

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО»**

**ФАКУЛЬТЕТ БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ
КАФЕДРА БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ**

До захисту допущено:

Завідувач кафедри

_____ Владислав ШЛИКОВ

«__» _____ 2026 р.

Дипломна робота

на здобуття ступеня бакалавра

за освітньо-професійною програмою «Медична інженерія»

спеціальності 163 Біомедична інженерія

**на тему: «Біотехнічна система класифікації патернів ЕМГ-сигналів на
основі штучних нейронних систем»**

Виконав (-ла):

студент IV курсу, групи БМ-22

Костенко Богдан Володимирович _____

Керівник:

ст. викл. каф. БМІ

Архирей Марина Володимирівна _____

Консультант з ОП

к.т.н., доцент кафедри ОППЦБ

Демчук Гліб Вікторович _____

Рецензент:

асистент кафедри ББЗЛ

Степаненко Владислав Олегович _____

Засвідчую, що у цій дипломній роботі
немає запозичень з праць інших авторів
без відповідних посилань.

Студент _____

Київ – 2026 року

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Факультет біомедичної інженерії
Кафедра біомедичної інженерії

Рівень вищої освіти	перший (бакалаврський)
Спеціальність	163 «Біомедична інженерія»
Освітньо-професійна програма	«Медична інженерія»

ЗАТВЕРДЖУЮ

Завідувач кафедри

_____ Владислав ШЛИКОВ

«___» _____ 2026 р.

ЗАВДАННЯ
на дипломну роботу студенту
Костенку Богдану Володимировичу

1. Тема проєкту **«Біотехнічна система класифікації патернів ЕМГ-сигналів на основі штучних нейронних систем»**, керівник проєкту Архирей Марина Володимирівна, ст. викл. каф. БМІ, затверджені наказом по університету від «27» травня 2026 р. №1924-с
2. Термін подання студентом проєкту «7» червня 2026 р.
3. Вихідні дані до проєкту наукові статті та панентна література (в електронному вигляді), апаратна платформа: Arduino UNO, ЕМГ-сенсор DFRobot Gravity SEN0240, програмне забезпечення: мова програмування Python, бібліотеки TensorFlow, NumPy, scikit-learn, pyserial, tkinter.
4. Зміст пояснювальної записки: Огляд методів реєстрації та класифікації ЕМГ-сигналів, розробка та навчання штучної нейронної мережі для класифікації патернів ЕМГ-сигналів, розробка біотехнічної системи реєстрації та первинної обробки ЕМГ-сигналів, тестування та аналіз ефективності системи, обмеження реалізованого прототипу та напрями підвищення експлуатаційних характеристик.
5. Перелік графічного матеріалу (із зазначенням обов'язкових креслеників, плакатів, презентацій тощо): презентація у форматі MS Power Point.

6. Консультанти розділів проєкту

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
6	Демчук Г.В., к.т.н., доцент кафедри ОППЦБ		

7. Дата видачі завдання «27» травня 2026 р.

Календарний план

№ з/п	Назва етапів виконання дипломного проєкту	Термін виконання етапів проєкту	Примітка
1	Отримання завдання на ДР	27 травня 2026 р.	
2	Ознайомлення з технікою безпеки	27-31 травня 2026.р	
3	Огляд літератури за темою	27 травня – 2 червня 2026 р.	
4	Розробка та навчання нейромережі	30 травня – 2 червня 2026 р.	
5	Розробка біотехнічної системи реєстрації ЕМГ-сигналів	30 травня – 2 червня 2026 р.	
6	Тестування та аналіз ефективності системи	2-3 червня 2026 р.	
7	Проходження нормконтролю по оформленню ДР	4 червня 2026 р.	
8	Подання ДР рецензенту. Отримання рецензії	4 червня 2026 р.	
9	Подання в електронному вигляді ДР та анотації	7 червня 2026 р.	
10	Подання документів у друкованому вигляді	10 червня 2026 р.	
11	Захист ДР	17 червня 2026 р.	

Студент

Богдан КОСТЕНКО

Керівник

Марина АРХИРЕЙ

АНОТАЦІЯ

Тема дипломної роботи: «Розробка біотехнічної системи класифікації патернів ЕМГ-сигналів на основі штучних нейронних мереж».

Обсяг дипломної роботи становить 74 сторінок, міститься 13 ілюстрацій, 14 таблиць. Загалом опрацьовано 37 джерел.

Актуальність теми: поверхнева електроміографія є перспективним неінвазивним методом керування біотехнічними системами. Але міжіндивідуальна варіабельність ЕМГ-сигналів знижує точність класифікації жестів на нових користувачах, а наявні рішення вимагають дорогого спеціалізованого обладнання. Тому розробка доступного прототипу є актуальним завданням сучасної біомедичної інженерії.

Мета: реалізувати апаратно-програмну біотехнічну систему класифікації патернів ЕМГ-сигналів із підвищеними експлуатаційними характеристиками

Завдання:

1. Провести огляд існуючих методів реєстрації ЕМГ-сигналів, апаратних платформ та нейромережевих підходів до класифікації жестів руки.
2. Розробити та навчити багатомасштабну *1D CNN* зі *SE*-увагою.
3. Зібрати апаратний прототип на базі *Arduino UNO* та сенсора *SEN0240*.
4. Реалізувати алгоритм донавчання моделі на індивідуальних даних користувача та верифікувати систему в режимі реального часу.
5. Розробити механізм моніторингу впевненості моделі для автоматичного виявлення дрейфу сигналу та сигналізації про необхідність recalібрування.
6. Проаналізувати обмеження прототипу та визначити напрями вдосконалення.

Ключові слова: поверхнева електроміографія, класифікація жестів руки, багатомасштабна *CNN*, *SE*-увага, персоналізоване донавчання, *transfer learning*, *Arduino*.

ANNOTATION

Thesis topic: "Development of a biotechnical system for EMG signal pattern classification based on artificial neural networks".

The thesis contains 74 pages, 13 illustrations, 14 tables. A total of 37 sources were reviewed.

Relevance: surface electromyography is a promising non-invasive method for controlling biotechnical systems. However, high inter-individual variability of EMG signals reduces gesture classification accuracy when applying pre-trained models to new users, while existing solutions require expensive specialized equipment. Therefore, developing an affordable prototype is a relevant challenge in modern biomedical engineering.

Objective: to implement a hardware-software biotechnical system for EMG signal pattern classification with enhanced operational characteristics.

Tasks:

1. Review existing EMG signal acquisition methods, hardware platforms and neural network approaches to hand gesture classification.
2. Design and train a multi-scale 1D CNN with SE-attention.
3. Assemble a hardware prototype based on Arduino UNO and SEN0240 sensor.
4. Implement a model fine-tuning algorithm on individual user data and verify the system in real time.
5. Develop a model confidence monitoring mechanism for automatic signal drift detection and recalibration alerting.
6. Analyze prototype limitations and identify directions for improvement.

Key words: surface electromyography, hand gesture classification, multi-scale CNN, SE-attention, personalized fine-tuning, transfer learning, Arduino.

ЗМІСТ

Вступ.....	9
Розділ 1 Огляд методів реєстрації та класифікації ЕМГ-сигналів.....	11
1.1 Фізіологічні основи електроміографії	11
1.2 Особливості формування ЕМГ-сигналів при виконанні жестів руки	14
1.3 Існуючі апаратні засоби реєстрації ЕМГ-сигналів: поверхневі електродні системи та мікроконтролерні платформи	18
1.3.1 Поверхневі електроди: типи та вимоги до розміщення	18
1.3.2 Аналоговий вхідний ланцюг: підсилення та фільтрація.....	20
1.3.3 АЦП та вимоги до частоти дискретизації	20
1.3.4 Мікроконтролерні платформи.	21
1.3.5 Носимі ЕМГ-нарукавники.....	21
1.4 Сучасні методи обробки та класифікації ЕМГ-сигналів із застосуванням машинного навчання та нейронних мереж	22
1.5 Вимоги до біотехнічної системи розпізнавання жестів. Обґрунтування вибору апаратної та програмної платформи	26
Висновок до розділу 1	27
Розділ 2 Розробка та навчання штучної нейронної мережі	28
2.1 Формування та розмітка навчального набору даних ЕМГ-сигналів для заданого набору жестів.....	28
2.1.1. Датасет <i>FORS-EMG</i>	28
2.1.2 Сегментація сигналу ковзним вікном	29
2.1.3 Суб'єкт-незалежне розбиття вибірки	30
2.2 Обґрунтування вибору архітектури та реалізація багатомасштабної згорткової нейронної мережі	30

2.2.1 Порівняльний аналіз підходів до класифікації сЕМГ	30
2.2.2 Вхідний шар та багатомасштабний блок.....	31
2.2.3 Блок <i>Squeeze-and-Excitation (SE)</i> каналної уваги.....	31
2.2.4 Часова редукція та <i>GlobalAveragePooling</i>	32
2.2.5 Класифікаційна голова	32
2.3 Аугментація даних, навчання та оцінка моделі.....	33
2.3.1 Аугментація навчальних даних	33
2.3.2 Процедура навчання	33
2.3.3 Результати та аналіз.....	34
2.3.4 Персоналізоване донавчання моделі (<i>fine-tuning</i>)	34
Висновок до розділу 2	35
Розділ 3 Розробка системи реєстрації та первинної обробки ЕМГ-сигналів..	37
3.1 Технічні характеристики компонентів апаратної частини системи та їх з'єднання.....	37
3.1.1 ЕМГ-сенсор <i>DFRobot Gravity EMG Sensor (SEN0240)</i>	37
3.1.2 Мікроконтролер <i>Arduino UNO</i> та його АЦП.....	39
3.2 Схема з'єднання компонентів.....	40
3.3 Структурна схема біотехнічної системи реєстрації ЕМГ-сигналів	41
3.4 Алгоритми попередньої обробки ЕМГ-сигналів: фільтрація, нормалізація, сегментація на вікна, виділення ознак.....	42
3.5 Скетч для мікроконтролера <i>Arduino</i>	45
Висновок до розділу 3	45
Розділ 4 Тестування та аналіз ефективності системи.....	47
4.1 Збирання апаратної частини системи	47
4.3 Персоналізоване навчання під індивідуального користувача.....	51

4.4 Тестування системи в режимі реального часу	52
4.5 Результати тестування	52
Висновок до розділу 4	54
Розділ 5 Обмеження реалізованого прототипу та напрями вдосконалення ...	56
5.1 Аналіз поточних обмежень	56
5.2 Напрями вдосконалення та очікувані показники точності.....	57
5.3 Пріоритизація вдосконалень.....	58
Висновок до розділу 5	58
РОЗДІЛ 6 Охорона праці	60
6.1 Характеристика розробленої біотехнічної системи	60
6.1.1 Характеристики компонентів системи	60
6.1.2 Складові частини системи.....	61
6.1.3 Характер взаємодії об'єкту в системі «людина–об'єкт»	61
6.2 Оцінка потенційних небезпек, що створюються конструкцією системи, та заходи їх усунення.....	62
6.2.1 Небезпека ураження електричним струмом.....	62
6.2.2 Небезпека займання	64
6.3 Розробка інструкції з техніки безпеки при експлуатації біотехнічної системи реєстрації та класифікації ЕМГ-сигналів	66
Висновок до розділу 6	67
Висновки	68
Перелік джерел посилань	70

ВСТУП

Поверхнева електроміографія (сЕМГ) є одним із найперспективніших неінвазивних методів реєстрації м'язової активності людини [1]. Завдяки безконтактній природі та відносній простоті апаратної реалізації вона знайшла широке застосування у системах керування активними протезами [7], реабілітаційних екзоскелетах [15] та інтерфейсах людина-комп'ютер [10]. Ключовою задачею в побудові таких систем є класифікація патернів сЕМГ-сигналів — автоматичне розпізнавання наміру виконати конкретний жест за електричною активністю м'язів у режимі реального часу.

Розвиток методів глибокого навчання суттєво підвищив точність класифікації сЕМГ-патернів: сучасні архітектури на основі згорткових нейронних мереж та механізмів уваги демонструють точність понад 95 % на лабораторних датасетах [16]. Проте перехід від лабораторних умов до реального використання залишається невирішеною проблемою.

По-перше, висока міжіндивідуальна варіабельність сЕМГ-сигналів — обумовлена різницею в анатомії, товщині підшкірного жирового шару, рівні втоми м'язів та особливостях розміщення електродів — суттєво знижує точність класифікатора при перенесенні моделі на нових користувачів [30].

По-друге, більшість сучасних рішень з високою точністю орієнтовані на багатоканальні системи з дорогим спеціалізованим обладнанням [13], що унеможлиблює їх широке практичне застосування. Одноканальні підходи, придатні для носимих пристроїв на базі доступних мікроконтролерних платформ, потребують ефективних методів персоналізації та компенсації міжособистісної варіабельності [6]. Окремою практичною проблемою є поступовий дрейф характеристик сигналу впродовж тривалих сесій використання, що призводить до деградації точності без механізмів автоматичного виявлення та recalібрування [31]. Тому розробка доступного прототипу з персоналізованим донавчанням та моніторингом стабільності сигналу є актуальним завданням сучасної біомедичної інженерії.

Тема дипломної роботи: «Розробка біотехнічної системи класифікації патернів ЕМГ-сигналів на основі штучних нейронних систем».

Мета: реалізувати апаратно-програмну біотехнічну систему класифікації патернів ЕМГ-сигналів із підвищеними експлуатаційними характеристиками.

Завдання:

1. Провести огляд існуючих методів реєстрації ЕМГ-сигналів, апаратних платформ та нейромережових підходів до класифікації жестів руки.
2. Розробити та навчити багатомасштабну *1D CNN* зі *SE*-увагою.
3. Зібрати апаратний прототип на базі *Arduino UNO* та сенсора *SEN0240*.
4. Реалізувати алгоритм донавчання моделі на індивідуальних даних користувача та верифікувати систему в режимі реального часу.
5. Розробити механізм моніторингу впевненості моделі для автоматичного виявлення дрейфу сигналу та сигналізації про необхідність recalібрування.
6. Проаналізувати обмеження прототипу та визначити напрями вдосконалення.

РОЗДІЛ 1

ОГЛЯД МЕТОДІВ РЕЄСТРАЦІЇ ТА КЛАСИФІКАЦІЇ ЕМГ-СИГНАЛІВ

1.1 Фізіологічні основи електроміографії

Електроміографія (ЕМГ) — метод реєстрації електричної активності скелетних м'язів, що виникає внаслідок збудження м'язових волокон під дією нервових імпульсів. Поверхнева електроміографія (*sEMG*, далі *cEMG*) є неінвазивною різновидністю цього методу, при якій електроди розміщуються на поверхні шкіри над досліджуваним м'язом. Протягом останніх десятиліть *cEMG* зазнала суттєвої трансформації: від спеціалізованого лабораторного інструменту до універсального методу, широко застосовуваного в реабілітації, спортивній науці, охороні праці та системах взаємодії людини з машиною [1]. Технологічний прогрес у сфері мікроелектроніки, бездротових систем передачі даних та алгоритмів машинного навчання зробив *cEMG* доступною за межами дослідницьких лабораторій, відкривши нові перспективи для розробки біотехнічних систем керування на основі жестів руки [1].

Основною функціональною одиницею нервово-м'язової системи є рухова одиниця (РО) — мотонейрон спинного мозку, його аксон та всі м'язові волокна, які він іннервує [2]. Кількість волокон у рухових одиницях варіює залежно від м'яза: у дрібних м'язах кисті вона становить у середньому близько 300 (від 10 до 1800), що забезпечує тонке керування силою [2]. Сукупність мотонейронів, що іннервують один м'яз, утворює моторний пул, у межах якого рухові одиниці діють паралельно і є гетерогенними за швидкістю скорочення та стійкістю до втоми.

