



Кривуляк І. І. [1; ORCID ID: 0009-0009-3795-045X],

д.ф.-м.н.,

Маркович Б. М. [1; ORCID ID: 0000-0002-8813-9108],

к.т.н.,

Корендій В. М. [1; ORCID ID: 0000-0002-6025-3013],

к.т.н., доцент

¹Національний університет «Львівська Політехніка»

ОГЛЯД ТА СПОСОБИ ПОКРАЩЕННЯ ІСНУЮЧИХ МЕТОДІВ КЕРУВАННЯ ПРОТЕЗАМИ ЗАВДЯКИ ЗАСТОСУВАННЮ АДАПТИВНИХ СИСТЕМ КОНТРОЛЮ НА БАЗІ НЕЙРОННИХ МЕРЕЖ

У статті проведено аналіз сучасних методів керування біонічними протезами верхніх кінцівок на основі EMG-сигналів. Розглянуто недоліки традиційних статичних класифікаторів (SVM, k-NN, CNN), що не враховують часову змінність м'язової активності, мають обмежену персоналізацію та чутливі до втоми м'язів і зміщення електродів. Запропоновано архітектуру адаптивної системи з використанням рекурентних мереж LSTM, здатних зберігати контекст скорочень, прогнозувати рухи ще до повної активації м'язів та зменшувати потребу в повторному калібруванні. Система включає сенсорний блок збору сигналів, модуль фільтрації, AI-компоненту з LSTM-ядром і виконавчий блок для керування протезом. На базі Arduino UNO створено програмний прототип, який демонструє ідентифікацію рухів навіть за частковими сигналами та підтримує інкрементальне навчання. Архітектура є масштабованою та апаратно-незалежною, що дозволяє застосовувати її до різних типів протезів, забезпечуючи природність керування, високу точність і надійність.

Ключові слова: біонічний протез; електроміографія; EMG-сигнали; адаптивне керування; LSTM; нейронні мережі; глибинне навчання; персоналізація; інтелектуальна система; рекурентна мережа; безперервне навчання.

Вступ

Сучасна біомедична інженерія досить швидко розвивається у напрямі створення інтелектуальних протезів. Основною ідеєю таких протезів є можливість забезпечити високий рівень функціональності та зробити їх більш адаптивними до потреб користувача. Однією з найперспективніших технологій у цій сфері є використання електроміографічних (EMG) сигналів [1]. EMG – це електричні

потенціали, що виникають при скороченні м'язів і використовуються для інтерпретації намірів користувача та керування штучними кінцівками. Більшість існуючих систем базуються на фіксованих шаблонних алгоритмах чи статичних моделях класифікації. Це деколи частково, а деколи суттєво обмежує їхню здатність до адаптації та зменшує точність у різних непередбачуваних ситуаціях. Крім того це ускладнює використання таких протезів у реальних умовах.

Ключовою проблемою сьогодні є відсутність механізмів довготривалої пам'яті та контексту, необхідних для розпізнавання складних послідовностей рухів та змін у м'язовій активності з часом. Індивідуальні особливості м'язової активності різних користувачів вимагають персоналізованого підходу до побудови систем керування.

У цій статті запропоновано новий підхід до побудови адаптивної системи керування протезами, що поєднує зчитування EMG сигналів та архітектуру глибокого навчання [2] на основі рекурентних нейронних мереж [3–5] типу LSTM (Long Short-Term Memory). Такий підхід дозволяє розпізнавати поточний рух, враховувати історію попередніх активацій м'язів, адаптуватися до змін та шумів у сигналах під час рухів користувача. Також такі системи можуть забезпечувати природніше керування протезом.

Мета дослідження – це побудова прототипу системи, здатної до самонавчання в умовах обмеженої кількості початкових даних. Пропонована система буде зберігати точність класифікації в локальному середовищі та зможе масштабуватися під протези різної складності.

Огляд існуючих підходів та потреба в LSTM

Упродовж останніх десятиліть розробка протезів із можливістю керування за допомогою електроміографічних (EMG) сигналів залишається одним із ключових напрямків біомедичної інженерії. Традиційні системи часто базуються на двопозиційних або пропорційних схемах, де сила м'язової активації визначає інтенсивність руху протеза. Попри простоту реалізації, такі рішення обмежені у функціональності та погано масштабуються на складні жести або багатоступеневі рухи.

З метою підвищення точності було запропоновано численні алгоритми класифікації EMG-сигналів, зокрема методи опорних векторів (SVM), k-найближчих сусідів (k-NN), наївний баєсів



класифікатор тощо. Останнім часом поширення набули глибокі згорткові нейронні мережі (CNN) для витягування ознак з EMG-сигналів. Проте в більшості випадків ці моделі залишаються статичними (не враховують контекст, не зберігають історії рухів та не адаптуються до індивідуальних змін користувача).

