Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп’ютерної інженерії та управління
(повна назва)
Кафедра Комп'ютерних інтелектуальних технологій та систем
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)
Гібридна нейро-нечітка мережа для діагностики психічних захворювань
(тема)

Виконав:
здобувач II року навчання,
групи КІТм-23-1
Дараган Д. М.
(прізвище, ініціали)

Спеціальність 123 Комп’ютерна інженерія
(код і повна назва спеціальності)
Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)
Освітня програма Комп'ютерна інженерія
(повна назва освітньої програми)

Керівник проф. каф. КІТС Корабльов М. М.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____ Руденко О. Г.
(підпис) (прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет	Комп’ютерної інженерії та управління
Кафедра	Комп’ютерних інтелектуальних технологій та систем
Рівень вищої освіти	перший (бакалаврський)
Спеціальність	123 Комп’ютерна інженерія
Тип програми	освітньо-професійна
Освітня програма	Комп’ютерна інженерія

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
«_____»_____202_ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачуві Дарагану Дмитру Миколайовичу
(прізвище, ім’я, по батькові)

1. Тема роботи Гібридна нейро-нечітка мережа для діагностики психічних захворювань

затверджена наказом по університету від “ 28 ” жовтня 2024 р. № 1156Ст

2. Термін подання студентом роботи до екзаменаційної комісії 22.01.2025

3. Вхідні дані до роботи

1) методи психодіагностики
2) методи аналізу електроенцефалограм
3) дані квантитативної електроенцефалографії хворих
4) алгоритми м’яких обчисленнь
5) середовище Jupyter Notebook

4. Перелік питань, що потрібно опрацювати в роботі

1) Аналіз предметної області і постановка задачі дослідження
2) Аналіз та вибір алгоритмів м’яких обчислень для подальшої гібридизації
3) Аналіз вхідних даних та конструювання ознак
4) Побудова гібридної нейро-нечіткої мережі для діагностики психічних захворювань
5) Проведення експериментальних порівняльних досліджень
6) Аналіз ефективності розробленої системи та окреслення перспектив її розвитку

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій Плакати – 16 арк. ф. А4

6. Консультанти розділів роботи и (п.6 включається до завдання за наявністю консультантів згідно до наказу, зазначеному у п.1)

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Видача та узгодження теми проєкту	01.09.2024	
2	Огляд стану проблеми та постановка задачі	02.09 -17.09	
3	Аналіз літератури за напрямком	18.09 - 01.10	
	кваліфікаційної роботи		
4	Аналіз алгоритмів м'яких обчислень	02.10 - 29.10	
5	Побудова гібридної нейро-нечіткої мережі для	30.10 – 26.11	
	діагностики психічних захворювань		
6	Проведення експериментальних досліджень	27.11 - 17.12	
7	Підготовка пояснювальної записки	18.12 - 07.01	
8	Підготовка графічного матеріалу	08.01 – 14.01	
9	Захист проєкту	24.01.2025	

Дата видачі завдання 23 жовтня 2024 р.

Здобувач _____
(підпис)

Керівник роботи _____ проф. Микола КОРАБЛЬОВ
(підпис) (посада, ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 102 с., 13 рис., 9 табл., 2 дод., 38 джерел.

ГІБРИДИЗАЦІЯ, НЕЧІТКА ЛОГІКА, НЕЙРО-НЕЧІТКІ МЕРЕЖІ, ANFIS, ГЕНЕТИЧНИЙ АЛГОРИТМ, ПСИХОДІАГНОСТИКА, КВАНТИТАТИВНА ЕЛЕКТРОЕНЦЕФАЛОГРАФІЯ, МАШИННЕ НАВЧАННЯ, М’ЯКІ ОБЧИСЛЕННЯ

Метою кваліфікаційної роботи є розробка гібридної нейро-нечіткої мережі для діагностування психічних захворювань шляхом аналізу даних електроенцефалограм.

Об’єктом дослідження є інтелектуальний аналіз даних квантитативних електроенцефалограм методами м’яких обчислень.

Предметом дослідження є методи м’яких обчислень, а саме нейронні мережі, нечіткі моделі та еволюційні алгоритми та шляхи їхньої гібридизації в контексті діагностики психічних захворювань.

Як результат, в роботі надано порівняльний аналіз алгоритмів м’яких обчислень та різних варіантів їхньої гібридизації, а також результатів класичних алгоритмів машинного навчання в якості еталону для розглянутої предметної області. Запропоновано гібридну нейро-нечітку мережу для вирішення актуальної в останні роки проблеми аналізу даних квантитативної електроенцефалографії. Визначено шляхи подальших досліджень та покращень запропонованої моделі.

Практичним результатом є гібридний алгоритм, що забезпечує достатню гнучкість та адаптивність для систем, що здійснюють афективний аналіз, зокрема для систем психодіагностики. Хоча за метриками точності запропоноване рішення поступається деяким класичним алгоритмам, гібридна модель демонструє надзвичайно цінну з економічної точки зору здатність адаптуватись до обмежених вхідних даних. Запропоноване в ході кваліфікаційної роботи рішення було успішно імплементоване в модифікованій формі в системі для комерційного застосування.

ABSTRACT

Master’s thesis: 102 pages, 13 figures, 9 tables, 2 appendices, 38 sources.

HYBRIDIZATION, FUZZY LOGIC, NEURO-FUZZY NETWORKS, ANFIS, GENETIC ALGORITHM, PSYCHODIAGNOSTICS, QUANTITATIVE ELECTROENCEPHALOGRAPHY, MACHINE LEARNING, SOFT COMPUTING

The purpose of this thesis is to develop a hybrid neuro-fuzzy network for mental disorders diagnosing by analyzing electroencephalography data. The object of the research is the intellectual analysis of quantitative electroencephalography data using soft computing methods. The subject of the study encompasses soft computing techniques, specifically neural networks, fuzzy models, and evolutionary algorithms, as well as their hybridization in the context of psychodiagnostics.

As a result, this paper presents a comparative analysis of soft computing algorithms and various hybridization approaches, using the efficiency of classical machine learning algorithms as a baseline. A hybrid neural-fuzzy network is proposed to address the problem quantitative EEG data of analyzing. This topic has gained significant relevance in medical research in recent years and is of considerable scientific interest. Additionally, the paper identifies potential avenues for further research and improvements to the proposed hybrid model.

The practical outcome of this research is a hybrid algorithm that offers sufficient flexibility and adaptability for systems performing affective analysis, e.g. psychodiagnostics by means of quantitative electroencephalography analysis. Although the proposed solution may be less accurate than some classical algorithms regarding accuracy metrics, the hybrid model demonstrates a valuable ability to adapt to highly variable and limited input data from an economic perspective. Furthermore, the proposed solution was successfully implemented in a modified form within a commercial system for industrial applications during the work under the master’s thesis.

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп’ютерної інженерії та управління
(повна назва)
Кафедра Комп'ютерних інтелектуальних технологій та систем
(повна назва)

АНОТАЦІЯ
Кваліфікаційної роботи

рівень вищої освіти другий (магістерський)
Гібридна нейро-нечітка мережа для діагностики психічних захворювань
(тема)

Виконав:
здобувач II року навчання,
групи КІТм-23-1
Дараган Д. М.
(прізвище, ініціали)

Спеціальність 123 Комп’ютерна інженерія
(код і повна назва спеціальності)
Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)
Освітня програма Комп'ютерна інженерія
(повна назва освітньої програми)

Керівник проф. каф. КІТС Корабльов М. М.
(посада, прізвище, ініціали)

2024 р.

АНОТАЦІЯ

Дараган Д.М. Гібридна нейро-нечітка мережа для діагностики психічних захворювань. – Магістерська кваліфікаційна робота.

У магістерській кваліфікаційній роботі вирішено актуальну задачу діагностики психічних захворювань на основі даних електроенцефалограм(ЕЕГ) за допомогою гібридних нейро-нечітких мереж

Метою кваліфікаційної роботи є розробка системи для діагностики психічних захворювань на основі аналізу даних енцефалограм, що базується на гібридних нейро-нечітких мережах.

Об’єктом дослідження є інтелектуальний аналіз даних квантитативних електроенцефалограм методами м’яких обчислень в контексті діагностики психічних захворювань.

Предметом дослідження є гібридні нейро-нечіткі мережі, які поєднують переваги штучних нейронних мереж та нечіткої логіки в контексті задачі аналізу даних ЕЕГ.

Методи дослідження. Особливості об’єкту і мета досліджень обумовлюють необхідність застосування наступних методів: аналіз, порівняння, та синтез, машинне навчання, нейронні мережі, нечітка логіка, еволюційні алгоритми, k-кратна випадкова кросвалідація.

Наукова новизна роботи полягає у дослідженні гібридного підходу на основі нечіткої логіки, нейронних мереж та еволюційного числення в контексті психодіагностики та аналізу квантитативних електроенцефалограм.

Практична цінність отриманих результатів полягає у можливості впровадження розроблених методів у система афективного аналізу та психодіагностики, найбільш очевидним застосуванням яких є клінічна практика психіатрів, психотерапевтів та неврологів. За умови тренування на відповідних даних та внесення ряду змін для специфічних задач, гібридна нейро-нечітка мережа, запропонована в роботі, може бути використана в педагогіці, криміналістиці, або

навіть в системах розумного дому та IoT(англ. Internet of Things – “інтернет речей”) для покращення взаємодії “людина-машина.

В першому розділі наведено аналіз предметної області. Детально розглянуто питання психодіагностики. Досліджено актуальність, проблеми, соціальну роль методологію та історію розвитку даної галузі.

Значення психодіагностики полягає в її здатності забезпечити точну і надійну інформацію про психічні характеристики особи, що є критично важливим для розробки ефективних стратегій лікування взаємодії та убезпечення ментального здоров’я суспільства. Серед проблем, що існують у психодіагностиці найбільш гостро стоять неоднозначність термінології, питання надійності та валідності психодіагностичних інструментів.

Основні напрями психодіагностики склалися на основі кількох ключових джерел: експериментальної психології, диференціальної психології, тестології та прикладної психології разом із психотехнікою. В результаті впровадження експериментального підходу в психології в психодіагностиці виникли апаратні методи, що передбачають використання спеціальних пристроїв для об’єктивного вимірювання психічних і фізіологічних характеристик. Сучасна апартна психодіагностика розширила свої методологічні можливості завдяки електрофізіологічним методам, таким як магніто- та електроенцефалографія, метод викликаних потенціалів, функціональна магнітно-резонансна томографія (фМРТ).

Практично електроенцефалографія являє собою метод графічної реєстрації біопотенціалів головного мозку для подальшого дослідження його фізіологічних характеристик. Результатом ЕЕГ є запис зареєстрованої хвильової біоелектричної активності мозку який називають електроенцефалограмою. Ключовим поняттям ЕЕГ є ритм, відомий також як канал, що являє собою активність хвиль приблизно однієї постійної частоти. За виразністю коливань частоти у різних фізіологічних станах виділять декілька основних фізіологічних частотних діапазонів: δ(<4 Гц), θ(4-7 Гц), α(8-13 Гц), β(13-40 Гц), γ(від 30-40 до 70-500 Гц).

Сучасним етапом розвитку ЕЕГ є квантитативна електроенцефалографія - галузь, що займається чисельним аналізом даних електроенцефалограм і

корельованих з її ритмами поведінкових паттернів. квантитативна електроенцефалографія передбачає статистичний аналіз даних для точної кількісної оцінки електричних потенціалів. Це означає перетворення безпосередніх даних ЕЕГ у більш релевантий формат, що спрощує його подальшу обробку.

Використання штучного інтелекту для аналізу сигналів квантитативної ЕЕГ стає дедалі перспективнішим з розвитком технологій, що відкривають нові можливості покращення точності та швидкості діагностики психічних розладів. Поширені традиційні алгоритми, що використовуються для класифікації ЕЕГ включають метод опорних векторів, дерева рішень, логістичну регресію, алгоритм k-найближчих сусідів та інші. Враховуючи різноманітність розглянутих в розділі існуючих рішень проблеми інтелектуального аналізу ЕЕГ, зроблено припущення, що поєднання різних підходів та використання нечіткої логіки суттєво підвищують точність і надійність інтелектуальної психодіагностики. Перспективним варіантом вирішення задачі психодіагностики на основі аналізу ЕЕГ було визначено гібридну нейро-нечітку мережу, розробці якої присв’ячено другий розділ даної кваліфікаційної роботи.

У другому розділі проведено теоретичний аналіз існуючих методів м’яких обчисленнь з метою їх подальшого застосування в гібридному рішенні. Вивчено підходи на основі нечіткої логіки, нейронних мереж та еволюційних алгоритмів. Розглянуто типові алгоритми та техніки кожного класу, проаналізовано особливості їхнього застосування, оціненно переваги та недоліки. Вивчено перспективи та шляхи їхньої гібридизації. На основі проведеного аналізу обрано конкретні алгоритми та тип гібридизації для синтезу гібридної моделі та наведено аргументації на користь такого вибору. Спроектовано кінцевий алгоритм гібридної нейро-нечіткої мережі.

Гібридизація є поєднанням різних підходів та технік, зокрема тих, що належать до парадигм м'яких обчислень, в рамках нових моделей, що поєднують сильні сторони початкових методів та мають вищу ефективність.

Нечітка логіка є способом формалізації людських міркувань є її органічний зв’язок з природною мовою. Нечіткий підхід базується на ідеї, що концепція

абсолютної істинності чи хибності є занадто обмеженою в умовах реального світу.

Нечітка логіка дозволяє системі працювати в умовах невизначеності, забезпечуючи адаптивність та гнучкість діагностики. Нечіткі моделі, у чистому вигляді мають обмежену здатність автоматично адаптуватися до нових даних і виявляти складні нелінійні залежності. нейро-нечіткі мережі, з іншого боку, здатні навчатися на основі вхідних даних, що дозволяє їм налаштовувати свої параметри автоматично та забезпечувати вищу точність і гнучкість моделювання. Нейро-нечітка гібридизація дозволяє системам поєднувати переваги обох підходів: здатність нейронних мереж до навчання та здатність нечіткої логіки працювати з неточними та неповними даними. Для діагностики психічних захворювань на основі ЕЕГ-даних, де часто доводиться мати справу з неоднозначною або неповною інформацією особливо ефективною виглядає модель ANFIS, що є різновидом штучної нейронної мережі, заснованої на моделі нечіткого виведення Такагі-Сугено.

Еволюційні обчислення є підвидом м’яких обчислень і широко застосовуються для вирішення складних оптимізаційних задач. Їхнє використання виправдане для розв’язання проблем занадто високої розмірності для оптимізації традиційними алгоритмами. До еволюційних алгоритмів належать численні підвиди, такі як генетичні алгоритми, еволюційне програмування, моделі ройового інтелекту та імунні обчислення. Тренування нейронної мереж за допомогою еволюційних алгоритмів, дозволяє ефективно оптимізувати ваги та параметри моделі, підвищуючи її точність і надійність. Наприклад, генетичні алгоритми здатні ефективно знаходити глобальні оптимуми завдяки еволюційному процесу селекції, кросинговеру та мутації, що дозволяє уникнути застрягання в локальному оптимумі, проблеми, характерної для традиційного машинного навчання.

Таким чином, для використання в кінцевій системі було обрано наступні алгоритми - нейро-нечітка мережа ANFIS, заснована на правилі нечіткого виводу Такагі-Сугено та класичний генетичний алгоритм. Було визначено переваги та недоліки такого рішення для використання в гібридній системі психодіагностики на основі даних ЕЕГ. Переваги такого варіанту полягають у здатності ANFIS обробляти нечіткі дані та виявляти складні залежності між вхідними параметрами та

більш ефективній оптимізації параметрів моделі завдяки генетичному алгоритму. Недоліком є вища обчислювальна складність системи та негарантована кінцева збіжність алгоритмів, необхідність правильного підбору гіперпараметрів всіх складових алгоритмів, що й було виявленно в ході експериментальної частини роботи. Запропонована модель спроектована на рівні підтвердження концепції, є State of the Science рішенням, а тому її вичерпна оптимізація до лімітів існуючого апаратного забезпечення та досягнення її максимальної ефективності являє інтерес для майбутніх наукових та практичних дослідженнь.

У третьому розділі проведено порівняльне експериментальне дослідження з використанням розробленої гібридної нейро-нечіктої мережі, інших гібридних підходів та її складових алгоритмів м’яких обчисленнь, а також традиційних методів машинного навчання. Було поставлено умови проведення експерименту та валідаціїї його результатів. Експериментальні результати було опрацьовано та проаналізовано поведінку, переваги та недоліки всіх тестованих підходів. Зроблено припущення про подальші покращення запропонованого рішення. Як підготовчий етап, здійснено статистичний аналіз вхідних даних та конструювання ознак при підготовці датасету до навчання моделей на ньому. В якості тренувальних даних використано датасет, зібраний в рамках дослідження ЕЕГ методами штучного інтелекту. Датасет складається з ретроспективно зібраних медичних записів, що включають показники коефіцієнта інтелекту (IQ) та дані квантитативної ЕЕГ у стані спокою від 945 суб’єктів. Параметри qEEG складаються зі значень спектральної густини та функціонального зв’язку для δ-, θ-, α-, β-, та γ-ритмів.

В ході екслоративного аналізу було виявлено незбалансованість використаного датасету та прийнято рішення в експериментальному дослідженні сфокусуватись на діагностиці шизофренії на основі даних спектральної щільності найбільш характерних для цього конкретного захворюваня каналів електроенцефалограм. Для всебічної та повної оцінки на реальних даних було протестовані такі три групи алгоритмів: гібридні системи, їхні складові частини, та класичні методи машинного навчання. В якості метрик для порівняння в поточному експерименті використано точність(англ. accuracy) та прецизійність(англ. precision),

а також продемонстровано час тренування моделей (значення часу мають лише відносний сенс, оскільки досягнення максимальної абсолютної ефективності не входить до переліку задач, також час залежеть від конкретного апаратного забезпечення, на якому проводились тести). Всі алгоритми оцінено за допомогою 5-кратної випадкової кросвалідації, зі співвідношенням випадково обраних тренувальних та тестових даних 80% та 20% на кожній ітерації. Всі експерименти проводились з використанням мови програмування Python та бібліотек sklearn, xgboost, aisp, keras/TensorFlow, pandas, PyGAD на базі середовища Jupyter Notebook, наданого платформою Kaggle.

Гібридна нейро-нечітка еволюційна система продемонструвала відносно низькі результати за точністю та прецизійністю, що вказує на необхідність подальшої оптимізації перед її використанням у клінічній практиці. Проте, система показала стабільні результати в порівнянні з чистими м’якими обчисленнями, що свідчить про її надійність у задачах класифікації та підтверджує припущення про її властивості гнучності й адаптивності, й підтверджую життєздатність концепції. Точність гібридної системи перевищила результати деяких класичних алгоритмів, що вказує на її потенціал у складних задачах. Використання еволюційних алгоритмів для оптимізації дозволяє системі знаходити кращі рішення в умовах невизначеності, коли традиційні методи не дають задовільних результатів.

Перспективи розвитку системи включають оптимізацію гіперпараметрів, інтеграцію нових архітектур нейронних мереж та правил нечіткого виводу, використання ансамблевих методів та покращення обробки даних. Адаптація алгоритму до мультимодальних даних також є пріоритетним напрямком покращеннь. Для досягнення високих стандартів, й придатності запропонованого рішення використання в для індустрії та клінічної практики, необхідно впроваджувати більш складні алгоритми м’яких обчислень.