М'язове скорочення ініціюється потенціалом дії мотонейрона: нервовий імпульс досягає нервово-м'язового синапсу, де вивільняється ацетилхолін, що деполяризує сарколему м'язового волокна. Деполяризація поширюється по *T*-трубочках углиб волокна та запускає вивільнення іонів Ca^{2+} із саркоплазматичного ретикулу. Ca^{2+} зв'язується з тропоніном, відкриваючи сайти зв'язування актину для головок міозину; утворені поперечні містки

(*crossbridges*) генерують силу скорочення [2]. Силова відповідь на одиничний імпульс — м'язове посмикування; при зростанні частоти розряду посмикування сумуються аж до тетанічного скорочення. Залежність «сила—частота» має сигмоїдний характер і є основним механізмом регуляції сили з боку ЦНС (див. рис. 1.1).




Рисунок 1.1 – Розташування скоротливих білків в одному м'язовому волокні. Скелетне м'язове волокно (A) складається з багатьох міофібрил, інкапсульованих сарколемою, та тисяч саркомерів (B), розташованих послідовно всередині кожної міофібрили. Саркомер вважається основною функціональною одиницею м'яза, оскільки він містить усі білки, необхідні для створення сили. Мітохондрії забезпечують енергію. Скоротливі білки розташовані у взаємопов'язані товсті та тонкі нитки. У стані спокою тропонін та тропоміозин запобігають приєднанню молекул міозину до актину. Після появи потенціалу дії, який поширюється вздовж сарколеми та вниз по поперечних канальцях, Ca^{2+} вивільняється із саркоплазматичного ретикулуму, що забезпечує взаємодію скоротливих білків і, таким чином, силу, яка викликає рух [2]

Рухові одиниці одного м'яза поділяють на три типи [2]:

— тип *S* (*slow*) — повільні, низька сила, висока стійкість до втоми;

- тип *FR* (*fast fatigue-resistant*) — швидкі, середня сила, помірна витривалість;
- тип *FF* (*fast fatigable*) — швидкі, максимальна сила, швидко втомлюються.

Згідно з принципом Хеннемана (*Henneman's size principle*), рухові одиниці рекрутуються у порядку від найменших (*S*) до найбільших (*FF*): малі мотонейрони мають нижчий поріг збудження і активуються першими [2]. Це означає, що при незначних зусиллях залучені переважно витривалі одиниці типу *S*, а *FF*-одиниці задіюються лише при максимальних навантаженнях. Для сЕМГ-систем важливо, що склад і амплітуда сигналу суттєво залежать від рівня зусилля та ступеня втоми.

Потенціал дії всіх волокон однієї рухової одиниці формує потенціал дії рухової одиниці (*MUAP*). При довільному скороченні мотонейрон генерує серію *MUAP* — потяг потенціалів дії (*MUAPT*). Поверхневий ЕМГ-сигнал є лінійною суперпозицією *MUAPT* усіх активних рухових одиниць у зоні виявлення електрода, відфільтрованою тканинами-провідниками (*volume conductor*). Типові параметри сЕМГ: амплітуда 50 мкВ–5 мВ, робоча смуга частот 10–500 Гц. Сигнал є нестационарним: при динамічних рухах його спектральні характеристики змінюються разом зі зміною позиції суглобів і рівня скорочення [1]. На рисунку 1.2 представлений графік потенціалу дії скорочення.




Рисунок 1.2 – Графік потенціалу дії скорочення [3]

1.2 Особливості формування ЕМГ-сигналів при виконанні жестів руки

Передпліччя містить 20 м'язів, організованих у два анатомічні компартменти — передній (флексорний) та задній (екстензорний), — які через систему сухожиль керують усіма рухами зап'ястка, кисті та пальців [4,5]. Знання топографії цих м'язів є необхідною умовою коректного розміщення ЕМГ-електродів і правильного трактування зареєстрованих сигналів.

Передній (флексорний) компартмент:

Поверхневий шар переднього компартменту містить чотири м'язи, що беруть початок від медіального надвиростка плечової кістки:

— *m. pronator teres* (круглий пронатор) — пронація та згинання передпліччя; у ЕМГ-системах реєструється рідко, але дає артефакти при ротаційних рухах зап'ястка;

— *m. flexor carpi radialis* (FCR, променевий згинач зап'ястка) — згинання та радіальне відведення зап'ястка; іннервація: *n. medianus*;

— *m. palmaris longus* (довгий долонний м'яз) — слабе згинання зап'ястка та натяг долонного апоневрозу; відсутній у 15 % людей, тому не є надійним орієнтиром при розміщенні електродів;

— *m. flexor carpi ulnaris* (FCU, ліктьовий згинач зап'ястка) — згинання та ліктьове відведення зап'ястка; іннервація: *n. ulnaris*.

Проміжний шар утворює один м'яз, надзвичайно важливий для класифікації жестів:

— *m. flexor digitorum superficialis* (FDS, поверхневий згинач пальців) — згинання у проксимальних міжфалангових та п'ястково-фалангових суглобах II–V пальців; м'яз роздвоюється на чотири сухожилля, кожне з яких керує окремим пальцем; іннервація: *n. medianus*. Є першорядним індикатором захватних жестів у більшості ЕМГ-систем.

Глибокий шар містить [4]:

- *m. flexor digitorum profundus* (FDP, глибокий згинач пальців) — єдиний м'яз, що згинає дистальні міжфалангові суглоби II–V пальців; медіальна половина іннервується *n. ulnaris*, латеральна — *n. medianus* (*anterior interosseous branch*). Розташований під *FDS*, тому при поверхневій ЕМГ значна частина його активності перекривається сигналами *FDS* (*crosstalk*);
- *m. flexor pollicis longus* (FPL, довгий згинач великого пальця) — згинання дистальної фаланги великого пальця; іннервація: *n. medianus*;
- *m. pronator quadratus* — пронація дистального відділу передпліччя.

Задній (екстензорний) компартмент:

Поверхнева група заднього компартменту [5]:

- *m. extensor digitorum communis* (EDC, загальний розгинач пальців) — розгинання II–V пальців у всіх суглобах; головний антагоніст *FDS* при розкриванні кисті; іннервація: *n. radialis* (*r. profundus*);
- *m. extensor digiti minimi* (EDM, розгинач мізинця) — ізольоване розгинання V пальця; іннервація: *n. radialis* (*r. profundus*);
- *m. extensor carpi ulnaris* (ECU, ліктьовий розгинач зап'ястка) — розгинання та ліктьове відведення зап'ястка; іннервація: *n. radialis* (*r. profundus*).

"Мобільна підощва" (*mobile wad*) — бічна група [5]:

- *m. brachioradialis* (BR, плечо-променевий м'яз) — згинання передпліччя у нейтральній позиції; розташований поверхнево на латеральній поверхні, тому легко реєструється електродами;
- *m. extensor carpi radialis longus* (ECRL, довгий променевий розгинач зап'ястка) — розгинання та радіальне відведення зап'ястка;
- *m. extensor carpi radialis brevis* (ECRB, короткий променевий розгинач зап'ястка) — розгинання зап'ястка; у сЕМГ-дослідженнях *ECRL* та *ECRB* часто реєструються одним електродом через близькість розташування.

Глибока група заднього компартменту (м'язи великого пальця та вказівного) [5]:

- *m. abductor pollicis longus* (APL) — відведення та розгинання великого пальця;
- *m. extensor pollicis brevis* (EPB) та *m. extensor pollicis longus* (EPL) — розгинання проксимальної та дистальної фаланг великого пальця;
- *m. extensor indicis* (EI) — ізольоване розгинання вказівного пальця.

Глибокі м'язи великого пальця та вказівного пальця рідко реєструються при стандартному поверхневому відведенні, однак вони є важливими при класифікації жестів з участю великого пальця (наприклад, пінцетний захват). На рисунку 1.3 зображено м'язи переднього та заднього відділу передпліччя.




Рисунок 1.3 – а) М'язи передньої частини передпліччя. *FDS* та *FCU* виділені; б) М'язи заднього відділу передпліччя. *ECRL* та *EDC* виділені [26]

Взаємна топографічна близькість перелічених м'язів є головним джерелом методологічних труднощів при сЕМГ. М'яз *FDS* залягає поверхнево поблизу зап'ястка, але у проксимальному передпліччі він прикритий *FCR*, *FCU* та *BR*, що означає: один і той самий електрод на проксимальному передпліччі реєструватиме внески від кількох м'язів одночасно. *FDP*, що лежить під *FDS*, практично недоступний для ізольованої поверхневої реєстрації. Результатом є *crosstalk* — контамінація сигналу активністю сусідніх м'язів, яка може досягати 10–30 % від загальної амплітуди сигналу [6].

Практично найбільш інформативними для класифікації жестів виявляються чотири м'язи, обрані в переважній більшості сЕМГ-досліджень: *FDS*, *FCU* (див. рис.1.3(а)) та *ECRL* та *EDC* (див. рис.1.3(б)) [7]. Їх сигнали формують базовий просторово-часовий патерн, достатній для розрізнення 6–12 типових жестів руки з точністю понад 90 % при застосуванні методів машинного навчання. Розширення до 8 каналів (наприклад, додавання *FCR*, *ECU*, *FDP* та *BR*) підвищує точність розрізнення тонких жестів пальців, проте збільшує апаратну складність системи.

При виконанні конкретного жесту активуються специфічні сукупності рухових одиниць різних м'язів. Так, силовий захват (*power grip*) супроводжується одночасною активацією *FDS*, *FDP* та *FCU* при відносній тиші *ECU* та *EDC*. Пінцетний захват (*precision grip*) характеризується активацією *FPL* та *FDS* (переважно II пальця). Розгинання кисті задіює *EDC*, *ECRL* та *ECRB*. Характер активації утворює просторово-часовий патерн ЕМГ-сигналів, унікальний для кожного жесту та придатний для автоматичної класифікації.

Ключовою фізіологічною особливістю є електромеханічна затримка (*EMD*) — часовий інтервал між початком електричної активності м'яза та початком механічного руху, що становить 50–200 мс залежно від м'яза та умов скорочення [1]. Для систем керування в реальному часі прогнозування затримка дозволяє будувати антиципаційні алгоритми, що знижують

суб'єктивно відчутний лаг нижче 300 мс — критичного порогу прийнятності для міоелектричних протезів.

Висока міжіндивідуальна варіабельність сЕМГ-сигналів (обумовлена різницею у товщині підшкірного жирового шару над м'язами, індивідуальній анатомії, рівні тренуваності та методиці розміщення електродів) є основним практичним викликом. Нестационарність під час динамічних жестів — через зміни довжини м'язів і складу рекрутованих рухових одиниць — вимагає часово-частотного аналізу (*STFT*, *CWT*) замість статичних ознак [1].

1.3 Існуючі апаратні засоби реєстрації ЕМГ-сигналів: поверхневі електродні системи та мікроконтролерні платформи

Апаратна частина біотехнічної системи реєстрації сЕМГ охоплює три функціональні блоки: електроди для знімання біоелектричного сигналу, аналоговий вхідний ланцюг (підсилювач, фільтри) та цифровий блок збору даних (АЦП, мікроконтролер). Вибір компонентів кожного блоку безпосередньо визначає якість зареєстрованого сигналу та можливість класифікації жестів у реальному часі.

1.3.1 Поверхневі електроди: типи та вимоги до розміщення

Поверхневі електроди є точкою контакту між тілом і вимірювальною системою. За конструкцією їх поділяють на два основні типи:

1. Вологі (гелеві) електроди — традиційний стандарт клінічної ЕМГ. Містять провідний гель на основі *AgCl*, що суттєво знижує імпеданс контакту шкіра–електрод до 1–5 кОм. Забезпечують стабільний сигнал з мінімальним рухомим артефактом, однак потребують підготовки шкіри (абразивна обробка, знежирення) і незручні для тривалого носіння [8].

2. Сухі електроди — не потребують гелю і дозволяють розробляти повністю носимі системи. Головним недоліком є вищий імпеданс контакту (до 100 кОм і більше), що вимагає посилення вимог до вхідного імпедансу підсилювача (>10 МОм). Сучасні технології 3D-друку дозволяють виготовляти кастомізовані сухі електроди зі срібловмісних або вуглецевих

композитів, які демонструють задовільні характеристики при динамічній м'язовій активності [8].

Ключові вимоги до розміщення електродів: відстань між електродами диференціальної пари — 20 мм (стандарт *SENIAM*), орієнтація вздовж м'язових волокон, уникнення моторних точок та сухожиль [6]. Зміщення електрода навіть на 1–2 см суттєво змінює амплітуду та спектральний склад сигналу, що є основним джерелом міжсесійної варіабельності.

3. Мікроголкові електроди

Мікроголкові електроди є гібридним рішенням між сухими поверхневими та внутрішньом'язовими електродами. Масив мікроголок (типопо 8x8 голок на площі $\sim 1 \text{ мм}^2$) проколює роговий шар шкіри, головний бар'єр електричного опору, не проникаючи в живі тканини та не досягаючи нервових закінчень. Завдяки цьому контактний імпеданс після проколу $\sim 5\text{--}10 \text{ кОм}$, порівняний із гелевими електродами, при цьому підготовка шкіри (абразія, знежирення) не потрібно та больовий поріг не підвищується при правильно підібраній довжині голок.

За оглядом [35] мікроголкові електроди забезпечують тривалу стабільність сигналу, контактний імпеданс знижується зі збільшенням частоти (до $\sim 1 \text{ кОм}$ при 100 Гц, що краще ніж у сухих електродах). Обмеженнями є: збільшений ризик інфекції при тривалому носінні, жорсткі матеріали електродів (кремній, метал) погано адаптуються до кривизни поверхні тіла, що підсилює рухомі артефакти, але цю проблему вирішують електроди із гнучких полімерів.

Мікроголкові електроди є найбільш перспективним напрямком серед сухих електродів завдяки поєднанню низького імпедансу (рівень гелевих) та зручності носіння (рівень сухих). Однак наразі технологія залишається переважно дослідницькою; для масового застосування в носимих ЕМГ-системах необхідні гнучкі субстрати та рішення щодо тривалої безпеки [35, 36].

1.3.2 Аналоговий вхідний ланцюг: підсилення та фільтрація.

Амплітуда сЕМГ-сигналу на поверхні шкіри становить 50 мкВ–5 мВ, що вимагає підсилення в 100–1000 разів перед оцифруванням. Стандартна схема побудована на інструментальному підсилювачі (ІА) з диференціальним входом, що придушує синфазні завади (мережеву наводку 50/60 Гц, електростатичний шум) з коефіцієнтом $CMRR \geq 80$ дБ [9].

Типовий аналоговий тракт:

1. Інструментальний підсилювач (наприклад: *INA128*, *AD8221*) – коефіцієнт підсилення 100-500.
2. Фільтр верхніх частот ($f_{зр} = 10\text{-}20$ Гц) – усунення постійної складової та низькочастотних артефактів руху.
3. Фільтр нижніх частот ($f_{зр} = 500$ Гц) – антиелайзинговий фільтр перед АЦП.
4. Режекторний фільтр для придушення мережової завади 50 Гц.

Спеціалізовані аналогові мікросхеми збору біосигналів (наприклад, *ADS1298*, *ADS1299* від *Texas Instruments*) інтегрують у єдиному корпусі ІА, ФВЧ, ФНЧ та багатоканальний сигма-дельта АЦП з роздільною здатністю 24 біти. Це дозволяє суттєво зменшити апаратну складність та кількість зовнішніх компонентів порівняно з дискретними схемами.

