

СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ
МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

Кваліфікаційна наукова
праця на правах рукопису

П'ЯТАЧЕНКО ВЛАДИСЛАВ ЮРІЙОВИЧ

УДК 004.93.1'

ДИСЕРТАЦІЯ
МОДЕЛІ ТА МЕТОДИ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ
РОЗПІЗНАВАННЯ СИСТЕМОЮ КЕРУВАННЯ ПРОТЕЗОМ КІНЦІВКИ
РУКИ ЕЛЕКТРОМІОГРАФІЧНИХ БІОСИГНАЛІВ

Спеціальність: 122 - комп'ютерні науки

Галузь знань – 12 інформаційні технології

Подається на здобуття ступеня доктора філософії

Дисертація містить результати власних проваджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

_____ В.Ю. П'ятченко

підпис

Науковий керівник

Довбиш Анатолій Степанович

доктор технічних наук, професор

Суми – 2023

АНОТАЦІЯ

П'ятаченко В.Ю. Моделі та методи інформаційної технології розпізнавання системою керування протезом кінцівки руки електроміографічних біосигналів. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 122 «Комп'ютерні науки». – Сумський державний університет, 2023.

Дисертаційна робота присвячена підвищенню точності виконання протезом кінцівки руки когнітивних команд шляхом створення інформаційної технології машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів в рамках функціонального підходу до моделювання когнітивних процесів природного інтелекту при формуванні та прийнятті класифікаційних рішень.

Об'єктом дослідження є слабоформалізований процес машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів за умови неповної визначеності даних, обумовленої довільними початковими умовами формування електроміографічних біосигналів і перетином в просторі ознак класів розпізнавання, які характеризують когнітивні команди для виконання відповідних рухів протезу.

Предметом дослідження є моделі і методи інформаційної технології інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів.

Обрані методи дослідження базуються на принципах і методах інтелектуального інформаційного аналізу даних та інформаційно-екстремальної інтелектуальної технології машинного навчання для побудови високо достовірних і оперативних вирішальних правил; методах математичної статистики для перевірки статистичних гіпотез; методах та характеристиках теорії інформації для оцінки функціональної ефективності інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки

для розпізнавання електроміографічних біосигналів; об'єктно-орієнтованій методології проектування складних систем для розробки інформаційного алгоритмічного та програмного забезпечення здатної навчатися системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів.

Обґрунтовано актуальність теми дисертації, зазначено зв'язок роботи з науковими темами, сформульовано мету та задачі дослідження, визначено об'єкт, предмет та методи дослідження, показано наукову новизну та практичне значення отриманих результатів, наведено інформацію про практичне використання, апробацію результатів та їх висвітлення у публікаціях.

За результатами аналізу сучасного стану та тенденцій розвитку інтелектуальних протезів кінцівок показано, що протези з інвазивною системою зчитування електроміографічних біосигналів характеризуються більшою точністю виконання когнітивних команд у порівнянні з неінвазивною системою. Але інвазивна система зчитування біосигналів потребує хірургічного втручання, створює для особи з інвалідністю некомфортні умови і не забезпечує через недосканалість існуючих інформаційних технологій розпізнавання електроміографічних сигналів відновлення втрачених функцій руки. У порівнянні з протезами руки з інвазивною системою зчитування біосигналів протези з неінвазивною системою зчитування є суттєво дешевшими та зручнішими при їх використанні. Але через високу зашумленість біосигналів, багатовимірність простору ознак розпізнавання і суттєвий перетин в просторі ознак розпізнавання класів розпізнавання, які характеризують основні рухи протезу, розробка інтелектуальних протезів вимагає подолання ускладнень науково-методологічного характеру, на які впливають такі фактори:

- довільні початкові умови формування електроміографічних біосигналів, обумовлених пошкодженням когнітивно-нервового тракту проходження біосигналу;
- перетин класів розпізнавання, що утворює у просторі ознак апріорно нечітке їх розбиття;
- багатовимірність словника ознак і алфавіту класів розпізнавання;

- вплив неконтрольованих факторів, пов'язаних, наприклад, із щільністю прилягання електроміографічних датчиків, їх місцезнаходженням, змінами параметрів живлення, емоційно-психічного стану особи з інвалідністю тощо, що обумовлює зашумленість та спотворення електроміографічних біосигналів відповідних когнітивних команд.

Саме через такі причини алгоритми машинного навчання системи керування протезом руки з використанням відомих методів технології Data Mining, включаючи нейроподібні структури, не забезпечують високу точність виконання когнітивних команд. Тому дисертаційна робота, яка виконана у науковій проблемній лабораторії кафедри комп'ютерних наук Сумського державного університету, є актуальною, оскільки спрямована на розв'язання важливої науково-практичної задачі підвищення функціональної ефективності протезів руки з неінвазивною системою зчитування біосигналів і наближення їх до функціональних можливостей інвазивних при збереженні відносно невисокої собівартості є актуальною.

У дисертаційній роботі дослідження виконувалися у рамках створеної в Сумському державному університеті так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи керування в процесі машинного навчання. Ідея розроблених методів інформаційно-екстремального машинного навчання системи керування протезом кисті руки для розпізнавання електроміографічних біосигналів як і в штучних нейронних мережах полягає в адаптації в процесі машинного навчання вхідного математичного опису до максимальної повної ймовірності прийняття правильних діагностичних рішень. Але основна перевага методів інформаційно-екстремального машинного навчання перед нейроподібними структурами полягає в тому, що вони розроблені у рамках функціонального підходу до моделювання когнітивних процесів, притаманних людині при формуванні та прийнятті класифікаційних рішень. Такий підхід на відміну від штучних нейронних мереж дозволяє методам інформаційно-екстремального машинного навчання надати гнучкість при перенавчанні системи через розширення алфавіту класів розпізнавання.

Водночас побудовані в рамках геометричного підходу вирішальні правила практично є інваріантними до багатовимірності словника ознак розпізнавання. Також варто підкреслити, що машинне навчання здійснюється не в інтерактивному режимі, а автоматично. Крім того, для формування навчальної матриці потрібно на порядок менше зразків, що є важливою перевагою перед нейроподібними структурами.

У дисертаційній роботі розв'язано важливе науково-практичне завдання розроблення інформаційної інтелектуальної технології машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів в рамках функціонального підходу до моделювання когнітивних процесів.

Вперше розроблено функціональні категорійні моделі і на їх основі створено метод інформаційно-екстремального машинного навчання за ієрархічною структурою даних у вигляді декурсивного бінарного дерева, який відрізняється способом побудови декурсивного дерева, що дозволяє оптимізувати структуру дерева і у результаті підвищити достовірність та оперативність розпізнавання електроміографічних біосигналів та забезпечити гнучкість при перенавчанні у разі розширення алфавіту класів розпізнавання;

Вперше розроблено модель та метод інформаційно-екстремального машинного навчання з оптимізацією рівня квантування електроміографічних біосигналів, що дозволяє збільшити повну ймовірність правильного прийняття класифікаційних рішень через використання зрідженої навчальної матриці;

Удосконалено метод інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з оптимізацією періоду квантування за часом електроміографічних біосигналів.

Отримав подальший розвиток метод агломеративного кластер-аналізу, що дозволяє автоматично формувати ієрархічну структуру найближчих сусідніх класів розпізнавання для машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

Усі теоретичні розробки дисертації автор довів до конкретних алгоритмів із використанням запропонованої інформаційної технології синтезу системи

керування протезом кінцівки руки, здатної розпізнавати електроміографічні біосигнали відповідних когнітивних команд. На основі запропонованих моделей, методів та алгоритмів реалізовано засоби інформаційної технології машинного навчання системи керування протезом кінцівки руки, які включають модулі формування вхідного математичного опису, машинного навчання, побудови вирішальних правил та функціонування системи в режимах функціонального тестування та екзамену.

Одержані наукові результати у вигляді інформаційного та програмного забезпечення використано в плані дослідно-конструкторських робіт ТОВ «НВП «Метекол» (акт від 31 липня 2023 р.) та впроваджено у навчальний процес Сумського державного університету (акт від 9 серпня 2023 р.).

Ключові слова: Інформаційно-екстремальне машинне навчання, оптимізація, інформаційний критерій оптимізації, параметр машинного навчання, протез кисті руки, електроміографічний біосигнал, когнітивна команда.

SUMMARY

Piatachenko V.Y. Models and methods of information technology for recognition of electromyographic biosignals by the hand prosthesis control system. – Qualification Scientific Work as a Manuscript.

Thesis for obtaining a doctor of philosophy degree in the field of information technology, specializing in 122 - Computer Science. - Sumy State University, Sumy, 2023.

The dissertation is devoted to increasing the accuracy of the execution of cogitative commands by prosthetic limbs by creating an information technology of machine learning of the hand prosthesis control system for recognition of electromyographic biosignals within the framework of a functional approach to modeling cognitive processes of natural intelligence in forming and making classification decisions.

The object of the research is the loosely formalized machine learning process of the hand prosthesis control system for recognition of electromyographic biosignals under conditions of incomplete data certainty due to the arbitrary initial conditions of the formation of electromyographic biosignals and the feature space intersection of recognition classes, which characterize the cognitive commands for performing the corresponding movements of the prosthesis.

The subject of the research are models and methods of information technology for recognition of electromyographic biosignals within information-extreme machine learning of the hand prosthesis control system.

The chosen research methods are based on the principles and methods of intelligent information analysis of data and information-extreme intelligent technology of machine learning to build highly reliable and operational decision rules methods of mathematical statistics for testing statistical hypotheses; methods and characteristics of information theory for evaluating the functional efficiency of information-extreme machine learning of the hand prosthesis control system for recognition of electromyographic biosignals; object-oriented methodology for the design of complex systems for the development of informational algorithms and software of the capable for machine learning hand prosthesis control system for recognition of electromyographic biosignals.

The relevance of the dissertation topic is substantiated, the connection of the work with scientific topics is indicated, the purpose and tasks of the research are formulated, the object, subject and methods of the research are defined, the scientific novelty and practical significance of the obtained results are shown, information is given about the practical use, approbation of the results and their coverage in publications.

According to the results of the analysis of the current state and trends in the development of intelligent limb prostheses, it is shown that prostheses with an invasive system for recording electromyographic biosignals are characterized by greater accuracy in the execution of cognitive commands in comparison with a non-invasive system.

In contrast the invasive biosignal recording system requires surgical intervention, creates uncomfortable conditions for a person with a disability, and does not ensure the restoration of lost hand functions due to the imperfection of existing information technologies for recognizing electromyographic signals. Prostheses with a non-invasive recording system are significantly cheaper and more convenient to use compared to hand prostheses with an invasive biosignal recording system. Due to the high noise of biosignals, the multidimensionality of the recognition features space and the significant intersection in the features space of recognition classes that characterize the main movements of the prosthesis, the development of intelligent prostheses requires overcoming scientific and methodological complications, which are influenced by the following factors:

- arbitrary initial conditions for the formation of electromyographic biosignals caused by damage to the cognitive-nerve path of biosignal transmission;
- recognition classes intersection, which creates an a priori unclear division of the feature space;
- multidimensionality of the feature dictionary and the alphabet of recognition classes;
- the influence of uncontrollable factors related to the density of attachment of electromyographic sensors, their position, changes in power parameters, the emotional and mental state of a person with a disability, etc., which causes noise, artifacts and distortion of electromyographic biosignals of the corresponding cognitive commands.

It is for these reasons that the machine learning algorithms of the hand prosthesis control system within known methods of Data Mining technology, including neuro-like structures, do not ensure high accuracy of cognitive command execution. Therefore, the dissertation, which was carried out in the scientific problem laboratory of the Department of Computer Sciences of Sumy State University, is relevant, as it is aimed at solving an important scientific and practical task of increasing the functional efficiency of hand prostheses with a non-invasive biosignal recording system and bringing them closer to the functional capabilities of invasive while maintaining a relatively low cost is relevant.

In the dissertation, the research was carried out within the framework of the so-called information-extreme intelligent technology (IEI-technology) of data analysis created at Sumy State University, which is based on maximizing the information capacity of the control system in the process of machine learning. The idea of the developed methods of information-extreme machine learning of the hand prosthesis control system for recognition of electromyographic biosignals, as well as in artificial neural networks approach, is to adapt the input mathematical description to the maximum full probability of making correct diagnostic decisions in the process of machine learning. Despite this the main advantage of information-extreme machine learning methods over neuro-like structures is that they are developed within the framework of a functional approach to modeling cognitive processes inherent in humans when forming and making classification decisions. This approach, unlike artificial neural networks, allows the methods of information-extreme machine learning to provide flexibility in retraining the system through the expansion of the alphabet of recognition classes. At the same time, the decisive rules constructed within the framework of the geometric approach are practically invariant to the multidimensionality of the dictionary of recognition features. It is also worth emphasizing that machine learning is not carried out interactively, but automatically. In addition, the formation of the training matrix requires an far fewer samples, which is an important advantage over neuro-like structures.

In the dissertation work, an important scientific and practical task of developing the information intelligent technology of machine learning of the hand prosthesis control system with a non-invasive system for recording biosignals within the framework of a functional approach to modeling cognitive processes is solved.

The functional categorical models based on the hierarchical structure of data in the form of a decursive binary tree were for the first time developed and a method of information-extreme machine learning was created according to them, which differs in the way of constructing a decursive tree, which allows optimizing the structure of the tree and, as a result, increasing the reliability and efficiency of recognition of electromyographic biosignals and ensuring flexibility during retraining due to the expansion of the alphabet of recognition classes. A model and method of information-

extreme machine learning with optimization of the quantization level of electromyographic biosignals was for the first time developed, which allows to increase the full probability of making the correct classification decisions through the use of a sparse learning matrix. In addition the method of information-extreme machine learning of the hand prosthesis control system with optimization of the time quantization period of electromyographic biosignals has been improved.

The method of agglomerative cluster analysis was further developed, which allows the automatic formation of a hierarchical structure of the nearest neighboring recognition classes for machine learning of the hand prosthesis control system with a non-invasive biosignal recording system.

The author brought all the theoretical developments of the dissertation to determined algorithms using the proposed information technology synthesis of the hand prosthesis control system capable of recognizing electromyographic biosignals of the corresponding cognitive commands. On the basis of the proposed models, methods and algorithms, the means of information technology of machine learning of the hand prosthesis control system have been implemented, which include modules for the formation of input mathematical description, machine learning, construction of decisive rules and functioning systems in the modes of functional testing and examination. The obtained scientific results in the form of information and software were used in the research and development plan of LLC "RPC Metekol" (implementation certificate dated July 31, 2023) and implemented in the educational process of Sumy State University (implementation certificate dated August 09, 2023).

Keywords: Information-extreme machine learning, optimization, information criterion, machine learning parameter, hand prosthesis, electromyographic biosignal, cognitive team.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Наукові праці, в яких опубліковано основні наукові результати дисертації:

[1] А. С. Довбиш, В. В. Москаленко та В. Ю. П'ятаченко, "Інформаційно екстремальне машинне навчання системи керування протезом руки", *Радіоелектронні і комп'ютерні системи*, №4, С. 40-49, 2017. (Особистий внесок: функціональна категорійна модель, вхідний математичний опис та алгоритм машинного навчання системи керування протезом кінцівки руки).

[2] A. S. Dovbysh, V. Y. Piatachenko, J. V. Simonovskiy and O. A. Shkuropat, "Information-extreme hierarchical machine learning of the hand brush prosthesis control system with a non-invasive bio signal reading system", *Radio Electronics, Computer Science, Control*, vol. 4, pp. 178–187, 2020. DOI:10.15588/1607-3274-2020-4-17 (Особистий внесок: функціональна категорійна модель, алгоритм машинного навчання та його програмна реалізація).

[3] A. S. Dovbysh, M. N. Budnyk, V. Yu. Piatachenko and M. I. Myronenko, "Information-Extreme Machine Learning of On-Board Vehicle Recognition System", *Cybernetics and Systems Analysis*, 56(4), pp. 534-543, 2020. DOI: 10.1007/s10559-020-00269-y. (Особистий внесок: алгоритм машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та його програмна реалізація)

[4] В. Ю. П'ятаченко, А. С. Довбиш. "Інформаційно-екстремальне машинне навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів за розрідженою навчальною матрицею". *Вісник Кременчуцького національного університету імені Михайла Остроградського*. – Кременчук: КрНУ, №2(139), с. 57–65, 2023. (Особистий внесок: функціональна категорійна модель, алгоритм інформаційно-екстремального машинного навчання системи керування алгоритм з оптимізацією рівня квантування електроміографічних біосигналів і його програмна реалізація).

Опубліковані праці апробаційного характеру:

[5] А. С. Довбиш, В. Ю. П'ятаченко. “Інтелектуальний протез кінцівки руки з неінвазивною системою зчитування біосигналів”. Четверта міжнародна наукова конференція «Вимірювання, контроль та діагностика в технічних системах», 31 жовтня – 2 листопада 2017 р. Збірник тез доповідей. – Вінниця: ПП «ТД «Едельвейс і К», 2017. – С. 206–207. (Особистий внесок: алгоритм машинного навчання системи керування протезом кісті руки для розпізнавання електроміографічних біосигналів).

[6] J. Simonovskiy, V. Piatachenko and N. Mironenko, “On-board Geographic Information System of Images’ Identification”. Proceeding of the VIth International Conference «Advanced Information Systems and Technologies, AIST 2018» 16-18 May 2018, Sumy, Ukraine, 2018, pp. 115-118. (Особистий внесок: алгоритм машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання).

[7] I. Naumenko, M. Myronenko and V. Piatachenko, “Information-Extreme Learning of On-Board System for Recognition of Ground Vehicles”. Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019) Zaporizhzhia, Ukraine, April 15-19, 2019, pp. 121-132. (Особистий внесок: алгоритм машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та його програмна реалізація).

[8] В.Ю. П'ятаченко, Ю.В. Симоновський, “Інформаційно-екстремальне машинне навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів”. Збірник тез доповідей VI Міжнародної науково-технічної Internet-конференції «Сучасні методи, інформаційне, програмне та технічне забезпечення систем керування організаційно-технічними та технологічними комплексами», м.Київ, Україна, 20 листопада 2019, 2019. – С. 169 – 170. (Особистий внесок: функціональна категорійна модель ієрархічного інформаційно-екстремального машинного навчання).

[9] A. Dovbysh and V. Piatachenko, “Hierarchical Clustering Approach for Information-Extreme Machine Learning of Hand Brush Prosthesis”. Proceedings of the 5th International Conference on Computational Linguistics and Intelligent Systems

(COLINS 2021) 2021, pp. 1706-1715. (Особистий внесок: функціональна категорійна модель і алгоритм машинного навчання системи розпізнавання електроміографічних біосигналів).

[10] В. П'ятаченко, “Агломеративне ієрархічне машинне навчання системи керування протезом кінцівки руки”. Збірник тез доповідей III Міжнародної науково-практичної конференції «Спільні дії військових формувань і правоохоронних органів держави: проблеми та перспективи», м. Одеса, Україна, 22 жовтня 2021 року, 2021. – С. 281-282.

[11] В. П'ятаченко, “Ієрархічна кластеризація біосигналів в процесі машинного навчання системи керування інтелектуальним протезом кінцівки руки”, Збірник тез доповідей XXI Міжнародна науково-технічна конференція Штучний Інтелект та Інтелектуальні Системи (AIPS'2021), м. Київ, Україна, 26-27 листопада 2021 року, 2021. – С. 100-103.

[12] I. Naumenko, V. Piatachenko, M. Myronenko, T. Savchenko, “Information-Extreme Machine Learning of an On-board Ground Object Recognition System with a Choice of a Base Recognition Class”, CEUR Workshop Proceedings of 6th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2022), Gliwice, Poland, May 12-13, 2022, 2022, pp. 1139–1148. (Особистий внесок: функціональна категорійна модель машинного навчання з визначенням базового класу розпізнавання).

Наукові праці, які додатково відображають наукові результати дисертаційної роботи

[13] Свідоцтво про реєстрацію авторського права на твір «Комп'ютерна програма «Програма формування вхідного математичного опису бортової системи розпізнавання наземних малогабаритних транспортних засобів» №88975 Україна / Довбиш А. С., П'ятаченко В.Ю., Мироненко М.І.; СумДУ; дата реєстрації 27.05.2019. (Особистий внесок: алгоритм формування вхідної навчальної матриці та його програмна реалізація).

[14] Свідоцтво про реєстрацію авторського права на твір «Комп'ютерна програма «Інформаційно-екстремальне машинне навчання системи діагностування онкопатологій за зображенням морфології тканини»

№100201 Україна / Довбиш А.С., Романюк А.М., Москаленко Р.А., П'ятаченко В.Ю.; СумДУ; дата реєстрації 05.10.2020. (Особистий внесок: алгоритм і його програмна реалізація для інформаційно-екстремального машинного навчання з паралельно-послідовною оптимізацією контрольних допусків).

[15] Свідоцтво про реєстрацію авторського права на твір «Комп'ютерна програма «Ієрархічне машинне навчання системи керування протезом кінцівки руки з неінвазивним зчитуванням біосигналів» №107707 Україна / Довбиш А.С., Шелехов І.В., П'ятаченко В.Ю.; СумДУ; дата реєстрації 01.09.2021. (Особистий внесок: алгоритм двохкласового інформаційно-екстремального машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та його програмна реалізація).

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ.....	16
ВСТУП.....	17
1.1 Сучасний стан та перспективи розвитку інтелектуальних протезів з неінвазивною системою зчитування біосигналів.....	24
1.2 Аналіз методів оброблення і фільтрації біосигналів.....	27
1.3 Аналіз методів машинного навчання системи розпізнавання біосигналів.....	35
1.4 Висновки до першого розділу.....	66
РОЗДІЛ 2. АНАЛІЗ І СИНТЕЗ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЕРУВАННЯ ІНТЕЛЕКТУАЛЬНИМ ПРОТЕЗОМ РУКИ.....	68
2.1 Аналіз об'єкту дослідження та обґрунтування вибору методу досліджень.....	68
2.2 Формалізована постановка задачі інформаційного синтезу системи керування протезом кінцівки руки для розпізнавання біосигналів електроміографічних датчиків.....	73
2.3 Формування вхідного математичного опису системи розпізнавання біосигналів з неінвазивною системою зчитування.....	77
2.4 Функціональні категорійні моделі машинного навчання системи керування протезом для розпізнавання електроміографічних біосигналів.....	81
2.5 Моделі функціонування системи керування протезом в режимі екзамену.....	87
2.6 Висновки до другого розділу.....	89
РОЗДІЛ 3. ОПТИМІЗАЦІЯ ПАРАМЕТРІВ МАШИННОГО НАВЧАННЯ СИСТЕМИ КЕРУВАННЯ ПРОТЕЗОМ.....	91
3.1 Інформаційно-екстремальне машинне навчання модуля системи керування протезом кисті руки для розпізнавання електроміографічних сигналів.....	91
3.2 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з паралельною оптимізацією системи контрольних допусків.....	97
3.3 Інформаційно екстремальне машинне навчання модуля розпізнавання системи керування протезом за ієрархічною структурою даних у вигляді декурсивного дерева.....	101

3.4 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з агломеративною ієрархічною структурою даних	106
3.5 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з оптимізацією рівня квантування сигналу для формування розрідженої матриці	112
3.6 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з оптимізацією часу квантування сигналу	118
3.7 Висновки до третього розділу.....	120
РОЗДІЛ 4. ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЕРУВАННЯ ІНТЕЛЕКТУАЛЬНИМ ПРОТЕЗОМ РУКИ	123
4.1 Структура та основні функції інтелектуальної системи керування протезом	123
4.2 Засоби інформаційної технології створення системи керування протезом кінцівки руки.....	125
4.3 Структура та основні функції інтелектуальної системи керування протезом в режимі екзамєну	128
4.4 Висновки до четвертого розділу.....	131
ВИСНОВКИ.....	133
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	130
ДОДАТОК А Акти впровадження.....	167
ДОДАТОК Б Список публікацій за темою дисертації	167

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

ІЕІ-технологія – інформаційно-екстремальна інтелектуальна технологія;

ЕМГ-сигнал – електроміографічний сигнал;

ЕЕГ-сигнал – електроенцефалографічний сигнал;

ФВЧ – фільтр високих частот;

ФНЧ – фільтр нижніх частот;

ФКМ – Функціональна категорійна модель;

СКД – система контрольних допусків;

КФЕ – критерій функціональної ефективності;

ШНМ – штучна нейронна мережа.

ВСТУП

Обґрунтування вибору теми дослідження. Створення інтелектуального протезу кінцівки руки дозволяє суттєво розширити його функціональні можливості, забезпечити реабілітацію людини з інвалідністю та її адаптацію до повноцінного життя, що має важливе соціально-економічне значення. Одним із перспективних шляхів підвищення функціональної ефективності протезів кінцівки руки є застосування ідей і методів машинного навчання для розпізнавання електроміографічних біосигналів, сформованих когнітивними командами для відповідних рухів протезу. Дослідження, пов'язані з моделюванням інтелектуальних систем різного призначення у науково-технічній літературі знайшли відносно широке висвітлення завдяки ідеям і науковим здобуткам Івахненка О. Г., Шлезінгера М. І, Шевченка А. І., Бодянського Є. В., Субботіна С. О., Довбиша А. С, Дуди Р., Харта П., Уатта Д. та інших вчених. Водночас питання підвищення функціональної ефективності машинного навчання все ще залишаються недостатньо дослідженими через науково-методологічні ускладнення, пов'язані з неповною визначеністю даних, суттєвим перетином у просторі ознак класів розпізнавання, які характеризують когнітивні команди відповідних рухів протезу кінцівки, руки, великою потужністю словника ознак і алфавіту класів розпізнавання. Крім того, жорсткі вимоги висуваються щодо оперативності прийняття класифікаційних рішень при виконанні протезом когнітивних команд. Тому однією із складних задач, на дослідження якої спрямована дисертаційна робота, є створення інформаційної технології машинного навчання у рамках функціонального підходу до моделювання когнітивних процесів природнього інтелекту природного інтелекту при формуванні та прийнятті класифікаційних рішень. Розв'язання цієї задачі полягає в необхідності створення нових методів формування вхідного математичного опису, машинного навчання і оцінки його функціональної ефективності з метою побудови високо достовірних і оперативних вирішувальних правил, інваріантних до великих обсягів даних.

У порівнянні з протезами руки з інвазивною системою зчитування біосигналів протези з неінвазивною системою зчитування є суттєво дешевшими зручнішими при їх використанні та не потребують хірургічного втручання. Але через високу зашумленість біосигналів, багатовимірність простору ознак розпізнавання і суттєвий перетин в просторі ознак розпізнавання класів розпізнавання розробка інтелектуальних протезів вимагає подолання ускладнень науково-методологічного характеру. Саме через ці причини машинне навчання системи керування протезом руки для розпізнавання електроміографічних біосигналів з використанням відомих методів технології Data Mining, включаючи нейроподібні структури не забезпечують високу точність виконання команд.

Тому тема дисертаційної роботи є **актуальною**, оскільки присвячена вирішенню важливого науково-прикладного завдання – розроблення інформаційної технології машинного навчання системи керування інтелектуальним протезом кінцівки руки для розпізнавання електроміографічних біосигналів, що забезпечує реабілітацію людини з інвалідністю та її адаптацію до повноцінного життя.

Зв'язок роботи з науковими програмами, планами, темами. Дисертаційне дослідження відповідає пріоритетним напрямкам наукових досліджень Сумського державного університету, зокрема держбюджетним науково-дослідним роботам «Інтелектуальний протез кінцівки, що самонавчається» (ДР № 0117U002248), «Інформаційна технологія автономної навігації безпілотного літального апарату за наземними природними та інфраструктурними орієнтирами» (ДР № 0122U000786).

Роль автора в цих науково-дослідних роботах полягала в розробленні математичних моделей, методів інформаційно-екстремального машинного навчання інтелектуальних систем, у тому числі системи керування протезом руки для розпізнавання електроміографічних біосигналів і засобів інформаційної технології її синтезу.

Мета і завдання дослідження. Метою дослідження є підвищення функціональної ефективності системи керування протезом кінцівки руки шляхом створення інформаційної технології машинного навчання.

Для досягнення мети дослідження необхідно вирішити такі **завдання**:

1. проаналізувати сучасний стан розвитку інтелектуальних протезів руки та методів формування вхідного математичного опису інтелектуальної системи керування;

2. розробити метод машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів за ієрархічною структурою даних;

3. розробити математичну модель і метод ієрархічного машинного навчання системи керування протезом для розпізнавання електроміографічних біосигналів відповідних когнітивних команд;

4. розробити метод машинного навчання за розрідженою навчальною матрицею шляхом оптимізації рівня квантування електроміографічних біосигналів;

5. оцінити функціональну ефективність машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів;

6. розробити апаратно-програмний інструментарій машинного навчання системи керування інтелектуальним протезом для розпізнавання електроміографічних біосигналів

Об'єктом дослідження є слабоформалізований процес машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів за умови неповної визначеності даних, обумовленої довільними початковими умовами формування електроміографічних біосигналів і перетином в просторі ознак класів розпізнавання, які характеризують когнітивні команди для виконання відповідних рухів протезу.

Предметом досліджень є моделі і методи інформаційної технології інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів.

Методи дослідження базуються на принципах і методах інтелектуального інформаційного аналізу даних та інформаційно-екстремальної інтелектуальної

технології машинного навчання для побудови високо достовірних і оперативних вирішальних правил; методах математичної статистики для перевірки статистичних гіпотез; методах та характеристиках теорії інформації для оцінки функціональної ефективності інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів; об'єктно-орієнтованій методології проектування складних систем для розробки інформаційного алгоритмічного та програмного забезпечення здатної навчатися системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів.

Наукова новизна отриманих результатів:

Вперше розроблено функціональні категорійні моделі і на їх основі створено метод інформаційно-екстремального машинного навчання за ієрархічною структурою даних у вигляді декурсивного бінарного дерева, який відрізняється способом побудови декурсивного дерева, що дозволяє оптимізувати структуру дерева і у результаті підвищити достовірність та оперативність розпізнавання електроміографічних біосигналів та забезпечити гнучкість при перенавчанні через розширення алфавіту класів розпізнавання;

Вперше розроблено модель та метод інформаційно-екстремального машинного навчання з оптимізацією рівня квантування електроміографічних біосигналів, що дозволяє збільшити повну ймовірність правильного прийняття класифікаційних рішень через використання зрідженої навчальної матриці;

Удосконалено метод інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з оптимізацією періоду квантування за часом електроміографічного біосигналу.

Отримав подальший розвиток метод агломеративного кластер-аналізу, що дозволяє автоматично формувати ієрархічну структуру найближчих сусідніх класів розпізнавання для машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

Особистий внесок здобувача. Дисертаційна робота є самостійним завершеним науковим дослідженням. Положення і результати, винесені на захист дисертаційної роботи, отримані здобувачем особисто. У працях,

опублікованих у співавторстві, автору належать: [1] – розроблення вхідного математичного опису та алгоритму машинного навчання системи керування протезом кінцівки руки; [2] – функціональна категорійна модель, алгоритм і його програмна реалізація для ієрархічного інформаційно-екстремального машинного навчання системи керування протезом; [3] – алгоритм і його програмна реалізація для інформаційно-екстремального машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання; [4] – функціональна категорійна модель, алгоритм та його програмна реалізація для інформаційно-екстремального машинного навчання системи керування алгоритм і його програмна реалізація для машинного навчання протезом з оптимізацією рівня квантування ЕМГ-біосигналів; [5] – опис алгоритму і його програмна реалізація для інформаційно-екстремального машинного навчання системи керування протезом кисті руки для розпізнавання ЕМГ-біосигналів; [6] – алгоритм і його програмна реалізація для інформаційно-екстремального машинного навчання за навчальною матрицею, сформованою за результатами оброблення зображень у полярній системі координат; [7] – опис алгоритму та його програмна реалізація для інформаційно-екстремального машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання; [8] – функціональна категорійна модель ієрархічного інформаційно-екстремального машинного навчання; [9] – функціональна категорійна модель і програмна реалізація інформаційно-екстремального машинного навчання; [12] – функціональна категорійна модель машинного навчання з визначенням базового класу розпізнавання; [13] – алгоритм і його програмна реалізація для формування вхідної навчальної матриці; [14] – алгоритм і його програмна реалізація для інформаційно-екстремального машинного навчання з паралельно-послідовною оптимізацією контрольних допусків; [15] – алгоритм і його програмна реалізація для інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки.

Апробація матеріалів дисертації. Основні положення та результати дисертаційної роботи доповідалися та обговорювалися на Міжнародних наукових конференціях та форумах, а саме: 4-й Міжнародній науковій

конференції «Вимірювання, контроль та діагностика в технічних системах» (м. Вінниця, Україна, 2017 р.); 6-й Міжнародній науковій конференції «Advanced Information Systems and Technologies, AIST-2018» (м. Суми, Україна, 2018 р.); 2-ій Міжнародній конференції «Computer Modeling and Intelligent Systems (CMIS-2019)» (м. Запоріжжя, Україна, 2019 р.); 6-й Міжнародній науково-технічній Internet-конференції «Сучасні методи, інформаційне, програмне та технічне забезпечення систем керування організаційно-технічними та технологічними комплексами» (м.Київ, Україна, 2019 р.); 5-й Міжнародній конференції «Computational Linguistics and Intelligent Systems (COLINS 2021)» (м. Львів, Україна, 2021р.); 3-й Міжнародній науково-практичній конференції «Спільні дії військових формувань і правоохоронних органів держави: проблеми та перспективи» (м. Одеса, Україна, 2021р.); 21-й Міжнародній науково-технічній конференції «Штучний інтелект та інтелектуальні системи, (AIPS'2021)» (м. Київ, Україна, 2021р.); 6-й Міжнародній конференції «Computational Linguistics and Intelligent Systems (COLINS 2022)» (м. Глівіце, Польща, 2022р.).

Практичне значення отриманих результатів. Усі теоретичні розробки дисертації автором доведено до конкретних інженерних методик, алгоритмів з використанням запропонованої інформаційної технології створення здатної навчатися системи керування протезом кінцівки руки. На основі запропонованих моделей, методів та алгоритмів розроблено інформаційне та програмне забезпечення, яке дозволяє підвищити точність виконання протезом кінцівки руки когнітивних команд. Одержані наукові результати можуть бути використані при створенні інтелектуальних протезів руки з різними ступенями її ураження, що потребує більшого обсягу вхідних даних та алфавіту класів розпізнавання. Одержані наукові результати впроваджено в навчальному процесі кафедри комп'ютерних наук Сумського державного університету (акт впровадження від 9 серпня 2023р.) і в науково-виробничому підприємстві Меткол, м Ніжин, Україна (акт використання від 31 липня 2023 р.).

Структура та обсяг дисертації. Дисертація складається із вступу, чотирьох розділів, висновків, списку використаних джерел і додатків. Загальний

обсяг дисертації складає 173 сторінок, з яких анотація на 5 сторінках, зміст на 2 сторінках, перелік умовних позначень на 1 сторінці, основний текст на 118 сторінках, список використаних джерел із 254 найменувань на 32 сторінках, додатки на 6 сторінках. Робота містить 5 таблиць, та 40 рисунків.

РОЗДІЛ 1

АНАЛІЗ МЕТОДІВ СИНТЕЗУ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ КЕРУВАННЯ ПРОТЕЗОМ КІНЦІВКИ РУКИ

1.1 Сучасний стан та перспективи розвитку інтелектуальних протезів з неінвазивною системою зчитування біосигналів

Основною метою розробки протезу кінцівки людини є покращення взаємодії особи з інвалідністю з середовищем шляхом якісної компенсації втрачених функцій організму. Головною рисою інтелектуальних протезів є здатність розпізнавати рухи та відтворювати жести, а не тільки візуально маскувати втрачену кінцівку. Водночас інтерфейс людина-машина є компромісом між алфавітом класів розпізнавання, які характеризують когнітивні команди на виконання протезом відповідних рухів, ефективністю їх розпізнавання, можливості зворотного зв'язку до м'язів та зручності протезу.

Розглянемо основні характеристики сучасних протезів для компенсації рухів руки з різним ступенем її враження.

Протез SCOMA Prosthetic Hand [1] наголошує на використанні сенсорів спротиву для зворотнього зв'язку щодо рухів. Протези DARPA MPL [2] зосереджені на відчуттях тиску, сили, вібрації. Водночас інвазивний спосіб керування дозволяє оптимізувати проблему втоми від ваги протезу та використати залишки нервових закінчень як частину керуючої структури. Протези завжди існують ризики, пов'язані з хірургічним втручанням. Сама ж ідея зворотнього зв'язку від протезу до людини має ваду [3]: природне кодування дотику є не лише задачею інтенсивності, оскільки нервова активність є складнішою за симуляцію індукції нервової активації у волокнах м'язів. Дослідження [4] наводить виклик відчуття володіння протезом за допомогою електростимуляції субдуральних електродів, які через мікроелектроди впливають на соматосенсорну зону мозку та цілеспрямовану реіннервацію – процедуру призначену для полегшення моторного контролю протеза шляхом

збільшення кількості контрольних ділянок на іншій більш проксимальній зоні, яку не зачепила ампутація.

Зі швидким розвитком фізіології, анатомії, мехатроніки та програмного забезпечення з'явилися дослідні та комерційні проекти неінвазивних протезів рук. Порівнюючи комерційні протези можна виявити тенденцію до утворення галузевого стандарту (табл.1.1) для складної системи керування, реєстрації сигналу та його розпізнавання. Наведені протези мають схожий набір рухів та швидкість реакції на імпульс, втім не можна не вказати вади у обмеженому наборі рухів та високій ціні пристроїв.

Таблиця 1.1 – Характеристики сучасних протезів руки

Назва	Вага (г)	Рівень свобод	Кількість активаторів	Швидкість руху	Жести
Vincent Hand	~450	6	6	–	Стискання, вказівний палець, розпрямлення долоні, взяття предмету двома пальцями, гакоподібний рух долоні
iLimb	450–615	6	5	1.2 сек.	Стискання, вказівний палець, розпрямлення долоні, взяття предмету двома пальцями, гакоподібний рух долоні
Bebionic	495–539	6	5	0.8-1.9 сек.	Стискання, вказівний палець, розпрямлення долоні, взяття предмету двома пальцями, гакоподібний рух долоні
Michelangelo	~420	2	2	–	Стискання, розпрямлення долоні

Наведені у таблиці 1.1 протези рук розроблялися з дедалі більшою кількістю ступенів свобод у розпізнавання жестів. Комерційний протез руки

SensorHand [5, 6] є чутливим до сили та швидкості імпульсу для реалізації рухів пальців трьох типів, що реалізують два ступені свободи, потрібні для руху великого пальця, один для приведення/відведення великого пальця та один для згинання/розгинання. Протези i-Limb hand та Bebionic мають відповідно 6 та 5 рівнів свободи та реалізують сенсори тиску для визначення сили стискання об'єкту [7], що передбачає регресивний аналіз сигналів. Через відсутність відповідності та гнучкості в структурі цих роботизованих протезів руки також необхідні додаткові механізми, щоб зробити їх безпечними для фізичної взаємодії з людьми та предметами. Звідси впливає вага протезів рук та складність, потреба в обслуговуванні та вартість, що водночас корелюється з довговічністю суттєво впливають на прийнятність користувачем рішення щодо відмови від протезування руки у 40-60% випадків [5].

Дослідний протез HIT/DLR Prosthetic hand [8] у якості зменшення помилки реконструкції положення руки розглядає синергічні параметри, отримані при зменшенні розмірності простору ознак глобально нелінійним процесом Гауса [9]. Розвитком ідеї адаптації рухів до потреби користувача є протез PRISMA Hand [10, 11], який реалізує п'ять рухів долоні та пальців та розвиває додаткові керуючі структури для зміни характеристик рухів. Модуль керування голосом забезпечує людино-машинну взаємодію для зміни положення кисті, сили та швидкості виконання команди [12]. Подібний керуючий модуль пропонує і протез Galileo Hand [13, 14] для керування шести рухами, включаючи стан спокою, втім наголошуючи, що якість розпізнавання рухів за показниками ЕМГ є нижчою за мультимодальний підхід з використанням МУО інтерфейсу [15].

Оцінка контролюючих алгоритмів протезів KIT Prosthetic hand [16, 17] демонструє доволі високі показники у 78% за протоколом оцінки антропоморфних протезів руки [18]. З метою адаптації руху протезу до об'єкту взаємодії використовується розпізнавання зображень за попередньо підготованою базою знань, яка визначає правила сили та швидкості руху [19].

Аналіз за даними праці [21] сучасних комерційних та дослідних розробок міоелектричних трансгумеральних протезів [20] визначає складність роботи з

ЕМГ сигналом, що обумовлює необхідність розробляти комбіновані алгоритми машинного навчання, які задіюють аналіз компонентів сигналу [21], застосовують фільтрацію сирого сигналу [22], поєднувати різні моделі машинного навчання або застосовувати електроенцефалографічні (ЕЕГ) сигнали як корегуючі імпульси [23, 24].