Результати дослідженнь та розробки, проведеної в рамках магістерської кваліфікаційної роботи успішно адаптовані до використання в системі афективного аналізу в рамках комерційного проєкту для немедичного застосування відповідно до специфіки предметної області та вхідних даних Покращення запропонованого

рішення надалі відбувається в рамках розвитку проєкту за наведеними вище напрямками згідно потреб розробки.

ГІБРИДИЗАЦІЯ, НЕЧІТКА ЛОГІКА, НЕЙРО-НЕЧІТКІ МЕРЕЖІ, ANFIS, ГЕНЕТИЧНИЙ АЛГОРИТМ, ПСИХОДІАГНОСТИКА, КВАНТИТАВНА ЕЛЕКТРОЕНЦЕФАЛОГРАФІЯ, МАШИННЕ НАВЧАННЯ, М’ЯКІ ОБЧИСЛЕННЯ

Публікації здобувача за темою роботи:

1. Дараган Д. М., Сагайдачний О.М., Сердюк Н. М. Application of clonal selection principle in neural architecture search //Матеріали 12-ї Міжнародної науково-технічної конференції “Інформаційні системи та технології”. 28 листопада 2023, м. Харків, Україна

2. Дараган Д. М., Корабльов М.М. Paralleling of artificial immune networks for pattern recognition //Матеріали XVII Всеукраїнської науково-практичної WEB конференції аспірантів, студентів та молодих вчених “Комп’ютерні інтелектуальні системи та мережі”, 26 березня 2024, м. Кривий Ріг, Україна

3. Darahan D., Korablyov M. Usage of genetic algorithm for the analysis of quantitative electroencephalography in psychiatry //Proceedings of the 2nd International Scientific and Practical Conference "Innovative Solutions in Science: Balancing Theory and Practice" December 23, 2024,San Francisco, USA

Використані в роботі публікації керівника та співробітників кафедри:

1. Korablyov, Mykola & Axak, Natalia & Barkovska, Olesia & Rosinskiy, Dmytro(2019). Hybrid adaptive decision-making model based on fuzzy logic and artificial immune systems. 62-66. 10.1109/STC-CSIT.2019.8929826.

4. Korablyov, Mykola & Axak, Natalia & Soloviov, Dmytro. (2018). Hybrid Evolutionary Decision-Making Model Based on Neural Network and Immune Approaches. 1-5. 10.1109/STC-CSIT.2018.8526594.

5. Руденко О. Г. Штучні нейронні мережі / О. Г. Руденко, Е. В. Бодянський. – Харків: Компанія СМІТ, 2006. – 404 с.

ЗМІСТ

ВСТУП 15
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ 17
1.1 Проблема психодіагностики 17
1.2 Напрямки та підходи психодіагностики 19
1.3 Електроенцефалографія в психодіагностиці 22
1.4 Огляд існуючих інтелектуальних методів психодіагностики 28
1.5 Постановка задачі дослідження 31
2 ПОБУДОВА ГІБРИДНОЇ СИСТЕМИ ДЛЯ ДІАГНОСТИКИ ПСИХІЧНИХ ЗАХВОРЮВАНЬ 33
2.1 Гібридний підхід на основі м’яких обчисленнь 33
2.2 Нечітка логіка 36
2.3 Нейро-нечіткі мережі 45
2.4 Еволюційні алгоритми 52
2.5 Гібридна система псіходіагностики 59
3 ЕКСПЕРИМЕНТАЛЬНА ЧАСТИНА 61
3.1 Постановка експерименту 61
3.2 Вхідні данні 64
3.3. Експериментальні результати 66
3.4 Обробка та оцінка результатів 69
ВИСНОВКИ 73
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ 76
Додаток А 80
Додаток Б 89

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

ANFIS - адаптивна нейро-нечітка система виводу (англ., Adaptive neuro fuzzy inference system)

CLONALG - клональний відбір (англ., Clonal Algorithm)

DL – глибоке навчання (англ., deep learning)

k-means – алгоритм k-середніх

kNN – алгоритм k-найближчих сусідів (англ., k-Nearest Neighbor)

ML – машинне навчання (англ., machine learning)

MLP – багатошаровий парсептрон (англ., Multi-Layer Parceptron)

State of the Art, SOTA - рішення, що використовує найновіші ідеї та методи та показують найвищу ефективність

State of the Science - рішення, що демонструють результати новітніх дослідженнь

qEEG – кванититивна електроенцефалографія (англ., quantitative electoencephalograpy)

ГА – генетичний алгоритм

ЕЕГ – елекроенцефалографія

ВСТУП

Діагностика психічних захворювань є однією з ключових складових системи охорони здоров’я, оскільки вона забезпечує основу для підтримки ментального добробуту суспільства. Актуальність обраної теми зумовлена необхідністю точного та своєчасного виявлення симптомів психічних розладів, що безпосередньо впливає на ефективність лікування. Традиційні методи діагностики часто стикаються з труднощами, пов'язаними з суб'єктивністю оцінок та недостатньою кількістю даних, що підкреслює потребу в нових, робастних алгоритмах і методах аналізу даних, які враховують специфіку психічних захворювань та доступні дані.

Об'єктом дослідження даної роботи є діагностика психічних захворювань на основі даних електроенцефалографії. Предметом дослідження є гібридні нейро-нечіткі мережі, які поєднують переваги штучних нейронних мереж та нечіткої логіки. Метою дослідження є розробка гнучкої автоматизованої системи для діагностики психічних захворювань на рівні, достатньому для підтвердження властивостей гнучкості та адаптивності запропонованого рішення.

Завданнями роботи є вивчення структури даних ЕЕГ, аналіз існуючих рішень у сфері їхнього інтелектуального аналізу, дослідження та порівняння різних алгоритмів штучного інтелекту в контексті мети роботи, розробка та тестування запропонованої гібридної нейро-нечіткої мережі в обсязі, достатньому для підтвердження її життєздатності. Для вирішення поставлених завдань використані методи аналізу, синтезу, порівняння, машинного навчання та k-кратної випадкової крос-валідації.

Таким чином, для досягнення поставленої мети та завданнь ціллю теоретичної частини роботи є аналіз типів гібридизації м’яких обчисленнь, аналіз типів м’яких обчисленнь, включно з нечіткою логікою, нейронними мережами й еволюційними численнями, вибір типу гібридизації та конкретних алгоритмів м’яких обчислень для реалізації в рамках гібридної системи, розробка схеми гібридної нейро-нечіткої мережі для діагностики психічних захворювань на основі даних ЕЕГ.

Ціллю експериментальної частини роботи в свою чергу є проведення експериментального дослідження, що включає тестування трьох груп алгоритмів: класичного машинного навчання, алгоритмів, що складають основу гібридних моделей, та власне гібридних моделей. Також в рамках експерементальної частини необхідно здійснити оцінку точності та прецизійності навчання кожного алгоритму з метою визначення їх ефективності у діагностиці психічних розладів та провести порівняльний аналіз результатів, для виявлення переваг та недоліків кожного з алгоритмів, а також оцінки можливостей для їхнього покращення.

Теоретична значимість роботи полягає у детальному аналізі та розробці моделей м’яких обчислень для діагностики психічних захворювань. Практичне значення дослідження полягає у розробці гібридних нейро-нечітких мереж для покращення точності та швидкості діагностики психічних захворювань на основі аналізу даних ЕЕГ зокрема, та систем афективного аналізу вцілому, результати поточної кваліфікаційної роботи лежать в основі науково-технічного проєкту в галузі штучного інтелекту, де у значно модифікованому вигляді застосовані для вирішення існуючих економічних завданнь.

У роботі використовуються матеріали вітчизняних та закордонних досліджень в галузі штучного інтелекту та медицини. Наукові джерела належать до таких напрямів, як психодіагностика, прикладна психологія та неврологія, теорія штучного інтелекту, аналізу данних та теорія алгоритмів. В число джерел входять публікації здобувача, наукового керівника та співробітників кафедри.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

1.1 Проблема психодіагностики

Психодіагностика — це галузь психологічної науки, що займається оцінкою та вимірюванням індивідуальних психічних особливостей особистості з метою постановки корректного діагнозу та адекватного хворобі лікування. Вона охоплює широкий спектр методів і інструментів, які дозволяють фахівцям проводити об'єктивну оцінку психічного стану пацієнтів. Психодіагностика включає в себе як традиційні методи, такі як інтерв'ю та спостереження, так і стандартизовані тести, розроблені для вимірювання різних аспектів особистості, когнітивних здібностей та емоційного стану. Ця галузь медицини постійно розвивається, інтегруючи нові дослідження та технології, що дозволяє покращувати точність і надійність діагностичних процедур.

Значення психодіагностики полягає в її здатності забезпечити точну і надійну інформацію про психічні характеристики особи, що є критично важливим для розробки ефективних терапевтичних стратегій. Вона допомагає виявити індивідуальні відмінності, які можуть впливати на поведінку, емоційний стан і загальне ментальне здоров'я пацієнта. Завдяки психодіагностиці фахівці мають змогу краще розуміти причини психічних розладів, що, в свою чергу, дозволяє їм адаптувати лікування до конкретних потреб кожного пацієнта, що підвищує ймовірність успішного лікування та покращення якості життя людей, які страждають від психічних розладів[1].

У практичному застосуванні психодіагностика використовується для оцінки психологічного стану особи та визначення рівня вираженості певних психічних особливостей. Психодіагностика також є значимою в контексті профілактики, оскільки дозволяє виявляти потенційні проблеми на ранніх стадіях, що дозволяє запобігти їх подальшому розвитку у разі своєчасного лікування. Таким чином, питання якісної та ефектиної психодіагностики тісно пов’язане з забезпеченням

суспільного здоров’я та добробуту.

Серед проблем, що існують у психодіагностиці найбільш гостро стоять неоднозначність термінології, питання надійності та валідності психодіагностичних інструментів, а також етичні аспекти, пов'язані з конфіденційністю даних пацієнтів. Неоднозначність термінології перешкоджає читкій професійній комунікації, що ускладнює співпрацю між фахівцями й стримує розвиток та поширення новітніх досягнень галузі. Питання надійності та валідності інструментів є критично важливими, оскільки ненадійні або невалідні методи часто призводять до помилкових діагнозів і, відповідно, до неефективного лікування. Етичні аспекти, такі як захист конфіденційності пацієнтів та коректність взаємодії з ними лікарів представляють критичну важливість, оскільки є гарантією довіри населення до медицини в аспекті підтримки психічного здоров’я та запорукою готовності людей звертатися за допомогою[1].

Зі стрімким розвитком штучного інтелекту перспективи його застосування в психодіагностиці виглядають обнадійливо, оскільки інтелектуальні технології дають змогу частково вирішити описані вище проблеми. Використання алгоритмів машинного навчання та аналізу великих даних може суттєво підвищити точність діагностики, дозволяючи виявляти патерни, які можуть бути непомітними для людського ока, робить виявлення психічних розладів швидшим та ефективнішим, а також відкриває шляхи до розробки нових, більш чутливих психодіагностичних інструментів. Інтеграція штучного інтелекту в психодіагностику також сприяє автоматизації процесів збору та аналізу даних, що в свою чергу дозволяє фахівцям зосередитися на інтерпретації результатів і взаємодії з пацієнтами. Наприклад, алгоритми можуть аналізувати електроенцефалографічні дані, виявляючи аномалії, які можуть свідчити про наявність психічних розладів, таких як шизофренія. Це не лише потенційно підвищує точність діагностики, але й скорочує час, необхідний для проведення оцінки.

Іншим потенційним варіантом застосування штучного інтелекту є розробка персоналізованих терапевтичних підходів на основі аналізу даних про пацієнтів і їхніх реакцій на лікування. Це дозволяє створити ефективніші програми лікування,

адаптовані до індивідуальних потреб кожного пацієнта. В той же час використання сучасних алгоритмів обробки та зберігання данних вирішує питання конфіденційності даних пацієнтів, виключаючи людський фактор, за умови використання в їхній реалізації досягненнь сучасної криптографії та приділення достатньої уваги до цієї проблеми на етапі проєктування медичного програмного забезпечення. Таким чином, впровадження штучного інтелекту в психодіагностику має потенціал не лише для покращення точності діагнозів, але й для підвищення загальної ефективності психологічної допомоги, що в кінцевому підсумку очикувано позитивно вплине на якість життя людей, що страждають від різноманітних психічних порушеннь.

1.2 Напрямки та підходи психодіагностики

Основні напрями психодіагностики склалися завдяки розвитку кількох ключових наукових джерел: експериментальної психології, диференціальної психології, тестології та прикладної психології/психотехніки. Кожен із цих напрямів вніс свій внесок у формування методів виявлення індивідуальних психічних особливостей людини, а їхній розвиток визначав етапи становлення психодіагностики[1].

Практичним напрямом, орієнтованим на вирішення завдань профвідбору, профорієнтації та оцінки професійної придатності є прикладна психологія та пов’язана з нею психотехніка. Перші тести для відбору працівників запропонував Г. Мюнстерберг. Спочатку тести Мюнстерберга застосовувались на групах із високими професійними досягненнями. Надалі методики практичної психології поступово доповнювалися мануальними тестами, орієнтованими на оцінку моторних навичок. Масове тестування стало особливо поширеним у період Першої та Другої світових воєн, коли мільйони військовослужбовців проходили тестові випробування. Розвиток практичної психології та психотехніки сприяв застосуванню тестів у сфері економіки та виробництва, забезпечуючи ефективний підбір кадрів[1,2].

Експериментальна психологія набула значного поширення наприкінці XIX століття, коли експеримент став основним методом дослідження психіки. Вплив позитивізму сприяв формуванню критеріїв науковості, таких як об’єктивність, повторюваність та верифікація. Центрами експериментальних досліджень стали лабораторії, зокрема перша експериментально-психологічна лабораторія Вільгельма Вундта, заснована у 1870-х роках у Німеччині. У цих умовах зароджувалися напрями психофізики та психофізіології. Предметом обох дисциплін є взаємодія між фізичними і психологічними аспектами. Психофізика вивчає взаємозв'язок між фізичними стимулами і суб'єктивними відчуттями. Психофізіологія досліджує вплив фізіологічих процесів в організмі на психічні стани і поведінку. Тогочасні дослідники психофізики та психофізіології також приділяли увагу також перцептивним процесам, увазі, пам’яті та мовному компоненту свідомості. Герман Еббінгауз розробив першу суто психологічну методику для вивчення запам’ятовування, запропонувавши концепцію «кривої забування» та заклавши основи експериментального дослідження пам’яті й навичок[1,2].

Диференціальна психологія почала формуватися наприкінці XIX століття як напрям, спрямований на вивчення індивідуальних відмінностей пацієнтів. Основи цього напряму були закладені працями таких дослідників, як А. Біне, Ф. Гальтон, та В. Штерн. У цей період розроблялися методи, що дозволяли кількісно оцінювати індивідуальні особливості, зокрема метод близнюків і антропометричні дослідження. Гальтон започаткував концепцію психологічних тестів, хоча вони здебільшого стосувалися фізіологічних показників. Поступово інтерес психологів перемістився до використання математично-статистичних методів для аналізу даних, що стало основою подальшої стандартизації психодіагностичних методик.

В розвитку класичної психодіагностики ключовим компонентом є впровадження тестології, що є тісно пов’язаною з диференційною психологією. Джеймс Кеттел у 1890 році запропонував концепцію психологічних тестів, що базувалися на об’єктивних вимірюваннях психічних процесів. Він висунув ідею систематизованого тестування великої кількості індивідів, що дозволило виявляти закономірності психічних функцій людини. Подальший розвиток цього напряму

пов’язаний із методикою Біне-Сімона, яка вперше дозволила оцінювати розумовий розвиток дітей. Ця методика вводить поняття «розумового віку» та коефіцієнта інтелекту(IQ), запропонованого Вільямом Штерном. Згодом методика була вдосконалена в Стенфордському університеті, де створено шкалу Біне-Стенфорд, що є основою для сучасного тестування інтелекту. Для сучасних дослідників робота з інструментарієм тестології є одним з основних напрямків автоматизації психодіагностики[2].

Апаратні методи в психодіагностиці виникли в результаті впровадження експериментального підходу в психології. Ці методи передбачають використання спеціальних пристроїв для об’єктивного вимірювання різних психічних і фізіологічних характеристик. Їхня основна мета — отримання точної кількісної інформації про функціонування психіки через реєстрацію поведінкових або нейрофізіологічних реакцій. Виникнення апаратних методів було пов’язане з ранніми дослідженнями сенсорної психіки, що проводилися у фізіологічних і психологічних лабораторіях у другій половині XIX століття. Зокрема, Г. Гельмгольц і Е. Геринг розробили низку технічних пристроїв для дослідження зорових і слухових відчуттів, таких як реактометр, хронометр, тахістоскоп, що згодом стали стандартним обладнанням експериментально-психологічних лабораторій. Апаратні методи активно використовувалися для дослідження сенсорних процесів, уваги, пам’яті, реакцій на подразники та інших психічних функцій. Наприклад, вимірювання часу реакції стало основою для багатьох експериментів, які дозволяли оцінювати швидкість обробки інформації нервовою системою. Також розроблялися спеціальні пристрої для вивчення порогів відчуттів, інтенсивності подразників і особливостей перцептивних процесів[1].

Особливого значення апаратні методи набули в психофізіології, основними напрямами досліджень в якій є вивчення сенсорних систем, моторних реакцій, уваги, емоцій, а також когнітивних процесів, таких як пам’ять і мислення. Розвиток психофізіології тісно пов’язаний з розвитком психофізики, де значним є вклад німецького фізика та психолога Г. Фехнера. Психофізика досліджує закономірності відчуттів у взаємозв’язку з фізичними характеристиками подразників. Зокрема, з

використанням апаратного підходу у психофізиці були сформульовані поняття порогів відчуттів — абсолютного (мінімальна сила подразника, яка викликає відчуття) та диференціального (мінімальна зміна сили подразника, яка може чуттєво сприймається)[1].

Сучасна психофізіологія значно розширила свої методологічні можливості завдяки впровадженню електрофізіологічних методів, таких як електроенцефалографія, магнітоенцефалографія(МЕГ), метод викликаних потенціалів, функціональна магнітно-резонансна томографія(фМРТ). Такі методи дозволяють досліджувати активність мозку в реальному часі, аналізувати локалізацію психічних функцій і вивчати нейрофізіологічні основи процесів свідомості та підсвідомості. Таким чином, апаратні методи й психофізіологія об’єднують емпіричний підхід до вивчення психічних явищ із точними вимірюваннями. Вони відкривають широкі можливості для дослідження взаємозв’язку психіки й фізіології, даючи змогу отримувати нові відомості про механізми функціонування людського мозку та психіки[3].

1.3 Електроенцефалографія в психодіагностиці

Сучасна психодіагностика постійно еволюціонує, інтегруючи новітні технології та методи для більш глибокого розуміння психічного здоров'я. Одним із таких інноваційних підходів, що активно застосовується в психофізіології, є електроенцефалографія, що дозволяє неінвазивно досліджувати електричну активність мозку в реальному часі. Цей метод є перспективним для оцінки психічних станів, виявлення аномалій та розробки індивідуалізованих терапевтичних стратегій[3].

ЕЕГ використовується для оцінки широкого спектру розладів мозку. ЕЕГ здатна виявляти аномалії у пацієнтів з мозковими ураженнями, отриманими внаслідок пухлин або інсультів, хворобу Альцгеймера, нарколепсію та певні види психозів чи епілепсії, де контретне порушення характеризується специфічним для

нього паттерном хвиль. Загальна електрична активність мозку, отримана методом ЕЕГ дозволяє оцінювати церебральні травми, ступінь ушкодження мозку у коматозних пацієнтів, інтоксикації наркотиками та проводити моніторинг кровотоку під час хірургічних втручань[3,4,5].