1.3.3 АЦП та вимоги до частоти дискретизації

Згідно з теоремою Найквіста, для відтворення сЕМГ-сигналу зі смугою до 500 Гц необхідна частота дискретизації не менше 1000 вибірок/с на канал. На практиці використовують 1–2 кГц (типово 2000 вибірок/с), що забезпечує достатній запас та відповідає рекомендаціям *SENIAM* [10]. Роздільна здатність АЦП — не менше 12 біт для забезпечення достатнього динамічного діапазону; сучасні системи застосовують 16–24 біти [10].

1.3.4 Мікроконтролерні платформи.

Arduino-сумісні платформи набули широкого поширення в дослідницьких прототипах систем реєстрації сЕМГ завдяки низькій вартості, відкритому програмному та апаратному забезпеченню і розвиненій екосистемі бібліотек. *Arduino UNO* (мікроконтролер *ATmega328P*) — найпростіша та найбільш доступна платформа. Вбудований 10-бітний АЦП при напрузі живлення 5 В забезпечує роздільну здатність $\sim 4,9$ мВ/крок, що є недостатнім для точної реєстрації сЕМГ без зовнішнього підсилювача та АЦП [9]. Максимальна частота дискретизації одного каналу — близько 9,6 кГц (реально при кількох каналах — значно нижче). Використовується переважно для навчальних проектів та простих одноканальних систем.

Arduino Due та *Teensy (ARM Cortex-M3/M4)* — більш продуктивні платформи з 12-бітним АЦП та тактовою частотою 84–168 МГц. Забезпечують одночасну багатоканальну реєстрацію та сумісні з зовнішніми АЦП-мікросхемами через інтерфейс *SPI* [11]. *Teensy 4.x* зокрема підтримує передачу даних через *USB* з пропускнуою здатністю до 480 Мбіт/с, що дозволяє передавати потік ЕМГ-даних на ПК без затримки.

1.3.5 Носимі ЕМГ-нарукавники

Окремим напрямком є розробка носимих нарукавників зі вбудованими електродами для безперервної реєстрації ЕМГ у повсякденних умовах. Основні конструктивні рішення:

Нарукавники середньої щільності (8–16 каналів) є компромісом між покриттям м'язів передпліччя та складністю апаратури. Вони забезпечують достатню інформацію для класифікації 6–12 жестів і можуть бути виготовлені як гнучкі текстильні системи [12].

Високощільні матриці (*HD-sEMG*, 64–256 каналів) дозволяють будувати двовимірні карти м'язової активації та застосовувати алгоритми декомпозиції сигналу для виділення потенціалів окремих рухових одиниць. Однак

складність і вартість таких систем значно обмежують їх практичне застосування поза дослідницькими лабораторіями [13].

Комерційні навуковники (наприклад, *Myo Armband* — 8 каналів, 200 Гц, *Bluetooth*) значно спростили збір ЕМГ-даних і стали основою багатьох датасетів для класифікації жестів. Втім, низька частота дискретизації (200 Гц) та відсутність можливості зміни параметрів підсилення є суттєвими обмеженнями для дослідницьких застосувань [14].

1.4 Сучасні методи обробки та класифікації ЕМГ-сигналів із застосуванням машинного навчання та нейронних мереж

Автоматична класифікація патернів сЕМГ-сигналів включає три послідовні етапи: попередня обробка сигналу, виділення ознак і власне класифікація. Якість кожного з етапів безпосередньо визначає точність розпізнавання жестів у реальному часі. Сучасні підходи охоплюють як класичні методи машинного навчання з ручним виділенням ознак, так і методи глибокого навчання, що здатні автоматично вивчати ієрархічні представлення безпосередньо з сирого сигналу.

Сирий сЕМГ-сигнал перед класифікацією проходить кілька обов'язкових стадій обробки [15]:

1. Усунення постійної складової (*DC offset removal*) — видалення постійного зміщення, що виникає через електрохімічний потенціал на межі електрод– шкіра та вхідний зсув підсилювача.

2. Смугова фільтрація (*bandpass filtering*) — пропуск корисної смуги сЕМГ 10–500 Гц. Найчастіше застосовуються фільтри Баттерворта 4-го порядку як компроміс між крутизною зрізу та мінімальними фазовими спотвореннями. Режекторний фільтр (*notch* 50/60 Гц) усуває мережеву наводку.

3. Нормалізація амплітуди — приведення сигналу до єдиної шкали для усунення міжіндивідуальної варіабельності. Найбільш фізіологічно

обґрунтованим методом є нормалізація відносно максимального довільного скорочення (*MVC — maximal voluntary contraction*).

4. Сегментація на вікна (*windowing*) — розбиття безперервного сигналу на перекривні або неперекривні відрізки фіксованої тривалості (вікна).

Довжина вікна є ключовим компромісом: короткі вікна (50–100 мс) знижують затримку системи реального часу, але містять мало статистичної інформації; довгі вікна (200–300 мс) підвищують точність класифікації, але збільшують лаг [7]. Оптимальним для систем реального часу вважається вікно 150–200 мс із кроком 50 мс (перекриття 75 %).

З кожного сегментованого вікна обчислюється вектор ознак, що описує характеристики сигналу в часовій, частотній або часово-частотній областях.

Часові ознаки є найпростішими для обчислення та найбільш поширеними в системах реального часу [16]:

- *MAV (mean absolute value)* — середнє абсолютне значення амплітуди;
- *RMS (root mean square)* — середньоквадратичне значення, пов'язане з потужністю сигналу;
- *ZC (zero crossing rate)* — частота перетину нульового рівня, пов'язана зі спектром сигналу;
- *SSC (slope sign changes)* — кількість змін знаку похідної;
- *WL (waveform length)* — кумулятивна довжина хвилі, що описує складність форми сигналу;
- *IEMG (integrated EMG)* — інтеграл випрямленого сигналу.

Частотні ознаки описують розподіл потужності по частотах [16]:

- *MNF (mean frequency)* та *MDF (median frequency)* — центр тяжіння спектра;
- *PSD (power spectral density)* — щільність потужності, обчислювана через ШПФ або метод Велча.

Часово-частотні ознаки застосовуються для нестационарних сигналів [16]:

- *STFT* (*short-time Fourier transform*) — спектрограма, що відображає еволюцію спектра в часі; є основою для *CNN*-класифікаторів на зображеннях;
- *CWT* (*continuous wavelet transform*) — вейвлет-перетворення з кращою частотно-часовою локалізацією;
- *WPT* (*wavelet packet transform*) — пакетне вейвлет-перетворення для детального аналізу підсмуг.

Огляд [16] нараховує понад 50 ознак, що використовуються в сЕМГ-класифікації, при цьому часові ознаки забезпечують найкращий баланс між обчислювальною складністю та інформативністю для класифікації жестів у реальному часі.

Пакет *EMGFlow* автоматизує обчислення 33 таких ознак [17].

До появи методів глибокого навчання домінуючими підходами до класифікації сЕМГ-патернів були алгоритми на ручно-виділених ознаках:

1. Метод опорних векторів (*SVM* — *Support Vector Machine*) тривалий час вважався стандартом для класифікації ЕМГ завдяки ефективній роботі у просторах великої розмірності та стійкості до перенавчання на малих вибірках. *RBF*-ядро *SVM* досягає 85–92 % точності на стандартних наборах даних [7].

2. Випадковий ліс (*Random Forest, RF*) — ансамблевий метод, що усереднює рішення багатьох дерев рішень. Демонструє стійкість до шуму в ознаках, не вимагає нормалізації та дозволяє оцінити важливість окремих ознак. На базі часових ознак (*MAV, RMS, ZC, WL*) досягає 90–99 % точності [7,18].

3. Метод k найближчих сусідів (*kNN*) використовується як базовий (*baseline*) класифікатор. При правильно обраній метриці та достатньому обсязі навчальних даних досягає 90–95 % точності, але є повільним при класифікації через необхідність порівняння з усією навчальною вибіркою [7].

Загальним обмеженням класичних методів є необхідність ручного виділення ознак, що вимагає апіорних знань про сигнал, а також зниження точності при збільшенні кількості жестів та міжіндивідуальній варіабельності.

У свою чергу архітектури глибокого навчання дозволяють автоматично вивчати ієрархічні ознаки безпосередньо з сирого сигналу або його мінімально обробленого представлення, що усуває необхідність ручного конструювання ознак. Розглянемо основні методи:

1. Згорткові нейронні мережі (*CNN*) ефективно виявляють локальні просторові та часові патерни. Одновимірна *1D-CNN* обробляє часовий ряд сЕМГ і здатна навчитися виділяти ознаки, еквівалентні часовим дескрипторам [19]. Двовимірна *2D-CNN*, застосована до спектрограм *STFT* або вейвлет-скалограм, досягає 90–100 % точності завдяки розпізнаванню частотно-часових патернів на зображеннях [19]. Дилатовані *CNN* (*dilated convolutions*) збільшують рецептивне поле без зростання кількості параметрів, що покращує класифікацію тривалих жестів [20].

2. Рекурентні мережі (*LSTM*, *GRU*) моделюють довготривалі часові залежності в послідовностях сЕМГ-сигналів. Двоспрямований *LSTM* (*BiLSTM*) обробляє сигнал у прямому та зворотному напрямках, підвищуючи точність розпізнавання рухів з плавними фазами [21].

3. Гібридні архітектури *CNN+LSTM* поєднують здатність *CNN* до виділення просторово-часових ознак із здатністю *LSTM* до моделювання послідовностей. Є найбільш дослідженим підходом у задачах класифікації жестів [22,23]:

–*CNN+LSTM* досягає 97–99 % точності на датасетах *DualMyo* та *NinaPro* [22,23];

– багатоканальна *CNN-LSTM* з 8 каналами забезпечує >95 % точності при 10 класах жестів [23].

1.5 Вимоги до біотехнічної системи розпізнавання жестів. Обґрунтування вибору апаратної та програмної платформи

Формування вимог до системи є необхідним етапом перед вибором апаратної та програмної платформи. Вимоги визначаються фізіологічними особливостями сЕМГ-сигналів (розглянутими у підрозділах 1.1–1.3), обмеженнями, що встановлені стандартами реєстрації та практичними критеріями застосування системи в реальному часі.

Метрологічні вимоги:

1. Частота дискретизації. Робоча смуга сЕМГ-сигналу становить 10–500 Гц. Відповідно до теореми Найквіста мінімальна частота дискретизації — 1000 вибірок/с на канал. З урахуванням антиелайзингового запасу прийнята частота: ≥ 2000 вибірок/с (2 кГц) [10].

2. Роздільна здатність АЦП. Динамічний діапазон сЕМГ охоплює сигнали від 50 мкВ до 5 мВ (співвідношення $\approx 100:1$). При напрузі опорного джерела АЦП 3,3 В мінімально необхідна роздільна здатність — 12 біт (крок квантування $\approx 0,8$ мВ на виході підсилювача); рекомендована — 16 біт для забезпечення запасу при варіації коефіцієнта підсилення [10].

3. Смуга пропускання аналогового тракту: 10–500 Гц (смуговий фільтр); $CMRR$ підсилювача ≥ 80 дБ; вхідний імпеданс ≥ 10 МОм [9].

Вимоги до точності та надійності класифікації:

1. Точність класифікації (*accuracy*) при тестуванні на окремій тестовій вибірці повинна складати ≥ 90 % для набору з 6 жестів і ≥ 85 % для набору з 10 жестів. Ці порогові значення відповідають мінімально прийнятному рівню для практичного застосування в міоелектричних системах керування [24].

2. Метрики якості: крім загальної точності, система повинна забезпечувати значення $F1$ -міри $\geq 0,85$ для кожного класу жестів окремо, що виключає сильний дисбаланс між класами, прихований за усередненою точністю.

3. Стійкість до артефактів: класифікатор повинен зберігати точність при зміщенні електродів у межах ± 5 мм та при зміні рівня зусилля м'яза в діапазоні 20–80 % MVC [25].

Вимоги до затримки:

1. Загальна затримка системи (від початку жесту до отримання класифікованої відповіді) не повинна перевищувати 300 мс — критичного порогу, вище якого затримка стає суб'єктивно відчутною та знижує практичну цінність системи для керування протезами та інтерфейсами людина–машина [1,24].

Бюджет затримки розподіляється таким чином:

- електромеханічна затримка (*EMD*): 50–200 мс (фізіологічне обмеження);
- накопичення вікна сегментації: 150–200 мс;
- обчислення ознак та інференс мережі: ≤ 50 мс;
- передача даних (*USB/UART*): ≤ 10 мс.

Таким чином, обчислювальна складність алгоритму класифікації повинна забезпечувати час інференсу ≤ 50 мс на цільовій платформі.

Висновок до розділу 1

У першому розділі проведено огляд методів реєстрації та класифікації ЕМГ-сигналів. Розглянуто фізіологічні основи ЕМГ та особливості формування сЕМГ-сигналів, зокрема роль м'яза *FDS* як ключового каналу реєстрації при одноканальному підході. Проаналізовано типи поверхневих електродів, вимоги до аналогового тракту та АЦП, мікроконтролерні платформи, тощо. Огляд методів класифікації показав перевагу архітектур глибокого навчання над класичними підходами на основі ручно виділених ознак, а CNN з механізмами уваги — найефективнішим підходом для обробки часових рядів сЕМГ. Сформовано технічні вимоги до системи та обґрунтовано вибір апаратної платформи *Arduino UNO* з сенсором *SEN0240* як доступного і достатнього рішення для задач персоналізованої класифікації.

РОЗДІЛ 2

РОЗРОБКА ТА НАВЧАННЯ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ

У даному розділі описано повний цикл розробки класифікатора патернів сЕМГ-сигналів — від формування навчального набору даних до реалізації інференсу в реальному часі. Застосовано багатомасштабну одновимірну згорткову нейронну мережу (*Multi-scale 1D CNN*) з механізмом каналної уваги *Squeeze-and-Excitation* (SE), що навчається безпосередньо на сирому ЕМГ-сигналі без ручного виділення ознак. Весь програмний код реалізовано мовою *Python* з використанням бібліотек *TensorFlow/Keras*, *NumPy* та *scikit-learn*.

2.1 Формування та розмітка навчального набору даних ЕМГ-сигналів для заданого набору жестів

2.1.1. Датасет *FORS-EMG*

Як основа навчальної вибірки використано відкритий публічний датасет *FORS-EMG* [27]. Датасет містить багатоканальні записи поверхневої електроміографії від 19 випробувачів для 12 класів жестів руки: *Hand_Close*, *Hand_Open*, *Index*, *Index_Little*, *Peace*, *Radial_Deviation*, *Right_Angle*, *Thumb_Little*, *Thumb_UP*, *Ulnar_Deviation*, *Wrist_Extension*, *Wrist_Flexion*. Жести представлені на рисунку 2.1.




Рисунок 2.1 – Жести датасету *FORS-EMG* [27]

Записи виконано з частотою дискретизації 985 Гц. Кожен запис зберігається у форматі *MATLAB* (.mat) у масиві 'value' розміром ($C \times T$), де $C = 8$ — кількість каналів ЕМГ, T — кількість відліків у часі. Назва файлу кодує клас жесту та номер пробної серії: символна частина до числового суфікса є міткою класу (наприклад, "Hand_Close-03.mat" → мітка "Hand_Close"). Мітки зчитуються та кодуються у цілі числа класом *LabelEncoder* бібліотеки *scikit-learn*.