EMG-сигнал – це різниця потенціалів між двома електродами, яка обчислюється за формулою:

$$V_{EMG}(t) = V_{+}(t) - V_{-}(t),$$

де $V_{+}(t), V_{-}(t)$ напруги на активному і референсному електродах у часі t

Після отримання аналогових даних з сенсорів вони оцифровуються через ADC (Analog-to-Digital Converter) за формулою:

$$ADC_{EMG} = \left(\frac{V_{EMG} - V_{min}}{V_{max} - V_{min}} \right) \times (2^n - 1),$$

де V_{min} та V_{max} – межі напруги ADC (наприклад 0 – 3.3 В) ;
 n – бітність ADC (наприклад, 10біт \rightarrow 1024 рівні).

Після цифрації даних з сенсорів шуми все ще залишаються, саме тому потрібно провести фільтрацію. Для цього застосовують смуговий фільтр (для частоти 20–450 Гц), а також Нотч-Фільтр (50/60 Гц) для видалення шуму мережі живлення.

EMG-сенсори передають сигнали на різних частотах, проте нам потрібні лише на проміжку [20, С. 450] Гц, оскільки все що менше 20 Гц – це шуми від зміщення електродів, а все що більше 450 Гц – це електронний шум. Смуговий фільтр пропускає лише ті частоти, які лежать між 20 і 450 Гц (основна корисна частота EMG):

$$H(f) = \begin{cases} 1, & 20 \leq f \leq 450 \\ 0, & f < 20 \text{ або } f > 450 \end{cases}$$

Крім того, існуючі системи зазвичай вимагають тривалого попереднього навчання на великому наборі даних і часто не демонструють стабільної роботи при зміні положення електродів, втомі м'язів або природних коливаннях сигналу.

Ці обмеження підкреслюють потребу у нових архітектурах, які можуть:

- зберігати короткочасну і довготривалу пам'ять для рухових патернів;

- адаптуватися до користувача у режимі реального часу;
- працювати зі змінними вхідними даними, зберігаючи стабільність роботи.

Одним з перспективних напрямків є використання рекурентних нейронних мереж (RNN) а саме їх модифікацій Long Short-Term Memory (LSTM), які мають здатність запам'ятовувати послідовності та виявляти залежності у часі.

У цьому контексті запропонований підхід заснований на використанні LSTM для створення адаптивного керування протезом, який зберігає контекст м'язових скорочень. Крім того системи на базі LSTM динамічно адаптуються до особливостей користувача та дозволяють досягти більш природного керування без повного перенавчання при кожній зміні умов.

Після фільтрації даних з сенсорів, система починає працювати з послідовностями на часовому проміжку T . Тобто, на даному етапі EMG-дані представлені у вигляді послідовностей x_1, x_2, \dots, x_n та точки для кожної послідовності $y_i \in \{0, 1\}$,

де $y_i = 1$ – означає, що у цій послідовності здійснено рух;

$y_i = 0$ – руху немає.

Основною ідеєю є навчити модель f_0 яка передбачає $\hat{y}_i = f_0(x_i)$.

Для цієї задачі використовується бінарна крос-ентропія:

$$L(\theta) = -\frac{1}{N} \sum_{i=1}^N [y_i \times \log(\hat{y}_i) + (1 - y_i) \times \log(1 - \hat{y}_i)],$$

де $L(\theta)$ – загальна функція втрат, яку ми мінімізуємо при навчанні;

θ – параметри моделі;

N – кількість прикладів у вибірці;

y_i – правильна мітка для i прикладу: $y_i = 1$ – рух є, $y_i = 0$ – руху немає;

\hat{y}_i – прогноз моделі: $[0; 1]$ – ймовірність руху;

$\log(\hat{y}_i)$ – логарифм ймовірності руху;

$\log(1 - \hat{y}_i)$ – логарифм ймовірності відсутності руху.

У дослідженні Padmini Sahu, Bikesh Kumar Singh та Neelamshobha Nirala «Optimized k-nearest neighbors for classification of prosthetic hand movements using EMG signals» [6] було запропоновано використовувати дискретне вейвлет-перетворення (DWT) для виділення ознак, а потім алгоритм ОКНН (optimized k-NN) для класифікації жестів протеза, досягаючи ~93% точності. Автори



обрали базу NinaPro DB3, що включає 17 рухів кисті, записаних від 11 ампутантів. Вони застосували дискретне вейвлет-перетворення (DWT) [7] для кожного EMG-сигналу з метою виділення часово-частотних ознак, потім виконали відбір цих ознак за допомогою алгоритму глобально орієнтованої мети Gaussian ABC (BGG ABC) [8]. Цей підхід показує високу точність, проте він досить складний, адже кожен крок містить різні параметри, які потребують тонкого налаштування. Використання LSTM в такому випадку автоматизує навчання ознак end-to-end, що усуває потребу в ручних алгоритмах DWT та BGGABC. Це суттєво знижує ризик втрати важливої інформації. Також, запровадження LSTM дозволить спростити архітектуру системи та зробити її більш ефективною, адже LSTM – самодостатній інструмент для класифікації рухів.

