

А. ПАСТУШЕНКО, Л. КОВАЛЬ

КЕРУВАННЯ РОБОТОМ-МАНІПУЛЯТОРОМ ЗА ДОПОМОГОЮ СИГНАЛІВ ПОВЕРХНЕВОЇ ЕЛЕКТРОМІОГРАФІЇ

Предметом дослідження є методи керування роботизованим маніпулятором на основі сигналів поверхневої електроміографії (ЕМГ) із застосуванням індивідуалізованої нормалізації та класифікації жестів згортковою нейронною мережею (CNN). **Мета роботи** – створення системи управління, що поєднує попередню нормалізацію ЕМГ-сигналів та глибоке навчання для підвищення точності розпізнавання жестів і стабільності в реальному часі. Для досягнення поставленої мети виконано такі **завдання**: здійснено збір ЕМГ-сигналів за допомогою міобраслета *Myo Armband*, проведено їх попереднє оброблення з використанням мінімакс-нормалізації та нормалізації з нульовим середнім, реалізовано перетворення сигналів у зображення за допомогою ковзного вікна, після чого побудовано та навчено згорткову нейронну мережу на основі архітектури *ResNet* з оптимізацією алгоритмом *Adam*, а також проаналізовано та порівняно точність CNN та класичних моделей машинного навчання (*SVM* і *Random Forest*). **Досягнуті результати** показали точність класифікації 97,27% у тестовому середовищі та 91,71% – у реальному часі. Модель CNN перевищила традиційні методи на 18–19%, а нормалізація нульового середнього підвищила точність на 2,34% порівняно з мінімакс-нормалізацією. Система зберігала стабільність навіть за умови варіацій положення браслета завдяки індивідуальній нормалізації. **Висновки.** Запропонована система продемонструвала високу точність, надійність і адаптивність у реальному часі. Наукова новизна полягає в поєднанні індивідуалізованої нормалізації ЕМГ-сигналів із *ResNet*, що забезпечує стабільність і перевищує точність традиційних алгоритмів. У майбутньому заплановано розширення набору жестів, дослідження більш складних умов та оптимізація нейронних мереж для вбудованих систем.

Ключові слова: електроміографія; керування жестами; роботизований маніпулятор; згорткова нейронна мережа; *ResNet*; нормалізація даних; біонічні протези; управління в реальному часі.

Вступ

Сучасний розвиток робототехніки та біомедичних технологій активно спрямований на вдосконалення інтерфейсів "людина – машина", які забезпечують інтуїтивне та ефективне управління роботизованими пристроями. Одним із перспективних напрямів є використання сигналів поверхневої електроміографії (ЕМГ) для керування роботами-маніпуляторами, що дає змогу відтворювати природні рухи людини за допомогою електричних сигналів м'язової активності. Проте точне й стабільне розпізнавання жестів на основі ЕМГ залишається викликом через індивідуальні особливості користувачів, варіативність сигналів і вплив зовнішніх факторів.

Одним із шляхів підвищення точності класифікації ЕМГ-сигналів є застосування глибоких нейронних мереж, зокрема згорткових нейронних мереж (CNN), які здатні ефективно виділяти складні просторово-часові властивості сигналів. Водночас індивідуалізована попередня нормалізація сигналів відіграє важливу роль у зниженні впливу шумів і варіацій, що підвищує стабільність та якість роботи системи. Поєднання цих двох підходів відкриває нові

можливості для створення більш точних і адаптивних систем керування роботизованими маніпуляторами.

У цьому дослідженні поставлено за мету розробити та дослідити метод управління роботом-маніпулятором, оснований на поєднанні індивідуалізованої попередньої нормалізації ЕМГ-сигналів і глибокої згорткової нейронної мережі. Реалізація такого підходу має забезпечити підвищену точність класифікації жестів і стабільність роботи системи в реальному часі, що є важливим кроком для практичного впровадження біонічних пристроїв і протезування.

Мета й завдання

Постановка мети полягає в розробленні системи управління роботизованим маніпулятором на основі сигналів поверхневої електроміографії, яка забезпечує високу точність і стабільність розпізнавання жестів у реальному часі. Для цього необхідно дослідити вплив різних методів індивідуалізованої попередньої нормалізації ЕМГ-сигналів на якість класифікації, а також розробити та навчити ефективну згорткову нейронну мережу, здатну адаптуватися до особливостей

кожного користувача. Крім того, потрібно проаналізувати й порівняти досягнуті результати з традиційними методами машинного навчання, щоб обґрунтувати переваги запропонованого підходу.

Аналіз сучасних публікацій

У сучасних дослідженнях активно вивчаються методи керування роботизованими маніпуляторами за допомогою сигналів поверхневої електроміографії (ЕМГ) у поєднанні з глибоким навчанням, зокрема згортковими нейронними мережами (CNN). Ці підходи дають змогу створювати інтуїтивні та точні інтерфейси для керування протезами й реабілітаційними пристроями.