ЕЕГ також набуває популярності як діагностичний інструмент у психіатрії та психології. Психіатри часто направляють пацієнтів на ЕЕГ, щоб виявити органічну етіологію психічних розладів, особливо у випадках делірію, деменції або вживання нейротоксичностих медикаментів. Серед пацієнтів, направлених на ЕЕГ-дослідження з психіатричних причин, близько 30-40% мають аномальні результати, що надає лікарям значиму інформацію для підтвердження діагнозу. В клінічній практиці електроенцефалографія використовується для діагностики та прогнозування психічних розладів насамперед завдяки можливості отримати біологічні маркери мозку[4,5,6].

Практично електроенцефалографія являє собою метод графічної реєстрації біопотенціалів головного мозку для подальшого дослідження його фізіологічних характеристик, виявлення осередкових уражень, неврологічних розладів та визначення їхнього характеру. Результатом ЕЕГ є запис зареєстрованої хвильової біоелектричної активності мозку який називають електроенцефалограмою. Типово під електроенцефалограмою розуміють поверхневий запис, тобто здійснений зі шкіри, як найбільш простий та безпечний в клінічній практиці неінвазивний метод оцінки мозкової діяльності[7,8].

Реєстрація і аналіз ЕЕГ у сучасній науці і клініці здійснюється за допомогою комп'ютерних електроенцефалографічних комплексів, які складаються із кількох функціональних блоків:

1) блок реєстрації сигналу;
2) блок фільтрів та підсилювачів;
3) аналогово-цифровий перетворювач (АЦП);
4) комп'ютерна програма для зберігання, візуалізації та математичного аналізу сигналу.

Схема розташування електродів на поверхні голови називається монтажем. У

клінічній та науковій електроенцефалографії стандартом є схема «10-20 %». Типовий монтаж електродів зображено на рисунку 1.1.

Щоб визначити місця накладання електродів, через маківку (Vertex) необхідно визначити два умовні меридіани. Перший мередіан пролягає від перенісся (Nasion) до потиличного бугра (Inion), другий мередіан намічається між вухами пацієнта (рис. 1.1). Мередіани, у відповідності з мнемонічною назвою даної класичної схеми діляться на відрізки по 10 і 20% від загальної довжини. Поперечні меридіани відкладаються по осі, що пролягає між вухами через маківку. Електроди розміщуються у місцях перетину умовних ліній. Електроди на лівій стороні голови, мають непарні індекси, електроди правої сторони отримують парні індекси. Електроди, розміщені на маківочній лінії, мають індекс z. Менший індекс електрода означає, що він розташований ближче до основних меридіанів. Для локалізації електродів на відповідних областях голови у їхньому іменування використовуються наступні позначення: F (Frontalis) — лобні; T (Temporalis) — скроневі; C (Centralis) — центральні; P (Parientalis) — тім'яні; O (Occipitalis) — потиличні; A (Auricularis) — вушні. Кількість накладених електродів залежить від конкретної мети дослідження. В разі необхідності схему 10-20% розширюють шляхом проведення додаткових меридіанів між основними. Стандартизація схеми накладання електродів дає можливість медикам та дослідникам зіставляти результати, отримані в різних лабораторних умовах[8,9].

З фізичної точки зору для реєстрації ЕЕГ необхідна наявність двох електродів, між якими і буде вимірюватися різниця електричних потенціалів. Пара електродів, між якими знімаються показання біоелектричної активності, називається відведенням[5].

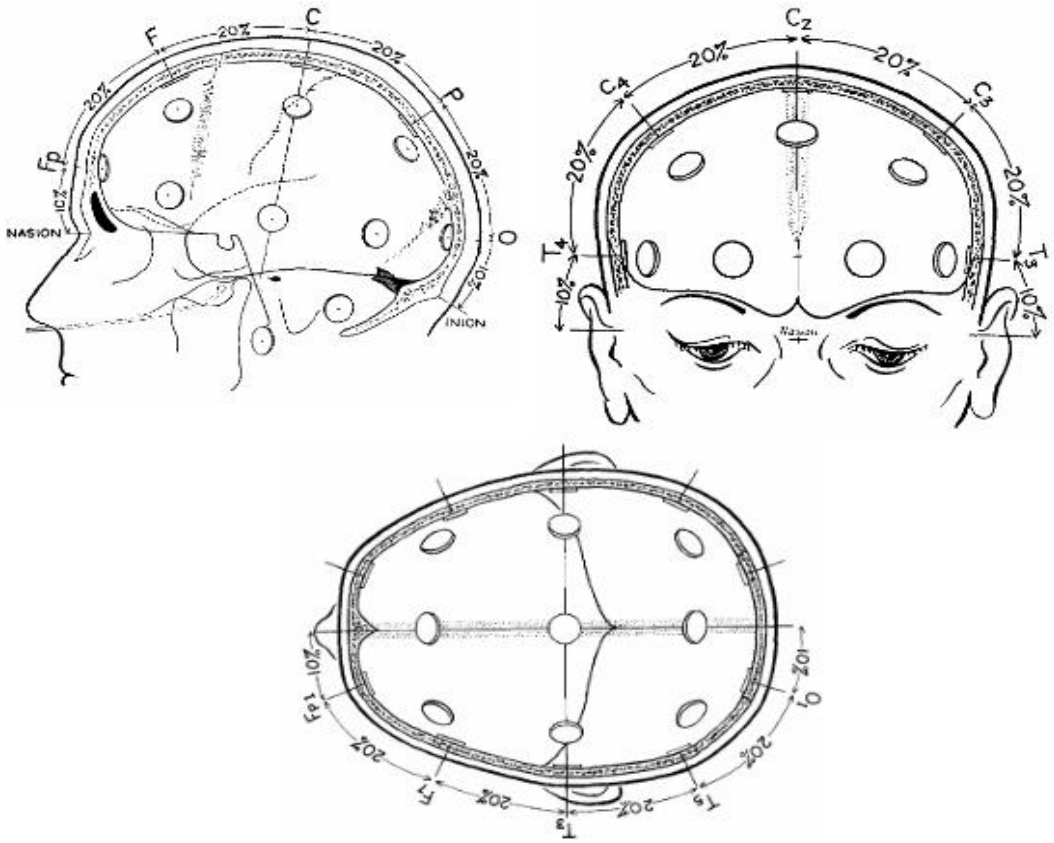

Рисунок 1.1 Схема розташування електродів у відповідності за типом 10-20% [9]

Ключовим поняттям електроенцефалографії є ритм, відомий також як канал, що являє собою активність хвиль приблизно однієї постійної частоти. Найбільш виражений ритм енцефалограми називається домінуючим.

Амплітуда хвиль ритмічної активності, що поступово і циклічно наростає та спадає, називається веретеноподібною ритмічною активністю. Зменшення амплітуди коливань потенціалів без зміни їх частотної характеристики називається депресією ритму. Формування регулярної, упорядкованої ритмічної активності й наростання амплітуди коливань є синхронізацією ритму[8].

За виразністю коливань частоти у різних фізіологічних станах виділять декілька основних фізіологічних частотних діапазонів: δ(<4 Гц), θ(4-7 Гц), α(8-13 Гц), β(13-40 Гц), γ(від 30-40 до 70-500 Гц залежно від підходу), див. табл. 1.1.

Таблиця 1.1 Структура ЕЕГ

Діапазон	Частота	Фізіологічні властивості
δ	до 4 Гц	коливання амплітудою 20-30 мкВ можуть зустрічатися у ЕЕГ здорової притомної людини; наявність коливання вище 40-300мкВ у притомної людини є ознакою мозкових пухлин; δ-коливання стають вираженими під час певних фаз природного сну, наркотичного сну або у стані коми
θ	4-7 Гц	коливання амплітудою до 40 мкВ можуть зустрічатися у ЕЕГ здорової притомної людини, зростання їх частки є ознакою емоційної активації; наявність θ-коливань вищої частоти характеризує патологічні або змінені стани свідомості
α	8-13 Гц	синусоїдальні коливання амплітудою до 100 мкВ у лобно-потиличному напрямку, є найбільш вираженим у ЕЕГ здорової притомної людини із закритими очима, коливання пригнічується при відкриванні очей, переході до активної діяльності, аналізу інформації
β	13-40 Гц	коливання амплітудою 5-30 мкВ пов’язані з активним функціональним станом мозку, зростання рівня активації головного мозку здебільшого супроводжується зменшенням частки α-коливань і зростанням частки β-коливань; виражений β-ритм вище 40 мкВ є патологічною ознакою
γ	від 30-40 до 70-500 Гц	коливання амплітудою до 10 мкВ вважається ознакою когнітивних процесів і свідомості; наявність коливань цього діапазону амплітудою вище 15 мкВ є вираженою патологічною ознакою

Для здорової притомної людини нормою є наявність α-ритму, присутність у електроенцефалограмі ритмів інших діапазонів є ознакою змінених станів свідомості, в тому числі викликаних мозковими патологіями[7,8].

Для оцінки коливань того чи іншого ритму використовується фільтрація сигналу. Фільтрація здійсніється за допомогою аналогових та/або цифрові фільтрів.

Сучасним етапом розвитку ЕЕГ є квантитативна електроенцефалографія. квантитативна електроенцефалографія (qEEG) — це галузь, що займається чисельним аналізом даних електроенцефалограм і корельованих з її ритмами поведінкових паттернів. qEEG передбачає статистичний аналіз даних для точної кількісної оцінки електричних потенціалів. Це передбачає перетворення безпосередніх даних ЕЕГ у більш релевантий формат, що спрощує його подальшу обробку. Фактично qEEG є підтипом задачі цифрової обробки сигналів, що визначає спектр її застосування. Базу qEEG складає використання вейвлет-аналізу і спектрального аналізу Фур’є з особливою увагою на співактивності ритмів, включаючи синхронність величини (комодуляція/кореляція та асиметрія) та фазову синхронність (когерентність, фазове відставання). Актуальні алгоритми аналізу даних енцефалограм відрізняються залежно від конкретного методу qEEG та конкретної програмної реалізації[10].

Незважаючи на велику кількість опублікованої наукової літератури про qEEG, цей метод все ще не набув широкого клінічного застосування і обмежується переважно академічними дослідженнями. квантитативна ЕЕГ все ще перебуває на стадії свого становлення. Серед медичної наукової спільноти точаться дискусії щодо цінності використання методу в клінічній практиці. Причинами полеміки в дослідженні qEEG є ряд факторів. До проблем qEEG входить відсутність стандартизації серед різних дослідників як в методології управління великими масивами досліджуваних данних, так і в протоколі проведення статистичного аналізу, інтер- та інтра-класова варіативність клінічних датасетів, вплив на ЕЕГ таких біологічних факторів як вік, стан тканин, режим сну, вимоги до якості обладнання та необхідність глибоких знань математичної статистики у лікаря, що здійснює діагностику[10,11].

1.4 Огляд існуючих інтелектуальних методів психодіагностики

Використання штучного інтелекту для аналізу сигналів ЕЕГ стає дедалі перспективнішим з розвитком технологій, що відкривають нові можливості підвищення точності та швидкості діагностики психічних розладів. Дослідження штучного інтелекту в цій галузі включають застосування як методів традиційного машинного навчання, так і глибокого навчання. Алгоритм діагностики психічних розладів за допомогою штучного інтелекту в загальному вигляді включає два основні етапи: попередню обробку з виділення та вибору ознак і власне класифікацію. В психодіагностиці за результатами ЕЕГ на основі методів ШІ, виділення ознак набуває особливої важливості[11,12].

В аналіз ЕЕГ за допомогою традиційного машинного навчання систематичний двоетапний процес виражений особливо чітко. Спершу із сигналів ЕЕГ виділяються ознаки, включно з такими характеристиками, як статистичні показники (математичне очікування та дисперсія) чи спектральна густина. Якість виділення ознак сильно впливає на продуктивність моделей машинного навчання. Надалі виділені ознаки передаються на вхід актуальної класифікаційної моделі. Поширені традиційні алгоритми, що використовуються для класифікації ЕЕГ включають метод опорних векторів (SVM), дерева рішень (DT), випадкові ліси (RF), логістичну регресію (LR), алгоритм k-найближчих сусідів (kNN), наївний алгоритм Баєса (NB), Adaboost і т.д. Основною перевагою традиційних підходів є можливість інтерпретації таких моделей. Чітко визначені ознаки дозволяють дослідникам розуміти фактори, що впливають на рішення моделі. Крім того, традиційні моделі машинного навчання демонструють надійність на малих датасетах, що робить їх придатними для сценаріїв з обмеженим обсягом даних[11,12].

Виявлення психічних розладів за допомогою машинного навчання є багатообіцяючим напрямом досліджень зі значним потенціалом для покращення перспектив ранньої діагностики та своєчасного втручання. Методи ML дають змогу аналізувати різні джерела даних, у тому числі ЕЕГ, для ідентифікації маркерів

психічних розладів. В останні роки спостерігається значний інтерес до цієї області як серед медиків, так і дослідників штучного інтелекту. Таблиця 1.2 коротко підсумовує останні досягнення даного напряму.

Таблиця 1.2 Огляд існуючих рішень

Дослідження	Передобробка	Метод	Датасет	Точність
Аґарвал, Сінґал 2023, [13]	FFT та статистичний аналіз	SVM, KNN, DT	IPN,Kaggle SCZ	99.25%
Девіа та ін., 2019, [14]	ICA, фільтр Баттерворта ,	LDA	Закритий	71%
Луджан та ін., 2022, [15]	Просторові фільтри та смуговий фільтр	SVM, kNN, RBF, Байєсівський LDA, Гаусовий NB, Adaboost та	Закритий	93.40%
Харе, Баджай, 2022, [16]	RVMD	Оптимізований ELM	Kaggle SCZ	92.93%
Айдемір та ін., 2022, [17]	CGP17Pat та INCA	kNN	IPN	99.91%
Наджафзаде та ін., 2021, [18]	Фільтр Баттерворта	ANFIS, SVM та ШНМ	IPN	100%
Су Мі Пак та ін. 2023, [19]	Статистичний аналіз	Набір класичних моделей	Власний	Порівняльний аналіз різних алгоритмів

З таблиці 1.2 ми бачимо, що дослідження штучного інтелекту в сфері аналізу сигналів ЕЕГ демонструють широкий спектр методів і підходів. Наприклад, у дослідженні Аґарвал та Сінґал[13] використано комбінацію швидкого перетворення

Фур’є(FFT) та статистичного аналізу у поєднанні з такими класифікаторами як метод опорних векторів (SVM), алгоритм k-найближчих сусідів (kNN), дерева рішень (DT) і випадкові ліси (RF), що дозволило досягти вражаючої точності 99,25% на датасетах IPN і Kaggle SCZ.

У контексті дослідження Девіа та ін.[14], зазначається, що використання фільтра Баттерворта та аналізу незалежних компонентів (ICA) призвело до нижчої точності у 71% для закритого набору даних ЕЕГ, що може бути пов'язано з обмеженим обсягом даних. Дослідження Луджан та ін.[15], продемонструвало, що інтеграція просторових фільтрів і смугового фільтра з шістьма різними класифікаторами, серед яких виділяється радіальна базисна мережа (RBF), забезпечила точність 93,40% на закритому датасеті.

Дослідження Харе та Баджай[16] показало, що використання робастної варіаційної моди декомпозиції (RVMD) для попередньої обробки та оптимізованого класифікатора методом екстремального навчання (ELM) на наборі даних Kaggle SCZ призвело до нижчої точності, але все ж перевершило результати, отримані в дослідженні Девіа та ін. У свою чергу, Айдемір та ін.[17], досягли дуже високої точності 99,91% завдяки використанню CGP17Pat для виділення ознак і алгоритму k-найближчих сусідів (KNN) для класифікації, хоча це не перевищило результати, досягнуті в роботі Наджафзаде та ін.[18], які продемонстрували ідеальну точність 100% за допомогою фільтра Баттерворта, адаптивної системи нейро-нечіткого висновку, SVM та штучних нейронних мереж.

Дослідження Су Мі Пак та ін.[19] надає спеціалізований датасет та порівняльний аналіз застосування на ньому ряду технік машинного навчання для виявлення кількох спектрів психічних хвороб.

Враховуючи різноманітність методів, які були розглянуті, можна відзначити, що поєднання різних підходів до аналізу сигналів ЕЕГ та використання нечіткої логіки суттєво підвищують точність та надійність інтелектуальної психодіагностики. Використання різних методів попередньої обробки та класифікації дозволяє краще врахувати специфіку даних, що в свою чергу, сприяє виявленню складних патернів нейронної активності. Крім того, інтеграція

традиційних алгоритмів машинного навчання з сучасними методами глибокого навчання потенційно може забезпечити більш ефективне виділення ознак і покращити загальну продуктивність моделей. Для досягнення цих переваг перспективним виглядає використаня гібридних моделей, що об'єднують сильні сторони різних методів м’яких обчисленнь. Від гібридного підходу очикується адаптивність до різних умов та типів вхідних даних та вища точність психодіагностики.

1.5 Постановка задачі дослідження

Ціллю дослідження в рамках поточної кваліфікаційної роботи є досягнення поставлених завдань та мети роботи шляхом, розробки та оцінки точності й ефективності гібридної нейро-нечіткої еволюційної системи у діагностиці психічних порушень на основі даних електроенцефалографії. Дослідження має виявити, наскільки ефективним є запропоноване рішення в порівнянні з існуючими методами, а також визначити переваги та недоліки кожного з підходів.

Таким чином, завданням теоретичної частини є:

а) Аналіз типів гібридизації м’яких обчисленнь;
б) аналіз типів м’яких обчисленнь;
   1) нечіткої логіки;
   2) нейронних мереж;
   3) еволюційних алгоритмів;
в) вибір типу гібридизації та конкретних алгоритмів м’яких обчислень для реалізації в рамках гібридної системи;
г) розробка схеми гібридної нейро-нечіткої мережі для діагностики психічних захворювань на основі даних ЕЕГ

Завданнями експериментальної частини роботи є:

1) проведення експериментального дослідження, яке включає тестування трьох груп алгоритмів: класичних алгоритмів машинного навчання, алгоритмів, що складають основу гібридної моделі, та власне гібридних моделей;

2) оцінка точності та прецизійності кожного алгоритму з метою визначення їхньої ефективності у діагностиці психічних розладів;
3) порівняльний аналіз результатів, для виявлення переваг та недоліків кожного з алгоритмів, а також оцінки можливостей для покращення.

Для проведення експерименту потрібно використати реальні дані ЕЕГ з метою забезпечення практичної значущості отриманих результатів. Кожен алгоритм необхідно протестувати на однакових навчальних та тестових наборах даних для коректності порівняння. Результати експериментів оцінюються за допомогою метрик точності та прецизійності. Надійність результатів забезпечується k-кратною випадковою крос-валідацією.

На основі аналізу результатів експерименту необхідно зробити обґрунтовані висновки про доцільність використання кожного з алгоритмів в рамках гібридної нейро-нечіткої моделі та застосування в практиці діагностики психічних розладів. Крім того, дослідження має на меті визначити вектор розвитку системи до стану State of the Art для майбутнього покращення ефективності діагностики та лікування психічних порушень.