Наступним розглянемо підхід «Real-time Bionic Arm Control Via CNN-based EMG Recognition», що було запропоновано в межах проєкту MIC-Laboratory [9]. Основною ідеєю тут є збір даних через 8-канальний sEMG, які передаються через ESP32 на систему, де використовується CNN для класифікації жестів. Модель досягає ~91% точності, працює на Sony Spresense через TensorFlow Lite і керує сервоприводами з реальним відгуком. Також автори відзначають обмеження: складність з EDGE deployment, фіксована тривалість вікон, latency через Bluetooth тунель. LSTM-підхід в цьому прикладі буде кращий, адже CNN обробляє лише фіксовані вікна, що обмежує адаптацію до рухів різної довжини, в той час, коли LSTM працює з довільно довгими послідовностями, без необхідності жорстких меж часового вікна. Також CNN аналізує інформацію локально, коли використання LSTM забезпечить систему внутрішньою пам'яттю, що дозволяє враховувати попередні миттєвості, уникаючи шумових «стрибків» і зміцнюючи сигнал класифікації.

Також, варто розглянути роботу Bahareh Ahkami, Kirstin Ahmed, Alexander Thesleff, Levi Hargrove, Max Ortiz-Catalan: «Electromyography-Based Control of Lower Limb Prostheses: A Systematic Review» [10]. У ній проводиться огляд більше сотні досліджень присвячених управлінню нижніми кінцівками через EMG-сигнали. Хоч основним об'єктом цього дослідження є покращення систем керування протезами верхніх кінцівок, проте у роботі «Electromyography-Based Control of Lower Limb Prostheses: A Systematic Review» наголошується на проблемах, які можуть

виникнути у будь-якій системі керування протезами різних типів. Автори вказують на такі проблеми, як-от:

- висока залежність результатів від стабільності EMG, ретельного налаштування розташування електродів;
- велика варіативність між користувачами та сесіями;
- необхідність частого калібрування та перенавчання при зміні користувача або умови;
- обмежена кількість досліджень реального часу, незрозумілі часові затримки, відсутність стандартних метрик оцінки.

Впровадження LSTM в системи керування протезів має за мету вирішити більшість таких проблем. LSTM-мережі здатні вчитися з урахуванням індивідуальних особливостей сигналів, знижуючи залежність від pre-train сесій чи рефітінгу, що дозволяє адаптуватись системі під окремого користувача без додаткового калібрування. Також, LSTM-алгоритми менш чутливі до зміщень сигналів, руху електродів або змін тиску в гвинтових колекторах, адже вони аналізують часові паттерни, а не лише миттєві значення.

У роботі Bahareh Ahkami, Kirstin Ahmed, Alexander Thesleff, Levi Hargrove та Max Ortiz-Catalan найбільший акцент зроблено на тому, що більшість досліджень застосовують прості машинні класифікатори (SVM, ANN) з додаванням додаткових сенсорів. На відміну від сумішей SVM/ANN + зовнішніх сенсорів, LSTM – це інтегрована, end-to-end система, що приймає EMG, аналізує інтенцію руху та генерує управління. Це відкидає потребу у додаткових сенсорах та зменшує час реакції на рух.

Ще однією статтею, яку варто розглянути, є «Support Vector Machine-Based EMG Signal Classification Techniques» [11] від авторів Diana C. Toledo-Pérez, Juvenal Rodríguez-Reséndiz, Roberto A. Gómez-Loenzo та J. C. Jauregui-Correa. У цій статті автори аналізують низку робіт, де використовується SVM з різними ядрами і ознаками (RMS, MAV, часова або часово-частотна інформація), розглядають архітектури фільтрації, частоти дискретизації та кількість каналів. Також розглядаються наступні обмеження такого підходу:

- SVM – це дискретна класифікація, що не генерує сигнали управління, а лише обирає категорію руху.
- Відсутність підтримки безперервної регресії або контролю інтенсивності руху.
- Потреба в ручному доборі набору фіч, препроцесінгу, оптимізації ядра та параметрів.



У LSTM-мережах, замість дискретної класифікації жестів, відбувається генерування континуальних сигналів керування, які передають інформацію про положення, швидкість або силу без додаткових модулів. Робота зі статичними ознаками на фреймах не враховує розвиток жесту у часі. LSTM запам'ятовує попередні стани і генерує плавніший, послідовний контроль, навіть у разі коротких імпульсних змін. Також, у LSTM використовується мінімальний препроцесінг та її набагато простіше розгорнути, адже не потрібно використовувати багаторівневі фільтри сигнала чи тонке налаштування. LSTM оптимізує ці етапи самостійно, що суттєво скорочує час розробки і складність моделі.

Пропонована система адаптивного керування протезом

У цій роботі запропоновано нову архітектуру адаптивного керування протезами верхніх кінцівок, яка поєднує зчитування електроміографічних сигналів (EMG) з можливостями глибинного навчання [12–13]. Основною ідеєю є використання рекурентної нейронної мережі типу Long Short-Term Memory (LSTM) як ядра обробки, що дозволяє аналізувати послідовності EMG-сигналів у часі та виявляти характерні патерни, пов'язані з руховими намірами користувача.