Guo et al. [1] запропонували легку згорткову нейронну мережу (Lw-CNN) для розпізнавання ЕМГ-сигналів і реального часу керування роботом-маніпулятором. Модель досягла середньої точності на 90% в офлайн-режимі та 84% у режимі онлайн, що демонструє її ефективність у розпізнаванні намірів руху верхньої кінцівки.

Wan et al. [2] розробили систему керування біонічним маніпулятором на основі CNN, яка забезпечує точність класифікації понад 91% для здорових осіб і близько 89% для ампутованих. Система працює в реальному часі із затримкою менше ніж 100 мс, що робить її придатною для практичного застосування.

У дослідженні *Bao et al.* [3] створено гібридну модель CNN-LSTM для оцінювання кінематики зап'ястя на основі ЕМГ-сигналів. Поєднання CNN для просторового аналізу та LSTM для оброблення часових залежностей дало змогу покращити точність оцінювання складних рухів зап'ястя.

Проект, поданий на *Hackster.io* [4], демонструє реальне впровадження CNN на мікроконтролері *Sony Spresense* для керування біонічною рукою в реальному часі. Система використовує *Myo Armband* для збору ЕМГ-сигналів та забезпечує точне розпізнавання жестів із низькою затримкою.

У роботі *Meng et al.* [5] запропоновано метод компенсації руху на основі sEMG для реабілітаційного роботизованого пристрою верхньої кінцівки. Система забезпечує активну участь пацієнта в тренуванні, адаптуючи допоміжну силу відповідно до інтенсивності ЕМГ-сигналів.

Atzori et al. [6] розробили відкритий набір даних з ЕМ-сигналами для керування роботизованими протезами рук. Ця інформація містить різноманітні

жести та учасників, що дає змогу досліджувати універсальні методи розпізнавання намірів руху. Застосування такого набору даних сприяє стандартизації тестування алгоритмів та порівнянню ефективності різних моделей машинного навчання в завданнях керування біонічними пристроями.

Banzi & Shiloh [7] описали платформу *Arduino* як універсальне середовище для прототипування електронних систем. У контексті керування роботизованими маніпуляторами *Arduino* використовується для інтеграції сенсорів, таких як ЕМГ-браслети, з виконавчими механізмами, забезпечуючи швидку реалізацію та тестування прототипів систем управління.

Patel & Patel [9] досліджують методи нормалізації даних у задачах дата-майнінгу та показують їх значний вплив на продуктивність алгоритмів. У контексті роботи це підтверджує необхідність застосування мінімаксу та нульового середнього для оброблення ЕМГ-сигналів, що підвищує стабільність і точність класифікації жестів.

Bhandari в праці [10] детально пояснює концепцію стандартного нормального розподілу та його застосування в статистичному аналізі. Це знання корисне в обробленні ЕМГ-сигналів, оцінюванні відхилень та інтерпретації результатів нормалізації, що впливає на ефективність моделей глибокого навчання.

Сучасні публікації [11–18] свідчать, що методи керування роботизованими маніпуляторами на основі сигналів поверхневої електроміографії (ЕМГ) у поєднанні з глибокими згортковими нейронними мережами (CNN) є перспективним напрямом досліджень. Наявні роботи демонструють можливість створення високоточних систем розпізнавання жестів і намірів руху в режимі реального часу, що підтверджується результатами з точністю класифікації від 84 до понад 91%. Поєднання CNN з іншими архітектурами, такими як LSTM, дає змогу ефективно зважати як на просторові, так і на часові властивості ЕМГ-сигналів, що покращує якість оцінки складних рухів. Практична реалізація таких систем, зокрема на вбудованих платформах, показує їх потенціал для застосування в реабілітації та протезуванні, забезпечуючи низьку затримку та стабільність роботи. Загалом, сучасні дослідження підтверджують доцільність використання глибокого навчання для підвищення точності та швидкодії систем керування роботизованими маніпуляторами на основі ЕМГ.

Опис системи

Система збирання та оброблення сигналів поверхневої електроміографії оснований на міопов'язці *Myo Armband*, яка знімає восьмиканальні ЕМГ-сигнали з частотою 200 Гц. Отримані результати попередньо обробляються для стабілізації сигналів за умови зміни положення пристрою. Оброблені сигнали перетворюються в послідовні матриці у вигляді зображень, що подаються на вхід згорткової нейронної мережі, яка забезпечує класифікацію жестів. Результати застосовуються для керування роботизованим маніпулятором за допомогою мікроконтролера *Arduino* в реальному часі.