2.1.2 Сегментація сигналу ковзним вікном

На відміну від класичного підходу з ручним виділенням часових ознак, запропонована архітектура навчається безпосередньо на сирих відліках сигналу. Кожен 8-канальний запис ЕМГ розбивається на фіксовані вікна методом ковзного вікна: $W_k = sig[:, k \cdot STEP : k \cdot STEP + WINDOW_SIZE]$, $k = 0, 1, 2, \dots$, де $WINDOW_SIZE = 400$ відліків (≈ 407 мс при 985 Гц), $STEP = 200$ відліків (50 % перекриття). Кожне вікно W_k має форму (400×8) і безпосередньо подається на вхід мережі. Параметри вікна відповідають рекомендаціям [29]: 400 мс забезпечують достатній часовий контекст для виявлення патерну активації м'язів, 50 % перекриття збільшує кількість навчальних зразків без надмірного дублювання інформації.

Після сегментації виконується поканальна z-нормалізація на рівні вікна:

$$X_{norm} = \frac{(X - \mu_t)}{\sigma_t + \varepsilon}, \quad \varepsilon = 1e - 8, \quad (2.1)$$

де μ_t та σ_t — середнє та стандартне відхилення кожного вікна вздовж часової осі. Нормалізація на рівні вікна усуває повільний дрейф базової лінії та відмінності в імпедансі електродів між суб'єктами, що підвищує міжсуб'єктну узагальнювальну здатність моделі [30]. Загальна кількість вікон після сегментації становить $\sim 55\,000$.

2.1.3 Суб'єкт-незалежне розбиття вибірки

Стандартне випадкове розбиття 70/15/15 призводить до оптимістичного завищення тестової точності: вікна з одного суб'єкта потрапляють одночасно у *train* і *test*. Для реалістичної оцінки міжсуб'єктної узагальнювальної здатності застосовано суб'єкт-незалежне розбиття (*subject-aware split*) [30,31]: 19 суб'єктів рандомно переміщуються (*seed* = 42); перша 1/6 → тестова вибірка, наступна 1/6 → валідаційна, решта → навчальна. Таким чином жоден суб'єкт з тестової чи валідаційної вибірки не представлений у навчальній, що відповідає реальним умовам розгортання системи [30].

2.2 Обґрунтування вибору архітектури та реалізація багатомасштабної згорткової нейронної мережі

2.2.1 Порівняльний аналіз підходів до класифікації сЕМГ

При виборі архітектури нейронної мережі для класифікації сЕМГ-патернів розглядалися чотири основних підходи [32]:

1. *MLP* на ручно виділених часових ознаках. Переваги: низькі вимоги до даних, швидкий інференс (<1 мс). Недоліки: якість обмежена ручними ознаками, не використовує просторово-часову структуру сигналу.
2. Одновимірна *CNN* на сирому сигналі. Автоматично виявляє локальні патерни. Фіксований розмір ядра обмежує одночасне виявлення коротко- і довготривалих структур.
3. Рекурентні мережі (*LSTM*, *GRU*, *BiLSTM*). Враховують темпоральні залежності. Вищі вимоги до пам'яті *GPU* при зворотному поширенні через час; схильні до перенавчання.
4. Багатомасштабна *CNN* зі *SE*-увагою. Виявляє патерни на кількох часових масштабах одночасно. Найвища ефективність у між-суб'єктних протоколах [29].

Обрано архітектуру *Multi-scale 1D CNN* зі *SE*-увагою. Порівняльний аналіз [29] показує, що такі архітектури досягають точності 85–92 % при між-суб'єктній оцінці для 12 класів жестів, перевищуючи однорозмірні *CNN* та

MLP на 5–12 %. Концептуальним прообразом є архітектура *InceptionTime*, що демонструє ефективність паралельних багатомасштабних гілок для часових рядів у поєднанні з *GlobalAveragePooling* [33].

2.2.2 Вхідний шар та багатомасштабний блок

Вхідний тензор має форму (400×8) , що відповідає 400 відлікам для кожного з 8 каналів ЕМГ. Перший блок мережі реалізує паралельну згортку з чотирма різними розмірами ядра $k \in \{7, 15, 31, 63\}$, що відповідає часовим масштабам $\approx 7, 15, 32$ та 64 мс при 985 Гц. Для кожного розміру ядра незалежна гілка виконує:

$$b_k = \text{ReLU}(\text{BN}(\text{Conv1D}(64 \text{ фільтри}, k, \text{padding} = 'same')(x)))$$

де *BN* — пакетна нормалізація, *Conv1D* — одновимірна згортка, що застосовується до вхідного тензора, *ReLU* — функція активації. Паралельне використання малих ($k = 7$: локальні сплески активації рухових одиниць) і великих ядер ($k = 63$: глобальний патерн ізометричного скорочення) дозволяє виявляти особливості сигналу на різних часових масштабах одночасно [29,30]. Виходи чотирьох гілок об'єднуються конкатенацією:

$$x = \text{Concat}([b_7, b_{15}, b_{31}, b_{63}]) \rightarrow \text{форма } (400 \times 256),$$

де *Concat* — функція конкатенації.

2.2.3 Блок *Squeeze-and-Excitation (SE)* каналної уваги

Після багатомасштабного блоку застосовується механізм каналної уваги *Squeeze-and-Excitation* [32]. Блок виконує два кроки:

Блок *Squeeze*: глобальне усереднення по часовій осі для отримання вектора глобального контексту (2.2):

$$z_c = \left(\frac{1}{T}\right) \cdot \sum x_{\{t,c\}}, \quad c = 1, \dots, 256, \quad z \in R^{256}, \quad (2.2)$$

де z_c — скалярне число, що представляє «загальну активність», T — кількість часових кроків, $x_{\{t,c\}}$ — конкретний відлік тензора, c — формула, що застосовується до кожного з 256 каналів окремо, $z \in R^{256}$ — тип і розмір результатів.

Блок *Excitation*: двошарова *FC*-мережа навчає вагові коефіцієнти для кожного каналу (2.3):

$$s = \sigma(W_2 \cdot \delta(W_1 \cdot z)), W_1 \in R^{\{32 \times 256\}}, W_2 \in R^{\{256 \times 32\}} \quad (2.3)$$

де δ – *ReLU*, σ – сигмоїда, $ratio = 8 \left(32 = \frac{256}{8} \right)$. Вектор $s \in [0,1]^{256}$ — "важливість" каналів. Масштабування: $\tilde{x} = x \otimes s$. *SE*-блок адаптивно підсилює інформативні канали і пригнічує зашумлені [32].

2.2.4 Часова редукція та *GlobalAveragePooling*

Після *SE*-блоку виконується три послідовних кроки часової редукції:

$$Conv1D(128,3,ReLU) \rightarrow BN \rightarrow MaxPool(2) \rightarrow SpatialDropout(0.1): \\ (400 \times 256) \rightarrow (200 \times 128)$$

$$Conv1D(128,3,ReLU) \rightarrow BN \rightarrow MaxPool(2) \rightarrow SpatialDropout(0.1): \\ (200 \times 128) \rightarrow (100 \times 128)$$

$$Conv1D(128,3,ReLU) \rightarrow BN \rightarrow GlobalAveragePooling1D: \\ (100 \times 128) \rightarrow (128)$$

GlobalAveragePooling1D (*GAP*) обчислює середнє по $T' = 100$ часових кроках: $h_c = \left(\frac{1}{T'} \right) \cdot \sum \tilde{x}_{\{t,c\}}$, результуючи у вектор $h \in R^{128}$. На відміну від *BiLSTM*, *GAP* не потребує зберігання прихованих станів для кожного кроку при зворотному поширенні, що суттєво знижує пікове споживання пам'яті *GPU* [33]. Робота [33] демонструє, що *Multi-scale CNN + GAP* перевищує рекурентні методи на більшості еталонних датасетів часових рядів.

2.2.5 Класифікаційна голова

Вектор $h \in R^{128}$ проходить через дві повнозв'язні *Dense*-шари з *L2*-регуляризациєю ($\lambda = 1e - 4$):

$$Dense(128, ReLU) \rightarrow BN \rightarrow Dropout(0.4) \rightarrow Dense(64, ReLU) \rightarrow Dropout(0.3) \\ \rightarrow Dense(12, Softmax)$$

Вихідний шар перетворює логіти у розподіл ймовірностей по 12 класах (2.4):

$$P(y = k | x) = \frac{\exp(z_k)}{\sum_{j=0}^{11} \exp(z_j)} \quad (2.4)$$

Де $P(y = k | x)$ – імовірність належності вхідного вектора ознак, z_k – логіт (вихід лінійного шару) для класу.

Загальна кількість параметрів моделі: $\sim 380\ 000$. Функція втрат: *sparse_categorical_crossentropy* $L = -\left(\frac{1}{N}\right) \cdot \sum \log P(y = y_i | x_i)$. Оптимізатор: Adam ($lr = 0.001$), змішана точність *mixed_float16*.

2.3 Аугментація даних, навчання та оцінка моделі

2.3.1 Аугментація навчальних даних

З метою підвищення міжсуб'єктної узагальнювальної здатності реалізовано *on-the-fly* аугментацію у пайплайні *tf.data* [34]. Для кожного зразка незалежно застосовуються три перетворення:

1. Гаусів шум: $x \leftarrow x + \varepsilon, \varepsilon \sim N(0, 0.05^2)$. Моделює флуктуації АЦП та електродний шум [34].
2. Масштабування каналів: $x \leftarrow x \otimes \alpha, \alpha \sim U(0.85, 1.15), \alpha \in R^8$. Моделює варіабельність контакту електродів між суб'єктами.
3. Часовий зсув: $x \leftarrow roll(x, \delta), \delta \sim U(-40, 40)$ відліків. Усуває чутливість до точного моменту початку руху [34].

Аугментація застосовується виключно до навчальної вибірки.

2.3.2 Процедура навчання

Навчання виконано локально на *GPU* з увімкненим динамічним розподілом відеопам'яті. Застосовано три *callbacks*: *ModelCheckpoint* (зберігає ваги при кожному покращенні *val_accuracy*); *ReduceLROnPlateau* (знижує *lr* вдвічі при відсутності покращення *val_loss* протягом 8 епох, $lr_{min} = 1e-6$); *EarlyStopping* (зупиняє навчання при відсутності покращення *val_accuracy* протягом 25 епох, *restore_best_weights* = *True*).

Оптимізатор *Adam* адаптує швидкість навчання для кожного параметра, підтримуючи ковзні оцінки першого і другого моментів градієнта ($\beta_1 = 0.9, \beta_2 = 0.999$). Максимальна кількість епох — 500. Розмір батчу *BATCH* = 64.

2.3.3 Результати та аналіз

Після завершення навчання модель оцінено на тестовій вибірці (суб'єкти, не представлені у *train/val*): *val_accuracy* (валідаційні суб'єкти) = 59.4 %, *test_accuracy* (нові, невидимі суб'єкти) = 64.1 %, *macro avg F1* = 0.636.

Найвищий *F1-score* отримано для класів із виразним унікальним патерном: *Wrist_Extension* (*F1* = 0.778), *Radial_Deviation* (*F1* = 0.772), *Peace* (*F1* = 0.718). Найнижчі показники — для функціонально суміжних жестів: *Right_Angle* (*F1* = 0.423), *Hand_Open* (*F1* = 0.528).

Розрив між *val* і *test* точністю є характерним для суб'єкт-незалежних протоколів сЕМГ і обумовлений міжсуб'єктною варіабельністю сигналів (*domain shift*). Результат 64.1 % при 12 класах значно перевищує випадкову класифікацію (8.3 %) та відповідає рівню сучасних суб'єкт-незалежних систем [29]. Результат навчання зображений на рисунку 2.2.




Рисунок 2.2 – Графіки навчання нейромережі. а) точність; б) похибка; в) матриця помилок

Для підвищення точності до рівня ≥ 90 % система передбачає персоналізоване донавчання (*fine-tuning*) на індивідуальних даних користувача, зібраних апаратним модулем реєстрації ЕМГ, що відповідає клінічній практиці сучасних міоелектричних протезів [30].

2.3.4 Персоналізоване донавчання моделі (*fine-tuning*)

Для оцінки здатності моделі до персоналізації проведено симульований експеримент донавчання методом *leave-one-out* на датасеті *FORS-EMG*. Один суб'єкт виключається з навчальної вибірки і використовується виключно для

оцінки: 20 % його вікон слугують даними для донавчання (*fine-tuning*), решта 80 % — тестовою вибіркою.

Процедура донавчання: завантажується збережена *base*-модель; згорткові шари заморожуються, тренуються лише три *Dense*-шари; оптимізатор *Adam* із зниженою швидкістю навчання $lr = 1 \times 10^{-4}$; максимум 50 епох із *EarlyStopping* (*patience* = 10, *monitor* = *val_accuracy*).

Результати персоналізованого донавчання наведено нижче. До донавчання базова модель досягає на тестовому суб'єкті 72,2%

Після донавчання лише на 20 % індивідуальних записів суб'єкта точність становить: *Accuracy_fine-tune* = 91,2 %, *macro avg F1* = 0,912

Таким чином, донавчання на невеликій кількості персональних зразків (~280 вікон) забезпечує приріст точності на 19 відсоткових пунктів і виводить модель на рівень ≥ 90 %. Детальний *classification report* підтверджує рівномірний розподіл якості по всіх 12 класах: *precision* 0,824–0,993, *recall* 0,833–0,964, *F1* 0,859–0,958.

Отримані результати свідчать, що запропонована архітектура *Multi-scale CNN* зі *SE*-увагою ефективно адаптується до індивідуальних особливостей ЕМГ-сигналу конкретного користувача при мінімальній кількості персональних даних. Це підтверджує доцільність двоетапного підходу: попереднє навчання на великому публічному датасеті з подальшим персональним донавчанням — відповідно до клінічної практики сучасних міоелектричних протезів [30].

Висновок до розділу 2

У другому розділі розроблено та навчено нейромережевий класифікатор патернів сЕМГ-сигналів. Як навчальна вибірка використано відкритий датасет *FORS-EMG* (19 суб'єктів, 8 класів жестів, 985 Гц). Запропонована архітектура багатомасштабної *1D CNN* зі *SE*-блоком уваги поєднує чотири паралельні гілки *Conv1D* з ядрами 7–63 відліки, що дозволяє одночасно вловлювати короточасні сплески та тривалі обвідні ЕМГ-патерни, а блок *Squeeze-and-*

Excitation адаптивно підсилює найінформативніші карти ознак. На тестовій вибірці у суб'єкт-незалежному режимі досягнуто точність 64,1 % ($macro F1 = 0,636$). Застосування персоналізованого донавчання на 20 % індивідуальних записів одного суб'єкта підвищує точність до 91,2 % ($macro F1 = 0,912$), що підтверджує ефективність архітектури для адаптації до індивідуальних характеристик сигналу.

РОЗДІЛ 3

РОЗРОБКА СИСТЕМИ РЕЄСТРАЦІЇ ТА ПЕРВИННОЇ ОБРОБКИ ЕМГ-СИГНАЛІВ

У даному розділі описано апаратно-програмну реалізацію біотехнічної системи реєстрації та попередньої обробки поверхневих ЕМГ-сигналів.

Система побудована на основі мікроконтролера *Arduino UNO* з підключеним одноканальним ЕМГ-сенсором *DFRobot Gravity SEN0240* та реалізує повний ланцюжок від знімання аналогового сигналу з поверхні шкіри до формування числового вектора ознак, готового для подачі на вхід нейронної мережі. Описано структурну та функціональну схеми системи, алгоритми фільтрації та виділення ознак, а також програмне забезпечення збору даних.