Запропонована система складається з чотирьох ключових модулів (рис. 1):

- Сенсорний блок, що включає EMG-датчики, прикріплені до залишкової частини кінцівки. Вони зчитують м'язову активність у реальному часі.
- Передобробка сигналу – це модуль фільтрації, нормалізації та сегментації EMG-даних. Він фільтрує сигнал для подальшого введення у модель.
- AI-модуль (LSTM-мережа), яка:
 - запам'ятовує послідовність м'язових активацій;
 - вчиться асоціювати їх із конкретними командами;
 - поступово адаптується до індивідуального стилю користувача.
- Блок керування протезом – модуль, що приймає рішення від LSTM-мережі та «прокидає» його в модуль керування, для подальшого сигналу на механічну кінцівку.

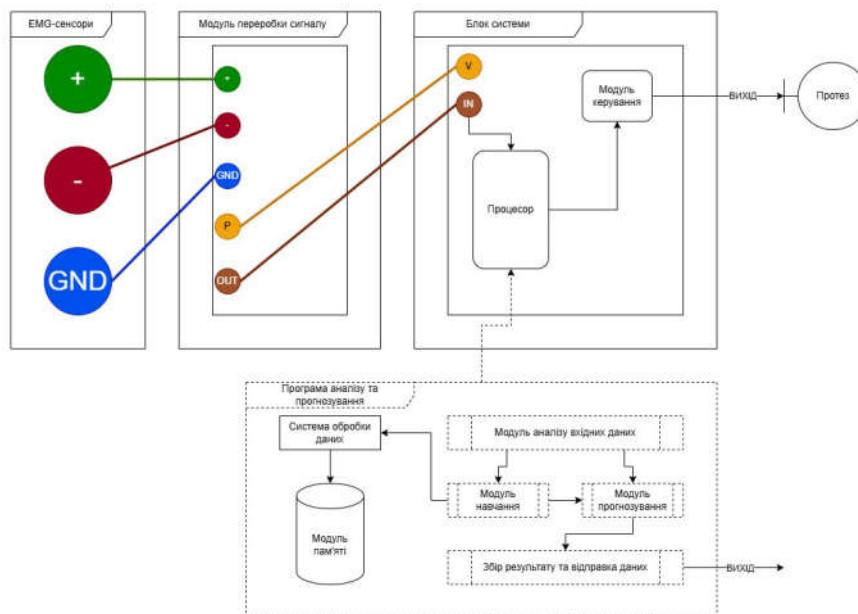


Рис. 1. Структура запропонованої системи

Одним із основних викликів при побудові системи керування протезами є необхідність персоналізації: EMG-сигнали значно варіюються між користувачами навіть при однакових рухах. Це унеможлиблює створення універсальної моделі, яка була б однаково ефективною для всіх. У запропонованому підході ця проблема вирішується через впровадження адаптивного навчання, що відбувається у кілька етапів.

Першим етапом є початкове навчання (рис. 2). Після підключення системи користувач виконує серію простих рухів, кожен з яких реєструється як EMG-послідовність. Ці патерни зберігаються та формують базовий набір для початкового навчання LSTM-моделі. На цьому етапі використовується невелика кількість даних, а тренування відбувається швидко, можливо навіть прямо на пристрої або на сервері з подальшим завантаженням моделі.

Наступним кроком є інкрементальне оновлення, яке забезпечує, що після базового навчання система не заморожується, а продовжує зчитувати сигнали та уточнювати модель у процесі використання. Зібрані нові дані автоматично додаються до тренувального набору. Крім того, вони можуть бути підтвержені чи відхилені користувачем та використовуються для періодичного перенавчання моделі без втрати попередніх знань [14].



Рис. 2. Модуль базового навчання

Далі відбувається адаптації до змін. Оскільки EMG-сигнали чутливі до змін, таких як зсув електродів, втома м'язів, зміна температури тощо, система регулярно оновлює внутрішні параметри моделі, щоб підтримувати точність. Це забезпечується завдяки використанню різних «патчів» з новими даними, що використовуються для донавчання моделі або мета-навчання для швидкої адаптації до нових умов з мінімумом прикладів.

Пропонована система також має опцію безперервного покращення. Вона має властивість навчитись один раз, а далі постійно адаптуватись. Крім того модель враховує історію сигналів та оновлюється на фоні і зберігає індивідуальні рухові особливості кожного користувача. Цей підхід дозволяє перейти від фіксованої класифікації до адаптивної системи керування, яка з часом покращує свою точність і зручність для конкретної людини.

Масштабованість та універсальність системи

Однією з головних переваг запропонованої системи є його незалежність від конкретної апаратної конфігурації протеза та забезпечення гнучкості складності завдань керування. Це забезпечує не лише високу адаптивність але й можливість широкого застосування в межах однієї технологічної платформи для різних типів протезів.