Обладнання

Для збирання ЕМГ-сигналів використовувалася наручна пов'язка *Myo Armband* [6], оснащена вісьмома сухими поверхневими ЕМГ-датчиками та інерційним вимірювальним блоком із дев'ятьма ступенями свободи. Частота дискретизації сигналів становила 200 Гц. Незважаючи на те, що медичні ЕМГ-датчики зазвичай працюють на частотах не менше ніж 1 кГц, простота використання *Myo* (зокрема можливість швидкого надягання пов'язки без додаткових налаштувань) зробила цей пристрій оптимальним для нашого експерименту. Роботизований маніпулятор, застосований у дослідженні, виготовлений за допомогою 3D-друку. Конструкція передбачала два пальці, кожен з яких рухався за допомогою мотора й пластикової нитки, яка виконувала роль приводу. Для керування моторами використовувався мікроконтролер *Arduino* [7] разом із драйверами двигунів. На цьому мікроконтролері було завантажено програму, що приймала індекси жестів і відповідно до них задавала кутові положення для кожного двигуна. З'єднання між *Myo*, *Arduino* та комп'ютером здійснювалося через послідовний інтерфейс: комп'ютер отримував сигнали від *Myo*, обробляв їх, розпізнавав жест за допомогою нейронної мережі, після чого передавав результат (ідентифікатор жесту) до *Arduino* для відповідного керування рухом маніпулятора.

База даних

У дослідженні базою даних використовувалася *NinaPro* [8] – відкрита платформа, розроблена для сприяння вивченню сучасних міоелектричних

протезів верхніх кінцівок. Ця база широко застосовується в наукових дослідженнях, пов'язаних із розпізнаванням жестів на основі ЕМГ-сигналів. Типовий підхід до збору інформації в *NinaPro* передбачає, що учасник утримує кожний жест протягом короткого проміжку часу, повторюючи його кілька разів. Для запобігання м'язовій втоми жести чергуються із фазами відпочинку. Однак, якщо жест утримується впродовж більш тривалого часу (наприклад, для моделювання реального повсякденного використання), у сигналі можуть з'являтися шуми, пов'язані із втомою м'язів, що впливає на стабільність та якість зчитуваної інформації.

Попереднє оброблення даних

У зібраних нами наборах даних використовувався один міобраслет, який у процесі кожного зчитування передавав вісім сигналів від електродів. Для оброблення інформації обрано вісім послідовних зчитувань і сформовано з них матрицю розміром 8×8 , де кожен рядок відповідав одному зчитуванню з восьми каналів.

Далі ці значення масштабувалися в діапазон від 0 до 255, що давало змогу подавати отриману матрицю як зображення у відтінках сірого. Отже, кожна матриця могла бути візуалізована як "кадр" або графік ЕМГ-сигналу. Зображення формувалося поступово: перший графік містив рядки 1–8-й, потім донизу додавали новий 9-й рядок, найстаріший рядок вилучався, і в такий спосіб формувався наступний графік з 2–9-го рядків. Такий підхід створював ковзне подання сигналів у вигляді послідовних "кадрів" ЕМГ, придатних для подання в нейронну мережу, яка працює із зображеннями.

Для нормалізації оброблення графіка ЕМГ використовувалися метод мінімакс-нормалізації та нормалізації нульового середнього.

Мінімально-максимальна нормалізація – це техніка лінійної нормалізації, що широко використовується в попередньому обробленні зображень. Цей метод не змінить розподіл набору даних [9]:

$$z = (x - \min(x)) / (\max(x) - \min(x)) \quad (1)$$

Мінімакс-нормалізація може відтворювати дані ЕМГ у вигляді 0 і 1.

Нормалізація нульового середнього є одним із найпоширеніших методів нормалізації, і дані, оброблені цим методом, підходять до стандартного нормального розподілу [10]:

$$z = (x - \mu) / \sigma \quad (2)$$

де μ і σ – середнє й стандартне відхилення повністю введених даних ЕМГ відповідно. Дані ЕМГ після нормалізації нульового середнього відповідають стандартному нормальному розподілу із середнім значенням 0 і стандартним відхиленням 1.

Під час тестування помітили, що амплітуда ЕМГ-сигналів змінюється щоразу, коли міопов'язку знімають і знову надягають. Через це під час кожного нового налаштування пристрою (наприклад, після ініціалізації *Myo*), ми просили користувача виконати певний жест з міткою 12 протягом 5 с. На підставі отриманих показників визначено максимальне й мінімальне значення сигналу, після чого обчислювалися середнє значення та дисперсія. Ці параметри використовувалися для подальшої нормалізації ЕМГ-сигналів, щоб забезпечити стабільність вхідної інформації для моделі незалежно від зміни положення або контакту пов'язки.

