

ВИКОРИСТАННЯ НЕЙРОМЕРЕЖІ НА БАЗІ TENSORFLOW ДЛЯ РОЗПІЗНАВАННЯ ЖЕСТІВ ТА КЕРУВАННЯ БІОНІЧНИМ ПРОТЕЗОМ

¹Вінницький національний технічний університет

У дослідженні детально проаналізовано точність розпізнавання різних жестів за допомогою нейромережі, побудованої на основі TensorFlow для керування біонічним протезом. Проведено серії експериментів із застосуванням наборів даних та параметрів моделі, в яких досліджено наскільки ефективно нейромережа розпізнає різні жести в контексті управління протезом. Результати експериментів дозволяють зрозуміти потенційні обмеження та можливості цієї технології для практичного застосування в реальних умовах. Описано модель та архітектуру нейромережі, функції активації та параметри, які використано для навчання. Також розглянуто параметри навчання, які впливають на ефективність навчання моделі. Для оцінки ефективності моделі використано метрики оцінки моделі, графіки продуктивності моделі, матриця плутанини, — які дозволяють оцінити рівень достовірності та продуктивності навченої нейромережі. Запропоновано методику збору даних електроміографії (ЕМГ), що полягає у використанні електричних сигналів, які виникають у м'язах у разі їхнього скорочення. Цей процес передбачає розміщення електродів на поверхні шкіри над м'язами, що аналізуються, для реєстрації електричних сигналів, які виникають у момент м'язової активності. Такий підхід дозволяє збирати об'єктивні дані про активність м'язів та їхні рухи, які потім можуть бути використані для навчання нейромережі та подальшого використання у керуванні біонічним протезом. Проведено серію експериментів для оцінки точності розпізнавання різних рухів за використання навченої моделі. Аналізуючи результати експериментів, можна зрозуміти, наскільки ефективно та надійно працює навчена модель у реальних умовах та яка її придатність для практичного застосування в системах управління біонічними протезами.

Ключові слова: нейромережа, TensorFlow, розпізнавання жестів, біонічний протез, електроміографія, точність розпізнавання.

Вступ

З розвитком технологій штучного інтелекту та біоніки, стає актуальнішим використання нейромереж для керування біонічними протезами. Одним з важливих аспектів у цій сфері є ефективне розпізнавання жестів та рухів людської кінетики для їхнього відтворення у контексті керування протезом. Завдяки поєднанню передових методів обробки сигналів, машинного навчання та біомедичної інженерії вдалося створити інноваційні системи, які дозволяють відновлювати функції тіла у людей з обмеженими можливостями.

Метою роботи є дослідження використання нейромережі на базі TensorFlow для розпізнавання жестів та рухів на основі даних електроміографії.

Результати дослідження

1. Збір даних

Для збору даних використано схему, що включає в себе датчик MuoWare та плату Esp32 (рис. 1). Датчик MuoWare доступний на ринку за низьку ціну, уможливує надійний запис електричних сигналів, може легко інтегруватися з іншими пристроями та програмним забезпеченням. Плата Esp32 характеризується доступною ціною, можливістю програмування та підключення до комп'ютера для передачі та відображення даних, а також різноманітними інтерфейсами, такими як GPIO, SPI, I2C.




Рис. 1. Ескізний проект електронної схеми

Теорема Найквіста стверджує, що для точної реконструкції сигналу частота дискретизації повинна бути принаймні удвічі більшою ніж найвища частота, присутня у сигналі. Застосовуючи цю теорему до електроміографії, необхідно встановити частоту дискретизації не менше 300 Гц, оскільки відповідна інформація міститься у діапазоні 50...150 Гц. З цієї причини вибрано частоту дискретизації 1 кГц.

Для обробки даних з плати ESP32 вибрано програмне забезпечення з використанням бібліотеки ESP32 і інтегрованим середовищем розробки arduino ide.

