

МІНІСТЕРСТВО ОСВІТИ ТА НАУКИ УКРАЇНИ
ПРИВАТНЕ АКЦІОНЕРНЕ ТОВАРИСТВО
«ПРИВАТНИЙ ВИЩИЙ НАВЧАЛЬНИЙ ЗАКЛАД
«ЗАПОРІЗЬКИЙ ІНСТИТУТ ЕКОНОМІКИ
ТА ІНФОМАЦІЙНИХ ТЕХНОЛОГІЙ»

ДО ЗАХИСТУ ДОПУЩЕНА

Зав. кафедрою інформаційних технологій

д.е.н., проф. С.І. Левицький

МАГІСТЕРСЬКА ДИПЛОМНА РОБОТА

НЕЧІТКИЙ МЕТОД ПРОГНОЗУВАННЯ ВІКУ КЛІТИН МОЗКУ
НА ОСНОВІ ЗАПИСІВ ЕНЦЕФАЛОГРАМИ

Виконав

ст. гр. ПЗ-112(м)

Чмихало В.Ю.

Керівник

к.т.н., доц.

Резніченко Ю.С.

Запоріжжя

2024

МІНІСТЕРСТВО ОСВІТИ ТА НАУКИ УКРАЇНИ
ПРИВАТНЕ АКЦІОНЕРНЕ ТОВАРИСТВО
«ПРИВАТНИЙ ВИЩИЙ НАВЧАЛЬНИЙ ЗАКЛАД
«ЗАПОРІЗЬКИЙ ІНСТИТУТ ЕКОНОМІКИ
ТА ІНФОМАЦІЙНИХ ТЕХНОЛОГІЙ»

ЗАТВЕРДЖУЮ

Зав. кафедрою інформаційних технологій

д. ф.-м. н., проф. С. І. Левицький

" 06 " вересня 2023 р.

ЗАВДАННЯ

НА МАГІСТЕРСЬКУ ДИПЛОМНУ РОБОТУ

Студенту гр. ППЗ-112(м), спец. 121 – «Інженерія програмного забезпечення»

Чмихало Володимиріу Юрійовичу

(прізвище, ім'я, по батькові)

1.Тема: *Нечіткий метод прогнозування віку клітин мозку на основі записів енцефалограми*

затверджена наказом інституту від: «06» вересня 2023 р. № 06.2-7-1

2. Термін здачі студентом закінченої роботи: «14» січня 2024 р.

3. Перелік питань, що підлягають розробці:

1. Аналіз біомедичних цифрових сигналів.

2. Дослідження фаз та циклів сну.

3. Аналіз підходів до визначення віку клітин головного мозку.

4. Огляд методу опорних векторів.

5. Огляд методів машинного навчання.

6. Формування вибірки вхідних даних.

7. Огляд методів перетворення сигналу електроенцефалограми.

8. Розробка адаптивної системи нейро-нечіткого виведення.

4. Календарний план роботи:

№ п/н	Назва розділів та етапи виконання	Строк виконання	
		За планом	Фактичний
1	Формування теми магістерської дипломної роботи, збір практичного матеріалу за темою магістерської дипломної роботи	05.09.2023	01.10.2023
2	I розділ магістерської дипломної роботи	24.10.2023	29.10.2023
3	II розділ магістерської дипломної роботи	21.11.2023	26.11.2023
4	III розділ магістерської дипломної роботи, висновки та рекомендації, додатки, реферат, перевірка програмою «Антиплагіат»	19.12.2023	24.12.2023
5	Доопрацювання магістерської дипломної роботи, підготовка презентації, отримання відгуку керівника та рецензії	25.12.2023	07.01.2023
6	Попередній захист магістерської дипломної роботи	09.01.2024	14.01.2024
7	Подача магістерської дипломної роботи на кафедру	13.01.2024	14.01.2024
8	Захист магістерської дипломної роботи	16.01.2024	21.01.2023

Дата видання завдання:

«06» вересня 2023 р.

Керівник магістерської дипломної роботи _____

(Підпис)

Резніченко Ю.С.

(прізвище та ініціали)

Завдання прийняв до виконання _____

(Підпис)

Чмихало В.Ю.

(прізвище та ініціали)

РЕФЕРАТ

Магістерська дипломна робота: 61 с., 33 рис., 6 табл., 1 додаток, 50 посилань.

Об'єкт дослідження — процеси, що пов'язані з енцефалограмами та іншими процесами дослідження мозку людини та втілення моделі прогнозування віку клітин.

Мета роботи — розробити модель визначення впливу біопотенціалів головного мозку на прогнозування віку клітин.

Метод дослідження — Нечітка модель Сугено адаптивної мережі.

У магістерській дипломній роботі розглянуті найважливіші методи досліджень вікових змін біоритмів людини, використовуючи записи ритмів електроенцефалограми; дослідження використання нечіткої логіки з нейронною мережею; передбачення рівня пильності і віку клітин мозку; дослідження сну та вдосконалення існуючих методів аналізу ЕЕГ; задіяна попередня обробка вхідної вибірки та сформовані вибірки вхідних даних; відфільтровано найбільш впливові ознаки; на основі платформи MATLAB версії 9.13 створено модель розпізнавання сигналів ЕЕГ; проведені дослідження з прогнозування віку клітин мозку за допомогою рівня пильності і методів нечіткої множини.

ЕЛЕКТРОЕНЦЕФАЛОГРАМА, СТАДІЯ СНУ, МАШИННЕ НАВЧАННЯ,
НЕЧІТКИЙ МЕТОД, АДАПТИВНА НЕЙРОННА МЕРЕЖА, ANFIS

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ ТА
ТЕРМІНІВ

ВСТУП

РОЗДІЛ 1. ПІДХОДИ ДО ОБРОБКИ СИГНАЛІВ ЕЛЕКТРОЕНЦЕФАЛОГРАМИ

1.1 Особливості сигналів електроенцефалограми

1.2 Дослідження фаз та циклів сну

1.3 Дослідження з визначення віку клітин мозку

1.4 Висновки до першого розділу

РОЗДІЛ 2. АНАЛІЗ МЕТОДІВ ОБРОБКИ СИГНАЛІВ

ЕЛЕКТРОЕНЦЕФАЛОГРАМИ

2.1 Метод опорних векторів

2.2 Метод машинного навчання

2.3 Метод клінічних нейрофізіологічних досліджень

2.4 Висновки до другого розділу

РОЗДІЛ 3. НЕЧІТКИЙ МЕТОД ВИЗНАЧЕННЯ ВІКУ КЛІТИН МОЗКУ

3.1 Формування наборів вхідних та вихідних даних

3.2 Реалізація методу перетворення сигналів електроенцефалограми

3.3 Розробка адаптивної системи нейро-нечіткого виведення

3.4 Висновки до третього розділу

ВИСНОВКИ

ПЕРЕЛІК ПОСИЛАНЬ

ДОДАТОК А. Matlab Fuzzy Logic Toolbox

ДОДАТОК Б. Фрагменти лістингу

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ ТА
ТЕРМІНІВ

Слово/словосполучення	Скорочення	Умова використання
Е		
Електроенцефалограма	ЕЕГ	В тексті
І		
Індекс Маса Тіла	ІМТ	В тексті
К		
Комп'ютерна Томографія	КТ	В тексті
М		
Магнітно-Резонансна Томографія	МРТ	В тексті
D		
Discrete Wavelet Transform	DWT	В тексті
G		
General Linear Model	GLM	В тексті
L		
Linear Discriminant Analysis	LDA	В тексті
M		

MATrix LABoratory	MATLAB	В тексті
P		
Power Spectral Density	PSD	В тексті
Polysomnography	PSG	В тексті
R		
Random Forest	RF	В тексті
S		
Support Vector Method	SVM	В тексті
Support Vector Regression	SVR	В тексті
W		
Wavelet Packet Decomposition	WPD	В тексті

ВСТУП

Оцінка розриву у віці мозку — це різниця між розрахунковим віком і індивідуальним хронологічним віком. Оцінка розриву вивчається в основному за допомогою методів МРТ. Сигнали ЕЕГ зазвичай не використовувалися для прогнозування віку людини. У біомедичних сигналах відображається активність систем фізіології та відображається інформація про їх компоненти. Зазвичай біомедичні сигнали по своїй природі випадкові і характеристики сигналів, серед яких дисперсія, спектральна щільність, середнє значення можуть змінюватись. Тому сигнали систем аналізують на протязі тривалого часового періоду, включаючи різноманітні стани 22 систем, а результати оцінюються зважаючи на відповідні стани. Різнманітні системи тіла людини мають зв'язок та взаємодіють. Якщо на це не зважати, сигнал може бути спотворений.

Біомедичні сигнали можуть бути забруднені шумом різноманітної природи, до прикладу, при дослідях, випадкових рухах кінцівками, це може вплинути на сигнал та утворити небажані артефакти, тому зараз більше користуються методами магнітно – резонансної томографії (МРТ) та комп'ютерної томографії (КТ), застосування ЕЕГ скорочується. Натомість ЕЕГ продовжує бути важливим інструментом при дослідях і діагностуванні. ЕЕГ продовжує бути доступним мобільним методом, в якому часова роздільна здатність коливається в діапазонах мілісекунди, що не є доступним у МРТ чи КТ.

Із бази, яка складається з 30 суб'єктів, група складалася з 14 жінок і 16 чоловіків у віці від 18 до 65 років, середній вік 33,5 років і індекс маси тіла (ІМТ) $32,4 \pm 7,3$ кг/м², в результаті попередньої обробки були виділені три класи даних: тривога, сонливість, сон.

Сигнали записували протягом 7 годин епізодів, а цифрові сигнали приймали кожні 20 хвилин для кожного блоку. Потім ці записи ЕЕГ були розділені на 5 сек. епохи і ці епохи були розділені на піддіапазони частот, такі як α , β , θ і δ .

Потім спектральна щільність потужності (PSD) вейвлет піддіапазону частот δ (1–4 Гц), θ (4–8 Гц), α (8–13 Гц) і β (13–30 Гц) застосовуються до PSD.

Стан тривоги має змішані частоти: α і β . У сонному стані α зникне. Під час сну α і β втрачаються, δ і θ спостерігаються.

Актуальність теми – аналіз ЕЕГ стадій сну може бути корисною при діагностиці і лікуванні розладів сну, використаний нечіткий метод і результати можуть бути корисними студентам і молодим науковцям, які починають свій науковий шлях.

Метою роботи є визначення впливу біопотенціалів головного мозку на прогнозування віку клітин.

Об'єктом дослідження є розробка моделі визначення впливу біопотенціалів головного мозку на прогнозування віку клітин.

РОЗДІЛ 1

ПІДХОДИ ДО ОБРОБКИ СИГНАЛІВ ЕЛЕКТРОЕНЦЕФАЛОГРАМИ

1.1 Особливості сигналів електроенцефалограми

Енцефалограма (ЕЕГ) – запис мозкової активності. При цьому розглядається активність наступних головних частин мозку: мозочку, кори головного мозку, таламусу (поміж середнім та напівсереднім мозком) та стовбуру мозку, який складається з середнього та довгастого мозку [?].

ЕЕГ реєструється за допомогою електроенцефалографа з використанням спеціального електроду. Тривалість записів ЕЕГ складає 15-20 хвилин одночасно по 7-16 каналах [?].

Сигнали ЕЕГ відображають декілька типів мозкової активності, зокрема ритмічну та періодичну. ЕЕГ містить наступні частотні діапазони (рис. 1.1):

1. Дельта (δ): $0,5 < f < 4$ Гц, високо-амплітудні хвилі (сотні мкВ) з частотою 1-4 Гц. Дельта-ритм виникає у випадку коми та у природному глибокому сні. Його спостерігають у випадках реєстрації ЕЕГ у ділянках кори, які можуть межувати з областю пухлин.
2. Тета (θ): $4 < f < 8$ Гц, є високим електричним потенціалом 100-150 мкВ, амплітуда хвиль висока. Тета-ритм найчастіше спостерігається у дітей від 2 до 8 років.
3. Альфа (α): $8 < f < 13$ Гц, амплітуда хвиль в середньому від 30-70 мкВ. Можливе спостереження низько-амплітудних та високо-амплітудних альфа-ритмів. Спостерігається у 80-95% дорослих людей, зазвичай у потиличному відділі.
4. Бета (β): $f > 13$ Гц, ЕЕГ ритм у діапазонах 14-30 Гц, напруга 5-30 мкВ, спостерігається стан неспання. Найчастіше спостерігається у лобовій області, може різко посилюватись при високо-інтенсивній діяльності та поширюватись у інших ділянках мозку. Вплив бета-ритмів має тенденцію на зростання у випадках нових несподіваних стимулів, в ситуаціях емоційних збуджень, підвищення уваги, при розумових напруженнях. За формами бета-

хвилі схожі на трикутні, спостерігається загострення вершин.

5. Гамма (γ): $30 < f < 120-170$ Гц, також може бути до 500 Гц. Спостерігається дуже низька амплітуда (нижче 10 мкВ), обернено пропорційні частоти. У випадку, коли амплітуди гамма-ритмів є вищими за 15 мкВ, ЕЕГ може вважатись патологічною. Гамма-ритми спостерігаються, коли вирішуються завдання, які потребують уваги та зосередження (інколи пов'язують з роботою підсвідомості).



Рисунок 1.1 – Різновиди фізіологічних ритмів ЕЕГ

У роботі [1] автори запропонували підхід до реєстрацію біоелектричної

активності мозку коня. При застосуванні вказаної методики виявляються хвилі біоелектричної активності головного мозку у спортивних коней наступних діапазонів (рис. 1.2): дельта (0,3-4 Гц, амплітуда до 40 мкВ), тета (4,1-7 Гц, амплітуда близько 30 мкВ), альфа (7,1-13 Гц, амплітуда до 100 мкВ), бета-1 (13,1-25 Гц, амплітуда 3–5 мкВ), бета-2 (25–40 Гц, амплітуда 3–5 мкВ) та гамма (понад 40 Гц).




Рисунок 1.2 – Ритми ЕЕГ на прикладі головного мозку коней

Шолом для фіксації ЕЕГ виконано у вигляді жорсткої прозорої пластини з множинними отворами (рис. 1.3). У середині отворів встановлено рухомі накладні трубчасті електроди, що закріплюються на голові тварини за допомогою широкої гумової стрічки.



Рисунок 1.3 – Шолом Іполітової для реєстрації ЕЕГ у тварин

Розглянутий підхід було протестовано на 120 спортивних конях різних порід (зокрема, тракененська, ганноверська, голштинська тощо), різної статі та різного віку (4–20 років).

Результатом експериментів за розглянутим підходом при навантаженні «виїздка – юнацька їзда», «конкур», «триборство» та «хобі-клас» став індекс виразності ритмів (табл. 1.1, де л.п. та п.п. – ліва та права півкуля). Найбільш вираженим є дельта-ритм та гамма-ритм, а при навантаженні «виїздка – малий, середній та великий приз» дельта-ритм достовірно нижче, ніж при інших видах навантажень.