Класифікація

Основним класифікатором у дослідженні була згортоква нейронна мережа із залишковими зв'язками (*ResNet*-архітектура) [11]. Її структура містила чотири згорткових шари, один залишковий блок, а також чотири повнозв'язані шари, доповнені механізмом випадкового відключення (*dropout*), і фінальний шар *softmax*, що забезпечував як класифікацію жестів, так і обчислення ймовірностей для кожного з них. Як функція втрат використовувалась нормалізована експоненціальна функція (*softmax loss*), що дає змогу ефективно працювати з багатокласовими задачами. Навчання мережі здійснювалося за допомогою оптимізатора *Adam* [12], що використовує зворотне поширення помилки для оновлення ваг кожного шару. У повнозв'язаних шарах застосовувались *ReLU*-активації, які краще розв'язують проблему зникнення градієнта порівняно з традиційними сигмоїдальними чи *tanh*-функціями. Щоб уникнути перенавчання, у цих шарах також застосовувалось *dropout*-відключення з імовірністю збереження нейронів 0,5. У залишковому блоці використовувалась нормалізація екземпляра (*instance normalization*) – аналог нормалізації до нульового середнього, але з тією різницею, що середнє значення (μ) та стандартне відхилення (σ) обчислюються лише на основі поточного вхідного графіка, властивого для завдань, пов'язаних зі стилізацією зображень. Уся модель була реалізована з використанням

фреймворку *TensorFlow* [13], а навчену модель збережено у вигляді бінарного файлу. Це дало змогу безпосередньо інтегрувати класифікатор у систему керування роботизованим маніпулятором із застосуванням розпізнаних жестів як команд.

Збирання навчальних даних

У збиранні даних для навчання класифікатора жестів брали участь п'ятеро здорових добровольців віком від 22 до 30 років. Усі молоді люди не мали відомих порушень нервово-м'язової системи й дали згоду на участь у дослідженні.

Перед початком експерименту кожному учаснику на передпліччя одягали міопов'язку, що забезпечувала зчитування електроміографічних (ЕМГ) сигналів із м'язів руки. Основним завданням учасників було виконання двох заздалегідь визначених жестів руки. Кожен жест повторювався по 10 разів, крім того, між повтореннями передбачалися короткі перерви для запобігання м'язовій втоми, що могло б вплинути на якість сигналу.

Для кожного виконаного жесту зчитувалися ЕМГ-сигнали, які безперервно записувалися у вигляді часових серій. Щоб забезпечити точну прив'язку сигналів до конкретних жестів, час виконання жесту маркувався відповідною міткою. Отримані сигнали розбивалися на короткі часові вікна фіксованої довжини, кожне з яких розглядалося як окремий зразок для подальшого аналізу.

Для покращення якості показників проводилася нормалізація сигналів. Оскільки амплітуда ЕМГ-сигналів може змінюватися залежно від положення пов'язки та ступеня контакту зі шкірою, після кожного нового надягання пристрою учасник виконував спеціальний тестовий жест упродовж 5 с. За цією інформацією визначалися параметри нормалізації, які використовувалися для приведення вхідних сигналів до стабільного діапазону. Такий підхід давав змогу зменшити вплив зміщень і забезпечити порівняність сигналів між різними сесіями експерименту.

Отримані нормалізовані часові вікна разом із відповідними мітками жестів формували базу даних, яка застосовувалася для навчання згорткової нейронної мережі. Завдяки такій методології було забезпечено збирання репрезентативних даних із чіткою класифікацією жестів для подальшої ефективної роботи системи розпізнавання.

Аналіз результатів навчання

Нейронна мережа була навчена за допомогою 5000 ітерацій, графік результату й втрат зображений

на рис. 1. Із графіків видно, що продуктивність мережі й помилки почали погіршуватися після 2000 ітерацій, з чого можна зробити висновок, що мережа навчена після 2000 ітерацій.




Рис. 1. Значення точності і втрат ітерацій

Оцінювання методів нормалізації

На рис. 2 продемонстровано порівняння загальної точності методів попереднього оброблення

даних. Можна зробити висновок, що нормалізація нульового середнього на 2,3362% вища, ніж мінімально-максимальна нормалізація.




Рис. 2. Результати оцінювання точності методів нормалізації

Оцінювання ефективності класифікаторів

З метою порівняння різних методів машинного навчання для оцінювання ефективності було протестовано кілька алгоритмів і методів аналізу функцій.

У дослідженні використано кілька методів машинного навчання для аналізу та класифікації даних. Зокрема застосовувалися RF (випадкові ліси), TD (часова різниця), mDWT (багатовимірне

дискретне перетворення вейвлетів), SVM (Support Vector Machine, метод опорних векторів), а також CNN (згортова нейронна мережа).

На рис. 3 подано результати тестування різних класифікаторів. Можна зробити висновок, що метод CNN, використаний у дослідженні, демонструє на 19,39% вищу ефективність порівняно з SVM і mDWT і на 18,37% вищу, ніж RF і TD. Унаслідок тестування класифікатора CNN досягнуто точність 97,27%.




Рис. 3. Результати точності класифікаторів

Аналіз тестування в режимі реального часу

Для оцінювання роботи системи розпізнавання жестів у реальному часі було проведено серію тестів із керування роботизованим маніпулятором. Учасники експерименту одягали міопов'язку Муо, яка збирала ЕМГ-сигнали, що в реальному часі оброблялися згортковою нейронною мережею (CNN) для класифікації жестів. Розпізнані жести миттєво передавалися до мікроконтролера *Arduino*, що забезпечував керування рухами двопальцевого маніпулятора. Під час тестування учасники виконували набір заздалегідь визначених жестів, які система мала розпізнати та правильно інтерпретувати для відповідного руху робота.