Система може бути інтегрована як у прості протези з однією або двома ступенями свободи (наприклад, лише стискання/розтиснення

кисті), так і в складні багатофункціональні пристрої, що підтримують індивідуальний контроль кожного пальця чи зап'ястя. Такі результати досягаються завдяки модульній структурі керуючих сигналів та можливості масштабування LSTM-моделі під більшу кількість класів. Крім того система забезпечуватиме збереження єдиного формату обробки EMG-даних.

AI-модуль видає абстрактні команди керування, які можна транслювати у будь-який інтерфейс керування протезом (PWM-сигнали, UART, CAN-шину, Bluetooth-пакети тощо). Завдяки цьому система не залежить від конкретного виробника протеза та може використовуватись повторно при заміні або модернізації механічної частини. Також забезпечується сумісність з новими поколіннями пристроїв без зміни ядра системи.

Крім різних типів протезів, система дозволяє легко адаптуватись до різної кількості доступних сенсорів (від 2 до 8+ каналів EMG), різного положення електродів на тілі та різного фізіологічного стану користувача (втома або зміна м'язового тону). Це забезпечує гнучкість під індивідуальні обмеження та дозволяє використовувати систему не лише в лабораторних умовах, а й у реальному середовищі.

Кожен користувач може мати власну персоналізовану модель (або спільну для протезів одного типу) та перенавчати її без втрати попереднього досвіду. Таким чином, створюється стійка екосистема адаптивного протезування, де користувач не залежить від єдиного апарату чи налаштування, а має переносну інтелектуальну систему контролю, що «знає» та «прогнозує» його рухи. Порівняння системи з традиційними підходами наведено у таблиці.

Таблиця

Критерій	Класичні системи	Запропонований підхід
Навчання	Попереднє, офлайн	Інкрементальне, адаптивне
Гнучкість до змін	Низька	Висока
Врахування контексту	Відсутнє	Через LSTM-пам'ять
Масштабування	Обмежене	Вільне
Персоналізація	Складна або відсутня	Вбудована

Порівняння системи з традиційними підходами

Огляд прототипу зі застосуванням примітивного модуля навчання

Пропонований прототип складається з сенсорів для зчитування показників при рухах, модуля цифрування даних з датчиків та



комп'ютера на базі Arduino UNO з прошивкою для обробки даних. Для коректного зчитування показників під час руху, сенсори клеються в точки найбільш виявлених м'язових скорочень (рис. 3):

- S+ в зону найкращого м'язового імпульсу при потрібному русі;
- S- дещо вище сенсора S+ для покращення сигналу;
- GND в зону слабого виявлення м'язових імпульсів під час руху.

руху.




Рис. 3. Розміщення сенсорів для зчитування даних під час руху кисті

Першим етапом є збір даних при русі (в цьому випадку стискання / розтискання кисті) та у стані спокою, для порівняння даних та можливості виявлення послідовностей. Оскільки результатом роботи модуля конвертації даних з сенсорів є нескінченний потік даних – кількість результатів є досить великою

для прямого навчання на пристрої Arduino UNO, тому для навчання і створення моделі використовується настільний ПК. Усі дані в даному прототипі записуються у CSV-файли для подальшої їх обробки системою.

Коли дані зібрані (30 с – 1 хв руху кисті з інтервалами між рухами ~ 1–2 с та у стані спокою), починається базове навчання моделі. Програмний код містить алгоритм, що обробляє збережені дані та визначає послідовності. Це можливо завдяки зберіганню сили імпульсу та часової шкали. Система перебирає велику кількість даних, знаходить послідовності серед всього «шуму» та «запам'ятовує» результати.

Після створення моделі та попереднього навчання, система отримує можливість не лише реагувати на завершену послідовність імпульсів, а й прогнозувати рух на основі початкових сигналів (рис. 4). Завдяки застосуванню LSTM-моделі, система здатна розпізнавати початок характерного шаблону ще до його завершення. Наприклад, електроміографічні послідовності для згину всієї кисті та для рухів окремих пальців мають різні початкові характеристики. У разі виявлення шаблону, що відповідає згину всієї кисті, система може негайно ініціювати рух, не очікуючи повної активації, та водночас у реальному часі коригувати траєкторію на основі подальших імпульсів. Такий підхід істотно зменшує затримку, підвищує швидкість реакції пристрою та створює передумови для рефлекторного, інтуїтивного керування протезом.