Сигнали ЕМГ чутливі до впливу шуму, тому необхідно прикладати зусилля для їхнього згладжування та очищення. З цією метою використано метод конвертації RMS, який рекомендує розраховувати квадратичне середнє у визначених вікнах часу. Мета цього методу полягає в згладжуванні сигналу без втрати репрезентативної інформації. Тому розмір часового вікна не може бути надто великим, оскільки це може призвести до втрати значущої інформації, або занадто малим, оскільки підсумковий сигнал все одно буде містити значний рівень шуму.

$$\sqrt{\frac{\sum_{n=1}^N x_n^2}{N}} \quad (1)$$

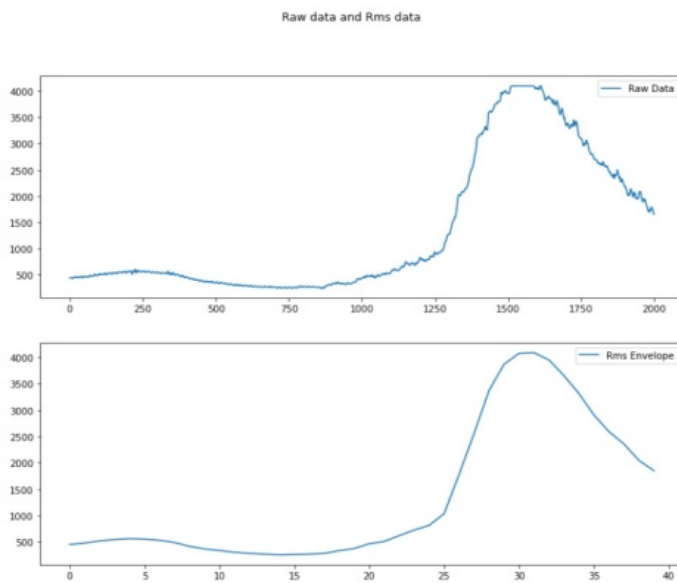


Рис. 2. RMS конверт

За дуже великих або дуже малих значень часового вікна характеристики не були репрезентативними, тому вибрано часове вікно, яке дало найкращі результати у класифікації, і воно становило 50 мс, як показано на рис. 2.

Процес нормалізації використовувався для стандартизації всіх даних у єдиному діапазоні, з метою того, щоб модель ШІ не приділяла більше уваги деяким зразкам порівняно з іншими. Використано метод пікової динаміки, де значення часового вікна виражено як відношення між отриманим значенням та максимальним значенням цього часового вікна.

$$X_{norm} = \frac{X}{X_{peak}} \quad (2)$$

За цим рівнянням усі значення вхідних даних залишаються в діапазоні [0, 1].

Існують різні види ознак, які можна використовувати для відтворення біологічного сигналу. У статистичному підході використовуються статистичні характеристики, такі як середнє абсолютне значення, медіанне абсолютне значення, дисперсія та стандартне відхилення, які служать для виділення ознак. У методі середньоквадратичного визначення обчислюється середньоквадратичне значення в часових вікнах попередньо визначеної тривалості. Вибрано характеристики середньоквадратичного методу через його перевагу у швидкості обчислення в реальному часі перед статистичним методом.

Дані отримано виключно від одного учасника дослідження. Експерименти проводились з учасником, який сидів у кріслі з опорами для рук. Три електроди розміщувалися на м'язі плеча, м'язі

ліктьового згину та м'язі розгину пальців. Жести для виконання відображались на моніторі, розташованому перед учасником. Спочатку на екрані з'являлось привітальне повідомлення учаснику, до початку експерименту включався таймер. Потім виконувався один з двох жестів — розгинання або згинання кисті. Кожна м'язова акція тривала 5 секунд, протягом якої учасник скорочував м'яз та утримував його, за 10 секунд відпочинку, щоб уникнути ризику м'язової втоми. Дії послідовно відображались на екрані, як показано на рис. 3. Кожне завдання повторювалося на екрані 10 разів.




Рис. 3. Експериментальний дизайн

2. Модель нейронної мережі

Як нейронна мережа використовувався багатошаровий перцептрон. Вибір перцептрона замість, наприклад, спайкінгових нейромереж [21], обґрунтований його простотою та швидкістю навчання, обчислювальною ефективністю на стандартному апаратному забезпеченні, а також широкою підтримкою інструментів, таких як TensorFlow.

Перцептрони добре підходять для завдань класифікації, таких як розпізнавання жестів на основі ЕМГ сигналів, а попередні дослідження показали їхню високу точність і надійність у подібних застосуваннях.