Результати

У процесі тестування в режимі реального часу було досягнуто середню точність розпізнавання жестів на рівні 91,7%.

Порівняння

Розроблена система досягла середньої точності розпізнавання жестів у режимі реального часу, яка становила 91,7%. Це є конкурентним результатом порівняно із сучасними дослідженнями. У праці [1] продемонстровано 90% точності офлайн і 84% онлайн. Автори роботи [3] досягли точності понад 91% для здорових користувачів. У дослідженні [14] отримали схожу точність (91,25%) з використанням легкої моделі CNN+LSTM, оптимізованої для вбудованих систем. У праці [15] автори продемонстрували 94% точності, використовуючи карти активації м'язів (ТМА), що може бути корисним для покращення розпізнавання складних жестів. У дослідженні [16] досягнуто 98,4% точності за умови застосування *Муо Armband* та CNN для розпізнавання шести жестів, що свідчить про високу ефективність запропонованого підходу. У праці [17] продемонстровано 93% точності з використанням EMGNet і трансферного навчання, що дає змогу покращити цю властивість за умови обмежених даних. Автори роботи [18] досягли

90,3% точності за допомогою моделі CNN з увагою до каналів, що може бути корисним для покращення точності в реальному часі.

Недоліки та обмеження

Основним обмеженням системи є чутливість до тривалих змін стану м'язів, таких як втома, що може впливати на стабільність сигналів і знижувати точність розпізнавання. Крім того, хоча індивідуальна нормалізація після кожного надягання пов'язки знижує вплив неточного розташування датчиків, повністю усунути цей фактор наразі не вдалося. Обмеження також пов'язані з кількістю підтримуваних жестів – у цьому дослідженні протестовано лише два основні жести, що обмежує застосовність системи в більш складних сценаріях.

Практичне значення для подальших досліджень

Досягнуті результати демонструють життєздатність використання міопов'язки в поєднанні зі згортковими нейронними мережами для реального часу керування роботизованими пристроями. Це відкриває перспективи для подальшого розширення набору розпізнаваних жестів, покращення алгоритмів адаптивної нормалізації та впровадження систем у практичні застосування, такі як протези, реабілітаційні пристрої або інтерфейси "людина – машина". Особливо перспективним є розвиток методів, які підвищать стійкість системи до фізіологічних змін і тривалої експлуатації в реальних умовах.

Висновки

У цьому дослідженні розроблено та протестовано систему розпізнавання жестів на основі сигналів поверхневої електроміографії (ЕМГ), зібраних за допомогою міопов'язки *Myo Armband*. Застосування восьмиканального пристрою з частотою дискретизації 200 Гц дало змогу отримати достатньо якісні сигнали для аналізу, а попереднє оброблення даних, зокрема перетворення сигналів у сірі зображення, зробило можливим ефективно використання згорткової нейронної мережі для класифікації жестів.

Оброблення сигналів передбачало нормалізацію за допомогою методів мінімально-максимальної нормалізації та нормалізації нульового середнього. Аналіз продемонстрував, що нормалізація нульового середнього забезпечує вищу точність класифікації

на 2,34%, що свідчить про її перевагу в цьому контексті. Важливим кроком стала увага до змін амплітуди сигналів після кожного нового надягання браслета, що дало змогу забезпечити стабільність даних за допомогою індивідуального калібрування.

Класифікація жестів здійснювалася за допомогою згорткової нейронної мережі *ResNet*-типу, яка досягла точності 97,27% на тестовій вибірці. Порівняльний аналіз з іншими методами (RF, SVM, mDWT, TD) підтвердив перевагу CNN, яка продемонструвала на 18–19% вищу точність розпізнавання. Навчання моделі з використанням оптимізатора *Adam* показало стабільну збіжність, а результати втрат свідчили про досягнення оптимального навчання після приблизно 2000 ітерацій.

Під час тестування в режимі реального часу було досягнуто середньої точності 91,7%, що підтверджує можливість практичного застосування системи для керування роботизованими пристроями. Це значення є конкурентним порівняно із сучасними аналогами, більшість з яких демонструють точність у межах 84–94%. Результати дослідження підтверджують ефективність запропонованого підходу навіть за умови обмеженої кількості жестів.

Однак система має певні обмеження. Вона чутлива до м'язової втоми та змін розташування датчиків, що знижує стабільність розпізнавання в разі тривалої експлуатації. Крім того, поточна реалізація підтримує лише два жести, що обмежує її функціональність у більш складних сценаріях використання.

З практичного погляду результати відкривають подальші перспективи для досліджень. Можливе розширення кількості розпізнаваних жестів, удосконалення методів нормалізації, підвищення стійкості до фізіологічних змін користувача, а також інтеграція з реальними пристроями, такими як біонічні протези або інтерфейси "людина – машина". Отримані напрацювання можуть стати основою для майбутніх досліджень у сфері реабілітації, допоміжних технологій та безконтактного управління технікою.