2 ПОБУДОВА ГІБРИДНОЇ СИСТЕМИ ДЛЯ ДІАГНОСТИКИ ПСИХІЧНИХ ЗАХВОРЮВАНЬ

2.1 Гібридний підхід на основі м’яких обчисленнь

На основі попереднього огляду існуючих методів штучного інтелекту для діагностики психічних розладів шляхом аналізу сигналів ЕЕГ, було висунуто припущення про високий потенціал поєднання різних типів м’яких обчисленнь для підвищення точності і надійності діагностики. Отже, першим кроком побудови системи діагностики психічних хвороб за сигналами ЕЕГ в рамках даної роботи є визначення потенційних шляхів гібридизації алгоритмів штучного інтелекту, приданих для створення більш ефективних моделей діагностики, що дадуть оптимальний результат в клінічній практиці.

Гібридизація - це процес поєднання різних підходів та технік, зокрема тих, що належать до парадигм м'яких обчислень, з метою створення нових моделей, які поєднують переваги початкових методів та підвищують ефективність та продуктивність вирішення реальних завдань. Крім того, важливим аспектом гібридизації в контексті поточної роботи є можливість адаптації моделей до специфічних умов та вимог клінічної практики. Використання комбінацій різних алгоритмів дає змогу створювати системи, що враховують індивідуальні особливості пацієнтів, такі як вік, стать, генетичні фактори та інші медичні показники. Це, в свою чергу, дає більш точні і персоналізовані діагнози, що є критично важливим у лікуванні психічних розладів. Адаптивні моделі, які здатні до самооптимізації, можуть значно підвищити ефективність діагностики, зменшуючи ймовірність помилок та покращуючи загальний результат лікування[20,21,23].

М'які обчислення - це набір підходів, що використовуються для отримання точних результатів у невизначених системах та імітують процеси людського міркування та прийняття рішень. Серед існуючих парадигм м’яких обчисленнь фундаметальними є три напрямки: штучні нейронні мережі, нечітка логіка та

еволюційні обчислення, кожен з яких окремо є придатним для застосування в системах діагностики психічних хвороб, таких як наприклад шизофренія[20,21,22].

Втім, кожна базова парадигма м'яких обчислень має свої переваги та недоліки. Системи з нечіткою логікою не мають здатності до автоматичного навчання, як нейронні мережі, але можуть виражати знання у вигляді мовних конструкцій, що є більш природним для людського мислення. Нейронні мережі, навпаки, розроблені спеціально для машинного навчання і є тривіальним рішенням для задач з розміченим датасетом достатнього обсягу. Еволюційні алгоритми, хоча і мають нижчу швидкість навчання порівняно з нейронними мережами є більш генералізованими та здатні краще апроксимувати цільові функції[20,21,22].

Гібридний підхід цінний тим, що різні алгоритми м'яких обчислень, працюють синергічно, а не конкурентно, а їхня взаємна залежність здатна привести до відчутних покращень продуктивності. Так, поєднання нечіткої логіки з нейронною мережею може дати систему, здатну як до навчання, так і вираження знань у вигляді мовних конструкцій. Подібним чином, поєднання еволюційних алгоритмів з нейронною мережею може забезпечити більш ефективне навчання завдяки покращеній апроксимації. Ідея гібридизації тісно переплітається з ансамблевими техніками, такими як стакінг, беггінг та бустинг проте дає більше гнучкості в проєктування кінцевої системи.

Можна виділити 4 основні варіанти гібридизації м’яких обчисленнь (див. рис. 2.1) :

- Нейро-фаззі гібридизація (нечітка логіка та нейронна мережа);
- Фаззі-еволюційна гібридизація (нечітка логіка та еволюційний алгоритм);
- Нейро-еволюційна гібридизація (нейронна мережа та еволюційний алгоритм);
- Нейро-фаззі-еволюційна гібридизації(поєднання всіх трьох згаданих типів м’яких обчислень в рамках однієї гібридної системи).

Рисунок 2.1 Діаграма можливих варіантів гібридизації

Кожен з наведених типів гібридизації має свої певні переваги та недоліки. Гібридизація нечіткої логіки та нейронної мережі забезпечує можливість вивчення і вираження знань у вигляді мовних конструкцій, проте накладає обмеження на глибину та ємність мережі. Гібридизація нечіткою логіки та еволюційних алгоритмів забезпечує ефективніше навчання і кращу генералізацію, проте не гарантує збіжності алгоритму. Нейроеволюційна гібридизація забезпечує більш ефективне навчання шляхом уникнення локальних оптимумів під час навчання, проте як і в попередньому випадку не гаратнує збіжності та вимагає значних обчислювальних ресурсів на етапі навчання. Гібридизація всіх трьох типів м'яких обчислень створює значну кількість можливих комбінацій базових алгоритмів і являє собою перспективне поле для досліджень, оскільки певні варіанти поєднання

м’яких обчисленнь здатні максимізовувати їхні переваги та мінімізовувати недоліки.

Перелічені напрями гібридизації дають різні шляхи покращення та взаємодії алгоритмів м’яких обчисленнь базових класів, а тому надалі цей розділ кваліфікаційної роботи присв’ячено вибору та аналізу базових алгоритмів нечіткої логіки, нейронних мереж та еволюційних численнь та пошуку оптимальної схеми їхнього поєднання в рамках системи психодіагностики на основі даних ЕЕГ[21-24].

2.2 Нечітка логіка

Нечітка логіка(фаззі-логіка, англ., fuzzy logic) була відкрита професором Лотфі Заде в 1965 році на основі теорії нечітких множин як розширення булевої логіки. Теорія нечітких множин є узагальненням класичної теорії множин і вводить поняття ступеня істинності під час перевірки умови належності, що дозволяє їй оперувати значенням, відмінними від абсолютно істинного чи хибного. Такий підхід забезпечує вищу гнучкість для формальних умовиводів, оскільки враховує неточність та невизначеність, характерні для понять, якими оперує людський розум[24,25].

Однією з головних переваг нечіткої логіки для формалізації людських міркувань є її органічний зв’язок з природною мовою. У реальному світі часто зустрічаються ситуації, коли неможливо чітко визначити істинність чи хибність стану, і нечітка логіка забезпечує гнучкість для їх оцінки та обробки з урахуванням неточності та невизначеності реального фізичного світу.

Нечіткий підхід Заде базується на ідеї, що концепція абсолютної істинності чи хибності є занадто обмеженою в умовах реального світу. Нечітка логіка допускає часткові істини, коли твердження може бути частково істинним або хибним, а не повністю істинним або хибним. Це дозволяє створювати моделі здатні більш точно відображати реальні процеси. Нечітка логіка знаходить широкий діапазон застосувань, таких як системи керування, обробка зображень, обробка природної мови, медична діагностика та дослідження штучного інтелекту[25].

Фундаментальною концепцією нечіткої логіки є функція належності, яка

визначає ступінь входження вхідного значення до певного набору або категорії. Ця функція відображає вхідне значення на ступінь належності між 0 і 1, де 0 означає відсутність членства, а 1 — повне членство, в той час як у булевій логіці 1 представляє абсолютну істиність, а 0 — абсолютну хибність[24,25].

Для реалізації цього підходу використовуються нечіткі правила, що являють собою оператори "ЯКЩО-ТО". Вони виражають зв’язок між вхідними та вихідними змінними нечітким способом. Результатом роботи системи є нечітка множина, що є сукупністю ступенів належності для кожного можливого вихідного значення.

В рамках кваліфікаційної роботи нечітка логіка виглядає ідеалним математичним механізмом для психодіагностики на основі ЕЕГ даних, оскільки її концепція невизначеності відповідає сучасній спектральній класифікації психічних розладів. Завдяки своїй здатності працювати з неточними та неповними даними, нечітка логіка має забезпечити гнучкий підхід до встановлення діагнозу в кінцевій системі. Однією з головних функцій нечіткої логіки в системі, що розроблюється заплановано використання вивчених нейронною мережею нечітких правил для діагностики захворювань, так як для її використання в чистому вигляді необхідні високі експерні знання та відповідні дослідження в галузі медицини і відносяться не до інженерії, а до клінічної практики. Після навчання нейронної мережі на великому обсязі ЕЕГ даних, система нечіткого виводу має бути здатна виявляти паттерни та аномалії, що свідчать про наявність психічних захворювань. На основі цих виявлених закономірностей формується набір нечітких правил, які відображають зв'язок між вхідними (сигналами ЕЕГ) та вихідними (ймовірними діагнозами) змінними.

Нечітка логіка дозволяє системі працювати в умовах невизначеності, забезпечуючи адаптивний і гнучкий підхід до діагностики. Наприклад, у випадку коли дані пацієнта неповні або нечіткі, система все одно зберігає здатність до обґрунтованих висновків на основі наявних даних завдяки використанню нечітких множин та операцій над ними. Така особливість системи значно підвищує ефективність і надійність діагностичного процесу.

Крім того, нечітка логіка дозволяє враховувати різні ступені належності до

певних класів, забезпечуючи більш точне моделювання медичних процесів. Якщо який-небудь параметр ЕЕГ сигналу виражає певний ступінь належності для характерного паттерну конкретного психічного захворюваня, наприклад шизофренії, гібридна нечітка система враховує цю інформацію при встановленні кінцевого діагнозу. Важливою перевагою нечіткої логіки є використання правил, сформульованих природною людською мовою. Це відкриває шлях до створення інтуїтивно більш зрозумілих моделей, що легше інтегруються в клінічну практику.

Отже, нечітка логіка, завдяки своїй здатності працювати з неточними та неповними даними, забезпеченню гнучкого та адаптивного підходу до моделювання складних систем обрана основою проектованої системи психодіагностики. Тут використання нечіткої логіки дозволяє підвищити ефективність встановлення діагнозів, враховуючи різноманітність і невизначеність медичних даних за умови правильного вибору правила нечіткого виводу. Надалі необхідно розглянути конкретний варіант реалізації нечіткої моделі в рамках поточної кваліфікаційної роботи.

Нечітка модель в проектованій системі базується на правилі Такагі-Сугено. Вибір цього правила як основи системи обумовлено його здатністю ефективно обробляти як лінійні, так і нелінійні залежності між вхідними і вихідними змінними. Основним фактором є відсутність дефазифікація вихідного значення у лінгвістичну змінну, на відміну від правила Мамдані, що дає змогу отримати більш точний діагноз. Правило Такагі-Сугено дозволяє моделювати складні системи з високою точністю, використовуючи математичні функції для опису наслідків нечітких правил. Це забезпечує гнучкість і точність моделі, що є критично важливим для розробленої системи діагностики психічних захворювань. Крім того, правило Такагі-Сугено передбачає відносно легку інтеграцію з нейронними мережами, що підвищує загальну ефективність та адаптивність системи. Надалі розглянемо роботу моделей нечіткого виводу(нечітких моделей) в чистому вигляді, і зокрема роботу моделей, заснованих на правилі Такагі-Сугено[27,28].

Під нечіткою моделлю розуміється модель статичної або динамічної системи, побудова, використання і аналіз якої базується на положеннях теорії нечітких

множин і нечіткої логіки. Для побудови нечіткої моделі необхідно задати наступні основні компоненти: функції приналежності, базу правил нечіткого виводу та алгоритм нечіткого виводу.

Нечітка множина А є сукупністю пар елементів x універсальної множини X і відповідних ступенів належності μ(x), де μ(x) - функція належності, що є характеристикою нечіткої множини. Функція μ(x) приймає значення в деякій лінійно впорядкованій множині. Найбільшого поширення набули трикутна, трапецеїдальна та гаусова функція належності.

Трикутна функція належності визначається трійкою чисел (a, b, c) і формулюється наступним чином:

$$f_{\Delta}=(x;a;b;c)=\begin{cases} 0, & x\leqslant a \\ \dfrac{x-a}{b-a}, & a\leqslant x\leqslant b \\ \dfrac{c-x}{c-b}, & b\leqslant x\leqslant c \\ 0, & c\leqslant x \end{cases}, \qquad (2.1)$$

де *a, b, c* – деякі числові параметри, які набувають довільних дійсних значень, і впорядковані відношенням $a\leqslant b\leqslant c$.

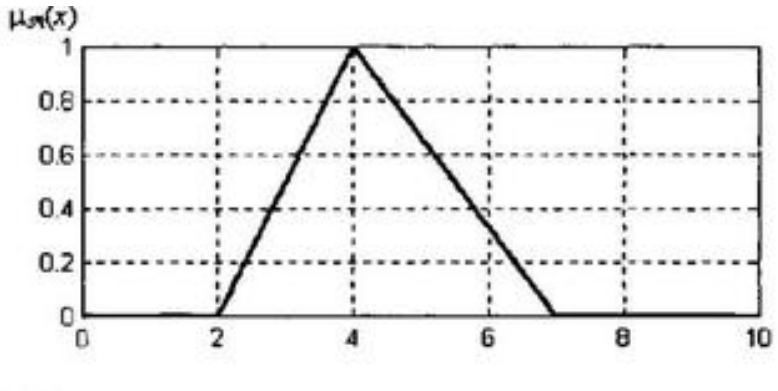

Рисунок 2.2 Графік трикутної функції приналежності[26]

Трапецієподібна функція належності визначається четвіркою чисел (a, b, c, d) і

має наступний вигляд:

$$f_T=(x;a;b;c;d)=\begin{pmatrix} 0, & x\leqslant a \\ \frac{x-a}{b-a}, & a\leqslant x\leqslant b \\ 1, & b\leqslant x\leqslant c \\ \frac{d-x}{d-c}, & c\leqslant x\leqslant d \\ 0, & d\leqslant x \end{pmatrix} \quad (2.2)$$

де *a*, *b*, *c* – деякі числові параметри, які набувають довільних дійсних значень, і впорядковані відношенням $a\leqslant b\leqslant c\leqslant d$.

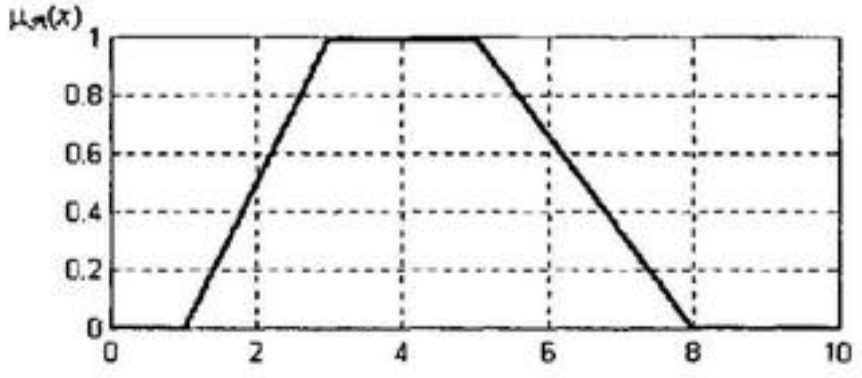

Рисунок 2.3 Графік трапецієвидної функції приналежності[26]

Функції 2.1 та 2.2 є кусково-незалежними та мають 3 та 4 гіперпараметри відповідно, тому для зменшення кількості гіперпараметрів та забезпечення достатньої нелінійності застосуємо гаусову функцію належності, що належить до класу П-подібних функцій.

Гаусова функція належності описується двома параметрами с та σ і має вигляд:

$$f_\gamma(x;\sigma;c)=e^{\frac{(x-c)^2}{2\sigma^2}}, \quad (2.3)$$

де с - координата максимуму;

σ - коефіцієнт концентрації.

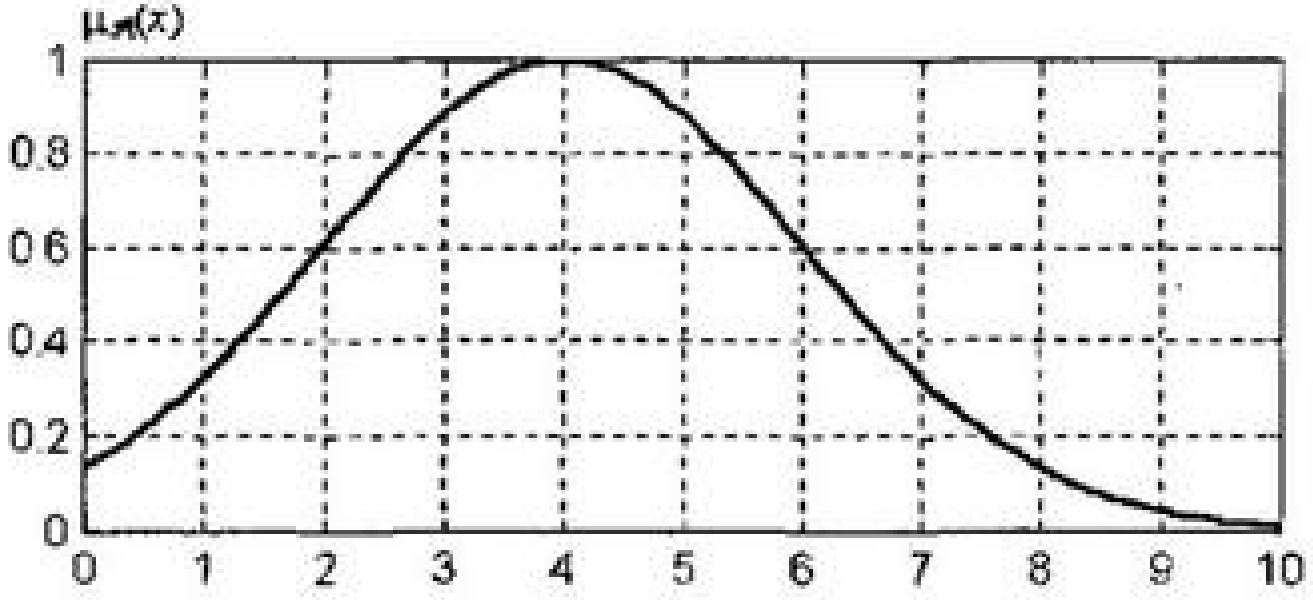

Рисунок 2.4 – Графік гаусової функції приналежності[26]

Іншим типом типом функцій є S- та Z-подібні, серед яких характерним є сигмоїд:

$$f_{\sigma}(\mathrm{x};\mathrm{a};\mathrm{b})=\frac{1}{1+\mathrm{e}^{-(x-b)}}\,, \qquad (2.4)$$

де *a, b* – деякі числові параметри, які приймають довільні дійсні значення.

При цьому в разі коли *a > 0* може бути отримана S-подібна функція належності, а в разі коли *a < 0* буде отримана Z-подібна функція належності.