Нейронна мережа (рис. 4) працює в режимі реального часу, приймаючи ЕМГ-сигнали та генеруючи команди управління для досягнення необхідних рухів. Математична модель нейронної мережі має такі формули:

– входи, сигнали ЕМГ

$$X = [x_1, x_2, \dots, x_n]; \quad (3)$$

– виходи, рухи біонічної руки

$$Y = [y_1, y_2, \dots, y_n]; \quad (4)$$

– ваги та упередження

$$P = [P_1, P_2, \dots, P_n]; \quad b = [b_1, b_2, \dots, b_n]; \quad (5)$$

– прихований шар

$$S = \sum_{i=1}^n X \cdot P_i + b_i, \quad (6)$$

де x_i — записаний сигнал ЕМГ; y_i — відповідний рух біонічної руки; P_i і b_i — ваги та зміщення шарів нейронної мережі.

Вилучення функцій

$$F = [f_1, f_2, \dots, f_n], \quad (7)$$

де f_i — характеристики, отримані з сегментів сигналів ЕМГ.

Навчальний набір даних

$$T = [(F_1, y_1), (F_2, y_2), \dots, (F_3, y_3)], \quad (8)$$

де F_i — вектор ознак.

Вихід

$$Y = \sum_{i=1}^n S \cdot P + b, \quad (9)$$

де P і b — ваги та зміщення вихідного рівня штучної нейронної мережі.

Для тренування нейронної мережі використовувалася бібліотека Tensorflow, яка надає різноманітні інструменти для розробки, навчання та впровадження моделей машинного навчання. Вибір здійснено на користь п'яти шарів, із застосуванням проміжних шарів з коефіцієнтом 20 %, щоб уникнути перенавчання моделі.

Навчання моделі виконувалося на основі 60 % доступних даних, решта 40 % використовувалися для тестування та перевірки. Параметри процесу навчання подані у табл. 1.

Таблиця 1

Гіперпараметри та функції, що використовуються в навчанні моделі

Функція активації	Softmax
Функція втрат	Categorical cross-entropy
Алгоритм оптимізації	Adam
Швидкість навчання	0,001
Ітерації	300
Розмір партії	8

Остаточні функції активації та функції втрат вибрано з урахуванням характеру завдання, яке включало багатокласову класифікацію. Використання функції Softmax дозволяє отримати ймовірнісний розподіл для N різних класів. Функція витрат, а саме категоріальна крос-ентропія, вимірює точність моделі щодо очікуваних значень для категоріальних змінних. Після перевірки їхньої ефективності та стабільності результатів, вирішено продовжити експерименти з випадковим вибором гіперпараметрів. В дослідженні використовувався діапазон значень від 0,01 до 0,0001 для швидкості навчання, ітерації були обмежені [100, 200, 300], і розмір партії залишався постійним.

Отриману модель конвертовано в вихідний файл C++ за допомогою конвертера бібліотеки Tensorflow Lite та збережено на платі розробки.

3. Результати

Система повинна мати швидкий час відгуку для ефективного її використання в повсякденній рутині користувача. Для визначення оптимального часу проведено етапи обробки зі зміною розміру часового вікна сигналів ЕМГ. На основі отриманих результатів побудовано графік, де показано різні розміри часового вікна в залежності від точності моделі, рис. 5. Проаналізувавши графік, дійшли висновку, що найоптимальніше часове вікно має тривалість 2 секунди. Це забезпечує відносно короткий час відгуку та високу точність системи.

Для оцінки ефективності штучного інтелекту використовувалася методика 10-кратної перехресної перевірки. Детальні результати подані у табл. 2.




Рис. 5. Розмір вікна в порівнянні з точністю моделі


Таблиця 2

Метрики оцінки моделі

Достовірність	78,67 %
Влучність	80,21 %
Повнота	75,67 %
Втрати	0,61
Час навчання	13,68 с]

Модель правильно визначила приблизно 78,67 % класів. З урахуванням помилкових спрацьовувань близько 80,21 % позитивних прогнозів виявилися правильними, що вказує на ефективність для більшості виконуваних рухів. Приблизно 75,67 % дій виявлено правильно.

Незважаючи на високу точність, спостерігалися великі втрати, і модель кілька разів допускала значні помилки. З рис. 6 видно, що в моделі присутні як зміщення, так і дисперсія. Для вирішення цієї проблеми необхідно більше даних для навчання або застосування методів регуляризації на проміжних рівнях. Проте, на першому етапі, вирішено проаналізувати поведінку моделі в різних класах.

Рис. 6. Графіки продуктивності моделі: — *a* графік точності; *б* — графік втрат

З рис. 6 випливає, що точність класів є відносно високою.

У зв'язку з цим вирішено детально проаналізувати поведінку моделі у контексті бінарної класифікації. Значення матриці плутанини показані на рис. 7, точність та втрати під час навчання для бінарної моделі показані на рис. 8*a* і 8*b* відповідно.