1.2 Аналіз методів оброблення і фільтрації біосигналів

Електроміографічний (ЕМГ) сигнал – це біомедичний сигнал, що відповідає електричній сталій, породженій нервово-м'язовою активністю у тканинах м'язів. Вся нервово-м'язова активність, напруження і розслаблення, контролюється нервовою системою людини. Тому ЕМГ сигнал є складеним сигналом, залежним від анатомічного та фізіологічного стану м'язів. Крім того рух електричного імпульсу крізь м'язову тканину викликає зашумленість при реєстрації сигналу. ЕМГ сенсор, розташований на шкірі, одночасно реєструє сигнали від різних наборів м'язів; перетин сигналів та фізичні властивості середовища також впливають на отримані значення біопотенціалів. Оскільки сигнал ЕМГ є біоелектричним сигналом, який контролюється взаємним впливом рецепторів і нервової системи людини, модель сигналу ЕМГ залежить як від суб'єктивних намірів користувача, так і від умов інтерактивного середовища під час виконання конкретних дій. Верхні кінцівки людського тіла включають передпліччя, лікоть, тилу руку, зап'ястя та кисть. М'язова маса верхньої кінцівки, як правило, невелика і струнка, а діапазон рухів верхньої кінцівки не великий. У порівнянні з нижніми кінцівками, сила м'язів верхніх кінцівок, як правило, слабша, тому що тіло не потребує підтримки. Основні функції верхніх кінцівок – це захоплення, розтягування та передача інформації жестами. Таким чином, біосигнали у верхній кінцівці можна розділити на дві категорії: положення кінцівок і жести руками.

Сенсорна система для збору сигналів ЕМГ в основному складається з електродів, підсилювачів, мікропроцесорів і пристроїв передачі. Електричний сигнал, що генерується м'язом, вловлюється електродами, посилюється схемою

підсилення, а потім передається на головний комп'ютер через пристрій передачі. Як правило, з'єднання між електродами і процесором є дротовим, тоді як передача зазвичай бездротова. У колекції ЕМГ конструкція сенсорного модуля зазвичай дуже схожа, за винятком електрода. Звичайні електроди ЕМГ включають два основних типи методів розміщення полюсів: монополярний електрод і біполярний електрод. Обидва методи розміщення вимірюють потенціал з посиленням на електрод, розміщений у місцях без відповіді ЕМГ (наприклад, щиколотки або коліно), тоді як метод монополя безпосередньо вимірює різницю потенціалів, а біполярний метод застосовує метод диференційного посилення [25]. Біполярні електроди мають вищу частоту використання, оскільки синфазний шум можна придушити в реальному застосуванні, але не має гнучкості налаштування в порівнянні з монополями. Крім того, на якість сигналу ЕМГ також впливає відстань між кожним електродеполем, а також їх діаметр і ширина при застосуванні біполярних електродів. Сучасні поверхневі електроди ЕМГ приклеюються до поверхні м'язів і уникають небезпеки потенційного пошкодження тканини м'язів, що вважається критичною проблемою при інвазивному зчитуванні ЕМГ. Крім того, під час використання ЕМГ оператори можуть вільно вибирати точки вимірювання на поверхні м'язової тканини і скорочувати витрати часу на проведення підготовчої роботи, як дезінфекція точок зонда спиртом. Тим не менш, останнім часом також були представлені деякі сміливі спроби застосування внутрішньом'язової ЕМГ [2, 3]. Внутрішньом'язова ЕМГ є ще одним джерелом сигналу для виявлення поведінки людського тіла та справляється з деякими труднощами, пов'язаними з контролем на основі ЕМГ, такими як нестабільний контакт електрода зі шкірою. Деякі інші додаткові переваги внутрішньом'язової ЕМГ наведені в [26], наприклад, здатність записувати глибокі м'язові сигнали з невеликими перехресними ЕМГ. Хоча всі експериментальні результати в [2–4] доводять, що внутрішньом'язова ЕМГ не може призвести до зменшення помилки класифікації від ЕМГ для окремих класифікаторів, тоді як для паралельних класифікаторів можна досягти значного зменшення помилки класифікації. Відповідно до практичних зусиль у [3],

паралельна конфігурація для одночасного контролю стає більш перспективною завдяки використанню внутрішньом'язової ЕМГ, яка довгий час була не вирішеною проблемою в дослідженнях ЕМГ.

Підсилення та фільтрація сигналу відіграють критичну роль у системах, що використовують ЕМГ сенсори. Від процесу реєстрації біопотенціалів вимагається зберегти максимальну кількість інформації з мінімальною кількістю шуму у сигналі [29]. Так завдання підсилення сигналу та фільтрації зводиться до максимізації відношення сигналу до шуму та мінімізації спотворення сигналу.

Так як протез являє собою пристрій, що носить, то на нього постійно впливає навколишнє середовище: наявність поту на шкірі призводить до погіршення її контакту з електродами, також можлива поява механічного впливу на електроди. Крім того, слід брати до уваги ефект поляризації електродів, наявність високого імпедансу шкіри, надійність кріплення електродів та ін. Внаслідок того, що амплітуда ЕМГ-сигналу відрізняється у різних людей та для різних видів м'язів, доводиться вибирати регулювання коефіцієнта підсилювача у досить широких межах.

Точна реєстрація потенціалу здійснюється за рахунок безпосереднього контакту датчика із тілом. У цьому випадку між датчиком та шкірою вводиться електропровідний гель. Хоча наявність гелю призводить до значного покращення якості контакту, це може призвести до серйозних вад. Гель може поширитися по поверхні тіла, внаслідок чого утворюється коротке замикання між датчиками. Наступним недоліком застосування гелю є неможливість проводити довготривалі вимірювання, оскільки гель може висихати. Наявність гелю в контакті не дозволяє організувати динамічні виміри, тобто коли пацієнт зазнає фізичного навантаження. Також зсув всього на 1 см знизить точність класифікації на 5-20% [30]. Навіть коли пацієнт виконує ту саму дію в тому самому середовищі, прикладена м'язова сила може дещо змінюватися через неможливість ідеально керувати тілом, що призводить до змін сигналів ЕМГ вибраних м'язів і зниження якості даних [31]. Просунуті засоби реєстрації та виявлення можуть бути можливими рішеннями проблеми низької якості даних. Завдяки інтеграції та мініатюризації сенсорних ланцюгів, ЕМГ високої

щільності (HD-ЕМГ) стала багатообіцяючим підходом до виявлення та реєстрації сигналів [32].

Діапазон коливань ЕМГ сигналу становить 0-10 mV (+5 до -5) до підсилення сигналу [33]. В цей сигнал входить електричний шум, який можна поділити на категорії:

1) Власний шум від електронного обладнання. Будь-яке електронне обладнання генерує шум, який неможливо повністю усунути. Вплив такого шуму можна лише зменшити за використання більш надійних та якісних компонентів системи реєстрації сигналів.

2) Шум навколишнього середовища. Джерелом такого шуму є електромагнітне випромінювання. Поверхня шкіри постійно вкрита електромагнітним полем, також майже неможливо уникнути електромагнітного впливу поверхні землі.

3)Arteфакти руху – спотворення інформації через зміщення рухомих частин системи сенсорів: інтерфейсу електроду або електричних кабелів системи.

4) Нестабільність сигналу. Амплітуда ЕМГ має випадковий характер, залежний від перепадів потужності джерела енергії.

Більшість шумів, що є в сигналі, високочастотні: шуми електронних пристроїв, навколишнє електромагнітне випромінювання, паразитні взаємонаведення з'єднувальних проводів електродів. Спотворення сигналу можуть виникати через побічний вплив сигналів електричної активності серця, зрушення електродів щодо призначеного положення, зміни біопотенціалів на референті при використанні референтної схеми вимірювання [34].

На високочастотному кінці спектру сигналу ЕМГ кутова частота фільтра нижніх частот (межа частотної характеристики фільтра, де енергія сигналу послаблюється на 3 дБ), повинна бути встановлена там, де амплітуда шумових компонентів перевищує амплітуду сигналу ЕМГ. Отже, для верхнього кінця частотного спектру ЕМГ бажано мати кутову частоту низьких частот у діапазоні 400–450 Гц.

Два власних джерела шуму виникають в електроніці системи посилення (тепловий шум) і на межі розділу шкіра-електрод (електрохімічний шум), відповідно. Разом ці джерела шуму утворюють базовий шум, який виявляється щоразу, коли датчик прикріплюється до шкіри. Додаткове джерело шуму, шум артефакту руху, також виникає на поверхні інтерфейсу електрод-шкіра. Він утворюється, коли: м'яз рухається під шкірою і коли імпульс сили проходить через м'яз і шкіру під датчиком, викликаючи рух на межі розділу електрод-шкіра. Результируюча змінна в часі напруга, що створюється на двох електродах, може бути найбільш проблемним із джерел шуму і вимагає найбільшої уваги. Видалення компонентів низькочастотного шуму зробить сигнал ЕМГ більш корисним для практичних застосувань [35].

Фільтри можуть поділятися на категорії та підкатегорії. Найбільш поширені з них – активні та пасивні; високочастотні, низькочастотні, смугові, режекторні та фазові; цифрові та аналогові; дискретні та тривалі за часом; лінійні та нелінійні; за нескінченною імпульсною характеристикою та з скінченною імпульсною характеристикою [36, 37]. Приклад розподілу частотних характеристик найбільш поширених фільтрів показано на рисунку 1.1 [37].




Рисунок 1.1 – Частотні характеристики: *a* – фільтр нижніх частот, *б* – фільтр високих частот, *в* – смуговий фільтри, *г* – режекторний фільтр

Вихідний сигнал ФВЧ завжди має двополярний характер з нульовою середньою інтегральною складовою, що означає – на виході ФНЧ відсутня постійна складова сигналу (за винятком залишкового зміщення нуля, яке може бути присутнім в активних аналогових фільтрах) [38].

Сигнал послаблюється або гаситься на низьких частотах, а вихідний сигнал зростає на +20 дБ/декаду, поки частота не досягне граничної точки (f_c).

Точку частоти зрізу для фільтра високих частот першого порядку можна знайти за допомогою відомої формули:

$$f_c = \frac{1}{2\pi RC}, \quad (1.1)$$

де R – опір резистору;

C – ємність конденсатору.

Найпопулярнішими фільтрами для обробки ЕМГ сигналу є смугові фільтри низьких частот, а саме фільтри Баттерворта, Чебишева, Бесселя та Вінера.

Фільтрація Вінера – це один з перших методів, розроблених для скорочення рівня випадкових шумів в сигналі. Вона заснована на положенні, що аддитивний шум – це стаціонарний випадковий процес, незалежний від частоти сигналу; алгоритм мінімізує квадратичну помилку між вихідним і відновленим набором імпульсів [39]. Фільтрація Вінера є фільтром низьких частот, але замість єдиного відрізка частоти, фільтр використовує нижню частоту зрізу в областях з малою деталізацією сигналу та верхньою частотою зрізу для збереження деталей в областях з високими відхиленнями [40]. За відсутності шуму фільтр Вінера перетворюється на інверсний фільтр. Отже, в області низьких частот, де, як правило, відношення сигнал/шум велике, передатні функції інверсного та вінерівського фільтрів практично збігаються.

За рахунок використання інформації про спектральні характеристики зображення і шуму, фільтр Вінера має відносно високу стійкість до перешкод і у нього відсутня сингулярність, обумовлена нулями передатної функції формуючої системи. Основним недоліком фільтра Вінера залишається наявність крайових ефектів, які виявляються у вигляді осцилюючої перешкоди, що маскує відновлений сигнал.

Передатна функція фільтру Бесселя складається виключно з полюсів, і не має нулів. Фільтр Бесселя дає постійний час затримки сигналів різних частот у

широкому діапазоні частот [41, 42]. Математично це співвідношення можна виразити так:

$$C = -\Delta\theta \times \Delta f, \quad (1.2)$$

де C – константа;

θ – фаза в градусах;

f – частота в Гц.

Фільтр Бесселя має найбільш плоску ділянку кривої часу запізнення в смузі пропускання, подібно до того, як фільтр Баттерворта має найбільш плоску амплітудно-частотну характеристику. За сталість часів запізнення у фільтрі Бесселя доводиться поступитись тим, що його амплітудно-частотна характеристика має ще більш пологі перехідну ділянку між смугами пропускання і затримування, ніж у характеристики фільтра Баттерворта [43].

Фільтр Баттерворта забезпечує найбільш плоску характеристику смуги пропускання, що досягається ціною плавності характеристики у перехідній області, тобто між смугами пропускання та затримування [44]. Його амплітудно-частотна характеристика задається такою формулою:

$$\frac{U_{out}}{U_{in}} = \frac{1}{\sqrt{1 + (\frac{f}{f_c})^{2n}}}, \quad (1.3)$$

де n визначає порядок фільтра (кількість полюсів).

Збільшення числа полюсів дає можливість зробити більш плоскою ділянку характеристики у смузі пропускання та збільшити крутість спаду від смуги пропускання до смуги придушення [45]. Характеристика фільтру йде горизонтально, починаючи від нульової частоти, перегин її починається на частоті зрізу - ця частота зазвичай відповідає точці -3 дБ.

У більшості застосувань найістотнішою обставиною є те, що нерівномірність характеристики у смузі пропускання має перевищувати певної величини. Фільтр Чебишева відповідає цій вимозі, при цьому допускається деяка

нерівномірність характерності у всій смузі пропускання, але при цьому сильно збільшується гострота її зламу [46]. Для фільтра Чебишева задають кількість полюсів та нерівномірність у смузі пропускання. Допускаючи збільшення нерівномірності у смузі пропускання, отримуємо гостріший злам [47]. Амплітудно-частотна характеристика цього фільтра визначається наступним співвідношенням

$$\frac{U_{out}}{U_{in}} = \frac{1}{\sqrt{1 + \varepsilon^2 C_n^2 \left(\frac{f}{f_c}\right)^{2n}}}, \quad (1.4)$$

де C_n - поліном Чебишева першого роду ступеня n ,

ε - константа, що визначає нерівномірність характеристики в смузі пропускання.

Фільтр Чебишева, як і фільтр Баттерворта, має фазочастотні характеристики, далекі від ідеальних [48]. На рис. 1.2 представлені для порівняння характеристики 6-полюсних фільтрів нижніх частот Чебишева та Баттерворта.




Рисунок 1.2 – Порівняння характеристик 6-полюсних фільтрів нижніх частот. Характеристики –полюсних фільтрів нижніх частот у логарифмічному (а) і в лінійному (б) масштабі. 1 - фільтр Бесселя; 2 - фільтр Баттерворта; 3 - фільтр Чебишева (пульсації 0,5 дБ).

Активні фільтри, побудовані з елементів, номінали яких мають деякий допуск, матимуть характеристику, що відрізняється від розрахункової, а це

означає, що в характеристиці фільтра Баттерворта завжди буде нерівномірність у смузі пропускання [49].

Таким чином, застосування смугових фільтрів низьких частот дозволяє зменшувати спотворення ЕМГ-сигналів, але їм притаманна нерівномірність характеристики у смузі пропускання. У зв'язку з цим перевагу слід віддавати фільтру Чебишева, який, допускаючи збільшення нерівномірності у смузі пропускання, дозволяє отримувати гостріший злам амплітудно-частотної характеристики.

1.3 Аналіз методів машинного навчання системи розпізнавання біосигналів

Машинне навчання системи розпізнавання біосигналів розглядається, як комбінація традиційних задач машинного навчання: класифікації, кластеризації та регресії [50]. Ці задачі можна також поділити на дві групи за втручанням людини в процес навчання системи: класифікація та регресія належать до задач машинного навчання з учителем, а кластеризація – без учителя.

У машинному навчанні з учителем використовуються дані, які є «помічені» [51], тобто яких навчальні дані містять приклади вхідних векторів разом із відповідними цільовими векторами. Орієнтуючись на навчальні дані, з існуючими в них зв'язками у «позначених» даних створюється принцип визначення закономірностей, який буде справедливим і для невідомих реалізацій [52]. Навчання з учителем дозволяє генерувати нові дані за попередньо існуючими наборами та оптимізувати критерії ефективності, виходячі з попереднього досвіду експерта. Машинне навчання з учителем використовується для опису завдань прогнозування, оскільки метою є прогнозування, або класифікація, конкретного результату за позначеними даними. Подібний тип навчання застосовується для задач з великою кількістю даних, за необхідності визначення прогностичних оцінок [53].

У таблиці 1.2 наведено популярні методи рішення задач машинного навчання відносно мети та типу навчання.

Таблиця 1.2 – Методи машинного навчання

Задача	Класифікація	Кластеризація	Регресія
Навчання	З учителем	Без учителя	З учителем
Методи	<p>k-найближчих сусідів (K-Nearest Neighbors);</p> <p>Опорні вектори (Support Vector Machines);</p> <p>Класифікатор дерева рішень (Decision Tree Classifier);</p> <p>Випадковий ліс (Random Forests);</p> <p>Наївний байесовський метод (Naive Bayes);</p> <p>Лінійний дискримінантний аналіз (Linear Discriminant Analysis);</p> <p>Штучні нейронні мережі;</p> <p>Інформаційно-екстремальний класифікатор.</p>	<p>k-середніх(k-mean);</p> <p>Ієрархічна кластеризація (Hierarchical Clustering);</p> <p>t-розподілене вкладення стохастичної близькості (t-distributed Stochastic Neighbor Embedding, t-SNE);</p> <p>Заснована на густині просторова кластеризація для додатків з шумом (DBSCAN);</p> <p>Штучні нейронні мережі.</p>	<p>Лінійна регресія (Linear Regression);</p> <p>Нелінійна регресія (Non-Linear Regression);</p> <p>Логістична регресія (Logistic Regression);</p> <p>Штучні нейронні мережі.</p>

Задачами класифікації прийнято вважати такі задачі, мета яких присвоїти кожному вхідному вектору одну з кінцевої кількості дискретних категорій. Якщо ж бажаний результат складається з однієї або кількох безперервних змінних, то завдання називається регресією. Щодо задач розпізнавання образів вхідні дані яких не містять цільових векторів розглядаються методи навчання без учителя. Мета такого навчання, пов'язаного з ідеєю кластеризації, виявити групи

подібних реалізацій у вхідних даних, або розділити у просторі ознак дані вхідного математичного опису, або зменшити розмірність простору ознак.

В області розпізнавання образів концепція невизначеності є ключовою, оскільки дані можуть містити шуми, артефакти, чи проблеми розмірності та масштабування [54]. Так імовірнісні моделі явно враховують невизначеність. Теорія ймовірностей забезпечує послідовну структуру для кількісної оцінки та маніпулювання невизначеністю і формує одну з центральних основ для розпізнавання образів.

Розглянемо процес категоризації вхідного математичного опису на прикладі моделі лінійного класифікатора, у якому вхідний вектор x можна віднести до одного з K класів розпізнавання C_k , де $k = 1 \dots K$. Розглядаючи класи як такі, що не перетинаються, вирішальні правила розпізнавання мають представлення розбиття простору ознак на поверхні рішень. Лінійні класифікатори розглядають такі поверхні як лінійні функції вхідного вектору x , отже визначені за $D - 1$ поверхнями у D -вимірному просторі. Імовірнісні моделі у випадку двоальтернативних гіпотез пропонують бінарне представлення задачі, у якому цільова змінна $t \in \{0,1\}$ така, що $t = 1$ представляє клас C_1 , а $t = 0$ – клас C_2 . Значення t можна інтерпретувати як ймовірність того, що реалізація належить класу C_1 , при цьому ймовірності приймають лише крайні значення 0 і 1. Для $K > 2$ класів зручно використовувати схему кодування 1 з K , у якій t дорівнює вектору довжини K такому, що якщо клас є C_j , то всі елементи t_k з t дорівнюють нулю крім елемента t_j , який приймає значення 1. Змінну t_k можна інтерпретувати як ймовірність належності класу C_k .

Розглянемо найпопулярніші методи вирішення задач класифікації.

Метод k -найближчих сусідів (kNN) – це алгоритм машинного навчання класифікаційних моделей, у якому k -кількість сусідніх об'єктів у просторі ознак, які порівнюються з невідомим об'єктом. У роботі з даними класів формуються відстані для визначення найближчого класу до невідомої розпізнаваної реалізації. Збільшення значення k підвищує значення достовірності класифікації, проте кордони класів розмиваються і збільшується можливий перетин класів.

Алгоритм традиційно поділяють на два етапи: навчання та класифікацію. В процесі навчання системою фіксуються вектори та мітки класів розпізнавання та визначається значення k , число сусідів. На наступному етапі визначаються найближчі, за обраною метрикою, реалізацій до невідомого класу та висувається гіпотеза належності тому класу, якому належить більшість з k реалізацій-сусідів. Втім подібний метод не передбачає вплив значущості ознак розпізнавання та припускає можливість неоднозначного визначення класу. Тому для прийняття рішення використовується функція поєднання, combination function [55]. У базовому алгоритмі розглядається так зване просте невважене голосування (simple unweighted voting). При цьому передбачається, що всі реалізації k мають однакове право «голосу» незалежно від відстань до класифікованого об'єкта. Проте, чим далі реалізація розташована від об'єкту, що класифікується, в просторі ознак, тим нижче її значимість для визначення класу. Тому для покращення результатів класифікації вводять зважування реалізацій залежно від їхньої віддаленості, зважене голосування (weighted voting) [56].

Алгоритм kNN – чутливий до навчальних даних системи і може зміщувати класифікаційне рішення в бік найбільш представленого класу, оскільки його реалізації частіше потрапляють у кількість ближчих сусідів [57, 58]. Розглядаючи недоліки методу, варто зазначити відсутність створення моделей, які узагальнюють попередній досвід та підвищені вимоги до репрезентативності даних. Також метод використовує всі доступні дані для формування класифікаційного рішення, що означає обробку великої кількості даних та високе використання ресурсів системи [59]. Зі збільшенням обсягів баз даних методи машинного навчання майже не можуть бути виконані однією обробною машиною за прийнятний час [60]. Для вирішення цієї проблеми розглядають підходи: використання високопродуктивних обчислювальних систем або зменшення обсягу необхідних обчислень, шляхом алгоритмічних перетворень даних – таких, як кластеризація вхідних даних [61, 62].

Головна ідея методу SVM як класифікатора [63] полягає в пошуку рівняння розділяючої гіперплощини $w_1x_1 + w_2x_2 + \dots + w_nx_n + w_0 = 0$ у просторі ознак, яка оптимально розділить навчальні класи розпізнавання у просторі. На етапі

навчання алгоритм будує функцію $F(x) = y$, яка приймає аргументом x об'єкт з простору \mathcal{R}^n і повертає мітку класу y . У загальному вигляді перетворення F об'єкту x у мітку класу Y має вигляд

$$F(x) = \text{sign}(w^T x - b), \quad (1.5)$$

де $w = (w_1, w_2, \dots, w_n)$ - ваги алгоритму, а $b = -w_0$ - відхилення.

Функція sign (1.5) зберігає в собі лінійну комбінацію ознак об'єкта з його вагами алгоритму. Після налаштування ваг та відхилення алгоритму, власне навчання системи до бінарної класифікації, всі об'єкти, які попадають на одну сторону побудованої гіперплощини, визначаються як перший клас, решта – другий.




Рисунок 1.3 – Розбиття простору ознак гіперповерхнею та формування роздільної полоси.

Розділяюча гіперплощина у алгоритмі опорних векторів будується таким чином, щоб об'єкти класів були розміщені у просторі з максимальною відстанню між гіперплощиною та об'єктами класів, які розташовані ближче за все до площини (рис. 1.3) [64]. Саме ці об'єкти і є опорними векторами. Для того, щоб розділяюча гіперповерхня якомога далі відстояла від точок вибірки, ширина полоси має бути максимальною. Вектор w — вектор нормалі до розділяючої гіперповерхні. Вивід правил налаштування ваг алгоритму має вигляд

$$\langle x_+ - x_-, w / \|w\| \rangle = \frac{\langle x_+, w \rangle - \langle x_-, w \rangle}{\|w\|} = \frac{(b+1) - (b-1)}{\|w\|} = 2 / \|w\| \rightarrow \max;$$

$$\|w\| \rightarrow \min; (w^T w / 2) \rightarrow \min. \quad (1.6)$$

Відступом об'єкту x від границі класів називається величина $M = y(w^T x - b)$, де $w^T x$ – скалярний добуток вектора ваг та вхідного вектору. Алгоритм припускає помилку на об'єкт тоді, і тільки тоді, коли відступ M від'ємний, коли y та $w^T x - b$ мають різні знаки. Якщо $M(0,1)$, то об'єкт потрапляє всередину розділяючої полоси; якщо ж $M > 1$, то об'єкт x класифікується коректно, та розташований віддалено від розділяючої полоси.

Алгоритм SVM напряду залежить від інформації, отриманої при дослідженні вхідних даних і частіше за все приміняється у задачах з обмеженим, не великим, набором даних – як текстова класифікація, або для задач з структурованими даними зв'язок (feature engineering) [65, 66]. З метою зменшення класифікаційних помилок алгоритм максимізує розділяючу полосу і зводиться до задачі квадратичного програмування випуклої області [67]. Це також означає, що задача завжди має одне рішення – роздільна гіперповерхня, яка задовольняє вимогам, завжди одна. Так метод є здатним до роботи з багатомірним простором ознак [68, 69], проте вимагає довгого часу навчання та є нестійким до шуму, артефакти у навчальних даних стають опорними об'єктами-порушниками і впливають на побудову роздільної гіперповерхні. Крім того методи побудови ядер класу та спрямовуючих просторів вимагають додаткових ресурсів на підбір корисних даних у випадку лінійної нероздільності класів [70, 71].

Логічним постає наступний метод автоматичного аналізу даних, здатний до обробки великих масивів вхідного матеріалу [72] – дерево рішень. Цей інструмент вважається ефективним для інтелектуального аналізу даних та предиктивної аналітики [73].

Дерево рішень являє ієрархічну деревоподібну структуру з правилами у вигляді умовних конструкцій типу «якщо А, то В». Ці правила формуються в процесі навчання за навчальною множиною і можуть бути використані як для задач класифікації [72, 74], так і для задач регресії [75].

Генерація правил відбувається з узагальнення множини навчальних прикладів, що описують предметну область, тобто процесу індукції [76]. Саме тому правила отримали назву індуктивні, а сам процес навчання у методі – індукція дерев рішень [77].

Парадигма навчання з учителем передбачає, що для навчальної множини існують моделі, або конкретніше для набору вхідних реалізацій існують цільові значення. За цими цільовими змінними розглядають дерева класифікації, для дискретних цільових змінних, та дерева регресії, для неперервних цільових змінних.

Відповідно до ієрархічної структури дерева [78] метод спирається на елементи двох типів: вузли та листя. Вузли мають в собі вирішальні правила і виконують перевірку реалізації на відповідність існуючим прикладам класів у моделі. У найпростішому випадку реалізація попадає у вузол, де відбувається умовна перевірка [79], за якою реалізація потрапляє у один з двох підпросторів ознак: перший підпростір відповідає виконанню умови правила, друга – не відповідає. Процедура повторюється для нових правил з вузлів до знаходження останнього вузла у ланці, листа, у якому не відбувається перевірка правила, і зупинки алгоритму. У листі міститься підмножина об'єктів, які відповідають всім правилам гілки з вузлами, яка закінчилась цим листом. Лист визначає рішення для кожної реалізації, яка попала в його підпростір. Для дерева класифікації це клас, який асоціюється з вузлом; для дерева регресії ж розглядається відповідний листу модальний інтервал цільової змінної. До кожного листа формується унікальний шлях, таким чином, що реалізація, за відповідності всім правилам гілки, може потрапити виключно в один лист, забезпечуються винесення єдиного рішення.

Алгоритм базується на концепті «жадібного алгоритму» [80], за яким можливе оптимальне рішення на кожному розбитті простору у вузлі та парадигмі «розділяй і володарюй» [81] при формуванні ієрархічних структур простору ознак. Вхідний математичний опис системи містить множину S , яка складається з n реалізацій, для кожної з яких задана мітка класу $C_i (i = 1..k)$; m ознак $A_j (j = 1..m)$, які визначають належність реалізації певному класові.

За алгоритмом [82, 83] розглядаються наступні випадки розмітки вхідних даних. Якщо реалізації множини S мають однакову мітку C_i , то всі навчальні приклади відносяться до одного класу. Отже у моделі всі реалізації представляють один клас – дерево є одним листом, асоційованим з класом C_i . Подібне розбиття вхідних даних зумовлює ситуацію, за якою всі невідомі об'єкти розпізнаються як один клас – що не є оптимальним рішенням задачі. Якщо ж множина S — пуста множина без реалізацій, то сформований лист, буде представляти інший клас з множини класів, батьківський клас у ієрархічній структурі.

Більшість алгоритмів машинного навчання на основі дерева рішень спирається на розмітку вхідних даних [84, 85], за якою множина S складається з навчальних реалізацій всіх класів C_k . Розбиття вхідної множини на підмножини, відповідні класам розпізнавання, відбувається через обрання ознаки з A_j множини S , з двох чи більше унікальних значень $a_1, a_2 \dots a_p$, де p – число унікальних значень ознаки. Множина S ділиться на p підмножин за реалізаціями з відповідними значеннями ознак. Процес розбиття виконується поки всі реалізації результуючої підмножини не залишаться такими, що належать одному класу. Цей алгоритм формує деревоподібну структуру згори вниз, тобто від кореневого вузла до листа.

Формування дерева рішень виконується поетапно, починаючи з процедури вибору ознаки для виконання розбиття у вузлі. Обрана ознака має розбивати множину так, щоб результуючі підмножини містили реалізації з однаковими мітками класу [85] або були максимально наближені до цього, тобто мінімізувати кількість реалізацій чужих класів [83].

Інформаційна ентропія [86], як міра неоднорідності підмножини за представленими класами, представлена формулою:

$$H = - \sum_{i=1}^n \frac{N_i}{N} \log \left(\frac{N_i}{N} \right), \quad (1.7)$$

де n – кількість класів в підмножині,

N_i – число реалізацій i -го класу,

N – загальна кількість реалізацій в підмножині.

Якщо класи представлені в рівних частках у вхідному наборі даних, а невизначеність класифікації максимальна, ентропія також сягне максимальних значень [86], на противагу якщо ж всі реалізації вузла належать одному класу – логарифмічна оцінка перетворить ентропію в нуль.

Обрана ознака розбиття A_j може вважатись оптимальною, у випадку коли таке розбиття максимізує зниження ентропії результуючої підмножини, відносно батьківської. Використовуючи обернену величину, міру інформації, вибір оптимальної ознаки забезпечується максимальним приростом інформації результуючого вузла, відносно початкового:

$$G(A) = \text{Info}(S) - \text{Info}(S_A), \quad (1.8)$$

де $\text{Info}(S)$ – інформація підмножини S до розбиття, $\text{Info}(S_A)$ – інформація підмножини S після розбиття за ознакою A .

Вибір ознаки зводиться до задачі пошуку максимуму інформації $G(A)$, і формулюється як критерій приросту інформації [86, 87].

Альтернативою теоретико-інформаційному підходу вважається статистична оцінка індексом Джині [87]. Індекс ілюструє як часто випадково обрана реалізація навчальної множини буде розпізнана неправильно. Важливою умовою використання такої оцінки є необхідність обирати цільові значення з визначеного статистичного розподілу. Так оцінка Джині визначає відстань між розподілами цільових значень та передбаченнями моделі, з чого випливає задача мінімізації цієї оцінки.

$$\text{Gini}(Q) = 1 - \sum_{i=1}^n p_i^2, \quad (1.9)$$

де Q – результуюча множина, n – число класів в ній, p_i – імовірність i -го класу.

Діапазон значень індексу $\{0,1\}$ характеризує розподіл реалізацій: значення 0 описує ситуацію, коли всі реалізації результуючої множини належать одному класу, 1 – класи представлені у рівних пропорціях та рівноімовірні. Оптимальним вважається розбиття, за яким значення індексу Джинні мінімальне [87, 88].

Наступним кроком після обрання ознаки розбиття вважається визначення критерію зупинки навчання [89]. Алгоритм навчання виконується до отримання «чистих» підмножин з реалізаціями одного окремого класу, втім це може сформуванню структуру, де для кожної реалізаціє є окремий відповідний листок. Таке дерево неможливо використати для виконання задач розпізнавання, через проблему перенавчання [90] – кожна реалізація отримає унікальний шлях у деревоподібній структурі, що сформує набір правил за якими можна класифікувати виключно реалізації з навчального набору. Також мінусом подібної перенавченої структури буде підвищена складність інтерпретації отриманої структури [91]. З метою запобігання перенавчання використовують алгоритмічну заборону побудови дерева.

Рання зупинка [92] – підхід за яким алгоритм зупиняє навчання за досягнення заданого значення критерію. Такий метод дає скорочення часу на навчання, проте негативно впливає на точність дерева.

Обмеження глибини дерева [93, 94] – підхід за яким навчання відбувається на попередньо заданому числі розбиття у гілках. Структура стає зручною до інтерпретації, але не має показників високої точності.

Також у алгоритмі дерев рішень розглядають підхід з заданням мінімальної допустимої кількості реалізацій класу розпізнавання в вузлі [91, 92]. Обмеження формулюється, як необхідність мати достатню кількість реалізацій класу, щоб сформуванню вузол – це дозволяє не створювати тривіальне розбиття та запобігає створенню малозначущих правил.

Метод дерева рішень формує чіткі, зрозумілі правила класифікації для галузей [95, 96], де формалізація вхідного набору даних є складною для формалізації. Подібні вирішальні правила є зручними для предиктивного аналізу даних [97] та можуть працювати з категоріальними ознаками даних. Очевидними

недоліками ж вважаються чутливість до шумів у вхідних даних [98], більша складність побудови роздільних поверхонь між класами розпізнавання [99], схильність відсікання гілок до проблеми перенавчання [100, 101]. Складний пошук оптимальної структури приводить до необхідності використання жадібних алгоритмів з максимальним приростом інформації, що не дає гарантії побудови дійсно оптимального дерева. Також дерево рішень реалізує константний прогноз для об'єктів розпізнавання, що належать простору ознак поза гіперповерхнею сформованих за навчальною вибіркою рішень, тобто вимагає процедури повторного навчання та зміни структури для якісної роботи з новими даними.

Удосконаленням попереднього алгоритму вважається випадковий ліс, який по суті своїй є ансамблем дерев рішень. Головною особливістю випадкового лісу є поєднання методу випадкових підпросторів та композитного машинного навчання алгоритму бегінгу (Bagging) [102, 103]. Бегінг вибирає випадкову вибірку з набору даних. Отже, кожна модель генерується із реалізацій класів розпізнавання, наданих вихідними даними із заміною, і згенерованими у відповідні вибірки рядків (bootstrap) [104, 105]. Кожна модель навчається самостійно, що дає результати. Остаточний результат базується на голосуванні більшості після об'єднання результатів усіх моделей. Цей крок, який передбачає об'єднання всіх результатів і отримання результату на основі голосування більшості, відомий як агрегація [106].

Серед особливостей алгоритму часто виносять такі його характеристики, як різноманітність, імунітет до багатовимірності, паралелізація, стійкість до перенавчання, стабільність [107, 108]. Ці особливості базуються на тому, що створення окремого дерева враховує не всі ознаки з навчальної вибірки, кожне дерево в лісі є унікальним відносно вхідних даних, що зменшує простір ознак для кожного окремого випадку. Древа рішень зазвичай страждають від проблеми перенавчання, якщо їм дозволено рости без будь-якого контролю. Випадкові ліси створюються з підмножин даних, а кінцевий результат базується на середньому рейтингу, що цю проблему вирішує. В свою чергу цей підхід [109] дозволяє раціональніше розподіляти навантаження на ресурси комп'ютера для

обрахунків та мати розподіл даних з навчальної вибірки для навчання та тестів. Стабільність системи досягається тому, що вибір результату базується на голосуванні більшості та середньому рейтингу.

Одне дерево рішень швидше обчислюється, проте результат у методі випадкового лісу є більш репрезентативним [110]. Випадковий ліс випадковим чином вибирає спостереження, будує дерево рішень і береться середній результат, без використання жодного набору формул, а тому є менше залежним до стану вхідних даних.

Серед переваг методу виділяють можливість використовувати його в як в задачах класифікації, так і в задачах регресії; стійкість до стану вхідних даних дозволяє формувати робочу модель навіть з даними, які містять частково відсутні дані. Випадковий принцип вибору навчальних даних для дерев та принцип голосування для формування результату є ефективним інструментом для розв'язання проблеми перенавчання [111], також кожне створене дерево рішень є незалежним від іншого, таким чином воно демонструє властивість розпаралелювання [112].

Але слід також зазначити, що випадковий ліс є структурно складнішим у порівнянні з деревами рішень, де рішення можна приймати, дотримуючись шляху дерева. Час навчання також є більшим [113, 114] в порівнянні з іншими моделями через складність

Серед традиційних підходів до задач класифікації варто згадати також один з класичних методів – Наївний класифікатор Байєса, який попри своє довге існування і простоту залишається популярним рішенням [115, 116]. Цей імовірнісний класифікатор засновано на використанні теореми Байєса з суворими, наївними, припущеннями щодо незалежності ознак. Теорема Байєса дозволяє зі знання щодо імовірності певної події-причини призвести до події-результату обчислити імовірність того, що саме ця подія-причина призводить до спостережуваних результатів.

$$P(c|d) = \frac{P(d|c)P(c)}{P(d)}, \quad (1.10)$$

де $P(c|d)$ – імовірність що реалізація d належить класу c ,
 $P(d|c)$ – імовірність знайти реалізацію d серед реалізацій класу c ,
 $P(c)$ – безумовна імовірність знайти реалізацію класу c серед всіх реалізацій алфавіту,
 $P(d)$ – безумовна імовірність знайти реалізацію d серед всіх реалізацій алфавіту.

Метою класифікації у даному підході вважається пошук найбільш імовірного класу до якого належить реалізація, що розглядається. Байєсовський класифікатор використовує оцінку апостеріорного максимуму, тобто серед класів алфавіту обирається той, у якого максимальна імовірність.

$$c_{map} = \arg_{c \in C} \max \frac{P(d|c)P(c)}{P(d)} \quad (1.11)$$

Імовірність реалізації є константним значенням, тому у задачах класифікації формула (1.11) набуває наступного вигляду:

$$c_{map} = \arg_{c \in C} \max [P(d|c)P(c)] \quad (1.12)$$

Варто зазначити, що розмірність класу впливатиме на кількість операцій множення, що може призвести до проблеми антипереповнення [117], тобто ситуації, коли результат обрахунків чисел з рухомою комою стає настільки близьким до нуля, що порядок числа виходить за межі розрядної сітки.

Така репрезентація моделі містить в собі ваду, оскільки не передбачає потрапляння в вхідні дані невідомих попередньо реалізацій [115, 118]. Подібна ситуація зведе оцінку імовірності належності нової невідомої реалізації відомим класам до нуля.

Серед переваг наївного Байєса виносять швидкість роботи щодо передбачення класу набору даних та можливість його застосування для вирішення завдань багатокласового прогнозування [119]. Наївний класифікатор

Байєса працює краще, ніж інші моделі з меншою кількістю навчальних даних, якщо виконується припущення про незалежність ознак [120]. Також наївний алгоритм Байєса працює виключно добре з категоричними вхідними даними, порівняно з числовими. Втім, якщо тестовий набір даних містить реалізацію, яка не була присутня в навчальному наборі даних, наївна модель Байєса призначить їй нульову імовірність [121] і не зможе робити жодних прогнозів щодо цієї реалізації. Це явище називається «нульовою частотою» [122], і вимагає використання технік згладжування, щоб вирішити цю проблему [123]. Алгоритм передбачає, що всі дані незалежні, і хоча в теорії така модель дає якісні результати, у задачах реального життя складно знайти набір незалежних вхідних даних. Серед сучасних практичних застосувань алгоритму виділяють багатокласові прогнози – за допомогою Байєсовського класифікатора можна легко знайти імовірність кількох цільових класів [124, 125]. Найкращі результати алгоритм показує у поєднанні з системами фільтрації вхідних даних [126, 127].

Серед класичних, проте дієвих методів які ефективно використовуються у прикладних задачах класифікації, звернемо увагу на лінійний дискримінантний аналіз (LDA). Цей метод використовується як інструмент для класифікації, зменшення розмірності та візуалізації даних [128]. Незважаючи на свою простоту, LDA часто дає надійні, пристойні результати класифікації [129], які є зручними до інтерпретації. Коли вирішуються реальні проблеми класифікації, LDA часто є первинним методом порівняльного аналізу до використання інших, більш складних і гнучких.

Проаналізуємо алгоритм контрольованої класифікації [130] за допомогою дискримінантного аналізу. Розглянемо загальну проблему класифікації: випадкова реалізація x походить з одного з k класів, з деякими специфічними для класу щільностями імовірності $f(x)$. Дискримінантне правило намагається розділити простір даних на k непересічних областей [131], які представляють усі класи. Для цих областей класифікація за допомогою дискримінантного аналізу означає розподіл реалізації x до класу j , якщо x знаходиться в просторі j . Задача зводиться до пошуку підпростору класу до якого потрапляють реалізації x .