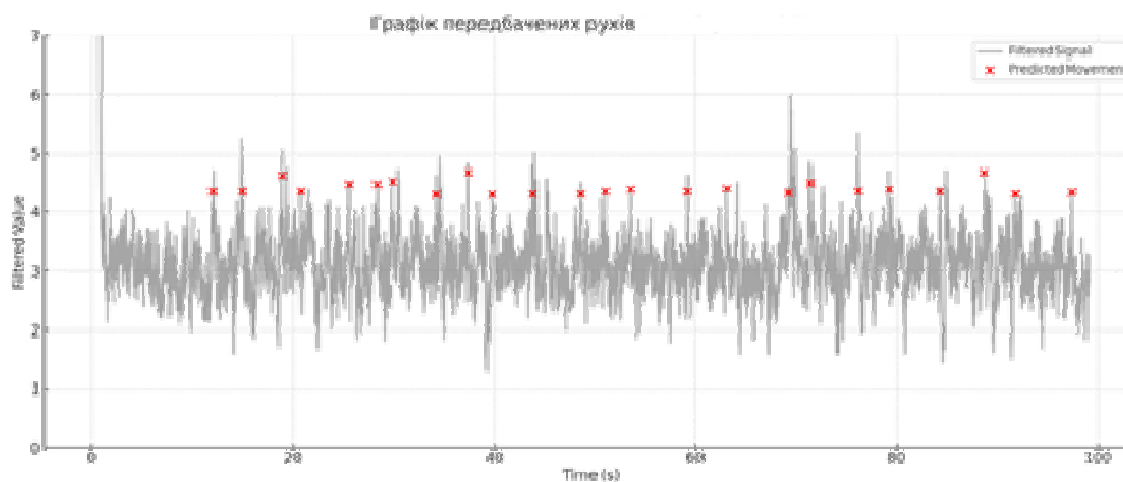


Рис. 4. Графік передбачених рухів на після аналізу даних з сенсорів системою



Для прикладу, розглянемо графік на часовому інтервалі [35; 40] с, силу імпульсів в цьому діапазоні та послідовності (рис. 5).

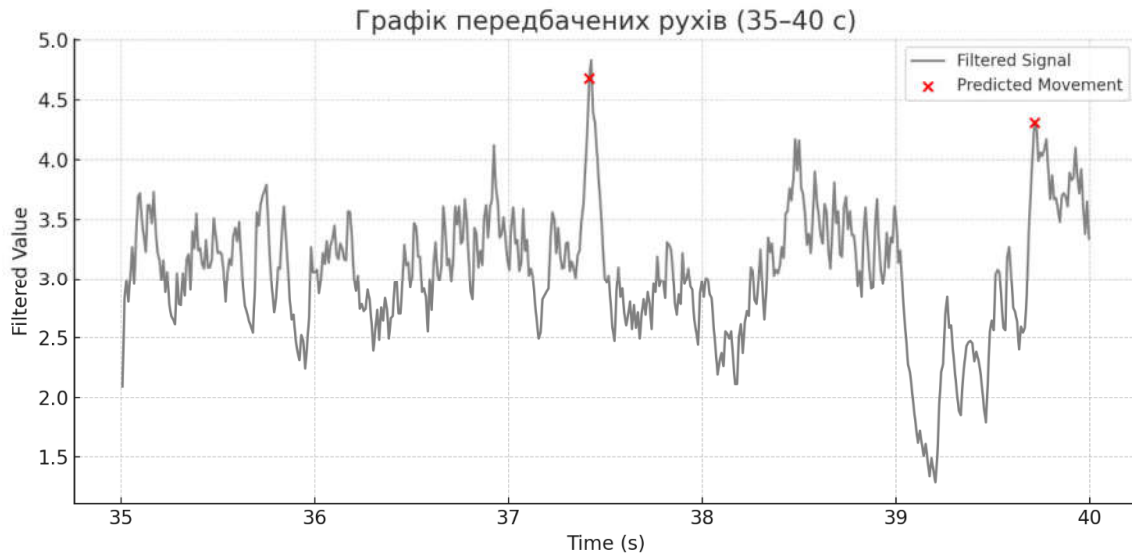


Рис. 5. Графік передбачених рухів на інтервалі [35; 40] с

На графіку на рисунку 5 можна побачити 2 плавні послідовності, які були отримані при згині та розгині кисті відповідно. Система проаналізувала вхідні дані (рис. 6) та «передбачила» рух ще до його повного завершення. Оскільки модель ще не є досконало навчена, то вона виявила рух лише під кінець завершення згину та розгину кисті, однак це дозволяє зрозуміти, що система проводить аналіз даних та може бути навчена розпізнавати різні види рухів завдяки обробці послідовностей.

Час (t)	Сила імпульсу	Прогнозування руху
37.346	3,01	
37.356	3,2	
37.366	3,24	
37.376	3,49	
37.386	3,62	
37.396	3,93	
37.406	4,23	
37.416	4,68	Рух прогнозовано
37.426	4,83	
37.436	4,39	
37.446	4,31	
37.456	4,06	
37.466	3,81	
37.476	3,59	
37.486	3,29	
37.496	3,01	
37.506	2,96	

Час (t)	Сила імпульсу	Прогнозування руху
39.655	2,54	
39.665	2,58	
39.675	2,86	
39.685	3,39	
39.695	3,72	
39.705	4,05	
39.715	4,31	Рух прогнозовано
39.725	4,28	
39.735	3,99	

Рис. 6. Числові дані послідовностей, під час яких було виконано рухи

Висновки

У цій роботі проведено системний аналіз недоліків традиційних підходів до керування біонічними протезами на основі електроміографічних (EMG) сигналів. Основна увага приділена проблемам відсутності адаптивності та складнощам із персоналізацією. Також розглянуто нестабільності в умовах зміни сигналів. Після аналізу та огляду різних наукових робіт було виявлено, що більшість існуючих систем потребують складного ручного налаштування, тривалого перенавчання та є надто чутливими до фізіологічних змін і впливу зовнішніх факторів.