Таблиця 1.1 – Індекс виразності ритмів (ІВР) для коней, %

Відведення/ Ритми	Добове відведення (л. п.)	Добове відведення (п. п.)	Тім'яне відведення (л. п.)	Тім'яне відведення (п. п.)	Потиличне відведення (л. п.)	Потиличне відведення (п. п.)
Тета	72,25±6,3	74±7,64	65,25±5,68	77,5±3,66	74,25±2,56	76,25±0,63
Альфа	64,5±7,1	64±5,64	61,5±4,55	62,75±4,25	54,75±2,22	67,5±1,06
Бета-1	79,75±8,11	77,25±5,23	73,25±4,78	76,75±4,82	70,25±4,01	77,75±1,49
Бета-2	63,25±3,41	65,5±4,86	62±3,61	69,75±2,88	58±4,01	62,75±1,92
Гамма	80,5±5,12	84,75±7,14	76,25±3,9	85,75±2,16	84,5±3,6	84,75±2,35
<i>Конкур</i>						
Дельта	87,3±0,3	90,6±0,07	86±2,63	86,3±0,94	90,3±3,48	88,6±1,82
Тета	79±0,72	82±0,49	79±3,05	76±1,37	77±3,89	74,6±2,25
Альфа	57,6±4,1	62±0,92	53±3,46	51,3±1,8	55,3±0,11	51±2,67
Бета-1	76,3±3,69	79,6±1,35	77±3,87	71±2,23	74,6±0,53	75±3,09
Бета-2	74,6±3,28	67,3±1,78	55,6±0,09	54±2,65	60,3±0,96	56±3,5
Гамма	85±2,86	84±2,21	81±0,51	84±3,07	84±1,39	79,3±3,91
<i>Виїздка – малий, середній, великий приз</i>						
Дельта	70,3±0,13	75±2,69	73±0,25	75,3±2,81	76±1,12	76,3±3,66
Тета	71±0,55	67,3±3,11	71±0,67	77,5±3,23	67,3±1,55	76,6±4,07
Альфа	61,3±0,98	69,3±3,52	63,3±1,1	62,3±3,64	65±1,98	66,3±0,29
Бета-1	76±1,41	79,3±3,93	74,6±1,53	74,6±4,05	73,6±2,41	71±0,71
Бета-2	68±1,84	81,6±0,16	71±1,96	70±0,27	73,6±2,83	72±1,14
Гамма	85,6±2,27	84±0,58	84±2,39	83,3±0,69	81±3,25	84±1,57
<i>Триборство</i>						
Дельта	88,5±1,01	86±2,0	87,5±0,33	85,5±2,89	86±1,2	85,5±3,74
Тета	70,3±1,44	81,3±2,43	76,3±0,75	81,3±3,31	78,3±1,63	80±4,15
Альфа	62,3±1,87	62±2,85	68,3±1,18	49±3,72	60±2,06	59,3±0,38
Бета-1	78±2,3	80,6±3,27	76±1,61	75,3±4,13	80±2,49	75±0,36
Бета-2	64±2,72	75±3,68	65±2,04	59±0,35	75±2,91	62±2,08
Гамма	81±3,14	82±4,09	84±2,47	82±0,77	83±3,33	82±2,53
<i>Хобі-клас</i>						
Дельта	87,75±0,43	86±2,99	84,75±1,3	85,5±3,84	88,75±2,18	87,25±0,46
Тета	67,75±0,85	77,25±3,41	65,25±1,73	77±4,25	71,5±2,61	78,25±0,88
Альфа	36,25±1,28	57,25±3,82	52±2,16	57,5±0,47	51,75±3,03	57,25±1,31
Бета-1	67±1,71	73±4,23	70,5±2,59	70,5±0,89	70,25±3,45	74,5±1,74
Бета-2	46,25±2,14	61,75±0,45	62±3,01	61,25±1,32	55±3,86	56,75±2,17
Гамма	82,75±2,57	83,5±0,87	84,5±3,43	85,75±1,75	80±4,27	83,25±2,6

Запропонований підхід дозволяє проводити ЕЕГ-оцінку придатності тварин з різним типом ІВР та різного віку до певного спортивного навантаження, що значно спрощує відбір коней із бажаними характеристиками без витрати часу, сил та коштів на вирощування свідомо безперспективних тварин.

У роботі [2] запроваджено підхід, який містить наступні етапи: метод «трубопроводу» для відбору каналів реєстрації, смуговий фільтр, розрахунок ознак, відбір ефективних ознак двома методами та моделювання з використанням класифікатора Байєса. Оптимальні ознаки виявлено за допомогою методів відбору, це допомагає подолати їх варіабельність та підвищує продуктивність класифікатора (рис. 1.4).



Рисунок 1.4 – Блок-схема експериментальної моделі

Розглянутий підхід було протестовано на наборі даних із змагань з нейрокомп'ютерного інтерфейсу, організованих групою Berlin BCI. Результат методу порівнюється з двома традиційними класифікаторами, якими є лінійний дискримінантний аналіз (LDA) та метод опорних векторів (SVM). Результати доводять, що метод забезпечує поліпшення точності у 95%.

1.2 Дослідження фаз циклів сну

Електроенцефалограма (ЕЕГ) є найпоширенішим інструментом для дослідження сну.

На протязі сну мозок може проходити через два стани, якісно різних - повільний і швидкий сон, що можуть складатися з 5 стадій (чотири стадії складаються з повільного сну і одна з швидкого). Стадії повторюються з півторагодинними циклами, приблизно 4-6 разів за ніч. Повільний сон характеризується уповільненням хвилі ЕЕГ, у швидкому спостерігається поява ЕЕГ хвилі, яка подібна до хвиль, які можуть реєструватися в станах бадьорості.

Під час першої стадії (період дрімоти) проходять переходи від станів бадьорості до станів сну. Ці явища можуть супроводжуватись зменшеннями альфа-активностей і появами низькоамплітудних дельта- та тета-хвиль. Триває стадія приблизно 10-15 хв. В кінцевій стадії можуть спостерігатися короткі спалахи.

На другій стадії (поверхневий сон) може спостерігатись часта поява "сонних веретен" – це веретеноподібний ритм від 14 до 18 коливань на секунду. При появі початкового веретена може відбуватися відключення свідомості. Під час пауз поміж веретенами ще легко розбудити людину. Приблизно половину загального часу нічного сну займає друга стадія.

На третій і четвертій стадіях відбувається поєднання під назвою дельта-сон, на ЕЕГ з'являється високоамплітудна повільна хвиля - дельта-хвиля. Третя стадія може характеризуватися усіма рисами другої стадії, до якої додається наявність в ЕЕГ повільного дельта коливання з частотою 2 Гц та менше, що займає 20-50% всієї ЕЕГ.

Четверта стадія характеризується дельта-хвилями, які займають понад 50% усієї ЕЕГ. Для цієї найглибшої стадії сну характерним є найвищий поріг пробудження і найсильніше відключення від зовнішнього світу. Ця стадія виникає приблизно у 80% сновидінь. Найчастіше на цій стадії спостерігаються нічні кошмари. В процесі пробудження на цій стадії людина важко орієнтується. Стадія дельта-сну більш виражена на початковій стадії сну і на протязі часу зменшується до його кінця. Перші чотири стадії сну зазвичай займають від 75 до 80% усього періоду сну.

На п'ятій стадії сну ("швидкий сон") спостерігається повна нерухомість людини внаслідок різких падінь в неї тону м'язів та з частотою 60-70 разів на секунду швидкі рухи очних яблук під замкненими віками. Окрім цього, може посилюватись кровотік у мозок та спостерігається підвищення активізації вегетатики на тлі глибокого розслаблення у м'язах. Можуть відбуватися різкі зміни дихання, частоти серцевих скорочень, артеріального тиску. На протязі цієї стадії сну в ЕЕГ можуть переважати високочастотні низькоамплітудні складові, які є характерними для станів бадьорості. На протязі "швидкого сну" п'ятої стадії виникає значна частина сновидінь, які легко запам'ятовувати.

Частка першої стадії в дорослих людей у нормі близько 10% часу всього сну, друга від 35 до 45%, третя і четверта по 10-15 %, п'ята - 20-25%.

У роботі [3] автори задіяли 3 методи машинного навчання: RF, бегінг (Bagging) та SVM, з погодинними характеристиками для характеристики етапу сну на базі одноканальної ЕЕГ. Нічні полісомнограми реєструвались від 25 суб'єктів, де задіян стандарт R&K. Для виявлення стадій сну були задіяні сигнали ЕЕГ. Результати ручного та автоматичного аналізів ритмів було послідовно об'єднано. Вибірка досліджень у стані сну складалась з 95000 40-ти секундних епох ЕЕГ. ЕЕГ епохи вирізняли шість стадій (W/S1/S2/S3/S4/REM) (рис. 1.5).




Рисунок 1.5 – Різновиди стадій сну на ЕЕГ

Кращі результати класифікації отримані методом випадкових лісів і досягають рівня точності показників чутливості та специфічності у 97,72%, 96,4%

і 99,55% відповідно.

Спостереження сну, яке проводиться у професійній лабораторії та аналізується спеціалістами – це досить дорогий та трудомісткий процес. Однак є розробки, що забезпечують реєстрацію ЕЕГ сну в домашніх умовах. У дослідженні [4] були запропоновані підходи для моніторингу сну в автоматичному режимі при допомозі методів машинного навчання (рис. 1.6). Набір функцій формується відповідно до даних сигналів ЕЕГ.

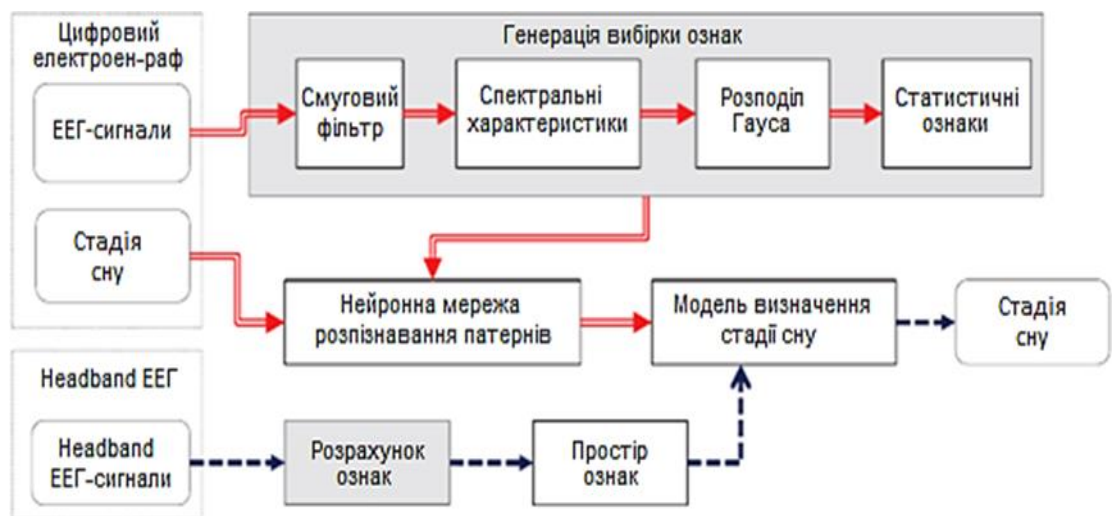


Рисунок 1.6 – Адаптована модель розшифрування сигналів на різних стадіях сну

1.3 Дослідження з визначення віку клітин мозку

Електроенцефалограма (ЕЕГ) сну людини змінюється з віком. Ці зміни можна характеризувати як «вік мозку», який можна порівняти з хронологічним віком, щоб відобразити ступінь відхилення від нормального старіння. На рівні архітектури сну старші учасники раніше засинають і раніше прокидаються, мають меншу тривалість сну, підвищену фрагментацію сну і знижений відсоток сну з швидкими рухами очей. На рівні мікроструктури ЕЕГ учасники старшого віку демонструють зниження повільних хвиль під час глибокого сну, зниження амплітуди, щільності та тривалості веретена сну.

Вік мозку служить біомаркером старіння, коли варіація віку мозку між особами одного віку нести важливу інформацію про ризик когнітивних порушень,

неврологічних або психіатричних захворювань або смерті. Для кращого прогнозування тривалості життя та функціональних можливостей було запропоновано різні біомаркери старіння, починаючи від молекулярного та клітинного рівнів і закінчуючи біомаркерами структурного рівня.

У роботі [5] представлена інтерпретована модель для прогнозування віку мозку. Модель мінімізує цільову функцію $J(w, b)$ за допомогою двох членів: середньоквадратична помилка передбачення і величина коваріації.

Фіксуються макро зміни сну, просуюваючись до п'ятого десятиліття старшого віку і далі, є набір добре охарактеризованих змін в архітектурі сну (рис. 1.7): передовий час сну (тобто ранній час сну та час підйому), більша затримка настання сну (тобто довший час, необхідний для засинання), коротша загальна тривалість сну, більший сон (тобто менш консолідований сон із більшою кількістю пробуджень, збуджень або переходів до більш легких стадій сну), більш крихкий сон (тобто більша ймовірність пробудження зовнішніми сенсорними подразниками), менша кількість більш глибокого сну (NREM) відомого як повільний сон (SWS), збільшення часу, проведеного в більш легких NREM-стадіях 1 і 2, коротші та менші цикли NREM-REM сну та збільшення часу, проведеного в неспанні протягом ночі.

Частота денного сну також зростає в більш пізньому віці: 10% дорослих у віці 55–64 років і 25% у віці 75–84 років повідомляють про появу денного сну. У цих старших вікових групах приблизно половина таких снів є незапланованими. Це збігається з висновком про те, що 1 з 4 літніх людей повідомляє, що відчуває денну сонливість, настільки серйозну, що регулярно порушує денні плани і може відображати багато характерних порушень нічного сну, описаних вище (наприклад, більше фрагментований сон, менший загальний час сну та менший повільний сон).

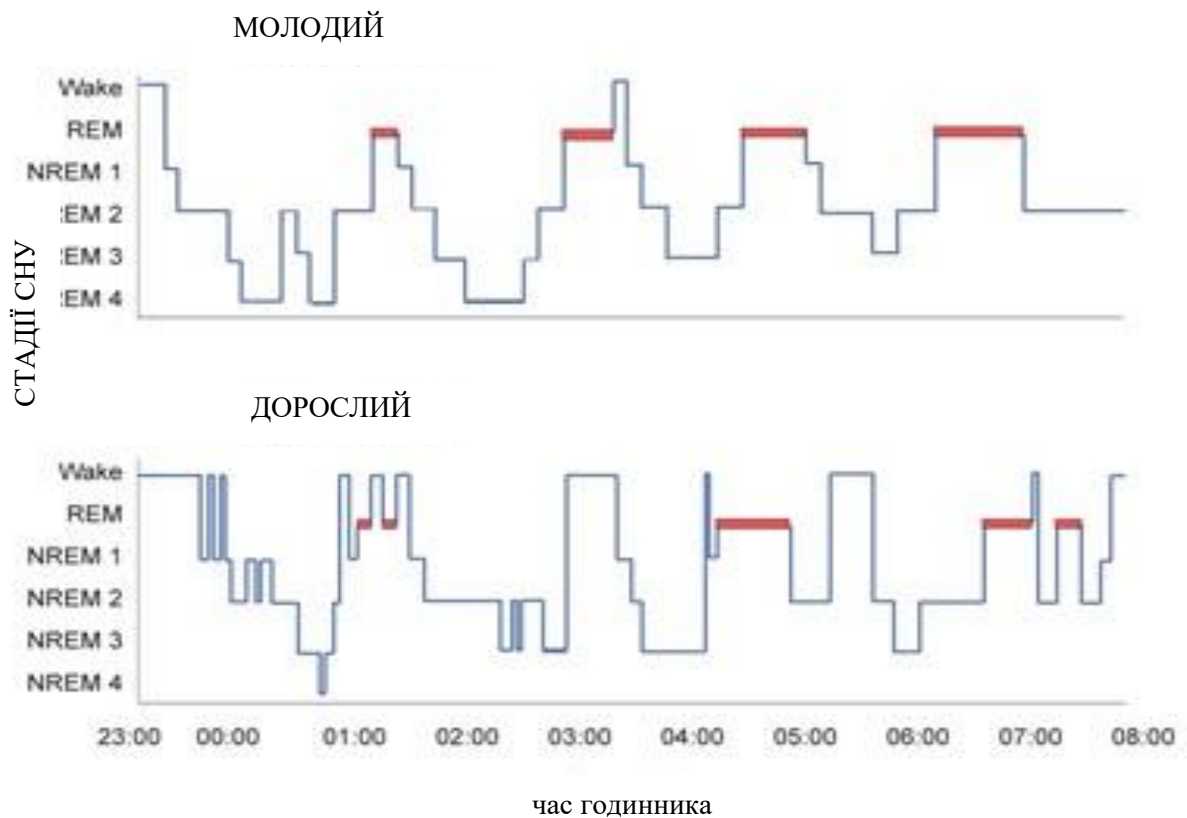


Рисунок 1.7 – Макро зміни сну

У моделі використовувався набір даних ($N = 2532$), який був розділений на здоровий навчальний набір ($N = 1343$), який використовувався для навчання моделі, і тестовий набір ($N = 1189$) для оцінки ефективності моделі. Спочатку була порівняна ефективність прогнозування віку (рис. 1.8) за допомогою особливостей макроструктури сну, під час тестування встановили середнє абсолютне відхилення за ознаками макроструктури (MAD) було значно вищим (23,3 року), ніж за ознаками ЕЕГ (7,8 року), а кореляція (r) була слабшою (0,46, 95% ДІ 0,42–0,50), ніж з використанням функцій ЕЕГ (0,82, 95% ДІ 0,80 – 0,84). Результати свідчать про те, що вплив віку на активність мозку більш послідовно відображається на ЕЕГ уві сні (мікроструктура), ніж у складі стадії сну (макроструктура).