Правила розподілу, які найчастіше використовують у цьому методі, визначаються як правило максимальної ймовірності [128, 132], або байєсовське правило [133]. За першим випадком робиться припущення, що кожен клас може виникнути з однаковою ймовірністю, і тоді можливо розподілити реалізацію x до класу j , якщо:

$$j = \arg \max_i f_i(x) \quad (1.13)$$

Байєсовське правило ж припускає, що за умови відомих апріорних імовірностей π , то можливо розподілити реалізацію x до класу j , якщо:

$$j = \arg \max_i \pi_i f_i(x) \quad (1.14)$$

Вхідні дані вважаються такими, що отримуються з багатомірного розподулі Гауса, тобто розподіл x распределение може бути визначене середнім значенням μ та коваріацією Σ . За правилом (1.14) дані x належать класу j , якщо вони мають найбільшу імовірність серед всіх K класів для $i = 1 \dots K$:

$$\delta_i(x) = \log f_i(x) + \log \pi_i \quad (1.15)$$

Дискримінантна функція (1.15) вказує наскільки вірогідними є дані x з кожного класу. Таким чином, границя рішення, що розділяє будь-які два класи, k і l , є набором x , де дві дискримінантні функції мають однакоє значення. Будь-які дані, які потрапляють на межу прийняття рішення, однакоє вірогідні для двох класів [134]. Для використання алгоритму LDA, припускають однакоє коваріацію серед K класів [24]: всі класи алфавіту отримують однакоє коваріаційну матрицю, замість формування однієї коваріаційної матриці на кожен окремий клас розпізнавання. Отримуємо дискримінантну функцію:

$$\delta_k(x) = x^T \Sigma^{-1} \mu_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + \log \pi_k \quad (1.16)$$

Формула (1.16) демонструє лінійну функцію від x . Межа рішення між будь-якою парою класів також є лінійною функцією від x . Без припущення рівної коваріації квадратичний член у ймовірності не скасовується, отже результуюча дискримінантна функція є квадратичною функцією від x :

$$\delta_k(x) = -\frac{1}{2} \log |\Sigma_k| - \frac{1}{2} (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) + \log \pi_k \quad (1.17)$$

У цьому випадку межа рішення є квадратичною по x . Така інтерпретація розглядається як квадратичний дискримінантний аналіз (QDA) [135]. У реальних задачах параметри генеральної сукупності зазвичай невідомі та оцінюються за навчальними даними як вибіркові середні значення та вибіркові коваріаційні матриці. Хоча QDA вміщує більш гнучкі межі прийняття рішень порівняно з LDA [136], кількість параметрів, які необхідно оцінити, також зростає швидше, ніж LDA.

Для кожної дискримінантної функції QDA в (1.17) необхідно оцінити вектор середнього значення, коваріаційну матрицю та пріоритет класу. Кількість параметрів, оцінених в LDA, зростає лінійно, тоді як кількість параметрів QDA збільшується квадратично з [137]. Логічно виходить, що QDA матиме гіршу продуктивність, ніж LDA, через збільшення розмірності даних розпізнавання [23].

Алгоритм LDA продукує лінійні вирішальні правила, які зручно імплементуються до систем розпізнавання [138] і, які через свою природу, здатні до швидкого прийняття класифікаційних рішень [139]. Проте очевидними проблемами алгоритму є довгий час навчання і необхідність обробляти значні обсяги даних за сформованими матрицями [140]. Та головним недоліком цього підходу вважається закладений в основу моделі нормальний розподіл імовірностей [141], який на практиці не завжди може існувати у даних поданих до класифікації.

З розглянутих алгоритмів легко бачити необхідність роботи з простором ознак розпізнавання, не як статичним, а розглядати модифікації та розбиття простору під кожен окремий клас розпізнавання. Причина цієї необхідності – перетин класів та потенційна належність одних ознак одразу декільком класам, Додавання ж нових реалізацій чи класів до алфавіту розпізнавання тільки збільшує наповненість простору ознак та можливий перетин класів. Логічним рішенням для такого є використання кластеризації, як задачі машинного навчання для утворення підпросторів та групування.

Кластеризація — це задача машинного навчання без учителя, також цей процес називають кластер-аналізом. Використання алгоритму кластеризації означає, що алгоритму навчання надається багато вхідних даних без міток і система формує кластери – групи з даних за внутрішніми параметрами системи, схожі одна на одну на основі їх відношення до оточуючих точок даних. Кластеризація використовується для виявлення шаблонів. Для роботи системи з невідомими даними кластеризація може бути інструментом, щоб отримати певну якісну інформацію.

Існуючі типи алгоритмів кластеризації поділяють за видом даних, що оброблюються [142]. У кластеризації на основі щільності дані групуються за областями високої концентрації точок даних, оточених областями низької концентрації точок даних [143]. В основному алгоритм знаходить місця, у яких багато точок даних, і формує там кластер. Такі кластери можуть мати будь-яку форму і ігнорують «викиди» у даних.

Кластеризація особливо корисна для дослідження даних, про які мало відомо. Алгоритм можете знайти зв'язки у непомаркованих даних, які не будуть помітні для людини. Розглянемо популярні методи кластеризації.

За допомогою підходу кластеризації на основі розподілу всі точки даних вважаються частинами кластера на основі ймовірності того, що вони належать до певного кластера.

Найчастіше застосовується кластеризацію на основі центроїда [144]. Цей метод чутливий до початкових параметрів, але швидкий і ефективний. Алгоритм

розділяє точки даних на основі кількох центроїдів у даних. Кожна точка даних призначається кластеру на основі квадрата її відстані від центроїда.

Алгоритм k -середніх — це ітераційний алгоритм, який має на меті розділити набір даних на попередньо визначені K окремі кластери, які не перекриваються, і де кожна реалізація даних належить лише одній групі. Метод намагається зробити внутрішньокластерні реалізації даних [145] якомога подібнішими, водночас зберігаючи кластери максимально різними. Алгоритм призначає реалізації даних кластеру таким чином, щоб сума квадратів відстані між точками даних і центроїдом кластера була мінімальною [146, 147]. Чим менше варіацій у кластерах, тим більш однорідними є реалізації даних у межах одного кластеру.

За попередньо заданої кількості кластерів K алгоритм k -середніх ініціалізує центроїди, перетасувавши набір даних та випадково обирає K реалізацій даних для центроїдів без заміни. Процедура повторюється до зміни центроїдів. За сумою квадратів відстаней між реалізаціями і всіма центроїдами кожна реалізація даних відноситься до найближчого кластеру [148].

Підхід k -середніх характеризується парадигмою очікування-максимізація [149 – 151]. E-крок призначає реалізації даних найближчому кластеру. M-крок [152] обчислює центроїд кожного кластера. Рішення щодо належності формується за цільовою функцією

$$J = \sum_{i=1}^m \sum_{k=1}^K w_{ik} \|x^i - \mu_k\|^2, \quad (1.18)$$

де $w_{ik} = 1$ для реалізації даних x^i , якщо вона належить кластеру k ;
інакше $w_{ik} = 0$, μ_k — центроїд кластера x^i .

Отримана функція являє собою задачу мінімізації з двох частин: диференціювання цільової функції відносно реалізації та актуалізувати модель кластеру, а також диференціювання цільової функції з перерахунком центроїдів після кластерного призначення з попереднього кроку. Правило (1.18) описується наступними формулами:

$$\frac{\partial J}{\partial w_{ik}} = \sum_{i=1}^m \sum_{k=1}^K \|x^i - \mu_k\|^2, w_{ik} = \begin{cases} 1, \text{ якщо } k = \arg \min_j \|x^i - \mu_k\|^2 \\ 0, \text{ якщо інакше.} \end{cases} \quad (1.19)$$

Отже реалізація x^i відноситься до кластеру за сумою квадратів відстані від центроїду кластера. Тоді як сам центроїд перевизначається для відображення нових реалізацій за формулою

$$\frac{\partial J}{\partial \mu_k} = 2 \sum_{i=1}^m w_{ik} (x^i - \mu_k) = 0 \quad (1.20)$$

$$\mu_k = \frac{\sum_{i=1}^m w_{ik} x^i}{\sum_{i=1}^m w_{ik}}$$

Оскільки алгоритми кластеризації використовують вимірювання на основі відстані для визначення подібності між точками даних необхідна стандартизація даних [151], щоб мати середнє значення нуль і стандартне відхилення одиниці, оскільки майже завжди об'єкти в будь-якому наборі даних матимуть різні одиниці вимірювання.

Враховуючи ітераційну природу k-середніх і випадкову ініціалізацію центроїдів на початку алгоритму, різні ініціалізації можуть призвести до різних кластерів, оскільки алгоритм може застрягти в локальному оптимумі та не збігатися з глобальним оптимумом [146]. Тому запускати алгоритм варто, використовуючи різні ініціалізації центроїдів і вибирати результати виконання, які давали б нижчу суму квадратів відстані [149].

Алгоритм k-середніх добре фіксує структуру даних, якщо кластери мають сферичну форму. Це означає, що коли кластери мають складну геометричну форму, метод матиме проблеми з кластеризацією даних [150]. Крім того, метод не вивчає кількість кластерів із вхідних даних і вимагає, щоб це значення було визначене заздалегідь [153]. Звідси виникає проблема, що алгоритм k-середніх надає більшу значущість більшим кластерам, також метод матиме проблему з віднесенням реалізацій до кластери за випадку якщо кластери

перекриваються [148]. Це зумовлене тим, що у методі не передбачена внутрішня міра невизначеності [153].

Кластеризація k -середніх може згрупувати непов'язані реалізації разом. Кожна реалізація з часом стає частиною якогось кластера, навіть якщо реалізації розкидані далеко у векторному просторі [154]. Оскільки кластери залежать від середнього значення елементів кластера, кожна точка даних відіграє певну роль у формуванні кластерів. Незначна зміна в даних може вплинути на результат кластеризації. Через цю проблему алгоритм було удосконалено у алгоритмі просторової кластеризації на основі щільності із шумом (DBSCAN) завдяки способу формування кластерів [155]. Інша проблема з методом k -середніх полягає в необхідності чітко вказати кількість кластерів.

Як альтернатива DBSCAN не потрібно знати апріорно кількість кластерів завдяки функції для обчислення відстані між значеннями та вказівок щодо того, яка відстань вважається «близькою». DBSCAN також дає більш прийнятні результати, ніж k -середні для різних розподілів [156]. Алгоритм DBSCAN використовує два параметри: порогове значення ($minPts$) – мінімальна кількість точок, згрупованих разом, щоб регіон вважався щільним, та ϵ – міра відстані, яка використовуватиметься для визначення місцезнаходження точок поблизу будь-якої точки. Досяжність у термінах щільності встановлює, що точка доступна з іншої, якщо вона знаходиться на певній відстані від неї. З іншого боку, зв'язність передбачає підхід ланцюжка на основі транзитивності, щоб визначити, чи розташовані точки в конкретному кластері [157].

Алгоритм виконується шляхом довільного вибору точки в наборі даних, доки всі точки не будуть відвідані, та пошуку точки в радіусі ϵ для можливості зробити висновок про належність обох точок до одного кластера. Кластери розширюються шляхом рекурсивного повторення обчислення сусідства для кожної сусідньої точки [158].

Кожне завдання інтелектуального аналізу даних має проблему параметрів. Як правило, мінімальний $minPts$ можна отримати з кількості вимірів D у наборі даних, оскільки $minPts \geq D + 1$. Низьке значення $minPts = 1$ не має сенсу, оскільки тоді кожна точка сама по собі вже буде кластером. Якщо $minPts \leq 2$,

результат буде таким самим, як і при ієрархічній кластеризації з одноланковою метрикою з дендрограмою, основою на висоті ε . Більші значення зазвичай кращі для наборів даних із шумом і дають більш значні кластери.

Значення для ε обирається за допомогою графіка k -відстаней, на якому відображають відстань до $k = \minPts - 1$ найближчого сусіда в порядку від найбільшого до найменшого значення. Оптимальні значення ε обираються з діапазону, де графік утворює точку екстремуму: якщо ε вибрано занадто малим, велика частина даних не буде згрупована; тоді як при занадто високому значенні – кластери об'єднуються, і більшість об'єктів буде в одному кластері [159].

Втім варто зазначити, що DBSCAN не може добре кластеризувати набори даних із великою різницею щільності, оскільки тоді комбінацію $\minPts - \varepsilon$ не можна правильно вибрати для всіх кластерів [160]. Вибір значущого значення ε залежить від інтерпретованості даних і може бути складним процесом якщо дані недостатньо зрозумілі. DBSCAN не є повністю детермінованим оскільки алгоритм починається з випадкової точки [157]. Таким чином, граничні точки, доступні з кількох кластерів, можуть бути частиною будь-якого кластера.

Кластеризація на основі ієрархії зазвичай використовується для даних, які отримуються з бази даних або таксономії. Цей підхід створює дерево кластерів, щоб все було організовано зверху вниз. Такий метод формує більше обмежень, ніж інші типи кластеризації. Метод ієрархічної кластеризації працює через групування даних у дерево кластерів. Ієрархічна кластеризація починається з обробки кожної реалізації даних як окремого кластера. Потім алгоритм виконує циклічну процедуру пошуку пари найближчих кластерів та об'єднання цієї пари у новий кластер [161]. Метою алгоритму є створення ієрархічної серії вкладених кластерів. Деревоподібна діаграма, яка формує статистичні закономірності послідовностей злиття або розбиття, графічно представляє ієрархічну структуру та є перевернутим деревом, яке описує порядок, у якому фактори об'єднуються або розбиваються кластери вгору, залежно від напрямку руху [162].

Основними методами створення ієрархічної кластеризації є агломерація [163] та розділення [164]. Перший метод розглядає кожну точку даних як окремий кластер і на кожному кроці об'єднує найближчі пари

кластера, рухаючись знизу вгору. На кожній ітерації кластери зливаються з різними кластерами, поки не буде сформований один кластер за всіма даними системи.

Розділова ж ієрархічна кластеризація є прямою протилежністю агломераційній ієрархічній кластеризації і в обробку беруться всі реалізації даних як один кластер. На кожній ітерації відокремлюються такі реалізації, які не можна порівняти з рештою набору [165]. Результиуюча деревоподібна структура, сформована згори вниз, сформує розбиття на ту кількість кластерів, скільки унікальних реалізацій буде виділено з вхідного набору.

У якості альтернативних підходів розглядають t-стохастичне розподілене вкладення сусідів (t-SNE) — це техніка зменшення розмірності, яка особливо добре підходить для візуалізації масивів даних великої розмірності [166]. Мета зменшення розмірності даних у методі має під собою ідеї збереження суттєвої структури або інформації даних, присутніх у високовимірних даних, у низьковимірному представленні. Крім того це дозволяє підвищити інтерпретабельність даних у низьковимірному просторі та сформувати стійкість до викидів [167]. t-SNE перетворює високовимірні евклідові відстані між реалізаціями x_i і x_j в умовні ймовірності $P_{j|i}$ [168].

$$P_{j|i} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma_i^2)}{\sum_{j' \neq i} \exp(-\|x_i - x_{j'}\|^2 / 2\sigma_i^2)}, \quad (1.21)$$

де σ_i — це дисперсія гауссової функції, яка центрується на реалізації даних x_i .

Визначені умовні імовірності та центри дозволяють визначити низьковимірне представлення даних [169], яке мінімізує невідповідність між P_{ij} і q_{ij} за допомогою градієнтного спуску на основі розбіжності Кульбака-Лейблера [166, 170]:

$$\sum_i KL(P_i || Q_i) = \sum_i \sum_j P_{ji} \log \frac{P_{ji}}{q_{ji}} \quad (1.22)$$

Мінімізація розбіжності Кульбака-Лейблера робить q_{ij} ідентичним P_{ij} , тому структура даних у високовимірному просторі буде подібна до структури даних у низьковимірному просторі.

Алгоритм ефективно обробляє нелінійні дані та є популярним інструментом як алгоритм зменшення розмірності. Втім варто зазначити обчислювальну складність алгоритму: t-SNE передбачає багато попарних обчислень імовірностей для кожної реалізації даних та мінімізацій суми різниці ймовірностей у вищих і нижчих вимірах. Оскільки t-SNE масштабується квадратично за кількістю об'єктів N , його застосовність обмежена розмірністю вхідних даних, що також пов'язано з вимогами до обчислювальних потужностей системи та часом на виконання обрахунків [171].

Не менш важливою задачею машинного навчання вважається регресія [172]. Це техніка навчання системи з учителем для дослідження зв'язку між незалежними змінними або ознаками та залежною змінною або результатом. Регресія використовується як метод прогнозного моделювання в машинному навчанні, у якому алгоритм використовується для прогнозування постійних результатів.

Розв'язування проблем регресії є одним із найпоширеніших застосувань для моделей в керованому машинному навчанні. Регресійний аналіз є невід'ємною частиною моделей прогнозування, а також поширеним методом у прогностичній аналітиці на основі машинного навчання.

Основними підходами вирішення задачі регресії визначають: лінійну, нелінійну та логістичну регресію.

Лінійний регресійний аналіз використовується для прогнозування зміни змінної на основі значення іншої змінної [173]. Ця форма аналізу оцінює коефіцієнти лінійного рівняння, що включає одну або кілька незалежних змінних, попередньо відомі значення які використовуються у обрахунках, які найкраще передбачають значення залежної змінної, змінної прогнозування якої відбувається у обрахунках. Лінійна регресія відповідає прямій лінії або поверхні, що мінімізує розбіжності між прогнозованими та фактичними вихідними значеннями.

Нелінійна регресія – це форма регресійного аналізу, у якій дані підлаштовуються під модель, а потім виражаються як математична функція, формується нелінійна залежність змінних [174]. Мета моделі — мінімізувати суму квадратів, міру яка відстежує, наскільки значення залежної змінної відрізняються від нелінійної функції, яка використовується для прогнозування.

Часто логістична регресія, як і задача регресії в цілому, розглядається як одношарова штучна нейронна мережа. Оскільки за ідеєю регресії формується функція, яка змінює форму залежно від типу регресії, для передбачення наступного значення змінної, формування такої функції можна представити моделлю нейромережі [175, 176]. Популярність нейроподібних підходів зумовила те, що на всі наведені вище задачі машинного навчання є рішення сформоване на основі нейронної мережі.

Нейронні мережі є функціональною одиницею глибокого навчання і імітують поведінку людського мозку для вирішення складних проблем, керованих даними [176, 177]. Вхідні дані обробляються різними шарами штучних нейронів з метою отримати бажаний результат. Архітектура нейронної мережі складається з окремих одиниць, званих нейронами, які імітують біологічну поведінку мозку.

Персептрон [178], як найпростіша архітектура нейронної мережі, приймає вектор вхідних даних реальних значень, виконує лінійну комбінацію кожного атрибута з відповідною вагою, призначеною кожному з них [179]. Зважені вхідні дані підсумовуються в одне значення та передаються через функцію активації. Блоки персептронів об'єднують, щоб утворити більшу архітектуру штучної нейронної мережі. Окремий персептрон імітує роботу окремого нейрону людського мозку [178].

Комбінація ж персептронів з прямим зв'язком формує багаторівневу нейронну мережу, в якій інформація передається в прямому напрямку — зліва направо. У прямому проході інформація надходить всередину моделі через вхідний рівень, проходить через ряд прихованих шарів і переходить до вихідного рівня. Ця архітектура нейронних мереж є передовою за своєю природою — інформація не зациклюється на двох прихованих шарах [179, 180]. Наступні

шари не дають зворотного зв'язку з попередніми, процес навчання мереж прямого зв'язку залишається таким же, як і окремого персептрона.

Глибокі нейронні мережі надзвичайно важко навчити через проблеми зникнення [181] та вибуху градієнта [181, 182]. Залишкові мережі забезпечують альтернативний шлях для потоку даних, щоб зробити процес навчання набагато швидшим. На відміну від прямого підходу попередніх архітектур нейронних мереж, основна ідея залишкових полягає в тому, що глибша мережа може бути створена з меншою шляхом копіювання ваги з аналогів за допомогою відображення ідентичності [183]. Дані з попередніх рівнів швидко перемотуються і копіюються вперед у нейронних мережах, утворюючи так звані пропускаючі з'єднання, які представлені в залишкових нейронних мережах для вирішення зникаючих градієнтів [182, 184].

Базова архітектура глибокого навчання [185, 186] має фіксований розмір вхідних даних, і це діє як блокування у сценаріях, де розмір вхідних даних не є фіксованим. Рішення, прийняті такою моделлю, базуються на поточних вхідних даних без урахування попередніх. Так повторювані нейронні мережі [187] створені для роботи з вхідними послідовностями даних, використовуючі попередні дані у формуванні майбутніх прогнозів. Вхідні дані у формі послідовних даних подаються в нейромережу з прихованим внутрішнім шаром [188], який оновлюється кожного разу, коли надходить наступна послідовність даних. Потім стан внутрішнього прихованого шару буде передано назад до моделі.

Проте, у повторюваній нейронній мережі кожен прогноз використовує лише одну позначку часу назад [185], тобто виключно використовує короткочасну пам'ять, функціонує без жодної інформації з попередніх станів. Щоб виправити це, розглядають структуру рекурентних нейронних мереж [187, 188] і розширюють її, додавши більше запам'ятовування станів [183].

Зв'язки і ваги прихованих нейронів фіксовані та розподіляються випадковим чином. Вихідний шар можна розглядати як лінійну модель зважених вхідних даних [189], що пройшли через усі приховані шари та цільовий вихід. Єдині ваги, які змінюються в процесі навчання, стосуються внутрішньої

структури мережі, яка з'єднує приховані шари з вихідними шарами. Так функція втрат набуває здатність до диференціації [190].

Популярним рішенням серед штучних нейронних мереж у задачах розпізнавання образів вважаються згорткові нейронні мережі [191, 192], тип нейронних мереж прямого зв'язку, який використовується для вирішення складних проблем класифікації. Такі нейронні мережі мають приховані згорткові шари, які утворюють основу таких мереж [193, 194]. Функції акцентуються на найдрібніших деталях у даних. На більш високому рівні згорткові шари виявляють шаблони в даних за допомогою фільтрів [191], втім з глибиною мережі ускладнюється пошук шаблонів [192, 194]. При додаванні згорткового шару до нейронної мережі потрібно чітко визначити кількість фільтрів. Фільтр часто розглядається як відносно невелика матриця ознак з випадковими числами. Коли цей згортковий шар отримує значення робочих вхідних даних, фільтр буде згортатися над кожним фрагментом вхідної матриці. Вихідні дані згорткового шару зазвичай пропускаються через функцію активації, щоб додати моделі нелінійність [195]. Об'єднання є дуже важливим кроком у згорткових моделях, оскільки дозволяє зменшити обчислення та робить модель стійкою до спотворень і варіацій [196, 197]. Повністю підключена щільна нейронна мережа використовуватиме згладжену матрицю ознак для прогнозування результату.

Використання згорткових шарів та максимальне їх об'єднання зменшує розмір реалізації під час її обробки [193]. Для повернення до вихідного розміру, використовується підвищення дискретизації та транспонування згорткових шарів [198, 199]. Підвищена дискретизація не має параметрів, які можна навчити, — виключно повторює рядки та стовпці даних за відповідними розмірами.

Згорткові шари потребують менше параметрів. Логічно витікає, що саме останні шари повністю зв'язаних нейронів викликають сплеск у кількості параметрів [186, 190]. Один із способів вирішити цю проблему — позбутися повністю пов'язаних шарів. Згортки та об'єднання зменшують роздільну здатність, але необхідність відобразити роздільність даних у відповідних класах зберігається [168, 188]. Тому у задачах розглядається ідея зменшити роздільну

здатність у міру заглиблення та збільшити кількість каналів за допомогою вкладених згорток. В архітектурі «мережа в мережі» останній повністю підключений рівень замінюється глобальним рівнем максимального об'єднання, що робить модель легкою у навчанні [181, 186].

Варто зазначити, що найвідомішим недоліком нейронних мереж є їхня природа «чорного ящика» [200, 201], а саме відсутність розуміння як і чому штучна нейронна мережа у процесі навчання прийшла до певного результату. Помилковість результату важко аналізувати, оскільки подібна модель не інтерпретується для вивчення їх поведінки.

Нейронні мережі вважаються гнучкими через здатність розпізнавати на ранніх етапах навчання шаблони у вхідних даних. Ця гнучкість має свою ціну – необхідно багато даних для навчання [202]. Вони не в змозі зробити узагальнення на основі обмежених навчальних даних. На невеликих наборах моделі нейронних мереж мають тенденцію до надмірного пристосування [203, 204]. Вони акцентуються на навчальних даних та погано узагальнюють нові приклади [187, 193]. Простіша ж модель машинного навчання працюватиме краще, ніж нейронна мережа на невеликих наборах даних. Рішенням цієї проблеми прийнято вважати трансферне навчання, процес навчання за яким використовується попередньо навчена модель нейронної мережі, яка під час функціонування переналаштовується відповідно до нових вхідних даних. Втім, якщо новий набір даних сильно відрізняється, малоймовірно, що трансферне навчання [202, 204] буде успішним [202].

Нейронні мережі чутливі до вхідних даних, якщо ж дані не масштабуються належним чином [194], це може призвести до неоптимальної моделі [205]. Подібна чутливість вимагає додаткових фільтрацій [185, 206] чи нормалізацій [190] у вхідних даних. Крім того, якщо вхідний набір даних незбалансований [219–221], нейронна мережа може вивчати шаблони, які не відповідають реальному світу, що також негативно скасується на точності системи.

Окремим недоліком є проблема розгортання нейронної мережі у виробництві [210, 211]. Штучні нейронні мережі потребують інтенсивних

обчислень. Без урахування обчислювальних потужностей система може бути повільною чи навіть непридатною для використання. Ретельна оптимізація моделі для виробництва включає використання паралелізму, розподіл обчислень та зменшення використання пам'яті [177, 196]. Що також є окремою складною задачею при створенні автономної інтелектуальної системи.

Сучасні методи розпізнавання сигналів характеризуються невисокою повною достовірністю розпізнавання оскільки вони, як правило, ігнорують апріорно нечітке розбиття класів розпізнавання і не враховують довільні початкові умови формування імпульсів, які обумовлюють апріорну невизначеність.

Перспективним підходом в галузі аналізу та синтезу інтелектуальних систем керування є використання ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технологія) [212, 213], яка ґрунтується на максимізації кількості інформації в процесі навчання системи шляхом введення додаткових інформаційних обмежень. Більшість відомих алгоритмів машинного навчання в системах розпізнавання образів орієнтовані на розв'язання модельних задач, які виключають перетин класів, характеризуються невисокою достовірністю розпізнавання і потребують на підготовчому етапі навчання нормалізації апріорно деформованих образів, що на практиці ускладнює процес навчання.

Отримання безпомилкових, за начальною матрицею, вирішальних правил є основною задачею інформаційного синтезу здатних навчатися систем керування [214]. З попередньо розглянутих методів універсальним підходом до формування вирішальних правил для вхідних даних високої розмірності є геометрична репрезентація простору ознак.

ІЕІ-технологія ґрунтується на прямій оцінці інформаційної спроможності системи розпізнавання [215, 216] і дозволяє оптимізувати її параметри функціонування в процесі машинного навчання. Прийняття рішень за ІЕІ-технологією здійснюється в рамках детерміновано-статистичного підходу шляхом побудови детермінованого класифікатора, статистична корекція якого здійснюється в процесі навчання з метою побудови безпомилкових, за

навчальними матрицями, вирішальних правил. Методи інформаційно екстремального машинного навчання ґрунтуються на застосуванні гіпотез як чіткої, так і нечіткої компактності реалізацій образу, тобто здатні опрацьовувати дані та відновлювати контейнери класів розпізнавання у просторі ознак за умови перетину класів розпізнавання [217], який часто зустрічається в реалізаціях ЕМГ-імпульсів жестів.

Базовий інформаційно-екстремальний алгоритм навчання інтелектуальної системи здійснює оптимізацію геометричних параметрів контейнерів класів розпізнавання, що формуються в базисі бінарного простору Хеммінга. Формування вирішальних правил для контейнерів класів виконується за глобальним максимумом інформаційної міри критерію функціональної ефективності навчання системи [213] у робочій, допустимій області визначення його функції.

Функціональна категорійна модель базового алгоритму інформаційно-екстремального машинного навчання [218] у вигляді діаграми відображення множин, якими система оперує у процесі навчання, представлена на рисунку 1.4




Рисунок 1.4 – Категорійна модель машинного навчання за базовим алгоритмом

Нечітке розбиття простору ознак $\mathfrak{R}^{|M|} \subset \Omega$, обумовлене перетином класів розпізнавання, виникає при обґрунтуванні гіпотези нечіткої компактності реалізацій класів. Діаграма (рис.1.4) наводить оператор $\theta: Y \rightarrow \mathfrak{R}^{|M|}$ розбиття простору ознак на класи розпізнавання і оператор класифікації $\psi: \mathfrak{R}^{|M|} \rightarrow I^{|S|}$, який перевіряє основну статистичну гіпотезу про належність реалізацій $\{x_m^{(i)} \mid j = \overline{1, n}\}$ класу X_m^0 , де l – кількість статистичних гіпотез. Оператор $\gamma: I^{|S|} \rightarrow$

$\mathfrak{S}^{|q|}$ шляхом оцінювання статистичних гіпотез формує множину точнісних характеристик $\mathfrak{S}^{|q|}$, де $q = l^2$ – кількість точнісних характеристик. Оператор $\varphi: \mathfrak{S}^{|q|} \rightarrow E$ обчислює множину значень інформаційного КФЕ, який є функціоналом точнісних характеристик. Оператор $r: E \rightarrow \mathfrak{R}^{|M|}$ замикає контур оптимізації геометричних параметрів нечіткого розбиття $\mathfrak{R}^{|M|}$ шляхом пошуку максимуму КФЕ навчання розпізнаванню реалізацій класу X_m^0 . Оператор $U: E \rightarrow G \times T \times \Omega \times Z$ регламентує процес навчання і дозволяє оптимізувати параметри його плану, які визначають, наприклад, обсяг і структуру векторів-реалізацій класів розпізнавання, черговість їх подання тощо.

На рис. 1.5 показано функціональну категорійну модель системи розпізнавання жестів в режимі екзамену [218] при якому відбувається безпосереднє прийняття рішення щодо належності вхідного вектора-реалізації до одного із класів алфавіту, сформованого на етапі навчання.




Рисунок 1.5 – Функціональна категорійна модель класифікатора у режимі екзамену

У діаграмі відображень множин на екзамені (рис.1.5) призначенням оператора U_E є регламентація екзамену. При цьому замість оператора θ вводиться оператор p відображення вибіркової множини $X \subset \Omega_B$, що розпізнається, на побудоване на етапі навчання розбиття $\mathfrak{R}^{|M|}$. Оператор Φ_1 із джерела інформації, яким є універсум випробувань $G \times T \times \Omega \times Z$, формує екзаменаційний вектор-реалізацію класу, що розпізнається, аналогічний за структурою вектору ознак розпізнавання із навчальної матриці. Оператор класифікації ψ утворює композицію двох операторів: $\psi_1: \mathfrak{R}^{|M|} \rightarrow F$, де F – множина функцій належності, і оператор $\psi_2: F \rightarrow I^{|M+1|}$, який вибирає гіпотезу за максимальним значенням функції належності.

Запропоновані категорійні моделі описують перетворення інформації та інформаційні потоки схожі до когнітивних процесів людського мозку, які залучені в процеси формування та прийняття класифікаційних рішень. Виходячи з цього варто наголосити, що використання категорійних моделей у рамках алгоритмічного підходу є перспективним узагальненням структурної схеми відповідних алгоритмів функціонування здатної навчатися системи керування протезом кінцівки руки, оскільки вони суттєво спрощують формалізацію задачі інформаційного синтезу інтелектуальних систем різного призначення [231–233].

Перехід до бінарного простору Хеммінга дозволяє адаптувати вхідний математичний опис системи керування протезом, і модулю розпізнавання рухів, до побудови безпомилкових вирішальних правил за бінарною навчальною матрицею, виконуючи допустимі перетворення ознак розпізнавання. Втім за результатом оптимізації параметрів навчання, які прямо впливають на геометричну форму контейнерів класів розпізнавання, є імовірність не сформулювати вирішальні правила прийнятної достовірності, тоді здійснюється перехід до оптимізації параметрів, що впливають на розподіл векторів-реалізацій класу в просторі ознак [222, 223], або до оптимізації словника ознак [224].

Автоматизація формування вхідної навчальної матриці класів розпізнавання може бути реалізована шляхом застосування ідей і методів кластер-аналізу, який дозволяє виявляти нові закономірності даних. Втім, збільшення потужності відкритого алфавіту класів розпізнавання вимагає перенавчання системи та формування нових вирішальних правил [225], здатних розпізнавати вектори-реалізації нового класу. Предметна область ЕМГ сигналу в такому випадку може породжувати схожі шаблони сигналів для різних рухів, через використання спільних груп м'язів. Такий процес буде суттєво збільшувати ступінь перетину в просторі ознак класів розпізнавання. У результаті буде зменшуватися повна ймовірність розпізнавання біосигналів а відповідно і виконання протезом відповідних когнітивних команд.

У рамках ІЕІ-технології машинне навчання системи полягає в послідовних направлених процесах пошуку при заданих обмеженнях на початкову точку. Тому комплекс впливів на початковий математичний опис системи зумовлює

інтерес до зменшення впливу потужності алфавіту класів розпізнавання на достовірність і оперативність процесу розпізнавання. В працях [225, 226] запропоновано алгоритм інформаційно-екстремального ієрархічного машинного навчання, з метою підвищення повної імовірності правильного виконання когнітивних команд та забезпечення інваріантності побудованих в процесі машинного навчання вирішальних правил до збільшення потужності алфавіту класів розпізнавання. При цьому суттєвий вплив на функціональну ефективність машинного навчання здійснює структурованість ієрархічних даних, що обумовлює необхідність оптимізації ієрархічної структури за інформаційним критерієм.

1.4 Висновки до першого розділу

Аналітичний огляд сучасного стану та тенденцій розвитку систем керування інтелектуальних протезів з неінвазивною системою зчитування біосигналів, а також інтелектуальних технологій їх інформаційного синтезу дозволяє зробити такі висновки

1. Основним напрямом, що активно розвивається в галузі інтелектуальних протезів, є створення протезів, здатних до самонавчання та розпізнавання електроміографічних біосигналів за біоімпульсами з шкіри користувача. Збільшення обсягу алфавіту відомих класів розпізнавання веде до значних змін в методах навчання системи і вимагає інтелектуалізації процесів обробки та аналізу даних.

2. Вхідний математичний опис системи представляє собою електроміографічний сигнал, зареєстрований з шкіри людини, який за своєю природою є зашумленим, містить артефакти та є чутливим до апаратних завад. Робота з такими вхідними даними вимагає не тільки використання методів фільтрації сигналу, а й залучення методів машинного навчання, здатних працювати з багатовимірними даними, що дозволяє підвищити значущість ознак розпізнавання сигналу.

3. Аналіз існуючих методів розпізнавання електроміографічних біосигналів показав, що використання традиційних підходів не забезпечує гнучкість системи до перенавчання та інваріантність до збільшенні потужностей словника ознак і алфавіту класів розпізнавання. Застосування методів машинного навчання подібних до когнітивних процесів людського мозку, як штучні нейронні мережі забезпечує високу модельну поведінку системи, проте мають проблему оперативності навчання, чутливі до багатовимірності простору ознак та не повністю враховують довільні умови формування сигналу та перетин класів розпізнавання.

4. Одним із перспективних шляхів аналізу та синтезу здатних навчатися систем керування протезом кінцівки руки є використання ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи розпізнавання в процесі її машинного навчання. Головна перевага методів інформаційно-екстремального машинного навчання полягає в тому, що вони розробляються в рамках функціонального підходу до моделювання когнітивних процесів, притаманних людині при формуванні та прийнятті класифікаційних рішень.

Основні наукові результати, наведені у першому розділі, опубліковано у працях автора [212], [217], [218],[225], [226].

РОЗДІЛ 2. АНАЛІЗ І СИНТЕЗ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЕРУВАННЯ ІНТЕЛЕКТУАЛЬНИМ ПРОТЕЗОМ РУКИ

2.1 Аналіз об'єкту дослідження та обґрунтування вибору методу досліджень

Функціональна ефективність машинного навчання суттєво залежить від двох основних факторів:

1) релевантності вхідних даних, які відбивають основні властивості об'єкту дослідження;

2) методу машинного навчання, який моделює когнітивні процеси природнього інтелекту при побудові та прийнятті класифікаційних рішень.

Науково-методологічні ускладнення, які виникають при машинному навчанні модуля системи керування протезом кінцівки руки, призначенням якого є розпізнавання електроміографічних біосигналів, пов'язані з невизначеністю вхідних даних, обумовленою як довільними умовами формуванні навчальної матриці, так і значним ступенем перетину класів розпізнавання у просторі ознак.

Крім того, досягнення високої функціональної ефективності машинного навчання такого модуля можливе за умови формування індивідуальної навчальної матриці, оскільки характеристики ЕМГ-сигналу є чутливими до особливостей реєстрації біопотенціалів користувача системи. Оскільки біосигнали зчитуються неінвазивною системою, то вони є суттєво зашумленими і залежними як від умов контакту ЕМГ-датчика, так і зовнішніх факторів, які впливають на емоційно-психологічний стан користувача [217]. Водночас в процесі формування вхідної навчальної матриці необхідно здійснити фільтрацію та нормалізацію ЕМГ-біосигналів. Отже, ЕМГ-біосигнал можна моделювати як стохастичний процес, який має статичну складову, обумовлену скороченням м'язових волокон при відсутності рухів суглобів, наприклад, при жестах утримання, та динамічні скорочення м'язових волокон у процесі рухів суглобів. Математична модель статичного скорочення є стаціонарним процесом, оскільки

середнє значення та коваріація залишаються приблизно однаковими з часом, а значення ЕМГ-імпульсу залежить виключно від м'язової сили [227]:

$$\text{EMG}(t) = \sum_{i=1}^N s_i(t) * m_i(t), \quad (2.1)$$

де N — кількість активних рухових одиниць;

$s_i(t)$ — ланцюг імпульсів, які вказують на активні моменти кожної рухової одиниці,

$m_i(t)$ — потенціал дії рухової одиниці;

$*$ — оператор згортки.

Водночас математичну модель статичного скорочення можна розглядати і як нестационарний процес, коли на ЕМГ сигнали впливають такі фактори, як м'язова втома та температура.

Математична модель динамічного скорочення, як нестационарного процесу, представляється модуляцією амплітуди:

$$\text{EMG}(t) = a(t)w(t) + n(t), \quad (2.2)$$

де $a(t)$ — функція, яка вказує на інтенсивність інформаційного сигналу;

$w(t)$ — гауссовий процес дисперсії несучого сигналу;

$n(t)$ — шум від датчиків і артефактів біологічного сигналу.

Математичні моделі (2.1) і (2.2) не знайшли практичного застосування при розпізнаванні ЕМГ-сигналів, утворених когнітивними командами відповідних рухів через складність оцінки параметрів нестационарних статистичних процесів. Але згідно з працею [228] використання методів машинного навчання дозволяє у рамках алгоритмічного підходу знаходити закономірності нестационарних статистичних процесів при аналізі сигналів ЕМГ-датчиків.

Реєстрація біопотенціалів електроміографічними датчиками, як це показано на рисунку 2.1, утворює квантовані за часом послідовності

електроімпульсів з яких і формується вхідний математичний опис системи, тобто навчальна матриця.




Рисунок 2.1 – ЕМГ-сенсори, закріплені на шкірі

Рисунок 2.2 демонструє реєстрацію зміни електроімпульсів на шкірі при виконанні типових рухів. За цими біопотенціалами відбувається формування вектору-реалізації з квантуванням у часі в 10 мс [225].




Рисунок 2.2 – Приклади зображень типових біосигналів:

а – згинання долоні; б — стискання долоні при утриманні предмету

Часова характеристика знімання показників ЕМГ сенсорів зумовлює однакову розмірність кожної реалізації руху у навчальному наборі даних. Втім, легко бачити, що рухи однієї групи м'язів породжують схожі набори ознак.

Використовуючи метод непропорційності [229] для обрахунку похідної сигналу, як характеристики тенденції зміни сигналу, можна спостерігати, що сигнали схожої розмірності породжують спільні ділянки ознак для двох сусідніх класів розпізнавання (рис 2.3).




Рисунок 2.3 – ЕМГ-сигнали з ділянками непропорційностей

За цим підходом електроміографічні імпульси, що реєструються датчиками на шкірі, можна подати, як дискретну функцію $y(x)$, де x – змінна часу, а відносна непропорційність першого порядку описується формулою:

$$\eta N_x^{(1)}y = 1 - \frac{x}{y} * \frac{dy}{dx}. \quad (2.3)$$

Фрагменти сигналів, подібних між собою, обумовлюють перетин класів розпізнавання у просторі ознак. Крім того, ЕМГ-сигнал містить артефакти, які ускладнюють процес відновлення у процесі машинного навчання контейнерів класів розпізнавання, геометричні параметри яких утворюють високодостовірні вирішальні правила.

Аналітичний огляд, проведений в першому розділі, показав, що одним із перспективних напрямів аналізу та синтезу здатних навчатися систем керування

протезом кінцівки руки є використання ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології). Методи інформаційно-екстремального машинного навчання ґрунтуються на максимізації інформаційної спроможності системи шляхом цілеспрямованої трансформації апріорного нечіткого розбиття простору первинних ознак на класи еквівалентності, контейнери яких відновлюються в радіальному базисі бінарного простору вторинних ознак Хеммінга. У рамках ІЕІ-технології існує принципова можливість побудови в процесі машинного навчання безпомилкових за навчальною матрицею вирішальних правил, що дозволяє одержати в робочому режимі системи керування повну ймовірність правильного класифікаційного висновку, наближену до асимптотичного максимального значення.

Вибір напрямку дисертаційних досліджень в рамках ІЕІ-технології потребує розв'язання набору науково-методологічних задач, пов'язаних з аналізом і синтезом системи керування протезом, здатної навчатися розпізнавати ЕМГ-сигнали.

Необхідно виконати перехід від унімодального гіперсферичного контейнера класу до формування ієрархічної структури гіперсферичних контейнерів [226] з метою розширення функціональних можливостей системи під час використанні багатомодальних розподілів реалізацій образу, що порушує принцип компактності. Визначити вплив кількості інтервалів контрольних допусків на значення ознак розпізнавання на функціональну ефективність машинного навчання модулю розпізнавання системи керування протезом. Уніфікувати подання різнотипних даних з метою оптимізації як кількісних так і категорійних ознак розпізнавання. Та автоматизувати формування вхідного математичного опису колективу інформаційно-екстремальних класифікаторів.