Саме тому було запропоновано нову архітектуру системи керування, що базується на використанні рекурентної нейронної мережі типу LSTM, яка забезпечує збереження часових залежностей у EMG-сигналах. Система забезпечуватиме кращу адаптацію до змін у м'язовій активності користувача в реальному часі та зможе підтримувати безперервне інкрементальне навчання без втрати попередніх знань. Також, основним завданням такої системи є прогнозування руху ще до завершення повного його завершення та кращий аналіз шумів і відкидання непотрібних даних, які можуть сповільнювати роботу системи.

Прототип системи працює на основі Arduino UNO та простих EMG-сенсорах. Результатом використання такого прототипу є підтвердження, що система здатна ефективно зчитувати дані та використовувати їх для навчання моделі після попередньої фільтрації. Навіть при обмежених обчислювальних ресурсах прототип показав здатність виявляти рухи і здійснювати прогнозування після аналізу послідовностей на часовій шкалі.

Основною перевагою запропонованої системи є масштабованість та апаратна незалежність системи. Така модель здатна інтегруватися в різні протези з різною складністю та кількістю ступенів свободи. Запропонований підхід дозволяє створити персоналізовані інтелектуальні протези, які будуть постійно покращувати точність і зручність керування. Крім того протези, що використовуватимуть LSTM-систему зможуть краще реагувати на зміни м'язового стану та не будуть вимагати періодичного ручного калібрування.

Таким чином, розроблена система створює основу для нового покоління біонічних протезів, які будуть мати високий рівень адаптивності та зможуть використовуватись за різних умов. Вони



будуть забезпечувати хороший рівень автономності та зручності для користувачів.

1. Merletti R., & Parker P. A. *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Wiley-IEEE Press, 2004. P. 2–10. 2. Goodfellow I., Bengio Y., & Courville A. *Deep Learning*. MIT Press, 2016. P. 3–22. 3. Graves A. Supervised Sequence Labelling with Recurrent Neural Networks. Springer, 2012. P. 31–76. 4. Bishop C. M. *Pattern Recognition and Machine Learning*. Springer, 2006. 5. Sutton R. S., & Barto A. G. *Reinforcement Learning: An Introduction*. 2nd ed. MIT Press, 2018. 6. Sahu P., Singh B. K., Nirala N. S. Optimized k-nearest neighbors for classification of prosthetic hand movements using EMG signals. *Engineering Applications of Artificial Intelligence*. 2024. Vol. 133. Article 108390. 7. Sattu K., Jain R., Negi A. Feature Extraction of Surface Electromyography Using Wavelet. *Journal of Healthcare Engineering*. 2020. Article 8824194. 8. Zhu G., Kwong S. Gbest-guided Artificial Bee Colony algorithm for numerical function optimization. *Applied Mathematics and Computation*. 2010. Vol. 217. P. 3166–3173. 9. MIC Laboratory. Real-time Bionic Arm Control Via CNN-based EMG Recognition (онлайн-проект). Hackster.io. опубл. 30 серпня 2022. 10. Ahkami B., Ahmed K., Thesleff A., Hargrove L., Ortiz-Catalan M. Electromyography-based control of lower limb prostheses: a systematic review. *IEEE Transactions on Medical Robotics and Bionics*. 2023. Vol. 5, No. 4. P. 547–562. 11. Toledo-Pérez D. C., Rodríguez-Reséndiz J., Gómez-Loenzo R. A., Jauregui-Correa J. C. Support Vector Machine-based EMG signal classification techniques: a review. *Applied Sciences (Switzerland)*. 2019. Vol. 9, No. 20. Article 4402. 12. De Luca C. J. *Surface Electromyography: Detection and Recording*. Boston : Delsys Inc., 2002. 10 p. 13. Zhou P., Rymer W. Z. *Biomedical Signal Processing for EMG-Based Control of Prostheses*. Boca Raton : CRC Press, 2018. 338 p. 14. Parisi G. I., Kemker R., Part J. L., Kanan C., Wermter S. Continual lifelong learning with neural networks: a review. *Neural Networks*. 2019. Vol. 113. P. 54–71. 15. Liu W. Using Arduino Uno and EMG electrodes for electromyographic signal measurement and servo control. *Theoretical and Natural Science*. 2025. Vol. 86, No. 1. P. 37–44.

