметрів, які були визначені за допомогою вище описаного методу наступний:

- активаційна функція – ReLU;
- швидкість навчання – 0,0001;
- кількість епох – 300;
- розмір серії – 128.

Навчання моделі триває 30 епох і його результати показані на рисунку 3.7.

```
Epoch 23/200
5298/5298 [=====] - 26s 5ms/step - loss: 0.3056 - accuracy:
0.8977 - val_loss: 0.3766 - val_accuracy: 0.8854
Epoch 24/200
5298/5298 [=====] - 24s 5ms/step - loss: 0.3032 - accuracy:
0.8984 - val_loss: 0.3779 - val_accuracy: 0.8856
Epoch 25/200
5298/5298 [=====] - 26s 5ms/step - loss: 0.2996 - accuracy:
0.8998 - val_loss: 0.3721 - val_accuracy: 0.8890
Epoch 26/200
5298/5298 [=====] - 25s 5ms/step - loss: 0.2975 - accuracy:
0.9007 - val_loss: 0.3742 - val_accuracy: 0.8879
Epoch 27/200
5298/5298 [=====] - 25s 5ms/step - loss: 0.2946 - accuracy:
0.9017 - val_loss: 0.3710 - val_accuracy: 0.8906
Epoch 28/200
5298/5298 [=====] - 26s 5ms/step - loss: 0.2928 - accuracy:
0.9025 - val_loss: 0.3709 - val_accuracy: 0.8892
Epoch 29/200
5298/5298 [=====] - 24s 5ms/step - loss: 0.2895 - accuracy:
0.9038 - val_loss: 0.3736 - val_accuracy: 0.8896
Epoch 30/200
5298/5298 [=====] - 24s 5ms/step - loss: 0.2876 - accuracy:
0.9045 - val_loss: 0.3728 - val_accuracy: 0.8893
```

Рисунок 3.7 – 23–30 епохи навчання моделі

Оцінка моделі представлена кривими точності та втрат. Рисунок 3.8

демонструє, що наша модель дала хороші результати: точність склала 90,45% після 30 ітерацій під час фази навчання та 88,93% під час тестової фази. Близькість двох значень точності свідчить про відсутність перенавчання та про те, що модель добре узагальнює нові дані.

Крім того, матриця помилок на рисунку 3.9 дає глибше розуміння продуктивності моделі щодо окремих класів жестів. З побудованої матриці видно, що матриця часто помилково класифікує такий жест як «Рука у спокої» як непозначені дані. Така помилкова класифікація може виникати через те, що патерни електроміографічних сигналів можуть бути слабкими, або подібними до невідмічених сигналів саме для даного жесту. Оскільки стан спокою дає мінімальні електроміографічні сигнали, які можуть бути легко переплутані з відсутністю будь-якого конкретного жесту (непозначені дані). Також модель помилково класифікує жест «Розкриття долоні» з непозначеними даними в 16.83% випадках, це може бути пов'язано з тим, що даний жест не виконувався всіма суб'єктами, тому через це модель могла погано навчитись цим патернам. Загалом, в близько в 84 % випадках модель правильно класифікує жести, і в більшості випадках помилково класифікує їх як непозначені дані.

Часті помилкові класифікації жестів як непозначені дані можуть бути спричинені кількома факторами:

- перекриття сигналів: деякі жести можуть мати подібні електроміографічні сигнали до стану спокою або інших слабо виражених жестів, що призводить до їх класифікації як непозначені дані;
- недостатня кількість навчальних даних: якщо деякі жести не представлені у достатній кількості, модель може погано навчатися розпізнавати ці патерни;
- шум в даних: наявність шуму в даних може впливати на точність класифікації, особливо якщо сигнали слабкі;
- недостатнє перед оброблення даних: недостатнє перед оброблення або неправильна нормалізація електроміографічних сигналів може

призводити до неправильної класифікації (рисунок 3.8).