Таким чином, аналіз електроміографічних сигналів демонструє необхідність підвищення функціональної ефективності модулю розпізнавання рухів в системі керування протезом і доцільність використання як напряду дисертаційних досліджень ідей і методів ІЕІ-технології аналізу і синтезу здатних навчатися систем розпізнавання образів.

2.2 Формалізована постановка задачі інформаційного синтезу системи керування протезом кінцівки руки для розпізнавання біосигналів електроміографічних датчиків

Детерміновано-статистичний підхід [226] до прийняття рішень, покладений в основу методів ІЕІ-технології вимагає завдання як системи нормованих, так і контрольних допусків на ознаки розпізнавання. Так базовий клас X_1^0 характеризує максимальну функціональну ефективність здатної навчатися системи і формує за функціональним станом системи нормоване поле допусків $\{\delta_{H,i}, i = \overline{1, N}\}$, в якому ознаки розпізнавання класів X_1^0 знаходяться з імовірністю $p_i = 1$ або $p_i = 0$. Структуровані вектори ознак розпізнавання, які далі в тексті будемо називати реалізаціями класів розпізнавання когнітивних команд відповідних рухів, формують навчальні матриці типу «об'єкт-властивість» $\|y_{m,i}^{(j)} | i = \overline{1, N}; j = \overline{1, n}\|$ для заданого алфавіту класів розпізнавання $\{X_m^0 | m = \overline{1, M}\}$ [217]:

$$\|y_{m,i}^{(j)}\| = \begin{vmatrix} y_{m,1}^{(1)} & y_{m,2}^{(1)} & \dots & y_{m,1}^{(1)} & \dots & y_{m,N}^{(1)} \\ y_{m,1}^{(2)} & y_{m,2}^{(2)} & \dots & y_{m,1}^{(2)} & \dots & y_{m,N}^{(2)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y_{m,1}^{(j)} & y_{m,2}^{(j)} & \dots & y_{m,1}^{(j)} & \dots & y_{m,N}^{(j)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y_{m,1}^{(n)} & y_{m,2}^{(n)} & \dots & y_{m,1}^{(n)} & \dots & y_{m,N}^{(n)} \end{vmatrix} \quad (2.2)$$

Оскільки при нормальному розподілі реалізацій образу виправданою є гіпотеза компактності реалізацій образу [217], то в ІЕІ-технології введено поняття “контейнер”, який є апроксимованим наближенням “точної” складної замкненої роздільної гіперповерхні класу розпізнавання [216, 230], яке відновлюється на кожному кроці машинного навчання в радіальному базисі простору ознак розпізнавання у вигляді правильної геометричної фігури. Геометричний центр контейнеру класу розпізнавання X_m^0 , який в процесі

машинного навчання відновлюється в радіальному базисі Хеммінгова простору ознак, визначає реалізація x_m , яка є математичним сподіванням випадкових реалізацій $\{x_m^{(j)}\}$ цього класу розпізнавання.

Структура двійкового еталонного вектору класу X_m^0 , має вигляд

$$x_m = \langle x_{m,1}, \dots, x_{m,i}, \dots, x_{m,N} \rangle, m = \overline{1, N}, \quad (2.3)$$

де $x_{m,i}$ – і-та координата вектора, яка приймає одиничне значення, якщо значення ознаки X_i знаходиться в нормованому полі допусків $\delta_{H,i}$, і нульове значення, якщо не знаходиться.

У загальному випадку при прийнятті гіпотези нечіткої компактності [231] реалізацій образу розбиття простору ознак на класи розпізнавання є нечітким розбиттям $\tilde{\mathfrak{R}}^{|\mathcal{M}|}$, яке відповідає умовам [212]:

- 1) $(\forall X_m^0 \in \tilde{\mathfrak{R}}^{|\mathcal{M}|}) [X_m^0 \neq \emptyset];$
- 2) $(\exists X_k^0 \in \tilde{\mathfrak{R}}^{|\mathcal{M}|}) (\exists X_l^0 \in \tilde{\mathfrak{R}}^{|\mathcal{M}|}) [X_k^0 \neq X_l^0 \rightarrow X_k^0 \cap X_l^0 \neq \emptyset];$
- 3) $(\forall X_k^0 \in \tilde{\mathfrak{R}}^{|\mathcal{M}|}) (\forall X_l^0 \in \tilde{\mathfrak{R}}^{|\mathcal{M}|}) [X_k^0 \neq X_l^0 \rightarrow \text{Ker} X_k^0 \cap \text{Ker} X_l^0 = \emptyset];$
- 4) $\bigcup_{X_m^0 \in \tilde{\mathfrak{R}}} X_m^0 \subseteq \Omega_B; k \neq l; k, l, m = \overline{1, M}.$

Оскільки в рамках ІЕІ-технології вхідна навчальна матриця трансформується у робочу бінарну навчальну матрицю $\|x_{m,i}^{(j)}\|$, ознаки розпізнавання якої можуть змінюватись в процесі машинного навчання, реагуючи на оптимізацію параметрів системи допусків, то для розпізнавання реалізацій класу X_m^0 параметри машинного навчання задаються у вигляді структурованого вектору

$$g_m = \langle x_m, d_m, \delta \rangle, \quad (2.5)$$

де x_m – усереднений вектор-реалізація, вершина якого визначає геометричний центр гіперсферичного контейнеру класу X_m^0 ;

d_m – радіус контейнеру класу X_m^0 ;

δ - відносний параметр навчання, який дорівнює половині симетричного поля контрольних допусків на ознаки розпізнавання [213].

На параметри навчання задано такі обмеження:

$$d_m < d(x_m \oplus x_c), \quad (2.6)$$

де $d(x_m \oplus x_c)$ – кодова відстань між вектором x_m і усередненим вектором x_c сусіднього класу X_c^0 ;

$$\delta < \delta_H/2, \quad (2.7)$$

де δ_H – нормоване поле допусків, яке задає область значень контрольного поля допусків на ознаки розпізнавання.

За ІЕІ-технологією формування оптимального контейнера K_m^0 в радіальному базисі здійснюється шляхом його цілеспрямованої послідовної трансформації гіперсфери [230, 232], з центром представленим вектором-еталоном класу, радіус контейнеру d_m збільшується на кожному кроці навчання за рекурентною процедурою:

$$d_m(k) = [d_m(k-1) + h | d_m(k) \in G_m^d], \quad (2.8)$$

де k – змінна числа збільшень радіуса контейнера K_m^0 ;

h – крок збільшення радіуса;

G_m^d – область допустимих значень радіуса d_m .

Для класів X_k^0 і X_l^0 , які мають серед усіх класів найменшу міжцентрову відстань $d(x_k \oplus x_l)$, де x_k, x_l – еталонні вектори відповідних класів, за ІЕІ-

технологією з метою запобігання “поглинання” одним класом ядра іншого класу умови розбиття простору доповнюються таким предикатним виразом:

$$(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|})(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& \& (d_l^* < d(x_k \oplus x_l))], \quad (2.9)$$

де d_k^*, d_l^* – оптимальні радіуси контейнерів K_k^o і K_l^o відповідно.

В процесі машинного навчання системи керування протезом розпізнавати ЕМГ-сигнали необхідно оптимізувати координати вектора (2.5), які забезпечують максимальне значення інформаційного критерію в робочій області визначення його функції:

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap G_d} E_m(d), \quad (2.10)$$

де $E_m(d)$ – інформаційний критерій оптимізації параметрів навчання системи розпізнавати реалізації класу X_m^o ;

d – дистанційна міра радіусів гіперсферичних контейнерів класів розпізнавання;

G_E – робоча область визначення функції інформаційного критерію оптимізації параметрів машинного навчання;

G_d – допустима область зміни радіусів контейнерів класів розпізнавання [225].

Таким чином, задача інформаційного синтезу модуля розпізнавання ЕМГ-сигналів системи керування протезом полягає в оптимізації параметрів машинного навчання (2.5) шляхом наближення глобального максимуму інформаційного критерію (2.10) до його максимального граничного значення.

2.3 Формування вхідного математичного опису системи розпізнавання біосигналів з неінвазивною системою зчитування

Розглядаючи інформаційну модель керування протезом кінцівки руки варто визначити процеси отримання вхідних даних та алгоритми їх аналізу та перетворення до подальшої обробки.

Вхідний математичний опис здатної навчатися системи керування протезом задамо у вигляді теоретико-множинної структури

$$\Delta_B = \langle G, AR, T, \Omega, Z, Y, X; f, f \rangle, \quad (2.11)$$

де G – простір факторів, які впливають на процес формування когнітивних команд на виконання відповідних рухів протезу;

AR – множина артефактів, які впливають на спотворення ЕМГ-сигналу;

T – множина моментів часу зняття інформації;

Ω – простір ознак розпізнавання;

Z – простір можливих когнітивних команд, які утворюють алфавіт класів розпізнавання;

Y – вибіркова множина, яка представляє вхідну навчальну матрицю;

$f_1: G \times AR \times T \times \Omega \rightarrow Y$ – оператор формування множини Y ;

$f_2: Y \rightarrow X$ – оператор формування у Хеммінговому просторі ознак розпізнавання двійкової робочої навчальної матриці X .

Таким чином, джерело інформації можна задати як декартовий добуток множин:

$$W = G \times T \times \Omega \times Z. \quad (2.12)$$

Дані ЕМГ-датчиків, зареєстровані зі шкіри користувача, розглядаються як первинні ознаки розпізнавання. Втім формування словника ознак вимагає структурованої, комплексної репрезентації даних, тому вторинними ознаками

розпізнавання можуть вважатись статистичні характеристики реалізацій класів розпізнавання або всієї навчальної матриці.

Розглянемо негативний вплив збільшення потужності алфавіту при незмінному словнику ознак розпізнаванн, що призводить до збільшення ступеню перетину класів розпізнавання на асимптотичні точнісні характеристики системи керування протезом, що характеризують функціональну ефективність навчання системи. Імовірнісний критерій ступеню перетину класів для заданого алфавіту $\{X_m^0\}$: $m = \overline{1, M}$ визначимо як відношення усереднених для всіх класів розпізнавання точнісних характеристик, обчислених на k -му кроці навчання системи при двоальтернативній системі оцінки рішень:

$$\eta = \frac{\bar{\alpha}^{(k)} + \bar{\beta}^{(k)}}{D_1^{(k)} + D_2^{(k)}}, \quad (2.13)$$

де $\bar{\alpha}^{(k)} = \frac{1}{M} \sum_{m=1}^M \alpha_m^{(k)}$ – усереднена помилка першого роду;

$\bar{\beta}^{(k)} = \frac{1}{M} \sum_{m=1}^M \beta_m^{(k)}$ – усереднена помилка другого роду;

$D_1^{(k)} = \frac{1}{M} \sum_{m=1}^M D_{1,m}^{(k)}$ – усереднена перша достовірність;

$D_2^{(k)} = \frac{1}{M} \sum_{m=1}^M D_{2,m}^{(k)}$ – усереднена друга достовірність.

Для двоальтернативної системи оцінок рішень точнісні характеристики знаходяться у співвідношенні:

$$D_{1,m}^{(k)} + \alpha_m^{(k)} = 1; D_{2,m}^{(k)} + \beta_m^{(k)} = 1. \quad (2.14)$$

Важливою характеристикою вхідних даних є їх обсяг, який впливає на функціональну ефективність машинного навчання системи розпізнавання ЕМГ-сигналів. На рисунку 2.4 показано структурну схему алгоритму визначення мінімального обсягу навчальної вибірки.

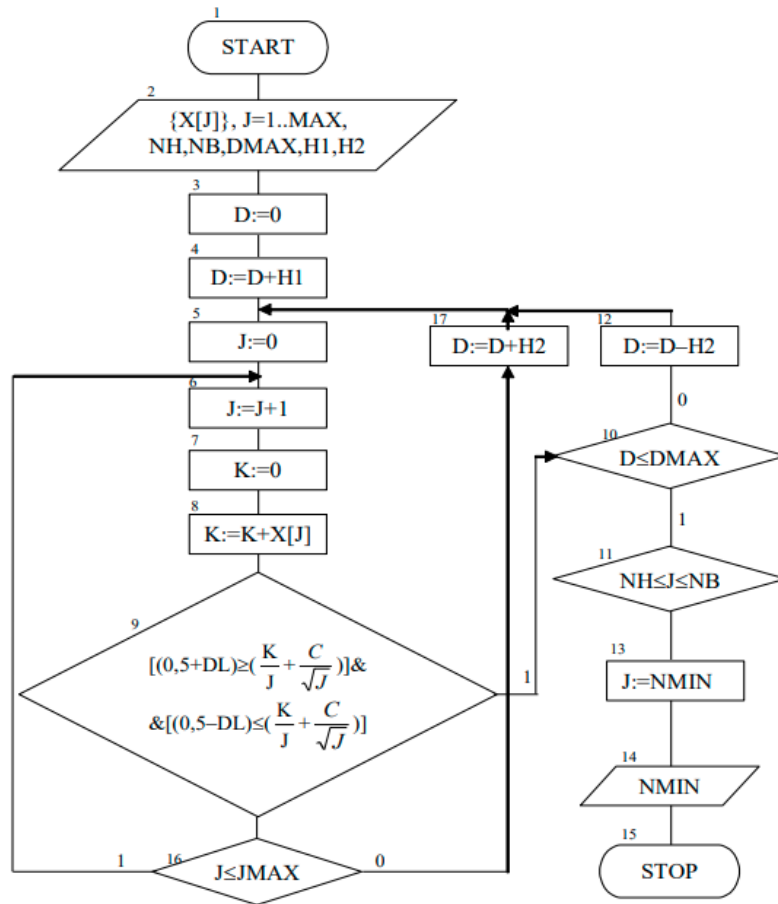


Рисунок 2.4 – Структурна схема алгоритму визначення репрезентативної навчальної вибірки

Вхідними даними алгоритму визначення мінімального обсягу репрезентативної навчальної вибірки є: $\{ [J] \}$ – бінарна навчальна вибірка, $J = \overline{1, MAX}$; DL – константа Δ ; ND – межа забороненої області I ; C – табличне значення аргументу функції Лапласа; H, SH – приращення константи Δ . Визначення $NMIN$ здійснювалося для кожної вибірки стовпчиків навчальної матриці. Блок 7 обчислює суму одиниць для кожної навчальної вибірки. Блок порівняння 8 визначає випробування, при якому заданий інтервал $[0,5 \pm \Delta]$ накриває поточний довірчий інтервал

$$P_{\text{дов}} \left\{ \frac{n_i}{n} - \varepsilon_{Q_{\max}}(n) \leq p_i \leq \frac{n_i}{n} + \varepsilon_{Q_{\max}}(n) \right\} = 1 - Q, \quad (2.15)$$

де Q – рівень значущості;

$\varepsilon_{Q_{\max}}(n)$ – максимальна статистична похибка, обчислена при заданому рівні значущості Q .

При заданому рівні значущості Q величина максимальної статистичної похибки $\varepsilon_{Q_{\max}}(n)$ обчислюється згідно з наслідком теореми Муавра-Лапласа як,

$$\varepsilon_{Q_{\max}}(n) = \frac{\arg[L(x)=1-\frac{Q}{2}]}{2\sqrt{n}}, \quad (2.16)$$

де $L(x)$ – функція Лапласа.

З метою машинного зупину процесу формування мінімальної репрезентативної навчальної вибірки визначається інтервал $[0,5 \pm \Delta]$ та задається компромісна область значень $0,5-\Delta < n < 0,5+\Delta$ для визначення мінімального обсягу репрезентативної навчальної вибірки [233]. В процесі машинного навчання визначається випробування n , при якому заданий інтервал $[0,5 \pm \Delta]$ покриває динамічний довірчий інтервал, що визначає мінімальний обсяг вибірки n_{\min} . З метою отримання однакової кількості векторів-реалізацій в навчальній матриці мінімальним обсягом всіх вибірок вважається максимальне значення

$$n_{\min} = \max_{\{j\}} n_{\min,i}. \quad (2.17)$$

Можливість використання визначених за наведеним вище алгоритмом навчальних вибірок мінімального обсягу в методах машинного навчання за інформаційно-екстремальною інтелектуальною технологією обумовлена ефектом згладження логарифмічних статистичних інформаційних критеріїв оптимізації параметрів машинного навчання. В інтелектуальних системах пріоритетність визначення обсягу навчальної вибірки забезпечення за інформаційною репрезентативністю переважає над задачами, які визначають репрезентативність випадкових вибірок в статистичному розумінні.

2.4 Функціональні категорійні моделі машинного навчання системи керування протезом для розпізнавання електроміографічних біосигналів

Розглянута в першому розділі категорійна модель машинного навчання за базовим алгоритмом інформаційно-екстремальної інтелектуальної технології представляла узагальнений орієнтований графа відображення множин, проте процес навчання модулю розпізнавання рухів системи керування протезом пов'язаний з аналізом значних обсягів вхідних даних. Необхідність передобробки сигналу зумовлює використання оптимізації системи допусків для ознак розпізнавання [216].




Рисунок 2.5 – Функціональна категорійна модель машинного навчання системи з оптимізацією системи контрольних допусків

На рис. 2.5 декартовий добуток $G \times AR \times T \times \Omega \times Z$ задає універсум випробувань. Оператор θ відображає двійкові вектори-реалізації навчальної матриці X на в загальному випадку нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$ простору ознак на класи розпізнавання, а оператор ψ перевіряє основну статистичну гіпотезу про належність реалізацій відповідному класу розпізнавання. За результатами статистичної перевірки гіпотез формується множина статистичних гіпотез $I^{|s|}$, де s – кількість статистичних гіпотез, а оператор γ формує множину точнісних характеристик $\mathfrak{Z}^{|q|}$, де $q = s^2$. Оператор ϕ обчислює множину E значень інформаційного критерію оптимізації параметрів навчання, а оператор r на кожному кроці машинного навчання відновлює в радіальному базисі простору

ознак контейнери класів розпізнавання. В категорійній моделі контур оптимізації контрольних допусків на ознаки розпізнавання замикається через терм-множину D – систему контрольних допусків, які використовуються як рівні квантування ознак розпізнавання при формуванні робочої бінарної навчальної матриці, яка в процесі навчання адаптується до високо достовірних вирішальних правил.

Алгоритм інформаційно-екстремального машинного навчання системи з оптимізацією контрольних допусків на ознаки розпізнавання згідно з категорійною моделлю (рис. 2.5) має вигляд

$$\{\delta_{k,i}^* | i = \overline{1, N}\} = \arg \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \}, \quad (2.18)$$

де $E^{(k)} = \frac{1}{M} \sum_{m=1}^M E_m^{(k)}$ – усереднене за алфавітом класів розпізнавання значення інформаційного КФЕ, обчислене на k -му кроці навчання; G_δ – область допустимих значень контрольних допусків на ознаки розпізнавання.

З метою підвищення функціональної ефективності інформаційно-екстремального ієрархічного машинного навчання [220, 234] системи керування протезом кісті руки з неінвазивною системою зчитування біосигналів шляхом оптимізації ієрархічної структури даних.

Категорійна модель (рис. 2.6) оптимізації ієрархічної структури класів розпізнавання [225] модифікує вхідний математичний опис у вигляді структури

$$I_B = \langle G, T, \Omega, Z, H, Y, X; f_1, f_2 \rangle. \quad (2.19)$$




Рисунок 2.6 – Категорійна модель машинного навчання системи з оптимізацією ієрархічної структури алфавіту класів розпізнавання

Декартовий добуток $G \times AR \times T \times \Omega \times Z \times H$ задає джерело інформації машинного навчання. Категорійна модель має додатковий контур оптимізації ієрархічної структури даних P , вершини якої містять атрибути класів розпізнавання із заданого алфавіту у вигляді їх навчальних матриць.

Згідно з категорійною моделлю (рис. 2.6) алгоритм машинного навчання системи керування протезом з оптимізацією структури P представимо у вигляді процедури

$$P^* = \arg \max_{G_p} \left\{ \max_{G_{Rn}\{S\}} \bar{E}_s \right\}. \quad (2.20)$$

Алгоритм оптимізації ієрархічної структури представимо основними етапами реалізації процедури (2.20)

- 1) обнуління лічильника варіантів ієрархічних структур: $r := 0$.
- 2) ініціалізація лічильника варіантів ієрархічних структур: $r := r + 1$.
- 3) обнуління лічильника ярусів структури даних: $h := 0$.
- 4) ініціалізація лічильника ярусів структури даних: $h := h + 1$.
- 5) обнуління лічильника страт яруса: $s := 0$.
- 6) ініціалізація лічильника страт яруса: $s := s + 1$.
- 7) для кожної s -ї страти h -го яруса r -ї ієрархічної структури реалізується базовий алгоритм інформаційно-екстремального машинного навчання, який реалізує оператори правого контуру категорійної моделі (рис. 2.5) з метою

оптимізації геометричних параметрів контейнерів класів розпізнавання за усередненим по всім кінцевим стратам інформаційного критерію $\bar{E}_{r,h,s}^*$.

8) якщо $s \leq S_h$, то виконується крок 6, інакше – крок 9.

9) якщо $h \leq h_{\max}$, де h_{\max} – кількість ярусів g -ї структури даних, то виконується крок 4, інакше – крок 10.

10) обчислюється усереднене за фінальними стратами максимальне значення інформаційного критерію оптимізації $\bar{E}_{r,h}^*$.

11) якщо $g \leq g_{\max}$, де g_{\max} – кількість ієрархічних структур даних, то виконується крок 2, інакше – крок 12.

12) визначається за процедурою (2.20) оптимальна ієрархічна структура даних.

13) ЗУПИН.

У якості альтернативи декурсивному формуванню дерева алгоритм оптимізації ієрархічної структури можна реалізувати за правилами агломеративного підходу кластеризації простору ознак [226].

Так попередній алгоритм модифікується наступними змінами:

8) За сформованими геометричними параметрами контейнерів класів розпізнавання визначаються міжцентрові відстані $D(X_1^0, X_2^0)$. Формується матриця міжкласових відстаней D' .

9) якщо $s \leq S_h$, то виконується крок 6, інакше – крок 10.

10) якщо $h \leq h_{\max}$, де h_{\max} – кількість ярусів g -ї структури даних, то виконується крок 4, інакше – крок 11.

11) Для найближчої пари класів $\min D(X_i^0, X_j^0)$ формується метакластер, який реалізує логіку нового контейнера класу. Новоутворений клас отримує реалізації обох класів як власні, формуючи новий центр класу за параметрами внутрішніх класів.

12) обчислюється усереднене за фінальними стратами максимальне значення інформаційного критерію оптимізації $\bar{E}_{r,h}^*$.

13) якщо $g \leq g_{\max}$, де g_{\max} – кількість ієрархічних структур даних, то виконується крок 2, інакше – крок 14.

14) визначається за процедурою (2.20) оптимальна ієрархічна структура даних.

15) ЗУПИН.

Наведені підходи описують цілеспрямований пошук глобального максимуму інформаційної міри системи для різних варіантів ієрархічної структури алфавіту класів розпізнавання.

Розглянемо рівень квантування біосигналів, як складову оптимізації процесу машинного навчання, для оптимізації адаптивності системи до характеристик ознак розпізнавання вхідного опису системи. Такий підхід [235] дозволяє сформулювати так звану зріджену навчальну матрицю, застосування якої зменшує вплив потужності алфавіту класів розпізнавання на повну ймовірність правильного прийняття класифікаційних рішень.




Рисунок 2.7 – Функціональна категорійна модель інформаційно-екстремального машинного навчання системи керування протезом

Варіант моделі, приведеної на рисунку 2.7, вводить новий контур оптимізації рівнів квантування електроміографічних біосигналів, який включає терм-множину H допустимих значень рівнів квантування [236]. У цьому контурі оператор h_1 на кожному кроці машинного навчання змінює рівень квантування, а оператор h_2 змінює словник ознак розпізнавання.

Алгоритм машинного навчання реалізує внутрішній цикл процедури (2.18), основними функціями якого є обчислення на кожному кроці машинного навчання інформаційного критерію оптимізації

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap \{k\}} E_m^{(k)} \quad (2.21)$$

та пошук його глобального максимуму [213].

У випадку базового класу X_m^0 алгоритм навчання вимагає визначити усереднений вектор ознак $y_m \in X_m^0$ та перетворити вхідну навчальну матрицю у робочу бінарну [213], елементи якої визначаються за правилом

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i} - \delta \leq y_{1,i}^{(j)} \leq y_{m,i} + \delta; \\ 0, & \text{if else.} \end{cases} \quad (2.22)$$

Формування масиву усереднених двійкових векторів-реалізацій $\{x_{m,i} | m = \overline{1, M}, i = \overline{1, N}\}$, керується за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m; \\ 0, & \text{if else,} \end{cases} \quad (2.23)$$

де ρ_m – рівень селекції координат двійкового вектора $x_m \in X_m^0$, який за замовчуванням приймається $\rho_m=0,5$;

Потім для заданого алфавіту з визначеним базовим класом розпізнавання реалізується у повному обсязі процедура (2.18) і визначаються оптимальні нижні і верхні контрольні допуски на ознаки розпізнавання [237] відповідно за правилами

$$A_{H,i}^* = y_{m,i} - \delta^*; A_{B,i}^* = y_{m,i} + \delta^*; \quad (2.24)$$

Таким чином для гіперсферичних контейнерів класів розпізнавання оптимальними параметрами інформаційно-екстремального машинному навчанні є усереднені вектори ознак розпізнавання для заданого алфавіту радіуси

контейнерів класів розпізнавання та система контрольних допусків і на ознаки розпізнавання.

2.5 Моделі функціонування системи керування протезом в режимі екзамену

Процес розпізнавання невідомої реалізації, який є етапом екзамену системи розпізнавання, можна представити діаграмою множин, яка має відмінності від діаграм оптимізаційного навчання у рамках ІЕІ-технології. Зворотний зв'язок у категорійній моделі екзамену не містить контурів оптимізації параметрів функціонування інформаційної системи керування протезом кінцівки руки, а оператор U_E реалізує регламентацію процесу екзамену. Замість оператора розбиття простору ознак на класи розпізнавання θ вводиться оператор P відображення бінарної вибіркової множини $X \subset \Omega_B$, що розпізнається, на сформоване на етапі машинного навчання чітке розбиття $\mathcal{R}^{|M|}$; оператор класифікації Ψ утворює композицію двох операторів: оператор обчислення функції належності $\Psi_1: \mathcal{R}^{|M|} \rightarrow F$, де F – множина функцій належності, і оператор дефазифікації $\Psi_2: F \rightarrow I^{|M+1|}$, який вибирає відповідну гіпотезу за максимальним значенням функції належності [233].

Результуюча діаграма відображень множин, що застосовуються при функціонуванні системи керування протезом в режимі екзамену набирає вигляду




Рисунок 2.8 – Категорійна модель інформаційно-екстремального машинного навчання системи керування протезом в режимі екзамену

На рисунку 2.8 оператор Φ_e відображає універсум випробувань на вибірку множини X , яка утворює екзаменаційну матрицю

$\|x_i^{(j)} | i = \overline{1, N}, j = \overline{1, n}\|$, аналогічну навчальній матриці за структурою, параметрами та процедурою формування. Попри те, що алгоритми екзамену у рамках ІЕІ-технології через розподіл реалізацій образів розпізнавання можуть утворювати різну структуру, обов'язковою умовою реалізації алгоритму є забезпечення однакових структурованості та параметрів формування як для навчальної, так і для екзаменаційної матриці.

За наявності чіткого розбиття, утвореного в процесі машинного навчання, алгоритм екзамену описує вхідні дані: M – кількість класів, які система керування протезом кінцівки руки навчена розпізнавати; $\{x_m^* | m = \overline{1, M}\}$ – масив еталонних двійкових векторів-реалізацій руху, які визначають центри відповідних оптимальних контейнерів класів розпізнавання; $\{d_m^*\}$ – масив оптимальних радіусів, утворених в процесі машинного навчання відповідних контейнерів класів розпізнавання; $\{x^{(j)} | j = \overline{1, n}\}$ – масив двійкових векторів-реалізацій рухів, що розпізнається; $\{\delta_{k,i}^* | i = \overline{1, N}\}$ – оптимальна СКД на ознаки розпізнавання, визначена на етапі машинного навчання системи керування.

За замовчуванням на практиці для бінеаризації екзаменаційної матриці приймається рівень селекції $\rho_m = 0,5$. Алгоритм розпізнавання реалізації в процесі екзамену у рамках ІЕІ-технології полягає в аналізі значень функції належності, яка для гіперсферичного контейнера класу розпізнавання X_m^0 має вигляд

$$\mu_m = 1 - \frac{d(x_m^* \oplus x^{(j)})}{d_m^*} \quad (2.25)$$

і обчислюється для кожної реалізації, що розпізнається.

Розглянемо реалізацію алгоритму екзамену при нечіткому розбитті простору ознак розпізнавання, яке відповідає загальному випадку:

- 1) формування лічильника класів розпізнавання: $m := m + 1$;
- 2) формування лічильника числа реалізацій, що розпізнаються: $j := j + 1$;

- 3) обчислення кодової відстані $d(x_m^* \oplus x^{(j)})$;
- 4) обчислення функції належності;
- 5) порівняння: якщо $j \leq n$, то виконується крок 2, інакше – крок 6;
- 6) порівняння: якщо $m \leq M$, то виконується крок 1, інакше – крок 7;
- 7) визначення класу X_m^0 , до якого належить реалізація руху, за умови

$$\bar{\mu}_m^* = \max_{\{m\}} \bar{\mu}_m, \text{ де } \bar{\mu}_m = \frac{1}{n} \sum_{j=1}^n \mu_{m,j} - \text{усереднене значення функцій належності}$$

реалізацій класу X_m^0 . У випадку $\bar{\mu}_m^* \leq c$, при пороговому значенні c , рішення системи буде маркувати реалізацію, подану до розпізнавання як невідомий клас.

За підходом ІЕІ-технології алгоритм екзамену є детермінованим і відрізняється незначною обчислювальною трудомісткістю, що дозволяє оперативно приймати класифікаційні рішення у реальному часі. У випадку чіткого розбиття простору ознак на класи розпізнавання нечіткий алгоритм є так само працездатним, оскільки він розглядається по відношенню до чіткого алгоритму як загальний.

2.6 Висновки до другого розділу

У другому розділі проаналізовано особливості розпізнавання рухів за ЕМГ сигналами, зареєстрованими з шкіри та розглянуто в рамках ІЕІ-технології питання інформаційного аналізу і синтезу здатної навчатися системи керування протезом кінцівки руки. Одержано такі наукові результати:

1. Аналіз електроміографічних сигналів показав необхідність підвищення функціональної ефективності існуючих систем розпізнавання жестів на основі машинного навчання та розпізнавання образів. При цьому основні ускладнення інформаційного синтезу таких систем пов'язані із такими причинами:

- зашумленість сигналу;
- довільні умови формування біоімпульсів, що обумовлені відмінними антропологічними особливостями користувача;

– перетин класів розпізнавання, що характеризують функціональні стани досліджуваних рухів;

Обґрунтовано доцільність використання, як напряму дисертаційних досліджень, ідей і методів ІЕІ-технології, орієнтованої на аналіз і синтез здатних навчатися систем керування здатних до розпізнавання образів за умов неповної визначеності даних.

2. Сформовано постановку задачі інформаційного синтезу системи керування протезом кінцівки руки, що навчається, для розпізнавання рухів за ЕМГ біосигналами, яка полягає в ітераційній процедурі оптимізації в процесі навчання за інформаційним КФЕ параметрів функціонування системи керування протезом і в прийнятті в режимі екзамену рішення розпізнавання жесту за побудованими на етапі навчання вирішальними правилами.

Таким чином, основний напрямок підвищення точності машинної інтерпретації біопотенціалів полягає в адаптації вхідного математичного опису та побудованих в процесі навчання вирішальних правил для класифікатора електроміографічних імпульсів, зареєстрованих на шкірі людини, до практичних умов проведення розпізнавання руху за імпульсами в м'язах шляхом максимізації інформаційної спроможності системи керування.

3. Вперше розроблено категорійні моделі системи керування протезом кінцівки руки для розпізнавання електроміографічних сигналів, які при побудові в процесі навчання вирішальних правил враховують формування ієрархічних структур для розбиття простору ознак з метою компенсації перетину ознак класів розпізнавання, як недоліку ЕМГ сигналу. При цьому додавання в контур оптимізації геометричних параметрів вирішальних правил дозволяє побудувати за ієрархічною структурою контейнери класів і підвищити точність класифікації зареєстрованого біосигналу за умов довільних умов формування розпізнаваної реалізації та нерівномірного розподілу навчальних векторів-реалізацій в області свого класу розпізнавання.

Основні наукові результати, наведені у другому розділі, опубліковано у працях автора [212], [217], [218], [225], [226], [236].

РОЗДІЛ 3. ОПТИМІЗАЦІЯ ПАРАМЕТРІВ МАШИННОГО НАВЧАННЯ СИСТЕМИ КЕРУВАННЯ ПРОТЕЗОМ

3.1 Інформаційно-екстремальне машинне навчання модуля системи керування протезом кисті руки для розпізнавання електроміографічних сигналів

Згідно з категорійною моделлю (рис. 2.4) інформаційно-екстремальний алгоритм машинного навчання системи керування з оптимізацією системи контрольних допусків на ознаки розпізнавання подається у вигляді процедури пошуку глобального максимуму інформаційного критерію в робочій області визначення його функції

$$\delta^* = \arg \max_{G_\delta} \left[\frac{1}{M} \sum_{m=1}^M \max_{G_{E_m} \cap \{d\}} E_m(d) \right], \quad (3.1)$$

де $E_m(d)$ – інформаційний критерій оптимізації параметрів машинного навчання системи розпізнавати реалізації класу X_m^0 ; на ознаки розпізнавання;
 G_{E_m} – робоча (допустима) область визначення критерію $E_m(d)$;
 $\{d\}$ – множина значень радіусів гіперсферичних контейнерів класів розпізнавання.

Основна ідея інформаційно-екстремального машинного навчання полягає у трансформації апріорного нечіткого розбиття багатовимірного евклідового простору ознак розпізнавання в чітку еквівалентність класів, контейнери яких відновлюються в радіальному базисі бінарного субпарацептуального простору Хеммічання. Водночас за отриманими у процесі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання будуються безпомилкові за навчальною матрицею вирішальні правила. Саме побудова вирішальних правил у рамках геометричного підходу надає їм такі важливі властивості, як практична інваріантність до багатовимірності простору

ознак розпізнавання та висока оперативність прийняття класифікаційних рішень, які із зростанням технічних можливостей сучасної обчислювальної техніки відіграють важливу роль при аналізі великих обсягів даних у кіберфізичних системах, до яких відносяться також інтелектуальні протези руки з різним ступенем враження.

Розглянемо основні етапи базового алгоритму інформаційно-екстремального машинного навчання, який обчислює оптимальні геометричні параметри контейнерів класів розпізнавання і реалізується у внутрішньому циклі процедури (3.1).

1. Навчальна бінарна матриця $\{x_{m,i}^{(j)}\}$ формується за прийнятим в ІЕІ-технології правилом

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_{K,i} \\ 0, & \text{else;} \end{cases} \quad (3.2)$$

2. Масив усереднених двійкових векторів $\{x_{m,i} | m = \overline{1, M}, i = \overline{1, N}\}$ визначається за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho; \\ 0, & \text{else;} \end{cases} \quad (3.3)$$

де ρ – рівень селекції координат двійкових усереднених векторів-реалізацій.

3. Знаходження для заданого алфавіту класів розпізнавання найближчих сусідів, які утворюють структуровану множину елементів попарного розбиття

$$\{\mathcal{R}_m^{\|2\|} = \langle x_m, x_c \rangle\}, \quad (3.4)$$

де x_c – усереднений вектор-реалізація найближчого сусіднього класу розпізнавання X_c^0 , яка задає план машинного навчання.

4. Оптимізація кодової відстані d_m відбувається шляхом перебору допустимих значень радіусів у частинному випадку гіперсферичних контейнерів класів розпізнавання..

5. Процедура закінчується при знаходженні максимуму інформаційного критерію оптимізації в робочій області його визначення, тобто

$$E_m^* = \max_{\{d\}} E_m, \quad (3.5)$$

де $\{d\} = \{0, 1, \dots, d < d(x_m \oplus x_l)\}$ – множина радіусів концентрованих гіперсфер, центр яких визначається вершиною вектора $x_m \in X_m^0$.

Інформаційна міра системи для оцінки функціональної ефективності має відображати згладжуючу властивість логарифмічної функції. Тому у якості ентропійної міри системи керування протезом кінцівки руки міра Кульбака розглядається як добуток відношення правдоподібності на міру відхилень розподілів імовірностей.

Нормований ентропійний критерій навчання [233] системи керування протезом кінцівки руки для розпізнавання рухів за біосигналами реалізацій класу X_m^0 визначається формулою:

$$E_m^{(k)} = \frac{I_m^{(k)}}{I_{max}^{(k)}} = \frac{H_m^{(k)} - H_m^{(k)}(\gamma)}{H_m^{(k)}}, \quad (3.6)$$

де $I_m^{(k)}$ – кількість умовної інформації, що обробляється на k -му кроці навчання системи керування протезом, розпізнавати реалізації класу X_m^0 ; $I_{max}^{(k)}$ – максимальна можлива кількість умовної інформації, одержаної на k -му кроці навчання; $H_m^{(k)}$ – апіорна ентропія, що існує на k -му кроці навчання системи розпізнавати реалізації класу X_m^0 , яка обчислюється за формулою:

$$H_m^{(k)} = - \sum_{l=1}^M p^{(k)}(\gamma_l) \log_2 p^{(k)}(\gamma_l), \quad (3.7)$$

де $p^{(k)}(\gamma_l)$ – безумовна ймовірність прийняття на k -му кроці навчання гіпотези γ_l ;

$H_m^{(k)}(\gamma)$ – апостеріорна ентропія, що характеризує залишкову невизначеність після k -го кроку навчання системи розпізнавати реалізації класу X_m^0 , яка обчислюється за формулою

$$H_m^{(k)}(\gamma) = - \sum_{l=1}^M \sum_{m=1}^M p^{(k)}(\gamma_l) p^{(k)}(\mu_m/\gamma_l) \log_2 p^{(k)}(\mu_m/\gamma_l), \quad (3.8)$$

де $p^{(k)}(\mu_m/\gamma_l)$ – апостеріорна ймовірність прийняття на k -му кроці машинного навчання рішення μ_m за умови, що попередньо була прийнята гіпотеза γ_l .

Розглядаючи двохальтернативну систему оцінок ($M = 2$) для рівноймовірних класифікаційних гіпотез ентропійний критерій для оптимізації геометричних параметрів гіперсферичних контейнерів класів визначається, як

$$\begin{aligned} E_m^{(k)} = 1 + \frac{1}{2} & \left(\frac{p_m^{(k)}(\gamma_2/\mu_1)}{p_m^{(k)}(\gamma_2/\mu_1) + p_m^{(k)}(\gamma_2/\mu_2)} \log_2 \frac{p_m^{(k)}(\gamma_2/\mu_1)}{p_m^{(k)}(\gamma_2/\mu_1) + p_m^{(k)}(\gamma_2/\mu_2)} + \right. \\ & + \frac{p_m^{(k)}(\gamma_1/\mu_2)}{p_m^{(k)}(\gamma_1/\mu_1) + p_m^{(k)}(\gamma_1/\mu_2)} \log_2 \frac{p_m^{(k)}(\gamma_1/\mu_2)}{p_m^{(k)}(\gamma_1/\mu_1) + p_m^{(k)}(\gamma_1/\mu_2)} + \\ & + \frac{p_m^{(k)}(\gamma_1/\mu_1)}{p_m^{(k)}(\gamma_1/\mu_1) + p_m^{(k)}(\gamma_1/\mu_2)} \log_2 \frac{p_m^{(k)}(\gamma_1/\mu_2)}{p_m^{(k)}(\gamma_1/\mu_1) + p_m^{(k)}(\gamma_1/\mu_2)} + \\ & \left. + \frac{p_m^{(k)}(\gamma_2/\mu_2)}{p_m^{(k)}(\gamma_2/\mu_2) + p_m^{(k)}(\gamma_2/\mu_1)} \log_2 \frac{p_m^{(k)}(\gamma_2/\mu_2)}{p_m^{(k)}(\gamma_2/\mu_2) + p_m^{(k)}(\gamma_2/\mu_1)} \right). \end{aligned} \quad (3.9)$$

Апріорні умовні ймовірності у формулі (3.9) представляють собою точнісні характеристики двохальтернативних класифікаційних рішень системи:

$D_{1,m}^{(k)} = p_m^{(k)}(\gamma_1/\mu_1)$ – перша достовірність;

$\alpha_m^{(k)} = p_m^{(k)}(\gamma_2/\mu_1)$ – помилка першого роду; $\beta_m^{(k)} = p_m^{(k)}(\gamma_1/\mu_2)$ – помилка другого

роду; $D_{2,m}^{(k)} = p_m^{(k)}(\gamma_2/\mu_2)$ – друга достовірність, і описують імовірності подій

однієї групи:

$$D_{1,m}^{(k)} + \alpha_m^{(k)} = 1; \quad D_{2,m}^{(k)} + \beta_m^{(k)} = 1. \quad (3.10)$$

Ентропійний критерій набуває вигляду:

$$E_m^{(k)} = 1 + \frac{1}{2} \left(\frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} + \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \frac{D_{1,m}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{D_{1,m}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \right), \quad (3.11)$$

де d – дистанційна міра, яка визначає радіуси гіперсферичних контейнерів класів розпізнавання, сортована за метрикою відстані для простору Хеммінга.