Перспективи подальших досліджень

Результати дослідження свідчать про значний потенціал системи розпізнавання жестів на основі сигналів ЕМГ, однак також окреслюють низку напрямів, які можуть бути суттєво розвинуті в подальших роботах.

По-перше, перспективним є розширення кількості розпізнаваних жестів. Поточна реалізація підтримує лише два жести, що обмежує можливості практичного застосування. Додавання більшої кількості жестів потребуватиме збільшення обсягу навчальної інформації, покращення архітектури нейронної мережі та оптимізації підходів до калібрування, щоб забезпечити збереження високої точності розпізнавання.

По-друге, важливо дослідити методи підвищення стійкості системи до змін зовнішніх умов. Зокрема варто розробити алгоритми, які будуть менш чутливими до неправильного надягання браслета, м'язової втоми, потовиділення чи інших фізіологічних змін користувача. Одним із можливих рішень є використання адаптивного навчання або персоналізованих моделей, які беруть до уваги індивідуальні особливості користувача в реальному часі.

Третім напрямом є оптимізація оброблення сигналів. Поглиблений аналіз часових і частотних

властивостей ЕМГ-сигналів може дати змогу сформувати більш інформативні вхідні ознаки для моделі. Також доцільно дослідити альтернативні способи перетворення сигналів у зображення або тривимірне подання, що може покращити ефективність нейронної мережі.

Крім того, перспективним є поєднання ЕМГ-даних з іншими типами сенсорної інформації, наприклад, із показниками акселерометра чи гіроскопа. Мультимодальні підходи можуть значно підвищити точність класифікації та дати змогу розпізнавати складні або динамічні жести.

Також варто приділити увагу практичній інтеграції системи в реальні пристрої: біонічні протези, інвалідні візки, системи віртуальної або доповненої реальності. Це передбачає не лише технічну адаптацію, а й дослідження ергономіки, зручності використання та тривалості взаємодії користувача із системою.

Список літератури

1. Guo B., Ma Y., Yang J., Wang Z., Zhang X. Lw-CNN-Based Myoelectric Signal Recognition and Real-Time Control of Robotic Arm for Upper-Limb Rehabilitation. *Computational Intelligence and Neuroscience*, 2020, 8846021 p. DOI: <https://doi.org/10.1155/2020/8846021>
2. Wan Y., Han Z., Zhong J., Chen G. (2018). Pattern recognition and bionic manipulator driving by surface electromyography signals using convolutional neural network. *Advances in Mechanical Engineering*, 10 (10), P. 1–11. 2018. DOI: <https://doi.org/10.1177/1729881418802138>
3. Bao T., Zaidi S. A. R., Xie S., Yang P., Zhang Z. A CNN-LSTM Hybrid Framework for Wrist Kinematics Estimation Using Surface Electromyography. *IEEE Transactions on Instrumentation and Measurement*. 82 p. 2019. DOI: <https://doi.org/10.1109/TIM.2020.3036654>
4. Real-time Bionic Arm Control Via CNN-based EMG Recognition. URL: <https://www.hackster.io/emgarm/real-time-bionic-arm-control-via-cnn-based-emg-recognition-b013d3>
5. Meng Q., Yue Y., Li S., Yu H. Electromyogram-based motion compensation control for the upper limb rehabilitation robot in active training. *Mechanical Sciences*, 13(2), 2022. P. 675–685. DOI: <https://doi.org/10.5194/ms-13-675-2022>
6. Atzori M., Gijssberts A., Castellini C., Caputo B., Mittaz Hager A.G., Elsig S., Giatsidis G., Bassetto F., Müller H. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, № 1, 140053 p. 2014. DOI: <https://doi.org/10.1038/sdata.2014.53>
7. Banzi M., Shiloh M. Getting Started with Arduino: The Open Source Electronics Prototyping Platform. Maker Media. 2014. URL: <https://www.sarcnet.org/files/Getting%20Started%20With%20Arduino.pdf>
8. Patel S., Patel V. A study on normalization techniques in data mining. *International Journal of Computer Applications*, 179(14), 2018. P. 1–4. DOI: <https://doi.org/10.5120/ijca2018917759>
9. Bhandari P. The Standard Normal Distribution Calculator, Examples & Uses. Scribbr. 2020. URL: <https://www.scribbr.com/statistics/standard-normal-distribution/>
10. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016. P. 770–778. DOI: <https://doi.org/10.1109/CVPR.2016.90>
11. Kingma D. P., Ba J. Adam: A method for stochastic optimization. In *Proceedings of the International Conference on Learning Representations (ICLR)*. 2014. DOI: <https://doi.org/10.48550/arXiv.1412.6980>
12. Abadi M., Barham P., Chen J., Chen Z., Davis A., Dean J., Devin M., Ghemawat S., Irving G., Isard M., Kudlur M., Levenberg J., Monga R., Moore S., Murray D., Steiner B., Zheng X. Tensor Flow: A system for large-scale machine learning. In *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI)*, 2016. P. 265–283. URL: <https://www.usenix.org/conference/osdi16/technical-sessions/presentation/abadi>