Зображено розсіювання прогнозованого віку проти фактичного з використанням (А) особливостей макроструктури ЕЕГ уві сні та (В) особливостей мікроструктури сну. Червона пунктирна діагональна лінія є тотожною лінією, де прогнозований дорівнює фактичному.

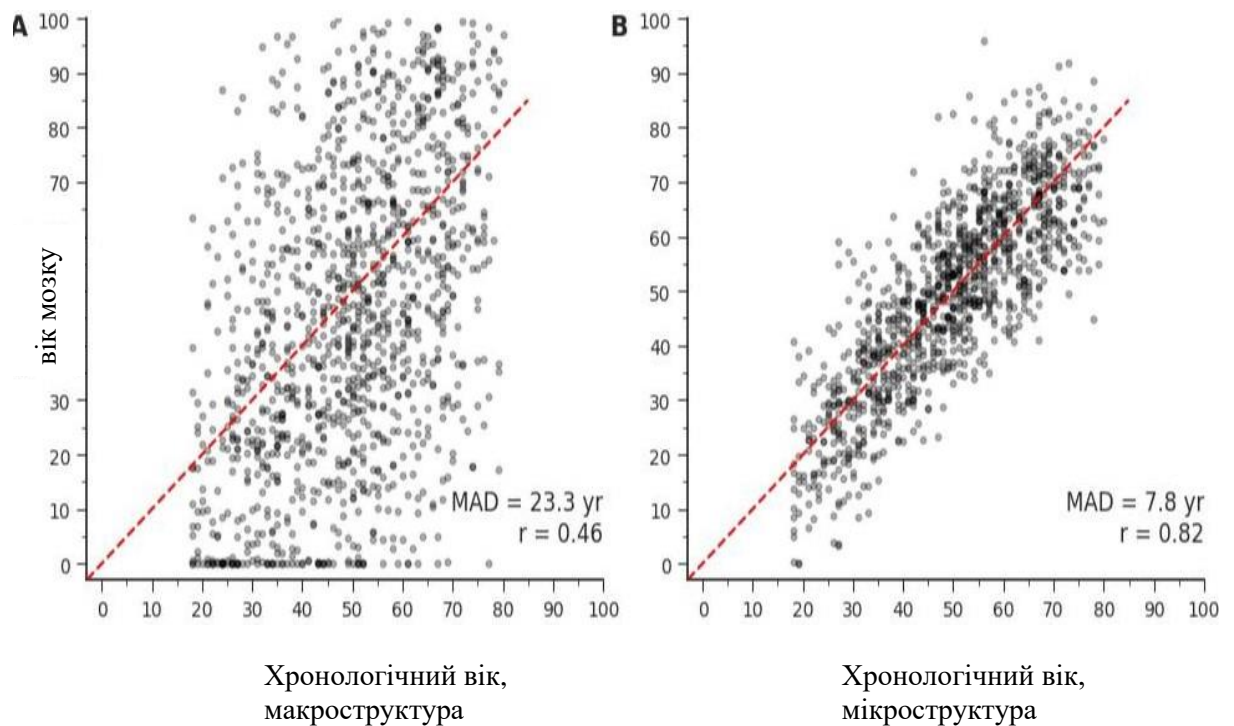


Рисунок 1.8 – Ефективність прогнозування віку

1.4 Висновки до першого розділу

У цьому розділі наведено огляд останніх досліджень у галузі аналізу електроенцефалограми (ЕЕГ) за допомогою різних методів. Розглянуті різні напрямки досліджень:

- обробка біомедичних цифрових сигналів, які можуть бути отримані з різних джерел та мають широкий спектр застосувань у медицині;
- дослідження фаз і циклів сну, які є важливі для розуміння того, як сон впливає на наше здоров'я та самопочуття;
- дослідження з визначення віку клітин мозку, які є важливою областю нейробиології. Ці дослідження можуть допомогти нам краще зрозуміти, як мозок старіє, і розробити нові методи лікування захворювань, пов'язаних із віком, таких як хвороба Альцгеймера та хвороба Паркінсона.

РОЗДІЛ 2

МЕТОДИ ДЛЯ АНАЛІЗУ ЕЛЕКТРОЕНЦЕФОЛОГРАМИ

Аналіз ЕЕГ залишається поширеним інструментом для пошуку і застосування математичних методів, на молекулярному та клітинному рівнях пов'язані зі старінням біомаркери включають довжину теломер лейкоцитів, експресію локусу, н-глікановий профіль, делеції мітохондріальної ДНК, а також статус метилювання ДНК по всьому геному. На структурному рівні анатомія мозку різко змінюється протягом життя, наприклад, об'єм кори, об'єм таламуса і цілісність білої речовини зменшуються зі старінням.

2.1 Метод опорних векторів

Метод опорних векторів заснован на припущенні про поділ простору об'єкту на підпростори, які є дотичні класам. У випадку бінарного класифікатора навчання метод звужується до пошуку гіперплощини з товщиною, це математична сутність методу, яка ділить об'єкти різноманітних класів навчального масиву даних [7]. Приклад на рис. 2.1, де площина тривимірного простору розділює блакитні і червоні кульки.




Рисунок 2.1 – Зразок відділяючої гіперплощини

Нехай є два класи $\{-1, +1\}$, де об'єкти простору X описуються n - вимірними дійсними векторами: $X = \mathbb{R}^n$, $Y = \{-1, +1\}$. Тоді лінійний пороговий класифікатор виглядає [8]:

$$a(x) = \text{sign} \left(\sum_{j=1}^N w_j x_j - w_0 \right) = \text{sign} (\langle w, x \rangle - w_0), \quad (2.1)$$

де $x = (x^1, \dots, x^n)$ – вектор ознак x ; вектор $w = (w^1, \dots, w^n) \in \mathbb{R}^n$ і $w_0 \in \mathbb{R}$ – параметри алгоритму, котрі необхідно шукати по навчальній вибірці, рівняння $\langle w, x \rangle = w_0$ – опис гіперплощини, яка ділить класи у простору \mathbb{R}^n .

Метод опорних векторів розшукує відділяючу гіперплощину, найбільш віддалену від деяких точок вибірки. Відстань між розглянутою гіперплощиною та найближчою точкою вибірки називають зазором класифікатора. В методі опорних векторів мають на увазі, що найважливіша функція розраховується малою підмножиною вибірки, яка впливає на розташування відділяючої гіперплощини. Такі точки мають назву опорних векторів (рис. 2.2). [9]

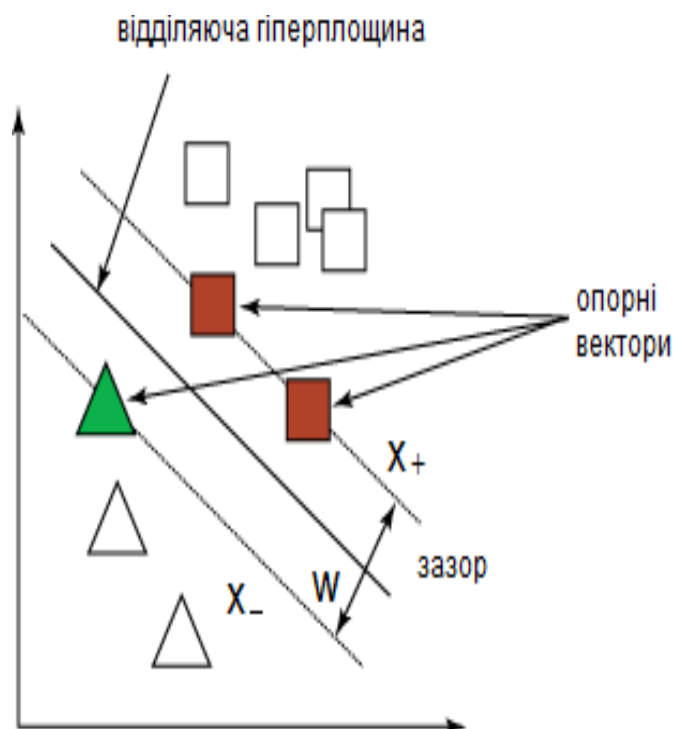


Рисунок 2.2 – Розташування гіперплощини та опорні вектори

Тобто, щоб розділяючи гіперплощини максимально далеко розташовувались від значень вибірки, має бути максимальною ширина смуги та дорівнювати [8]:

$$\frac{\langle x_+ - x_-, w \rangle}{\|w\|} = \frac{2}{\|w\|} \quad (2.2)$$

де, x_- та x_+ – класи об'єктів.

Засіб, за допомогою якого можна накреслити відділяючу гіперплощину за допомогою методу опорних векторів, не унікальний (рис. 2.3). Є багато різноманітних варіантів зосередження гіперплощини.

Об'єкти, які класифікуються, не в кожному випадку можуть розділитися гіперплощиною. Реальні системи мають похибку в даних (рис. 2.4), через яку гіперплощина не виконує розподіл з абсолютною точністю. [7]

Метод опорних векторів не змушений враховувати багато похибок класифікацій об'єкту, тому заводять додатковий параметр, який встановлює яка кількість невірно класифікованих об'єктів можуть перетинати зазор гіперплощини та наскільки далеко вони розташовані відносно них. Вводиться навколо гіперплощини м'яка межа похибки.




Рисунок 2.3 – Варіанти розташування гіперплощини у просторі




Рисунок 2.4 – Варіаційні похибки під час класифікації об'єктів

Об'єкти, які класифікуються, можуть бути розділені лінійно тільки в деяких випадках. Найчастіше вони не є такими. Задля вирішення цієї проблеми лінійного розподілу застосовують функції ядра, які проєктують дані у багатовимірний простір з низьковимірною.

Об'єкти можуть розділятися лінійно гіперплощиною у багатовимірному просторі при вдалому виборі функції ядра .

2.2 Метод машинного навчання

В дослідженні [10] досліджується, чи впливають вікові зміни на ЕЕГ-сигнали мозку, і чи можливо передбачити хронологічний вік, використовуючи сувору структуру із новим та розширеним виділенням характеристик ЕЕГ. Дані ЕЕГ отримані від 468 здорових учасників з розладами настрою/тривоги, харчової поведінки та вживання психоактивних речовин (297 жінок). П'ять наборів попередньо оброблених характеристик ЕЕГ по каналах і діапазонах частот використовуються з різними методами для прогнозування віку, використовується підхід вкладеної перехресної перевірки і стек-ансамбль навчання на основі характеристик ЕЕГ, виводяться особливості та їх просторовий розподіл. Загальна послідовність методу: попередня обробка даних ЕЕГ, вилучення функцій ЕЕГ,

зменшення функцій, методи машинного навчання, результати.

Для кожного сканування дані ЕЕГ попередньо оброблялися за допомогою внутрішнього сценарію, розробленого в MATLAB. Сценарій розроблявся для видалення артефакту градієнта та кардіобалістичного артефакту з даних ЕЕГ. Потім кардіобалістичний артефакт був скоригований за допомогою віднімання оптимальних базових наборів, що вимагає визначення часу циклу артефакту. Щоб досягти надійного визначення циклу артефакту, сценарій визначав цикл артефакту, використовуючи кардіобалістичний компонент безпосередньо з даних, що були виділені за допомогою аналізу незалежних компонентів і були автоматично ідентифіковані.

Надалі відбувалося виділення ознак, які залежить від пошуку загальних ознак серед зразків ЕЕГ. Кожен канал розділений на m епох, звідти відфільтровували кожен епоху на діапазони частот α , β , θ , γ і W . Потім для кожної відфільтрованої епохи застосували бажану функцію. Це призвело до m значень ознаки з усіх епох, які потім усереднюються для оцінки функції на рівні каналу. На малюнку (рис. 2.5) представлено кожен функцію за допомогою трьох індексів: $f(\text{канал}, \text{епоха}, \text{діапазон})$ з каналом = $[1..N]$, епохою = $[1..m]$ і діапазоном = $[\alpha, \beta, \theta, \gamma, W]$. Остаточний вихід є функцією на рівні каналу та представлений двома індексами $f(\text{канал}, \text{діапазон})$. [12]

До уваги брались смуги ЕЕГ ($\delta = 0,5-4$; $\theta = 4-7$; $\alpha = 7-13$; $\beta = 13-30$; $W = 0,5-30$) Гц за допомогою біполярного монтажу ЕЕГ, де W позначає весь частотний діапазон ЕЕГ. Позначили ряди ЕЕГ як $x_i[n]$ із діапазонами частот $i = \alpha, \beta, \theta, \gamma, W$ і n – індекс каналу (загальна кількість каналів $N = 31$). Вибрали п'ять типів ознак: амплітуда, діапазон, спектр, зв'язність і фрактальна розмірність. Записи ЕЕГ були розділені від кожного суб'єкта на 60 с і 50% перекриття між епохами (14 епох). Для кожного каналу сигнал розділений на m епох, а потім відфільтровується кожна епоха у відповідні діапазони частот. У підсумку було оцінено характеристику на рівні каналу для відповідного діапазону частот як середнє за всі епохи. [13]