Реалізація базового алгоритму навчання системи керування протезом руки для розпізнавання рухів за біоімпульсами здійснювалася за вибіркою серій зареєстрованих електроміографічними датчиками рухів долоні використовує модифіковану інформаційну міру Кульбака, яка для двохальтернативних рішень з апіорно рівноймовірними гіпотезами має вигляд:

$$E_m(d) = [D_{1,m}(d_m) - \beta_m(d_m)] \log_2 \frac{1 + [D_{1,m}(d_m) - \beta_m(d_m)] + 10^{-r}}{1 - [D_{1,m}(d_m) - \beta_m(d_m)] + 10^{-r}}, \quad (3.12)$$

де 10^{-r} достатньо мале число, яке вводиться для уникнення поділу на нуль.

Для алфавіту класів розпізнавання, які характеризують ЕМГ-сигнали для трьох рухів: клас розпізнавання X_1^0 – згинання долоні, клас розпізнавання X_2^0 – розгинання долоні, клас розпізнавання X_3^0 – стискання предмету, було реалізовано базовий алгоритм інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з метою формування вирішальних правил.

На рис. 3.1 показано графіки залежності інформаційного критерію (3.12) від радіусів контейнерів, що одержані в процесі реалізації базового алгоритму інформаційно-екстремального машинного навчання з гіперсферичним

класифікатором. Штрихована ділянка на графіках позначає робочу область визначення функції КФЕ, в якій значення першої та другої достовірностей перевершують відповідні помилки.

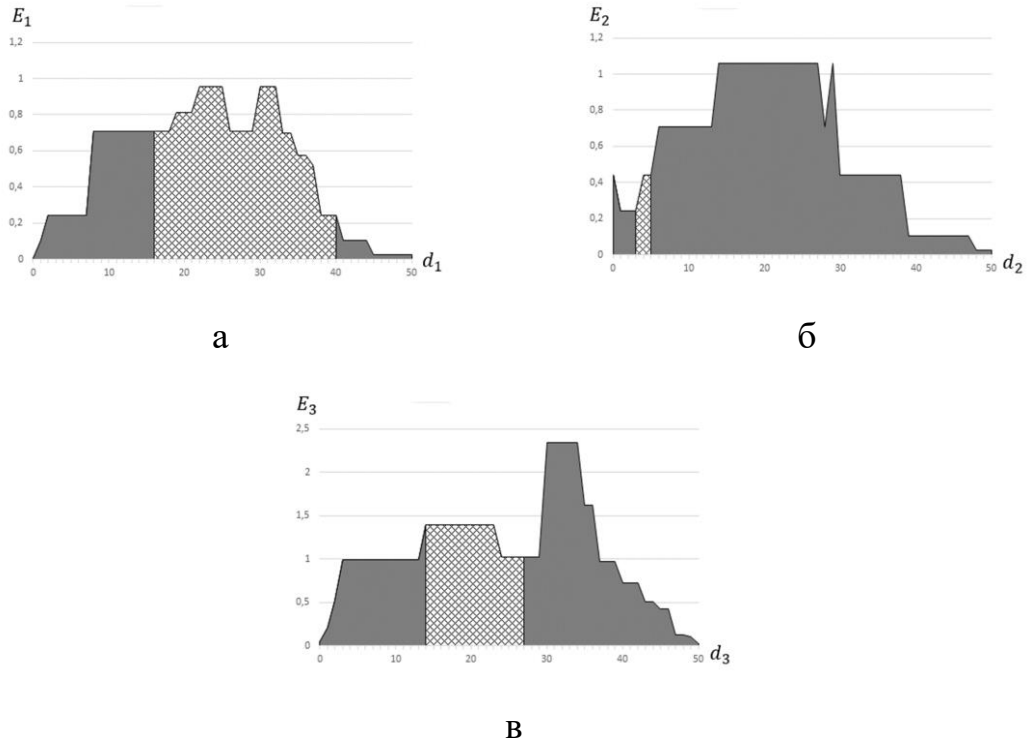


Рисунок 3.1 – Графіки залежності інформаційного критерію від радіусів контейнерів: а – клас розпізнавання X_1^0 ; б – клас розпізнавання X_2^0 ; в – клас розпізнавання X_3^0 .

Аналіз графіків оптимізації радіусів контейнерів класів розпізнавання рис. 3.1 демонструє, що їх оптимальні значення відповідно дорівнюють: $d_1^* = 22$, $d_2^* = 4$ та $d_3^* = 14$ (тут і далі в кодових одиницях). Міжцентрові відстані контейнерів класів дорівнюють $d(x_1 \otimes x_2) = 31$, $d(x_1 \otimes x_3) = 41$ та $d(x_2 \otimes x_3) = 59$ відповідно. При цьому отримано відповідні максимальні значення нормованого КФЕ: $E_1^* = 0,95$, $E_2^* = 0,44$ і $E_3^* = 1,4$. Значення усередненого нормованого КФЕ навчання дорівнює $\bar{E} = 0,93$, тобто не досягає граничного максимального, що зумовлено неоптимальними значеннями параметрів функціонування системи керування протезом кінцівки руки, в першу чергу системи контрольних допусків на ознаки розпізнавання.

3.2 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з паралельною оптимізацією системи контрольних допусків.

Згідно з категорійною моделлю (рис.2.4), інформаційно-екстремальний алгоритм навчання системи керування з оптимізацією системи контрольних допусків на ознаки розпізнавання подається у вигляді процедури пошуку глобального максимуму інформаційного критерію (3.12) в робочій області визначення його функції

$$\{\delta_{k,i}^* | i = \overline{1, N}\} = \arg \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \}. \quad (3.13)$$

Оптимізація системи контрольних допусків відбувається за паралельним алгоритмом з симетричною стратегією, що забезпечує високу оперативність реалізації алгоритму. На рисунку 3.3 показано схему симетричних допусків на ознаку розпізнавання.




Рисунок 3.2 – Симетричне поле допусків

Рисунок 3.2 ілюструє принцип визначення меж для системи допусків за параметрами ознак навчання з A_0 - номінальним значенням ознаки y_i , A_H і A_B - нижній і верхній нормовані допуски відповідно; A_{HK} і A_{BK} - нижній і верхній контрольні допуски відповідно; $\delta_{H,i}$ - нормоване поле допусків; $\delta_{K,i}$ - контрольне поле допусків.

Вхідною інформацією для алгоритму навчання є масив вхідної навчальної матриці $\{y_{m,i}^{(j)}\}$ і система полів нормованих допусків $\{\delta_{H,i}\}$ на ознаки розпізнавання, яка задає область значень відповідних контрольних допусків.

Основні етапи реалізації алгоритму навчання системи керування з паралельною оптимізацією контрольних допусків на ознаки розпізнавання, за якою на кожному кроці навчання змінюються контрольні допуски для всіх ознак розпізнавання одночасно полягають в:

1) ініціалізації лічильника кроків зміни параметра δ поля контрольних допусків на ознаки розпізнавання: $\delta := 0$;

2) $\delta := \delta + 1$;

3) обчисленні для всіх ознак розпізнавання $A_{HK,i}$ і $A_{BK,i}$ контрольних допусків на ознаки розпізнавання:

$$A_{HK,i} = y_i - \delta; A_{BK,i} = y_i + \delta; \quad (3.14)$$

4) реалізується внутрішній цикл процедури обчислення на кожному кроці зміни радіусів контейнерів класів розпізнавання інформаційного критерію оптимізації параметрів навчання, пошуку глобального максимуму інформаційного критерію і визначенні оптимальних радіусів контейнерів класів розпізнавання за процедурою

5) якщо $\delta \leq \delta_H / 2$, то виконується пункт 2, інакше – пункт 6;

6) обчислюється усереднене за алфавітом класів розпізнавання максимальне значення критерію E^* ;

7) визначається оптимальний параметр поля контрольних допусків, який забезпечує максимальне значення усередненого критерію E^* ;

8) обчислюється за формулою (3.14) оптимальна система контрольних допусків на ознаки розпізнавання

9) ЗУПИН

Таким чином, параметрами інформаційно-екстремального навчання системи керування за процедурою (4) є оптимальні радіуси $\{d_m^*\}$

гіперсферичних контейнерів класів розпізнавання, оптимальні еталонні вектори-реалізації $\{x_m^*\}$ класів розпізнавання і оптимальний параметр δ^* поля контрольних допусків на ознаки розпізнавання.

Отримані за результатами паралельної оптимізації контрольні допуски на ознаки розпізнавання є по суті квазіоптимальними, оскільки вони на кожному кроці навчання змінювалися для всіх ознак на однакову величину.




Рисунок 3.3 – Графік залежності інформаційного критерію від параметра поля контрольних допусків

На рисунку 3.3 подвійною штриховкою позначено робочі області визначення критерію (3.13), в яких перша і друга достовірності перевершують відповідно помилки першого і другого роду. При цьому оптимальне значення параметра δ визначається максимальною величиною інформаційного критерію у всіх робочих областях. Аналіз графіку показує, що оптимальне значення параметру поля контрольних допусків дорівнює $\delta^* = \pm 13 \text{mV}$ при максимальному значенні ненормованого інформаційного критерію $E^* = 1,2$.

Для побудови вирішальних правил необхідно знання оптимальних в інформаційному розумінні геометричних параметрів контейнерів класів розпізнавання. На рис. 3.4 показано графіки залежності інформаційного критерію (3.12) від радіусів контейнерів класів розпізнавання, одержаних при оптимальному параметрі поля контрольних допусків на ознаки розпізнавання.

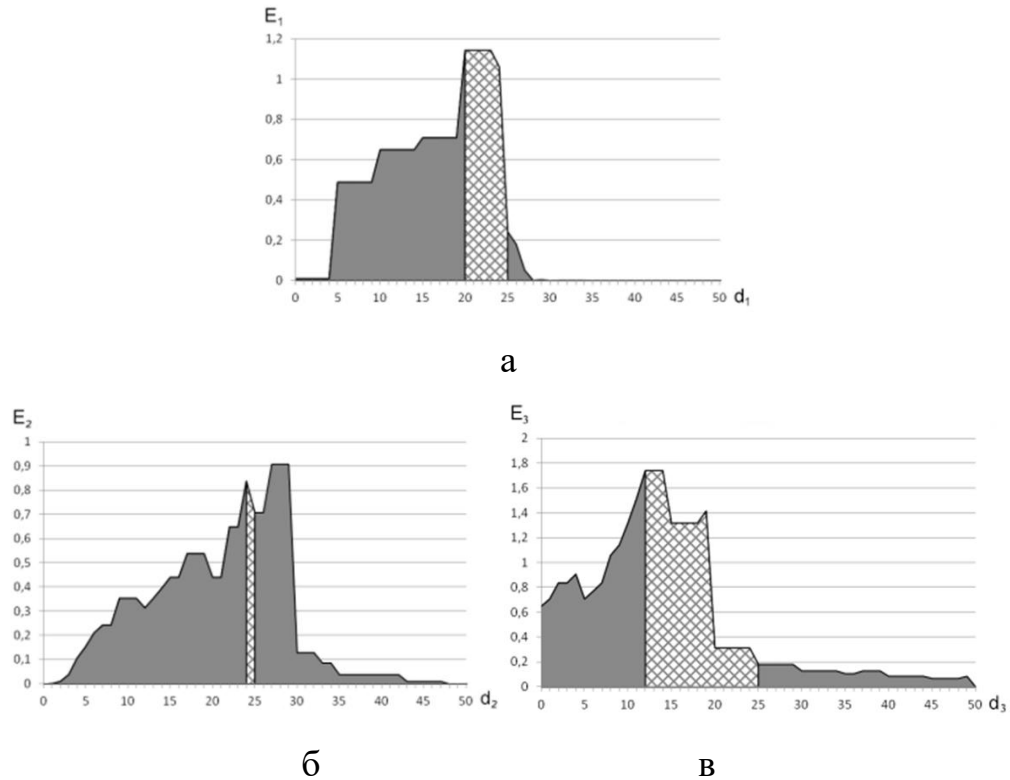


Рисунок 3.4 – Графіки залежності інформаційного критерію від радіусів контейнерів класів розпізнавання: а – клас розпізнавання X_1^0 ; б – клас розпізнавання X_2^0 ; в – клас розпізнавання X_3^0 .

Аналіз рисунку 3.4 показує, що оптимальні значення радіусів контейнерів класів розпізнавання, визначені при оптимальному параметрі поля контрольних допусків, дорівнюють: для класу розпізнавання $X_1^0 - d_1^* = 23$, для класу $X_2^0 - d_2^* = 24$ і для класу $X_3^0 - d_3^* = 12$.

В результаті машинного навчання системи керування протезом руки здійснено оптимізацію системи контрольних допусків на ознаки розпізнавання, досліджено їх вплив на функціональну ефективність навчання системи і побудовано вирішальні правила, які дозволили оперативно приймати високо достовірні класифікаційні рішення. Проте оскільки інформаційний критерій оптимізації параметрів машинного навчання систем керування протезом кінцівки руки не досягає свого граничного максимального значення, то синтезований класифікатор біосигналів не є безпомилковим за навчальною матрицею. Для підвищення функціональної ефективності доцільно збільшити

глибину машинного навчання шляхом оптимізації додаткових параметрів функціонування системи керування.

3.3 Інформаційно екстремальне машинне навчання модуля розпізнавання системи керування протезом за ієрархічною структурою даних у вигляді декурсивного дерева

Збільшення потужності алфавіту зменшує точність машинного навчання через збільшення ступеню перетину в просторі ознак класів розпізнавання. У праці [238] запропоновано вирішення цієї проблеми шляхом представлення складних рухів як комбінації декількох простих рухів. Проте у дослідженнях [239, 240] звертають увагу, що через багатовимірність зростає набір ознак і це спричиняє помилки у розпізнаванні рухів від одного м'язу, чи м'язів, що належать до однієї локальної групи.

Суттєве збільшення словника ознак зменшує точність розпізнавання [238], оскільки збільшення наборів ознак ускладнює розпізнавання сигналів за відомими дискретними шаблонами.

З метою зменшення впливу перетину класів розпізнавання у просторі ознак згідно з працями [241 – 244], простір ознак декомпозується у менші підпростори, формуючи агломеративну ієрархічну структуру [225, 245, 246].

Розглянемо формалізовану постановку задачі інформаційно-екстремального кластер-аналізу вхідних даних системи керування протезом руки з неінвазивною системою зчитування сигналів. Нехай кожний клас розпізнавання характеризує біосигнал, який зчитується з електроміографічного датчика при виконанні відповідної когнітивної команди. Дано ієрархічну структуру алфавіту класів розпізнавання

$$\{X_{h,s,m}^o | h = \overline{1, H}, s = \overline{1, S}, m = \overline{1, M}\}, \quad (3.15)$$

де H – кідькість ярусів дерева і S – кідькість страт h -го яруса, для якого за результатами моніторингу сигналів з датчика інформації для кожної страти сформовано чотиривимірну навчальну матрицю

$$\|y_{h,s,m,i}^{(j)}\|, i = \overline{1, N}, j = \overline{1, n}. \quad (3.16)$$

Згідно з категорійною моделлю (рис. 2.5) алгоритм машинного навчання системи керування протезом з оптимізацією структури P представимо у вигляді процедури

$$P^* = \arg \max_{G_P} \{ \max_{G_R \cap \{S\}} \overline{E}_S \}. \quad (3.17)$$

При формуванні навчальної матриці крок квантування біосигналів складав 10 мілісекунд, а інтервал квантування – 1,2 с. Таким чином, структурований вектор-реалізація одного класу розпізнавання складався із 120 ознак розпізнавання, які дорівнювали дискретним значенням біосигналів, що зчитувалися послідовно з електроміографічного датчика. При цьому з метою усунення фонового шуму вектор ознак складався з дискрет, значення яких були більше 30 mV.

При інформаційно-екстремальному машинному навчанні системи керування протезом досліджувалися дві ієрархічні структури даних: дихотомічна бінарна ієрархічна структура, за якою спочатку оптимізувалися геометричні параметри одного класу розпізнавання, а додругого входили вектори ознак всіх інших класів.

Після оптимізації параметрів першого класу розпізнавання його вектори ознак видалялися із вхідної навчальної матриці. Потім аналогічно оптимізувалися параметри одного класу розпізнавання із трьох класів, які залишилися в алфавіті. І нарешті здійснювалася оптимізація параметрів машинного навчання для двох останніх класів розпізнавання. Іншою досліджувалася так звана декурсивна ієрархічна структура у вигляді бінарного


У таблиці 3.1 показано результати оптимізації ієрархічних структур даних в процесі інформаційно-екстремального машинного навчання системи керування протезом кісті руки з неінвазивною системою зчитування біосигналів для заданого алфавіту з чотирьох класів розпізнавання.

Таблиця 3.1 – Результати оптимізації ієрархічних структур


Номер варіанту	\bar{E}^*	\bar{D}_1	$\bar{\beta}$	\bar{P}_t^*
1	3,99	0,88	0,07	0,91
2	3,50	0,80	0,11	0,84
3	3,55	0,82	0,12	0,85
4	4,40	1,00	0,00	1,00

У таблиці 3.1 як перший варіант розглядається дихотомічна бінарна ієрархічна структура даних, другий варіант – структура, показана на рисунку 3.5а, третій варіант – структура на рисунку 3.5б і четвертий варіант – структура рисунок 3.5в.

На рисунку 3.6 показано графіки залежності інформаційного критерію оптимізації (3.18) від радіусів контейнерів класів розпізнавання першої фінальної страти ієрархічної структури, показаної на рис. 3.7в.



а



б

Рисунок 3.6 – Графіки залежності критерію від радіусів контейнерів класів розпізнавання першої фінальної страти а – клас розпізнавання X_1^0 ; б – клас розпізнавання X_4^0 .

На рисунку 3.9 показано графіки залежності критерію (3.18) від радіусів контейнерів класів розпізнавання другої фінальної страти структури (рис. 3.5в).




Рисунок 3.7 – Графіки залежності критерію від радіусів контейнерів класів розпізнавання другої фінальної страти структури: а – клас розпізнавання X_2^0 ; б – клас розпізнавання X_3^0

Аналіз рисунків 3.6 і 3.7 показує, що середнє значення критерію оптимізації (3.18) для фінальних страт дорівнює максимальному значенню критерію $E^*=4,39$. Оскільки графіки на цих рисунках мають ділянки типу “плато”, то визначення оптимальних радіусів контейнерів класів розпізнавання здійснювалося за умови мінімальних значень коефіцієнта нечіткої компактності який має вигляд

$$\eta = \frac{d_{h,s,m}^*}{d(x_{h,s,m} \oplus x_{h,s,c})}. \quad (3.19)$$

Визначені згідно з виразом (3.19) оптимальні радіуси контейнерів класів розпізнавання відповідно дорівнювали: $d_1^*=11$, $d_2^*=25$, $d_3^*=29$ і $d_4^*=15$.

Таким чином, при функціонуванні системи керування в режимі екзамену, на якому оцінюється функціональна ефективність машинного навчання, або безпосередньо в робочому режимі за вирішальними правилами визначається належність вектору ознак, що розпізнається, одному із класів із заданого

алфавіту. При цьому вирішальні правила через малу обчислювальну трудомісткість відрізняються високою оперативністю.

3.4 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з агломеративною ієрархічною структурою даних

З метою збільшення розміру алфавіту класів додатково було розглянуто електроміографічні сигнали шести рухів [247], які задіюють спільні групи м'язів (рис.3.8).




Рисунок 3.8 – Схематичне зображення рухів: а – циліндричний хват; б – взяття 2 пальцями; в – гаковий хват; г – взяття 3 пальцями; д – взяття предмету; е – притискання великим пальцем.

Формування вхідного сигналу алфавіту шести рухів подається як послідовна процедура виконання 30 повторів руху в часовому проміжку 6 секунд на один рух. Отримані сигнали характеризуються частотою дискретизації в 500Hz. Розглянемо основні етапи реалізації алгоритму оптимізації агломеративної ієрархічної структури даних в процесі машинного навчання.

1) обнуління лічильника варіантів ієрархічних структур (кроків навчання): $r := 0$.

2) ініціалізація лічильника варіантів ієрархічних структур: $r := r + 1$.

3) обнуління лічильника ярусів структури даних: $h := 0$.

4) ініціалізація лічильника ярусів структури даних: $h := h + 1$.

5) обнуління лічильника страт яруса: $s := 0$.

6) ініціалізація лічильника страт яруса: $s := s + 1$.

7) для кожної s -ї страти h -го ярусу r -ї ієрархічної структури реалізується базовий алгоритм інформаційно-екстремального машинного навчання, який реалізує оператори правого контуру категорійної моделі (рис. 2.5) з метою оптимізації геометричних параметрів контейнерів класів розпізнавання за усередненим по всім фінальним стратам інформаційного критерію $\bar{E}_{r,h,s}^*$.

8) за сформованими параметрами контейнерів обчислюються міжцентрові відстані $D(X_1^0, X_2^0)$, формується матриця відстаней \hat{D} .

9) якщо $s \leq S_h$, то виконується пункт 6, інакше – пункт 10.

10) якщо $h \leq h_{max}$, де h_{max} – кількість ярусів r -ї структури даних, то виконується пункт 4, інакше – пункт 11.

11) Для найближчої пари класів $\min D(X_i^0, X_j^0)$ утворюється метакластер, який реалізує логіку нового контейнеру класу (рис. 3.9). Метаклас отримує реалізації обох класів, як свої, центром мета класу стає середнє значення центрів його внутрішніх класів.

12) обчислюється усереднене за фінальними стратами максимальне значення інформаційного критерію оптимізації $\bar{E}_{r,h}^*$.

13) якщо $r \leq r_{max}$, де r_{max} – кількість ієрархічних структур даних, то виконується пункт 2, інакше – пункт 12.

14) визначається за процедурою (1) оптимальна ієрархічна структура даних.




Рисунок 3.9 – Схематичне утворення метакластеру $AB = A \cup B$.

Описаний алгоритм машинного навчання реалізує логіку пошуку для різних ієрархічних структур глобального максимуму інформаційного критерію

$$\bar{E}_{\max} = \frac{1}{S_f} \sum_{s=1}^{S_f} E_{\max}^{(s)}. \quad (3.20)$$

На рисунку 3.20 показано агломеративну структуру розбиття класів розпізнавання для алфавіту, який складався з класу розпізнавання X_1^0 – «циліндричний хват», класу розпізнавання X_2^0 – «гаковий хват», класу розпізнавання X_3^0 – «взяття предмету двома пальцями», класу розпізнавання X_4^0 – «взяття предмету трьома пальцями», класу розпізнавання X_5^0 – «взяття предмету», класу розпізнавання X_6^0 – «притискання великим пальцем».




Рисунок 3.10– Схема розбиття класів розпізнавання у ієрархічній структурі

При розбитті простору ознак на підпростори, відповідно до ієрархічної структури класів, найближча за жадібним підходом пара класів утворювала метакластер $X_7^0 = X_3^0 \cup X_4^0$, який буде представляти надалі цю пару, і буде використаний як внутрішній клас більшого метакластера $X_9^0 = X_7^0 \cup X_6^0$. За логікою агломеративної ієрархічної кластеризації з алфавіту класів було утворено бінарні ієрархічні структури, за якими оптимізувалися геометричні параметри пар класів розпізнавання. При цьому навчальна матриця оптимального класу розпізнавання видалялася із вхідної навчальної матриці. Потім аналогічно оптимізувалися параметри пар класів розпізнавання, які залишилися в алфавіті.

Інформаційний критерій (3.18) обчислювався при обсязі навчальної вибірки $n = 3000$ і $p = 2$. При цих значеннях максимальне значення критерію дорівнює $E^* = 4,39$.

На рис. 3.11 показано графіки залежності інформаційного критерію оптимізації (3.18) від радіусів контейнерів класів розпізнавання.

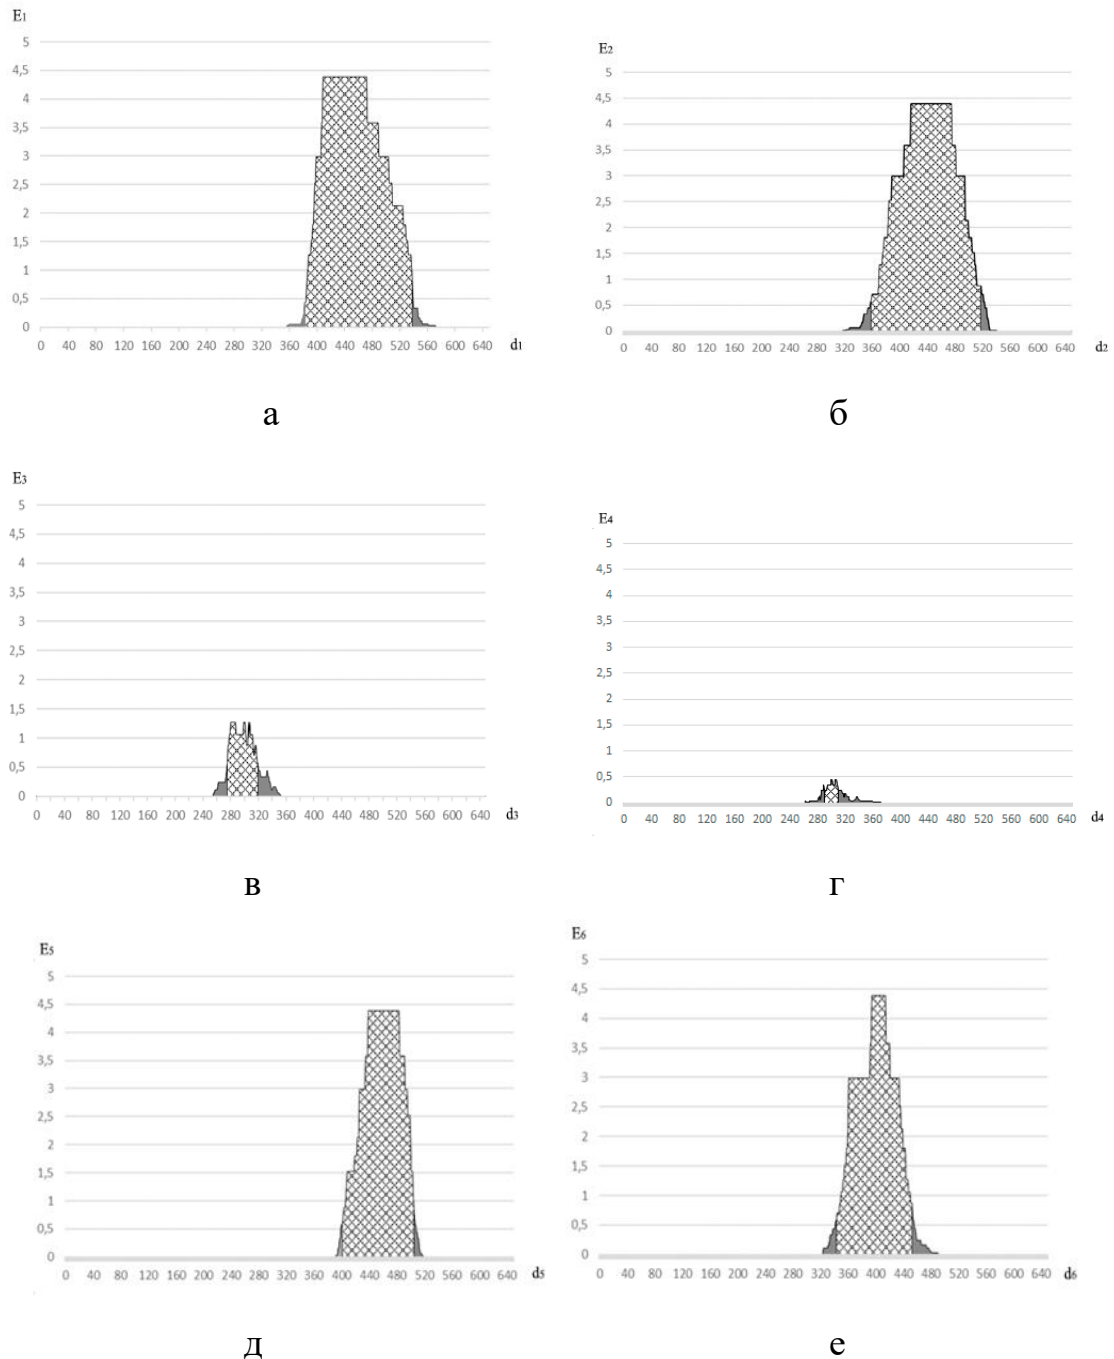


Рисунок 3.11 – Графіки залежності критерію від радіусів контейнерів класів розпізнавання: а – клас X_1^0 ; б – клас X_2^0 ; в – клас X_3^0 ; г – клас X_4^0 ; д – клас X_5^0 ; е – клас X_6^0 .

У таблиці 3.2 показано результати машинного навчання системи керування протезом кісті руки з оптимізацією радіусів контейнерів класів для заданого алфавіту з шести класів розпізнавання.

Таблиця 3.2 – Результати машинного навчання

Class ID	\bar{E}^*	\bar{D}_1	$\bar{\beta}$	\bar{P}_t
1	4.39	1.00	0.00	1.00
2	4.39	1.00	0.00	1.00
3	1.27	0.65	0.15	0.54
4	0.44	0.75	0.35	0.39
5	4.39	1.00	0.00	1.00
6	4.39	1.00	0.00	1.00
7	4.39	1.00	0.00	1.00
8	2.98	0.90	0.05	0.79
9	0.87	0.85	0.30	0.47
10	4.39	1.00	0.00	1.00

Аналіз таблиці 3.2 показує, що пари класів X_1^0 і X_2^0 , X_5^0 , метаклас X_{10}^0 , X_6^0 і метаклас X_7^0 сформували оптимальні класифікатори і їх інформаційна міра досягла максимального значення для цього набору ознак. Проте класи X_3^0 і X_4^0 продемонстрували доволі низькі значення критерію Кульбака, як і метакласи X_8^0 і X_9^0 (рис.3.12).

Графіки на рис. 3.11 та 3.12 демонструють розподіл інформаційної міри для пар кластерів ієрархічної структури. З графіків видно, що розподіл значень має ділянки типу “плато”, для них визначення оптимальних радіусів контейнерів класів розпізнавання здійснювалося за мінімальними значеннями коефіцієнтів нечіткої компактності [233]:

$$l_m = \frac{d(x^{(j)} \oplus x_m)}{d_m^*}; \quad l_c = \frac{d(x^{(j)} \oplus x_c)}{d_c^*}. \quad (3.21)$$

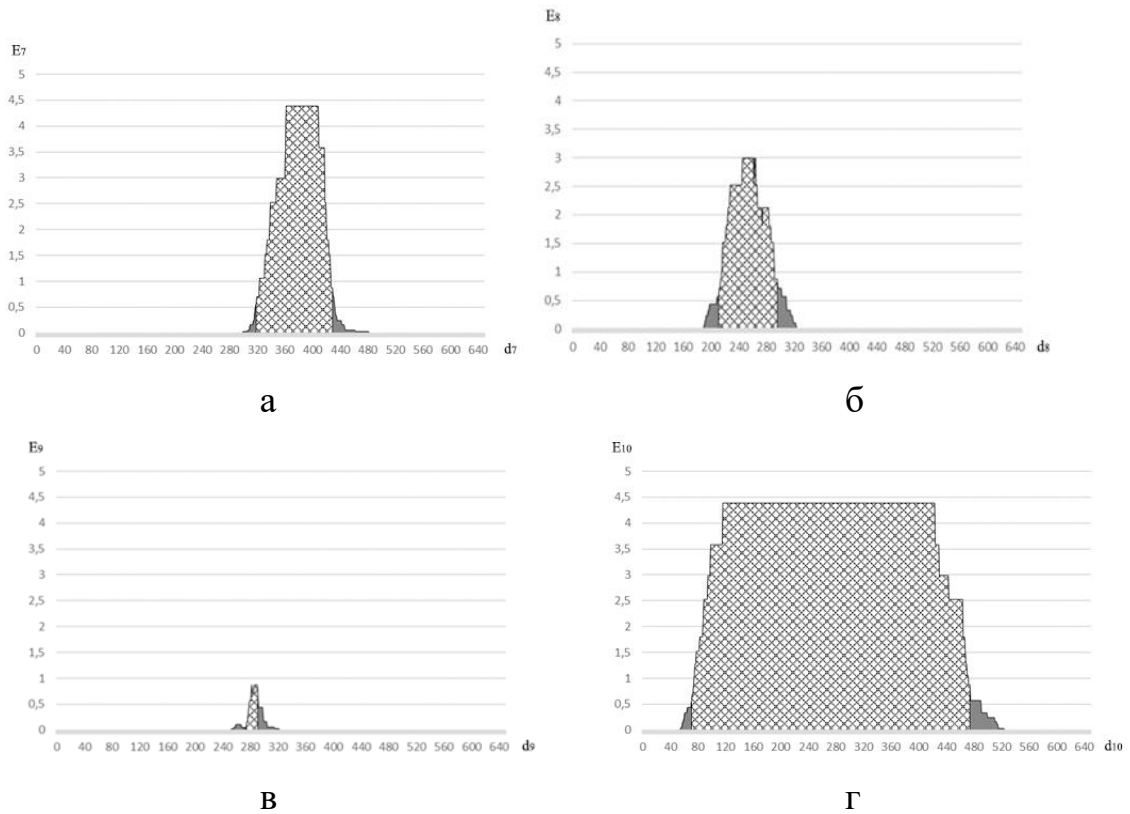


Рисунок 3.12 – Графіки залежності критерію від радіусів контейнерів метакласів розпізнавання: а – метаклас X_7^0 ; б – метаклас X_8^0 ; в – метаклас X_9^0 ; г – метаклас X_{10}^0 .

Визначені згідно з виразом (3.21) оптимальні радіуси контейнерів класів розпізнавання відповідно дорівнювали: для пар класів $X_1^0 - d_1^* = 409$ та $X_2^0 - d_2^* = 417$, класів $X_3^0 - d_3^* = 293$ та $X_4^0 - d_4^* = 307$, класу $X_6^0 - d_6^* = 394$ та для метакласу $X_7^0 - d_7^* = 408$, пар метакласів $X_8^0 - d_8^* = 261$ та $X_9^0 - d_9^* = 282$, класу $X_5^0 - d_5^* = 467$ та метакласу $X_{10}^0 - d_{10}^* = 421$.

За отриманими результатами навчання функціональну ефективність машинного навчання слід вважати високою, оскільки значення повної ймовірності правильного розпізнавання когнітивних команд близьке до одиниці. Отримана за результатами екзамену середня повна ймовірність правильного розпізнавання когнітивних команд для заданого алфавіту класів розпізнавання дорівнювала $\bar{P}_t = 0,82$. Такий показник є достатньо високим, оскільки він знаходиться на рівні показників протезів із інвазивною системою зчитування біосигналів. Проте слід завважити, що система продемонструвала не високу

ймовірність розпізнавання класів X_3^0 (взяття трьома пальцями) та X_4^0 (притискання великим пальцем), що можна пояснити значною схожістю рухів.

3.5 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з оптимізацією рівня квантування сигналу для формування розрідженої матриці

Функціональну категорійну модель інформаційно-екстремального машинного навчання системи керування інтелектуальним протезом представимо у вигляді орієнтованого графу відображення множин [236], які задіяні в процесі оптимізації параметрів машинного навчання. Водночас вхідний інформаційний опис задається структурою

$$I = \langle G, AR, T, \Omega, Z, Y^{|M|}, X^{|M|}; f_1, f_2 \rangle, \quad (3.22)$$

де $GF=G \times AR$ – множина факторів, які впливають на форму біосигналів;

T – множина моментів часу зчитування інформації;

Ω – простір ознак розпізнавання;

Z – алфавіт класів розпізнавання;

$Y^{|M|}$ – вхідна навчальна матриця;

$X^{|M|}$ – робоча бінарна навчальна матриця, задана у просторі ознак

Хеммінга;

f_1 – оператор формування навчальної матриці $Y^{|M|}$;

f_2 – оператор формування бінарної навчальної матриці $X^{|S|}$.

Функціональну категорійну модель інформаційно-екстремального машинного навчання з оптимізацією рівня квантування сигналу для формування розрідженої матриці показано на рисунку 3.13.




Рисунок 3.13 – Функціональна категорійна модель машинного навчання

На рисунку 3.13 декартовий добуток $GF \times T \times \Omega \times Z$ розглядається як джерело інформації. Терм-множина E описує значення інформаційного критерію оптимізації параметрів машинного навчання системи і є загальною для всіх контурів процедур оптимізації. Оператор r ітеративно в процесі машинного навчання відновлює в просторі ознак контейнери класів розпізнавання, які формують нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$. Оператор ξ відображає розподіл векторів ознак бінарної навчальної матриці $X^{|S|}$ на розбиття $\tilde{\mathfrak{R}}^{|M|}$, а оператор ψ перевіряє основну статистичну гіпотезу належності цих векторів ознак відповідному класу розпізнавання і формує множину гіпотез $I^{|G|}$, де G – кількість статистичних гіпотез. Оператор γ шляхом оцінки статистичних гіпотез формує множину точнісних характеристик $\mathfrak{Z}^{|Q|}$, де $Q = G^2$ – кількість точнісних характеристик. Оператор $\phi: \mathfrak{Z}^{|Q|} \rightarrow E$ обчислює на кожному кроці машинного навчання множину значень інформаційного критерію E , який є функціоналом точнісних характеристик. Категорійна модель містить контур оптимізації симетричних контрольних допусків на ознаки розпізнавання, який замикається через терм-множину D допустимих значень контрольних допусків. Водночас оператор δ_1 на кожному кроці машинного навчання змінює контрольне поле, а оператор δ_2 оцінює залежність ознак розпізнавання заданому контрольному полю допусків. Крім того, категорійна модель містить контур оптимізації рівнів квантування електроміографічних біосигналів, який включає терм-множину V допустимих значень рівнів квантування. У цьому контурі оператор q_1 на кожному кроці

машинного навчання змінює рівень квантування, а оператор q_2 змінює словник ознак розпізнавання. Оператор u регламентує процес машинного навчання.

Отже, за категорійною моделлю (рис. 3.12) алгоритм інформаційно-екстремального машинного навчання системи керування протезом зводиться до ітераційної процедури пошуку глобального максимуму інформаційного критерію оптимізації (3.18) в робочій області визначення його функції:

$$q^* = \arg \max_{G_q} \{ \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}_{max}^{(k)} \} \}, \quad (3.23)$$

де $\bar{E}_{max}^{(k)}$ – усереднене значення інформаційного критерію, обчислене за формулою (3.18) на k -му кроці машинного навчання;

G_q – область допустимих значень рівнів квантування біосигналів;

G_δ – область допустимих значень контрольних допусків на ознаки розпізнавання.

За отриманими в процесі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання було побудовано вирішальні правила, які мають типовий в методах ІЕІ-технології вигляд:

$$(\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}) \left(\begin{array}{l} \text{if} [(\mu_m > 0) \& (\mu_m = \max\{\mu_m\})] \text{ then } x^{(j)} \in X_m^o \\ \text{else } x^{(j)} \notin X_m^o \end{array} \right), \quad (3.24)$$

де $x^{(j)}$ – вектор, що розпізнається;

μ_m – функція належності вектора $x^{(j)}$ контейнеру класу розпізнавання X_m^o .

Для гіперсферичного класифікатора функція належності має вигляд

$$\mu_m = 1 - \frac{d(x^{(j)} \oplus x_m^*)}{d_m^*}, \quad (3.25)$$

де $d(x^{(j)} \oplus x_m^*)$ – кодова відстань Хеммінга між реалізацією $x^{(j)}$ і

оптимальною усередненою реалізацією x_m^* класу розпізнавання X_m^o ;

d_m^* – отриманий в процесі машинного навчання оптимальний радіус контейнера класу розпізнавання X_m^0 .

Реалізація розглянутого алгоритму машинного навчання здійснювалася за вхідною навчальною матрицею 3 класів розпізнавання: X_1^0 – «взяття предмету», X_2^0 – «гакоподібний хват предмету», X_3^0 – «рух 3 пальців».

За алгоритмом машинного навчання з оптимізацією ієрархічної структури [225] було визначено оптимальне розбиття простору ознак (рис.3.14).




Рисунок 3.14 – Декурсивна ієрархічна структура даних

Рисунок 3.15 Ілюструє залежність усередненої за всіма класами інформаційної міри від параметру системи допусків δ , де штрихована область вказує на робочу область системи, в якій для класів розпізнавання можна сформувати контейнери.




Рисунок 3.15 – Графік залежності критерію від параметру поля контрольних допусків

При максимальному значенні усередненої інформаційної міри $\bar{E} = 22,3$ в робочій області $\delta = 13$, проведено оптимізацію радіусів контейнерів класів(рис.3.16).