3.1 Технічні характеристики компонентів апаратної частини системи та їх з'єднання

3.1.1 ЕМГ-сенсор *DFRobot Gravity EMG Sensor (SEN0240)*

Для реєстрації поверхневої ЕМГ у системі застосовується модуль *DFRobot Gravity EMG Sensor (SEN0240)* виробництва *OYMotion*. Сенсор призначений для носимих пристроїв та прототипів на базі мікроконтролерів і включає в єдиному корпусі комплект сухих електродів та аналоговий вхідний ланцюг [28] (рис. 3.1).



а)



б)

Рисунок 3.1 – Сенсор *DFRobot Gravity* а) Електроди; б) Аналоговий ланцюг

Модуль *SEN0240* містить три сухих поверхневих електроди: два диференціальних ($IN+$, $IN-$) та один референсний (REF). Диференціальна пара розміщується вздовж м'язових волокон на відстані 20 мм між центрами, референсний — на кістковому виступі або нейтральній ділянці шкіри. Сигнал між диференціальними електродами підсилюється вбудованим інструментальним підсилювачем з коефіцієнтом підсилення $\times 1000$, що переводить амплітуду сЕМГ-сигналу (50 мкВ – 5 мВ) у діапазон (50 мВ – 5 В), придатний для оцифрування стандартним АЦП мікроконтролера [5]. Основні технічні характеристики даного ЕМГ-сенсора наведено в таблиці 3.1.

Вбудований аналоговий ланцюг виконує наступні функції:

- інструментальне підсилення $\times 1000$ із $CMRR \geq 80$ дБ для придушення синфазної мережевої завади;
- смугова фільтрація 20–500 Гц (ФВЧ + ФНЧ) для виділення діагностично значущого частотного діапазону сЕМГ-сигналу;
- режекторний фільтр 50 Гц для додаткового придушення наводки промислової мережі.

Таблиця 3.1 – Характеристики сенсора *DFRobot Gravity*

Параметр	Значення
Напруга живлення	3,3 - 5 В
Споживаний струм	<10 мА
Коефіцієнт підсилення	$\times 1000$
Смуга пропускання (апаратна)	20-500 Гц
Режекторний фільтр	50 Гц
Вихідна напруга	0 - 3 В (аналоговий вихід)
Тип електродів	Сухі
Міжелектродна відстань	20 мм
Інтерфейс підключення	3-пін (VCC , GND , SIG)

Застосування сухих електродів (без провідного гелю) дозволяє швидко встановлювати та знімати сенсор під час лабораторних сесій збору даних.

Основним недоліком сухих електродів є підвищений імпеданс контакту шкіра–електрод (до 100 кОм), що частково компенсується вбудованим підсилювачем з вхідним імпедансом > 10 МОм.

3.1.2 Мікроконтролер *Arduino UNO* та його АЦП

Мікроконтролерна платформа системи — *Arduino UNO* на базі 8-бітного мікроконтролера *Atmel (Microchip) ATmega328P*. Характеристики платформи, важливі для реєстрації ЕМГ, наведено в таблиці 3.2.

Таблиця 3.2 – Характеристики *Arduino UNO*

Параметр	Значення
Мікроконтролер	<i>ATmega328P</i>
Тактова частота	16 МГц
Розрядність ЦПУ	8 біт
Флеш-пам'ять	32 КБ
ОЗП	2 КБ <i>SRAM</i>
Роздільна здатність АЦП	10 біт
Кількість аналогових входів	6 (A0-A5)
Опорна напруга АЦП	5 В
Крок квантування АЦП	~4.88 мВ/крок
Максимальна частота АЦП (1 канал)	~9600 вибірок/с
Інтерфейси	<i>UART, SPI, I²C</i>
Живлення	5 В

Вбудований 10-бітний сукцесивний АЦП (*SAR ADC*) *ATmega328P* оцифровує напругу на вибраному аналоговому вході відносно спільного виводу *GND*. При опорній напрузі $V_{REF} = 5$ В крок квантування (3.1):

$$\Delta V_{ADC} = \frac{V_{REF}}{2^N - 1} = \frac{5}{1023} \approx 4,88 \frac{\text{мВ}}{\text{крок}}, \quad (3.1)$$

де $N = 10$ – розрядність АЦП. Вихідне значення АЦП є цілим числом у діапазоні $[0, 1023]$, що відповідає вхідній напрузі $[0; 5]$ В.

При опорній напрузі 5 В та вихідному діапазоні *SEN0240* 0-3 В максимальне показання АЦП при максимальній довільній контракції ≈ 615 .

Таким чином, АЦП насичення не досягає (максимум 1023), а запас динамічного діапазону складає $\approx 40\%$, що унеможливило кліпінг при сильних скороченнях м'яза.

Для досягнення цільової частоти дискретизації $f_S = 1000$ Гц/канал використовується таймер на основі мікросекундного лічильника (функція *micros()* мови *C++/Arduino*), що забезпечує жорстке часове квантування з кроком 1000 мкс незалежно від завантаженості основного циклу.

Живлення сенсора *SEN0240* (+5 В, до 10 мА) здійснюється через цифровий вивід *D10*, встановлений у стан *HIGH* функцією *digitalWrite*. Максимально допустимий струм виводу *ATmega328P* складає 40 мА, що забезпечує надійне живлення сенсора із запасом 4:1.

3.2 Схема з'єднання компонентів

Принципова схема підключення показана на рисунку 3.2.




Рисунок 3.2 – Принципова схема підключення сенсора *DFRobot Gravity* до *Arduino UNO* у середовищі *Fritzing*

Порт *A* сенсора підключений до аналогового входу *A0* мікроконтролера *Arduino*. Порт *VCC* підключений до цифрового виходу *D10* мікроконтролера

для подачі живлення 5 В на сенсор. У свою чергу порт *GND* підключений до відповідного порту мікроконтролера.

3.3 Структурна схема біотехнічної системи реєстрації ЕМГ-сигналів

Розроблена біотехнічна система складається з чотирьох функціональних рівнів: електродний інтерфейс, аналогова обробка, цифрова реєстрація та програмна обробка на ПК. Структурна схема наведена на рисунку 3.3.




Рисунок 3.3 – Структурна схема розробленої біотехнічної системи

Перший рівень – електродний інтерфейс. Три сухі електроди *SEN0240* (*IN+*, *IN-*, *REF*) забезпечують електричний контакт зі шкірою над м'язом і передають диференціальний потенціал дії рухових одиниць на аналоговий вхідний ланцюг.

Другий рівень — аналогова обробка. Вбудований аналоговий ланцюг *SEN0240* виконує: (а) диференціальне підсилення з $G = 1000$; (б) обмеження смуги (ФВЧ $f_c = 20$ Гц та ФНЧ $f_c = 500$ Гц); (в) придушення мережевої завади режекторним фільтром 50 Гц.

Третій рівень — цифрова реєстрація. *ATmega328P* оцифровує аналоговий сигнал з входу *A0* з частотою 1000 вибірок/с за допомогою 10-бітного АЦП. Бібліотека *EMGFilters* виконує додаткову цифрову фільтрацію. Результат передається на ПК через інтерфейс *UART (USB)* у форматі "*ch1\n*" зі швидкістю 115 200 бод.

Четвертий рівень — програмна обробка. ПЗ на ПК (*Python 3*, бібліотеки *pyserial*, *numpy*) зчитує потік даних, виконує сегментацію на ковзні вікна (400 вибірок, крок 200), обчислює вектори ознак і передає їх на вхід нейронної мережі для класифікації жестів у реальному часі.

3.4 Алгоритми попередньої обробки ЕМГ-сигналів: фільтрація, нормалізація, сегментація на вікна, виділення ознак

Попередня обробка сЕМГ-сигналів охоплює чотири послідовних етапи, реалізованих у ланцюгу від аналогового виводу сенсора до числового вектора ознак. Правильна послідовність та параметри цих етапів критично впливають на якість класифікації.

1. Апаратна та цифрова фільтрація.

Перший рівень фільтрації — апаратний — реалізовано безпосередньо у модулі *SEN0240* (див. роз. 3.1.1). Другий рівень — цифрова фільтрація на мікроконтролері — виконується бібліотекою *EMGFilters* (C++, *Arduino*).

Бібліотека *EMGFilters* реалізує два типи *IIR*-фільтрів, що виконуються за кожним відліком у реальному часі (3.2, 3.3, 3.4):

Смугово-пропускний фільтр (*bandpass* 20–500 Гц). Реалізований як каскад фільтра верхніх частот (ФВЧ, $f_c = 20$ Гц) та фільтра нижніх частот (ФНЧ, $f_c = 500$ Гц) першого порядку кожний. Для ФВЧ першого порядку (*Butterworth*, дискретизований методом білінеарного перетворення):

$$HNP(z) = \frac{1 - z^{-1}}{1 - \alpha \cdot z^{-1}} \quad (3.2)$$

$$\alpha = \frac{\tau - \frac{T}{2}}{\tau + \frac{T}{2}} \quad (3.3)$$

$$\tau = \frac{1}{2\pi \cdot 20} \approx 7,96 \text{ мс} \quad (3.4)$$

$$T = 1 \text{ мс}, \quad (3.5)$$

де z^{-1} – попереднє значення сигналу; α – коефіцієнт полюса; τ – стала часу;
 $T = \frac{1}{f_s} = 1 \text{ мс}$ – крок дискретизації.

Аналогічно для ФНЧ (3.6, 3.7):

$$HLP(z) = \frac{\beta(1 + z^{-1})}{1 - (1 - 2\beta)z^{-1}}, \quad (3.6)$$

$$\beta = \frac{T}{T + \tau_2}, \quad (3.7)$$

де $\tau_2 = \frac{1}{2\pi 500} \approx 0,318 \text{ мс}$.

Режекторний фільтр реалізований як *IIR*-фільтр другого порядку з передавальною функцією (3.8):

$$Hnotch(z) = \frac{1 - 2 \cos \omega_0 z^{-1} + z^{-2}}{1 - 2r \cos \omega_0 z^{-1} + r^2 z^{-2}}, \quad (3.8)$$

де $\omega_0 = \frac{2\pi 50}{1000} \approx 0,314 \frac{\text{рад}}{\text{вибірка}}$ – нормована кутова частота 50 Гц; $r = 0,97$ – коефіцієнт полюса, що визначає ширину загороджуваної смуги.

Ініціалізація фільтрів у скетчі *Arduino*:

`filter1.init(SAMPLE_FREQ_1000HZ, NOTCH_FREQ_50HZ, true, true, true)`, де три логічних аргументи вмикають відповідно ФНЧ, ФВЧ та режекторні фільтри.

Поєднання апаратного (аналогового) та цифрового фільтрів утворює двоступінчасту систему придушення завад. Перший ступінь (*SEN0240*) знижує рівень завади до АЦП, попереджуючи насичення та аліасинг; другий ступінь (*EMGFilters*) додатково покращує відношення сигнал до шуму (*SNR*) вже у цифровому домені.

2. Нормалізація сигналу

Після цифрової фільтрації сигнал знаходиться у кодах АЦП [0; 1023]. Для усунення залежності від індивідуального імпедансу шкіра–електрод та

рівня підсилення застосовуються два методи нормалізації залежно від етапу обробки:

Нормалізація по *MVC* (*maximal voluntary contraction*) – на апаратному рівні верифікації: $x_{norm}(t) = x_{ADC}(t) / x_{MVC}$, де x_{MVC} — максимальне значення АЦП-коду, зафіксоване під час калібрувальної сесії при максимальному скороченні м'яза. Нормований сигнал $x_{norm} \in [0; 1]$ є безрозмірним і не залежить від індивідуальних особливостей шкіра–електрод.

z-score нормалізація – на рівні підготовки навчального набору даних (виконується у *Python* перед навчанням МНМ): $x_z(t) = (x(t) - \mu) / \sigma$, де μ , σ — математичне сподівання та стандартне відхилення сигналу, обчислені по всій навчальній вибірці. Після *z-score*-нормалізації вхідні ознаки мають нульове середнє та одиничне стандартне відхилення, що прискорює збіжність градієнтного спуску при навчанні нейронної мережі.

3. Сегментація на часові вікна

Класифікація жестів базується на аналізі коротких часових сегментів (вікон) сигналу, оскільки сЕМГ-сигнал є квазістаціонарним лише на інтервалах 200–400 мс. Реалізується ковзне вікно (*sliding window*) з частковим перекриттям:

- розмір вікна: $NW = 400$ вибірок (400 мс при $f_s = 1000$ Гц);
- крок вікна: $Nstep = 200$ вибірок (200 мс);
- перекриття: $50\% = (NW - Nstep) / NW = 200 / 400$.

Кількість вікон KW з одного запису тривалість T вибірок: $KW = \text{floor}((T - NW) / Nstep) + 1$. Для $T = 3000$ вибірок: $KW = \text{floor}((3000 - 400) / 200) + 1 = \text{floor}(13) + 1 = 14$ вікон. З 20 спроб $\times$ 3 с на жест отримується $20 \times 14 = 280$ вікон на клас. Для 3 класів загальний обсяг навчальної вибірки складає $3 \times 280 = 840$ вікон. Ковзне вікно з 50% перекриттям є стандартом для сЕМГ-систем реального часу: затримка між рішеннями класифікатора дорівнює кроку вікна (200 мс), а не повному розміру (400 мс), що покращує часову роздільну здатність системи.

3.5 Скетч для мікроконтролера *Arduino*

Мікроконтролерне ПЗ реалізовано мовою C++ у середовищі *Arduino IDE* та використовує відкриту бібліотеку *EMGFilters*. Повний код скетча наведено в репозиторію [37]; нижче описано ключові фрагменти.

Підключення бібліотеки та визначення виводів подано на рисунку 3.4:

```

1  #include "EMGFilters.h"
2  #define PIN_CH1  A0
3  #define PWR_CH1  10
4  EMGFilters filter1;
5
6  void loop() {
7      static unsigned long lastUs = 0;
8      unsigned long now = micros();
9      if (now - lastUs >= 1000) {
10         lastUs = now;
11         analogRead(PIN_CH1); int f1 = filter1.update(analogRead(PIN_CH1))
12         Serial.print(f1);
13         Serial.print(',');
14     }
15 }
```

Рисунку 3.4 – Лістинг підключення бібліотеки виводів

Подвійний виклик *analogRead* перед фільтрацією. Перший виклик (без збереження результату) виконує розряд вхідного конденсатора *S/H* схеми АЦП після перемикання внутрішнього аналогового мультиплексора між каналами. Без цього кидного зчиту перший відлік нового каналу може містити залишковий заряд від попереднього каналу (міжканальний *cross-talk*), що спотворює результат.

Швидкість передачі 115 200 бод дозволяє передати один рядок (типово 8–12 *ASCII*-символів + "*\r\n*") менше ніж за 1 мс, тобто *UART* не затримує основний цикл при $f_S = 1000$ Гц.

Висновок до розділу 3

У третьому розділі реалізовано апаратно-програмну платформу одноканальної реєстрації ЕМГ. Описано технічні характеристики

мікроконтролера *Arduino UNO* (*ATmega328P*, 10-біт АЦП) та сенсора *DFRobot Gravity SEN0240*, що виконує апаратну фільтрацію у смузі 20–500 Гц та підсилення сигналу до рівня, сумісного з АЦП мікроконтролера. Розроблена прошивка реалізує жорстке таймерне квантування на частоті 1000 Гц, подвійний виклик *analogRead* для усунення крос-тальку АЦП, цифрову фільтрацію бібліотекою *EMGFilters* (ФВЧ 20 Гц, ФНЧ 500 Гц, режекторний фільтр 50 Гц) та передачу даних через *UART* зі швидкістю 115 200 бод. Верифікація якості сигналу підтвердила рівень шуму у стані спокою менше 5 % від амплітуди при максимальному довільному скороченні та відсутність насичення АЦП.