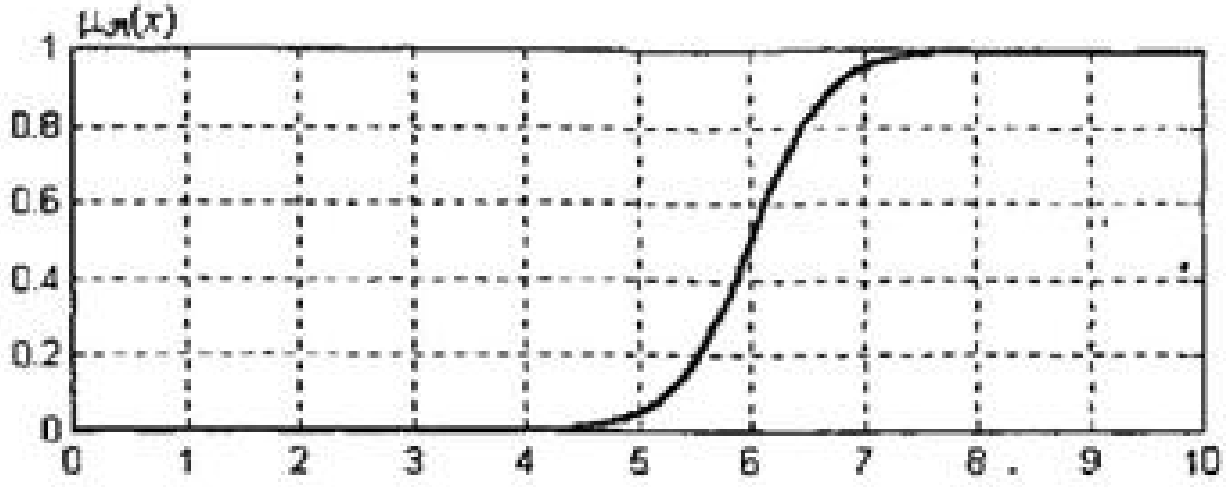

Рисунок 2.5 – Графік сигмоїдальної функції належності[26]

Оскільки подібні функції занадто генералізовані й поділяють простір рішенн занадто розмити(див. рис. 2.5), перевагу при проєктуванні системи надано саме гаусовій функції належності.

Для опису об'єктів і явищ за допомогою нечітких множин використовуються поняття нечіткої і лінгвістичної змінних. Нечітка змінна - це змінна, значення якої може бути наскрізь нечітким, тобто нечіткість допускається в її значеннях (наприклад, "тепла" температура). Лінгвістична змінна - це змінна, значення якої представлені висловами природної людської мови (наприклад, "низький", "середній", "високий" рівень температури). Нечіткий логічний висновок є апроксимацією залежності вихідних змінних на основі лінгвістичних висловлювань (нечітких правил) виду “якщо А, то В”, де А – антецедент (передумова), В-консеквент (висновок) даного правила у вигляді нечітких висловлювань і логічних операцій над нечіткими множинами[28].

Правила нечіткого висновку можна розділити на дві основні групи:

1) Нечіткі лінгвістичні правила, в яких як передумови, так і висновки правил є нечіткими висловлюваннями.
1) Нечіткі правила, в яких передумови правил є нечіткими висловлюваннями, а висновки – чіткими значеннями

Правила нечіткого висновку першого типу виглядають наступним чином:

$$\Pi_i: \begin{matrix} \text{ЯКЩО} x_1 \in A_{i1} \oplus \ldots \oplus x_j \in A_{ij} \oplus \ldots \oplus x_m \in A_{im}, \\ \text{ТО} y_1 \in B_{i1} \oplus \ldots \oplus y_k \in B_{kj} \oplus \ldots \oplus y_p \in B_{ip}, i=1,\ldots,n \end{matrix}, \quad (2.5)$$

де $x_i (j=1,\ldots,m)$ – вхідні змінні, $x_j \in X_j$;

X_j – область визначення відповідного антецеденту;

$y_k (k=1,\ldots,p)$ – нечіткі вихідні змінні, $y_k \in Y_k$;

Y_k – область визначення відповідного консеквенту;

A_{ij}, B_{jk} – лінгвістичні терми, що являють собою нечіткі множини, визначені на X_j и Y_k з функціями приналежності $\mu_{A_{ij}}(x_j) \in [0;1]$ і $\mu_{B_{ik}}(x_k) \in [0;1]$ відповідно.

Базу знань, сформовану нечіткими правилами, можна тлумачити як розбиття простору факторів, що впливають на зони з розмитими межами, всередині яких функція належності приймає нечітке значення. Кількість таких нечітких зон рівняється кількості нечітких правил. Нечіткі правила такого виду є основою нечіткої моделі Мамдані[26].

Для нечіткої правила другого виду можна представити наступним чином:

$$\Pi_i: \begin{matrix} \text{ЯКЩО} x_1 \in A_{i1} \oplus \ldots \oplus x_j \in A_{ij} \oplus \ldots \oplus x_m \in A_{im}, \\ \text{ТО} y = f(x_1,\ldots,x_j,\ldots,x_m), i=1,\ldots,n \end{matrix}, \quad (2.6)$$

де $y = f(x_1,\ldots,x_j,\ldots,x_m)$ – функція, що має однакову для всіх *n* правил структуру і розрізняється лише параметрами для кожного правила.

Нечіткі правила даного виду є основою нечіткої моделі Такагі-Сугено. Найбільш широке практичне застосування знайшов варіант використання лінійної функції (такий спосіб відомий також як нечітка модель Такагі-Сугено першого порядку):

$$\Pi_i: \begin{matrix} \text{ЯКЩО} x_1 \in A_{i1} \oplus \ldots \oplus x_j \in A_{ij} \oplus \ldots \oplus x_m \in A_{im}, \\ \text{ТО} y = k_{i0} + k_{i1} x_1 + \ldots + k_{ij} x_j + \ldots + k_{im}, i=1,\ldots,n \end{matrix}, \quad (2.7)$$

де $k_{ij} (j=1,\ldots,m)$ – коефіцієнти аргументів функції;

k_{i0} – зміщення.

Крім того, часто використовується нечітка модель Такагі-Сугено нульового порядку:

$$\Pi_i: \begin{matrix} \text{ЯКЩО} x_1 \in A_{i1} \oplus \ldots \oplus x_j \in A_{ij} \oplus \ldots \oplus x_m \in A_{im}, \\ \text{ТО} y = k_i, i = 1, \ldots, n \end{matrix}, \qquad (2.8)$$

де k_i- константа.

Для побудови бази правил нечіткого виведення, як правило, використовується експертна інформація. При цьому для формування нечітких висловлювань в передумовах і висновках нечітких правил попередньо повинні бути задані функції належності відповідних нечітких множин[27].

Алгоритми нечіткого логічного висновку розрізняються головним чином видом використаних нечітких правил, логічних операцій та методу дефазифікації.

У загальному вигляді структуру моделі нечіткого висновку наведено на рис. 2.6.

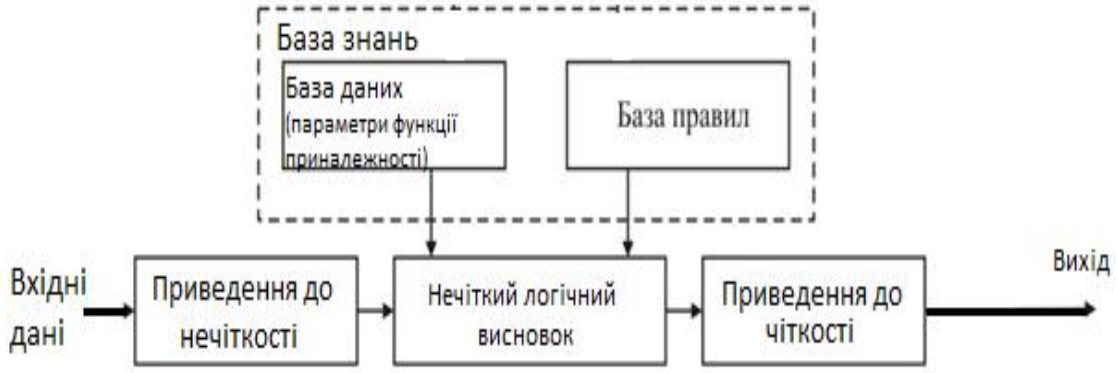

Рисунок 2.6 Узагальнена модель нечіткого висновку[26]

Узагальнений алгоритм нечіткого виводу має наступний вигляд:

1) Фазифікація (приведення до нечіткості) – встановлення відповідності між чисельним значенням вхідної змінної системи нечіткого висновку і значенням функції приналежності відповідного терма лінгвістичної змінної;
2) Агрегування ступеня істинності передумов правил – визначення ступеня

істинності умов по кожному з правил системи нечіткого висновку;

3) Активізація висновків правил – знаходження ступеня істинності кожного з елементарних логічних висловлювань;
4) Акумулювання активізованих висновків правил – знаходження функції приналежності для кожної з вихідних лінгвістичних змінних;
5) Дефазифікація (приведення до чіткості) – перехід від функції приналежності вихідної лінгвістичної змінної до її чіткого (числового) значення.

Існують правила нечіткого висновку Мамдані, Такагі-Сугено-Канга, Ларсена, Цукамото. Найбільшого поширення набули нечіткі моделі Мамдані та Такагі-Сугено. В рамках поточної кваліфікаційної роботи обрано модель Такагі-Сугено з причин, описаних вище. Цей алгоритм забезпечує виведення діагнозів на основі даних ЕЕГ, використовуючи гнучкість і адаптивність нечіткої логіки[26].

2.3 Нейро-нечіткі мережі

Нечіткі моделі, такі як Такагі-Сугено, у чистому вигляді мають обмежену здатність автоматично адаптуватися до нових даних і виявляти складні нелінійні залежності, що знижує ефективність їхнього застосування у системах зі складними залежностями. Нейро-нечіткі мережі, з іншого боку, здатні навчатися на основі вхідних даних, що дозволяє їм налаштовувати свої параметри автоматично та забезпечує вищу точність і гнучкість моделювання. Це робить нейро-фаззі системи набагато більш ефективними для використання у складних динамічних системах, де необхідно враховувати велику кількість змінних та їхню взаємодію одне з одним.

Використання нейронної мережі для адаптації нечітких систем базується на здатності нейронних мереж навчатися на основі існуючих даних і знаходити складні закономірності. Нейро-нечіткі мережі налаштовують параметри функцій належності та інших компонентів системи, що забезпечує точний і надійний процес діагностики. Це стає можливим завдяки гібридному підходу, що дозволяє нейронним мережам використовувати адаптивні можливості для коригування параметрів у режимі реального часу[23].

Нейро-нечітка гібридизація дозволяє системам поєднувати переваги обох підходів м’яких обчисленнь: здатність нейронних мереж навчатися на основі даних та здатність нечіткої логіки працювати з неточними та неповними даними. Для діагностики психічних захворювань на основі ЕЕГ-даних, де часто доводиться мати справу з неоднозначною або неповною інформацією особливо ефективною виглядає модель ANFIS.

Нейро-нечітка мережа ANFIS (англ. Adaptive Neuro-Fuzzy Inference System) є різновидом штучної нейронної мережі, заснованої на моделі нечіткого виведення Такагі-Сугено. Ця архітектура поєднує в собі одночасно принципи як нейронних мереж, так і та нечіткої логіки, що дозволяє використати переваги обох підходів при проєктуванні єдиної гібридної системи. Використання ANFIS дозволяє одночасно зберігати здатність моделі до адаптації та навчання, характерну для нейронних мереж, при цьому враховуючу мінливість та невизначеність данних, що є перевагою нечіткої логіки[29,30].

Нейро-нечітка мережа ANFIS цінна у системах психодіагностики завдяки високій точності та гнучкості. Однією з головних переваг використання ANFIS є можливість навчання нейронної мережі для адаптації нечітких систем. Це дозволяє автоматично налаштовувати параметри функцій належності та інших компонентів системи на основі даних навчання, що покращує здатність системи до точного та надійного діагностування психічних захворювань на основі ЕЕГ-даних.

При аналізі ЕЕГ нейро-нечітка мережа ANFIS використовуватися в рамках гібридної системи для ідентифікації та класифікації патернів мозкової активності. Враховуючи складність і багатовимірність сигналів ЕЕГ, ANFIS дозволяє ефективно обробляти дані та виділяти ключові ключові маркери біоелектричної активності, що пов'язані з різними психічними розладами. Завдяки здатності адаптуватися до нових даних, ANFIS з часом може покращувати точність діагностики, враховуючи нові патерни та зміни в мозковій активності. Завдяки використанню нечіткої логіки, система може приймати рішення на основі неточних або часткових даних, що є особливо важливим у медичних системах, де повнота і точність даних бувають обмеженими. Такі фактори роблять ANFIS перспективним інструментом для аналізу

ЕЕГ у психодіагностиці та зумовлюють вибір саме цього алгоритму для застосування в гібридній системі, що розробляється в рамках поточної кваліфікаційної роботи[29].

Логічно система ANFIS відповідає набору нечітких правил типу "ЯКЩО-ТО", які мають здатність навчатися для апроксимації нелінійних функцій. ANFIS є універсальним апроксиматором, здатним досягати високої точності в різних умовах.

Структурно модель являє собою багатошарову нейронну мережу прямого поширення без зворотних зв'язків[30], у якій використовуються чіткі сигнали, ваги і функції активації (нечіткі нейрони не використовуються і є характерними для іншого способу нейро-нечіткої гібридизації, а саме реалізації нечітких функції в рамках нейронів спеціального виду). Виконання внутрішніх операцій ANFIS засновано на використанні Т-норми та Т-конорми[31].

Т-норма (Т) дозволяє моделювати операцію перетину нечітких множин і визначається як:

$$T(a,b)=a\odot b\ , \qquad (2.9)$$

Т-конорма (S) використовується для моделювання об'єднання нечітких множин і визначається як:

$$S(a,b)=a\oplus b, \qquad (2.10)$$

При цьому значення входів, виходів і ваг гібридної нейронної мережі являють собою дійсні числа в діапазоні [0, 1]. Такий підхід забезпечує гнучкість і точність моделювання, дозволяючи адаптувати систему до різних умов та вхідних даних.

ANFIS представляє собою багатошарову мережу з прямим розповсюдженням сигналу, що реалізовує алгоритм нечіткого висновку Такагі-Сугено для n вхідних змінних, описаних m нечіткими множинами з гауссовими функціями належності; однієї вихідної змінної і m^n нейронами у прихованих шарах 2 – 4, де m^n максимальна кількість правил нечіткого висновку(рис. 2.7).

ANFIS складається з п'яти шарів, кожен з яких виконує певні функції:

1) шар фазифікації;
2) шар активації правил;
3) шар нормалізації;
4) шар висновків;
5) шар дефазифікації.

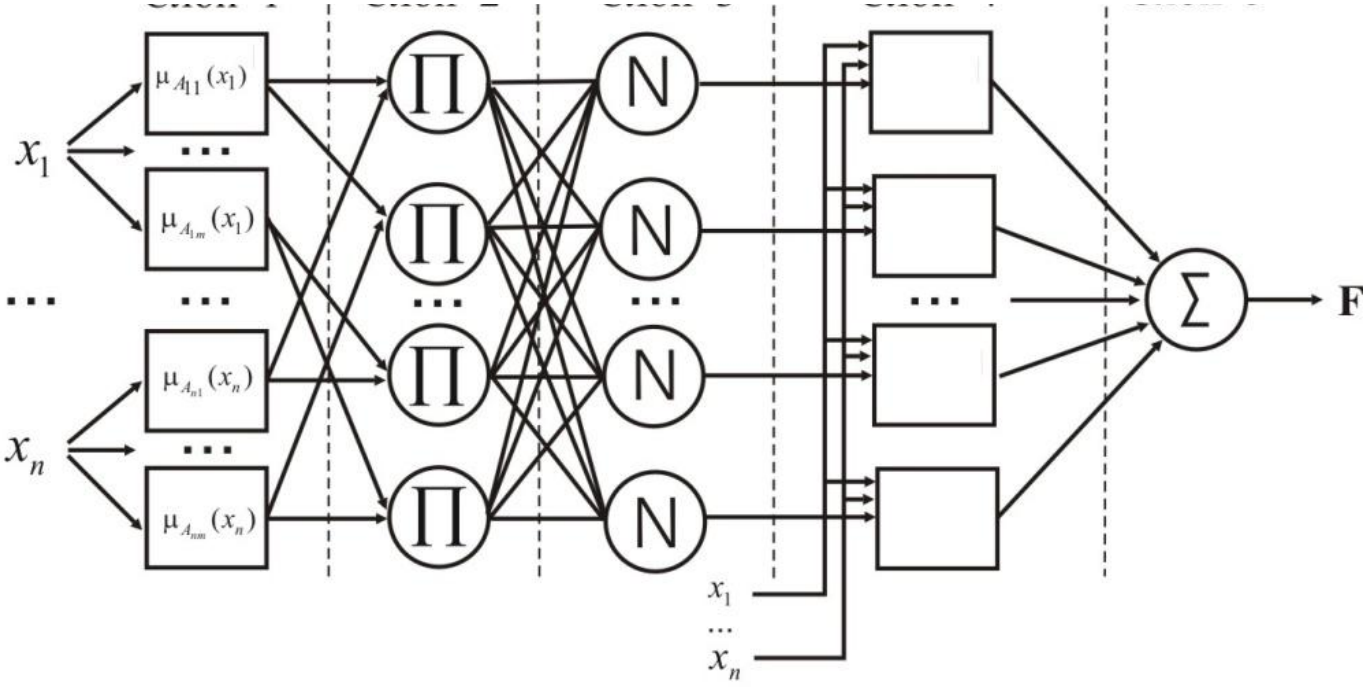

Рисунок 2.7 – Структура нейро-нечіткої мережі виду ANFIS[29]

Перший шар архітектури виконує функцію введення нечіткості. Виходи нейронів цього шару представляють значення гаусових функцій належності для вхідних змінних x_t (формула 2.11).

$$\mu_{A_{tj}}(x_t) = \exp\left[-\left(\frac{x_t - c_{tj}}{\sigma_{tj}}\right)^2\right], \qquad (2.11)$$

де $t=1,\ldots,n; j=1,\ldots,m$.

Нейрони другого шару виконують множення вхідних сигналів і слугують для формування ваги правила:

$$w_i = \prod_{j=1}^{m} \mu_{A_{ij}}(x_t), i = 1, \ldots, m^n, \quad (2.12)$$

де m^n – кількість нечітких правил.

Кожен і-й нейрон у третьому шарі слугує для обчислення відношення ваги правила *i* до суми ваг всіх правил:

$$\overline{w}_i = \frac{w_i}{\sum_{i=1}^{m^n} w_i}, i = 1, \ldots, m^n. \quad (2.13)$$

Четвертий шар мережі ANFIS реалізує функцію активації нейронів, кожен нейрон в ньому описується виразом:

$$\overline{w}_i f_i = k_{i0} + k_{i1} x_1 + k_{i2} x_2 + \ldots + k x_n, \quad (2.14)$$

де $k_{ij}, i = 1, \ldots, m^n, j = 0, \ldots, n$ – параметри *i*-го правила Такагі-Сугено першого порядку.

У п’ятому шарі міститься єдиний нейрон, що обчислює загальний вихід мережі як суму вхідних сигналів попереднього шару:

$$F = \sum_{i=1}^{m^n} \overline{w}_i f_i, \quad (2.15)$$

Важливим етапом роботи ANFIS є тренування, що забезпечує її здатність до адаптації та точного моделювання. Процес навчання полягає в налаштуванні параметрів системи на основі наявних даних так, щоб мінімізувати помилку між передбаченими та фактичними значеннями. Традиційно для тренування ANFIS використовується метод зворотнього поширення.

Метод зворотного поширення помилки є одним із найбільш поширених і найбільш ефективних алгоритмів навчання штучних нейронних мереж, особливо багатошарових перцептронів, згорткових та рекуретих мереж. Завдяки цьому методу нейронна мережа має можливість поступово мінімізувати функцію помилки, тобто відхилення між передбачуваним виходом і реальним результатом. Це досягається через корекцію ваг нейронів у зворотному напрямку, починаючи з вихідного шару і закінчуючи вхідним шляхом розрахунку впливу похибок, які оцінюються за результатами кожного прямого поширення тренувальних данних. Таким чином нейронна мережа навчається з кожним етапом, адаптуючи свої параметри для досягнення максимальної точності в процесі обробки даних і передбачень результатів[30,31].