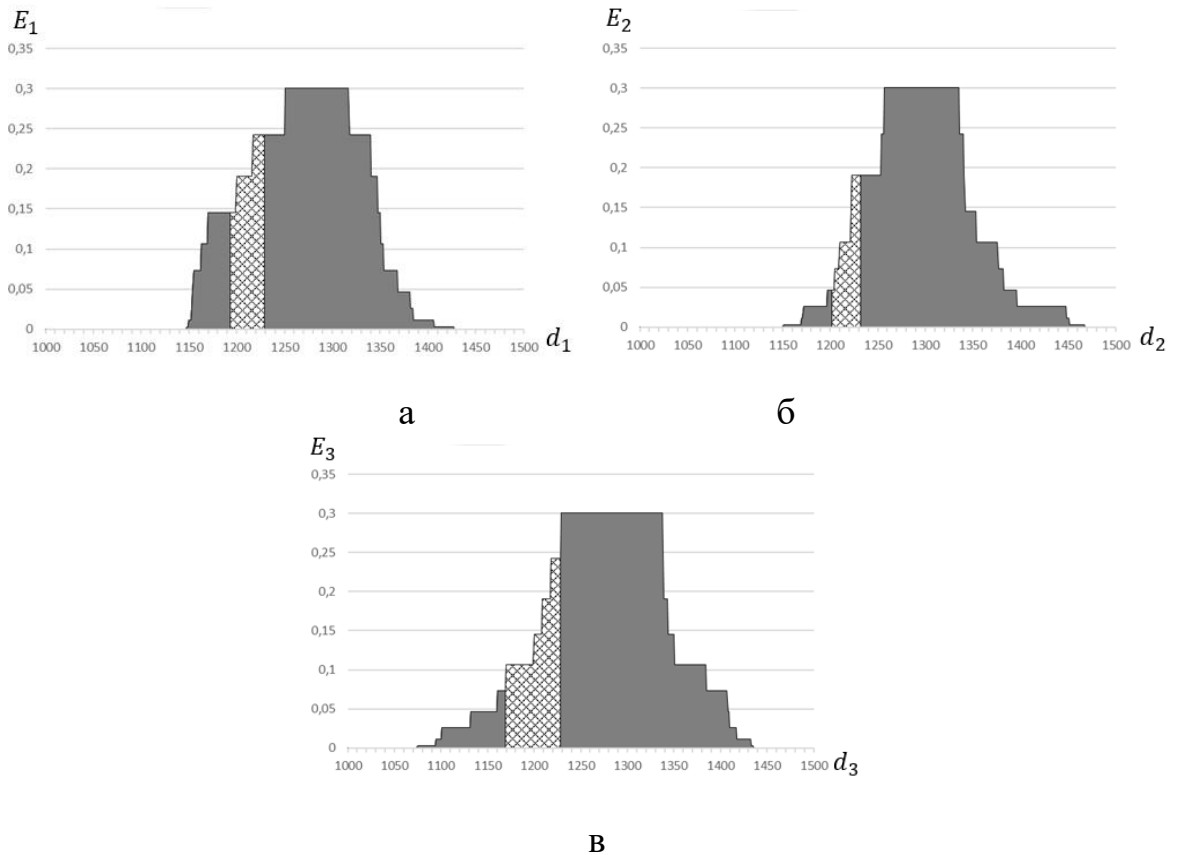


Рисунок 3.16 – Графіки залежності критерію від радіусів контейнерів класів: а – клас розпізнавання X_1^0 , б – клас розпізнавання X_2^0 , в – клас розпізнавання X_3^0 .

Оптимальні радіуси контейнерів класів розпізнавання дорівнюють: $d_1 = 1223$ для класу X_1^0 , $d_2 = 1221$ для класу X_2^0 , $d_3 = 1218$ для класу X_3^0 .

В процесі оптимізації рівнів квантування, визначено оптимальне значення параметру $q^* = 90 mV$, за яким сформовано розріджену бінарну навчальну матрицю.

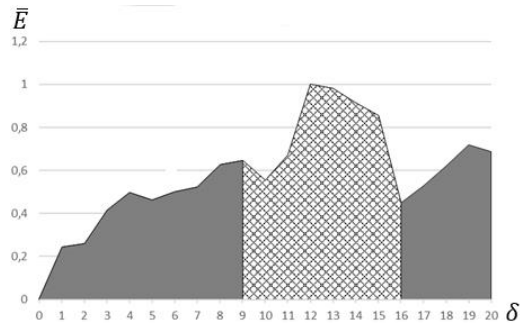


Рисунок 3.17 – Графік залежності критерію від параметру контрольних допусків при розріджених навчальних матрицях

Машинне навчання системи за розрідженими навчальними матрицями дозволило отримати максимальне значення усередненої інформаційної міри $\bar{E} = 1$ при оптимальному параметрі $\delta = 12$ (рис. 3.17). Водночас нові оптимальні радіуси контейнерів класів розпізнавання дорівнюють: $d_1 = 1243$ для класу X_1^0 , $d_2 = 1190$ для класу X_2^0 , $d_3 = 1221$ для класу розпізнавання X_3^0 .

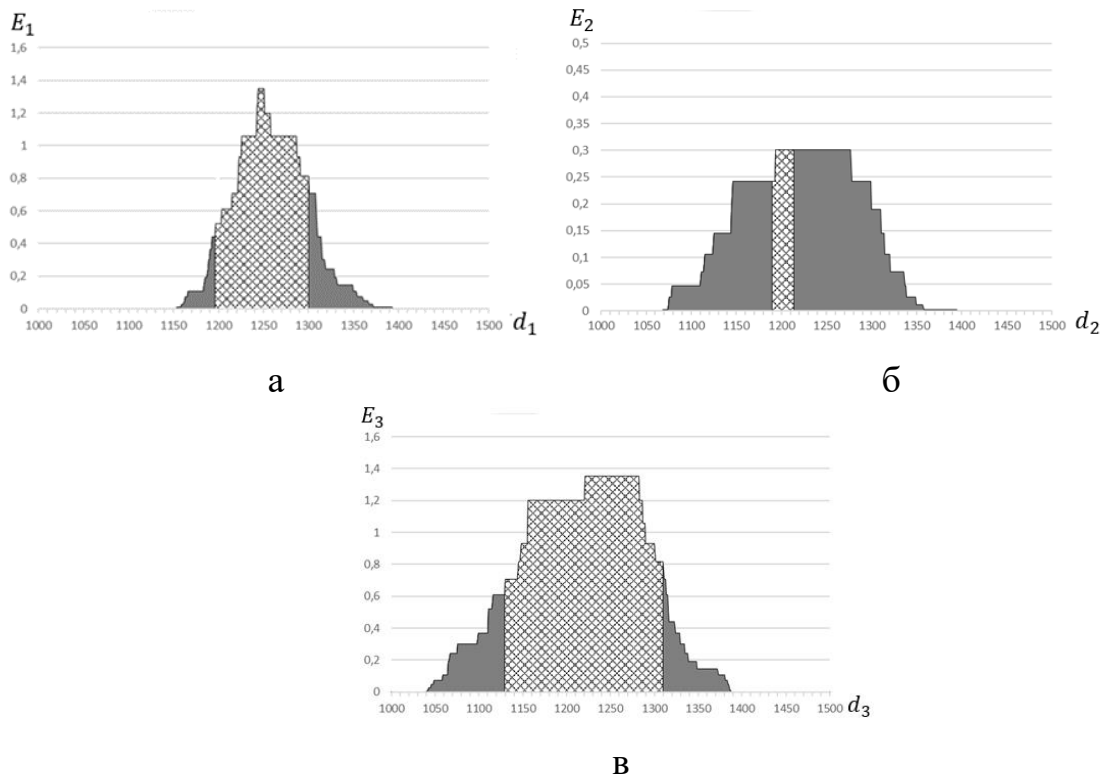


Рисунок 3.18 – Графіки залежності критерію від радіусів контейнерів класів при розрідженій навчальній матриці: а – клас X_1^0 , б – клас X_2^0 , в – клас X_3^0 .

Використання розріджених навчальних матриць дозволило підвищити значення інформаційної міри для класів X_1^0 та X_3^0 . Значення критерію Кульбака для класу X_2^0 не змінилось, що зумовлено перетином просторів ознак з іншими класами, адже саме цей клас було обрано в процесі машинного навчання як «клас-сусід» для оптимізації геометричних параметрів решти класів.

3.6 Інформаційно екстремальне машинне навчання модулю розпізнавання системи керування протезом з оптимізацією часу квантування сигналу

Розглянемо введення додаткового інформаційного обмеження системи керування протезом кінцівки руки в процесі машинного навчання з метою підвищення інформаційної міри. Оскільки функціонування системи керування протезом є чутливим до умов формування вхідного сигналу електроміографічного датчика варто розглянути оптимізацію параметрів початкового оброблення сигналу з метою підвищення властивості адаптивності системи. Процес реєстрації біосигналів зі шкіри є дискретним, звідси впливає необхідність розглянути процес оптимізації кроку квантування в часі електроміографічного сигналу неінвазивним датчиком. Виконання оптимізації дискретизації сигналу додає до категорійної моделі новий контур оптимізації параметра τ – крок квантування у часі вхідної реалізації. Тобто у процесі інформаційно-екстремального машинного навчання необхідно визначити оптимальні значення параметру τ^* :

$$\tau^* = \arg \max_{g \in G} E_m, \quad (3.26)$$

де E_m – критерій функціональної ефективності машинного навчання системи розпізнавати реалізації біосигналів,
 G – область допустимих значень параметрів функціонування.

На рисунку 3.19 контур оптимізації кроку квантування у часі замикається оператором $\tau_1: E \rightarrow \mathfrak{X}$, де \mathfrak{X} – множина значень кроку квантування, і оператором $\tau_2: \mathfrak{X} \rightarrow T$, який змінює інтервали часу зняття інформації.




Рисунок 3.19 – Функціональна категорійна модель машинного навчання

Процедура оптимізації кроку квантування подається алгоритмом машинного навчання системи:

1. Визначаються правила зміни кроку квантування $\tau := \tau + \Delta\tau$, де $\tau(0) := \tau_0$, який попередньо набуває початкового значення τ_0 .
2. Формуються навчальні матриці класів розпізнавання за поточним значенням кроку дискретизації τ .
3. Реалізується базовий алгоритм машинного навчання системи за поточним значенням кроку дискретизації τ .
4. Здійснюється пошук глобального значенні інформаційної міри системи E^* в робочій області визначення його функції. Якщо $E^*(\tau) \geq E^*(\tau + \Delta\tau)$, де $\tau \leq \tau_{max}$, виконується крок 1, інакше – крок 5.
5. Визначається оптимальне значення параметру τ^* квантування за часом вхідного електроміографічного сигналу.

Наведений алгоритм було застосовано до алфавіту класів 3 класів розпізнавання: X_1^0 – «взяття предмету», X_2^0 – «гакоподібний хват предмету», X_3^0 – «рух 3 пальців».

Для навчальних матриць класів електроміографічних сигналів сформованих з 30 повторів біосигналів з 3000 ознак розглянуто оптимізацію обсягу реєстрації біосигналів за 1 мс.

Рисунок 3.20 демонструє залежність усередненого значення інформаційної міри машинного навчання від кількості сигналів, зареєстрованих електроміографічним датчиком в діапазоні від 50 ознак на мілісекунду до 250 ознак на мілісекунду.




Рисунок 3.20 – Графік залежності інформаційної міри від параметру контрольних допусків при квантуванні за часом

Максимальне значення критерію функціональної ефективності, отримане в процесі оптимізації кроку квантування за часом досягло $\bar{E} = 2,764$, при зменшенні кількості ознак розпізнавання, зареєстрованих в момент часу до 200, що вище за попереднє значення $\bar{E} = 1,963$ для 500 ознак в мілісекунду.

Зміна кроку квантування за часом дозволила отримати наступні максимальні значення нормованого КФЕ: $E_1^* = 4,39$, $E_2^* = 1,52$ і $E_3^* = 1,19$, що ілюструє підвищення ефективності навчання системи для класів: X_1^0 – «взяття предмету», X_2^0 – «гакоподібний хват предмету».

Можливість використання визначених за наведеним вище алгоритмом навчальних вибірок мінімального обсягу в методах ІЕІ-технології обумовлена сгладжувальним ефектом логарифмічних статистичних інформаційних критеріїв оптимізації параметрів машинного навчання.

3.7 Висновки до третього розділу

У третьому розділі розроблено та програмно реалізовано алгоритми інформаційно-екстремального машинного навчання системи керування

протезом кінцівки руки та досліджено вплив параметрів оптимізації на функціональну ефективність машинного навчання. Одержано такі наукові результати :

1. За реальними даними електроміографічних біосигналів розроблено і програмно реалізовано алгоритми інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки. У процесі машинного навчання здійснюється паралельна оптимізація контрольних допусків на ознаки розпізнавання. Такий підхід дозволяє підвищити як достовірність прийняття рішень, так і оперативність алгоритму машинного навчання з оптимізацією контейнерів класів розпізнавання, оскільки пошук глобального максимуму інформаційного критерію не виходить за межі робочої області визначення його функції.

2. Запропоновано і реалізовано метод інформаційно-екстремального машинного навчання системи керування за ієрархічною структурою даних, що дозволяє підвищити функціональну ефективність машинного навчання при розширенні алфавіту класів розпізнавання. Розглянуто алгоритми кластеризації простору ознак в рамках ієрархічного підходу машинного навчання системи, що опрацьовують дані в деревоподібній структурі класів як згори-вниз, так і знизу-вгору. За аналізом результатів представлених ієрархічних методів машинного навчання запропоновано для машинного навчання використовувати так звану декурсивну ієрархічну структуру даних, в якій кожний клас розпізнавання вищого ярусу повертається в свою страту нижчого ярусу. Така структура забезпечує підвищення функціональної ефективності машинного навчання системи керування протезом шляхом розбиття всіх класів розпізнавання заданого алфавіту біосигналів на страти малої потужності, що зменшує ступінь їх перетину в просторі ознак розпізнавання. Запропоновано модифікацію інформаційного критерію Кульбака для оцінки функціональної ефективності ієрархічного машинного навчання системи керування протезом. Експериментально доведено, що при збільшенні алфавіту класів розпізнавання ієрархічний алгоритм машинного навчання забезпечує більше значення інформаційного критерію функціональної ефективності.

3. Розроблено і програмно реалізовано методи інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з оптимізацією агломеративної ієрархічної структури класів розпізнавання та декурсивної ієрархічної структури даних. Експериментально доведено, що функціональна ефективність інформаційно-екстремального машинного навчання залежить від розбиття простору ознак при розташуванні класів з відомого алфавіту біосигналів у вершинах декурсивного дерева.

4. Удосконалено і програмно реалізовано методи інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з оптимізацією рівня квантування сигналу для формування розрідженої матриці.

5. Удосконалено і програмно реалізовано методи інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з оптимізацією часу квантування сигналу під час формування вхідного математичного опису системи.

Основні наукові результати, наведені у третьому розділі, опубліковано у працях автора [217], [225], [236].

РОЗДІЛ 4. ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЕРУВАННЯ ІНТЕЛЕКТУАЛЬНИМ ПРОТЕЗОМ РУКИ

4.1 Структура та основні функції інтелектуальної системи керування протезом кінцівки руки

На основі отриманих в дисертаційній роботі наукових результатів розроблено структуру, інформаційне та програмне забезпечення системи керування протезом кінцівки руки, вирішальні правила якої формуються в процесі інформаційно-екстремального машинного навчання. Структурна схема системи керування протезом кінцівки руки в режимі екзамену показана на рис.4.1.

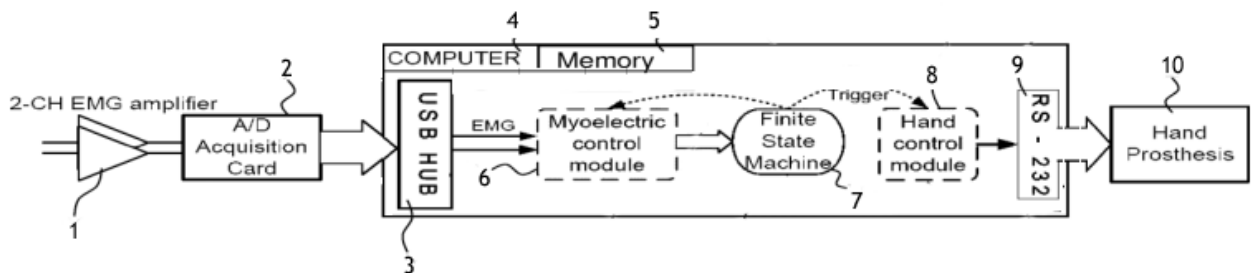


Рисунок 4.1 – Структурна схема інтелектуального протезу кінцівки руки

На схемі вказано наступні складові: 1 – підсилювач сигналу; 2 – карта отримання; 3 – USB хаб; 4 – Комп’ютер; 5 – Пам’ять; 6 – електроміографічний модуль керування; 7 – автомат кінцевих станів, 8 – модуль керування протезом; 9 – інтерфейс обміну даними; 10 – протез кінцівки руки.

Наведена схема наводить необхідні складові для реалізації функціонування в режимі екзамену, тобто використання протезу користувачем з розпізнаванням біосигналів та виконанням рухів протезом. Вирішальні правила, сформовані для користувача на етапі машинного навчання, зберігаються в пам’яті системи та використовуються для обчислення функції належності біосигналу, отриманого з електроміографічних датчиків на шкірі користувача.

Функціонування системи в режимі машинного навчання передбачає використання протезу у синхронізації з комп'ютерною програмою для персонального комп'ютера. Система керування процесом навчання представлена на Рисунку 4.2.

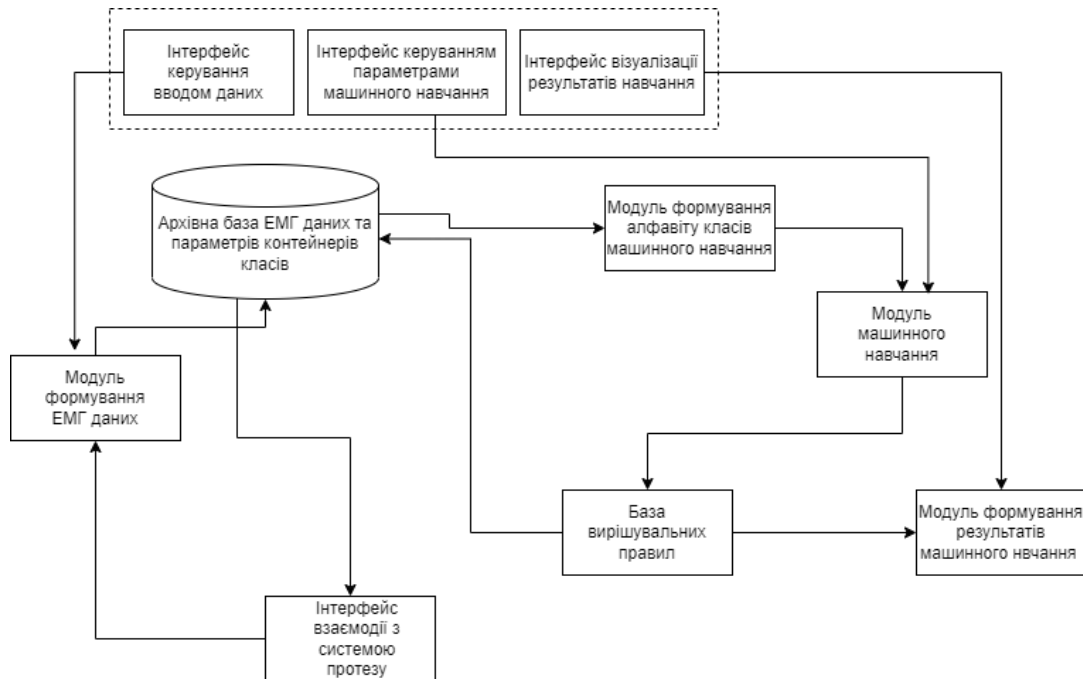


Рисунок 4.2 – Структурна схема системи машинного навчання

Як показано на рис. 4.2 візуальний інтерфейс розробленої системи складається з вікон керування процесом вводу даних в систему, налаштуванням процесу машинного навчання та візуалізації результатів отриманих в процесі оптимізації внутрішніх параметрів системи. Використовуючи наведені інтерфейси взаємодії з системою користувач реалізує взаємодію протезу та програмного забезпечення машинного навчання.

Інтерфейс взаємодії комп'ютерної програми з системою протезу передбачає забезпечення процесу отримання ЕМГ сигналів для формування навчальних матриць, з залученням модулю формування та підготовки ЕМГ даних для навчання системи, та синхронізації параметрів функціонування системи в режимі екзамену з актуальними, сформованими системою та збереженими для подальшого використання у архівній базі ЕМГ сигналів та параметрів контейнерів класів.

Задачі машинного навчання системи розділені між модулями формування алфавіту класів машинного навчання, модулю машинного навчання, який вміщує в собі реалізації алгоритмів навчання системи з оптимізацією внутрішніх параметрів навчання системи, та модулю формування результатів машинного навчання, який дозволяє ознайомитись з звітами оптимізацій параметрів системи та реалізує тестування роботи системи у режимі екзамену.

4.2 Засоби інформаційної технології створення системи керування протезом кінцівки руки

Система реалізована мовою програмування Java з використанням об'єктно-орієнтованого підходу до формування архітектури проєкту та реалізацією патернів програмування для покращення користувацького досвіду взаємодії з системою.

Використання шаблону Model-View-Controller (MVC) [248], дозволило створити гнучкий програмний продукт, який можна зручно масштабувати. Принцип інкапсуляції даних, застосований в архітектурі системи, дозволяє реалізувати модульність програми та спростити рефакторинг та підтримку частин проєкту.

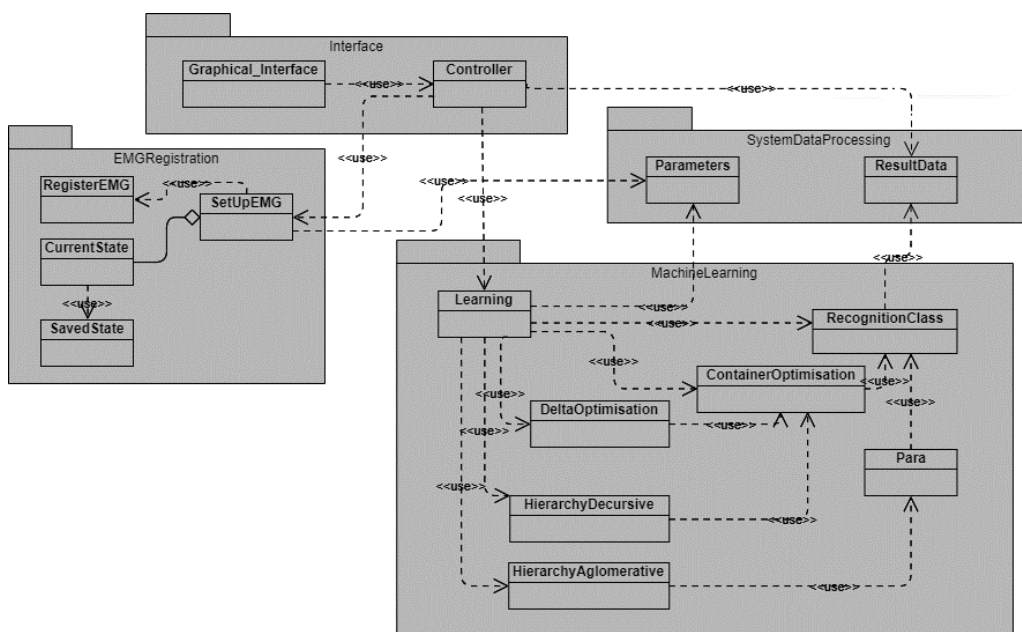


Рисунок 4.3 – Діаграма класів системи

Рисунок 4.3 наводить UML-діаграму класів, задіяних у взаємодії користувача системи з базою даних та знань, яка містить параметри вирішальних правил інформаційно-екстремального класифікатора. EMGRegistration модуль реалізує патерн Memento [249] для забезпечення збереження попереднього стану з відповідними класами та внутрішніми параметрами системи. Результати машинного навчання та збережені стани системи зберігаються в json-файлі, з використанням бібліотеки org.json. Клас Learning в системі використовує логіку Facade для реалізації роботи різних алгоритмів машинного навчання на вибір користувача.

На рис. 4.4. показано графічний інтерфейс програми машинного навчання системи.

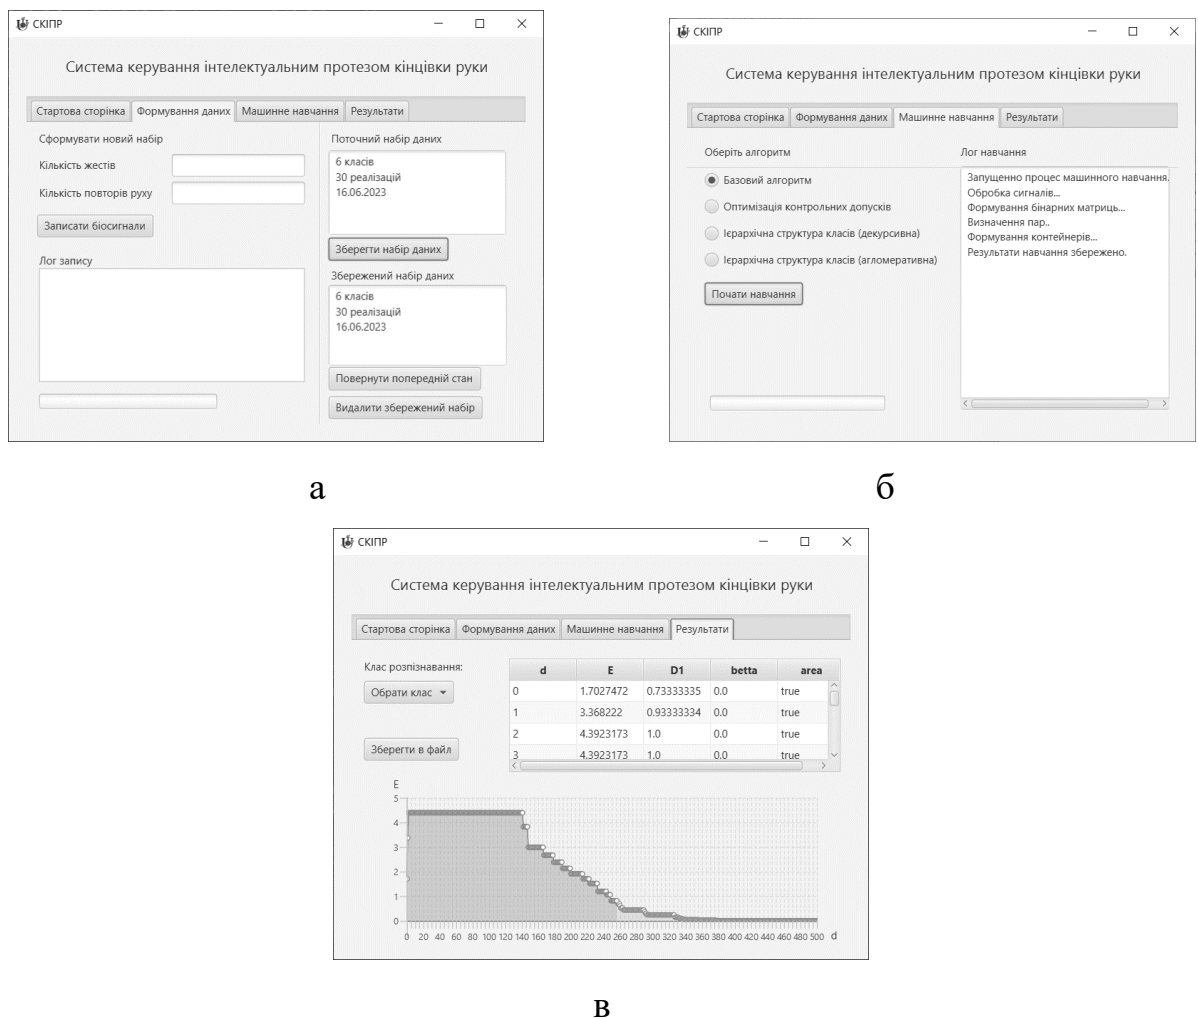


Рисунок 4.4 – Інтерфейс комп'ютерної програми: а – інтерфейс керування вводом даних; б – інтерфейс машинного навчання системи; в – сторінка представлення результатів машинного навчання.

Графічний інтерфейс реалізований з використанням java бібліотеки JavaFX, яка дозволяє реалізувати зручний інтерфейс керування системою для користувача та відобразити звіти машинного навчання у вигляді таблиць та графіків. На рис. 4.4а показані кнопки «Записати біосигнали», ініціалізація якої дозволяє отримати в буфер програми дані від протезу руки, «Зберегти набір даних», ініціалізація якої дозволяє створити локальну копію даних для подальшого використання в системі, «Повернути попередній стан», яка реалізує відновлення даних системи з попередньої локально збереженої версії, «Видалити збережений набір» для видалення існуючого збереженого набору.

Відповідно рис.4.4б демонструє вікно, в якому користувач може обрати алгоритм машинного навчання, який буде застосовано до збережених в буфері програми даних та ініціалізувати запуск процесу оптимізації параметрів системи кнопкою «Почати навчання». Отримані результати автоматично відображаються для кожного з класів машинного навчання у відповідній вкладці програми(рис.4.4в), з можливістю зберегти дані у файл для подальшого їх аналізу.

Графічний інтерфейс системи в режимі підтримки прийняття рішень (екзамену) показано на рис. 4.5.

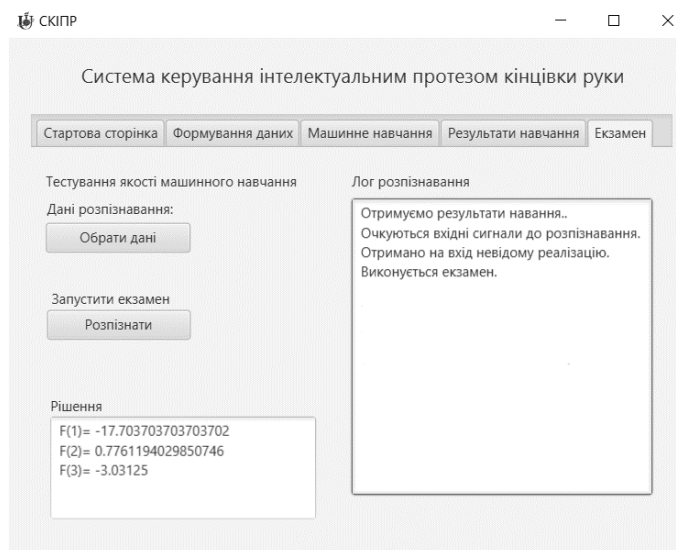


Рисунок 4.5 – Інтерфейс функціонування комп'ютерної програми в режимі екзамену

Після завершення машинного навчання системи параметри гіперсферичних контейнерів класів зберігаються в системі та використовуються програмою на етапі екзамену, тобто власне розпізнаванні невідомих реалізацій, отриманих на вхід системи. Кнопка «Обрати дані» дозволяє виконати тестування навчання системи до синхронізації отриманих правил з збереженими в протезі, обрати до передобробки до розпізнавання вхідний біосигнал, поданий в систему.

Кнопка «Розпізнати» запускає виконання процесу екзамену, в якому для отриманої невідомої реалізації визначаються функції належності до класів розпізнавання з обраного на етапі машинного навчання алфавіту.

4.3 Структура та основні функції інтелектуальної системи керування протезом в режимі екзамену

Для визначення практичної функціональної ефективності розробленого інформаційного та програмного забезпечення системи керування протезом кінцівки руки на базі одержаних в дисертаційній роботі наукових результатів розглянемо результати фізичного моделювання, тобто з електроміографічними біосигналами, зареєстрованими з шкіри кінцівки людини, отримані з бази UCI Machine learning repository [247].

У таблиці 4.1 наведено результати розпізнавання біосигналів тестової вибірки за вирішальними правилами, сформованими за інформаційно-екстремальним алгоритмом машинного навчання з алгоритмами оптимізації ієрархічної структури класів розпізнавання та оптимізації параметрів системи контрольних допусків на значення ознак [225, 236]. Для одержання репрезентативної статистики в процесі машинного навчання використано три класи розпізнавання з поділом обсягу даних на 630 реалізацій для навчальної матриці, 90 для валідаційної та 90 для тестової. При цьому клас X_1^0 є базовим і визначається рухом «взяття предмету». Клас X_2^0 описує рух «гакоподібний хват предмету», а X_3^0 – «рух 3 пальців», які є класами розпізнавання з значним

перетином реалізацій в просторі ознак. Приклади реалізацій даних класів приведено на рис. 3.10.

Таблиця 4.1 – Результати алгоритму екзамену

Класи розпізнавання	Достовірність розпізнавання			
	%	D_1	D_2	P_f
Клас X_1^0	0,961	0,97	0,952	0,039
Клас X_2^0	0,852	0,879	0,825	0,148
Клас X_3^0	0,809	0,824	0,794	0,191

Наведені в таблиці 4.1 результати розпізнавання електроміографічних біосигналів сягають 87,4%, і є наближеними до максимальної асимптотичної достовірності, визначеної на етапі навчання системи керування протезом кінцівки руки, і характеризуються достовірністю, яка перевершує результати, отримані при моделюванні нейроподібної системи.

Розглянуто процес машинного навчання штучної нейронної мережі з рекурентним шаром для розпізнавання біосигналів наведеної вище тестової вибірки.

Для роботи з електроміографічним сигналом штучна нейронна мережа субдискретизує та фільтрує дані електроміографічного сигналу через низькі частоти як вхідні дані моделі. В публікаціях [250, 251] зазначено, що точність класифікації згорковою нейронною мережею була вищою, ніж середні результати класичних методів, але нижчою, ніж найкращі результати архітектур ШНМ довгою короткочасною пам'яттю. Так метод машинного навчання розвинуто у роботах [252, 253] для подальшого застосування глибоких нейронних мереж з рекурентним шаром для міоелектричного контролю.




Рисунок 4.6 – Схема штучної нейронної мережі з рекурентним шаром

Модель рекурентного шару (рис.4.6) реалізує для нейронів орієнтований в часі граф, що дозволяє адаптувати для методу динамічну поведінку в часі та використати системну пам'ять для обробки довільних послідовностей введів. Архітектура рекурентної мережі використовує вихід прихованого нейрону, як вхід для наступного кроку.

За результатами машинного навчання ШНМ отримано наступні матриці невідповідностей (рис.4.7).

Output Class	1	40 29.6%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	13 9.6%	6 4.4%	68.4% 31.6%
	3	0 0.0%	37 27.4%	39 28.9%	51.3% 48.7%
		100% 0.0%	26.0% 74.0%	86.7% 13.3%	68.1% 31.9%
		Target Class			

Рисунок 4.7 – Матриці невідповідностей результатів машинного навчання

Аналіз результатів машинного навчання показує, що для класу X_1^0 «взяття предмету» сформовані безпомилкові за навчальною матрицею вирішальні правила, проте для класів X_2^0 «гакоподібний хват предмету» та X_3^0 «рух 3 пальців», які мають значний перетин в просторі ознак, результати розпізнавання дорівнюють 68,4% та 51,3% відповідно. Водночас загальна точність розпізнаванн, отримана в результаті роботи штучної нейронної

мережі, дорівнює 85,8%, що є нижчим за результат, отриманий в рамках ІЕІ-технології (87,4%). Також необхідно враховувати час машинного навчання, який для обраної ШНМ тривав 75 хвилин, що у п'ять разів більше у порівнянні з інформаційно-екстремальним машинним навчанням для однакового алфавіту класів розпізнавання. Порівняння отриманих результатів з багатозгортковими ШНМ не проводилися, оскільки вони для досягнення однакової точності машинного навчання потребують значно більшу вибірку навчальних зразків як це наголошується, наприклад, у праці [254].

4.4 Висновки до четвертого розділу

У четвертому розділі розроблено апаратно-програмний інструментарій проектування здатної навчатися системи керування протезом кінцівки руки. У результаті проведених досліджень одержано такі результати:

1. Розроблено концептуальну, структурну та функціональну схеми системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

2. Результати фізичного моделювання за реальними даними електроміографічних біосигналів підтверджують, що розроблене інформаційне та програмне забезпечення дозволяє за результатами реалізації запропонованих методів інформаційно-екстремального машинного навчання системи побудувати вирішальні правила, які на етапі екзамену або безпосередньо в режимі розпізнавання, забезпечують повну ймовірність правильного прийняття класифікаційних рішень наближену до максимального граничного значення.

3. Створений програмний інструментарій з використанням шаблонів проектування та мови програмування Java забезпечує для системи керування протезом кінцівки руки кросплатформенність, зменшення витрат на розробку, супроводження та функціональне масштабування.

4. Розроблена в дисертаційній роботі інформаційна технологія та її засоби дозволяють здійснити в рамках ІЕІ-технології інформаційний синтез системи керування протезом кінцівки руки, наділеної властивостями самонавчання,

адаптації до довільних початкових умов формування вхідного сигналу, інваріантності до багатовимірності словника ознак розпізнавання та перенавчання за умови збільшення потужності алфавіту класів розпізнавання.

Основні наукові результати, наведені у четвертому розділі, опубліковано у працях автора [225], [236] .

ВИСНОВКИ

У дисертаційній роботі розв'язано важливу науково-практичну задачу розробки моделей та методів функціонування системи керування протезом кінцівки руки з неінвазивним зчитуванням біосигналів. У ході виконання дисертаційної роботи отримано наступні результати:

1. Проаналізовано сучасний стан розвитку систем керування протезами кінцівок, їх керуючих сигналів, та методів машинного навчання, і встановлено, що основною тенденцією їх подальшого розвитку є створення та застосування інтелектуальних інформаційних технологій на основі машинного навчання та теорії розпізнавання образів. За результатами аналітичного огляду та аналізу праць попередників обґрунтовано вибір методу досліджень в рамках інформаційно-екстремальної інтелектуальної технології аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи керування протезом кінцівки руки.

2. Вперше розроблено категорійні моделі і на їх основі методи інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки за ієрархічною структурою даних.

3. Вперше розроблено метод оцінювання функціональної ефективності інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з ієрархічною структурою даних на основі запропонованої модифікації інформаційного критерію оптимізації параметрів машинного навчання, що дозволяє підвищити достовірність вирішальних правил.

4. Вперше розроблено модель та метод інформаційно-екстремального машинного навчання з оптимізацією рівня квантування сигналу для формування розрідженої матриці.

5. Удосконалено модель та метод інформаційно-екстремального машинного навчання з оптимізацією часу квантування сигналу під час формування вхідного математичного опису системи.

6. Отримав подальший розвиток метод агломеративного кластер-аналізу, що дозволяє автоматично формувати ієрархічну структуру найближчих сусідніх

класів розпізнавання для машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

7. Розроблено і програмно реалізовано засоби технології інформаційного синтезу здатної навчатися системи керування протезом кінцівки руки, що дозволило за результатами ієрархічного машинного навчання побудувати безпомилкові за навчальною матрицею вирішальні правила, які дозволяють в робочому режимі приймати високоточні діагностичні рішення в режимі реального часу.

8. Основні наукові результати впроваджено у вигляді інформаційної технології, яка включає категорійні моделі, методи, критерії оцінки функціональної ефективності, алгоритми оптимізації і програмне забезпечення у план дослідно-конструкторських робіт ТОВ «НВП «Метекол»(м.Ніжин) створення інтелектуального протезу кисті руки і в навчальний процес Сумського державного університету.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. C. Garcia et al., "SCOMA hand prosthetic", *Proceedings of 2021 International Conference on Mechatronics, Electronics and Automotive Engineering, ICMEAE 2021*, pp. 232–238, 2021, doi: 10.1109/ICMEAE55138.2021.00044.
2. M. S. Johannes et al., "The Modular Prosthetic Limb", *Wearable Robotics: Systems and Applications*, pp. 393–444, Jan. 2020, doi: 10.1016/B978-0-12-814659-0.00021-7.
3. S. Raspopovic, G. Valle, and F. M. Petrini, "Sensory feedback for limb prostheses in amputees", *Nature Materials*, vol. 20, no. 7, pp. 925–939, Apr. 2021, doi: 10.1038/s41563-021-00966-9.
4. P. Svensson, U. Wijk, A. Björkman, and C. Antfolk, "A review of invasive and non-invasive sensory feedback in upper limb prostheses", *Expert Review of Medical Devices*, vol. 14, no. 6, pp. 439–447, Jun. 2017, doi: 10.1080/17434440.2017.1332989.
5. A. Mohammadi et al., "A practical 3D-printed soft robotic prosthetic hand with multi-articulating capabilities", *PLoS One*, vol. 15, no. 5, May 2020, doi: 10.1371/JOURNAL.PONE.0232766.
6. N. Thomas, F. Fazlollahi, J. D. Brown, and K. J. Kuchenbecker, "Sensorimotor-inspired Tactile Feedback and Control Improve Consistency of Prosthesis Manipulation in the Absence of Direct Vision", *IEEE International Conference on Intelligent Robots and Systems*, pp. 6174–6181, 2021, doi: 10.1109/IROS51168.2021.9635885.
7. M. A. Abd, M. Al-Saidi, M. Lin, G. Liddle, K. Mondal, and E. D. Engeberg, "Surface Feature Recognition and Grasped Object Slip Prevention with a Liquid Metal Tactile Sensor for a Prosthetic Hand", *Proceedings of the IEEE RAS and EMBS International Conference on Biomedical Robotics and Biomechatronics*, pp. 1174–1179, Nov. 2020, doi: 10.1109/BIOROB49111.2020.9224294.
8. Z. Chen, N. Y. Lii, T. Wimböck, S. Fan, H. Liu, and A. Albu-Schäffer, "Experimental analysis on spatial and cartesian impedance control for the dexterous

DLR/HIT II hand", *International Journal of Robotics and Automation*, vol. 29, no. 1, pp. 1–13, 2014, doi: 10.2316/JOURNAL.206.2014.1.206-3669.

9. L. Jiang, B. Liu, S. Fan, and H. Liu, "A posture planning method in clustered synergy subspace for HIT/DLR hand II", *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11745, pp. 134–145, 2019, doi: 10.1007/978-3-030-27529-7_12.

10. D. E. Canbay et al., "Calibration of tactile/force sensors for grasping with the PRISMA Hand II", *IEEE/ASME International Conference on Advanced Intelligent Mechatronics, AIM*, pp. 442–447, Jul. 2021, doi: 10.1109/AIM46487.2021.9517508.