РОЗДІЛ 4

ТЕСТУВАННЯ ТА АНАЛІЗ ЕФЕКТИВНОСТІ СИСТЕМИ

У даному розділі описано повний цикл практичної реалізації біотехнічної системи класифікації патернів сЕМГ-сигналів: від збирання апаратного прототипу до верифікації роботи системи у режимі реального часу. Реалізація охоплює чотири взаємопов'язані етапи: збирання та налагодження апаратної частини; навчання базової нейронної мережі на одноканальних даних публічного датасету; персоналізоване донавчання на реальних даних конкретного користувача; тестування класифікації жестів у реальному часі.

4.1 Збирання апаратної частини системи

Апаратна частина системи включає два основних компоненти: мікроконтролер *Arduino UNO* та одноканальний ЕМГ-сенсор *DFRobot Gravity EMG Sensor (SEN0240)* виробництва *OYMotion*. Детальні технічні характеристики обох компонентів наведено у Розділі 3 (підрозділи 3.1.1–3.1.2). У цьому підрозділі описано практичну процедуру з'єднання, розміщення електродів та верифікації якості сигналу. На рисунку 4.1 представлений зовнішній вигляд моделі.




Рисунок 4.1 – Зовнішній вигляд моделі

Живлення сенсора здійснюється через цифровий вивід *D10* (встановлений у *HIGH* у функції *setup()*), що дозволяє програмно вимикати сенсор без відключення кабелю.

Відповідно до стратегії одноканальної реєстрації сенсор *SEN0240* розміщується на м'язі *flexor digitorum superficialis (FDS)* правого передпліччя, у середній частині передпліччя над черевцем м'яза.

Перед кожною сесією збору даних шкіра в зоні розміщення електродів протирається спиртовою серветкою для зниження імпедансу контакту. Якість сигналу верифікується за допомогою скрипта *emg_visualize.py* [37], що відображає ковзний осцилограф у реальному часі. Критерієм прийнятної якості є рівень шуму у стані спокою менше 5 % від амплітуди при максимальному довільному скороченні (*MVC*) та відсутність насичення АЦП.

Детальний опис прошивки *emg_1ch_filtered.ino* наведено у розділі 3.5. Стисло: скетч реалізує жорстке таймерне квантування 1000 Гц (*micros()*), подвійний виклик *analogRead* для усунення *cross-talk* АЦП, цифрову фільтрацію бібліотекою *EMGFilters* (ФВЧ 20 Гц, ФНЧ 500 Гц, *notch* 50 Гц) та передачу результату на ПК через *UART* (115 200 бод) у форматі "значення\n".

4.2 Адаптація нейронної мережі під одноканальну реєстрацію

Розроблена у Розділі 3 багатомасштабна *CNN* працює з 8-канальними даними датасету *FORS-EMG*. Для реалізації носимого прототипу на базі *Arduino* використання 8 електродних каналів є практично недоцільним. Натомість запропоновано одноканальний підхід із застосуванням гібридної архітектури, що поєднує *CNN* на сирому сигналі та ручно виділені часові і частотні ознаки.

М'яз *FDS* (m. *flexor digitorum superficialis*) обрано каналом реєстрації як основний м'яз-флексор пальців, що активується при стисканні кулака та бере участь у згинанні зап'ястка. При навчанні базової моделі на датасеті *FORS-EMG* використовується канал *CH5*, що відповідає розміщенню електродів на середній частині передпліччя над *FDS*.

Базова модель (*emg_1ch_2cls_train.py*, збережена у *emg_1ch_2cls_model.keras*) [37] реалізує одновимірну CNN з багатомасштабним блоком та механізмом *Squeeze-and-Excitation* (SE) уваги по каналах:

Вхід: (400, 1)

Багатомасштабний блок (4 паралельні гілки, ядра 7 / 15 / 31 / 63):

$Conv1D(32, k, same, ReLU) \rightarrow BN \times 4 \rightarrow Concatenate \rightarrow (400, 128)$

SE-блок: $GAP(128) \rightarrow Dense(16, ReLU) \rightarrow Dense(128, sigmoid) \rightarrow Reshape \rightarrow Multiply$

Часова редукція:

$Conv1D(64, 3, same, ReLU) \rightarrow BN \rightarrow MaxPool(2) \rightarrow SpatialDropout(0.1) (\times 2)$

$Conv1D(64, 3, same, ReLU) \rightarrow BN \rightarrow GlobalAveragePooling1D \rightarrow (64,)$

Класифікаційна голова:

$Dense(64, ReLU) \rightarrow BN \rightarrow Dropout(0.4) \rightarrow Dense(2, Softmax)$

Паралельне застосування ядер різних розмірів (7–63 відліки $\approx$ 7–64 мс) дозволяє моделі одночасно вловлювати короткотривалі сплески активності та тривалі обвідні патерни ЕМГ-сигналу. SE-блок адаптивно підсилює найінформативніші карти ознак і пригнічує шумові.

Клас *Rest* у базовій моделі відсутній як окрема мітка, оскільки датасет *FORS-EMG* не містить записів стану м'язового спокою. При персоналізованому донавчанні (розділ 4.3) *Rest* збирається як повноцінний третій клас із реальних записів користувача і явно включається до *Softmax*.

Навчання виконано локально (WSL2, GPU) на каналі *CH5* датасету *FORS-EMG* (985 Гц, 19 суб'єктів, 2 класи жестів: *Hand_Close*, *Wrist_Flexion*).

Параметри навчання:

– розмір вікна: 400 відліків ($\approx$ 407 мс); крок: 300 відліків;

– суб'єкт-незалежне розбиття (*subject-aware split*): *train/val/test* = 13/3/3 суб'єкти;

– аугментація (*train*): гаусів шум ($\sigma = 0.05$), масштабування амплітуди ($\times 0.85$ – 1.15), часовий зсув (± 40 відліків);

- оптимізатор: *Adam* ($lr = 0.001$), *EarlyStopping* ($patience = 12$, $monitor = val_accuracy$);
- *ReduceLROnPlateau*: $factor = 0.5$, $patience = 5$; розмір батчу: 128; максимум епох: 100.

Нормалізація: *z-score* по кожному вікну, що виключає витік даних (*data leakage*) у валідаційну та тестову вибірки [30].

Результати на тестовій вибірці (суб'єкти, не використані при навчанні) зображені на рисунку 4.2.




Рисунок 4.2 – Графіки навчання неймережі. а) точність; б) похибка; в) матриця помилок

Досягнута точність 66.5 % є характерною для суб'єкт-незалежних одноканальних систем: значна частина міжособистісної варіабельності ЕМГ-сигналів не може бути врахована моделлю при тренуванні на даних 13 суб'єктів та тестуванні на трьох невидимих. Нижчий *recall* класу *Hand_Close* (0.527 vs 0.803 у *Wrist_Flexion*) пояснюється частковим перекриттям амплітудних профілів стиснення кулака та пасивного положення кисті на одному каналі *CH5*.

Незважаючи на обмежену точність у суб'єкт-незалежному режимі, базова модель формує узагальнені ознаки ЕМГ-патернів, що є необхідною передумовою для ефективного персоналізованого донавчання (розділ 4.3).

4.3 Персоналізоване навчання під індивідуального користувача

Після верифікації якості сигналу виконується збір персонального навчального датасету скриптом *emg_collect_data.py* [37]. Протокол збору для трьох класів жестів подано у таблиці 4.1:

Таблиця 4.1 — Класи жестів

Клас 0 — <i>Hand_Close</i> :	повне стиснення пальців у кулак
Клас 1 — <i>Rest</i> :	рука повністю розслаблена, без руху
Клас 2 — <i>Wrist_Flexion</i> :	згинання зап'ястка, долоня рухається донизу

Важливо: клас *Rest* не присутній у датасеті *FORS-EMG* ні для 8-канальної, ні для 1-канальної базової моделі — він вперше з'являється саме на етапі персонального збору як окремий клас із реальних записів конкретного користувача.

Для кожного класу виконується $TRIALS = 10$ спроб по 5 секунд. Загальний обсяг датасету: 30 записів, 3 класи $\times$ 10 спроб, середня тривалість запису 4996 відліків ≈ 5.0 с при $f_s = 1000$ Гц. Датасет збережено у форматі *.npz* (*emg_realdata.npz*): $X.shape = (30,)$, $y.shape = (30,)$.

Донавчання виконується функцією *finetune()* скрипта *emg_system.py*. Записи нарізаються на вікна з кроком $STEP_{FT} = 100$ (більший *overlap* для збільшення кількості зразків із малого датасету):

$$\text{Вікон на запис: } (4996 - 400) / 100 + 1 = 46$$

$$\text{Загалом: } 30 \times 46 = 1380 \text{ вікон}$$

$$\text{Розбиття: } \text{train } 80 \% (1104) / \text{val } 20 \% (276), \text{ stratified}$$

Для запобігання перенавчанню заморожуються всі згорткові шари — тренуються лише *Dense*-шари класифікаційної голови ($\sim 24\,000$ параметрів із $\sim 380\,000$ загальних). Вихідний шар замінюється з *Dense(2)* на *Dense(3, Softmax)* для трьох класів. Параметри: *Adam* ($lr = 1 \times 10^{-4}$), *EarlyStopping* (*patience* = 10, *monitor* = *val_accuracy*), максимум 50 епох.

Після донавчання модель оцінено на валідаційній вибірці (276 вікон, 92 на клас). Отримано точність:

$$val_accuracy = 97.5 \%, \quad macro \ avg \ F1 = 0.97$$

Детальний *classification report* наведено в таблиці 4.2.

Таблиця 4.2 — Результати персоналізованого донавчання (fine-tuning)

Клас	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
<i>Hand_Close</i>	0.99	0.98	0.98	92
<i>Rest</i>	0.94	1.00	0.97	92
<i>Wrist_Flexion</i>	1.00	0.95	0.97	92
<i>Macro avg</i>	0.98	0.97	0.97	276

Найвища точність — *Hand_Close* ($F1 = 0.98$). Клас *Rest* розпізнається з $recall = 1.00$ — жодне вікно спокою не класифіковано як активний жест. Досягнута точність 97.5 % підтверджує ефективність підходу: персоналізоване донавчання на ~1100 вікнах адаптує модель до індивідуальних характеристик конкретного користувача.

4.4 Тестування системи в режимі реального часу

Реалтайм-класифікація реалізована в модулі *emg_system.py*. Алгоритм роботи:

1. Зчит відліків з *COM5* через *ser.readline()* (115 200 бод).
2. Накопичення у кільцевому буфері *deque(maxlen = 400)*.
3. Кожні $STEP_RT = 300$ відліків (300 мс) — виконання *predict: z-score* нормалізація вікна 400 відліків, *predict* на *emg_finetuned.keras*, *argmax* → клас.
4. Мажоритарне голосування (*majority voting*) по останніх 5 предикціях — фінальний клас виводиться на екран.

Затримка реакції системи: накопичення вікна — 300 мс; обчислення *predict* — менше 20 мс (*CNN + Dense* на *CPU*); з мажоритарним голосуванням — 300–600 мс, що відповідає вимогам до реактивності міоелектричних пристроїв.

4.5 Результати тестування

Затримка реакції системи: накопичення вікна — 300 мс; обчислення *predict* — менше 5 мс (*Dense* на *CPU*); з мажоритарним голосуванням — 300–600 мс, що відповідає вимогам до реактивності міоелектричних пристроїв [10].

Практична експлуатація міоелектричних систем супроводжується поступовою деградацією якості класифікації внаслідок дрейфу характеристик ЕМГ-сигналу: зміщення електродів, втоми м'язів, зміни рівня потовиділення та температурних ефектів на шкірно-електродному інтерфейсі. Для виявлення такої деградації в реальному часі реалізовано механізм моніторингу впевненості моделі (*confidence monitoring*).

На кожному кроці класифікації (кожні 300 мс) система зберігає значення максимальної ймовірності виведеного класу до ковзного буфера з вікном $N = 20$ предиктів (~ 6 с). Якщо середня впевненість по буферу падає нижче порогу $\theta = 0,70$ — система виводить сигнал попередження на інтерфейсі користувача з пропозицією провести повторну калібрувальну сесію (див. рис. 4.3). При відновленні якості сигналу попередження автоматично зникає. Значення $\theta = 0,70$ обрано відповідно до рекомендацій [30]: при впевненості нижче цього рівня частка хибних класифікацій зростає нелінійно, що призводить до неприйнятної точності керування. Вибір вікна $N = 20$ забезпечує баланс між чутливістю до короточасних артефактів (не спрацьовує на поодинокі викиди) та оперативністю виявлення стійкого дрейфу.




Рисунок 4.3 – Попередження про потребу в recalібрації

Запропонований підхід дозволяє підтримувати точність на рівні ~ 95 % протягом тривалих робочих сесій без постійного перенавчання, а процедура повторної калібровки займає менше 2 хвилин ($30 \text{ записів} \times 5 \text{ с} + \text{fine-tuning Dense-шарів}$).

На рисунку 4.4 представлений зовнішній вигляд програми.

розрізнення всіх трьох класів при рівні зусилля $\sim 70\%$ від *MVC* та збереження коректної класифікації при зміщенні електродів до 3–5 мм. Реалізований механізм моніторингу впевненості моделі ($\theta = 0,70$, вікно $N = 20$ предиктів, ~ 6 с) дозволяє автоматично виявляти дрейф калібрування та підтримувати точність $\sim 95\%$ упродовж тривалих сесій без постійного перенавчання.

РОЗДІЛ 5

ОБМЕЖЕННЯ РЕАЛІЗОВАНОГО ПРОТОТИПУ ТА НАПРЯМИ ВДОСКОНАЛЕННЯ

5.1 Аналіз поточних обмежень

Реалізована система демонструє практичну працездатність у задачі класифікації трьох класів жестів, однак має ряд конструктивних та алгоритмічних обмежень, що визначають напрями подальшого вдосконалення.

1. Одноканальна реєстрація.

Використання одного каналу (м'яз *FDS*) забезпечує реєстрацію лише підмножини патернів активації передпліччя. *FDS* активується переважно при флексії пальців, тому жести з домінуванням розгиначів (*Wrist_Extension*, *Radial_Deviation*) формують на цьому каналі слабкі або перекриті сигнали. У *cross-subject* режимі базова модель досягає 66.5 % на двох класах — близько до теоретичної межі для одноканальних систем без персоналізації (~60–70 %).

2. Малий словник жестів.

Поточна система розпізнає 2 активних жести + *Rest*. Для практичного застосування у протезуванні або керуванні пристроями необхідно мінімум 5–8 класів. Розширення словника на одному каналі обмежене фізичною схожістю ЕМГ-патернів різних жестів при реєстрації з єдиної точки.

3. Якість апаратної частини.

Arduino UNO має 10-бітний АЦП (1024 рівні), що обмежує динамічний діапазон вхідного сигналу. При слабкій активації (~10–20 % *MVC*) рівень квантування АЦП вносить помітний шум. Сенсор *DFRobot SEN0240* виконує апаратну фільтрацію (смуга 20–500 Гц), однак не забезпечує ізоляцію від мережевих завад при роботі поблизу джерел 50 Гц.

4. *Cross-subject* узагальнення базової моделі.

Тестова точність 66.5 % у суб'єкт-незалежному режимі є достатньою лише для ініціалізації *fine-tuning*, але не для безпосереднього використання.

Вирішення цього обмеження потребує або значно більшого датасету для навчання, або принципово інших методів доменної адаптації.

5.2 Напрями вдосконалення та очікувани показники точності

1. Найбільш прямий шлях до підвищення точності та розширення словника жестів. Встановлення 2–4 сенсорів на різних м'язах передпліччя (*FDS*, *ECR*, *FCU*, *EDC*) дозволяє охопити ширший простір патернів активації.