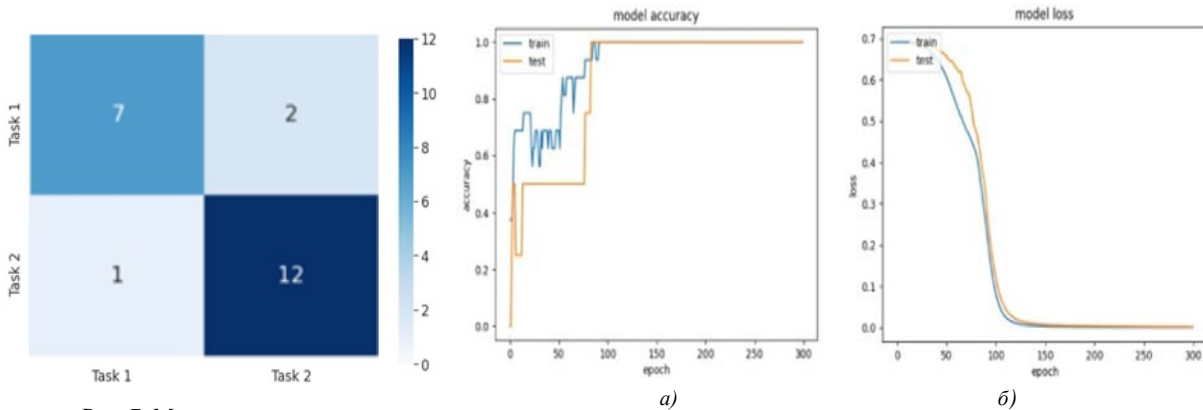
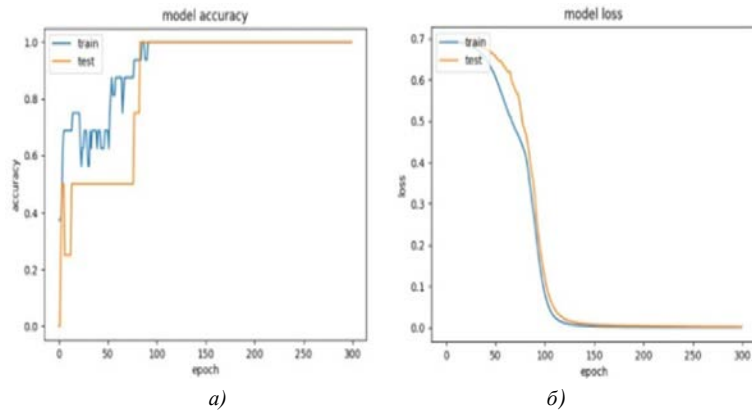


Рис. 7. Матриця плутанини (мультикласова модель)

Рис. 8. Графіки продуктивності моделі (бінарна модель): *a* — графік точності; *b* — графік втрат

Графік втрат вказує на те, що помилка під час навчання та тестування залишалася на подібному рівні. Це свідчить про те, що рівень зміщення та дисперсії в моделі був низьким, що дозволяло їй ефективно узагальнювати.

Висновки

Система обробки сигналів ґрунтується на аналізі поведінки сигналу, на відміну від систем, які використовують інтенсивність сигналу ЕМГ як тригер для забезпечення надійності. У випадку, коли користувач виявляє ознаки м'язової втоми внаслідок тривалого використання, система може охарактеризувати форму сигналу, незалежно від його відносної інтенсивності.

Нейронна мережа успішно класифікувала приблизно 95,13 % класів на основі даних, зібраних від одного суб'єкта. Час класифікації системи становив 0,08 секунди, тоді як час запису даних становив 2 секунди, загальний час реакції протеза становив 2,18 секунди. Використовуючи порогове значення для врахування лише прогнозів з точністю понад 70 %, досягнуто зменшення кількості помилкових прогнозів між класами. Головним пріоритетом було зниження кількості неправильних класифікацій до мінімуму. Іншими словами, коли суб'єкт виконував дію, він утримував жест нерухомо, уникнувши неправильних рухів. У цьому випадку виявлено відсутність явища зміщення або дисперсії в моделі, оскільки помилки під час навчання та тестування були мінімальними. Аналіз точності в різних часових вікнах показав, що збільшення часового вікна під час запису даних не обов'язково приводить до значного підвищення точності моделі. Це пояснюється