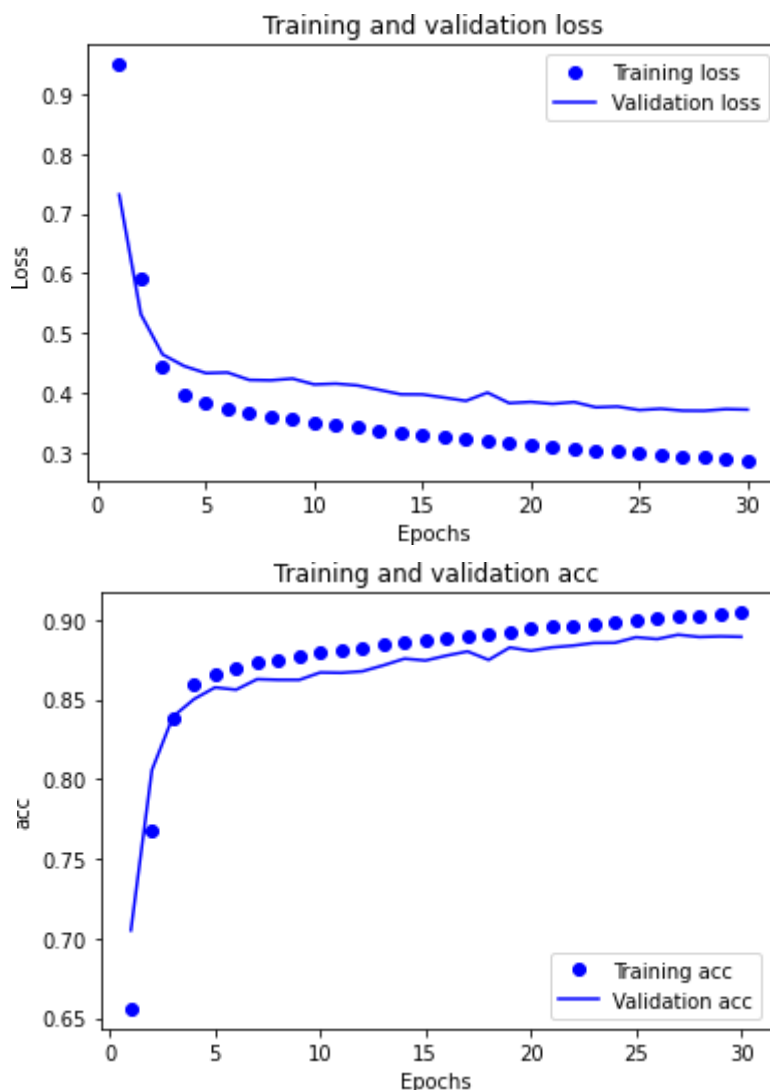


Рисунок 3.8 – Метрики навчання моделі

Шляхами вирішення даної проблеми може бути покращення обробки сигналу, через фільтрацію (використання високочастотних і низькочастотних фільтрів для зменшення шуму та видалення артефактів), нормалізацію (нормалізація електроміографічних сигналів для усунення варіацій, спричинених різними суб'єктами або умовами вимірювання), екстракція ознак (використання передових методів екстракції ознак для покращення розпізнавання патернів жестів). Також іншим шляхом вирішення проблеми може бути покращення архітектури моделі, тобто

використати складнішу архітектуру нейронної мережі, наприклад таку як рекурентні нейронні мережі, які можуть краще розпізнавати певні закономірності у послідовних даних (рисунок 3.9).

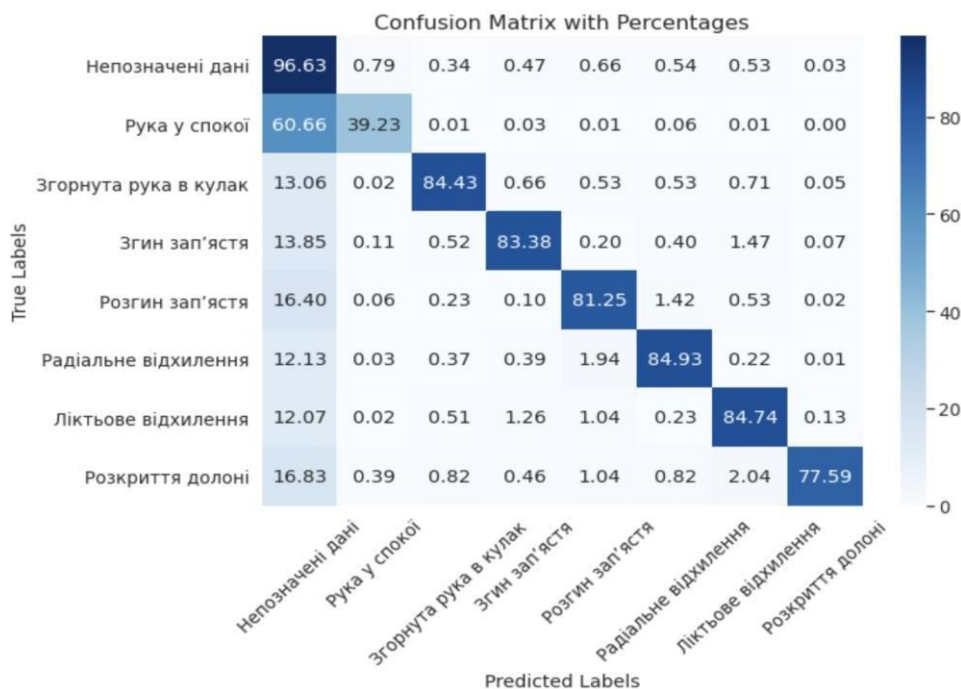


Рисунок 3.9 – Метрики навчання моделі

Отже, матриця помилок підкреслює важливі проблеми в класифікації жестів, особливо щодо помилкової класифікації жестів як непозначених даних. Вирішення цих проблем вимагає поєднання покращення якості даних, вдосконалення архітектури моделі та ретельного аналізу помилок. Застосування цих підходів може значно підвищити точність та надійність системи розпізнавання жестів на основі електроміографічних сигналів.