11. A. Leccia, M. Sallam, S. Grazioso, T. Caporaso, G. Di Gironimo, and F. Ficuciello, "Development and testing of a virtual simulator for a myoelectric prosthesis prototype – the PRISMA Hand II – to improve its usability and acceptability", *Engineering Applications of Artificial Intelligence*, vol. 121, May 2023, doi: 10.1016/J.ENGAPPAI.2023.105853.

12. F. Ficuciello, G. Pisani, S. Marcellini, and B. Siciliano, "The PRISMA Hand I: A novel underactuated design and EMG/voice-based multimodal control", *Engineering Applications of Artificial Intelligence*, vol. 93, Aug. 2020, doi:10.1016/J.ENGAPPAI.2020.103698.

13. J. Fajardo, D. Cardona, G. Maldonado, V. Ferman, and E. Rohmer, "A Robust Control Strategy for Sensorless Under-Tendon-Driven Prosthetic Hands", *Proceeding of 20th International Conference on Advanced Robotics*, pp. 581–587, 2021, doi: 10.1109/ICAR53236.2021.9659369.

14. J. Fajardo, V. Ferman, D. Cardona, G. Maldonado, A. Lemus, and E. Rohmer, "Galileo hand: An anthropomorphic and affordable upper-limb prosthesis", *IEEE Access*, vol.8, pp.81365–81377, 2020, doi:10.1109/ACCESS.2020.2990881.

15. D. Cardona, G. Maldonado, V. Ferman, A. Lemus, and J. Fajardo, "Impact of Diverse Aspects in User-Prosthesis Interfaces for Myoelectric Upper-limb Prostheses", *Proceedings of the IEEE RAS and EMBS International Conference on Biomedical Robotics and Biomechatronics*, pp. 954–960, Nov. 2020,

doi: 10.1109/BIOROB49111.2020.9224288.

16. L. De Arco, O. Ramos, M. Munera, M. Moazen, H. Wurdemann, and C. A. Cifuentes, "The PrHand: Functional Assessment of an Underactuated Soft-Robotic Prosthetic Hand", *Proceedings of the IEEE RAS and EMBS International Conference on Biomedical Robotics and Biomechatronics*, pp.1-6, 2022,

doi: 10.1109/BIOROB52689.2022.9925316.

17. P. Weiner, C. Neef, Y. Shibata, Y. Nakamura, and T. Asfour, "An Embedded, Multi-Modal Sensor System for Scalable Robotic and Prosthetic Hand Fingers", *Sensors*, vol. 20, no. 1, p. 101, Dec. 2019, doi: 10.3390/S20010101.

18. I. Llop-Harillo, A. Pérez-González, J. Starke, and T. Asfour, "The Anthropomorphic Hand Assessment Protocol (AHAP)", *Robotics and Autonomous Systems*, vol.121, p. 103259, Nov. 2019, doi:10.1016/J.ROBOT.2019.103259.

19. P. Weiner, J. Starke, F. Hundhausen, J. Beil, and T. Asfour, "The KIT Prosthetic Hand: Design and Control", *IEEE International Conference on Intelligent Robots and Systems*, pp. 3328–3334, Dec. 2018, doi: 10.1109/IROS.2018.8593851.

20. N. Y. Sattar, Z. Kausar, S. A. Usama, U. Farooq, and U. S. Khan, "EMG Based Control of Transhumeral Prosthesis Using Machine Learning Algorithms", *International Journal of Control, Automation, and Systems*, vol. 19, no. 10, pp. 3522–3532, Oct. 2021, doi: 10.1007/S12555-019-1058-5/METRICS.

21. S. Abbaspour, M. Lindén, H. Gholamhosseini, A. Naber, and M. Ortiz-Catalan, "Evaluation of surface EMG-based recognition algorithms for decoding hand movements", *Medical & Biological Engineering & Computing*, vol. 58, no. 1, pp. 83–100, Jan. 2020, doi: 10.1007/S11517-019-02073-Z/TABLES/9.

22. T. Roland, S. Amsuess, M. F. Russold, and W. Baumgartner, "Ultra-Low-Power Digital Filtering for Insulated EMG Sensing", *Sensors*, vol.19, no.4, p. 959, Feb. 2019, doi: 10.3390/S19040959.

23. G. Cisotto, M. Capuzzo, A. V. Guglielmi, and A. Zanella, "Feature stability and setup minimization for EEG-EMG-enabled monitoring systems", *EURASIP Journal on Advances in Signal Processing*, no. 1, pp. 4–22, Dec. 2022, doi: 10.1186/S13634-022-00939-3/FIGURES/4.

24. M. S. Al-Quraishi, I. Elamvazuthi, T. B. Tang, M. Al-Qurishi, S. Parasuraman, and A. Borboni, "Multimodal Fusion Approach Based on EEG and EMG Signals for Lower Limb Movement Recognition", *IEEE Sensors Journal*, vol.21, no. 24, pp. 27640–27650, Dec. 2021, doi:10.1109/JSEN.2021.3119074.
25. M. Simao, N. Mendes, O. Gibaru, and P. Neto, "A Review on Electromyography Decoding and Pattern Recognition for Human-Machine Interaction", *IEEE Access*, vol. 7, pp. 39564–39582, 2019, doi: 10.1109/ACCESS.2019.2906584.
26. L. H. Smith and L. J. Hargrove, "Comparison of surface and intramuscular EMG pattern recognition for simultaneous wrist/hand motion classification", *Conference proceedings of Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, p. 4223, 2013, doi: 10.1109/EMBC.2013.6610477.
27. L. H. Smith, T. A. Kuiken, and L. J. Hargrove, "Real-time simultaneous and proportional myoelectric control using intramuscular EMG", *Journal of Neural Engineering*, vol.11, no. 6, Nov. 2014, doi: 10.1088/1741-2560/11/6/066013.
28. T. R. Farrell and R. F. ff Weir, "A comparison of the effects of electrode implantation and targeting on pattern classification accuracy for prosthesis control", *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 9, pp. 2198–2211, Sep. 2008, doi: 10.1109/TBME.2008.923917.
29. J. Wang, L. Tang, and J. E Bronlund, "Surface EMG Signal Amplification and Filtering", *International Journal of Computer Applications*, vol. 82, no. 1, 2013, doi: 10.5120/14079-2073.
30. C. Fang, B. He, Y. Wang, J. Cao, and S. Gao, "EMG-Centered Multisensory Based Technologies for Pattern Recognition in Rehabilitation: State of the Art and Challenges", *Biosensors*, vol. 10, no. 8, p. 85, Jul. 2020, doi: 10.3390/BIOS10080085.
31. O. W. Samuel et al., "Intelligent EMG pattern recognition control method for upper-limb multifunctional prostheses: Advances, current challenges, and future prospects", *IEEE Access*, vol. 7, pp. 10150–10165, 2019, doi: 10.1109/ACCESS.2019.2891350.

32. W. Geng, Y. Du, W. Jin, W. Wei, Y. Hu, and J. Li, "Gesture recognition by instantaneous surface EMG images", *Scientific Reports*, vol. 6, pp. 6–13, Nov. 2016, doi: 10.1038/srep36571.
33. M. B. I. Reaz, M. S. Hussain, and F. Mohd-Yasin, "Techniques of EMG signal analysis: detection, processing, classification and applications", *Biological Procedures*, vol. 8, no. 1, pp. 11–35, Mar. 2006, doi: 10.1251/BPO115.
34. J. Reeves and L. McLean, "The influence of contraction type, prior performance of a maximal voluntary contraction and measurement duration on fine-wire EMG amplitude", *Journal of Electromyography and Kinesiology*, vol.59, p. 102566, Aug. 2021, doi: 10.1016/J.JELEKIN.2021.102566.
35. C. J. de Luca, L. Donald Gilmore, M. Kuznetsov, and S. H. Roy, "Filtering the surface EMG signal: Movement artifact and baseline noise contamination", *Journal of Biomechanics*, vol. 43, no. 8, pp. 1573–1579, May 2010, doi: 10.1016/j.jbiomech.2010.01.027.
36. N. Khan, M. Alam, A. Masud, and A. Amin, "Importance of High Order High Pass and Low Pass Filters", *World Applied Sciences Journal*, vol. 34, no. 9, pp. 1261–1268, 2016, doi: 10.5829/idosi.wasj.2016.1261.1268.
37. A. Kurapa, D. Rathore, D. R. Edla, A. Bablani, and V. Kuppili, "A Hybrid Approach for Extracting EMG signals by Filtering EEG Data for IoT Applications for Immobile Persons", *Wireless Personal Communications*, vol.114, no. 4, pp. 3081–3101, Jun. 2020, doi: 10.1007/S11277-020-07518-5.
38. I. Arregui et al., "High-Power Filter Design in Waveguide Technology: Future Generation of Waveguide Satellite Filters in Payloads Handling Increasing Bit Rates and Numbers of Channels", *IEEE Microwave Magazine*, vol. 21, no. 6, pp. 46–57, Jun. 2020, doi: 10.1109/MMM.2020.2979154.
39. B. Somers, T. Francart, and A. Bertrand, "A generic EEG artifact removal algorithm based on the multi-channel Wiener filter", *Journal of Neural Engineering*, vol. 15, no.3, Feb. 2018, doi: 10.1088/1741-2552/AAAC92.
40. L. Moreau, L. Stehly, P. Boué, Y. Lu, E. Larose, and M. Campillo, "Improving ambient noise correlation functions with an SVD-based Wiener filter", *Geophysical Journal International*, vol. 211, no. 1, pp. 418–426, Oct. 2017,

doi: 10.1093/GJI/GGX306.

41. A. Soni and M. Gupta, "Analysis and Design of Optimized Fractional Order Low-Pass Bessel Filter", *Journal of Circuits, Systems and Computers*, vol. 30, no. 2, Aug. 2020, doi: 10.1142/S0218126621500353.
42. A. Soni and M. Gupta, "Designing of Fractional Order Bessel Filter using Optimization Techniques", *International Journal of Electronics Letters*, vol. 10, pp.71-86, 2021, doi: 10.1080/21681724.2020.1870715.
43. P. Cao et al., "Compensation circuit design for tuned half-wavelength transmission lines based on Bessel filter", *International Journal of Electrical Power & Energy Systems*, vol.134, p.107335, Jan.2022, doi:10.1016/J.IJEPES.2021.107335.
44. I. M. Khairuddin, S. N. I. Sidek, A. P. P. A. Majeed, and A. A. Puzi, "Classifying Motion Intention from EMG signal: A k-NN Approach", *Proceeding of 7th International Conference on Mechatronics Engineering, ICOM 2019*, pp. 1-4, Oct. 2019, doi: 10.1109/ICOM47790.2019.8952042.
45. Z. Zhang, K. Yang, J. Qian, and L. Zhang, "Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network", *Sensors*, vol. 19, no. 14, p. 3170, Jul. 2019, doi: 10.3390/S19143170.
46. G. L. Ying, I. Elamvazuthi, M. K. A. A. Khan, and S. Parasuraman, "Development of EMG based Upper Arm Exoskeleton", *Proceedings of the IEEE International Conference on Recent Trends in Electrical, Control and Communication, RTECC*, pp. 1–5, Jan. 2019, doi: 10.1109/RTECC.2018.8625671.
47. M. T. Almalchy, V. Ciobanu, and N. Popescu, "Noise removal from ECG signal based on filtering techniques", *Proceedings of 22nd International Conference on Control Systems and Computer Science, CSCS 2019*, pp. 176–181, May 2019, doi: 10.1109/CSCS.2019.00037.
48. P. Podder, Md. M. Hasan, Md. R. Islam, and M. Sayeed, "Design and Implementation of Butterworth, Chebyshev-I and Elliptic Filter for Speech Signal Analysis", *International Journal of Computer Applications*, vol. 98, no. 7, pp. 12–18, Feb. 2020, doi: 10.5120/17195-7390.

49. S. Mahata, R. Kar, and D. Mandal, "Direct digital fractional-order Butterworth filter design using constrained optimization", *International Journal of Electronics and Communications*, vol. 128, p. 153511, Jan. 2021, doi: 10.1016/J.AEUE.2020.153511.
50. D. E. O'Leary, "Artificial Intelligence and Big Data", *IEEE Intelligent Systems*, vol. 28, no. 2, pp. 96–99, 2013, doi: 10.1109/MIS.2013.39.
51. Y. Wei et al., "A Semi-Supervised Progressive Learning Algorithm for Brain-Computer Interface.", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 2067–2076, 2022, doi: 10.1109/TNSRE.2022.3192448.
52. G. Prathap, T. N. Kumara, and R. Ragel, "Near real-time data labeling using a depth sensor for emg based prosthetic arms", *Advances in Intelligent Systems and Computing*, vol. 869, pp. 310–325, 2018, doi: 10.1007/978-3-030-01057-7_25.
53. T. Jiang, J. L. Gradus, and A. J. Rosellini, "Supervised Machine Learning: A Brief Primer", *Behavior Therapy*, vol. 51, no. 5, pp. 675–687, 2020, doi: 10.1016/j.beth.2020.05.002.
54. A. Furui, H. Hayashi, and T. Tsuji, "An EMG Pattern Classification Method Based on a Mixture of Variance Distribution Models", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 5216–5219, Oct. 2018, doi: 10.1109/EMBC.2018.8513446.
55. E. Dann, N. C. Henderson, S. A. Teichmann, M. D. Morgan, and J. C. Marioni, "Differential abundance testing on single-cell data using k-nearest neighbour graphs", *Nature Biotechnology*, vol. 40, no. 2, pp. 245–253, Sep. 2021, doi: 10.1038/s41587-021-01033-z.
56. H. A. Abu Alfeilat et al., "Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review", *Big Data*, vol. 7, no. 4, pp. 221–248, Dec. 2019, doi: 10.1089/BIG.2018.0175.
57. C. Sitawarin and D. Wagner, "On the robustness of deep K-nearest neighbors", *Proceedings of 2019 IEEE Symposium on Security and Privacy Workshops, SPW 2019*, pp. 1–7, May 2019, doi: 10.1109/SPW.2019.00014.

58. N. Papernot and P. McDaniel, "Deep k-Nearest Neighbors: Towards Confident, Interpretable and Robust Deep Learning", *arXiv*, Mar. 2018, doi: 10.48550/arxiv.1803.04765.
59. I. Triguero, D. García-Gil, J. Maillo, J. Luengo, S. García, and F. Herrera, "Transforming big data into smart data: An insight on the use of the k-nearest neighbors algorithm to obtain quality data", *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 9, no. 2, Mar. 2019, doi: 10.1002/WIDM.1289.
60. H. Saadatfar, S. Khosravi, J. H. Joloudari, A. Mosavi, and S. Shamshirband, "A New K-Nearest Neighbors Classifier for Big Data Based on Efficient Data Pruning", *Mathematics*, vol. 8, no. 2, p. 286, Feb. 2020, doi: 10.3390/MATH8020286.
61. J. Zhang, C. Ling, and S. Li, "Human movements classification using multi-channel surface EMG signals and deep learning technique", *Proceedings of 2019 International Conference on Cyberworlds*, pp. 267–273, Oct. 2019, doi: 10.1109/CW.2019.00051.
62. L. Z. Liao, Y. L. Tseng, H. H. Chiang, and W. Y. Wang, "EMG-based Control Scheme with SVM Classifier for Assistive Robot Arm", *Proceedings of 2018 International Automatic Control Conference, CACS*, Jan. 2019, doi: 10.1109/CACS.2018.8606762.
63. A. Subasi, "Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders", *Computers in Biology and Medicine*, vol. 43, no. 5, pp. 576–586, Jun. 2013, doi:10.1016/J.COMPBIOMED.2013.01.020.
64. Q. Meng, J. Zhang, and X. Yang, "Virtual Rehabilitation Training System Based on Surface EMG Feature Extraction and Analysis", *Journal of Medical Systems*, vol. 43, no. 3, pp. 1–11, Jan. 2019, doi: 10.1007/S10916-019-1166-Z.
65. D. C. Toledo-Perez, J. Rodriguez-Resendiz, and R. A. Gomez-Loenzo, "A study of computing zero crossing methods and an improved proposal for EMG signals", *IEEE Access*, vol. 8, pp. 8783–8790, 2020, doi:10.1109/ACCESS.2020.2964678.

66. A. Alkan and M. Günay, "Identification of EMG signals using discriminant analysis and SVM classifier", *Expert Systems With Applications*, vol. 39, no. 1, pp. 44–47, Jan. 2012, doi: 10.1016/J.ESWA.2011.06.043.
67. N. Kalcheva, M. Karova, and I. Penev, "Comparison of the accuracy of SVM kernel functions in text classification", *Proceedings of the International Conference on Biomedical Innovations and Applications, BIA 2020*, pp. 141–145, Sep. 2020, doi: 10.1109/BIA50171.2020.9244278.
68. P. S. Asmi, K. Subramaniam, and N. v. Iqbal, "Classification of fractal features of uterine EMG signal for the prediction of preterm birth", *Biomedical and Pharmacology Journal*, vol. 11, no. 1, pp. 369–374, 2018, doi: 10.13005/BPJ/1381.
69. Y. Li, W. Dai, and W. Zhang, "Bearing Fault Feature Selection Method Based on Weighted Multidimensional Feature Fusion", *IEEE Access*, vol. 8, pp. 19008-19025, 2020, doi: 10.1109/ACCESS.2020.2967537.
70. T. T. Dai and Y. S. Dong, "Introduction of svm related theory and its application research", *Proceedings of 2020 3rd International Conference on Advanced Electronic Materials, Computers and Software Engineering, AEMCSE 2020*, pp. 230–233, Apr. 2020, doi:10.1109/AEMCSE50948.2020.00056.
71. K. Shankar, S. K. Lakshmanaprabu, D. Gupta, A. Maseleno, and V. H. C. de Albuquerque, "Optimal feature-based multi-kernel SVM approach for thyroid disease classification", *The Journal of Supercomputing*, vol. 76, no. 2, pp. 1128–1143, Jul. 2018, doi: 10.1007/S11227-018-2469-4.
72. B. Taha Jijo and A. Mohsin Abdulazeez, "Classification Based on Decision Tree Algorithm for Machine Learning", *Journal of Applied Science and Technology Trends*, vol. 2, no.1, pp. 20–28, Mar. 2021, doi: 10.38094/jastt20165.
73. I. D. Mienye, Y. Sun, and Z. Wang, "Prediction performance of improved decision tree-based algorithms: a review", *Procedia Manufacturing*, vol. 35, pp. 698–703, Jan. 2019, doi: 10.1016/J.PROMFG.2019.06.011.
74. S. Tangirala, "Evaluating the Impact of GINI Index and Information Gain on Classification using Decision Tree Classifier Algorithm", *International Journal of Advanced Computer Science and Applications*, vol.11, no.2, pp. 612–619, 2020, doi: 10.14569/IJACSA.2020.0110277.

75. H. H. Patel and P. Prajapati, "Study and Analysis of Decision Tree Based Classification Algorithms", *International Journal of Computer Sciences and Engineering*, vol. 6, no. 10, pp. 74–78, Oct. 2018, doi: 10.26438/IJCSE/V6I10.7478.
76. D. Priyanka Kumar, "Decision tree classifier: A detailed survey", *International Journal of Information and Decision Sciences*, vol.12, no.3, pp. 246–269, 2020, doi: 10.1504/IJIDS.2020.108141.
77. J. Bekker and J. Davis, "Estimating the Class Prior in Positive and Unlabeled Data Through Decision Tree Induction", *Proceedings of the AAI Conference on Artificial Intelligence*, vol. 32, no. 1, pp. 2712–2719, Apr. 2018, doi: 10.1609/AAAI.V32I1.11715.
78. A. Ahmim, L. Maglaras, M. A. Ferrag, M. Derdour, and H. Janicke, "A novel hierarchical intrusion detection system based on decision tree and rules-based models", *Proceedings of 15th Annual International Conference on Distributed Computing in Sensor Systems, DCOSS 2019*, pp. 228–233, May 2019, doi: 10.1109/DCOSS.2019.00059.
79. W. Zhang and E. Ntoutsi, "FAHT: An Adaptive Fairness-aware Decision Tree Classifier", *IJCAI International Joint Conference on Artificial Intelligence*, pp. 1480–1486, Jul. 2019, doi: 10.48550/arxiv.1907.07237.
80. M. Azad et al., "Entropy-Based Greedy Algorithm for Decision Trees Using Hypotheses", *Entropy*, vol. 23, no. 7, p. 808, Jun. 2021, doi:10.3390/E23070808.
81. A. Zharmagambetov, S. S. Hada, M. Gabidolla, and M. A. Carreira-Perpinan, "Non-Greedy Algorithms for Decision Tree Optimization: An Experimental Comparison", *Proceedings of the International Joint Conference on Neural Networks, Shenzhen, China, 2021*, pp. 1-8, doi:10.1109/IJCNN52387.2021.9533597.
82. L. L. Custode and G. Iacca, "Evolutionary Learning of Interpretable Decision Trees", *IEEE Access*, vol. 11, pp. 6169–6184, 2023, doi: 10.1109/ACCESS.2023.3236260.
83. S. R. Jiao, J. Song, and B. Liu, "A Review of Decision Tree Classification Algorithms for Continuous Variables", *Journal of Physics: Conference Series*, vol. 1651, no. 1, Nov. 2020, doi: 10.1088/1742-6596/1651/1/012083.

84. M. Batra and R. Agrawal, "Comparative analysis of decision tree algorithms", *Advances in Intelligent Systems and Computing*, vol. 652, pp. 31–36, 2018, doi: 10.1007/978-981-10-6747-1_4.
85. A. Trabelsi, Z. Elouedi, and E. Lefevre, "Decision tree classifiers for evidential attribute values and class labels", *Fuzzy Sets and Systems*, vol. 366, pp. 46–62, Jul. 2019, doi: 10.1016/J.FSS.2018.11.006.
86. G. Singer, R. Anuar, and I. Ben-Gal, "A weighted information-gain measure for ordinal classification trees", *Expert Systems With Applications*, vol. 152, p. 113375, Aug. 2020, doi: 10.1016/J.ESWA.2020.113375.
87. S. Tangirala, "Evaluating the Impact of GINI Index and Information Gain on Classification using Decision Tree Classifier Algorithm", *International Journal of Advanced Computer Science and Applications*, vol.11, no.2, pp.612–619, 2020, doi: 10.14569/IJACSA.2020.0110277.
88. F. J. Yang, "An extended idea about decision trees", *Proceedings of 6th Annual Conference on Computational Science and Computational Intelligence, CSCI 2019*, pp. 349–354, Dec. 2019, doi: 10.1109/CSCI49370.2019.00068.
89. M. Wu, M. C. Hughes, S. Parbhoo, M. Zazzi, V. Roth, and F. Doshi-Velez, "Beyond sparsity: Tree regularization of deep models for interpretability", *Proceedings of 32nd AAAI Conference on Artificial Intelligence, AAAI 2018*, pp. 1670–1678, 2018, doi: 10.1609/aaai.v32i1.11501.
90. R. G. Leiva, A. F. Anta, V. Mancuso, and P. Casari, "A novel hyperparameter-free approach to decision tree construction that avoids overfitting by design", *IEEE Access*, vol. 7, pp. 99978–99987, 2019, doi: 10.1109/ACCESS.2019.2930235.
91. V. A. S. Hernández, R. Monroy, M. A. Medina-Pérez, O. Loyola-González, and F. Herrera, "A Practical Tutorial for Decision Tree Induction", *ACM Computing Surveys*, vol. 54, no. 1, Jan. 2021, doi: 10.1145/3429739.
92. A. Kadiyala and A. Kumar, "Applications of python to evaluate the performance of decision tree-based boosting algorithms", *Environmental Progress & Sustainable Energy*, vol. 37, no. 2, pp. 618–623, Mar. 2018, doi: 10.1002/EP.12888.

93. S. Visalaxi, D. Punnoose, and T. S. Muthu, "An analogy of endometriosis recognition using machine learning techniques", *Proceedings of the 3rd International Conference on Intelligent Communication Technologies and Virtual Mobile Networks, ICICV 2021*, pp. 739–746, Feb. 2021, doi: 10.1109/ICICV50876.2021.9388403.
94. M. Moencks, V. de Silva, J. Roche, and A. Kondo, "Adaptive Feature Processing for Robust Human Activity Recognition on a Novel Multi-Modal Dataset", *arXiv*, pp.1-13, Jan. 2019, doi: 10.48550/arxiv.1901.02858.
95. V. G. Costa and C. E. Pedreira, "Recent advances in decision trees: an updated survey", *Artificial Intelligence Review*, vol.56, pp.4765–4800, Oct. 2022, doi: 10.1007/S10462-022-10275-5.
96. F. Avellaneda, "Efficient Inference of Optimal Decision Trees", *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 4, pp. 3195–3202, Apr. 2020, doi: 10.1609/AAAI.V34I04.5717.
97. N. Arifah, M. Nor, A. Mohamed, and S. Mutalib, "Prevalence of hypertension: predictive analytics review", *International Journal of Artificial Intelligence*, vol. 9, no. 4, pp. 576–583, 2020, doi: 10.11591/ijai.v9.i4.pp576-583.
98. M. E. McNamara, M. Zisser, C. G. Beevers, and J. Shumake, "Not just “big” data: Importance of sample size, measurement error, and uninformative predictors for developing prognostic models for digital interventions", *Behaviour Research and Therapy*, vol. 153, p. 104086, Jun. 2022, doi: 10.1016/J.BRAT.2022.104086.
99. M. Bansal, A. Goyal, and A. Choudhary, "A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning", *Decision Analytics Journal*, vol. 3, p. 100071, Jun. 2022, doi: 10.1016/J.DAJOUR.2022.100071.
100. M. Decuyper, M. Stockhoff, S. Vandenberghe, and X. Ying, "An Overview of Overfitting and its Solutions", *Journal of Physics: Conference Series*, vol. 1168, no. 2, p. 022022, Feb. 2019, doi: 10.1088/1742-6596/1168/2/022022.
101. G. K. Gupta and D. K. Sharma, "A Review of Overfitting Solutions in Smart Depression Detection Models", *Proceedings of the 2022 9th International*

Conference on Computing for Sustainable Global Development, INDIACom 2022, pp. 145–151, 2022, doi: 10.23919/INDIACOM54597.2022.9763147.

102. B. Ghogh and M. Crowley, "The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial", *arXiv*, p.1-23, May 2019, doi: 10.48550/arxiv.1905.12787.

103. A. Parmar, R. Katariya, and V. Patel, "A Review on Random Forest: An Ensemble Classifier", *Lecture Notes on Data Engineering and Communications Technologies*, vol. 26, pp. 758–763, 2019, doi: 10.1007/978-3-030-03146-6_86.

104. A. B. Shaik and S. Srinivasan, "A brief survey on random forest ensembles in classification model", *Lecture Notes in Networks and Systems*, vol. 56, pp. 253–260, 2019, doi: 10.1007/978-981-13-2354-6_27.

105. J. Hu and S. Szymczak, "A review on longitudinal data analysis with random forest", *Briefings in Bioinformatics*, vol. 24, no. 2, pp. 1-11, Jan. 2023, doi: 10.1093/BIB/BBAD002.

106. M. M. Jibril et al., "An overview of streamflow prediction using random forest algorithm", *GSC Advanced Research and Reviews*, vol. 13, no. 1, pp. 50–57, Oct. 2022, doi: 10.30574/GSCARR.2022.13.1.0112.

107. W. Nabi, A. Bansal, and B. Xu, "Applications of artificial intelligence and machine learning approaches in echocardiography", *Echocardiography*, vol. 38, no. 6, pp. 982–992, Jun. 2021, doi: 10.1111/ECHO.15048.

108. J. Roy, M. A. Ali, M. R. Ahmed, and K. Sundaraj, "Machine learning techniques for predicting surface EMG activities on upper limb muscle: A systematic review", *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering*, vol. 325, pp. 330–339, 2020, doi: 10.1007/978-3-030-52856-0_26/COVER.

109. S. M. Khan, A. A. Khan, and O. Farooq, "Selection of features and classifiers for EMG-EEG-Based upper limb assistive devices - A review", *IEEE Reviews in Biomedical Engineering*, vol. 13, pp. 248–260, 2020, doi: 10.1109/RBME.2019.2950897.

110. A. Subasi and E. Yaman, "Emg signal classification using discrete wavelet transform and rotation forest", *Proceeding of International Conference on Medical and Biological Engineering 2019*, vol. 73, pp. 29–35, 2019, doi: 10.1007/978-3-030-17971-7_5.
111. R. G. Leiva, A. F. Anta, V. Mancuso, and P. Casari, "A novel hyperparameter-free approach to decision tree construction that avoids overfitting by design", *IEEE Access*, vol. 7, pp. 99978–99987, 2019, doi: 10.1109/ACCESS.2019.2930235.
112. T. Zhou, O. M. Omisore, W. Du, L. Wang, and Y. Zhang, "Adapting Random Forest Classifier Based on Single and Multiple Features for Surface Electromyography Signal Recognition", *Proceedings of 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics, CISP-BMEI 2019*, Suzhou, China, 19-21 Oct. 2019, pp. 1-6, 2019 doi: 10.1109/CISP-BMEI48845.2019.8965719.
113. A. A. Abdullah, A. Subasi, and S. M. Qaisar, "Surface EMG signal classification by using WPD and ensemble tree classifiers", *Proceedings of the International Conference on Medical and Biological Engineering 2017*, Springer, vol. 62, pp. 475–481, 2017, doi: 10.1007/978-981-10-4166-2_73.
114. E. Yaman and A. Subasi, "Comparison of Bagging and Boosting Ensemble Machine Learning Methods for Automated EMG Signal Classification", *BioMed Research International*, 2019, doi: 10.1155/2019/9152506.
115. Y. Narayan, "Comparative analysis of SVM and Naive Bayes classifier for the SEMG signal classification", *Materials Today*, vol. 37, no. 2, pp. 3241–3245, Jan. 2021, doi: 10.1016/J.MATPR.2020.09.093.
116. A. Asghar, S. Jawaid Khan, F. Azim, C. S. Shakeel, A. Hussain, and I. K. Niazi, "Review on electromyography based intention for upper limb control using pattern recognition for human-machine interaction", *Proceedings of the Institution of Mechanical Engineers, Part H*, vol. 236, no. 5, pp. 628–645, May 2022, doi: 10.1177/09544119221074770.

117. Y. Xue, Y. Yu, K. Yin, P. Li, S. Xie, and Z. Ju, "Human In-Hand Motion Recognition Based on Multi-Modal Perception Information Fusion", *IEEE Sensors Journal*, vol. 22, no. 7, pp. 6793–6805, Apr. 2022, doi: 10.1109/JSEN.2022.3148992.
118. P. Kumar, S. K. V, M. C. Lakkannavar, and V. C. R, "Comparison of Machine Learning Algorithms for EMG based Muscle Function Analysis", *Proceeding of 4th International Conference on Circuits, Control, Communication and Computing (I4C)*, Bangalore, India, 2022, pp. 123–128, Mar. 2023, doi: 10.1109/I4C57141.2022.10057856.
119. S. Tortora, L. Tonin, C. Chisari, S. Micera, E. Menegatti, and F. Artoni, "Hybrid Human-Machine Interface for Gait Decoding Through Bayesian Fusion of EEG and EMG Classifiers", *Frontiers in Neurorobotics*, vol. 14, p. 89, Nov. 2020, doi: 10.3389/FNBOT.2020.582728/BIBTEX.
120. S. Kim et al., "Development of an Armband EMG Module and a Pattern Recognition Algorithm for the 5-Finger Myoelectric Hand Prosthesis", *International Journal of Precision Engineering and Manufacturing*, vol. 20, no. 11, pp. 1997–2006, Nov. 2019, doi: 10.1007/S12541-019-00195-W/METRICS.
121. D. S. Pamungkas and I. Simatupang, "Comparison EMG Pattern Recognition Using Bayes and NN Methods", *Proceeding of International Conference on Mechanical, Electronics, Computer, and Industrial Technology, MECnIT 2020*, pp. 1–4, Jun. 2020, doi: 10.1109/MECNIT48290.2020.9166666.
122. F. Di Nardo, T. Basili, S. Meletani, and D. Scaradozzi, "Wavelet-Based Assessment of the Muscle-Activation Frequency Range by EMG Analysis", *IEEE Access*, vol. 10, pp. 9793–9805, 2022, doi: 10.1109/ACCESS.2022.3141162.
123. Y. Zhou et al., "EMG Signal Processing for Hand Motion Pattern Recognition Using Machine Learning Algorithms", *Archives of Orthopaedics*, vol. 1, no.1, pp. 17–26, Jun. 2020, doi: 10.33696/ORTHOPAEDICS.1.005.
124. N. Subhashini and A. Kandaswamy, "Gesture Classification of Surface Electromyography Signals Using Machine Learning Algorithms for Hand Prosthetics", *Journal of Medical Imaging and Health Informatics*, vol. 11, no. 12, pp. 3141–3152, Jan. 2022, doi: 10.1166/JMIHI.2021.3907.

125. J. Mantilla-Brito, D. Pozo-Espín, S. Solórzano, and L. Morales, "Embedded System for Hand Gesture Recognition Using EMG Signals: Effect of Size in the Analysis Windows", *Advances in Intelligent Systems and Computing*, vol. 1078, pp. 214–225, 2020, doi: 10.1007/978-3-030-33614-1_15.
126. P. Valdiviezo-Diaz, F. Ortega, E. Cobos, and R. Lara-Cabrera, "A Collaborative Filtering Approach Based on Naïve Bayes Classifier", *IEEE Access*, vol. 7, pp. 108581–108592, 2019, doi: 10.1109/ACCESS.2019.2933048.
127. T. Yu, K. Akhmadeev, E. Le Carpentier, Y. Aoustin, and D. Farina, "On-line recursive decomposition of intramuscular emg signals using gpu-implemented bayesian filtering", *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 6, pp. 1806–1818, Jun. 2020, doi: 10.1109/TBME.2019.2948397.
128. C. W. Antuvan and L. Masia, "An LDA-Based Approach for Real-Time Simultaneous Classification of Movements Using Surface Electromyography", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 27, no. 3, pp. 552–561, Mar. 2019, doi: 10.1109/TNSRE.2018.2873839.
129. B. Saeed et al., "Leveraging ANN and LDA Classifiers for Characterizing Different Hand Movements Using EMG Signals", *Arabian Journal for Science and Engineering*, vol. 46, no. 2, pp. 1761–1769, Feb. 2021, doi: 10.1007/S13369-020-05044-X/METRICS.
130. H. Zhang, Y. Zhao, F. Yao, L. Xu, P. Shang, and G. Li, "An adaptation strategy of using LDA classifier for EMG pattern recognition", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 4267–4270, 2013, doi: 10.1109/EMBC.2013.6610488.
131. R. Atangana, D. Tchiotsop, G. Kenne, and L. C. DjoufackNkengfac k, "EEG Signal Classification using LDA and MLP Classifier", *Health Informatics - An International Journal*, vol. 9, no. 1, pp. 14–32, Feb. 2020, doi: 10.5121/HIJ.2020.9102.
132. Y. Narayan, "Hb vsEMG signal classification with time domain and Frequency domain features using LDA and ANN classifier", *Materials Today: Proceedings*, vol. 37, no. 2, pp. 3226–3230, Jan. 2021, doi: 10.1016/J.MATPR.2020.09.091.

133. Z. Shen, Y. Zhang, and W. Chen, "A Bayesian Classification Intrusion Detection Method Based on the Fusion of PCA and LDA", *Security and Communication Networks*, pp.1-11, 2019, doi: 10.1155/2019/6346708.
134. P. Wei, J. Zhang, F. Tian, and J. Hong, "A comparison of neural networks algorithms for EEG and sEMG features based gait phases recognition", *Biomedical Signal Processing and Control*, vol. 68, Jul. 2021, doi: 10.1016/J.BSPC.2021.102587.
135. S. Pancholi and A. M. Joshi, "Intelligent upper-limb prosthetic control (iulp) with novel feature extraction method for pattern recognition using emg", *Journal of Mechanics in Medicine and Biology*, vol. 21, no. 6, Jun. 2021, doi: 10.1142/S0219519421500433.
136. R. Pradeep, L. S. Praveen, and P. Shankpal, "Implementation of Multiple DOF Bionic Hand for EMG Controlled Schemes", *Proceeding of 2nd International Conference on Innovative Mechanisms for Industry Applications, ICIMIA*, pp. 36–40, Mar. 2020, doi: 10.1109/ICIMIA48430.2020.9074874.
137. S. Pancholi, P. Jain, A. Varghese, and A. M. Joshi, "A Novel Time-Domain based Feature for EMG-PR Prosthetic and Rehabilitation Application", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 5084–5087, Jul. 2019, doi: 10.1109/EMBC.2019.8857399.
138. H. Basak, A. Roy, J. B. Lahiri, S. Bose, and S. Patra, "SVM and ANN based Classification of EMG signals by using PCA and LDA", *arXiv*, pp. 1-10, 2021, doi:10.48550/arXiv.2110.15279
139. H. A. Javaid et al., "Classification of Hand Movements Using MYO Armband on an Embedded Platform", *Electronics*, vol. 10, no. 11, 2021, doi: 10.3390/ELECTRONICS10111322.
140. M. Venugopalan and D. Gupta, "An enhanced guided LDA model augmented with BERT based semantic strength for aspect term extraction in sentiment analysis", *Knowledge-based Systems*, vol. 246, Jun. 2022, doi: 10.1016/J.KNOSYS.2022.108668.

141. S. Gao et al., "Use of Advanced Materials and Artificial Intelligence in Electromyography Signal Detection and Interpretation", *Advanced Intelligent Systems*, vol. 4, no. 10, Oct. 2022, doi: 10.1002/AISY.202200063.
142. S. Saranya, S. Poonguzhali, and S. Karunakaran, "Gaussian mixture model based clustering of Manual muscle testing grades using surface Electromyogram signals", *Physical and Engineering Sciences in Medicine*, vol. 43, no. 3, pp. 837–847, Sep. 2020, doi: 10.1007/S13246-020-00880-5.
143. G. Jia, H. K. Lam, S. Ma, Z. Yang, Y. Xu, and B. Xiao, "Classification of Electromyographic Hand Gesture Signals Using Modified Fuzzy C-Means Clustering and Two-Step Machine Learning Approach", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, no. 6, pp. 1428–1435, Jun. 2020, doi: 10.1109/TNSRE.2020.2986884.
144. A. Mengarelli, A. Tigrini, S. Fioretti, S. Cardarelli, and F. Verdini, "On the Use of Fuzzy and Permutation Entropy in Hand Gesture Characterization from EMG Signals: Parameters Selection and Comparison", *Applied Sciences*, vol. 10, no. 20, p. 7144, Oct. 2020, doi: 10.3390/APP10207144.
145. R. Nock et al., "A Geometric Clustering Tool (AGCT) to robustly unravel the inner cluster structures of time-series gene expressions", *PLoS One*, vol. 15, no. 7, Jul. 2020, doi: 10.1371/JOURNAL.PONE.0233755.
146. M. Faisal, E. M. Zamzami, and Sutarman, "Comparative Analysis of Inter-Centroid K-Means Performance using Euclidean Distance, Canberra Distance and Manhattan Distance", *Journal of Physics: Conference Series*, vol. 1566, no. 1, Jun. 2020, doi: 10.1088/1742-6596/1566/1/012112.
147. B. Jumadi Dehotman Sitompul, O. Salim Sitompul, and P. Sihombing, "Enhancement Clustering Evaluation Result of Davies-Bouldin Index with Determining Initial Centroid of K-Means Algorithm", *Journal of Physics: Conference Series*, vol. 1235, no. 1, Jun. 2019, doi: 10.1088/1742-6596/1235/1/012015.
148. X. Wei, Y. Chen, X. Jia, Y. Chen, and L. Xie, "Muscle Activation Visualization System Using Adaptive Assessment and Forces-EMG Mapping", *IEEE Access*, vol. 9, pp. 46374–46385, 2021, doi: 10.1109/ACCESS.2021.3067360.

149. D. Kusuru, A. C. Turlapaty, and M. Thakur, "A Laplacian-Gaussian Mixture Model for Surface EMG Signals from Upper Limbs", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 681–685, 2021, doi: 10.1109/EMBC46164.2021.9630143.
150. Z. Tirandaz, G. Akbarizadeh, and H. Kaabi, "PolSAR image segmentation based on feature extraction and data compression using Weighted Neighborhood Filter Bank and Hidden Markov random field-expectation maximization", *Measurement*, vol. 153, p. 107432, Mar. 2020, doi: 10.1016/J.MEASUREMENT.2019.107432.
151. J. S. Low, Z. Ghafoori, J. C. Bezdek, and C. Leckie, "Seeding on samples for accelerating k-means clustering", *ACM International Conference Proceeding Series*, pp. 41–45, Aug. 2019, doi: 10.1145/3361758.3361774.
152. Y. Fang, D. Zhou, K. Li, Z. Ju, and H. Liu, "Attribute-Driven Granular Model for EMG-Based Pinch and Fingertip Force Grand Recognition", *IEEE Transactions on Cybernetics*, vol. 51, no. 2, pp. 789–800, Feb. 2021, doi: 10.1109/TCYB.2019.2931142.
153. F. Samann and T. Schanze, "EMG based muscle fatigue detection using autocorrelation and k-means clustering", *Proceedings on Automation in Medical Engineering*, vol. 2, no. 1, pp. 739–739, Mar. 2023.
154. A. Miniak-Górecka, K. Podlaski, and T. Gwizdała, "Using K-Means Clustering in Python with Periodic Boundary Conditions", *Symmetry*, vol. 14, no. 6, p. 1237, Jun. 2022, doi: 10.3390/SYM14061237.
155. V. Asanza, E. Pelaez, F. Loayza, I. Mesa, J. Diaz, and E. Valarezo, "EMG Signal Processing with Clustering Algorithms for motor gesture Tasks", *Proceeding of IEEE 3rd Ecuador Technical Chapters Meeting, ETCM*, Cuenca, Ecuador, 2018, pp. 1-6, doi: 10.1109/ETCM.2018.8580270.
156. M. Piorecký, J. Štrobl, and V. Krajca, "Automatic EEG Classification Using Density Based Algorithms Dbscan And Denclue", *Acta Polytechnica*, vol. 59, no. 5, pp. 498–509, Nov. 2019, doi: 10.14311/AP.2019.59.0498.