13. Dianchun Bai, Tie Liu, Xinghua Han, Hongyu Yi. Application Research on Optimization Algorithm of sEMG Gesture Recognition Based on Light CNN+LSTM Model. *Cyborg and Bionic Systems*. Vol 2021. 2021. DOI:10.34133/2021/9794610
14. Silva A. D., Perera M. V., Wickramasinghe K., Naim A. M., Dulantha Lalitharatne, Kappel S. L. Real-Time Hand Gesture Recognition Using Temporal Muscle Activation Maps of Multi-Channel Semg Signals, *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, Spain, 2020, P. 1299–1303, DOI: 10.1109/ICASSP40776.2020.9054227
15. Asif A.R., Waris A., Gilani S.O., Jamil M., Ashraf H., Shafique M., Niazi I.K. Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG. *Sensors* 2020, № 20, 1642 p. DOI: <https://doi.org/10.3390/s20061642>
16. Gopal P., Gesta A., Mohebbi A. A Systematic Study on Electromyography-Based Hand Gesture Recognition for Assistive Robots Using Deep Learning and Machine Learning Models. *Sensors* 2022, № 22, 3650 p. DOI: <https://doi.org/10.3390/s22103650>
17. Yu G., Deng Z., Bao Z., Zhang Y., He B. Gesture Classification in Electromyography Signals for Real-Time Prosthetic Hand Control Using a Convolutional Neural Network-Enhanced Channel Attention Model. *Bioengineering* 2023, № 10, 1324 p. DOI: <https://doi.org/10.3390/bioengineering10111324>

References

1. Guo, B., Ma, Y., Yang, J., Wang, Z., Zhang, X. (2020), "Lw-CNN-Based Myoelectric Signal Recognition and Real-Time Control of Robotic Arm for Upper-Limb Rehabilitation". *Computational Intelligence and Neuroscience*, 2020, 8846021 p. DOI: <https://doi.org/10.1155/2020/8846021>
2. Wan, Y., Han, Z., Zhong, J., & Chen, G. (2018), "Pattern recognition and bionic manipulator driving by surface electromyography signals using convolutional neural network". *Advances in Mechanical Engineering*, Vol. 10(10), P. 1–11. DOI: <https://doi.org/10.1177/1729881418802138>
3. Bao, T., Zaidi, S. A. R., Xie, S., Yang, P., Zhang, Z. (2019), "A CNN-LSTM Hybrid Framework for Wrist Kinematics Estimation Using Surface Electromyography". *IEEE Transactions on Instrumentation and Measurement*. 82 p. 2019. DOI: <https://doi.org/10.1109/TIM.2020.3036654>
4. "Real-time Bionic Arm Control Via CNN-based EMG Recognition". available at: <https://www.hackster.io/emgarm/real-time-bionic-arm-control-via-cnn-based-emg-recognition-b013d3>
5. Meng, Q., Yue, Y., Li, S., Yu, H. (2022), "Electromyogram-based motion compensation control for the upper limb rehabilitation robot in active training". *Mechanical Sciences*, 13(2), P. 675–685. DOI: <https://doi.org/10.5194/ms-13-675-2022>
6. Atzori, M., Gijssberts, A., Castellini, C., Caputo, B., Mittaz Hager, A.G., Elsig, S., Giatsidis, G., Bassetto, F., Müller, H. (2014), "Electromyography data for non-invasive naturally-controlled robotic hand prostheses". *Scientific Data*, № 1, 140053 p. DOI: <https://doi.org/10.1038/sdata.2014.53>
7. Banzi, M., Shiloh, M. (2014), "Getting Started with Arduino: The Open Source Electronics Prototyping Platform. Maker Media", available at: <https://www.sarcnet.org/files/Getting%20Started%20With%20Arduino.pdf>
8. Patel, S., Patel, V. (2018), "A study on normalization techniques in data mining". *International Journal of Computer Applications*, № 179(14), P. 1–4. DOI: <https://doi.org/10.5120/ijca2018917759>
9. Bhandari, P. (2020), "The Standard Normal Distribution | Calculator, Examples & Uses. Scribbr". available at: <https://www.scribbr.com/statistics/standard-normal-distribution/>
10. He, K., Zhang, X., Ren, S., Sun, J. (2016), "Deep residual learning for image recognition". In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, P. 770–778. DOI: <https://doi.org/10.1109/CVPR.2016.90>
11. Kingma, D. P., Ba, J. (2014), "Adam: A method for stochastic optimization". In *Proceedings of the International Conference on Learning Representations (ICLR)*. DOI: <https://doi.org/10.48550/arXiv.1412.6980>
12. Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D., Steiner, B., Zheng, X. (2016), "TensorFlow: A system for large-scale machine learning". In *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI)*, P. 265–283. available at: <https://www.usenix.org/conference/osdi16/technical-sessions/presentation/abadi>
13. Dianchun Bai, Tie Liu, Xinghua Han, Hongyu Yi. (2021), "Application Research on Optimization Algorithm of sEMG Gesture Recognition Based on Light CNN+LSTM". *Cyborg and Bionic Systems*. Vol 2021. 2021. DOI:10.34133/2021/9794610
14. Silva, A.D., Perera, M.V., Wickramasinghe, K., Naim, A.M., Dulantha, Lalitharatne, Kappel, S. L. (2020), "Real-Time Hand Gesture Recognition Using Temporal Muscle Activation Maps of Multi-Channel Semg Signals," *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, Spain, 2020, P. 1299–1303, DOI: 10.1109/ICASSP40776.2020.9054227
15. Asif, A.R.; Waris, A.; Gilani, S.O.; Jamil, M.; Ashraf, H.; Shafique, M.; Niazi, I.K. (2020), "Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG". *Sensors*. № 20, 1642 p. DOI: <https://doi.org/10.3390/s20061642>