### 3.5 Порівняння моделі CNN-ECA з класичними моделями машинного навчання

Побудовану CNN-ECA модель було порівняно з наступними алгоритмами машинного навчання SVM (методом опорних векторів), k-NN (методом k найближчих сусідів), NB (наївним Баєсівським

класифікатором), RF (алгоритмом випадкового лісу) і DT (деревом рішень).

SVM є одним з алгоритмів навчання з учителем, який мінімізує структурний ризик і включає теорію статистичного навчання. SVM особливо популярний у таких сферах, як розпізнавання облич, текстів і почерку, медичних прогнозах, часових рядах, для класифікації та регресії. SVM включає кілька ядер, які можуть бути лінійними, поліноміальними, радіальними, експоненціальними, сигмоїдальними та гібридними функціями. Для класифікації жестів руки використовується радіальна базисна функція як ядро, пара параметрів  $[c, \gamma]$  визначена як  $[0, 2]$ , а максимальна кількість ітерацій визначена як 100000 після багатьох повторних експериментів.

Алгоритм k-NN є алгоритмом класифікації та регресії, де сусіди роблять внесок залежно від своєї відстані. Кожен сусід має вагу, пропорційну  $1/d$ , де  $d$  – це відстань до сусіда. Найважливішим параметром k-NN є значення  $k$ , яке визначається як кількість сусідів. Для задачі класифікації жестів параметр  $k$  було вибрано як 5, а відстань Евкліда використовується як метрика відстані.

Класифікатор NB базується на ймовірнісному підході. NB класифікатори також можна розглядати як байєсівську мережу, складену з незалежних атрибутів умовно. Для цієї задачі класифікації було обрано наступні параметри: кількість ядер – 12, мінімальна ширина смуги пропускання – 0,01, режим оцінки – жадібний.

Основна ідея DT полягає в повторному поділі даних на групи за допомогою алгоритму кластеризації. Кластеризація виконується для того, щоб усі елементи групи мали однакову мітку класу. Критерій DT було обрано як інформаційний приріст. Інші параметри, такі як максимальна глибина, мінімальний розмір листа, мінімальний приріст і мінімальний розмір для розбиття були обрані як 10, 4, 0,1 і 4 відповідно.

Алгоритм RF є видом колективного навчання, який має на меті

підвищити точність класифікації шляхом створення кількох DT під час процесу класифікації. Індивідуально створені DT об'єднуються для формування лісу рішень. RF переважно використовується в таких сферах, як астрономія, біомедицина, фінанси, охорона здоров'я та фізика. За допомогою RF можна вирішувати завдання класифікації та регресії. Для вирішення задачі розпізнавання жестів були вибрані наступні параметри: кількість дерев – 100, критерій – інформаційний приріст, максимальна глибина – 10.

Для того, щоб отримати більш точні результати класифікації жестів були випробувані різні параметри. Наведені вище параметри виявились найкращими комбінаціями для даної задачі (рисунок 3.10).

Model	Accuracy (%)	Precision (%)	Sensitivity (%)	Specificity (%)	\
0 SVM	70.0	69.0	70.0	72.0	
1 k-NN	73.0	72.0	73.0	75.0	
2 NB	71.0	70.0	71.0	74.0	
3 DT	69.0	68.0	69.0	71.5	
4 RF	73.0	72.0	73.0	75.0	

	Classification Error (%)	Kappa	Root Mean Squared Error	Correlation
0	30.0	0.63	0.40	0.68
1	27.0	0.66	0.37	0.72
2	29.0	0.64	0.38	0.70
3	31.0	0.61	0.41	0.67
4	27.0	0.66	0.37	0.72

Рисунок 3.10 – Метрики навчання класичних моделей машинного навчання

З рисунку 3.10 можна побачити, що моделі k-NN та RF дали найкращі результати в порівнянні з іншими класичними моделями машинного навчання. Однак модель CNN-ECA перевершує всі інші наведені вище моделі у всіх метриках оцінки, що свідчить про її ефективність у розв'язанні задачі розпізнавання жестів на основі електроміографічних сигналів.