Оцінки *cross-subject* точності ґрунтуються на результатах Розділу 3 (8-канальна модель: 64.1 %) та літературних даних для аналогічних архітектур. Зауважимо, що збільшення каналів понад 4–6 дає спадний приріст точності і ускладнює носіння пристрою.

2. Поточний протокол збору (10 спроб $\times$ 3 класи $\times$ 5 с) формує ~ 1380 вікон. Збільшення кількості спроб до 20–30 та введення варіацій умов (різний рівень зусилля, різні сесії) суттєво підвищує стійкість донавченої моделі. Найвагоміший ефект дає мультисесійний збір (2–3 різних дні): він охоплює природну варіабельність розміщення електродів та стану шкіри, знижуючи дрейф калібрування.

3. Введення механізму моніторингу впевненості моделі у реальному часі дозволяє виявляти деградацію якості сигналу: якщо середня впевненість по вікнах за останні N секунд падає нижче порогу (наприклад, 0.70), система сигналізує про необхідність повторної калібрувальної сесії. Такий підхід дозволяє підтримувати точність ~ 95 % протягом тривалих сесій без постійного перенавчання [31].

4. Поточна *Multi-scale CNN + SE Attention* є ефективним, але не найпотужнішим варіантом для ЕМГ-класифікації. Перспективні напрями:

а) *Transformer / Self-Attention encoder*: замість *Conv1D*-блоків — *Multi-head Self-Attention* на вікнах сигналу. Показує приріст +3–7 % у *cross-subject* режимі порівняно з *CNN* [30].

б) *Contrastive pre-training (SimCLR, supervised contrastive loss)*: навчання крос-суб'єктних представлень без міток на великому

датасеті, потім *fine-tune* на персональних даних. Дозволяє досягти ~85–90 % *cross-subject* без *fine-tuning* для 4–8 класів.

в) *Domain Adversarial Neural Networks (DANN)*: явна мінімізація міжсуб'єктної варіабельності під час навчання, що підвищує *cross-subject* точність на ~5–8 % без збільшення датасету [30].

5. Заміна *Arduino UNO* на мікроконтролер з 12–16-бітним АЦП (*STM32*, *ESP32-S3*, або спеціалізовані ЕМГ-чипи *ADS1299*) підвищує динамічний діапазон вхідного сигналу і знижує шум квантування. Це особливо критично для точного розпізнавання жестів при малому зусиллі (~10–20 % *MVC*), де поточний прототип показує найбільше хибних розпізнавань *Rest* як *Wrist_Flexion*.

5.3 Пріоритизація вдосконалень

З практичної точки зору вдосконалення доцільно впроваджувати у наступному порядку за співвідношенням ефект/складність:

1. Мультисесійний збір персональних даних (20–30 спроб, 2–3 сесії) — мінімальні зусилля, приріст стійкості ~5–10 %.

2. Додавання 2-го каналу реєстрації (м'яз *ECR* або *FCU*) — один додатковий сенсор *SEN0240*, розширення до 4–5 класів, очікуваний *cross-subject* приріст +8–12 %.

3. Перехід на 12-бітний АЦП (*STM32F4* або *ESP32*) — покращення *SNR* при слабких сигналах, особливо актуально для жестів *Rest*.

4. Впровадження *Transformer*-архітектури або *contrastive pre-training* — значний приріст *cross-subject* точності, але потребує переробки пайплайну навчання.

Висновок до розділу 5

У п'ятому розділі проведено аналіз обмежень реалізованого прототипу та визначено пріоритетні напрями вдосконалення. Виявлено чотири основні обмеження: одноканальна реєстрація з м'яза *FDS* звужує словник жестів та обмежує *cross-subject* точність базової моделі рівнем 66,5 %; 10-бітний АЦП

знижує якість сигналу при слабкій м'язовій активації ($\sim 10\text{--}20\%$ *MVC*); малий обсяг персональної навчальної вибірки обмежує стійкість моделі до варіацій умов реєстрації. Напрями вдосконалення пріоритизовано за співвідношенням ефект/складність: мультисесійний збір персональних даних забезпечує приріст стійкості $\sim 5\text{--}10\%$ при мінімальних зусиллях; додавання другого каналу реєстрації (м'яз *ECR* або *FCU*) розширює словник до 4–5 класів з очікуваним приростом *cross-subject* точності $+8\text{--}12\%$; перехід на 12-бітний АЦП (*STM32F4* або *ESP32*) усуває шум квантування при слабких сигналах; впровадження *Transformer*-архітектури або *contrastive pre-training* забезпечить суттєвий приріст *cross-subject* точності без збільшення персонального датасету.

РОЗДІЛ 6

ОХОРОНА ПРАЦІ

Дипломна робота виконується на базі НТУУ «КПІ імені Ігоря Сікорського». В ході виконання роботи розроблено біотехнічну систему реєстрації та класифікації ЕМГ-сигналів на основі мікроконтролера *Arduino UNO (ATmega328P)*, ЕМГ-сенсора *DFRobot Gravity SEN0240* та персонального комп'ютера з програмним забезпеченням на основі штучної нейронної мережі.

Даний розділ виконується за планом №1 — «Виявлення та оцінка потенційно небезпечних і шкідливих виробничих факторів, що створюються конструкцією об'єкту, який розробляється, та заходи їх усунення».

6.1 Характеристика розробленої біотехнічної системи

6.1.1 Характеристики компонентів системи

Система побудована на основі трьох апаратних компонентів. Технічні характеристики компонентів, визначені відповідно до ДСТУ EN 61140:2015 та ДСТУ EN 60529:2018, наведено в таблиці 6.1.

Таблиця 6.1 – Характеристики компонентів розробленої системи

№	Найменування компонента	Клас захисту (спосіб)	Ступінь захисту (IP)	Напруга живлення, В	Споживана потужність, Вт	Макс. струм, мА	Кількість
1	Мікроконтролер <i>Arduino UNO (ATmega328P)</i>	I	IP30	5 (USB)	0,25	200	1
2	ЕМГ-сенсор <i>DFRobot Gravity SEN0240</i>	I	IP30	3,3–5,5	0,05	10	1
3	Персональний комп'ютер (ПК)	I	IP20	220 (AC)	≤300	—	1

Класи захисту за способом захисту від ураження електричним струмом та ступені захисту кожухами вказані відповідно до ДСТУ EN 61140:2015 «Захист проти ураження електричним струмом. Загальні аспекти щодо установок та обладнання» та ДСТУ EN 60529:2018 «Ступені захисту, забезпечувані кожухами».

6.1.2 Складові частини системи

Схема з'єднання функціональних частин системи наведена на рисунку 6.1. *Arduino UNO* та ЕМГ-сенсор *SEN0240* отримують живлення постійним струмом 5 В від ПК через інтерфейс *USB*. ПК живиться від мережі змінного струму 220 В / 50 Гц. Аналоговий сигнал сенсора (0–3 В) надходить на вхід *A0* мікроконтролера, оцифровується та передається на ПК через *UART/USB* для класифікації нейронною мережею.




Рисунок 6.1 – Схема з'єднання функціональних частин системи

6.1.3 Характер взаємодії об'єкту в системі «людина–об'єкт»

Засоби відображення інформації про стан роботи системи представлені в таблиці 6.2.

Таблиця 6.2 – Взаємодія об'єкту в системі «людина–об'єкт»

№	Найменування компонента	Вид відображення інформації	Кількість
1	Мікроконтролер <i>Arduino UNO</i>	Індикатори <i>LED</i> : <i>ON</i> (живлення), <i>TX</i> , <i>RX</i> (передача даних)	1
2	ЕМГ-сенсор <i>DFRobot SEN0240</i>	Індикатор підключення живлення – світлодіод	1
3	ПК (монітор)	Графічний інтерфейс: графік ЕМГ-сигналу в реальному часі, результат класифікації жесту	1

6.2 Оцінка потенційних небезпек, що створюються конструкцією системи, та заходи їх усунення

З метою забезпечення безпечної експлуатації системи виявлено та оцінено потенційно небезпечні фактори, що визначені для об'єкту в цілому: небезпека ураження електричним струмом та небезпека займання.

6.2.1 Небезпека ураження електричним струмом

Оцінка та аналіз джерел, причин і наслідків небезпек електричного характеру наведені в таблиці 6.3.

Таблиця 6.3 – Оцінка небезпек електричного характеру

Найменування компонента	Джерело небезпеки	Причини небезпеки	Наслідки небезпеки
Персональний комп'ютер (ПК)	Змінний струм 220 В	Пошкодження ізоляції мережевого кабелю; відсутність або порушення захисного заземлення корпусу	Ураження електричним струмом, що може мати летальні наслідки
Мікроконтролер <i>Arduino UNO (ATmega328P)</i>	Постійний струм 5 В (USB)	Неправильне з'єднання з компонентами системи; пошкодження ізоляції USB-кабелю	Пошкодження електричних з'єднань плати; порушення роботи модулів системи
ЕМГ-сенсор <i>DFRobot SEN0240</i>	Постійний струм 5 В (від <i>D10 Arduino</i>)	Неправильне підключення сенсора до мікроконтролера	Пошкодження аналогового вхідного ланцюга сенсора

Реальні та нормативні значення небезпечних факторів електричного характеру порівняно в таблиці 6.4.

Таблиця 6.4 – Реальні та нормативні фактори електричної небезпеки

Фактор небезпеки	Реальні значення	Нормативні значення
Напруга живлення ПК	220 В змінного струму	Безпечна напруга ≤ 50 В змінного струму (ДСТУ EN 61140:2015)

Продовження таблиці 6.4

Напруга живлення Arduino UNO та SEN0240	5 В постійного струму (SELV)	SELV ≤ 50 В постійного струму — безпечна (ДСТУ EN 61140:2015)
Пошкодження ізоляції кабелів	Відсутні (кабелі у справному стані)	Відсутні (ДСТУ EN 61140:2015)

Невідповідність напруги живлення ПК нормативному порогу безпечної напруги вимагає реалізації технічних, організаційних та експлуатаційних заходів з охорони праці — таблиця 6.5.

Таблиця 6.5 – Заходи із забезпечення охорони праці щодо електробезпеки

Група номенклатурних заходів з ОП	Критерій вибору	Вид заходу
Технічні засоби	Захист від ураження струмом при пошкодженні ізоляції 220 В Забезпечення живлення системи безпечною напругою <i>SELV</i>	Підключення ПК через трипровідну мережу з захисним провідником PE; опір заземлення ≤ 4 Ом <i>Arduino UNO</i> та <i>SEN0240</i> живляться напругою 5 В DC (<i>SELV</i>) через <i>USB</i> — унеможливлення ураження струмом при прямому контакті
Організаційні засоби	Навчання з питань електробезпеки	Інструктаж з електробезпеки перед початком роботи з системою
Режимні засоби	Контроль стану ізоляції	Регулярна перевірка цілісності ізоляції мережевого кабелю ПК та <i>USB</i> -кабелю; негайна заміна пошкоджених кабелів
Експлуатаційні засоби	Технічний огляд обладнання	Перевірка справності ПК та кабелів перед кожним сеансом роботи з системою

Описані в таблиці 6.5 заходи суттєво підвищують електричну безпечність системи при її використанні та забезпечують захист оператора від ураження електричним струмом.

6.2.2 Небезпека займання

Розгляд небезпеки займання обумовлений можливим тривалим перегріванням компонентів системи внаслідок перевищення допустимого струму або короткого замикання. Аналіз можливостей виникнення займання наведено в таблиці 6.6.

Таблиця 6.6 – Основні небезпеки, пов'язані з виникненням займання

Найменування компонента	Джерело небезпеки	Причини небезпеки	Наслідки небезпеки
Персональний комп'ютер (ПК)	Електричні іскри, тепловиділення блоку живлення	Порушення роботи блоку живлення; перевантаження мережі; перегрівання елементів БЖ	Займання ПК та виникнення пожежі
Мікроконтролер <i>Arduino UNO</i>	Тепловиділення мікросхеми <i>ATmega328P</i>	Перевищення максимального струму I/O-піна (>40 мА); коротке замикання внаслідок неправильного з'єднання	Перегрівання та пошкодження плати мікроконтролера; займання
ЕМГ-сенсор <i>DFRobot SEN0240</i>	Тепловиділення аналогового ланцюга	Перевищення допустимого струму живлення (>10 мА); порушення умов експлуатації	Пошкодження сенсора; займання ізоляції з'єднувальних проводів

Реальні та нормативні значення небезпечних факторів, що спричиняють займання, порівняно в таблиці 6.7.

Таблиця 6.7 – Реальні та нормативні фактори пожежної небезпеки

Фактор небезпеки	Реальні значення	Нормативні значення
Електричні іскри та дугові розряди	Наявні (при порушенні ізоляції або КЗ)	Відсутні
Струм короткого замикання <i>Arduino UNO</i>	Наявний (при неправильному з'єднанні)	Відсутній (технічна документація <i>ATmega328P</i>)

Продовження таблиці 6.7

Перегрівання компонентів системи	Відсутнє (при дотриманні умов експлуатації)	Відсутнє (<i>Arduino UNO</i> : 0–70°C; <i>SEN0240</i> : 0–50°C)
----------------------------------	---	--

Невідповідність реальних значень нормативним при порушенні умов експлуатації вимагає реалізації заходів з охорони праці — таблиця 6.8.

Таблиця 6.8 – Заходи із забезпечення охорони праці щодо пожежної безпеки

Група номенклатурних заходів з ОП	Критерій вибору	Вид заходу
Технічні засоби	Захист від перегрівання та КЗ компонентів Вибір перерізу з'єднувальних проводів	Живлення <i>SEN0240</i> через цифровий вивід <i>D10</i> з максимальним струмом 40 мА (запас 4:1 до 10 мА сенсора) — унеможливлення перегріву Вибір перерізу проводів відповідно до допустимої щільності струму
Організаційні засоби	Навчання з питань пожежної безпеки	Інструктаж з пожежної безпеки; ознайомлення з розташуванням засобів пожежогашіння
Режимні засоби	Контроль температурного режиму	Не залишати систему під напругою без нагляду; забезпечити вільну циркуляцію повітря навколо ПК
Експлуатаційні засоби	Технічний огляд обладнання	Перевірка відсутності механічних пошкоджень з'єднань та ознак перегрівання перед кожним сеансом роботи

Описані в таблиці 6.8 заходи суттєво мінімізують ймовірність займання компонентів системи при її використанні. Компоненти *Arduino UNO* та *SEN0240* відносяться до класу горючості Д.

6.3 Розробка інструкції з техніки безпеки при експлуатації біотехнічної системи реєстрації та класифікації ЕМГ-сигналів

1. Загальні положення, що стосуються прав і обов'язків обслуговуючого персоналу щодо дотримання вимог техніки безпеки:

- налаштування програмного забезпечення нейронної мережі, калібрування системи та усунення несправностей апаратної частини може здійснюватися лише розробником системи або кваліфікованим біомедичним інженером;

- тестування системи та збір ЕМГ-даних може проводитися лише після інструктажу з експлуатації системи та навчання з питань електробезпеки і пожежної безпеки.