тим, що датчики EMG MyoWare мають активний фільтр, який не дозволяє сигналу залишатися активним тривалий час. Таким чином, інформація отримується під час активації м'язів, а не його дезактивації. Зменшення часового вікна може виявитися корисним для зменшення кількості нерепрезентативних даних.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] A. M. Elbreki, S. Ramdan, F. Mohamed, K. Alshari, Z. Rajab, and B. Elhub, "Practical Design of an Upper Prosthetic Limb Using Three Dimensional Printer with an Artificial Intelligence Based Controller," in *Proceedings of the 2022 International Conference on Engineering & MIS (ICEMIS)*, Istanbul, Turkey, Jul. 4-6, 2022, pp. 1-6.
- [2] O. Kerdjadj, K. Amara, F. Harizi, and H. Boumidja, "Implementing Hand Gesture Recognition using EMG on the Zynq Circuit," *IEEE Sensors Journal*, vol. 9, pp. 10054-10061, 2023. <https://doi.org/10.1109/JSEN.2023.3259150>.
- [3] N. M. Hye, U. Hany, S. Chakravarty, L. Akter, and I. Ahmed, "Artificial Intelligence for sEMG-based Muscular Movement Recognition for Hand Prosthesis," *IEEE Access*, vol. 11, pp. 38850-38863, 2023. <https://doi.org/10.1109/ACCESS.2023.3267674>.
- [4] L. C. Zayia, and P. Tadi, "Neuroanatomy, motor neuron," *StatPearls*, StatPearls Publishing, Tampa, FL, USA, 2021.
- [5] L. Mc Manus, G. De Vito, and M.M. Lowery, "Analysis and biophysics of surface EMG for physiotherapists and kinesiologists: Toward a common language with rehabilitation engineers," *Frontiers in Neurology*, vol. 11, p. 576729, 2020. <https://doi.org/10.3389/fneur.2020.576729>.
- [6] D. Mahmood, H. N. Riaz, and H. Nisar, "Advances in Non-Invasive Biomedical Signal Sensing and Processing with Machine Learning: Introduction to Non-Invasive Biomedical Signals for Healthcare," *Springer International Publishing*, Cham, Switzerland, 2023.
- [7] V. Asanza, E. Peláez, F. Loayza, L. L. Lorente-Leyva, and D. H. Peluffo-Ordóñez, "Identification of Lower-Limb Motor Tasks via Brain-Computer Interfaces: A Topical Overview," *Sensors*, vol. 22, p. 2028, 2022. <https://doi.org/10.3390/s22052028>.
- [8] I. Daimiel Naranjo et al., "Radiomics and Machine Learning with Multiparametric Breast MRI for Improved Diagnostic Accuracy in Breast Cancer Diagnosis," *Diagnostics*, vol. 11, p. 919, 2021. <https://doi.org/10.3390/diagnostics11060919>.
- [9] M. A. Gulum, C. M. Trombley, and M. Kantardzic, "A Review of Explainable Deep Learning Cancer Detection Models in Medical Imaging," *Applied Sciences*, vol. 11, p. 4573, 2021. <https://doi.org/10.3390/app11104573>.
- [10] M. Zivkovic, et al. "A Hybrid CNN and XGBoost Model Tuned by Modified Arithmetic Optimization Algorithm for COVID-19 Early Diagnostics from X-ray Images," *Electronics*, vol. 11, p. 3798, 2022. <https://doi.org/10.3390/electronics11223798>
- [11] A. Toro-Ossaba, J. Jaramillo-Tiguerros, J. C. Tejada, A. Peña, A. López-González, and R.A. Castanho, "LSTM Recurrent Neural Network for Hand Gesture Recognition Using EMG Signals," *Applied Sciences*, vol. 12, p. 9700, 2022. <https://doi.org/10.3390/app12199700>.
- [12] Á. L. Valdívieso Caraguay, J. P. Váscónez, L. I. Barona López, and M. E. Benalcázar, "Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks," *Sensors*, vol. 23, p. 3905, 2023. <https://doi.org/10.3390/s23083905>.
- [13] Y. Xu, P. C. Barbosa, J. S. da Cunha Neto, L. Zhang, V. H. C. de Albuquerque, V. Shanmuganathan, and S. Pasupathi, "Development of intelligent and integrated technology for pattern recognition in EMG signals for robotic prosthesis command," *Expert Systems*, vol. 40, p. e13109, 2023. <https://doi.org/10.1111/exsy.13109>.
- [14] K. Dokic, M. Martinovic, and D. Mandusic, "Inference speed and quantisation of neural networks with TensorFlow Lite for Microcontrollers framework," in *Proceedings of the 2020 5th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM)*, Corfu, Greece, Sep. 25-27, 2020, pp. 1-5.
- [15] Y. Fang, J. Yang, D. Zhou, and Z. Ju, "Modelling EMG driven wrist movements using a bio-inspired neural network," *Neurocomputing*, vol. 470, pp. 89-98, 2022. <https://doi.org/10.1016/j.neucom.2021.10.104>.
- [16] A. K. Mukhopadhyay, S. Samui, "An experimental study on upper limb position invariant EMG signal classification based on deep neural network," *Biomed. Signal Process. Control.* 2020;55:101669. <https://doi.org/10.1016/j.bspc.2019.101669>.
- [17] D. Buongiorno, et al., "Deep learning for processing electromyographic signals: A taxonomy-based survey," *Neurocomputing*, vol. 452, pp. 549-565, 2021. <https://doi.org/10.1016/j.neucom.2020.06.139>.
- [18] V. Asanza, et al., "SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi," *IFAC-PapersOnLine*, vol. 54, pp. 388-393, 2021. <https://doi.org/10.1016/j.ifacol.2021.10.287>.
- [19] A. Constantine, V. Asanza, F. L. Loayza, E. Peláez, and D. Peluffo-Ordóñez, "BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control," *IFAC-PapersOnLine*, vol. 54, pp. 364-369, 2021. <https://doi.org/10.1016/j.ifacol.2021.10.283>.
- [20] D. Tinoco-Varela, J. A. Ferrer-Varela, R. D. Cruz-Morales, and E. A. Padilla-García, "Design and Implementation of a Prosthesis System Controlled by Electromyographic Signals Means, Characterized with Artificial Neural Networks," *Micromachines*, vol. 13, p. 1681, 2022. <https://doi.org/10.3390/mi13101681>.
- [21] O. K. Kolesnytskyj, I. V. Bokotsey, and S. S. Yaremchuk, "Optoelectronic implementation of pulsed neurons and neural networks using bispin-devices," *Opt. Mem. Neural Networks*, no. 19, pp. 154-165, 2010. <https://doi.org/10.3103/S1060992X10020062>.