157. E. J. McDermott, T. Zwiener, U. Ziemann, and C. Zrenner, "Real-time decoding of 5 finger movements from 2 EMG channels for mixed reality human-computer interaction", *bioRxiv*, p. 462120, Sep. 2021, doi: 10.1101/2021.09.28.462120.
158. J. Lundsberg, A. Björkman, N. Malesevic, and C. Antfolk, "Compressed spike-triggered averaging in iterative decomposition of surface EMG", *The Computer Methods and Programs in Biomedicine*, vol. 228, p. 107250, Jan. 2023, doi: 10.1016/J.CMPB.2022.107250.
159. X. Li, S. Liang, S. Yan, J. Ryu, and Y. Wu, "Adaptive detection of Ahead-sEMG based on short-time energy of local-detail difference and recognition in advance of upper-limb movements", *Biomedical Signal Processing and Control*, vol. 84, p. 104752, Jul. 2023, doi: 10.1016/J.BSPC.2023.104752.
160. S. Sonawani, K. Patil, and P. Natarajan, "Biomedical signal processing for health monitoring applications: a review", *International Journal of Applied Systemic Studies*, vol. 10, no. 1, p. 44, 2023, doi: 10.1504/IJASS.2023.129065.
161. M. Simao, N. Mendes, O. Gibaru, and P. Neto, "A Review on Electromyography Decoding and Pattern Recognition for Human-Machine Interaction", *IEEE Access*, vol. 7, pp. 39564–39582, 2019, doi: 10.1109/ACCESS.2019.2906584.
162. F. Stival, S. Michieletto, M. Cognolato, E. Pagello, H. Müller, and M. Atzori, "A quantitative taxonomy of human hand grasps", *Journal of NeuroEngineering and Rehabilitation*, vol. 16, no. 1, pp. 1–17, Feb. 2019, doi: 10.1186/S12984-019-0488-X/FIGURES/6.
163. W. Piatkowska, F. Spolaor, A. Guiotto, G. Guarneri, A. Avogaro, and Z. Sawacha, "EMG analysis across different tasks improves prevention screenings in diabetes: a cluster analysis approach", *Medical & Biological Engineering & Computing*, vol. 60, no. 6, pp. 1659–1673, Jun. 2022, doi: 10.1007/S11517-022-02559-3/FIGURES/8.
164. H. Su, S. E. Ovrur, X. Zhou, W. Qi, G. Ferrigno, and E. De Momi, "Depth vision guided hand gesture recognition using electromyographic signals", *Advanced Robotics*, vol. 34, no. 15, pp. 985–997, Aug. 2020,

doi: 10.1080/01691864.2020.1713886.

165. K. Gokcesu and H. Gokcesu, "Natural Hierarchical Cluster Analysis by Nearest Neighbors with Near-Linear Time Complexity", *arXiv*, pp.1-5, Mar. 2022, doi:10.48550/arXiv.2203.08027

166. G. Hajian, A. Etemad, and E. Morin, "An Investigation of Dimensionality Reduction Techniques for EMG-based Force Estimation", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 698–701, Jul. 2019, doi: 10.1109/EMBC.2019.8856293.

167. N. Thiamchoo and P. Phukpattaranont, "Evaluation of feature projection techniques in object grasp classification using electromyogram signals from different limb positions", *PeerJ Computer Science*, vol. 8, pp.1-24, May 2022, doi: 10.7717/PEERJ-CS.949/SUPP-1.

168. Z. Zhang, K. Yang, J. Qian, and L. Zhang, "Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network", *Sensors*, vol. 19, no. 14, p. 3170, Jul. 2019, doi: 10.3390/S19143170.

169. E. Jeon, W. Ko, J. S. Yoon, and H. Il Suk, "Mutual Information-Driven Subject-Invariant and Class-Relevant Deep Representation Learning in BCI", *IEEE Transactions on Neural Networks and Learning Systems*, vol. 34, no. 2, pp. 739–749, Feb. 2023, doi: 10.1109/TNNLS.2021.3100583.

170. G. Hajian, B. Behinaein, A. Etemad, and E. Morin, "Bagged tree ensemble modelling with feature selection for isometric EMG-based force estimation", *Biomedical Signal Processing and Control*, vol. 78, p. 104012, Sep. 2022, doi: 10.1016/J.BSPC.2022.104012.

171. O. P. Idowu, A. E. Ilesanmi, X. Li, O. W. Samuel, P. Fang, and G. Li, "An integrated deep learning model for motor intention recognition of multi-class EEG Signals in upper limb amputees", *Computer Methods and Programs in Biomedicine*, vol. 206, p. 106121, Jul. 2021, doi: 10.1016/J.CMPB.2021.106121.

172. A. Ameri, M. A. Akhaee, E. Scheme, and K. Englehart, "Regression convolutional neural network for improved simultaneous EMG control", *Journal of*

Neural Engineering, vol. 16, no. 3, pp. 36015, Apr. 2019, doi: 10.1088/1741-2552/AB0E2E.

173. S. Stapornchaisit, Y. Kim, A. Takagi, N. Yoshimura, and Y. Koike, "Finger angle estimation from array EMG system using linear regression model with independent component analysis", *Frontiers in Neurorobotics*, vol. 13, p. 75, Sep. 2019, doi: 10.3389/FNBOT.2019.00075/BIBTEX.

174. J. Liu, Y. Ren, D. Xu, S. H. Kang, and L. Q. Zhang, "EMG-Based Real-Time Linear-Nonlinear Cascade Regression Decoding of Shoulder, Elbow, and Wrist Movements in Able-Bodied Persons and Stroke Survivors", *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 5, pp. 1272–1281, May 2020, doi: 10.1109/TBME.2019.2935182.

175. G. Hajian and E. Morin, "Deep Multi-Scale Fusion of Convolutional Neural Networks for EMG-Based Movement Estimation", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 486–495, 2022, doi: 10.1109/TNSRE.2022.3153252.

176. H. Su, W. Qi, Z. Li, Z. Chen, G. Ferrigno, and E. De Momi, "Deep Neural Network Approach in EMG-Based Force Estimation for Human-Robot Interaction", *IEEE Transactions on Artificial Intelligence*, vol. 2, no. 5, pp. 404–412, Oct. 2021, doi: 10.1109/TAI.2021.3066565.

177. W. Yang, D. Yang, Y. Liu, and H. Liu, "Decoding Simultaneous Multi-DOF Wrist Movements from Raw EMG Signals Using a Convolutional Neural Network", *IEEE Transactions on Human-Machine Systems*, vol. 49, no. 5, pp. 411–420, Oct. 2019, doi: 10.1109/THMS.2019.2925191.

178. S. Zhou, K. Yin, F. Fei, and K. Zhang, "Surface electromyography-based hand movement recognition using the Gaussian mixture model, multilayer perceptron, and AdaBoost method", *International Journal of Distributed Sensor Networks*, vol. 15, no. 4, pp.1-13, Apr. 2019, doi: 10.1177/1550147719846060.

179. J. G. Colli-Alfaro, A. Ibrahim, and A. L. Trejos, "Design of user-independent hand gesture recognition using multilayer perceptron networks and sensor fusion techniques", *Proceeding of IEEE International Conference on Rehabilitation Robotics, 2019*, pp. 1103–1108, Jun. 2019,

doi: 10.1109/ICORR.2019.8779533.

180. E. Nsugbe, C. Phillips, M. Fraser, and J. McIntosh, "Gesture recognition for transhumeral prosthesis control using EMG and NIR", *IET Cyber-Systems and Robotics*, vol. 2, no. 3, pp. 122–131, Sep. 2020, doi: 10.1049/IET-CSR.2020.0008.

181. M. Jabbari, R. N. Khushaba, and K. Nazarpour, "EMG-Based Hand Gesture Classification with Long Short-Term Memory Deep Recurrent Neural Networks", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 3302–3305, Jul. 2020, doi: 10.1109/EMBC44109.2020.9175279.

182. K. Zhang and F. Chen, "Research on sEMG Gesture Recognition Based on Hybrid Dilated Convolutional Neural Network Combining Bidirectional Gated Recurrent Unit And Attention Mechanism", *Proceeding of 2021 China Automation Congress, CAC 2021*, pp. 3760–3763, 2021, doi: 10.1109/CAC53003.2021.9727886.

183. Z. Li, J. Zuo, Z. Han, X. Han, C. Sun, and Z. Wang, "Intelligent classification of multi-gesture EMG signals based on LSTM", *Proceedings of International Conference on Artificial Intelligence and Electromechanical Automation, AIEA 2020*, pp. 62–65, Jun. 2020, doi: 10.1109/AIEA51086.2020.00020.

184. H. Han, "Residual Learning Based CNN for Gesture Recognition in Robot Interaction", *Journal of Information Processing Systems*, vol. 17, no. 2, pp. 385–398, Apr. 2021, doi: 10.3745/JIPS.01.0072.

185. A. K. Mukhopadhyay and S. Samui, "An experimental study on upper limb position invariant EMG signal classification based on deep neural network", *Biomedical Signal Processing and Control*, vol. 55, p. 101669, Jan. 2020, doi: 10.1016/J.BSPC.2019.101669.

186. A. R. Asif et al., "Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG", *Sensors*, vol. 20, no. 6, p. 1642, Mar. 2020, doi: 10.3390/S20061642.

187. A. Toro-Ossaba, J. Jaramillo-Tigreros, 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, no. 19, p. 9700, Sep. 2022, doi: 10.3390/APP12199700.

188. M. Simão, P. Neto, and O. Gibaru, "EMG-based online classification of gestures with recurrent neural networks", *Pattern Recognition Letters*, vol. 128, pp. 45–51, Dec. 2019, doi: 10.1016/J.PATREC.2019.07.021.

189. J. Luo, C. Liu, and C. Yang, "Estimation of EMG-Based force using a neural-network-based approach", *IEEE Access*, vol. 7, pp. 64856–64865, 2019, doi: 10.1109/ACCESS.2019.2917300.

190. Z. Lei, "An upper limb movement estimation from electromyography by using BP neural network", *Biomedical Signal Processing and Control*, vol. 49, pp. 434–439, Mar. 2019, doi: 10.1016/J.BSPC.2018.12.020.

191. X. Chen, Y. Li, R. Hu, X. Zhang, and X. Chen, "Hand Gesture Recognition based on Surface Electromyography using Convolutional Neural Network with Transfer Learning Method", *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 4, pp. 1292–1304, Apr. 2021, doi: 10.1109/JBHI.2020.3009383.

192. K. T. Kim, C. Guan, and S. W. Lee, "A Subject-Transfer Framework Based on Single-Trial EMG Analysis Using Convolutional Neural Networks", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, no. 1, pp. 94–103, Jan. 2020, doi: 10.1109/TNSRE.2019.2946625.

193. Z. Yu, J. Zhao, Y. Wang, L. He, and S. Wang, "Surface EMG-Based Instantaneous Hand Gesture Recognition Using Convolutional Neural Network with the Transfer Learning Method", *Sensors*, vol. 21, no. 7, p. 2540, Apr. 2021, doi: 10.3390/S21072540.

194. Y. Yamanoi, Y. Ogiri, and R. Kato, "EMG-based posture classification using a convolutional neural network for a myoelectric hand", *Biomedical Signal Processing and Control*, vol. 55, p. 101574, Jan. 2020, doi: 10.1016/J.BSPC.2019.101574.

195. T. Bao, A. Zaidi, S. Xie, and Z. Zhang, "Surface-EMG based wrist kinematics estimation using convolutional neural network", *Proceeding of IEEE 16th*

International Conference on Wearable and Implantable Body Sensor Networks, BSN 2019, Chicago, IL, USA, 2019, pp. 1-4, May 2019, doi: 10.1109/BSN.2019.8771100.

196. J. Chen, S. Bi, G. Zhang, and G. Cao, "High-Density Surface EMG-Based Gesture Recognition Using a 3D Convolutional Neural Network", *Sensors*, vol. 20, no. 4, p. 1201, Feb. 2020, doi: 10.3390/S20041201.

197. O. Kerdjidj, K. Amara, F. Harizi, and H. Boumridja, "Implementing Hand Gesture Recognition using EMG on the Zynq Circuit", *IEEE Sensors Journal*, vol. 23, no. 9, pp. 10054-10061, May 2023, doi: 10.1109/JSEN.2023.3259150.

198. F. Medina, K. Perez, D. Cruz-Ortiz, M. Ballesteros, and I. Chairez, "Control of a hybrid upper-limb orthosis device based on a data-driven artificial neural network classifier of electromyography signals", *Biomedical Signal Processing and Control*, vol. 68, p. 102624, Jul. 2021, doi: 10.1016/J.BSPC.2021.102624.

199. K. Maksymenko, A. K. Clarke, I. Mendez Guerra, S. Deslauriers-Gauthier, and D. Farina, "A myoelectric digital twin for fast and realistic modelling in deep learning", *Nature Communications*, vol. 14, no. 1, pp. 1–15, Mar. 2023, doi: 10.1038/s41467-023-37238-w.

200. 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, Jan. 2022, doi: 10.1016/J.NEUCOM.2021.10.104.

201. 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, Jan. 2022, doi: 10.1016/J.NEUCOM.2021.10.104.

202. E. Tyacke et al., "Hand Gesture Recognition via Transient sEMG Using Transfer Learning of Dilated Efficient CapsNet: Towards Generalization for Neurorobotics", *IEEE Robotics and Automation Letters*, vol. 7, no. 4, pp. 9216–9223, Oct. 2022, doi: 10.1109/LRA.2022.3191238.

203. H. T. Darch, N. L. Cerminara, I. D. Gilchrist, and R. Apps, "Pre-movement changes in sensorimotor beta oscillations predict motor adaptation drive", *Scientific Reports*, vol. 10, no. 1, pp. 1–12, Oct. 2020, doi: 10.1038/s41598-020-74833-z.

204. Z. Liu, "Research on the Possibility of Smart Wearable Devices in Ice and Snow Sports Based on Wireless Network", *Wireless Communications and Mobile Computing*, vol. 2022, pp.1-15, 2022, doi: 10.1155/2022/6235607.

205. Z. Han, Q. Tao, Q. Lai, and L. Liu, "Multi-gesture recognition method of single-channel EMG signal based on deep learning", *Proceedings of International Conference on Cyber-Physical Social Intelligence, ICCSI 2021, Beijing, China*, pp. 1-8, 2021, doi: 10.1109/ICCSI53130.2021.9736226.

206. Y. Liu et al., "Wrist angle prediction under different loads based on GA-ELM neural network and surface electromyography", *Concurrency and Computation*, vol. 34, no. 3, pp. 1-19, Feb. 2022, doi: 10.1002/CPE.6574.

207. G. Anitha, R. T. Prabu, P. Nirmala, G. Ramya, and G. Ramkumar, "An Artificial Neural Network Classifier for palm Motion categorization based on EMG signal", *Proceedings of the 2022 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2022, Chennai, India*, pp. 1-11, 2022, doi: 10.1109/ICSES55317.2022.9914097.

208. K. Radouane, A. Tchechmedjiev, B. Xu, and S. Harispe, "Comparison of Deep Learning Approaches for Protective Behaviour Detection under Class Imbalance from MoCap and EMG data", *Proceedings of the 2021 9th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos, ACIIW 2021, Nara, Japan*, pp. 01-08, 2021, doi:10.1109/ACIIW52867.2021.9666417.

209. W. Gao, S. Guo, and D. Bu, "Convolution Neural Network (CNN)-based Upper Limb Action Recognition", *Proceedings of the 2020 IEEE International Conference on Mechatronics and Automation, ICMA 2020*, pp. 1576–1580, Oct.2020, doi: 10.1109/ICMA49215.2020.9233594.

210. 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, no. 10, p. 1681, Oct. 2022, doi: 10.3390/MI13101681.

211. N. Parajuli et al., "Real-Time EMG Based Pattern Recognition Control for Hand Prostheses: A Review on Existing Methods, Challenges and Future

Implementation", *Sensors*, vol. 19, no. 20, p. 4596, Oct. 2019, doi: 10.3390/S19204596.

212. A. S. Dovbysh, M. M. Budnyk, V. Y. Piatachenko, and M. I. Myronenko, "Information-Extreme Machine Learning of On-Board Vehicle Recognition System", *Cybernetics and Systems Analysis*, vol. 56, no. 4, pp. 534–543, Jul. 2020, doi: 10.1007/S10559-020-00269-Y.

213. A. S. Dovbysh, V. V. Moskalenko, and A. S. Rizhova, "Information-Extreme Method for Classification of Observations with Categorical Attributes", *Cybernetics and Systems Analysis*, vol. 52, no. 2, pp. 224–231, 2016, doi: 10.1007/s10559-016-9818-1.

214. A. Dovbysh, V. Liubchak, I. Shelehov, J. Simonovskiy, and A. Tenytska, "Information-extreme machine learning of a cyber attack detection system", *Radioelectronic and Computer Systems*, no. 3, pp. 121–131, Sep. 2022, doi: 10.32620/reks.2022.3.09.

215. A. S. Dovbysh, S. S. Martynenko, A. S. Kovalenko, and N. N. Budnyk, "Information-extreme Algorithm for Recognizing Current Distribution Maps in Magnetocardiography", *Journal of Automation and Information Sciences*, vol. 43, no.2, pp. 63–70, 2011, doi: 10.1615/JAUTOMATINFSCIEN.V43.I2.60.

216. A. Korobov, A. Moskalenko, V. Nahorny, J. Zavgorodnya, O. Berest, and V. Zhurba, "Parameters optimization method of the information-extreme object recognition system on the terrain", *Proceeding of the 2018 IEEE 1st International Conference on System Analysis and Intelligent Computing, SAIC 2018, Kyiv, Ukraine*, pp. 1-5, Oct. 2018, doi: 10.1109/SAIC.2018.8516771.

217. А. С. Довбиш, В. В. Москаленко, та В. Ю. П'ятаченко, "Інформаційно-екстремальне машинне навчання системи керування протезом руки", *Радіоелектронні і комп'ютерні системи*, vol. 4, no. 84, pp. 40–49, 2017.

218. I. Naumenko, M. Myronenko and V. Piatachenko, "Information-Extreme Learning of On-Board System for Recognition of Ground Vehicles". *Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019) Zaporizhzhia, Ukraine, April 15-19, 2019*, pp. 121-132, 2019.

219. A. S. Dovbysh, M. N. Budnyk, V. Yu. Piatachenko and M. I. Myronenko, "Information-Extreme Machine Learning of On-Board Vehicle Recognition System", *Cybernetics and Systems Analysis*, 56(4), p. 534-543, 2020, doi: 10.1007/s10559-020-00269-y.

220. Shelehov, I. V., Barchenko, N. L., Prylepa, D. V., & Bibyk, M. V., "INFORMATION-EXTREME MACHINE TRAINING SYSTEM OF FUNCTIONAL DIAGNOSIS SYSTEM WITH HIERARCHICAL DATA STRUCTURE", *Radio Electronics, Computer Science, Control*, no. 2, pp. 189–189, Jul. 2022, doi: 10.15588/1607-3274-2022-18.

221. V. Moskalenko, M. Zaretskyi, A. Moskalenko, and V. Lysyuk, "Sewer pipe defects classification based on deep convolutional network with information-extreme error-correction decision rules", *Communications in Computer and Information Science, Springer Science and Business Media Deutschland GmbH*, Aug. 2020, pp. 253–263. doi: 10.1007/978-3-030-61656-4_16.

222. A. Dovbysh, D. Velykodnyi, I. Shelehov, and M. Bibyk, "Information-extreme machine learning of the control system over the power unit of a thermal power main line", *Eastern-European Journal of Enterprise Technologies*, vol. 5, no. 4, pp. 17–24, 2017, doi: 10.15587/1729-4061.2017.112121.

223. V. Moskalenko, A. Moskalenko, Z. Nikolay, and V. Lysyuk, "Deep feature extractor with information-extreme decision rules for visual classification of sewer pipe defects and its training method", *Proceedings of the 2020 IEEE 3rd International Conference on Data Stream Mining and Processing, DSMP 2020, Institute of Electrical and Electronics Engineers Inc.*, Aug. 2020, pp. 191–194. doi: 10.1109/DSMP47368.2020.9204083.

224. A. Dovbysh, I. Naumenko, M. Myronenko, and T. Savchenko, "Information-extreme machine learning on-board recognition system of ground objects with the adaptation of the input mathematical description", *Proceedings of The Third International Workshop Computer Modeling and Intelligent Systems (CMIS-2020)*, vol. 2608, pp. 913–925, 2020.

225. A. S. Dovbysh, V. Y. Piatachenko, J. V. Simonovskiy, and O.A.Shkuropat, "INFORMATION-EXTREME HIERARCHICAL MACHINE

LEARNING OF THE HAND BRUSH PROSTHESIS CONTROL SYSTEM WITH A NON-INVASIVE BIO SIGNAL READING SYSTEM", *Radio Electronics, Computer Science, Control*, no. 4, pp. 178–187, Dec. 2020, doi: 10.15588/1607-3274-2020-4-17.

226. A. Dovbysh and V. Piatachenko, "Hierarchical Clustering Approach for Information-Extreme Machine Learning of Hand Brush Prosthesis", *Proceedings of the 5th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2021)*, pp. 1706–1715, 2021.

227. A. Jaramillo-Yáñez, M. E. Benalcázar, and E. Mena-Maldonado, "Real-Time Hand Gesture Recognition Using Surface Electromyography and Machine Learning: A Systematic Literature Review", *Sensors*, vol. 20, no. 9, p. 2467, Apr. 2020, doi: 10.3390/S20092467.

228. I. M. Khairuddin, S. N. Sidek, A. P. P. A. Majeed, M. A. M. Razman, A. A. Puzi, and H. M. Yusof, "The classification of movement intention through machine learning models: the identification of significant time-domain EMG features", *PeerJ Computer Science*, vol. 7, pp. 1–15, Feb. 2021, doi: 10.7717/PEERJ-CS.379/SUPP-2.

229. V. V. Avramenko, I. V. Shelehov, and M. O. Zaretsky, "RAPID RECOGNITION OF REFERENCE SIGNAL DURING ITS DISTORTION BY NONLINEAR OBJECTS WITH EXPONENTIAL STATIC CHARACTERISTIC", *Radio Electronics, Computer Science, Control*, no. 1, pp. 50-55, May 2017, doi: 10.15588/1607-3274-2017-1-6.

230. V. Moskalenko, A. Moskalenko, A. Korobov, O. Boiko, S. Martynenko, and O. Borovenskyi, "Model and Training Methods of Autonomous Navigation System for Compact Drones", *Proceedings of the 2018 IEEE 2nd International Conference on Data Stream Mining and Processing, DSMP 2018*, pp. 503–508, Oct. 2018, doi: 10.1109/DSMP.2018.8478521.

231. K. Taha, "Methods that optimize multi-objective problems: A survey and experimental evaluation", *IEEE Access*, vol. 8, pp. 80855–80878, 2020, doi: 10.1109/ACCESS.2020.2989219.

232. O. Protsenko, T. Savchenko, M. Myronenko, and O. Prikhodchenko, "Informational and extreme machine learning for onboard recognition system of ground objects", *Proceedings of 2020 IEEE 11th International Conference on Dependable Systems, Services and Technologies, DESSERT 2020*, pp. 213–218, May 2020, doi: 10.1109/DESSERT50317.2020.9125025.

233. А. С. Довбиш, Основи проектування інтелектуальних систем. *Видавництво СумДУ*, 2009 – 171 с. ISBN 978-966-657-225-0.

234. А. С. Довбиш, В. І. Зимовець, та М. В. Бібик, "Оптимізація ієрархічної структури даних інтелектуальної системи функціонального діагностування технічного стану складної машини". *Вісник Національного технічного університету «ХПІ»*. Серія: Системний аналіз, управління та інформаційні технології, №44, сс.42–49, 2018, doi: 10.20998/2079-0023.2018.44.08.

235. M. K. Suprunenko, O. P. Zborshchuk, and O. Sokolov, "Information-Extreme Machine Learning of Wrist Prosthesis Control System Based on the Sparse Training Matrix", *Journal of Engineering Sciences*, vol. 9, no. 2, pp. 28–35, 2022, doi: 10.21272/JES.2022.9(2).E4.

236. В. Ю. П'ятаченко and А. С. Довбиш, "Інформаційно-екстремальне машинне навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів за розрідженою навчальною матрицею", *Вісник Кременчуцького національного університету імені Михайла Остроградського*, № 2(139), сс. 57–65, 2023.

237. V. V. Moskalenko and A. G. Korobov, "INFORMATION-EXTREME ALGORITHM OF THE SYSTEM FOR RECOGNITION OF OBJECTS ON THE TERRAIN WITH OPTIMIZATION PARAMETER FEATURE EXTRACTOR", *Radio Electronics, Computer Science, Control*, no. 2, pp. 61–69, Nov. 2017, doi: 10.15588/1607-3274-2017-2-7.

238. A. E. Olsson, P. Sager, E. Andersson, A. Björkman, N. Malešević, and C. Antfolk, "Extraction of Multi-Labelled Movement Information from the Raw HD-sEMG Image with Time-Domain Depth", *Scientific Reports*, vol. 9, no. 1, pp. 1–10, 2019, doi: 10.1038/s41598-019-43676-8.

239. J. M. Fajardo, O. Gomez, and F. Prieto, "EMG hand gesture classification using handcrafted and deep features", *Biomedical Signal Processing and Control*, vol. 63, p. 102210, Jan. 2021, doi: 10.1016/j.bspc.2020.102210.
240. M. Simão, P. Neto, and O. Gibaru, "EMG-based online classification of gestures with recurrent neural networks", *Pattern Recognition Letters*, vol. 128, pp. 45–51, Dec. 2019, doi: 10.1016/j.patrec.2019.07.021.
241. G. Huang, Z. Xian, Z. Zhang, S. Li, and X. Zhu, "Divide-and-conquer muscle synergies: A new feature space decomposition approach for simultaneous multifunction myoelectric control", *Biomedical Signal Processing and Control*, vol. 44, pp. 209–220, 2018, doi: 10.1016/j.bspc.2018.04.011.
242. V. Asanza, E. Pelaez, F. Loayza, I. Mesa, J. Diaz, and E. Valarezo, "EMG Signal Processing with Clustering Algorithms for motor gesture Tasks", *Processing of 2018 IEEE 3rd Ecuador Technical Chapters Meeting, ETCM 2018, Institute of Electrical and Electronics Engineers Inc., Cuenca, Ecuador, 2018*, pp. 1-6, Dec. 2018, doi: 10.1109/ETCM.2018.8580270.
243. A. Joshi, S. Ghosh, M. Betke, S. Sclaroff, and H. Pfister, "Personalizing Gesture Recognition Using Hierarchical Bayesian Neural Networks", *Processing of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017*, pp. 455-464, 2017, doi: 10.1109/CVPR.2017.56.
244. V. Agostini, S. Rosati, C. Castagneri, G. Balestra, and M. Knaflitz, "Clustering analysis of EMG cyclic patterns: A validation study across multiple locomotion pathologies", *Processing of 2017 IEEE International Instrumentation and Measurement Technology Conference, Proceedings, Institute of Electrical and Electronics Engineers Inc., Turin, Italy, 2017*, pp. 1-5, Jul. 2017, doi: 10.1109/I2MTC.2017.7969746.
245. F. Murtagh and P. Contreras, "Algorithms for hierarchical clustering: an overview, II", *WIREs Data Mining and Knowledge Discovery*, vol. 7, no. 6, pp.1-16, Nov. 2017, doi: 10.1002/widm.1219.
246. V. Cohen-Addad, V. Kanade, F. Mallmann-Trenn, and C. Mathieu, "Hierarchical clustering: Objective functions and algorithms", *Journal of the ACM*, vol. 66, no. 4, pp. 1–42, Jun. 2019, doi: 10.1145/3321386.

247. C. Sapsanis, A. Tzes, and G. Georgoulas, "sEMG for basic hand movements data set", *UCI Machine Learning Repository*, 2014.

248. M. Ozkaya and I. Fidandan, "MVCLang: A software modeling language for the model-View-Controller design pattern", *Proceedings of the 15th International Conference on Software Technologies (ICSOFT 2020)*, pp. 75–83, 2020, doi: 10.5220/0009571400750083.

249. V. Sarcar, "Memento Pattern", *Java Design Patterns. Apress, Berkeley, CA*, pp. 435–454, 2022, doi: 10.1007/978-1-4842-7971-7_20.

250. M. Atzori, M. Cognolato, and H. Müller, "Deep learning with convolutional neural networks applied to electromyography data: A resource for the classification of movements for prosthetic hands", *Frontiers in Neurorobotics*, vol. 10, pp. 1–10, 2016, doi: 10.3389/fnbot.2016.00009.

251. N. Nahid, A. Rahman, and M. A. R. Ahad, "Deep Learning Based Surface EMG Hand Gesture Classification for Low-Cost Myoelectric Prosthetic Hand", *Proceeding of 9th International Conference on Informatics, Electronics and Vision and 2020 4th International Conference on Imaging, Vision and Pattern Recognition, ICIEV and icIVPR 2020, Kitakyushu, Japan, 2020*, pp. 1-8, Aug. 2020, doi: 10.1109/ICIEVICIVPR48672.2020.9306613.

252. R. B. Azhiri, M. Esmaili, and M. Nourani, "Real-Time EMG Signal Classification via Recurrent Neural Networks", *Proceedings of the 2021 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2021*, pp. 2628–2635, 2021, doi: 10.1109/BIBM52615.2021.9669872.

253. M. Jabbari, R. N. Khushaba, and K. Nazarpour, "EMG-Based Hand Gesture Classification with Long Short-Term Memory Deep Recurrent Neural Networks", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, vol. 2020, pp. 3302–3305, Jul. 2020, doi: 10.1109/EMBC44109.2020.9175279.

254. E. Rahimian, S. Zabihi, S. F. Atashzar, A. Asif, and A. Mohammadi, "Surface EMG-Based Hand Gesture Recognition via Hybrid and Dilated Deep Neural Network Architectures for Neurobotic Prostheses", *Journal of Medical Robotics Research*, vol. 05, no.1, pp.1-12, Jan. 2020, doi: 10.1142/S2424905X20410019.

ДОДАТОК А Акти впровадження

ЗАТВЕРДЖУЮ

Перший проректор Сумського
державного університету

Сергій ЛСОНОВ

29 грудня 2023 р.

АКТ

впровадження результатів дисертаційної роботи у навчальний процес

«Моделі та методи інформаційної технології розпізнавання системою керування протезом кінцівки руки електроміографічних біосигналів».

У ході виконання дисертаційної роботи розроблено моделі, методи, алгоритми і програмне забезпечення системи підтримки прийняття рішень (СППР) для розпізнавання рухів кінцівки руки за електроміографічними біосигналами.

Здобувач наукового ступеня кандидата технічних наук П'ятаченко Владислав Юрійович.

Комісія в складі:

Голова комісії: голова ради з якості факультету
електроніки та інформаційних технологій

Ірина ПАЗУХА

Члени комісії:
заступник декана факультету електроніки
та інформаційних технологій, к.ф.-м.н, доцент

Тарас ЛЮТИЙ

в.о. завідувача кафедри комп'ютерних наук,
к.т.н., доцент

Ігор ШЕЛЕХОВ

заступник завідувача кафедри
комп'ютерних наук, к.ф.-м.н., ст. викладач

Оксана ШОВКОПЛЯС

Встановила, що результати дисертаційної роботи використовуються в навчальному процесі за освітньо-науковою програмою «Інформатика» спеціальності 122 – Комп'ютерні науки другого (магістерського) рівня, шляхом реалізації наступного:

- 1) наукові результати використано при написанні підрозділу «Інформаційно-екстремальне машинне навчання з оптимізацією рівня квантування в часі вхідного сигналу» в навчальному посібнику «Основи проектування інтелектуальних систем».
- 2) розроблено інформаційне та програмне забезпечення віртуального тренажеру для проведення лабораторних робіт з навчальної дисципліни «Основи проектування інтелектуальних систем».

Голова комісії: _____

Ірина ПАЗУХА

Члени комісії: _____

Тарас ЛЮТИЙ

Ігор ШЕЛЕХОВ

Оксана ШОВКОПЛЯС



Товариство з обмеженою відповідальністю
«Науково-виробниче підприємство
«М Е Т Е К О Л»

16604, Чернігівська обл., м. Ніжин, вул. Незалежності, 13. Тел/факс: (04631) 7-56-32
E-mail: metecol@epsilon.com.ua Код ЄДРПОУ 14234523

Вих. № 42
від 31.07.2023 р.

В Сумський державний університет
м. Суми, вул. Харківська 116

ЗАТВЕРДЖУЮ
Директор НВП «МЕТЕКОН»
Микола ВЕРБНИЙ
“31” липня 2023 року

АКТ

**використання наукових результатів дисертаційної роботи
П'ятаченка Владислава Юрійовича
на тему «Моделі та методи інформаційної технології розпізнавання системою керування
протезом кінцівки руки електроміографічних біосигналів», представленої на здобуття
наукового ступеня доктора філософії за спеціальністю 122 – комп'ютерні науки**

Складений 31 липня 2023 року комісією у складі: голова комісії – заступник директора з науки, голова Науково-технічної ради, доктор технічних наук Микола БУДНИК, члени комісії: заступник директора з якості та перспективних розробок, секретар Науково-технічної ради Валерій БЕРСЕНЬОВ, технічний директор Віктор МЄШКОВ.

У період з 26 липня по 28 липня 2023 року комісія розглянула наукові результати представленої на здобуття наукового ступеню доктора філософії за спеціальністю 122 – комп'ютерні науки дисертаційної роботи П'ятаченка Владислава Юрійовича на тему «Моделі та методи інформаційної технології розпізнавання системою керування протезом кінцівки руки електроміографічних біосигналів», виконану на кафедрі комп'ютерних наук Сумського державного університету.

Комісія встановила:

1. На основі одержаних при виконанні дисертаційної роботи наукових результатів та засобів інформаційної технології розроблено пропозиції щодо включення у план дослідно-конструкторських робіт ТОВ «НВП «Метекол» створення інтелектуального протезу кисті руки з використанням розробленого методу інформаційно-екстремального машинного навчання системи керування протезом для розпізнавання електроміографічних біосигналів когнітивних команд на виконання відповідних рухів. Крім того, розроблена методика ієрархічного машинного навчання була використана під час розроблення загальних вимог для тренажера безпілотного авіаційного комплексу.


Голова комісії: заступник директора з науки

 Микола БУДНИК

Члени комісії: заступник директора з якості
та перспективних розробок

 Валерій БЕРСЕНЬОВ

технічний директор

 Віктор МЄШКОВ

ДОДАТОК Б Список публікацій за темою дисертації

Наукові праці, в яких опубліковано основні наукові результати дисертації:

[1] А. С. Довбиш, В. В. Москаленко та В. Ю. П'ятаченко, "Інформаційно екстремальне машинне навчання системи керування протезом руки", *Радіоелектронні і комп'ютерні системи*, №4, С. 40-49, 2017. (Особистий внесок: функціональна категорійна модель, вхідний математичний опис та алгоритм машинного навчання системи керування протезом кінцівки руки).

[2] A. S. Dovbysh, V. Y. Piatachenko, J. V. Simonovskiy and O. A. Shkuropat, "Information-extreme hierarchical machine learning of the hand brush prosthesis control system with a non-invasive bio signal reading system", *Radio Electronics, Computer Science, Control*, vol. 4, pp. 178–187, 2020. DOI:10.15588/1607-3274-2020-4-17 (Особистий внесок: функціональна категорійна модель, алгоритм машинного навчання та його програмна реалізація).

[3] A. S. Dovbysh, M. N. Budnyk, V. Yu. Piatachenko and M. I. Myronenko, "Information-Extreme Machine Learning of On-Board Vehicle Recognition System", *Cybernetics and Systems Analysis*, 56(4), pp. 534-543, 2020. DOI: 10.1007/s10559-020-00269-y. (Особистий внесок: алгоритм машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та його програмна реалізація)

[4] В. Ю. П'ятаченко, А. С. Довбиш. "Інформаційно-екстремальне машинне навчання системи керування протезом кінцівки руки для розпізнавання електроміографічних біосигналів за розрідженою навчальною матрицею". *Вісник Кременчуцького національного університету імені Михайла Остроградського*. – Кременчук: КрНУ, №2(139), с. 57–65, 2023. (Особистий внесок: функціональна категорійна модель, алгоритм інформаційно-екстремального машинного навчання системи керування алгоритм з оптимізацією рівня квантування електроміографічних біосигналів і його програмна реалізація).

Опубліковані праці апробаційного характеру:

[5] А. С. Довбиш, В. Ю. П'ятаченко. “Інтелектуальний протез кінцівки руки з неінвазивною системою зчитування біосигналів”. Четверта міжнародна наукова конференція «Вимірювання, контроль та діагностика в технічних системах», 31 жовтня – 2 листопада 2017 р. Збірник тез доповідей. – Вінниця: ПП «ТД «Едельвейс і К», 2017. – С. 206–207. (Особистий внесок: алгоритм машинного навчання системи керування протезом кісті руки для розпізнавання електроміографічних біосигналів).

[6] J. Simonovskiy, V. Piatachenko and N. Mironenko, “On-board Geographic Information System of Images’ Identification”. Proceeding of the VIth International Conference «Advanced Information Systems and Technologies, AIST 2018» 16-18 May 2018, Sumy, Ukraine, 2018, pp. 115-118. (Особистий внесок: алгоритм машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання).

[7] I. Naumenko, M. Myronenko and V. Piatachenko, “Information-Extreme Learning of On-Board System for Recognition of Ground Vehicles”. Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019) Zaporizhzhia, Ukraine, April 15-19, 2019, pp. 121-132. (Особистий внесок: алгоритм машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та його програмна реалізація).

[8] В.Ю. П'ятаченко, Ю.В. Симоновський, “Інформаційно-екстремальне машинне навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів”. Збірник тез доповідей VI Міжнародної науково-технічної Internet-конференції «Сучасні методи, інформаційне, програмне та технічне забезпечення систем керування організаційно-технічними та технологічними комплексами», м.Київ, Україна, 20 листопада 2019, 2019. – С. 169 – 170. (Особистий внесок: функціональна категорійна модель ієрархічного інформаційно-екстремального машинного навчання).

[9] A. Dovbysh and V. Piatachenko, “Hierarchical Clustering Approach for Information-Extreme Machine Learning of Hand Brush Prosthesis”. Proceedings of the 5th International Conference on Computational Linguistics and Intelligent Systems

(COLINS 2021) 2021, pp. 1706-1715. (Особистий внесок: функціональна категорійна модель і алгоритм машинного навчання системи розпізнавання електроміографічних біосигналів).

[10] В. П'ятаченко, “Агломеративне ієрархічне машинне навчання системи керування протезом кінцівки руки”. Збірник тез доповідей III Міжнародної науково-практичної конференції «Спільні дії військових формувань і правоохоронних органів держави: проблеми та перспективи», м. Одеса, Україна, 22 жовтня 2021 року, 2021. – С. 281-282.

[11] В. П'ятаченко, “Ієрархічна кластеризація біосигналів в процесі машинного навчання системи керування інтелектуальним протезом кінцівки руки”, Збірник тез доповідей XXI Міжнародна науково-технічна конференція Штучний Інтелект та Інтелектуальні Системи (AIPS'2021), м. Київ, Україна, 26-27 листопада 2021 року, 2021. – С. 100-103.

[12] I. Naumenko, V. Piatachenko, M. Myronenko, T. Savchenko, “Information-Extreme Machine Learning of an On-board Ground Object Recognition System with a Choice of a Base Recognition Class”, CEUR Workshop Proceedings of 6th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2022), Gliwice, Poland, May 12-13, 2022, 2022, pp. 1139–1148. (Особистий внесок: функціональна категорійна модель машинного навчання з визначенням базового класу розпізнавання).

Наукові праці, які додатково відображають наукові результати дисертаційної роботи

[13] Свідоцтво про реєстрацію авторського права на твір «Комп'ютерна програма «Програма формування вхідного математичного опису бортової системи розпізнавання наземних малогабаритних транспортних засобів» №88975 Україна / Довбиш А. С., П'ятаченко В.Ю., Мироненко М.І.; СумДУ; дата реєстрації 27.05.2019. (Особистий внесок: алгоритм формування вхідної навчальної матриці та його програмна реалізація).

[14] Свідоцтво про реєстрацію авторського права на твір «Комп'ютерна програма «Інформаційно-екстремальне машинне навчання системи діагностування онкопатологій за зображенням морфології тканини»

№100201 Україна / Довбиш А.С., Романюк А.М., Москаленко Р.А., П'ятаченко В.Ю.; СумДУ; дата реєстрації 05.10.2020. (Особистий внесок: алгоритм і його програмна реалізація для інформаційно-екстремального машинного навчання з паралельно-послідовною оптимізацією контрольних допусків).

[15] Свідоцтво про реєстрацію авторського права на твір «Комп'ютерна програма «Ієрархічне машинне навчання системи керування протезом кінцівки руки з неінвазивним зчитуванням біосигналів» №107707 Україна / Довбиш А.С., Шелехов І.В., П'ятаченко В.Ю.; СумДУ; дата реєстрації 01.09.2021. (Особистий внесок: алгоритм двохкласового інформаційно-екстремального машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та його програмна реалізація).