ПОПЕРЕДНЬО ОБРОБЛЕНИЙ ЕЕГ

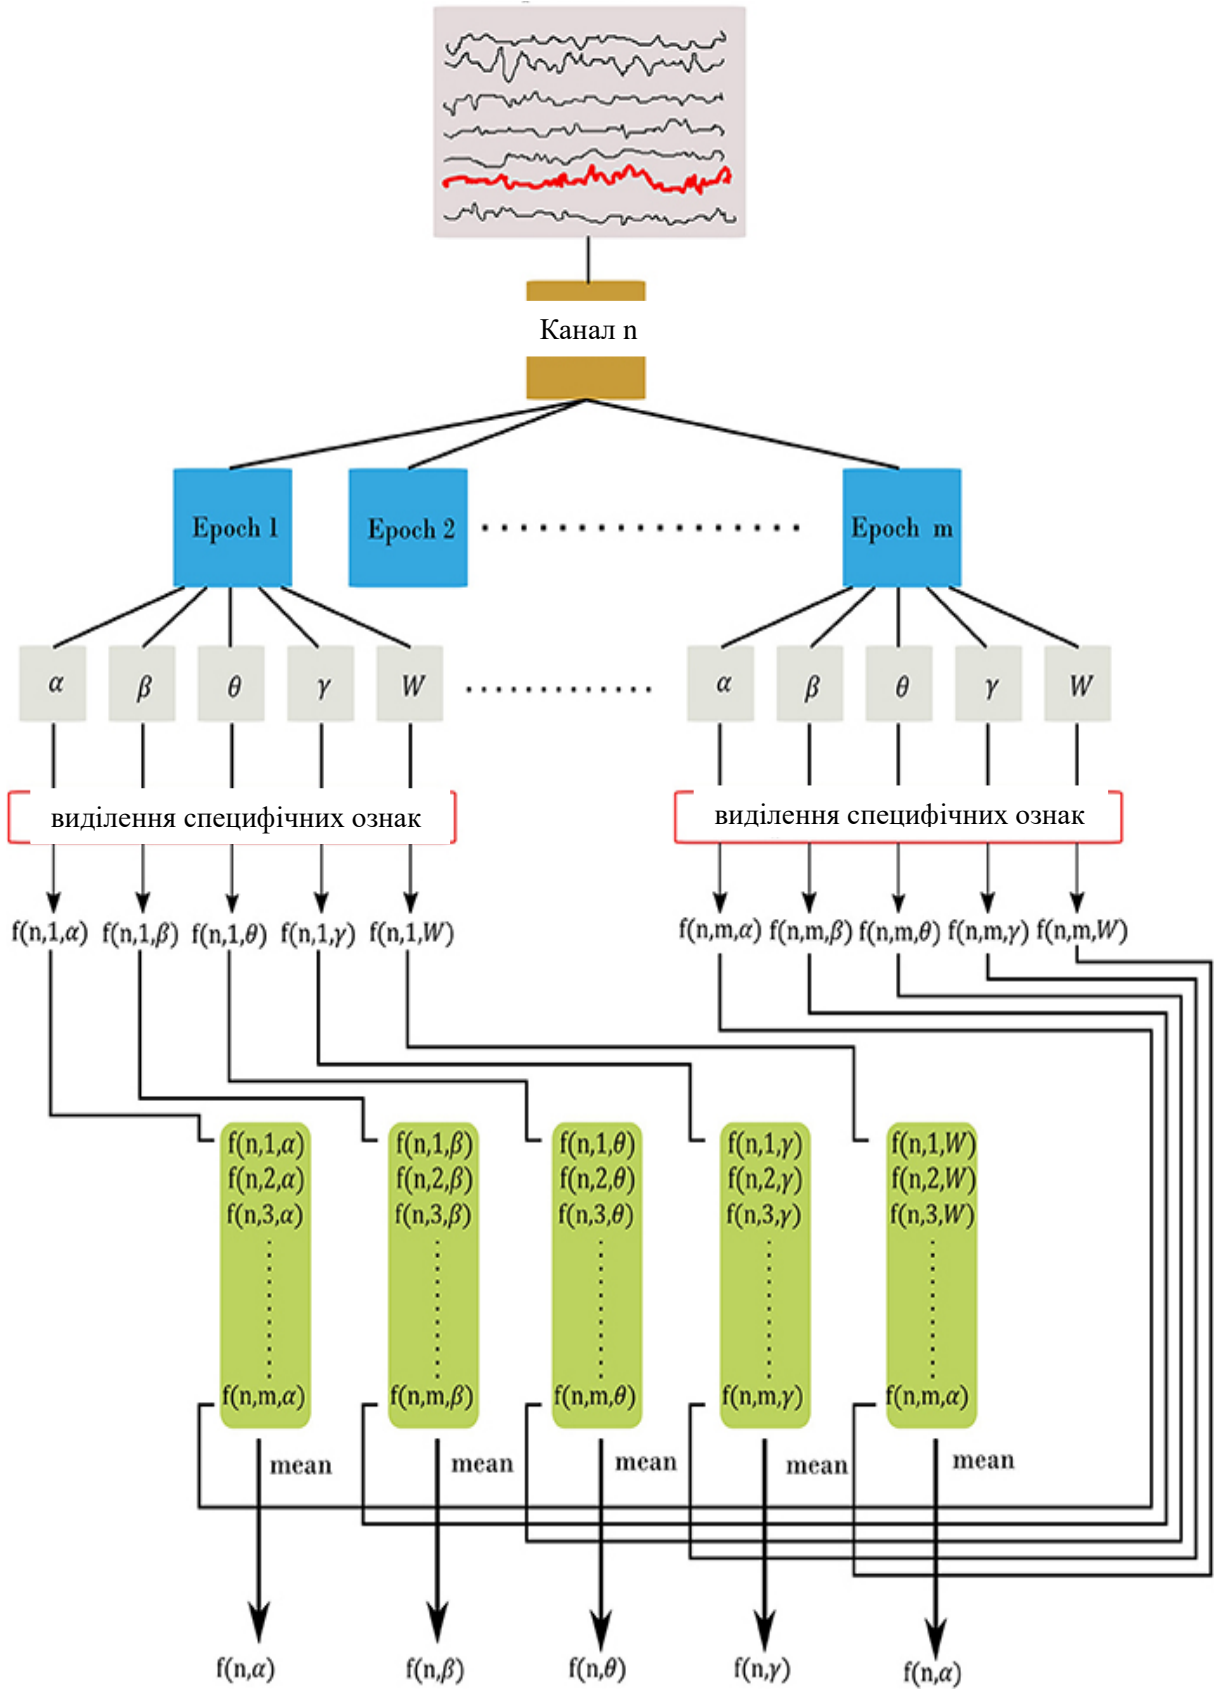


Рисунок 2.5 – Процедура вилучення ознак

Амплітудні ознаки характеризують статистичні властивості потужності сигналу і обвідна сигналу. Було розраховано: середнє значення, стандартне відхилення, асиметрія та ексцес для кожного каналу в діапазонах частот. Обвідна сигналу обчислюється з використанням середнього значення обвідної $e[n]_i$, яке ідентифікується як $e_i[n]=|x_i[n]+jH\{x_i[n]\}|^2$, за допомогою якого відбувається перетворення Гільберта. [14]

Характеристики діапазону враховують зміни напруги від піку до піку та характеризують зміни сигналу з часом. Щоб досягти цього сегментується кожна епоха на короткочасні частини, кожна з розміром вікна $w = 2$ с і перекриттям = 50%. Потім для кожного сегмента розраховується відповідний діапазон від піку до піку. Це створило вибірки з кожної епохи для оцінки середнього, медіани, 5-го та 95-го процентилів, стандартного відхилення, коефіцієнта варіації та міри симетрії. [15]

Спектральні характеристики були найбільш часто використовуваними характеристиками для ЕЕГ. Щоб отримати спектральні характеристики, застосовували періодграму Велча для оцінки спектральної щільності потужності і вікна Хеммінга з довжиною 2 с і перекриттям 50%. Було виділено наступні спектральні характеристики: потужність, відносна потужність, ентропія (з використанням методів Вінера та Шенона), крайова частота (частота зрізу, на якій охоплює 95% спектральної потужності) і відмінності між послідовними короткочасними спектральними оцінками.

Розрахован індекс симетрії мозку як середнє значення різниці між лівою та правою півкулями для кожного діапазону частот ($K = \delta, \theta, \alpha, \beta, \gamma$). [16]

Крім того, розрахована медіана та лаг максимального коефіцієнта кореляції Спірмена між огинаючими каналів, що спарюються півкулями, та когерентністю між парами каналів. Зведені результати розпізнавання ознак представлені в таблиці 2.1.

Таблиця 2.1 – Витягнуті ознаки з даних ЕЕГ

Група ознак	Підмножина функцій	Кількість функцій
Амплітуда	Загальне середнє значення потужності, стандартне відхилення, асиметрія, ексцес, середнє значення обвідної та стандарт	6x4x31
Вік від піку до піку	Середнє значення, медіана 5 та 95 проценталі, стандартне відхилення, коефіцієнт, варіації та міра симетрії	7x4x31
Спектральна потужність	Спектральна та відносна потужність, спектральна ентропія (за методами Вінера та Шенона), частота краю спектра (частота зрізу, який охоплює 95%) спектральної потужності і спектральні відмінності між послідовними короткочасними спектральними оцінками	6x4x31
Підключення	Індекс симетрії мозку, кореляція, середнє значення та максимум частоти, при якій досягається максимальна когерентність	5x4
Фрактальна розмірність	Фрактальна розмірність	31

Після виділення ознак були усунуті ознаки, які або мало варіюються між предметами, або сильно корелюють з іншими ознаками, використовуючи програмне забезпечення . Потім знаходиться найвища абсолютна попарна кореляція, якщо дві ознаки мають високу кореляцію ($r \geq 0,9$ кореляції Пірсона), усувається функція з найвищою середньою абсолютною кореляцією. Слід зазначити, що для вибору найкращих характеристик за допомогою підходу NCV можна використовувати інші методи відбору ознак. Однак інтерпретація такого підходу може бути складною, тобто вибрані ознаки внутрішнього циклу NCV можуть відрізнятися в різних складках. Крім того, в кожному циклі NCV слід застосовувати вибір інших функцій, що збільшує накладні витрати на обчислення. Підсумовуючи, видалення корельованих функцій забезпечує кращий спосіб вибору функцій у цьому випадку.

На малюнках показано кореляційні матриці до та після видалення корельованих ознак. Двовимірну візуалізацію простору ознак (рис. 2.6) отримують спочатку за допомогою аналізу головних компонентів, щоб зменшити 510-вимірний простір ознак до 65 вимірів (зберігаючи 95% дисперсії), а потім за допомогою локального лінійного вбудовування для проектування у двох вимірах.




Рисунок 2.6 – Кореляційна матриця для всіх ознак

Вибір відповідних алгоритмів є критично важливим кроком для досягнення надійної оцінки. Після представлення характеристик кожного суб'єкта в одному рядку кінцевий розмір набору даних становить $x = n \times m$, з $n = 468$ і $m = 863$. Використовується пакет «caret» для виконання набору алгоритмів регресії: Еластична сітка (ENET), опорна векторна регресія (SVR), випадковий ліс (RF), екстремальне дерево підвищення градієнта (XgbTree) і процес Гауса з поліномом ядра (gaussprPoly).

Мета полягала в тому, щоб перевірити різні методи, щоб забезпечити кращу оцінку віку. Використовується ядро з радіальною базисною функцією для проектування даних у простір високої розмірності. Пакет caret має такі відмінні риси: використання універсальних синтаксисів у командах, незалежно від синтаксисів вихідних функцій, що реалізують ті чи інші алгоритми, автоматизовані знаходження оптимального значення гіперпараметру моделі, яке в більшості

випадків неможливо обчислювати аналітично, можливості організації паралельного обчислення, яке значно прискорює процеси навчання моделі. [18]

До складу caret входять функції, що сприяють реалізації повного циклу розробки передбачуваних моделей. В таблиці 2.2 наведено приклади деяких з цих функцій.

Таблиця 2.2 – Приклад функцій пакету caret

функція	опис
featurePlot()	призначена до виконання графічного розвідувального аналізу даних.
findCorrelation()	дозволяє виявити предиктори, які значною мірою корелюють з іншими предикторами. Багато статистичних моделей мають чутливість до наявності подібної змінної і можуть давати нестійке рішення (тобто йдеться про проблему мультиколінеарності), у зв'язку з чим предиктори, які один з одним дуже корелюють, потрібно виключати з даних.
train()	одночасно може виконувати навчання моделі, знаходити оптимальні гіперпараметри та оцінювати передбачення сили моделі. Останні дві завдань зреалізовані з використанням різних методів утворення повторної вибірки (багаторазовий бутстреп, бутстреп, декілька видів перехресної перевірки). У процесі навчання параметри задаються аргументом trControl, у який подаються списки параметрів, заздалегідь створені при допомозі функції trainControl(). Якісна оцінка моделі виконується на основі критеріїв, які задаються аргументом metric.
confusionMatrix()	корисним способом узагальнень якостей при роботі з моделями-класифікаторами є зведення міток частот класів у т.зв. "матрицю неточностей" ("confusion matrix"). Функція confusionMatrix() може створити схожі матриці та розраховувати набір підсумкової статистики, який характеризує якість передбачення.

Створюються різні моделі з навчальних даних, а потім усереднюються, щоб мінімізувати розбіжності між моделями. Функція `XgbTree` використовує поєднання ансамблевого навчання, оптимізації та регуляризації для побудови узагальненої моделі з навчальних даних. Функція `gaussprPoly` — це ймовірнісний підхід до побудови регресійної моделі шляхом вивчення розподілу даних навчання з урахуванням відповіді (вік). Подібно до функції ядра, `gaussprPoly` використовує поліноміальне ядро для проектування даних у простір високої розмірності. [19]

Щоб забезпечити неупереджене передбачення віку, під час створення моделей прогнозування прийнято вкладену перехресну перевірку. На малюнку зображено процедуру NCV (рис. 2.7), яка складається з двох основних циклів: внутрішнього та зовнішнього. Внутрішній цикл використовується для пошуку найкращих параметрів із навчального набору, тоді як зовнішній цикл використовується для оцінки найкращих параметрів на тестовому наборі. Щоб детальніше розповісти про NCV, нехай нижній індекс посилається на дані та моделі з внутрішнього циклу NCV, тоді як верхній індекс представляє ті, що із зовнішнього циклу. У циклі використовується десятикратна перехресна перевірка ($K_I=10$) для внутрішнього та десятикратну перехресну перевірку для зовнішнього циклу ($K_O=10$). Внутрішній цикл використовувався для оцінки найкращих параметрів даних навчання ($T_{r^{(1)}}$) за допомогою пошуку по сітці та правила однієї стандартної помилки. Кожен внутрішній цикл складається з 5 повторів ($R=5$) для кожного методу. Зовнішній цикл використовує найкращі отримані моделі для побудови моделі стек-ансамбль. Найкращі моделі представлені своїми найкращими параметрами θ_i^l , де i є індексом методу відповідного методу M_i ($i = 1, \dots, r$), а l відноситься до згортання l із зовнішнього циклу.

Ансамбль стекування допомагає підвищити стабільність прогнозу шляхом поєднання прогнозу з інших моделей, тобто прогнози з п'яти методів були об'єднані шляхом вивчення ваг за допомогою загальної лінійної моделі (GLM). Потім GLM використовувався для надання одного середньозваженого прогнозу в 10-кратній перехресній перевірці ($K_{Ens}=10$). Звідси найкраща модель стек-ансамбль використовувався для прогнозування віку для набору для тестування. Тобто

прогноз віку розраховується за окремими методиками $y_{Tr_i^l} = P_i(Tr^l, \theta_i)$.