Найбільш викликом у розпізнаванні жестів рук на основі алгоритмів машинного навчання є те, що незважаючи на те, що кількість екземплярів

у наборі даних «EMG Data for Gestures» є досить великою, кількість суб'єктів, які брали участь у дослідженні, дуже обмежена. Набір даних складається з електроміографічних сигналів дуже небагатьох людей, але було записано багато повторень певних рухів. В цьому випадку досить важко оцінити успішність класифікатора, адже це можливо, за допомогою великої кількості електроміографічних сигналів жестів рук, які виконані раніше невідомими суб'єктами дослідження. Для покращення точності класифікації моделей варто розширити набір даних та методологію дослідження з використання набору даних з урахуванням різних вікових груп та статі суб'єкта дослідження.

## ВИСНОВКИ

У результаті проведеного аналізу міографічних сигналів можна зробити наступні висновки.

Було досліджено основні характеристики електроміографічних сигналів, їх виявлення та декомпозицію, а також було розглянуто методи їх обробки, що дозволяють підвищити якість даних перед їх подальшим аналізом.

Було розглянуто нейронні мережі для класифікації електроміографічних сигналів, зокрема згорткову нейронну мережу (CNN), рекурентну нейронну мережу (RNN) та мережу довготривалої короткочасної пам'яті (LSTM). Кожна з цих архітектур має свої унікальні переваги та недоліки у розв'язанні задачі класифікації ЕМГ сигналів, враховуючи різні аспекти, такі як здатність до вилучення ознак та обробки часових залежностей.

Було розроблено та навчено модель CNN-ECA на наборі даних, що містить ЕМГ сигнали, зібрані під час виконання різних жестів рукою. Навчання моделі показало задовільні результати, демонструючи високу точність у класифікації жестів. Також було порівняно точність даної моделі з класичними алгоритмами машинного навчання, що підтвердило її переваги у розпізнаванні патернів у ЕМГ сигналах.

Незважаючи на успішні результати, отримані за допомогою моделі CNN-ECA, має сенс розглянути можливість застосування більш складних архітектур, таких як рекурентні нейронні мережі (RNN) або мережі довготривалої короткочасної пам'яті (LSTM), у майбутньому. Це може покращити обробку послідовних даних та врахування часових залежностей, що є важливим для класифікації ЕМГ сигналів. Також в подальшому варто розглянути інші методи попередньої обробки електроміографічних сигналів.

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Chung E. A., Benalcázar M. E. Real-Time Hand Gesture Recognition Model Using Deep Learning Techniques and EMG Signals. *27th European Signal Processing Conference (EUSIPCO)*. 2019. P. 1–5.
2. Krilova N., Kastalskiy I., Kazantsev V., Makarov V., Lobov V. EMG Data for Gestures. UCI Machine Learning Repository. 2019.
3. Karapinar Senturk Z., Sevgul Bakay M. Machine Learning Based Hand Gesture Recognition via EMG Data. *Advances in Distributed Computing and Artificial Intelligence Journal*. 2021. T. 10, № 2. P. 123–136.
4. Yu G., Deng Z., Bao Z., Zhang Y., He B. Gesture Classification in Electromyography Signals for Real-Time Prosthetic Hand Control Using a Convolutional Neural Network-Enhanced Channel Attention Model. *Bioengineering*. 2023. T. 10. P. 1324.
5. Ozdemir M. A., Kisa D. H., Guren O., Onan A., Akan A. EMG based Hand Gesture Recognition using Deep Learning. *Medical Technologies Congress (TIPTEKNO)*. 2020.
6. Reaz M. B. I., Hussain M. S., Mohd-Yasin F. Techniques of EMG signal analysis: detection, processing, classification and applications. *Biological Procedures Online*. 2006. T. 8, № 1. P. 11–35.
7. Vonsevych K. P., Bezuglyi M. O., Haponiuk A. O. Evaluation of Electromyogram Time Characteristics of the Wrist Functional Movements for Intuitive Control of Bionic Prosthesis. *Naukovi Visti NTUU KPI*. 2018. № 1. P. 45–53.
8. Brigham E. O. The fast fourier transform and its applications. Englewood Cliffs: Prentice-Hall. 1988. 448 c.
9. Cerna M., Harvey A. F. The fundamentals of FFT-based signal analysis and measurement. Application Note 041, National Instruments. 2000. P. 1–20.

10. Miller S., Childers D. Probability and random processes: With applications to signal processing and communications. Academic Press. 2012.
11. Amira A., Chandrasekaran S. Power Modeling and Efficient FPGA Implementation of FHT for Signal Processing. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*. 2007. T. 15, № 3. P. 286–295.
12. Goodfellow I., Bengio Y., Courville A. Deep learning. *MIT press*. 2016.
13. Ferrer L. Analysis and comparison of classification metrics. 2022.
14. Manaswi N. K., Manaswi N. K. Rnn and lstm. Deep Learning with Applications Using Python: Chatbots and Face, Object, and Speech Recognition With TensorFlow and Keras. 2018. P. 115–126.
15. O'Shea K., Nash R. An introduction to convolutional neural networks. 2015.