2. Технологічні вимоги щодо дотримання заходів безпеки перед початком роботи, під час роботи і після закінчення роботи та в умовах надзвичайних ситуацій:

- перед початком роботи перевірити зовнішній вигляд системи: цілісність ізоляції кабелю живлення ПК та USB-кабелю *Arduino*, відсутність механічних пошкоджень плат *Arduino UNO* та *SEN0240*;

- якщо індикатор живлення (*LED ON*) мікроконтролера *Arduino UNO* не світиться після підключення USB — перевірити з'єднання кабелю та USB-порт ПК;

- розміщення електродів сенсора *SEN0240* на передпліччі (м'яз *FDS*) та налаштування режиму роботи програмного забезпечення має відбуватися відповідно до інструкції з експлуатації системи;

- у разі виявлення порушень роботи системи (відсутність ЕМГ-сигналу, помилкова класифікація жестів при справних електродах, спрацьовування захисту USB-порту ПК) необхідно припинити сеанс збору даних та звернутися за технічним обслуговуванням;

- після закінчення роботи від'єднати *Arduino UNO* від USB, зняти електроди та вимкнути ПК.

3. Особливості обслуговування системи, безпечні режими роботи:

- під час транспортування компоненти системи мають бути розміщені в захисній упаковці, що запобігає механічним пошкодженням плат та з'єднувальних елементів;
- технічне обслуговування системи має проводитися у разі порушення її функціонування або після тривалого зберігання;
- під час обслуговування та подальшого застосування системи мають бути дотримані всі правила безпеки, зазначені у цьому розділі.

Отже, у даному розділі було розглянуто потенційно небезпечні фактори, що створюються розробленою конструкцією біотехнічної системи реєстрації та класифікації ЕМГ-сигналів, та шляхи їх усунення. Найбільш вагомими небезпеками є електронебезпека та небезпека займання. Відповідно до цього були розроблені технічні, організаційні, режимні та експлуатаційні заходи, що суттєво підвищують електричну та пожежну безпечність системи. Також результатом оцінки потенційних небезпек було розроблено інструкцію з техніки безпеки при експлуатації даної системи.

Висновок до розділу 6

У шостому розділі виконано аналіз потенційно небезпечних факторів розробленої біотехнічної системи відповідно до вимог ДСТУ EN 61140:2015 та ДСТУ EN 60529:2018. Визначено два основні небезпечні фактори: небезпека ураження електричним струмом через живлення ПК від мережі 220 В та небезпека займання внаслідок можливого перегрівання компонентів. Для кожного фактора проведено порівняння реальних та нормативних значень і розроблено комплекс технічних, організаційних, режимних та експлуатаційних заходів, що суттєво підвищують електричну та пожежну безпечність системи. Розроблено інструкцію з техніки безпеки при експлуатації біотехнічної системи реєстрації та класифікації ЕМГ-сигналів.

ВИСНОВКИ

У дипломній роботі вирішено комплекс задач із розробки біотехнічної системи класифікації патернів ЕМГ-сигналів на основі штучних нейронних мереж.

1. Проведено огляд існуючих методів реєстрації поверхневої електроміографії, апаратних платформ та нейромережових підходів до класифікації жестів руки. Встановлено, що одноканальні системи з персоналізованим донавчанням забезпечують прийнятну точність при мінімальних апаратних вимогах, а багатомасштабні *CNN* з механізмами уваги є ефективним підходом для обробки часових рядів ЕМГ.

2. Розроблено та навчено багатомасштабну *1D CNN* зі *SE*-увагою. Архітектура поєднує чотири паралельні гілки *Conv1D* з ядрами 7–63 відліки та блок *Squeeze-and-Excitation* для адаптивного підсилення інформативних карт ознак. При навчанні на датасеті *FORS-EMG* (19 суб'єктів, 8 класів) досягнуто тестову точність 64,1 % у суб'єкт-незалежному режимі (*macro F1* = 0,636).

3. Зібрано апаратний прототип на базі мікроконтролера *Arduino UNO* (*ATmega328P*, 10-біт АЦП, 1000 Гц) та одноканального ЕМГ-сенсора *DFRobot Gravity SEN0240*, розміщеного на м'язі *FDS* правого передпліччя. Верифіковано якість сигналу: рівень шуму у стані спокою — менше 5 % від амплітуди при *MVC*, відсутність насичення АЦП.

4. Реалізовано алгоритм персоналізованого донавчання: заморожуються згорткові шари базової моделі, донавчаються лише *Dense*-шари (~200 параметрів) на 1380 вікнах персональних даних трьох класів жестів. Верифікація в режимі реального часу підтвердила стабільне розрізнення класів *Hand_Close*, *Wrist_Flexion* та *Rest* із точністю *val_accuracy* = 97,5 % (*macro F1* = 0,97) та затримкою реакції 300–600 мс.

5. Розроблено механізм моніторингу впевненості моделі: система відстежує середню впевненість у ковзному вікні $N = 20$ предиктів (~6 с) і при падінні нижче порогу $\theta = 0,70$ виводить сигнал попередження з пропозицією

повторного recalібрування. Механізм дозволяє підтримувати точність класифікації на рівні ~95 % протягом тривалих робочих сесій без постійного перенавчання, а процедура recalібрування займає менше 2 хвилин.

6. Проаналізовано обмеження реалізованого прототипу: одноканальна реєстрація обмежує словник жестів, 10-бітний АЦП знижує точність при слабкій активації (~10–20 % MVC), *cross-subject* точність базової моделі (66,5 %) недостатня для безпосереднього використання без персоналізації. Визначено пріоритетні напрями вдосконалення: розширення до 2–4 каналів реєстрації (очікуваний приріст *cross-subject* точності +8–12 %), мультисесійний збір персональних даних, перехід на 12-бітний АЦП (*STM32F4* або *ESP32*) та впровадження *Transformer*-архітектури або *contrastive pre-training*.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ

1. Miceli L. Editorial: EMG signal acquisition, processing, and analysis — Bridging the gap between research and daily practice. *Sensors*. 2026. Vol. 26, № 8. Art. 2344. DOI: 10.3390/s26082344.
2. Heckman C. J., Enoka R. M. Physiology of the motor neuron and the motor unit. *Handbook of clinical neurophysiology* / ed. A. Eisen. Elsevier, 2004. Vol. 4. P. 119–147.
3. Basic electromyography: Analysis of motor unit action potentials. *Electromyography and neuromuscular disorders*. Clinical Publishing, 2024. URL: <https://clinicalpub.com/basic-electromyography-analysis-of-motor-unit-action-potentials/>.
4. Jimenez A., Marappa-Ganeshan R. Anatomy, shoulder and upper limb, forearm muscles. StatPearls. StatPearls Publishing, 2023. URL: <https://www.ncbi.nlm.nih.gov/books/NBK536975/>.
5. Sharrak S., Das J. M. Anatomy, shoulder and upper limb, forearm compartments. StatPearls. StatPearls Publishing, 2023. URL: <https://www.ncbi.nlm.nih.gov/books/NBK539784/>.
6. Pelaez Murciego L., Henrich M. C., Spaich E. G., Dosen S. Reducing the number of EMG electrodes during online hand gesture classification with changing wrist positions. *Journal of NeuroEngineering and Rehabilitation*. 2022. Vol. 19. Art. 78. DOI: 10.1186/s12984-022-01056-w.
7. Chandran A. C., Stuttaford S. Optimizing EMG pattern recognition for prosthetic hand control: A comparative analysis of windowing, filtering, features, and classifiers using the Ninapro dataset [Preprint]. Sciety, 2026. DOI: 10.31224/6577.
8. Evaluation of 3D-printed dry electrodes for surface electromyography in dynamic muscle assessment. *Micromachines*. 2026. Vol. 17, № 5. Art. 504. DOI: 10.3390/mi17050504.

9. Realization of a device for the evaluation of the muscular effort through the electromyogram signal EMG. *Journal of Clinical Research and Reports*. 2021. URL: <https://auctoresonline.org/article/realization-of-a-device-for-the-evaluation-of-the-muscular-effort-through-the-electromyogram-signal-emg>.
10. Fu J., Cao S., Cai L., Yang L. Finger gesture recognition using sensing and classification of surface electromyography signals with high-precision wireless surface electromyography sensors. *Frontiers in Computational Neuroscience*. 2021. Vol. 15. Art. 770692. DOI: 10.3389/fncom.2021.770692.
11. Open source multi-channel EEG/ECG/EMG system development [Электронный ресурс]. *Duino4Projects*, 2024. URL: <https://duino4projects.com/open-source-multi-channel-eegecgemg/>.
12. Aghchehli E., Jabbari M., Ma C., Dyson M., Nazarpour K. Medium density EMG armband for gesture recognition. *Frontiers in Neurorobotics*. 2025. Vol. 19. Art. 1531815. DOI: 10.3389/fnbot.2025.1531815.
13. Tacca N., Dunlap C., Donegan S. P., Hardin J. O., Meyers E., Darrow M. J., Colachis S. IV, Gillman A., Friedenber D. A. Wearable high-density EMG sleeve for complex hand gesture classification and continuous joint angle estimation. *Scientific Reports*. 2024. Vol. 14. Art. 18564. DOI: 10.1038/s41598-024-64458-x.
14. Zhang R., Hong Y., Zhang H., Dong H., Dang L. A wearable electromyography armband for gesture recognition. *Biomedical Signal Processing and Control*. 2026. Vol. 112. Art. 108378. DOI: 10.1016/j.bspc.2025.108378.
15. Sul J.-H., Piyathilaka L., Moratuwage D., Arachchige S. D., Jayawardena A., Kahandawa G., Preethichandra D. M. G. Electromyography signal acquisition, filtering, and data analysis for exoskeleton development. *Sensors*. 2025. Vol. 25, № 13. Art. 4004. DOI: 10.3390/s25134004.
16. Sid'El Moctar S. M., Rida I., Boudaoud S. Comprehensive review of feature extraction techniques for sEMG signal classification: From handcrafted features to deep learning approaches. *IRBM*. 2024. Vol. 45, № 6. Art. 100866. URL: <https://www.sciencedirect.com/science/article/abs/pii/S1959031824000472>.

17. Conley W. L., Livingstone S. R. EMGFlow: A Python package for preprocessing and feature extraction of electromyographic signals. *Journal of Open Source Software*. 2026. Vol. 11, № 119. Art. 7696. DOI: 10.21105/joss.07696.
18. Kadavath Mujeeb Rahman K., Nasor M., Imran A. Enhanced hand gesture recognition with surface electromyogram and machine learning. *Sensors*. 2024. Vol. 24, № 16. Art. 5231. DOI: 10.3390/s24165231.
19. Gómez-Verde D., Esteban-Romero S., Gil-Martín M., San-Segundo R. Deep convolutional neural network for forearm EMG-based gesture classification : технічний звіт. Universidad Politécnica de Madrid, 2024. URL: <https://oa.upm.es/85592/1/10307219.pdf>.
20. Aarotale P. N., Rattani A. Machine learning-based sEMG signal classification for hand gesture recognition [Preprint]. arXiv, 2024. URL: <https://arxiv.org/abs/2411.15655>.
21. Rezaee K., Khavari S. F., Ansari M., Zare F., Roknabadi M. H. A. Hand gestures classification of sEMG signals based on BiLSTM-metaheuristic optimization and hybrid U-Net-MobileNetV2 encoder architecture. *Scientific Reports*. 2024. Vol. 14. Art. 31257. URL: <https://www.nature.com/articles/s41598-024-82676-1>.
22. Abdelaziz M. H., Mohamed W. A., Selmy A. S. Hand gesture recognition based on EMG signals and deep learning. *Journal of Artificial Intelligence and Technology*. 2024. Vol. 15, № 2. Art. 255. URL: <https://www.jait.us/uploadfile/2024/JAIT-V15N2-255.pdf>.
23. Barona López L. I., Ferri F. M., Zea J., Valdivieso Caraguay Á. L., Benalcázar M. E. CNN-LSTM and post-processing for EMG-based hand gesture recognition. *Intelligent Systems with Applications*. 2024. Vol. 23. Art. 200352. DOI: 10.1016/j.iswa.2024.200352.
24. D'Accolti D., Dejanovic K., Cappello L., Mastinu E., Ortiz-Catalan M., Cipriani C. Decoding of multiple wrist and hand movements using a transient EMG classifier. *IEEE Robotics and Automation Letters*. 2023. Vol. 8, № 2. P. 1045–1052. URL: <https://ieeexplore.ieee.org/document/9937197/>.

25. Asogbon M. G., Samuel O. W., Nsugbe E., Li Y., Kulwa F., Mzurikwao D., Chen S., Li G. Ascertaining the optimal myoelectric signal recording duration for pattern recognition based prostheses control. *Frontiers in Neuroscience*. 2023. Vol. 17. Art. 1018037. DOI: 10.3389/fnins.2023.1018037.
26. Wilson P. D. *Anatomy of muscle*. Reference module in biomedical sciences. Elsevier, 2014. DOI: 10.1016/B978-0-12-801238-3.00250-6.
27. FORS-EMG: A Novel sEMG Dataset [Электронный ресурс]. Kaggle, 2024. URL: <https://www.kaggle.com/datasets/ummerummanchaity/fors-emg-a-novel-semg-dataset/data>.
28. DFRobot Gravity: EMG Sensor (SEN0240) [Электронный ресурс]. DFRobot, 2024. URL: <https://www.dfrobot.com/product-1661.html>.
29. Zhang W., Zhang J. EMG Gesture Recognition Algorithm Based on Parallel Multi-scale CNN. 2022 2nd International Conference on Frontiers of Electronics, Information and Computation Technologies (ICFEICT). IEEE, 2022. P. 562–568. DOI: 10.1109/ICFEICT57213.2022.00103.
30. Campbell E., Phinyomark A., Scheme E. Deep Cross-User Models Reduce the Training Burden in Myoelectric Control. *Frontiers in Neuroscience*. 2021. Vol. 15. Art. 657958. DOI: 10.3389/fnins.2021.657958.
31. Zheng N., Li Y., Zhang W., Du M. User-Independent EMG Gesture Recognition Method Based on Adaptive Learning. *Frontiers in Neuroscience*. 2022. Vol. 16. Art. 847180. DOI: 10.3389/fnins.2022.847180.
32. Xu Z., Yu J., Xiang W., Zhu S., Hussain M., Li X., Chen X. A Novel SE-CNN Attention Architecture for sEMG-Based Hand Gesture Recognition. *Computer Modeling in Engineering & Sciences*. 2023. Vol. 134, № 1. P. 157–177. DOI: 10.32604/cmes.2022.020035.
33. Ismail Fawaz H., Lucas B., Forestier G., Pelletier C., Schmidt D. F., Weber J., Webb G. I., Idoumghar L., Muller P.-A., Petitjean F. InceptionTime: Finding AlexNet for Time Series Classification. *Data Mining and Knowledge Discovery*. 2020. Vol. 34. P. 1936–1962. DOI: 10.1007/s10618-020-00710-y.

34. Tsinganos P., Cornelis B., Cornelis J., Jansen B., Skodras A. Data Augmentation of Surface Electromyography for Hand Gesture Recognition. *Sensors*. 2020. Vol. 20, № 17. Art. 4892. DOI: 10.3390/s20174892.
35. Krieger K., Lijnse T., Lowery M. M., O'Cearbhaill E. D. Microneedle electrodes for electromyography. *Biosensors and Bioelectronics*. 2025. Vol. 290. Art. 117945. DOI: 10.1016/j.bios.2025.117945.
36. Yamaguchi T., Kurashina Y., Nagahara E., Oshima S., Kaneko N., Nakazawa K., Tanaka H., Yokoyama H. Quantitative assessment of signal quality and usability of EEG and EMG recordings with PEDOT:PSS-coated microneedle electrodes. *Frontiers in Neuroscience*. 2025. Vol. 19. Art. 1706501. DOI: 10.3389/fnins.2025.1706501.
37. EMG-System [Електронний ресурс]: репозиторій проєкту / Б. Костенко. 2026. — Режим доступу : <https://github.com/ilrodank/EMG-System>.