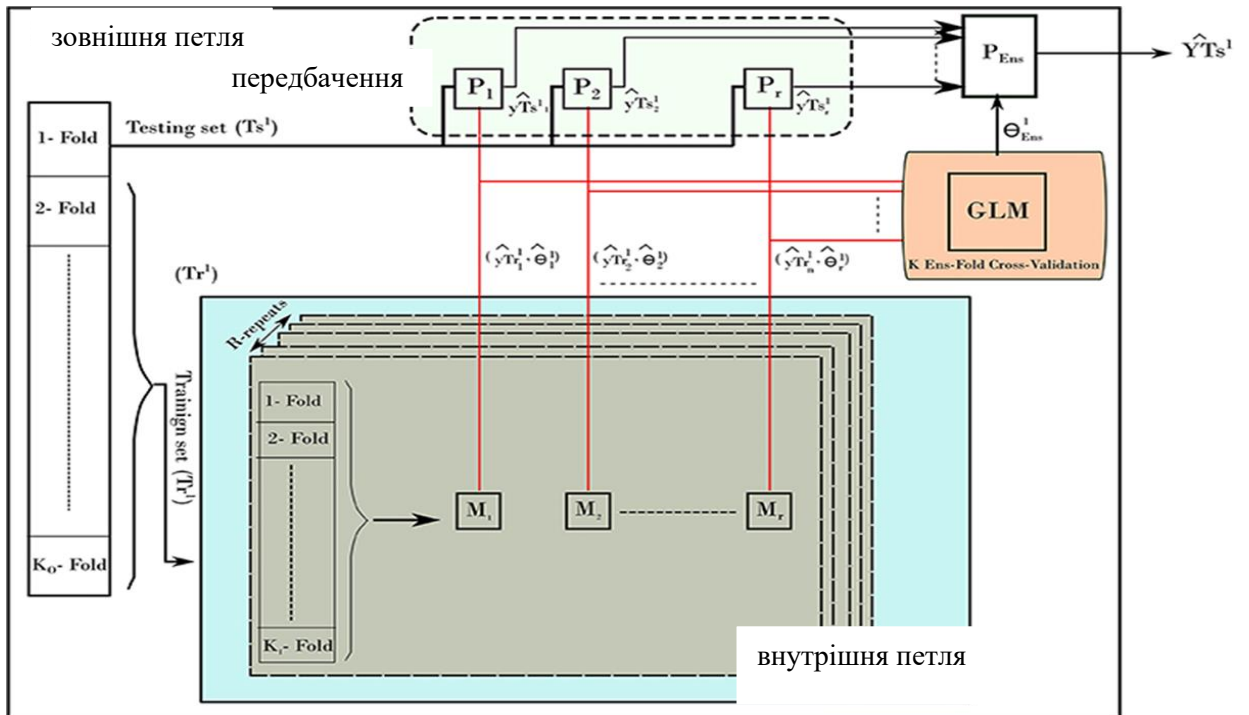


Рисунок 2.7 – Двовимірна візуалізація простору ознак

Після повторення всіх згорток із зовнішнього циклу можна створити прогноз щодо віку для всього набору даних. Крім того, змінна важливість предикторів з моделей ансамблю накопичення була оцінена по зовнішньому контуру NCV. Прогнозований вік, вікові значення використані для оцінки набору даних (рис. 2.8).

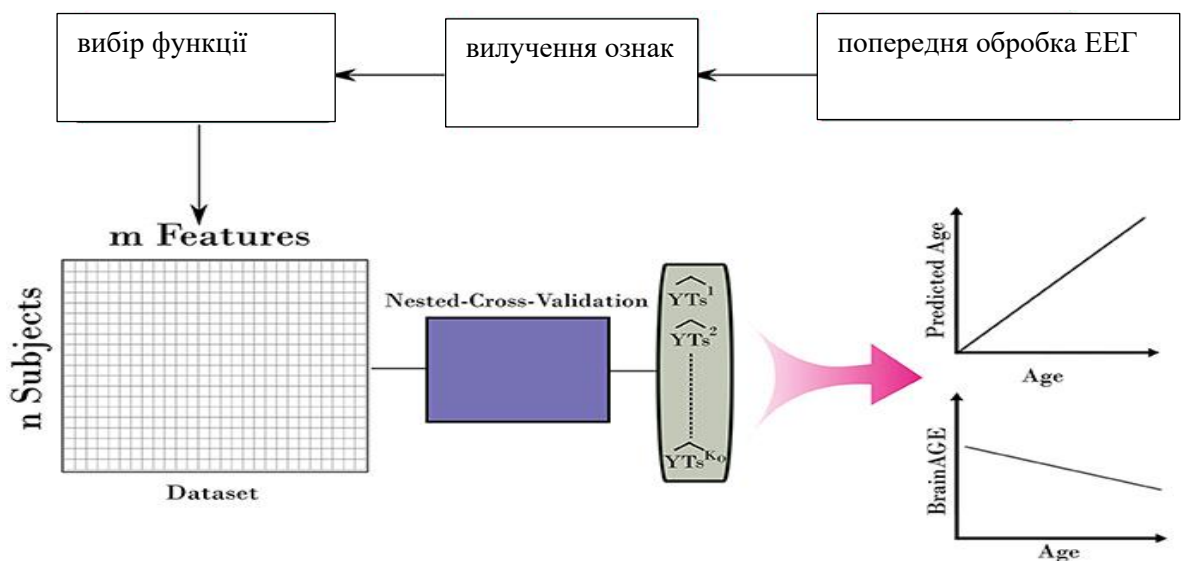


Рисунок 2.8 – структура для оцінки EEG форми

Досліджена ефективність (NCV) для методів Stack-Ensemble і underlay (рис. 2.9), індивідуальна продуктивність для кожного методу розрахована перед фазою стек-ансамбль. Результати показали, що SVR з радіальним ядром досяг найкращої точності $R^2 = 0,34$ (0,056), MAE = 7,01 (0,68) років і RMSE = 8,7 (0,63) років. З іншого боку, стек-ансамбль покращив загальну продуктивність з $R^2 = 0,37$ (0,064), MAE = 6,87 (0,69) років і RMSE = 8,46 (0,59) років. Досліджена кореляція між прогнозованим віком (рис. 2.10) і віком.




Рисунок 2.9 – Моделювання продуктивність за допомогою NCV




Рисунок 2.10 – Прогнозований вік проти віку

Важливість ознак оцінена таким чином, щоб загальна сума важливості ознак становила 100 з кожного згину зовнішньої петлі NCV. Потім оцінки важливості були усереднені по складках. У цьому випадку результатами є середні значення для всіх складок. Виявлені 15 важливих предикторів віку (рис. 2.11). Колір стовпчиків представляє значення кореляції Пірсона між кожним предиктором і віком. З графіка можемо помітити, що спектральна рівність бета-смуги (рис. 2.12) з каналу TP9 є найважливішим предиктором віку з $r = 0,34$.




Рисунок 2.11 – Топ 15 важливих ознак для прогнозування віку

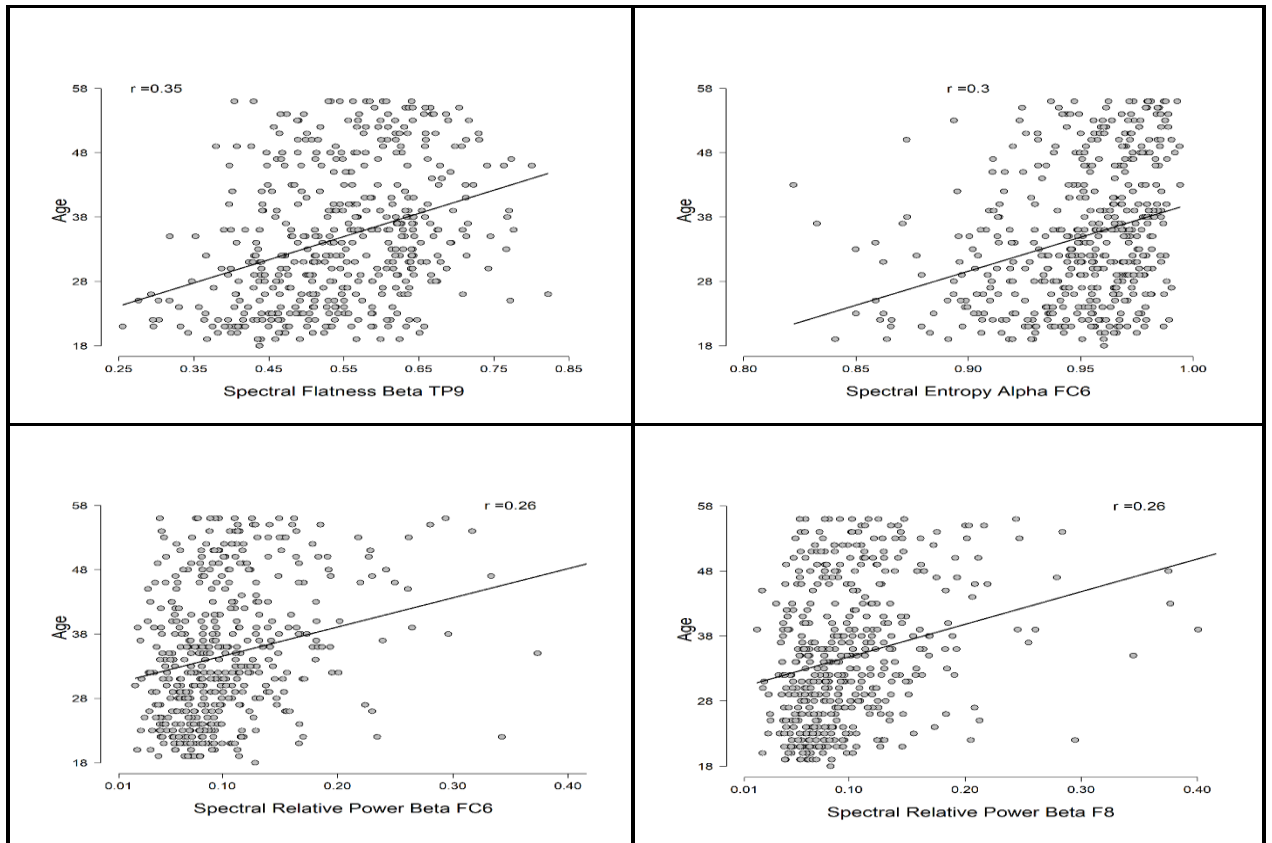


Рисунок 2.12 – Кореляція головних рис з віком

Розглядаємо вплив кількості вибірок (рис. 2.13) на ефективність прогнозування віку на прикладі графіка.




Рисунок 2.13 – Вплив кількості зразків на прогноз віку

2.3 Метод клінічних нейрофізіологічних досліджень

Клінічне нейрофізіологічне дослідження (КНІ) - це метод, який дозволяє дати оцінку функціям мозку за допомогою реєстрації ЕЕГ-сигналів.

Під час КНІ піддослідний робить певні завдання, такі як мовлення, виконання завдань на увагу, запам'ятовування списків слів. Ці завдання дозволяють вивчати зв'язок між поведінковими реакціями та ЕЕГ-сигналами.

КНІ використовується для оцінки широкого спектру функцій мозку, включаючи:

- Увагу
- Пам'ять
- Мову
- Когнітивні функції

КНІ також використовується для моніторингу та діагностики захворювань головного мозку, таких як:

- Травми головного мозку
- Епілепсія
- Деменція

КНІ є відносно неінвазивним методом дослідження, який не вимагає хірургічного втручання. Цей метод для більшості пацієнтів є безпечним.

Однак КНІ може бути небажаним або неможливим у деяких випадках. Наприклад, КНІ не може бути використане у пацієнтів з металевими імплантатами в голові. Також КНІ може бути незручним для пацієнтів з деякими медичними станами, такими як епілепсія.

В цілому КНІ є потужним інструментом для діагностики захворювань головного мозку та вивчення функцій мозку. Цей метод для більшості пацієнтів є відносно безпечним та неінвазивним.

Цей метод може використовуватися для вивчення широкого спектру функцій мозку, включаючи мовлення, пам'ять, увагу, а також для моніторингу захворювань головного мозку та діагностики.

2.4 Висновки по другому розділу

У другому розділі представлені методи для аналізу електроенцефалограми, які можуть бути використані для розпізнавання активності мозку. Методи машинного навчання мають ряд переваг перед класичними методами аналізу ЕЕГ. До таких переваг відносяться:

- методи машинного навчання можуть бути використані для виявлення більш тонких закономірностей в ЕЕГ-сигналах, ніж класичні методи;
- методи машинного навчання можуть бути використані для аналізу більш складних ЕЕГ-сигналів, ніж класичні методи;
- методи машинного навчання можуть бути адаптовані до конкретних задач.

РОЗДІЛ 3

НЕЧІТКИЙ МЕТОД ПРОГНОЗУВАННЯ ВІКУ КЛІТИН МОЗКУ

3.1 База даних дослідження

Для дослідження були використані ЕЕГ-сигнали з медичного факультету, лабораторія сну, кафедра психічного здоров'я та хвороб [20]. У цьому дослідженні ЕЕГ-сигнали були отримані від 30 суб'єктів. Група складалася з 14 жінок і 16 чоловіків у віці від 18 до 65 років, середній вік 33,5 років і індекс маси тіла (ІМТ) $32,4 \pm 7,3$ кг/м². Пацієнти з нормальним інтелектом і без психічних розладів включені в дослідження після проходження неврологічного скринінгу. Усі записи проводились відповідно до стандартів медичної етики. Піддослідні не були позбавлені сну. У них не було відхилень від звичного циркадного циклу і вони не приймали ліків і алкоголю. Фіксувались такі стани: тривожність, сонливість або сон. Використовувалися посріблені електроди записів, і було застосовано стандартний розрахунок С3-А2 суб'єкту експерименту. Вимірювання були отримані за допомогою полісомнографії Grass Model-78.

Таблиця 3.1 – Інформація про пацієнтів

Пацієнт	Стать	Вік	Стан
01	ж	60	без психічних розладів
02	ч	18	без психічних розладів
03	ж	20	без психічних розладів
04	ч	65	без психічних розладів
05	ж	52	без психічних розладів
06	ж	21	без психічних розладів
07	ж	32	без психічних розладів
08	ч	40	без психічних розладів
09	ж	55	без психічних розладів
10	ч	35	без психічних розладів
11	ж	25	без психічних розладів
12	ж	40	без психічних розладів
13	ж	50	без психічних розладів
14	ч	27	без психічних розладів

Продовження таблиці 3.1 – Інформація про пацієнтів

15	ч	41	без психічних розладів
16	ч	44	без психічних розладів
17	ж	53	без психічних розладів
18	ч	47	без психічних розладів
19	ч	37	без психічних розладів
20	ж	61	без психічних розладів
21	ж	46	без психічних розладів
22	ч	30	без психічних розладів
23	ч	39	без психічних розладів
24	ч	19	без психічних розладів
25	ж	58	без психічних розладів
26	ч	35	без психічних розладів
27	ч	22	без психічних розладів
28	ч	44	без психічних розладів
29	ж	55	без психічних розладів
30	ч	33	без психічних розладів

Записи були відфільтровані смуговим фільтром між 0,3 і 70 Гц.

Дані містять ЕЕГ, ЕОГ, ЕМГ підборіддя та маркери подій. Деякі записи також містять дані про дихання та температуру тіла [21].

ЕЕГ FPZ - електроенцефалограма, зареєстрована між передньою центральною точкою на лобі та центральною точкою на маківці. ЕЕГ PZ-OZ - електроенцефалограма, зареєстрована між тім'яно-потиличної і потиличної точками. Для дослідження взаємозв'язку сигналів уві сні я використовую ЕЕГ PZ-OZ (тім'яно-потиличні відведення), тому що під час сну найбільш виражені зміни біоелектричної активності відбуваються в потиличних і тім'яних ділянках кори головного мозку. Відведення ЕЕГ PZ-OZ реєструє активність саме цих ділянок.

З віком відбуваються зміни структури сну, збільшується латентність і тривалість дельта-хвиль, знижується тривалість REM фази. Ці зміни добре відображаються в задніх відведеннях ЕЕГ PZ-OZ. Фронтальні відведення ЕЕГ FPZ-CZ меншою мірою відображають вікові зміни сну і частіше використовуються для інших цілей.

Таким чином, для дослідження впливу віку на структуру сну краще використовувати тім'яно-потиличні відведення EEG PZ-OZ, а не фронтальні FPZ-CZ. Це дасть змогу отримати більш надійні та інформативні дані.

Для дослідження взаємозв'язку сигналів уві сні з віком людини я використовую тільки дані sleep-telemetry (телеметричної полісомнографії), а не sleep-cassette.