Реалізація алгоритму зворотнього поширення виглядає наступим чином:

1) Вибір з множини тренувальних даних чергової пари $(x(i), y(i))$, $i=\overline{1,P}$ та подання на вхід мережі сигналу x(i);
2) Обчислення реакції мережі y(i);
3) Порівняння отримної реакції y(i) з необхідною $y(i)$ та визначення помилки $y(i) - y(i)$;
4) Корегування мережі таким чином, щоб помилка мінімізувалась між ітераціями;
5) Поторення кроків 1-4 для всієї множини вхідних даних допоки помилка не досягне необхідного порогу.

Схематично роботу алгоритму на прикладі багатошарового парсептрону зображено на рисунку 2.8.

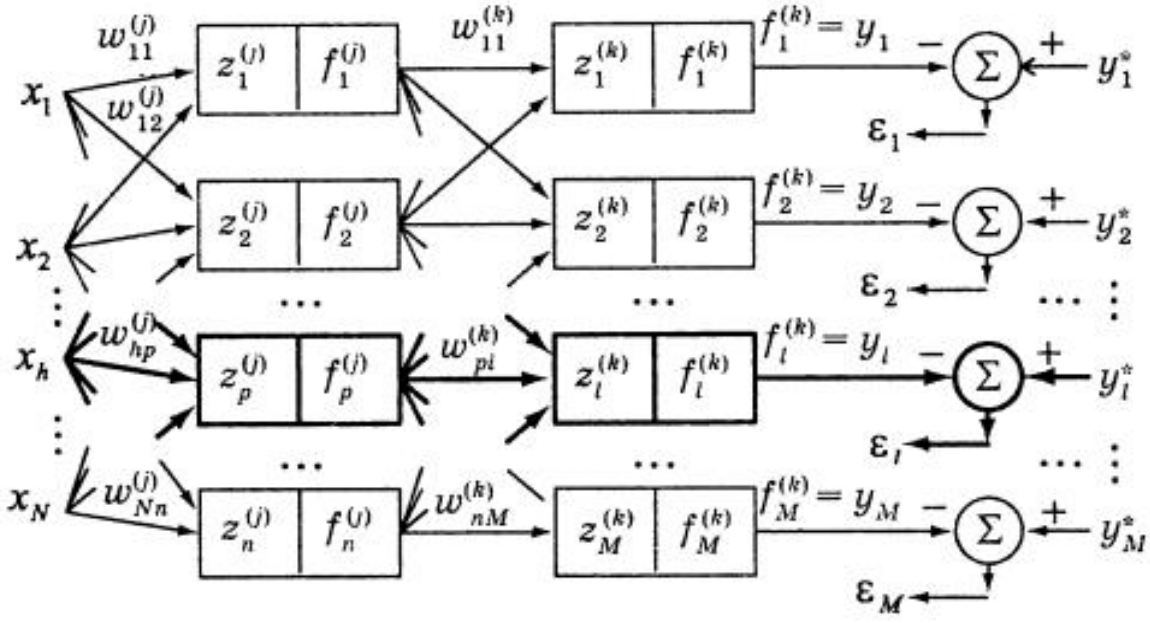

Рисунок 2.8 Схема роботи алгоритму зворотнього поширення[32]

де $w^{(k)}_{pl}$- вага зв’язку р-го нейрона попереднього шару j з l-м нейроном наступного шару k;

$f^{(j)}_{p}$- активаційна функція p-го нейрону i-го шару;

$z^{(j)}_{p}$- зважена сума вихідних сигналів попереднього i-го шару при її надходженні на вхід p-го нейрону наступного шару j.

Для таких моделей як багатошаровий парсептрон та ANFIS алгоритм зворотнього поширення традиційно використовується в парі з градієнтним спуском в якості оптимізаційного алгоритму та квадратичним критерієм якості навчання в якості цільової функції, що виглядає таким чином.Значення помилки ζ_l визначається як:

$$\zeta_l = y_l - f^{(k)}_l, \qquad (2.16)$$

де $y_l = f^{(k)}_l$.

При піднесенні значення помилки до квадрату стає можливим отримати значення градієнту, на що додається до ваг даного шару:

$$\Delta w_{pl}^{(k)} = -\gamma_{pl} \frac{\delta \zeta_l^2}{\delta w_{pl}^{(k)}}, \qquad (2.17)$$

де γ_{pl} – коефіцієнт навчання.

Варто пам’ятати, що в класичній мережі ANFIS тренованими є лише два шари, а саме шар фазифікації та шар дефазифікації, оскільки інші шари не мають змінних параметрів[28].

Одним з недоліків застосування градієнтного спуску для навчання нейронних мереж є застрягання цільової функції мінімізації в локальномому мінімумі, що перешкоджає досягненню оптимального навчання мережі. Популярним способом подолання цієї проблеми є регуляризація шляхом дропауту або додавання штрафів до функції оновлення ваги. Іншим підходом є відмова від градієнтного спуску і використання інших класів оптимізаційних алгоритмів, не схильних до застрягання в локальному оптимумі, таких як еволюційні числення[22].

2.4 Еволюційні алгоритми

Еволюційні обчислення є підвидом м’яких обчислень і широко застосовуються для вирішення складних оптимізаційних задач. Їхнє використання виправдане для розв’язання проблем занадто високої розмірності для оптимізації традиційними алгоритмами. До еволюційних алгоритмів належать численні підвиди, такі як генетичні алгоритми, еволюційне програмування, моделі ройового інтелекту та імунні обчислення. Як зрозуміло із назви, алгоритми цього класу переважно натхненні біологічними процесами, що робить їх ефективними у предметних областях, що не підкоряються детерміністичним законам або де такі закони ще не виявлені. Еволюційні алгоритми беруть свій початок у теорії ймовірності, біології, антропології чи соціології та розроблені для ефективної роботи в умовах невизначеності та складності. Застосування таких алгоритмів охоплює різні галузі, зокрема й психіатрію та психологію, до якої відноситься об’єкт поточної

кваліфікаційної роботи.

Генетичні алгоритми є метаевристиками пошуку, що вирішують проблеми оптимізації, використовуючи концепцію природного відбору. Генетичний алгоритм неодноразово змінює популяцію окремих рішень, вибираючи кращих індивідів для створення наступного покоління. Протягом кількох поколінь популяція «еволюціонує» до оптимального рішення. Такий підхід є ефективним в задачах, де цільова функція є розривною, недиференційованою, стохастичною або сильно нелінійною[33,34].

Іншим підкласом еволюційних алгоритмів, значною мірою подібним до генетичних є імунні алгоритми(CLONALG), що імітують принципи роботи біологічної імунної системи. Вони використовують механізми виявлення, розпізнавання та запам'ятовування антигенів для розв'язання задач оптимізації та класифікації. Завдяки здатності до адаптації та навчання, імунні алгоритми також ефективно знаходять рішення у складних просторах пошуку, але часто включають додаткові кроки для оптимізації процесу навчання, як наприклад клональна та мережева супресія у штучних імунних системах[35,36].

Використання еволюційних обчислень, таких як генетичні або імунні алгоритми в гібридних системах діагностики психічних захворювань на основі даних ЕЕГ несе значний потенціал для підвищення точності мережі шляхом кращої оптимізації ваг нейро-нечіткої мережі, порівняно зі зворотнім поширенням[37]. Еволюційні алгоритми потенційно можуть покращити здатність ANFIS до класифікації шляхом уникнення застрягання градієнту в локальному мінімумі, що часто є проблемою в традиційних методах оптимізації ваг. Таким чином, інтеграція генетичних або імунних алгоритмів у гібридну систему діагностики психічних захворювань на основі даних ЕЕГ є доцільною через перспективу покращення точності діагностики і підвищення адаптивності системи до змін у симптомах пацієнтів. Поточна аргументація говорить про виправданість використання як генетичних, так і імунних алгоритмів, тому вибір конкретного кінцевого підходу потребує подальшого аналізу обох варіантів.

Суть генетичного алгоритму полягає в циклічній заміні однієї популяції

рішень на наступну, яка є більш пристосованою для вирішення поставленої задачі. Популяція складається з індивідів. Кожен індивід представляє рішення в просторі пошуку для поставленої задачі. Кожна особина кодується як вектор компонентів кінцевої довжини, що в термінології генетичних алгоритмів іменується хромосомою. Компоненти вектора хромосоми іменуються генами. Для оцінки пристосованості особини використовується фітнес-функція (критерій оптимізації). Фітнес-функція визначає ступінь придатності індивіда до розмноження (здатність конкурувати з іншими особами) на основі чого отримується імовірність того, що особина буде обрана для відтворення[33,34].

Робота ГА базується на наступних операторах:

1) оператор відбору;
2) оператор кросинговеру;
3) оператор мутації.

Оператор відбору має на меті вибір індивідів з високою пристосованістю для подальшого схрещування. Найпростішим варіантом є вирахування фітнесс-функціїї для всіх наявних хромосом та відібрати *n* особин з найкращим значенням функції.

Відбір двох або більше хромосом для отримання потомства зазвичай здійснюється випадковим пропорційним чином, а вірогідність відбору описується як:

$$P(i)=\frac{f(x_i)}{\sum_{j=1}^{N} f}(x_j), \qquad (2.18)$$

де P(i) — ймовірність вибору індивіда x_i;

$f(x_i)$ — функція пристосованості для індивіда x_i;

N — загальна кількість індивідів у популяції.

Оператор кросинговеру поєднує гени двох предківських індивідів для створення нових нащадків. Для кожної пари предків випадковим чином вибирається одна або кілька точок кросинговеру в межах хромосоми. Після вибору точки кросинговеру гени в цій позиції обмінюються між предками.

Схематично кросинговер для точки p=3 зображено на рисунку 2.9.

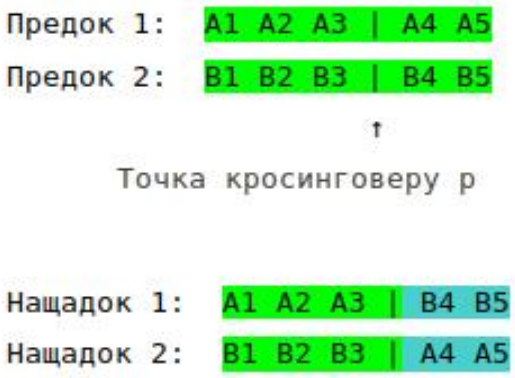

Рисунок 2.9 Приклад кросинговеру

Оператор мутації вводить випадкові зміни в гени нащадків, щоб зберегти різноманітність популяції. В новому потомстві, що утворилося, деякі з генів можуть бути піддані мутації з випадковою ймовірністю. Це означає, що відповідний ген зазнає модифікації. Мутація здійснюється для підтримки різноманітності популяції, запобіганню передчасній збіжності та застряганню в локальному оптимумі.

Рисунок 2.10 Приклад мутації

Узагальнений метод генетичного пошуку можна описати наступними кроками:

1) випадкова ініціалізація популяції P(0) з N індивідів: $P(0)=\{x_1,x_2, \ldots, x_N\}$;

2) оцінка фітнес-функціїдля всіх індивідів у популяції;
3) вибір частини популяції для схрещування;
4) кросинговер (схрещування);
5) мутація;
6) оновлення популяції;
7) перевірка умов завершення, перехід до пункту 2 у їх разі недотримання.

ГА забезпечує ефективний процес оптимізації, дозволяючи знаходити найкращі рішення для складних задач. Завдяки своїй структурі, генетичні алгоритми можуть адаптуватися до різних умов і змін, що робить їх особливо ефективними для задач оптимізації в системах діагностики психічних захворювань.

Генетичний алгоритм потенційно можна замінити алгоритмом клонального відбору, який є специфічним підкласом імунних алгоритмів і базується на принципах біологічної імунної системи. Імунний алгоритм клонального відбору (CLONALG) імітує процеси виявлення, розпізнавання та клонування для досягнення ефективної оптимізації параметрів.

В термінології імунних алгоритмів антиген – завдання, яке необхідно розв'язати, антитіло – конкретне можливе розв'язання даної задачі, популяція антитіл являє собою множину можливих розв'язків, афінність – характеристика, яка кількісно описує силу взаємодії антитіла та антигену.

Афінність обчислюється як Хеммінгова відстань між антитілом і антигеном (число позицій, в яких розрізняються відповідні символи антитіла та антигену):

$$\mathrm{Aff}\left(\mathrm{Ab}_i - \mathrm{Ag}_j\right) = \sum_{l=1}^{L} \delta_l, \qquad (2.19)$$

де $\delta_l = \begin{Bmatrix} 1, \text{if } \mathrm{Ab}_{il} \neq \mathrm{Ag}_{jl} \\ 0 \end{Bmatrix}$.

Значною мірою аналогом антитіл в теорії ГА є хромосоми, гени відповідають епітопам, фітнес-функція – афінності. Втім, повної відповідності між імунними та генетичними алгоритмами немає, оскільки вони базуються на різних біологічних концепціях, і для більш просунутих алгоритмів обох класів аналогія

прослідковується менш яскраво.

Набір імунних операторів клонального відбору загалом подібний до генетичних операторів і включає оператор відбору, оператор мутації, виключає оператор кросинговеру. Відмінністю CLONALG від ГА є наявність оператора клонування.

Оператор клонування створює кілька копій кожного обраного індивіда, звані клонами. Клонування для CLONALG функціонально замінює оператор кросинговеру та дозволяє зберігати та підсилювати кращі розв'язки, на які спирається вся популяція. Під час клонування копії антигенів утворюються без змін або з мінімальними змінами, залежно від конкретної реалізації алгоритму. Клони можуть піддаватися подальшим модифікаціям, таким як мутації, для підтримки різноманітності популяції та оптимізації пошуку розв'язків. Так, оператор клонування допомагає локалізувати області пошуку, де найкращі антитіла демонструють найперспективніші розв'язки, сприяючи швидкій адаптації алгоритму.

Певна відмінність між CLONALG та ГА також є в операторі відбору. Генетичний відбір фокусується на селекції найбільш пристосованих індивідів, рекомбінації генетичного матеріалу предків через кросинговер і мутації для створення різноманітного потомства. Імунний відбір базується на клонуванні високоафінних антитіл і піддання їх мутації для посилення отриманих результатів. Ключова різниця полягає в тому, що генетичний алгоритм акцентує увагу на кросинговері, тоді як клональний відбір—на клональному відборі та мутації клонів.

Основні етапи імунного алгоритму клонального відбору включають:

1) випадкова ініціалізація антитіл;
2) оцінка афінності для всіх антитіл у популяції;
3) вибір антитіл з високою афінністю для клонування;
4) клонування обраних антитіл (створення множинних копій);
5) мутація клонів для підвищення різноманітності;
6) оновлення популяції з урахуванням найкращих клонів;
7) перевірка умови завершення.

Такий процес дозволяє CLONALG ефективно оптимізувати параметри нейронної мережі, аналогічно до генетичного алгоритму. Імунний алгоритм клонального відбору може забезпечити високу точність і надійність діагностичних рішень завдяки своїй здатності до адаптації та навчання[36].

Тренування нейронної мережі ANFIS (Adaptive Neuro-Fuzzy Inference System) за допомогою еволюційних алгоритмів, таких як генетичний алгоритм і імунний алгоритм клонального відбору, дозволяє ефективно оптимізувати параметри системи, підвищуючи точність і надійність моделі. Генетичні алгоритми здатні ефективно знаходити глобальні оптимуми завдяки еволюційному процесу селекції, кросинговеру та мутації, що дозволяє уникнути застрягання в локальному оптимумі, одночасно зберігаючи простоту в реалізації завдяки універсальності їх застосування. Імунні алгоритми, з іншого боку, підвищують адаптивність навчання через клональнуванню, що дозволяє алгоритму швидко підлаштовуватися під змінні умови, зосереджуючись на областях простору рішеннь, де знаходяться найкращі розв'язки поставленої задачі, підвищують точність вихідної моделі шляхом виділення клонів високопристосованих антитіл і мають високий рівень адаптивності, що сприяє підвищенню загальної точності нейро-нечіткої мережі[37].
Таким чином, обидва алгоритми мають свої сильні сторони, які можна використовувати для ефективного тренування ваг нейро-нечіткої мережі, особливо в умовах обмеженої кількості тренованих шарів. Втім, через простоту генетичного алгоритму та більші обчислювальні витрати клонального відбору через оператор клонування, для використання в гібридній системі психодіагностики на основі ЕЕГ обрано саме ГА[38].

2.5 Гібридна система псіходіагностики

Вище в кваліфікаційній роботі було проведено огляд існуючих стратегій гібридизації м'яких обчисленнь, та здійснено їхній аналіз, на основі чого було обрано наступні алгоритми для використання в кінцевій діагностичній системі - нейро-нечітка мережа ANFIS, що поєднує переваги нейронних мереж та правила нечіткого виводу Такагі-Сугено та класичний генетичний алгоритм. Було визначено сильні та слабкі сторони такого рішення для використання в гібридній системі психодіагностики на основі ЕЕГ.

Переваги такої комбінації полягають у здатності ANFIS обробляти нечіткі дані та виявляти складні залежності між вхідними параметрами, що є критично важливим для аналізу психоемоційного стану. Нечітка логіка дозволяє моделювати людське мислення, що робить систему більш інтуїтивно зрозумілою. ГА забезпечує ефективну оптимізацію параметрів моделі, що дозволяє уникнути проблем, пов'язаних із локальними мінімумами, характерними для традиційних методів навчання нейронних мереж, таких як зворотнє поширення з градієнтним спуском.

В той же час існує ряд недоліків, вплив яких менший порівняно з альтернативними варіантами. По-перше, обчислювальна складність генетичного алгоритму вища, ніж у зворотнього поширення, особливо при великій кількості поколінь та популяцій, проте нижча ніж у клонального відбору. По-друге, ANFIS, хоча і є потужним інструментом, може бути чутливим до вибору форми функцій приналежності, що впливає на загальну точність системи.

Схема поєднання алгоритмів м’яких обчисленнь у рамках єдиної системи передбачає, що нейронна мережа ANFIS використовується для вивчення нечітких правил та пошуку параметрів функцій приналежності. Для тренування нейронної мережі замість традиційного алгоритму зворотного поширення помилки застосовується генетичний алгоритм, здатний уникати локальні оптимуми.

Схематично гібридну систему зображено на рис. 2.11.