16. Gopal, P.; Gesta, A.; Mohebbi, A. (2022), "A Systematic Study on Electromyography-Based Hand Gesture Recognition for Assistive Robots Using Deep Learning and Machine Learning Models". *Sensors*. № 22, 3650 p. DOI: <https://doi.org/10.3390/s22103650>
17. Yu, G.; Deng, Z.; Bao, Z.; Zhang, Y.; He, B. (2023), "Gesture Classification in Electromyography Signals for Real-Time Prosthetic Hand Control Using a Convolutional Neural Network-Enhanced Channel Attention Model". *Bioengineering*. № 10, 1324 p. <https://doi.org/10.3390/bioengineering10111324>

Надійшла (Received) 03.01.2025

Відомості про авторів / About the Authors

Пастушенко Антон Олександрович – аспірант, Вінницький національний технічний університет, кафедра біомедичної інженерії та оптико-електронних систем, м. Вінниця, Україна. e-mail: hate6death88@gmail.com; ORCID ID: <https://orcid.org/0009-0006-7028-4071>

Коваль Леонід Григорович – кандидат технічних наук, доцент, Вінницький національний технічний університет, завідувач кафедри біомедичної інженерії та оптико-електронних систем, Вінниця, Україна. e-mail: koval.l@vntu.edu.ua; ORCID ID: <https://orcid.org/0000-0001-9887-2605>

Pastushenko Anton – a graduate student of the Department of Biomedical Engineering and Opto-Electronic Systems, Vinnytsia National Technical University, Vinnytsia, Ukraine.

Koval Leonid – Candidate of Technical Sciences, Associate Professor, Head of the Department of Biomedical Engineering and Optoelectronic Systems, Vinnytsia National Technical University, Vinnytsia, Ukraine.

CONTROL OF A ROBOT MANIPULATOR USING SURFACE ELECTROMYOGRAPHY SIGNALS

The subject of the study is the methods of controlling a robotic manipulator based on surface electromyography (EMG) signals using individualized normalization and classification of gestures by a convolutional neural network (CNN). **The aim of the work** is to create an effective control system that combines pre-normalization of EMG signals and deep learning to increase the accuracy of gesture recognition and stability in real time. **For this purpose**, the following were used: signal collection using the Myo Armband, pre-processing (min-max and zero-mean), signal conversion into images through a sliding window, CNN training (ResNet, Adam optimization) and comparison with SVM and Random Forest models. **The results** obtained showed a classification accuracy of 97.27% in the test environment and 91.71% in real time. The CNN model outperformed traditional methods by 18–19%, and zero-mean increased the accuracy by 2.34% compared to min-max normalization. The system remained stable even with variations in the bracelet position due to individual normalization. **Conclusions:** the proposed system demonstrates high accuracy, reliability and adaptability in real time. The scientific novelty lies in the combination of individualized normalization of EMG signals with ResNet, which provides stability and exceeds the accuracy of traditional algorithms. In the future, it is planned to expand the set of gestures, study more complex conditions and optimize neural networks for embedded systems.

Keywords: electromyography; gesture control; robotic manipulator; convolutional neural network; ResNet; data normalization; bionic prostheses; real-time control.

Бібліографічні описи / Bibliographic descriptions

Пастушенко А. О., Коваль Л. Г. Керування роботом-маніпулятором за допомогою сигналів поверхневої електроміографії. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 3 (33). С. 203–212. DOI: <https://doi.org/10.30837/2522-9818.2025.3.203>

Pastushenko, A., Grigorovich, K. (2025), "Control of a robot manipulator using surface electromyography signals", *Innovative Technologies and Scientific Solutions for Industries*, No. 3 (33), P. 203–212. DOI: <https://doi.org/10.30837/2522-9818.2025.3.203>