Sleep-telemetry дає змогу проводити безперервну багатоканальну реєстрацію біосигналів протягом усієї ночі сну пацієнта. Це дає повніші дані для аналізу структури сну. Під час sleep-cassette запис ведеться тільки фрагментарно, тому можна прогавити важливі стадії сну та їхню динаміку. Телеметричну полісомнографію проводять у домашніх умовах, що важливо під час дослідження літніх людей. Sleep-cassette часто записується в незвичних умовах лабораторії.

Дані sleep-telemetry менше схильні до артефактів, оскільки немає необхідності від'єднувати і приєднувати датчики в процесі. Цифровий запис під час телеметрії забезпечує більш високу якість і точність даних.

Таким чином, sleep-telemetry дає більш надійні, повні і якісні дані для дослідження впливу віку на структуру сну. Ці переваги переважають вищу вартість обладнання для телеметрії.

ST7011J0-PSG і ST7011JP-Hypnogram - це назви протоколів запису полісомнограми. Розшифровуються вони так:

- ST - позначення серії систем полісомнографії Nihon Kohden;
- 7011 - модель конкретного полісомнографа;
- J0 - варіант протоколу запису з використанням 10 каналів;
- PSG - полісомнографія (polysomnography);
- Hypnogram - гіпнограма, графік стадій сну.

Тобто ST7011J0-PSG - це протокол 10-канальної полісомнографії, а ST7011JP-Hypnogram - протокол побудови гіпнограми сну на основі цих даних.

Візуалізувати ці дані можна за допомогою програмного забезпечення Polysom.




Рисунок 2.13 – Візуалізація даних

3.2 Методи перетворення сигналу ЕЕГ

Вказано різні епохи ЕЕГ (Рис. 3.1). Сигнали реєструвалися протягом 7 год, епізодові цифрові сигнали приймалися кожні 20 хвилин для кожного блоку. Потім ці записи ЕЕГ були розділені на 5 епох і ці епохи розділені на чотири піддіапазони частот, такі як α , β , θ та δ .

Для розрізнення нестационарних сигналів з різними частотними особливостями використовувалося вейвлет-перетворення [22]. Сигнал є нерухомим, якщо він не сильно змінюється з часом. Перетворення Фур'є можна застосувати до стаціонарних сигналів. Однак, як і ЕЕГ, сигнали можуть містити нестационарні або перехідні характеристики. Тобто, не найкраще застосовувати пряме перетворення Фур'є на такі сигнали.




Рисунок 3.1 – ЕЕГ сигнали: а) тривога (б) сонливість (с) сон

Вейвлет-перетворення розкладає сигнал на набір функцій, які називаються вейвлетами. [23] Ці основні функції отримані розширеннями, скороченнями та зсувами називаються вейвлет-прототипом. [24] Безперервні вейвлети – це функції, породжені з однієї єдиної функції ϕ шляхом розширення. [25]

Сімейство вейвлетів (DWT) розраховується за наступною формулою:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (3.1)$$

де b - дійсне значення і називається параметром зсуву.

Оскільки параметри (a , b) мають неперервні значення, перетворення називається безперервним вейвлет-перетворенням. Визначення класичних вейвлетів як розширень однієї функції означає, що високочастотні вейвлети відповідають $a < 1$ або вузькій ширині, тоді як низькочастотні вейвлети мають ширину $a > 1$ або більше.

В вейвлет-перетворення $f(t)$ виражається як лінійна комбінація масштабування та вейвлет-функції. Обидві функції масштабування і вейвлет-функції є повними наборами. [25] Однак зазвичай використовують і вейвлет і функції масштабування в представленні перетворення. Загалом, параметри масштабу та зсуву сімейства дискретних вейвлетів подаються як:

$$a = a_0^j \text{ і } b = kb_0 a_0^j \quad (3.2)$$

де j і k — цілі числа.

Загалом, функція може бути повністю представлена використовуючи L -кінцеву роздільну здатність вейвлета та функцію масштабування зі значенням параметрів $a_0 = 2$ і $b_0 = 1$ як:

$$f_w(t) = \sum_{k=-\infty}^{\infty} c_{L,k} 2^{-\frac{L}{2}} \varphi(2^{\frac{t}{L}} - k) + \sum_{j=1}^L \sum_{k=-\infty}^{\infty} d_{j,k} 2^{-j/2} \psi(2^{t/j} - k) \quad (3.3)$$

Сімейство вейвлетів аналізує сигнал у різних діапазонах частот, з різною роздільною здатністю шляхом розкладання сигналу на грубе наближення та детальну інформацію. DWT працює з двома наборами функцій, які називаються функціями масштабування та вейвлетом функції, які пов'язані з нижніми і високими частотами фільтрів відповідно. Розкладання сигналу на різні смуги

частот просто отримують послідовними фільтраціями високих і нижніх частот сигналу часової області.

Початковий сигнал $x(n)$ спочатку пропускається через половину діапазону фільтру високих частот $g(n)$ і фільтр низьких частот $h(n)$. Після фільтрації половина зразків може бути виключена відповідно до критерію Найквіста, оскільки сигнал тепер має найвищу частоту $\pi/2$, радіан замість π . Тому сигнал може бути відібрано на 2, просто відкидаючи кожен іншу пробу. Ця процедура становить один рівень декомпозиції і математично можна виразити наступним чином:

$$Y_{high}[k] = \sum x[n]g[2k - n] \quad (3.4)$$

де $Y_{high}[k]$ - вихід високочастотного сигналу і фільтрів низьких частот після субдискретизації. [26]

Наведена вище процедура, яка також відома як піддіапазон кодування, можна повторити для подальшої декомпозиції. На кожному рівні, фільтрація та підвибірка призведе до половини кількості вибірок.

Вейвлет перетворення порядку 2 Добеші було застосовано до таких понять: тривога, сонливість і сигнали сну. Нижче показано (рис. 3.2) п'ять різних рівнів наближення (позначаються a_1 – a_5 і відображаються у лівому стовпчику) та деталі (позначені d_1 – d_5 і відображені у правому стовпчику) сигналу ЕЕГ. Ці приблизні та детальні записи реконструйовано з вейвлет коефіцієнтів. Апроксимація a_4 отримується шляхом накладання деталей d_5 на апроксимацію a_5 , наближення a_3 отримується шляхом накладання деталей d_4 на апроксимацію a_4 і так далі. Нарешті виходить вихідний сигнал шляхом накладання деталей d_1 на апроксимацію a_1 . Вейвлет перетворення діє як математичний мікроскоп, масштабуючи малі масштаби, щоб виявити компактно розподілені події в часі, і зменшуючи масштаби у великих масштабах, щоб продемонструвати глобальні шаблони хвилі. [27]




Рисунок 3.2 – Вейвлет перетворення Добеші сигналу ЕЕГ

Тришарова штучна нейронна мережа прямого зв'язку з одним прихованим шаром і одним вихідним шаром (рис. 3.3) були навчені за допомогою стандартного алгоритму зворотного поширення. Вхідний вектор застосовується до вхідного шару, де всі вхідні дані розподіляються по кожному підрозділу в прихованому шарі. Всі одиниці мають вектори ваги, які множаться на ці вхідні дані вектора. Кожна одиниця підсумовує ці вхідні дані та створює значення, що перетворюється нелінійною функцією активації, для яких використовуємо загальну асиметричну сигмоїдну функцію. Потім результат кінцевого шару обчислюється шляхом множення вихідного вектора із прихованого шару за вагами на завершальний шар. Додаткові суми та активації цих одиниць дають фактичний результат мережі. Визначення відповідної кількості прихованих шарів є одним із найбільш критичних завдань у розробці нейронної мережі.




Рисунок 3.3 – Багатошарова модель нейронної мережі

Визначення відповідної кількості прихованих шарів є одним із найбільш критичних завдань у розробці нейронної мережі. В мережі з малою кількістю прихованих вузлів буде неможливо розрізнити складні моделі, що призведе лише до лінійної оцінки фактичної тенденції. Зі збільшенням кількості прихованих шарів навчання стає надто трудомістким. Найпопулярніший підхід до пошуку оптимальної кількості прихованих шарів здійснюється методом проб і помилок. [28] У цьому дослідженні нейронна мережа складалася з одного вхідного шару, одного прихованого шару та одного вихідного шару.

Стосовно похибки вимірювання, враховуючи випадковий набір початкових ваг, виходи мережі будуть дуже відрізнятися від бажаних класифікацій. [29] Коли мережа навчається, ваги системи постійно коригуються, щоб зменшити різницю між виходом системи та бажаною реакцією. Різниця називається похибкою і може бути виміряна в кількох шляхах. Найпоширенішим вимірюванням є SSE і MSE. SSE – це середнє значення квадратів різниці між кожним результатом і бажаним результатом. [30] У цьому дослідженні SSE використовується для вимірювання продуктивності нейронної мережі.

Виконується наступна процедура перехресної перевірки для навчання мережі як способу контролю надмірної підгонки навчання даних: випадковим чином обираємо набір даних 13 суб'єктів (60% загальних даних) для навчання мережі та

набір даних 5 суб'єктів (10% загальних даних) для перевірки після кожної епохи навчання. Помилка мережі в даних перевірки обчислюється після кожного проходу або епохи через навчальні дані. Після 5416 епох стан мережі (її значення ваги) в епоху, для якої помилка перевірки є найменшою, вибирається як мережа, яка найкраще працюватиме з новими даними. Ця найкраща мережа потім застосовується до даних решти 12 суб'єктів (30% загальних даних), які називають тестовим набором. Усі репрезентації класифікували 30 разів з використанням різних випадкових виборів наборів тренувань, валідації та тестування та початкових значень ваги. [31] Ефективність оцінювалася як на тренувальному, так і на перевірочному наборі.

Класифікація та регресія нейронної мережі використовуються як для класифікації, так і для регресії. У класифікації мета полягає в тому, щоб призначити шаблони вхідних даних одному з кількох класів, зазвичай представлених виходами, які обмежені діапазоном від 0 до 1, щоб вони представляли ймовірність приналежності до класу. При проведенні класифікації конкретний зразок відносять до конкретного класу відповідно до обраних для нього характерних ознак. У регресії бажаний вихід і фактичні результати мережі можуть бути показані на одному графіку, і таким чином можна оцінити продуктивність мережі.

У дослідженні представлено метод класифікації стану пильності до станів тривоги, сонливості або сну на основі поточної ЕЕГ для довільного здорового суб'єкта. Доведено, що вейвлет-аналіз записів ЕЕГ є потужним інструментом для визначення стадій сну та переходів від тривожного до сонного стану. [32] Вейвлет аналіз використовував той факт, що така ЕЕГ складається з характерного ритму, який зникає коли суб'єкт стає сонним. [33] Статистична класифікація сигналів ЕЕГ може бути ефективним методом для класифікації та виявлення змін у пильності, хоча вона не використовувалася для розрізнення між станом настороженості та сонливістю. [34]

У цьому дослідженні рівень сонливості за сигналами ЕЕГ був отриманий за допомогою дискретного вейвлет перетворення (DWT) . Сигнали записували протягом 7 годин епізодів, а цифрові сигнали приймали кожні 20 хвилин для

кожного блоку. Потім ці записи ЕЕГ були розділені на 5 сек. епохи (рис. 3.4) і ці епохи були розділені на піддіпазони частот, такі як α , β , θ і δ , за допомогою DWT. Потім спектральна щільність потужності (PSD) вейвлет піддіпазону частот δ (1–4 Гц), θ (4–8 Гц), α (8–13 Гц) і β (13–30 Гц) застосовуються до PSD. Стан тривоги має змішані частоти: α і β . У сонному стані α зникне. Під час сну α і β втрачаються, δ і θ спостерігаються.




Рисунок 3.4 – Спектральні щільності потужності тривоги, сонливості та сну

3.3 Нечітка модель Сугено адаптивної мережі

В цьому дослідженні система нечіткого логічного висновку будується на основі адаптивної мережі ANFIS. ANFIS — це нечітка модель Сугено, введена в структуру адаптивних систем для полегшення навчання та адаптації. [35] Така структура робить моделювання ANFIS більш систематичним). Щоб представити архітектуру ANFIS, розглядаються два нечітких правила «якщо-тоді» на основі моделі Сугено першого порядку:

$$\text{Правило 1: якщо } (x \in A_1) \text{ та } (y \in B_1) \text{ тоді } (f_1 = p_1x + q_1y + r_1) \quad (3.5)$$

$$\text{Правило 2: якщо } (x \in A_2) \text{ та } (y \in B_2) \text{ тоді } (f_2 = p_2x + q_2y + r_2) \quad (3.6)$$

де x і y – входи; A_i і B_i – нечіткі набори; f_i – виходи в межах нечіткої області, заданої нечітким правилом; p_i , q_i і r_i – параметри проектування, які визначаються

під час процесу навчання.

Архітектура ANFIS (рис. 3.5) для схематичної реалізації цих двох правил передбачає, що коло вказує на фіксований вузол, тоді як квадрат вказує на адаптивний вузол. На першому рівні всі вузли є адаптивними:

$$O_i^1 = \mu_{A_i}(x), \quad i=1,2 \quad (3.7)$$

$$O_i^1 = \mu_{B_{i-2}}(y), \quad i=3,4 \quad (3.8)$$

де $\mu_{A_i}(x)$, $\mu_{B_{i-2}}(y)$ - може приймати будь-яку нечітку функцію належності.

Рівень 2: вузли цього шару зафіксовані. Вони позначені M , щоб вказати, що відіграють роль простого множника. Виходи цих вузлів задані:

$$O_i^2 = w_i = \mu_{A_i}(x) \mu_{B_i}(y), \quad i=1,2 \quad (3.9)$$




Рисунок 3.5 – Архітектура нечіткої моделі ANFIS

Рівень 3: у третьому рівні вузли також є фіксованими вузлами. Вони позначені літерою N, що вказує на те, що вони відіграють нормалізаційну роль щодо сили попереднього рівня. Виходи цього шару можна представити як:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (3.10)$$

Рівень 4: на четвертому рівні вузли є адаптивними вузлами. Результат кожного вузла в цьому шарі є просто добутком нормалізованої сили стрільби та полінома першого порядку (для моделі Сугено першого порядку). Таким чином, виходи цього рівня задані як:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i=1,2 \quad (3.11)$$

Рівень 5: на п'ятому рівні є лише один фіксований вузол, позначений літерою S. Цей вузол виконує підсумовування всіх вхідних сигналів. Таким чином, загальний вихід моделі заданий як:

$$O_i^5 = \sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum_{i=1}^2 w_i f_i}{w_1 + w_2} \quad (3.12)$$

В цій архітектурі ANFIS є два адаптивні рівні, а саме перший рівень і четвертий рівень. На першому рівні є три модифіковані параметри $\{a_i, b_i, c_i\}$, які пов'язані з вхідними функціями належності. Ці параметри є так званими параметрами приміщення. На четвертому рівні також є три модифіковані параметри $\{r_i, q_i, g_i\}$, що відносяться до полінома першого порядку. Ці параметри є так званими послідовними параметрами.

Параметри a_i , b_i та c_i функції приналежності є фіксованими та описують сигму, нахил і центр функції приналежності. Таким чином, вихід моделі ANFIS можна записати як:

$$f = \overline{w}_1 p_1 x + \overline{w}_1 q_1 y + \overline{w}_1 r_1 + \overline{w}_2 p_2 x + \overline{w}_2 q_2 y + \overline{w}_2 r_2 \quad (3.13)$$

Для легкого визначення оптимальних значень цих параметрів можна використовувати метод найменших квадратів. Коли параметри передумови не фіксовані, простір пошуку стає більшим, а конвергенція навчання стає повільнішою. Для вирішення цієї проблеми використовується гібридний алгоритм, що поєднує метод найменших квадратів і метод градієнтного спуску. Гібридний алгоритм складається з проходу вперед і назад. Метод найменших квадратів (прямий перехід) використовується для оптимізації послідовних параметрів із фіксованими передумовами. Як тільки оптимальні послідовні параметри знайдені, зворотний прохід починається негайно. Метод градієнтного спуску (зворотний перехід) використовується для оптимального налаштування передумовних параметрів, що відповідають нечітким множинам у вхідній області. Вихід ANFIS обчислюється шляхом використання послідовних параметрів, знайдених у прямому проході. Вихідна помилка використовується для адаптації передумовних параметрів за допомогою стандартного алгоритму зворотного поширення.