REFERENCES:

1. Merletti R., & Parker P. A. *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Wiley-IEEE Press, 2004. P. 2–10. 2. Goodfellow I., Bengio Y., & Courville A. *Deep Learning*. MIT Press, 2016. P. 3–22. 3. Graves A. Supervised Sequence Labelling with Recurrent Neural Networks. Springer, 2012. P. 31–76. 4. Bishop C. M. *Pattern Recognition and Machine Learning*. Springer, 2006. 5. Sutton R. S., & Barto A. G. *Reinforcement Learning: An Introduction*. 2nd ed. MIT Press, 2018. 6. Sahu P., Singh B. K., Nirala N. S. Optimized k-nearest neighbors for classification of prosthetic hand movements using EMG signals. *Engineering Applications of Artificial Intelligence*. 2024. Vol. 133. Article 108390. 7. Sattu K., Jain R., Negi A. Feature Extraction of Surface Electromyography Using Wavelet. *Journal of Healthcare Engineering*. 2020. Article 8824194. 8. Zhu G., Kwong S. Gbest-guided Artificial Bee Colony algorithm for numerical function optimization. *Applied Mathematics and Computation*. 2010. Vol. 217. P. 3166–3173. 9. MIC Laboratory. Real-time Bionic Arm Control Via CNN-based EMG Recognition (онлайн-проект). Hackster.io. opubl. 30 serpnia 2022. 10. Ahkami B., Ahmed K., Thesleff A., Hargrove L., Ortiz-Catalan M.

Electromyography-based control of lower limb prostheses: a systematic review. *IEEE Transactions on Medical Robotics and Bionics*. 2023. Vol. 5, No. 4. P. 547–562. **11.** Toledo-Pérez D. C., Rodríguez-Reséndiz J., Gómez-Loenzo R. A., Jauregui-Correa J. C. Support Vector Machine-based EMG signal classification techniques: a review. *Applied Sciences (Switzerland)*. 2019. Vol. 9, No. 20. Article 4402. **12.** De Luca C. J. *Surface Electromyography: Detection and Recording*. Boston : Delsys Inc., 2002. 10 p. **13.** Zhou P., Rymer W. Z. *Biomedical Signal Processing for EMG-Based Control of Prostheses*. Boca Raton : CRC Press, 2018. 338 p. **14.** Parisi G. I., Kemker R., Part J. L., Kanan C., Wermter S. Continual lifelong learning with neural networks: a review. *Neural Networks*. 2019. Vol. 113. P. 54–71. **15.** Liu W. Using Arduino Uno and EMG electrodes for electromyographic signal measurement and servo control. *Theoretical and Natural Science*. 2025. Vol. 86, No. 1. P. 37–44.

Kryvuliak I. I. ^[1; ORCID ID: 0009-0009-3795-045X],
Candidate of Physical and Mathematical Sciences (Ph.D.),
Markovych B. M. ^[1; ORCID ID: 0000-0002-8813-9108],
Candidate of Engineering (Ph.D.),
Korendii V. M. ^[1; ORCID ID: 0000-0002-6025-3013],
Candidate of Engineering (Ph.D.), Associate Professor

¹Lviv Polytechnic National University, Ukraine

REVIEW AND ENHANCEMENT STRATEGIES FOR EXISTING PROSTHETIC CONTROL METHODS THROUGH THE APPLICATION OF NEURAL NETWORK-BASED ADAPTIVE CONTROL SYSTEMS

The paper presents a comprehensive overview of current approaches to controlling upper-limb bionic prostheses using electromyographic (EMG) signals. It highlights the main limitations of conventional control systems, particularly those relying on static classifiers such as SVM, k-NN, and CNN, which often fail to account for temporal variations in muscle activity. Special attention is given to issues of personalization, real-time adaptability, sensitivity to electrode displacement, and muscle fatigue. Building upon literature analysis and practical solutions, the study proposes a new adaptive control architecture based on recurrent neural networks of the Long Short-Term Memory (LSTM) type. This architecture enables temporal tracking of muscle contractions, supports early movement prediction before full activation, and adapts dynamically to changes in the user's physiological conditions. The system comprises several functional modules: a sensing unit for acquiring EMG data, a preprocessing and filtering module, an AI component with an LSTM core, and an actuator module that translates decisions into prosthetic movements. A prototype implementation using an Arduino UNO and a basic training setup is described. Even in this simple



configuration, the system is capable of recognizing motion patterns from partial EMG signals and making early predictions. The proposed solution supports incremental and continual learning and can be scaled to prostheses with varying degrees of freedom, sensor channels, and complexity levels. Its hardware-independence allows flexible integration with different prosthetic platforms, including those with limited computational capabilities. In conclusion, the developed system forms a foundation for the next generation of intelligent bionic prostheses – offering natural responsiveness, user-specific control adaptation, high accuracy, and reliability in real-world conditions.

Keywords: bionic prosthesis; electromyography; EMG signals; adaptive control; LSTM; neural networks; deep learning; personalization; intelligent system; recurrent network; continual learning.

Отримано: 05 травня 2025 року
Прорецензовано: 02 червня 2025 року
Прийнято до друку: 16 червня 2025 року