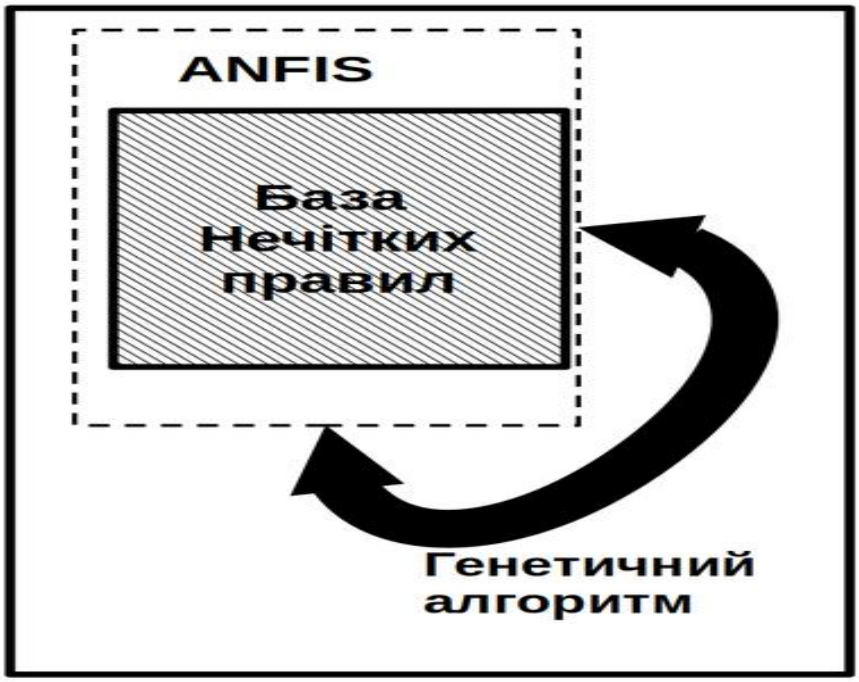

Рисунок 2.11 Схема гібридної системи психодіагностики на основі ЕЕГ

У даній системі хромосомами (або антитілами в термінології імунних обчислень) є вагами нейронних шарів нейро-нечіткої, що зводить генетичний пошук до мультицільової оптимізації. Кожна ціль відповідає оптимізації ваг окремого шару нейронної мережі. Оскільки ANFIS має всього п’ять шарів, з яких необхідно тренувати лише два, кількість цілей обмежується двома, що значно спрощує процес оптимізації порівняно з тренуваням глибоких нейронних мереж за допомогою, коли кількість шарів, а отже й цілей може доходити до десятків та сотень і використання генетичного алгоритму економічно менш доцільне через значні обчислювальні витрати. Оскільки база нечітких правил системи фактично являє собою лише ваги нейронної мережі, то на етапі інференсу необхідно лише подати дані на вхід ANFIS й здійснити пряме поширення. Етап тренування також аналогічний звичайному тренуванню нейронної мережі, з тією відмінністю, що оптимізація здійснюється шляхом застосування генетичного алгоритму.

Варто зазначити, що в рамках поточної кваліфікаційної роботи розробляється лише гібридна система, здатна підтвердити властивості обраного підходу, а отже пропонується найбільш базове рішення.

3 ЕКСПЕРИМЕНТАЛЬНА ЧАСТИНА

3.1 Постановка експерименту

Для дослідження точності та ефективності запропонованої гібридної нейро-нечіткої еволюційної системи діагностики психічних порушень на основі даних ЕЕГ необхідно провести експериментальне дослідження. Це дозволить виявити, наскільки доцільним є запропоноване рішення у порівнянні з існуючими методами. Для всебічної та повної оцінки необхідно провести як тестування гібридної системи, так і її складових алгоритмів, а також класичних алгоритмів для отримання еталонних значеннь. Це дозволяє визначити переваги та недоліки кожного підходу, а також знайти можливості для подальшого покращення.

Таким чином, на реальних даних мають бути протестовані три групи алгоритмів: гібридна система, її складові частини, та класичні методи машинного навчання. На основі аналізу результатів мають бути зроблені обґрунтовані висновки про доцільність використання кожного з алгоритмів у практиці діагностики психічних розладів та всієї системи в цілому а також визначити вектор розвитку системи до стану SOTA.

Першу групу складають класичні алгоритми машинного навчання. До цієї групи включено метод опорних векторів(SVM), логістичну регресію, алгоритм k-найближчих сусідів(kNN), а також XGBoost, алгоритм випадкових лісів як приклад ансамблевих технік.

Другу групу формують алгоритми, що так чи інакше складають основу гібридної моделі та відносяться до трьох типів м’яких обчисленнь, що розглядались в розділі 2 поточної кваліфікаційної роботи. Сюди входить простий багатошаровий парсептрон (MLP, англ. Multy-Layer Parceptron) з одним прихованим шаром з 64 нейронів як приклад нейронних мереж, дійсний негативний відбір (RNSA, англ. Real Negativ Selection Algorithm). Як приклад нечіткої моделі, а також нейронної мережі тестується ANFIS. Як представники еволюційних обчисленнь обрані генетичний

алгоритм та CLONALG, що здійснюють оптимізовацію модифікованого для класифікації алгоритму к-середніх(k-means). Щодо модифікації k-means, в хромосомах або антитілах закодовано координати центрів кластерів для контрольних здорових пацієнтів та хворих на шизофренію. В якості фітнес-функції чи функції афінності використовується середнє арифметичне відстані центроїда до всіх семплів відповідного класу, що задає еволюційним алгоритмам додаткову умову асоціювати кластери з наперед заданими класами та уникнути застосування алгоритмів асоціації для відновлення класів після етапу тренування. Це переводить навчання даної модифікації k-mean з класу навчання без учителя, до навчання з учителем та наближає її певною мірою до алгоритму k-найближчих сусідів[38].

Третя група являє собою гібридні моделі. До неї включено нейро-нечітку еволюційну систему, що складається з мережі ANFIS, оптимізованої генетичним алгоритмом. Для чистоти експерименту також в цю групу додано багатошаровий парсептрон, що оптимізується генетичним алгоритмом. В таблиці 3.1 узагальнено використані алгоритми та їхні гіперпараметри.

Таблиця 3.1. Тестовані алгоритми та їхні гіперпараметри

Група	Алгоритм	Параметри
1	2	3
Класичні алгоритми	SVM	Стандартні значення реалізацій з бібліотеки scikit-learn
	Логістична регресія	
	kNN	
	Випадковий ліс	
	XGBoost	
	MLP	1 прихований шар, 64 нейрони
	RNSA	N=1000, r=0.05, r_s=0.01, алгоритм V-detector
	ANFIS	Коефіцієнт навчання ζ = 0.05

Продовження таблиці 3.1. Тестовані алгоритми та їхні гіперпараметри

1	2	3
М’які отчисления	Генетичний алгоритм + KNN	Випадкова мутація з вірогідністю 50%, 50 індивідів в популяції, відбір половини предків для кросинговеру або клонування, 100 генерацій
	Clonalg + KNN	
Гібридні алгоритми	MLP + Генетичний алгоритм	Випадкова мутація з вірогідністю 50%, 20 індивідів в популяції, відбір 5 предків для кросинговеру , 10 генерацій

В якості метрик для порівняння в поточному експерименті використано точність(англ. accuracy) та прецизійність(англ. precision), а також продемонстровано час тренування моделей з іллюстративною метою. Метрики точності та прецизійності є показниками для оцінки якості класифікаційних моделей. Значення часу мають лише відносний сенс, оскільки досягнення максимальної абсолютної ефективності не є не обхідним для демонстрації властивостей гнучкості та адаптивності, також час залежить від конкретного апаратного забезпечення, на якому проводились тести.

Точність (A) визначає, яка частина всіх передбачень моделі є правильними та обчислюється за формулою:

$$A=\frac{TP+TN}{TP+TN+FP+FN}, \qquad (3.1.1)$$

де TP (True Positives) — кількість правильних позитивних передбачень;

TN (True Negatives) — кількість правильних негативних передбачень;

FP (False Positives) — кількість неправильних позитивних передбачень;

FN (False Negatives) — кількість неправильних негативних передбачень.

Прецизійність (P) показує, яка частина позитивних передбачень є

правильними та обчислюється за формулою:

$$P=\frac{TP}{TP+FP}, \qquad (3.2.1)$$

Всі алгоритми оцінено за допомогою 5-кратної випадкової кросвалідації, зі співвідношенням випадково обраних тренувальних та тестових даних відповідно 80% та 20% на кожній ітерації.

3.2 Вхідні данні

В якості тренувальних даних використано датасет, зібраний в рамках дослідження ЕЕГ методами штучного інтелекту[19]. Датасет складається з ретроспективно зібраних медичних записів, що включають показники IQ та характеристики квантитативної ЕЕГ у стані спокою від 945 суб’єктів. Вибірка сладається з даних 850 хворих із серйозними психічними розладами (шість великих категорійних та дев’ять специфічних розладів) та 95 здорових контрольних пацієнтів, зібрані з 2011 по 2018 роки в медичних установах Південної Кореї. Параметри qEEG складаються зі значень спектральної густини та функціонального зв’язку для δ-, θ-, α-, β-, та γ-ритмів.

Серед недоліків використання класичних алгоритмів машинного навчання на обраному датасеті основними є відсутність контролю впливу ліків, супутніх патологій та тяжкості розладу на результат аналізу, а також його ретроспективних характер. Одним з шляхів подолання зазначених обмежень існуючих підходів є підвищення адаптивності використовуваних алгоритмів, що й досягається запропонованою в кваліфікаційній роботі гібридною нейро-нечіткою еволюційною системою. Використання еволюційних численнь дає змогу обійти обмеження класичних алгоритмів та потенційно адаптувати аналіз під вхідні данні в режимі реального часу. Для кращого планування поточного експерименту необхідно провести короткий експлоративний аналіз даного датасету.

945 семплів датасету поділяються на шість діагнозів великої категорії та дев’ять специфічних діагнозів: шизофренія (117 входжень), розлади настрою (266 входжень), тривожні розлади (107 входжень), панічний розлад (59 входжень), соціальні тривожні розлади (48 входжень), обсесивно-компульсивний розлад (46, входжень), розлади залежності (186 входжень), а також розлади, пов’язані з травмою та стресом (128 входжень).

Семпли датасету містять наступні ознаки параметри qEEG, а також данні про вік, стать, освіту та IQ. Параметри qEEG складаються зі значень спектральної щільності (PSD, 19 ознак на канал) та функціонального зв’язку (FC, 171 ознака на канал) для δ-, θ-, α-, β-, та γ-ритмів. Таким чином кожен семпл складається з 1144 ознак, що є доволі високою розмірністю для класичних алгоритмів машинного навчання.

Датасет має такий розподіл входжень за класами(рис. 3.1):

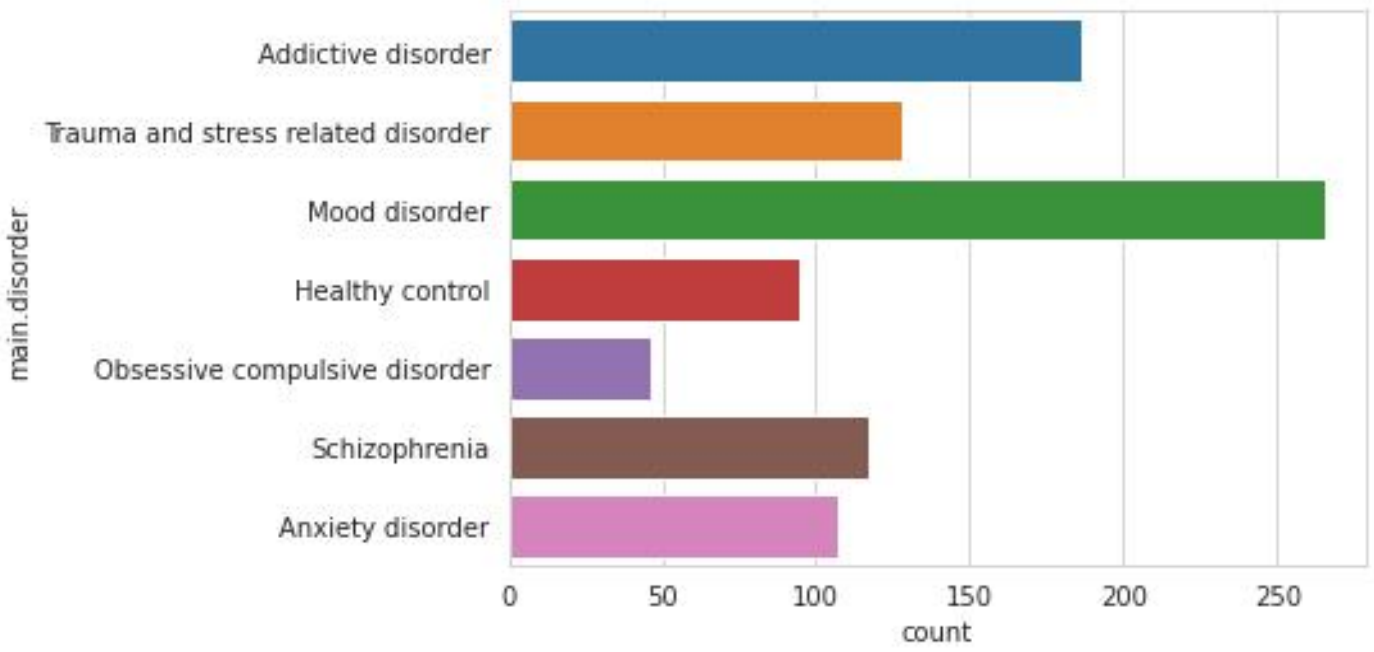

Рисунок 3.1 Розподіл семплів датасету за класами

Як бачимо датасет незбалансований, а тому в таких умовах обмежимось визначенням лише наявності конкретного розладу. Результати авторів датасету

показали, що один з найкращіх результатів за точністю класифікації для розрізнення пацієнтів з діагнозу кожного великого спектру та контрольними пацієнтами зі скоригованим IQ була шизофренія, класифікована згідно альфа PSD, 93,83 ± 5,74%, а отже для досягнення цілей поточної кваліфікаційної роботи оптимальним варіантом оптимальним варіантом проведення експерименту буде бінарна класифікація результатів контрольних здорових пацієнтів, та хворих на шизофренію.

3.3. Експериментальні результати

Всі експерименти проводились з використанням мови програмування Python та бібліотек sklearn, xgboost, aisp, keras/TensorFlow, pandas, PyGAD на базі середовища Jupyter Notebook, наданого платформою Kaggle.

При використанні в якості вхідних ознак PSD альфа-каналу та відомостей про стать, вік і IQ (22 ознаки), як найбільш інформативних для діагностики шизофренії було отримано такі результати.

Таблиця 3.2 Результати експериментальних досліджень класичних алгоритмів

Алгоритм	Точність	Прецизійність	Середній час тренування, мс
XGBoost	78.60% ± 3.72%	87.03% ± 4.10%	59.04
SVM	77.20% ± 5.77%	76.93% ± 11.94%	2.73
Логістична регресія	80.46% ±1.13%	84.90% ± 2.54%	7.73
kNN	81.39% ± 3.89%	72.36% ± 7.57%	0.81
Випадковий ліс	76.74% ± 2.08%	80.28% ± 7.12%	167.10

Таблиця 3.3 Результати експериментальних досліджень м’яких обчисленнь

Алгоритм	Точність	Прецизійність	Середній час тренування, мс
MLP	78.30% ± 1.57%	80.27% ± 6.25%	1395.84
RNSA	52.55% ± 8.52%	54.85% ± 40.76%	1381.27
ANFIS	50.69% ±5.38%	45.30% ±22.71%	101.82
ГА+ KNN	81.86% ± 5.77%	85.47% ± 11.72%	275.60
Clonalg + KNN	59.53% ± 7.44%	62.62% ± 5.29%	2702.69

Таблиця 3.4 Результати експериментальних досліджень гібридних еволюційних моделей

Алгоритм	Точність	Прецизійність	Середній час тренування, мс
ГА+ MLP	69.30% ± 8.50%	72.35% ± 14.50%	62936.60
Гібридна нейро-нечітка еволюційна система	77.20% ± 5.77%	76.93% ± 11.94%	2.73

При спробі підвищити точність результатів в якості вхідних даних було використано PSD всіх каналів ЕЕГ разом з даними про стать, вік та IQ, сумарно 117 вхідних ознак, що означає збільшення розмірності вхідного вектора приблизно в 5 разів. Такий варіант дозволяє врахувати більше факторів, що можуть впливати на психічний стан пацієнтів. Однак, зростання розмірності вхідного вектора може також призвести до т.зв. “прокляття розмірності”, коли збільшена кількість ознак ускладнює навчання моделей і може знижувати їхню продуктивність.

Таблиця 3.5 Результати експериментальних дослідженнь класичних алгоритмів (117 ознак)

Алгоритм	Точність	Прецизійність	Середній час тренування, мс
XGBoost	81.39% ± 4.41%	84.16% ± 2.01%	160.81
SVM	79.06% ± 6.06%	79.09% ± 8.18%	4.37
Логістична регресія	86.04% ±2.54%	85.64% ± 5.32%	7.82
kNN	62.79% ± 2.54%	40.89% ± 3.62%	1.38
Випадковий ліс	76.74% ± 3.28%	89.05% ± 6.02%	235.85

Таблиця 3.6 Результати експериментальних досліджень м’яких обчисленнь (117 ознак)

Алгоритм	Точність	Прецизійність	Середній час тренування, мс
MLP	72.45% ± 4.19%	73.05% ± 13.03%	1592.15
RNSA	53.48% ± 6.24%	69.57% ± 39.25%	1609.19
ANFIS	53.48% ±6.06%	46.05% ± 23.20%	108.33
ГА + KNN	70.23% ± 10.12%	70.27% ± 16.86%	418.90
Clonalg + KNN	74.41% ± 7.64%	79.59% ± 6.42%	4426.22

Таблиця 3.7 Результати експериментальних досліджень гібридних еволюційних моделей (117 ознак)

Алгоритм	Точність	Прецизійність	Середній час тренування, мс
ГА+ MLP	68.37% ± 8.89%	76.40% ± 18.26%	72072.35
Гібридна нейро-нечітка еволюційна система	55.43% ±0.22%	0.5787% ±0.28%	2233.64

3.4 Обробка та оцінка результатів

Результати експериментальних дослідженнь доволі суперечливі, оскільки загалом було використано базові форми найбільш характерних представників відповідних типів м’яких обчисленнь, що проте не заважає оцінити основні властивості тестованих алгоритмів.

У таблиці 3.2 представлені результати експериментальних досліджень класичних алгоритмів для 22 вхідних ознак. Найвищу точність (81.39% ± 3.89%) продемонстрував алгоритм kNN, хоча його прецизійність (72.36% ± 7.57%) була нижчою в порівнянні з іншими методами. Логістична регресія також показала хороші результати з точністю 80.46% ± 1.13% та прецизійністю 84.90% ± 2.54%.

Алгоритм XGBoost досяг точності 78.60% ± 3.72% і прецизійності 87.03% ± 4.10%, що свідчить про його придатність, але з нижчою загальною точністю в порівнянні з kNN та логістичною регресією. Випадковий ліс показав найнижчу точність (76.74% ± 2.08%) серед класичних алгоритмів, але його прецизійність (80.28% ± 7.12%) була на прийнятному рівні.

У таблиці 3.3 результати алгоритмів м’яких обчислень показують, що MLP досяг точності 78.30% ± 1.57% та прецизійності 80.27% ± 6.25%. Проте, результати RNSA та ANFIS були значно нижчими, з точністю 52.55% ± 8.52% та 50.69% ± 5.38% відповідно, що свідчить про недостатню ефективність базової форми алгоритму у даному контексті та необхідність подальшої структурно-параметричної оптимізації для їхнього застосування в системах психодіагностики.

Генетичний алгоритм у поєднанні з k-means показав хороші результати з точністю 81.86% ± 5.77% та прецизійністю 85.47% ± 11.72%, що вказує на потенціал еволюційних алгоритмів у покращенні класичних методів ML. Clonalg + k-means, навпаки, показав значно нижчі результати, з точністю 59.53% ± 7.44%.

У таблиці 3.4 результати гібридних еволюційних моделей показують, що ГА у поєднанні з MLP досяг точності 69.30% ± 8.50% та прецизійності 72.35% ± 14.50%. Це свідчить про те, що використання еволюційних алгоритмів у поєднанні з нейронними мережами може не завжди призводити до покращення результатів.

Гібридна нейро-нечітка еволюційна система показала точність 77.20% ± 5.77%, що є кращим результатом у порівнянні з чистими м’якими обчисленнями, але все ще нижчим, ніж результати класичних алгоритмів.