Було доведено, що цей гібридний алгоритм є високоефективним у навчанні ANFIS. [35] З цієї причини в цьому дослідженні запропонована модель ANFIS була навчена за допомогою методу градієнтного спуску зворотного поширення в поєднанні з методом найменших квадратів, коли значення ентропії Шеннона для вейвлет коефіцієнтів тета, альфа і бета сигналів ЕЕГ використовувалися як вхідні

дані.

З метою зменшення розмірності векторів ознак розраховували значення ентропії Шеннона кожного піддіапазону ЕЕГ. Як видно з таблиці 3.2, значення ентропії Шеннона дельта-вейвлет-коефіцієнтів трьох типів ЕЕГ демонструють коливання, але значення ентропії Шеннона піддіапазонів тета, альфа та бета трьох типів сигналів ЕЕГ відрізняються одне від одного. З цієї причини надлишковий дельта-піддіапазон було відкинуто, а значення ентропії Шеннона для тета-, альфа- та бета-піддіапазонів було вибрано для класифікації стану пильності як стану тривоги, сонливості або сну.

Таблиця 3.2 – Значення ентропії

Тип ЕЕГ	Значення ентропії Шеннона для кожного піддіапазону			
	Дельта	Тета	Альфа	Бета
тривожний	80.202193	33.731814	23.989287	19.025308
тривожний	132.892591	20.385317	19.125974	17.396348
тривожний	133.992397	19.965381	16.679835	14.497496
тривожний	94.564127	21.785588	19.455582	16.002690
тривожний	95.737034	26.648795	18.599003	6.446857
сонливий	104.750823	6.998347	2.813458	2.199035
сонливий	30.298429	7.256460	2.033390	1.210499
сонливий	83.602294	8.190247	3.594895	2.322696
сонливий	54.980851	7.915981	2.707823	1.901773
сонливий	110.211417	10.481283	2.046696	1.797456
сон	45.945438	3.596002	0.561822	0.399303
сон	36.116427	2.743367	0.612531	0.372539
сон	39.758465	2.461374	0.590308	0.396251
сон	66.590357	3.829498	0.531423	0.379465
сон	82.567503	2.514802	0.384547	0.228683

Архітектура нечітких правил класифікаторів ANFIS була розроблена з використанням функції приналежності кривої Гауса, яка була визначена наступним рівнянням:

$$\mu(x) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (3.14)$$

де c, σ - параметри функції приналежності.

Кожен класифікатор ANFIS був реалізований за допомогою програмного пакету MATLAB (MATLAB версії 9.13 (рис. 3.7) з набором інструментів нечіткої логіки). Кожен ANFIS містить 8 правил, з 2 функціями належності, призначеними кожній вхідній змінній, а загальна кількість модифікованих параметрів кожного ANFIS становить 44, які складаються з 12 передумовних параметрів і 32 послідовних параметрів.

У цьому дослідженні були сформовані тренувальні та тестові вибірки 405 прикладів (по 135 прикладів з кожного типу ЕЕГ). Близько 225 прикладів (по 75 прикладів з кожного типу ЕЕГ) з них було використано для процедури навчання. Решта 180 прикладів (по 60 прикладів з кожного типу ЕЕГ) були використані для процедури тестування. У цьому випадку співвідношення між навчальним набором даних і модифікованими параметрами становить 225/44. Крім того, щоб покращити здатність до узагальнення запропонованої моделі, набір тренувальних даних було отримано від 18 із 30 здорових суб'єктів, а тестовий набір даних – від решти 12 здорових суб'єктів. Навчальний набір даних використовувався для навчання кожного класифікатора ANFIS, тоді як набір даних тестування використовувався для перевірки точності та ефективності кожної навченої моделі ANFIS (рис. 3.6) для класифікації трьох типів ЕЕГ як тривоги, сонливості та сну. На рис. 3.6 показано архітектуру нечітких правил кожного ANFIS з використанням функції приналежності у формі Гауса, визначеної в рівнянні.


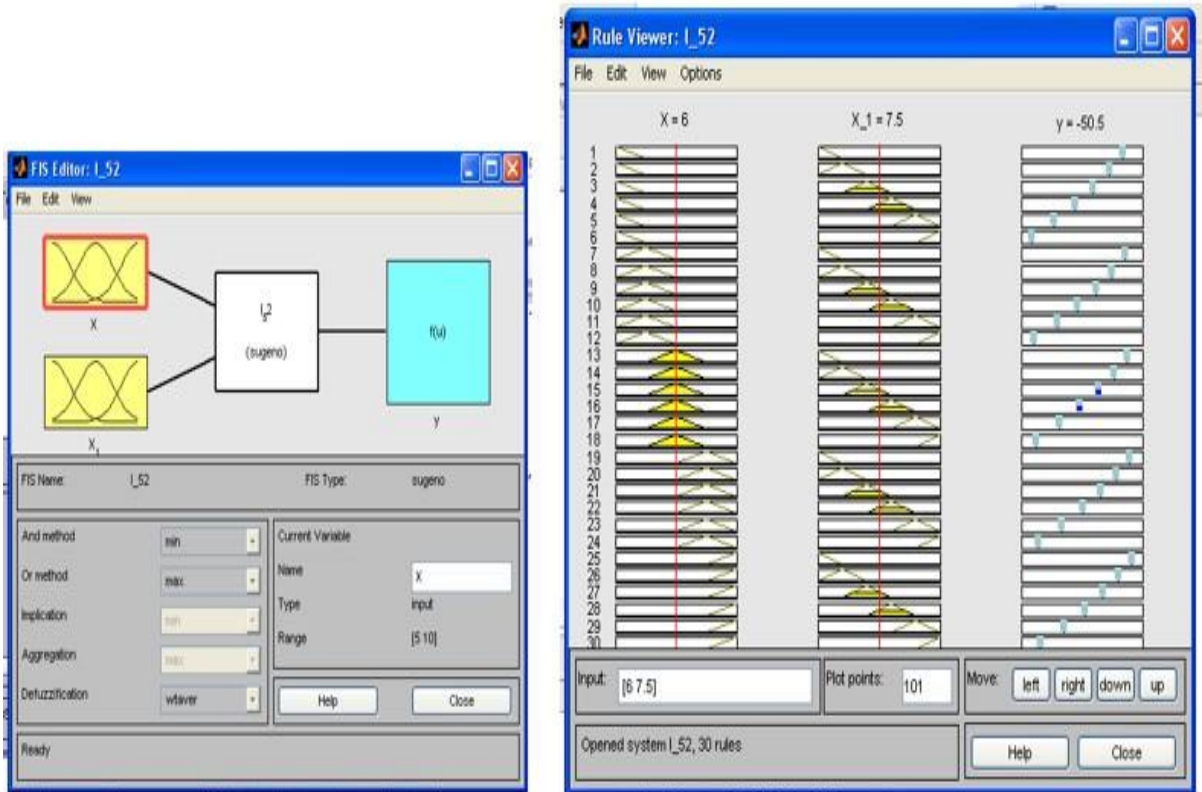
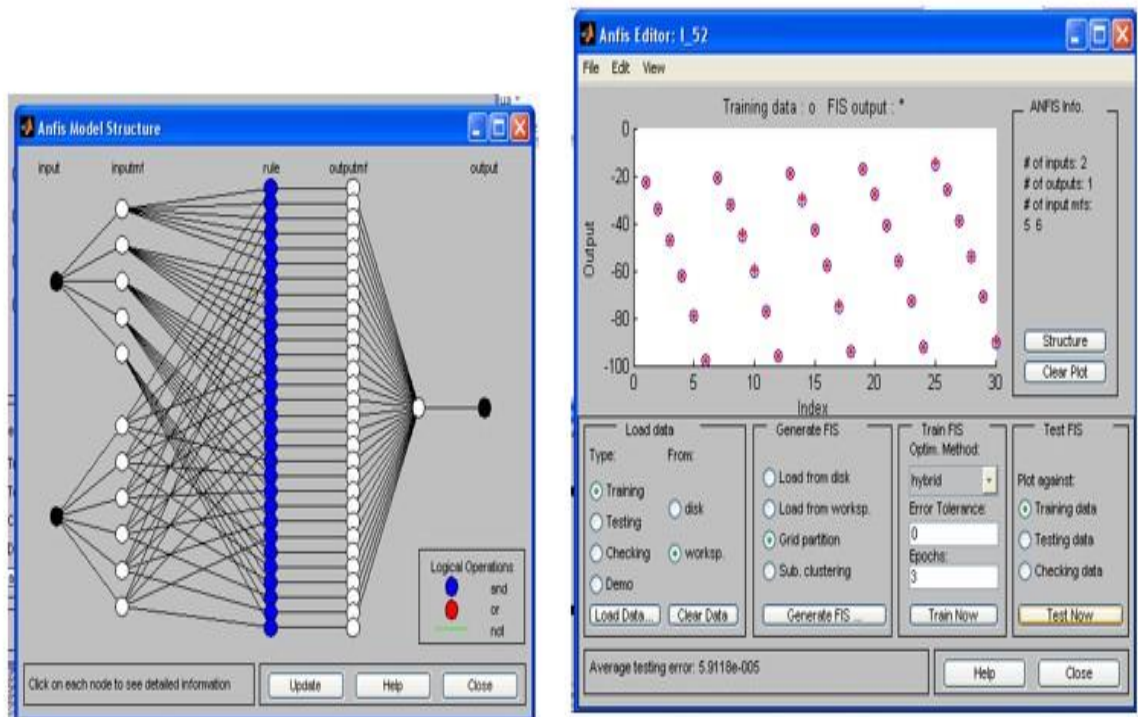


Рисунок 3.6 – Архітектура нечітких правил кожного класифікатора ANFIS

Функцію належності кожного вхідного параметра було розділено на дві області, а саме малу та велику. Дослідження початкової та кінцевої функцій (рис. 3.8) приналежності показує, що є значні зміни в кінцевих функціях приналежності (рис. 3.9) входу 2 (значення ентропії альфа-піддіапазону) та входу 3 (значення ентропії бета-піддіапазону), але кількість змін у кінцеві функції входу 1 (значення ентропії тета) менше. На рис. 3.8 та 3.9 показано початкову та кінцеву функції належності входу 2 та входу 3 відповідно. Цей аналіз було зроблено, оскільки кількість змін у кінцевих функціях належності вхідних даних вказує на вплив вхідних даних на виявлення вихідних даних. Грунтуючись на аналізі функцій приналежності, можна сказати, що значення ентропії альфа- та бета-піддіапазонів мають більш значний вплив, ніж значення ентропії тета-піддіапазону, на виявлення стану пильності на ЕЕГ як пильності, сонливості та сну. Після навчання було використано 180 даних тестування для підтвердження точності моделі ANFIS для оцінки станів пильності, сонливості та сну. У класифікації мета полягає в тому, щоб призначити шаблони вхідних даних одному з кількох класів, зазвичай представлених виходами, які обмежені діапазоном від 0 до 1, щоб вони представляли ймовірність приналежності до класу.



Меню «EDIT» → підменю «ANFIS»



«Load Data» → data; «Test Now»

Рисунок 3.7 – Нейронечітка система Anfis в середовищі МатЛаб

значення ентропії Альфа- піддіапазону

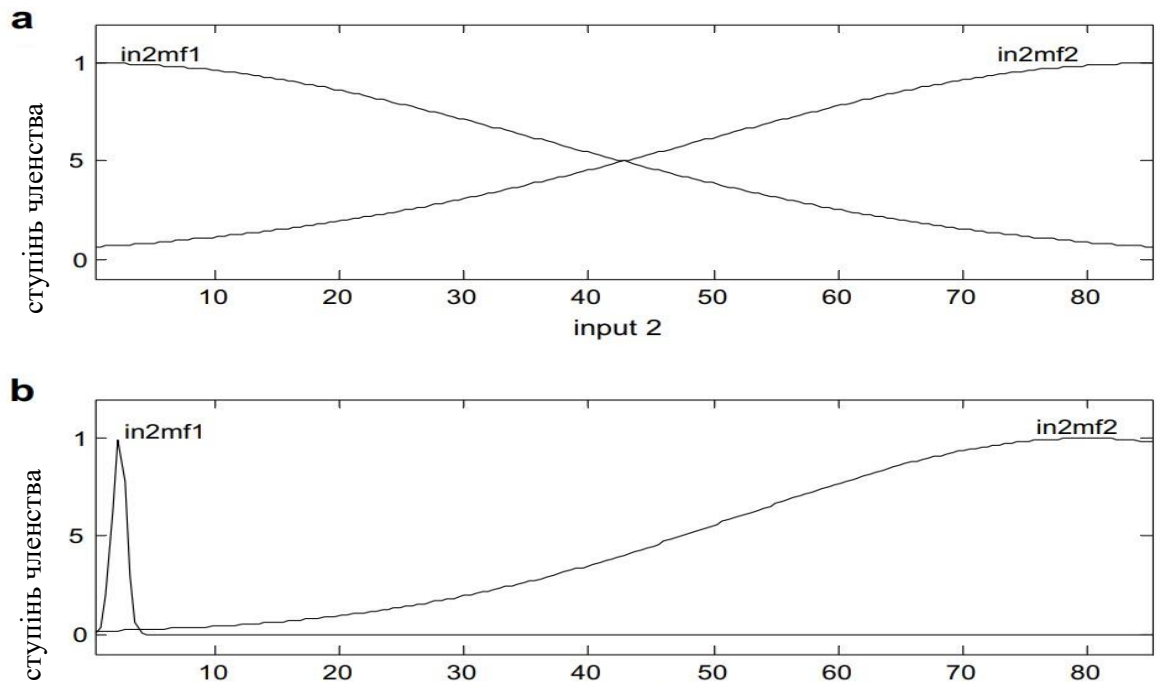


Рисунок 3.8 - (а) Початкова та (b) кінцева функція належності Гауса входу 2

значення ентропії Бета- піддіапазону




Рисунок 3.9 - (а) Початкова та (b) кінцева функція належності Гауса входу 2

Ефективність класифікації запропонованої моделі ANFIS була визначена шляхом обчислення наступних статистичних параметрів: чутливість (кількість справді позитивних рішень / кількість позитивних випадків, визначених двома експертами), специфічність (кількість істинно негативних рішень / сума кількості істинно негативних рішень з помилково позитивними рішеннями), точність: (сума значення чутливості зі значенням специфічності)/2).

Ефективність класифікації запропонованої моделі ANFIS за статистичними параметрами (чутливість, специфічність і точність) наведена в таблиці 3.3. Як видно з таблиці 3.3, запропонована модель оцінює стан пильності як бадьорість, сонливість і стан сну з точність 98,75%, 97,51% і 98,75% відповідно. Середня точність моделі склала 98,34%.