Рекомендована кафедрою біомедичної інженерії та оптико-електронних систем ВНТУ

Стаття надійшла до редакції 9.05.2024

Білий Руслан Ігорович — аспірант кафедри біомедичної інженерії та оптико-електронних систем, e-mail: ram13b.biliy@gmail.com.

Вінницький національний технічний університет, Вінниця

Using a TensorFlow-Based Neural Network for Gesture Recognition and Control of a Bionic Prosthesis

¹Vinnitsia National Technical University

This study analyzes in detail the recognition accuracy of various gestures using a neural network built on TensorFlow to control a bionic prosthesis. By conducting a series of experiments using data sets and model parameters, it is investigated how effectively the neural network recognizes various gestures in the context of prosthesis control. The results of the experiments will allow us to understand the potential limitations and opportunities of this technology for practical application in real conditions. The neural network model and architecture, activation functions and parameters used for training are described. Learning parameters that affect the effectiveness of model learning are also considered. To evaluate the effectiveness of the model, results such as model evaluation metrics, model performance graphs, and confusion matrix are used to evaluate the level of reliability and performance of the trained neural network. Method of collecting electromyography (EMG) data is proposed, which consists in the use of electrical signals arising in muscles during their contraction. This process involves placing electrodes on the surface of the skin over the muscles being analyzed to record the electrical signals that occur at the moment of muscle activity. This approach allows collecting objective data on muscle activity and their movements, which can then be used to train a neural network and further use it in controlling a bionic prosthesis. A series of experiments was conducted to assess the accuracy of recognition of various movements using the trained model. Analyzing the results of the experiments, it is possible to understand how efficiently and reliably the trained model works in real conditions and how suitable it is for practical use in control systems of bionic prostheses.

Keywords: neural network, TensorFlow, gesture recognition, bionic prosthesis, electromyography, recognition accuracy.

Bilyy Ruslan I. — Post-Graduate Student of the Chair of Biomedical Engineering and Opto-Electronic Systems, e-mail: ram13b.bilyy@gmail.com