При спробі підвищити точність результатів шляхом використання спектральної щільності всіх каналів ЕЕГ датасету разом з даними про стать, вік та IQ (таблиця 3.5), спостерігається загальне покращення точності для більшості класичних алгоритмів. Логістична регресія показала найвищу точність (86.04% ± 2.54%) та прецизійність (85.64% ± 5.32%), що свідчить про її ефективність у даному контексті. Алгоритм kNN, навпаки, зазнав значного зниження точності до 62.79% ± 2.54% та прецизійності 40.89% ± 3.62%, що вказує на обернено-пропорціційний зв'язок між розмірністю вхідного вектора та ефективністю алгоритму kNN. Це може бути пов'язано з тим, що kNN чутливий до “прокляття розмірності”, коли збільшення кількості ознак призводить до зниження якості класифікації.

У таблиці 3.6 результати м’яких обчислень на даних збільшеної розмірності показують, що алгоритм MLP досяг точності 72.45% ± 4.19% та прецизійності 73.05% ± 13.03%. Це свідчить про те, що, незважаючи на збільшення розмірності вхідних даних, MLP зберігає свою ефективність, хоча й не досягає рівня класичних алгоритмів в умовах поточного експерименту. Алгоритм RNSA продемонстрував точність 53.48% ± 6.24%, що є незначним покращенням у порівнянні з попередніми результатами, але все ще залишається на низькому рівні. ANFIS показав аналогічні результати з точністю 53.48% ± 6.06%, що вказує на ті ж самі проблеми, що й при використанні даних меншої розмірності. Генетичний алгоритм у поєднанні з k-means показав точність 70.23% ± 10.12% та прецизійність 70.27% ± 16.86%, що свідчить про те, що еволюційні алгоритми здатні покращувати результати класичних методів, хоча й не досягають найкращих показників.

У таблиці 3.7 результати гібридних еволюційних моделей показують, що генетичний алгоритм у поєднанні з MLP досяг точності 68.37% ± 8.89% та прецизійності 76.40% ± 18.26%. Це свідчить про те, що, хоча генетичний алгоритм може бути корисним для оптимізації, він не завжди призводить до значного покращення результатів у поєднанні з нейронними мережами, що залежить від

глибини та ємності їхніх шарів.

Гібридна нейро-нечітка еволюційна система показала найнижчі результати з точністю 55.43% ± 0.22% та прецизійністю 0.5787% ± 0.28%. Це вказує на те, що даний підхід потребує подальшої оптимізації та вдосконалення перед застосуванням в клінічній практиці, оскільки результати є незадовільними для медичного застосування.

В той же час, як прототип, що підтверджує концепцію, гібридна нейро-нечітка еволюційна система продемонструвала кілька значних переваг, що підтверджується експериментально. По-перше, вона забезпечила стабільні результати в порівнянні з чистими м’якими обчисленнями, такими як ANFIS та RNSA, які показали значно нижчі показники точності. Це свідчить про надійність гібридної системи при виборі для задач класифікації.

Хоча точність гібридної нейро-нечіткої еволюційної системи не була найвищою серед усіх алгоритмів, вона все ж перевищила результати деяких класичних алгоритмів і м’яких обчислень, що вказує на її потенціал у складних задачах. Використання еволюційних алгоритмів для вирішення задачі оптимізації дозволяє системі знаходити кращі рішення в умовах складності та невизначеності, що може бути особливо корисним, коли традиційні методи не дають задовільних результатів.

Гібридна нейро-нечітка еволюційна система також демонструє гнучкість у налаштуванні, що робить її універсальним інструментом для класифікації. Це дозволяє адаптувати систему до специфічних вимог дослідження, що є важливим аспектом у різних контекстах. Результати експерименту вказують на потенціал для подальшого вдосконалення точності та прецизійності через оптимізацію гіперпараметрів складових алгоритмів, відкриваючи можливості для майбутніх досліджень.

Перспективи подальшого розвитку системи включають кілька ключових аспектів. Першим аспектом є оптимізація гіперпараметрів, шо може суттєво підвищити точність та прецизійність розробленої системи. Використання більш розвинених еволюційних алгоритмів може забезпечити таку оптимізацію.

Другим аспектом є можливість інтеграції нових архітектур нейронних мереж, таких як згорткові та рекурентні нейронні мереж чи трансформери, які можуть покращити здатність системи до обробки складних даних і виявлення прихованих патернів. Це потенційно може дати переваги у випадках, коли дані мають часову або просторову структуру.

Третім аспектом є дослідження можливостей використання ансамблевих методів, які поєднують результати кількох моделей для досягнення кращих показників. Це може включати комбінацію різних типів нейронних мереж або поєднання нейронних мереж з класичними алгоритмами машинного навчання.

Також важливим напрямком є покращення обробки даних, зокрема, використання методів попередньої обробки та зменшення розмірності, таких як PCA (метод головних компонент), що можуть допомогти зменшити шум у даних і підвищити ефективність навчання.

Нарешті, варто звернути увагу на розширення можливостей системи для роботи з різними типами даних, такими як текст, зображення або звук, що дозволить гібридній нейро-нечіткій еволюційній мережі враховувати більше значимої інформації.

Таким чином, майбутні дослідження запропонованої гібридної нейро-нечіткої еволюційної мережі включають оптимізацію гіперпараметрів, інтеграцію нових архітектур нейронних мереж, використання ансамблевих методів, покращення обробки даних та розширення можливостей для роботи з різними типами вхідних даних. З цими вдосконаленнями запропонована гібридна система може показати значно кращі рішення, ніж базове демонстраційне рішення, тестоване в рамках поточної кваліфікаційної роботи.

ВИСНОВКИ

В ході теоретичного та експериментального дослідження було досягнено поставлену мету магістерської кваліфікаційної роботи, а саме розроблено гібридну нейро-нечітку мережі для діагностування психічних захворювань шляхом аналізу даних квантитативних електроенцефалограм, що було зроблено на прикладі базової форми класифікації медичних показників хворих на шизофренію та контрольних пацієнтів. Систему спроектовано в обсязі, достатньому для підтвердження висунутих гіпотез про її ключові властивості, а саме гнучкість та адаптивність, тому досягнення State of the Art результатів для гібридної нейро-еволюційної системи все ще являє серйозний науково-практичний інтерес.

Для досягнення поставленої мети було виконано визначені завдання. Проведено аналіз предметної області та огляд існуючих рішень, а саме досліджено питання психодіагностики, її методів та проблем, використання апаратних підходів в галузі, зокрема електроенцефалографії. Вивчено природу та структуру даних ЕЕГ, застосування електроенцефалографії в психології та психіатрії. Розглянуто сучасний етап розвитку даного підходу, що включає перехід до квантитативної електроенцефалографії та аналіз даних пацієнтів засобами штучного інтелекту. Проведено огляд існуючих рішень та зроблено припущення на його основі про доцільність застосування гібридних м’яких обчислень.

Для розробки гібридної нейро-нечіткої мережі в теоретичній частині було проаналізовано існуючі типи гібридизації, для визначення найбільш ефективної схеми поєднання різних алгоритмів штучного інтелекту. Для вибору конкретних складових проектованої системи було проведено аналіз наступних типів м’яких обчислень — моделей нечіткого виводу, нейронних мереж та еволюційних алгоритмів. Було розглянуто ключові концепції та фундаментальні алгоритми кожного типу, проаналізовано їхні переваги та недоліки, визначено оптимальний спосіб гібридизації з іншими підходами. На основі проведеного аналізу здійснено синтез, в результаті якого було розроблено архітектуру гібридної нейро-нечіткої

еволюційної моделі. Розроблена модель базується на нейро-нечіткій мережі ANFIS, тренування якої здійснюється за допомогою генетичного алгоритму.

Для перевірки життєздатності запропонованої моделі, валідації її ключових особливостей та оцінки її продуктивності в експериментальній частині роботи проведено порівняльне дослідження. З використанням 5-кратної крос-валідації було протестовано три групи алгоритмів - класичні алгоритми машинного навчання, м'які обчислення, що складають основу проектованої гібридної мережі та власне гібридні мережі з нейро-фаззі-еволюційною оптимізацією. В ході порівняльного аналізу підтверджено ключові переваги запропонованого рішення, а саме в висока гнучкість та адаптивність. Таким чином можна стверджувати, що поставлені мета та задачі роботи виконані в повному обсязі з досягненням наукового та практичного результату.

Наукова новизна полягає у використанні нейро-нечіткої еволюційної системи для діагностики психічних захворювань шляхом гібридизації моделі ANFIS та генетичного алгоритму, а також в експериментальному застосуванні алгоритму клонального відбору як для класифікації даних квантитативної електроенцефалографії, так і для оптимізації нейро-нечіткої мережі. Побічно, серед не опублікованих на момент захисту даної кваліфікаційної роботи матеріалів, певний науковий інтерес та новизну являє собою модифікація алгоритму k-середніх для задач класифікації та асоціації шляхом інтеграції його з генетичним алгоритмом.

Загалом, в ході магістерської роботи емпіричним шляхом за результатом експерименту було спостережено наступні факти:

- Класичні алгоритми машинного навчання, такі як дерево рішень, випадковий ліс, XGBoost, логістична регресія та KNN працюють краще за глибоке навчання, імунні алгоритми та системи нейро-нечіткого виводу на малих обсягах вхідних даних низької розмірності, перевищуючи їх в точності та швидкості навчання, але демонструють залежність від розмірності та інформативності вхідних даних;

- Імунні алгоритми вимагають більше обчислювальних ресурсів за генетичні алгоритми через наявність оператора клонування;

- Гібридизація різних методів м’яких обчислень підвищує ефективність складових алгоритмів порівняно з базовими рішеннями.

Гібридна нейро-еволюційна мережа в базовому варіанті реалізації показує найнижчий результат за точністю та прецизійністю, але демонструє високу гнучкість та адаптивність, слабку залежність від розмірності вхідних даних та здатність уникати локальних мінімумів при оптимізації ваги.

Таким чином, розроблена гібридна нейро-нечітка мережа має практичну цінність навіть за відносно низьких результатів за точністю та прецизійності порівняно з класичними алгоритмами машинного навчання. Запропонована модель надає необхідну гнучкість та адаптивність порівняно з існуючими рішеннями, розглянутими в огляді наукової літератури. Система здатна досягти стану SOTA в ході подальших доопрацювань.

Як висновок, вивчення гібридних нейро-еволюційних систем все ще залишається актуальним напрямком наукової роботи. Враховуючи отримані результати, з метою покращення запропонованого рішення в майбутніх дослідженнях варто розглянути шляхи оптимізації гіперпараметрів складових алгоритмів, використання нейронних мереж та правил нечіткого виводу, більш ефективних за використані в ході поточної кваліфікаційної роботи.

В науковому плані вивчення гібридних нейро-еволюційних систем відповідає напрямку дослідженнь штучного інтелекту, що проводяться в Харківському Національному Університеті Радіолектроніки, зокрема на кафедрі комп’ютерних інтелектуальних технологій. Рішення, запропоновані в поточній магістерській кваліфікаційній роботі знайшли застосування на комерційній основі в рамках системи афективного аналізу після значної модифікації для відповідної предметної області. Результати дослідження розвиваються за наміченим вище планом в рамках діяльності дослідницько-розробницького відділу проєкту в галузі штучного інтелекту.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Матейко Н.М. Основи психодіагностики: інструктивно-методичні матеріали до самостійної роботи. – Івано-Франківськ: Симфонія форте, 2013. – 80с

6. Москалець В. П. Психологія особистості [текст] навчальний посібник. — М 82 К.: «Центр учбової літератури», 2013. — 416 с., 71-77 с

7. Fenton, G. W., & Standage, K. (1993). The EEG in psychiatry. Psychiatric Bulletin, 17(10), 601–603.

8. Singh, M., Muhammad, A., & Jahangiri, F. R. (2023). Electroencephalography (EEG) in Psychiatry: A Review Article. J of Neurophysiological Monitoring, 1(1), 44–50.

9. Robinson S. Relationship between EEG and Behavior. Psichotriopic Drugs and the Human EEG / Mod . Probl. Pharmacopsychiat., v. 8, p. 286—300, ed. Turan M. Itil, New York, N.Y. (Kargel, Basel 1974)

10. Hughes, J. R. (1996). A Review of the Usefulness of the Standard EEG in Psychiatry. Clinical Electroencephalography, 27(1),

11. Libenson, M. H. (2010). Practical approach to electroencephalography. Philadelphia, PA: Elsevier/Saunders. ISBN 978-1-4557-4594-4.

12. Чернінський А. О., Крижановський С. А., Зима І.Г. (2011). Електрофізіологія головного мозку людини: методичні рекомендації до практикуму; — Київ: Мартинюк, 2011;— 49 с. ISBN 978-966-96879-7-5

13. Jasper, H. H. (1958). The 10-20 electrode system of the International Federation. Electroencephalography and Clinical Neurophysiology, 10, 370-375.

14. Livint Popa L, Dragos H, Pantelemon C, Verisezan Rosu O, Strilciuc S. The Role of Quantitative EEG in the Diagnosis of Neuropsychiatric Disorders. J Med Life. 2020 Jan-Mar;13(1):8-15. doi: 10.25122/jml-2019-0085. PMID: 32341694; PMCID: PMC7175442.

15. Hosseini, M.-P., Hosseini, A., & Ahi, K. (2020). A review on machine learning for EEG signal processing in bioengineering. IEEE Reviews in Biomedical Engineering.

16. Rahul J, Sharma D, Sharma LD, Nanda U, Sarkar AK. A systematic review of

EEG based automated schizophrenia classification through machine learning and deep learning. Front Hum Neurosci. 2024 Feb 14;18:1347082. doi: 10.3389/fnhum.2024.1347082. PMID: 38419961; PMCID: PMC10899326.

17. Agarwal M., Singhal A. (2023). Fusion of pattern-based and statistical features for Schizophrenia detection from EEG signals

18. Devia C., Mayol-Troncoso R., Parrini J., Orellana G., Ruiz A., Maldonado P., et al. (2019). EEG classification during scene free-viewing for schizophrenia detection. IEEE Trans. Neural Syst. Rehabil. Eng. 27 1193–1199. 10.1109/TNSRE.2019.2913799

19. Luján M., Mateo Sotos J., Torres A., Santos J., Quevedo O., Borja A. (2022). Mental disorder diagnosis from EEG signals employing automated leaning procedures based on radial basis functions. J. Med. Biol. Eng. 42 853–859. 10.1007/s40846-022-00758-9

20. Khare S., Bajaj V. (2022). A hybrid decision support system for automatic detection of Schizophrenia using EEG signals. Comput. Biol. Med. 141:105028. 10.1016/j.compbiomed.2021.105028

21. Aydemir E., Dogan S., Baygin M., Ooi C., Barua P., Tuncer T., et al. (2022). CGP17Pat: Automated schizophrenia detection based on a cyclic group of prime order patterns using EEG Signals. Healthcare 10:643. 10.3390/healthcare10040643

22. Najafzadeh H., Esmaeili M., Farhang S., Sarbaz Y., Rasta S. (2021). Automatic classification of schizophrenia patients using resting-state EEG signals. Phys. Eng. Sci. Med. 44 855–870. 10.1007/s13246-021-01038-7

23. Park, S. M., Jeong, B., Oh, D. Y., Choi, C.-H., Jung, H. Y., Lee, J.-Y., Lee, D., & Choi, J.-S. (2021). Identification of major psychiatric disorders from resting-state electroencephalography using a machine learning approach. Frontiers in Psychiatry, 12, 707581.

24. Korablyov, Mykola & Axak, Natalia & Soloviov, Dmytro. (2018). Hybrid Evolutionary Decision-Making Model Based on Neural Network and Immune Approaches. 1-5. 10.1109/STC-CSIT.2018.8526594.

25. Korablyov, Mykola & Axak, Natalia & Barkovska, Olesia & Rosinskiy, Dmytro(2019). Hybrid adaptive decision-making model based on fuzzy logic and artificial

immune systems. 62-66. 10.1109/STC-CSIT.2019.8929826.

26. Castellano, Giovanna & Castiello, Ciro & Fanelli, Anna & Jain, Lakhmi. (2007).Evolutionary Neuro-Fuzzy Systems and Applications. 10.1007/978-3-540-72377-6_2.

27. Alpaydin G, Dandar G, Balkir S (2002) Evolution-based design of neural fuzzy networks using self-adapting genetic parameters. IEEE Trans. Fuzzy Systems 10(2):211-221

28. Zadeh, L. A. (February 1968). "Fuzzy algorithms". Information and Control. 12 (2): 94–102. doi:10.1016/S0019-9958(68)90211-8.

29. Zadeh, L. A. (June 1965). "Fuzzy sets". Information and Control. 8 (3). San Diego: 338–353. doi:10.1016/S0019-9958(65)90241-X. ISSN 0019-9958. Zbl 0139.24606.

30. Конспект лекцій з дисципліни "Нечіткі множини" для підготовки фахівців освітньо-кваліфікаційного рівня магістр за спеціальністю 122 – Комп’ютерні науки [Електронне видання] / Упоряд. К.Е. Петров. – Харків: ХНУРЕ, 2018 – 128 с

31. J. L. Castro and M. Delgado, “Fuzzy systems with defuzzification are universal approximators,” IEEE Trans. Syst., Man, Cybern., vol. 26, pp. 149–152, 1996.

32. T. Takagi and M. Sugeno, “Fuzzy identification of systems and its applications to modeling and control,” IEEE Trans. Syst., Man, Cybern., vol. 15, pp. 116–132, 1985

33. Jang, J.-S.R. (1993). "ANFIS: adaptive-network-based fuzzy inference system". IEEE Transactions on Systems, Man, and Cybernetics. **23** (3): 665–685.

34. Jang, Sun, Mizutani (1997) – Neuro-Fuzzy and Soft Computing – Prentice Hall, pp 335–368

35. I. Goodfellow and Y. Bengio and A. Courville (2016). Deep Learning. MIT Press.

36. Руденко О. Г. Штучні нейронні мережі / О. Г. Руденко, Е. В. Бодянський. – Харків: Компанія СМІТ, 2006. – 404 с.

37. Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. Multimedia Tools and Applications, 80(5), 8091-8126.

38. Lambora, A., Gupta, K., & Chopra, K. (2019). Genetic Algorithm - A Literature

Review. 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), Faridabad, India, 2019, pp. 380-384

39. de Castro, L. N.; Von Zuben, F. J. (2002). "Learning and Optimization Using the Clonal Selection Principle" (PDF). IEEE Transactions on Evolutionary Computation. **6** (3): 239–251.

40. Дараган Д. М., Сагайдачний О.М., Сердюк Н. М. Application of clonal selection principle in neural architecture search//Матеріали 12-ї Міжнародної науково-технічної конференції “Інформаційні системи та технології”. 28 листопада 2023, м. Харків, Україна

41. Дараган Д. М., Корабльов М.М. Paralleling of artificial immune networks for pattern recognition//Матеріали XVII Всеукраїнської науково-практичної WEB конференції аспірантів, студентів та молодих вчених “Комп’ютерні інтелектуальні системи та мережі”, 26 березня 2024, м. Кривий Ріг, Україна

42. Darahan D., Korablyov M. Usage of genetic algorithm for the analysis of quantitative electroencephalography in psychiatry //Proceedings of the 2nd International Scientific and Practical Conference "Innovative Solutions in Science: Balancing Theory and Practice" December 23, 2024,San Francisco, USA