Таблиця 3.2 – Класифікація ефективності моделі за статистичними параметрами

Тип ЕЕГ	Статистичні параметри		
	Специфічність (%)	Чутливість (%)	Точність (%)
тривожний	99.15	98.33	98.75
сонливий	98.33	96.67	97.51
сон	99.15	98.33	98.75
середній	98.88	97.78	98.34

У літературі вибрали дослідження (Kiyumik et al., 2004). [20] А також (Subasi, 2005). [37] Ці два дослідження використовували таку ж кількість здорових суб'єктів, що й у нашому дослідженні, для визначення ефективності запропонованої ними моделі. Киймік та ін. (2004) описали метод автоматичного розпізнавання рівня пильності на основі записів повного спектру ЕЕГ за допомогою вейвлет-перетворення та нейронної мережі зворотного поширення. Вони представляли сигнали ЕЕГ з їх дельта, та, альфа і бета піддіапазами, отриманими за допомогою вейвлет-перетворення. Ці піддіапази використовувалися як вхідні дані для класифікатора нейронної мережі зворотного поширення з трьома дискретними виходами: тривога, сонливість і сон. Щоб

перевірити продуктивність системи, вони використовували записи ЕЕГ, отримані від 12 здорових суб'єктів. Середня точність їх моделі становила 95%. Субасі запропонував інший метод автоматичного розпізнавання рівня пильності за записами ЕЕГ. Відмінністю його методу від попереднього методу було представлення сигналів ЕЕГ з набором статистичних ознак, виділених із піддіапазонів. Продуктивність системи перевірялася за допомогою записів ЕЕГ, отриманих від 12 здорових суб'єктів. Середня точність його моделі була вище 93%. Таким чином, показники точності моделі ANFIS, представленої для цієї програми, виявилися вищими, ніж у моделей ШНМ, представлених Кійміком і Субасі.

Рівень пильності досліджувався А. Н. Леонт'євим (рис. 3.10), де був встановлений взаємозв'язок між пильністю і віком людини. [39]




Рисунок 3.10 - Паралелограмм розвитку пильності

За допомогою нечіткого метода встановлено, що вік клітин мозку залежить від двох ритмів – альфа та бета, що збігається з висновками метода машинного навчання і з дослідженнями функціональних нейромаркерів (рис. 3.11) для психіатрії. [40]

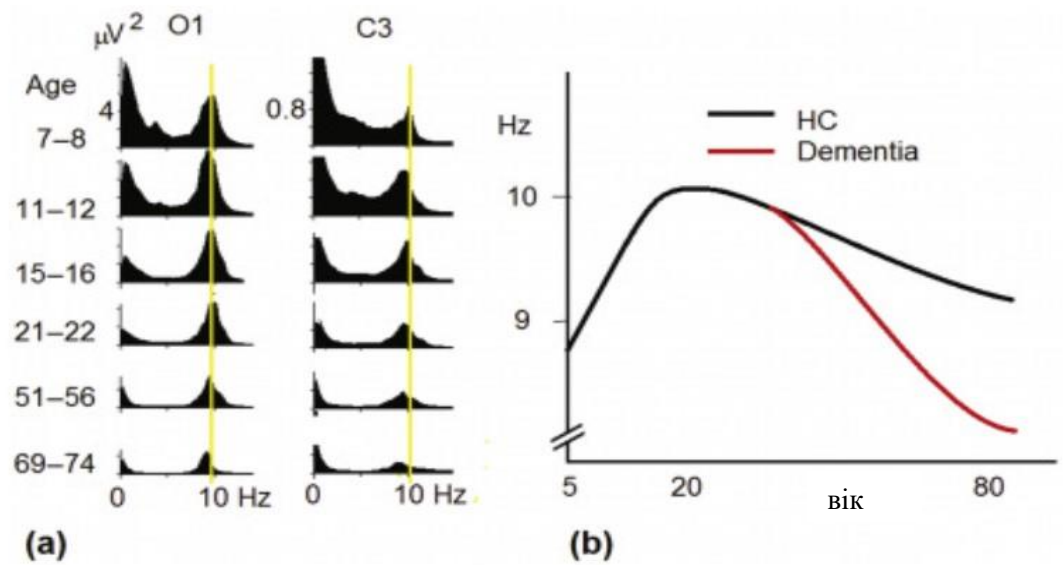


Рисунок 3.11 – Вікова динаміка альфа-ритмів

Нечітка модель підтверджує, що активність клітин мозку досягає свого максимуму (рис. 3.12) приблизно в 20 років, а потім повільно починає знижуватись. [41]

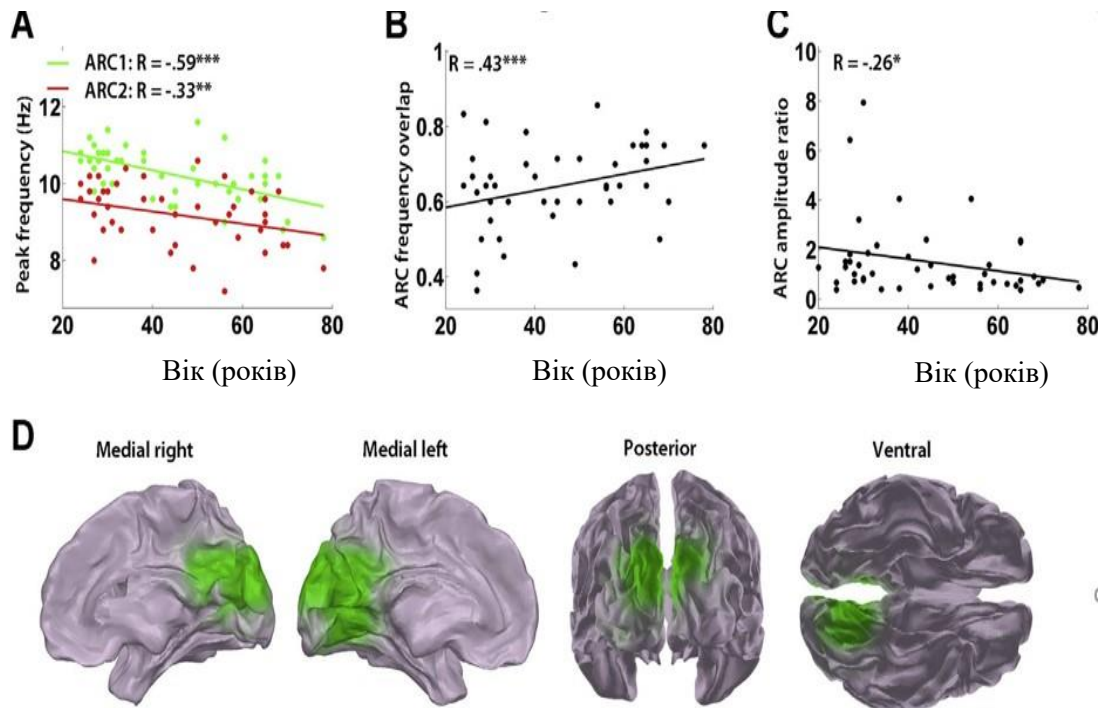


Рисунок 3.11 – Вікові тенденції частоти та просторових особливостей

3.4 Висновки по третьому розділу

У третьому розділі було проведено дослідження ЕЕГ-сигналів, включаючи їх попередню обробку. У результаті цієї обробки було виділено три класи даних: тривога, сонливість, сон. У цьому розділі було обрано метод нечіткої логіки Сугено з нейронною мережею, метод вейвлет перетворення. Також для дослідження системи нечіткого логічного висновку було обрано адаптивну мережу ANFIS. Запропонована модель оцінює стан пильності як бадьорість, сонливість і стан сну з точністю 98,75%, 97,51% і 98,75% відповідно. Середня точність моделі склала 98,34%. Використовуючи паралелограм розвитку пильності було встановлено зв'язок ЕЕГ-сигналів та віку клітин головного мозку людини.

ВИСНОВКИ

В цій роботі було проаналізовано сучасний стан застосування та вивчення ЕЕГ сигналів у наукових дослідженнях, були використані нейро-нечіткі системи, методи дослідження сну на основі машинного навчання. Виділено основний напрямок розвитку досліджень: використання нечіткої логіки з нейронною мережею, передбачення рівня пильності і віку клітин мозку, вдосконалення існуючих методів аналізу ЕЕГ та дослідження сну.

Для вирішення задач зв'язку в даному дослідженні були обрані наступні засоби: метод нечіткої логіки Сугено з нейронною мережею, метод вейвлет перетворення.

З бази, що складається з 30 суб'єктів, група складалася з 14 жінок і 16 чоловіків у віці від 18 до 65 років, середній вік 33,5 років і індекс маси тіла (ІМТ) $32,4 \pm 7,3$ кг/м², в результаті попередньої обробки були виділені три класи даних: тривога, сонливість, сон.

Сигнали записували протягом 7 годин епізодів, а цифрові сигнали приймали кожні 20 хвилин для кожного блоку. Потім ці записи ЕЕГ були розділені на 5 сек. епохи і ці епохи були розділені на піддіапазони частот, такі як α , β , θ і δ . Потім спектральна щільність потужності (PSD) вейвлет піддіапазону частот δ (1–4 Гц), θ (4–8 Гц), α (8–13 Гц) і β (13–30 Гц) застосовуються до PSD. Стан тривоги має змішані частоти: α і β . У сонному стані α зникне. Під час сну α і β втрачаються, δ і θ спостерігаються.

Кожен класифікатор ANFIS був реалізований за допомогою програмного пакету MATLAB (MATLAB версії 9.13 з набором інструментів нечіткої логіки). Кожен ANFIS містив 8 правил, з 2 функціями належності, призначеними кожній вхідній змінній, а загальна кількість модифікованих параметрів кожного ANFIS становила 44, які складаються з 12 передумовних параметрів і 32 послідовних параметрів.

У цьому дослідженні були сформовані тренувальні та тестові вибірки 405

прикладів (по 135 прикладів з кожного типу ЕЕГ). Близько 225 прикладів (по 75 прикладів з кожного типу ЕЕГ) з них було використано для процедури навчання. Решта 180 прикладів (по 60 прикладів з кожного типу ЕЕГ) були використані для процедури тестування. У цьому випадку співвідношення між навчальним набором даних і модифікованими параметрами становило 225/44.

Були отримані такі результати класифікації:

- ефективність класифікації запропонованої моделі ANFIS за статистичними параметрами (чутливість, специфічність і точність) склала 98,34%;
- ця модель використовувала менше вхідних даних, ніж попередні методи.

Фінальний результат був отриманий за допомогою паралелограма розвитку пильності, де був встановлений взаємозв'язок між пильністю і віком клітин мозку. Було встановлено, що вік клітин мозку досягає свого максимуму приблизно в 20 років, а потім повільно починає знижуватись.

ПЕРЕЛІК ПОСИЛАНЬ

- 1 Nikolayeva E.B., Khomutnikova Y.A. Metodika registratsii elektroentsefalogrammy u loshadey [EEG recording in horses] // Bolezni loshadey: diagnostika, profilaktika, lecheniye: Materialy chetvertoy nauchno-pr. konf. po boleznyam loshadey / M., 2003. pp. 80–82.
- 2 Motor Imagery EEG Signal Processing and Classification Using Machine Learning Approach / [Sreeja. S. R, J. Rabha, K. Y. Nagarjuna and other]. // 2017 International Conference on New Trends in Computing Sciences (ICTCS). – 11-13 Oct. 2017, Amman, Jordan/IEEE
- 3 Qureshi S. Evaluate different machine learning techniques for classifying sleep stages on single-channel EEG / S. Qureshi, S. Vanichayobon. // 2017 14th International Joint Conference on Computer Science and Software Engineering (JCSSE), 12-14 July 2017, Nakhon Si Thammarat, Thailand/ IEEE. – Page(s): 1 - 6.
- 4 Zhang Z. An accurate sleep staging system with novel feature generation and auto-mapping / Z. Zhang, C. Guan// 2017 International Conference on Orange Technologies (ICOT), 8-10 Dec. 2017, Singapore, Singapore/ IEEE. – Page(s): 214 - 217.
- 5 Sun H, Paixao L, Oliva JT, Goparaju B, Carvalho DZ, van Leeuwen KG, Akeju O, Thomas RJ, Cash SS, Bianchi MT, Westover MB. Brain age from the electroencephalogram of sleep. *Neurobiol Aging*. 2019 Feb;74:112-120.
- 6 Al Zoubi O, Ki Wong C, Kuplicki RT, Yeh H, Mayeli A, Refai H, Paulus M, Bodurka J (2018) Predicting Age From Brain EEG Signals—A Machine Learning Approach. *Front. Aging Neurosci*. 10:184.
- 7 Ермаков П. Д. Исследование методов машинного обучения в задаче автоматического определения тональности текстов на естественном языке / П. Д. Ермаков, Р. В. Федянин. // Новые информационные технологии в автоматизированных системах. – 2015. – №18. – С. 600 – 616.
- 8 Воронцов К. В. Лекции по методу опорных векторов / К. В. Воронцов. – 2007.
- 9 Guazzelli A. Predictive modeling techniques / AlexGuazzelli. – 2012 [Електронний

- ресурс] – Режим доступа: <https://www.coursehero.com/file/35838407/Predictive-Modeling-Techniquespdf/> – Дата доступа: 12.12.2023.
- 10 Al Zoubi O, Ki Wong C, Kuplicki RT, Yeh H, Mayeli A, Refai H, Paulus M and Bodurka J (2018) Predicting Age From Brain EEG Signals—A Machine Learning Approach. *Front. Aging Neurosci.* 10:184.
 - 11 Cohen A, Kovacevic J. Wavelets: the mathematical background. *Proc IEEE* 1996;84:514–22
 - 12 Varma, S., and Simon, R. (2006). Bias in error estimation when using cross-validation for model selection. *BMC Bioinformatics* 7:91. doi: 10.1186/1471-2105-7-91
 - 13 Friedman, J., Hastie, T., and Tibshirani, R. (2001). *The Elements of Statistical Learning*. New York, NY: Springer Series in Statistics.
 - 14 Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., et al. (2013). MEG and EEG data analysis with MNE-Python. *Front. Neurosci.* 7:267. doi: 10.3389/fnins.2013.00267
 - 15 Benninger, C., Matthis, P., and Scheffner, D. (1984). EEG development of healthy boys and girls. Results of a longitudinal study. *Electroencephalogr. Clin. Neurophysiol.* 57, 1–12. doi: 10.1016/0013-4694(84)90002-6
 - 16 Gasser, T., Verleger, R., Bächer, P., and Sroka, L. (1988). Development of the EEG of school-age children and adolescents. I. Analysis of band power. *Electroencephalogr. Clin. Neurophysiol.* 69, 91–99. doi: 10.1016/0013-4694(88)90204-0
 - 17 Marciani, M. G., Maschio, M., Spanedda, F., Caltagirone, C., Gigli, G., and Bernardi, G. (1994). Quantitative EEG evaluation in normal elderly subjects during mental processes: age-related changes. *Int. J. Neurosci.* 76, 131–140. doi: 10.3109/00207459408985998
 - 18 Widagdo, M., Pierson, J., and Helme, R. (1998). Age-related changes in qEEG during cognitive tasks. *Int. J. Neurosci.* 95, 63–75. doi: 10.3109/00207459809000650
 - 19 Kikuchi, M., Wada, Y., Koshino, Y., Nanbu, Y., and Hashimoto, T. (2000). Effect of normal aging upon interhemispheric EEG coherence: analysis during rest and photic
20 stimulation. *Clin. Electroencephalogr.* 31, 170–174. doi:

10.1177/155005940003100404

- 21 Kiymik MK, Akin M, Subasi A. Automatic recognition of alertness level by using wavelet transform and artificial neural network. *J Neurosci Methods*. 2004 Oct 30;139(2):231-40
- 22 База данных sleep-edf [Электронный ресурс] – Режим доступа: [URL:https://drive.google.com/drive/folders/1YkYsWuUnX5U4Z6JVvbnvdlZuLreKM84B?usp=sharing](https://drive.google.com/drive/folders/1YkYsWuUnX5U4Z6JVvbnvdlZuLreKM84B?usp=sharing). – Дата доступа: 17.09.2023.
- 23 Daubechies I. Ten lectures on wavelets. CBMS-NSF regional series in applied mathematics. Philadelphia, PA: SIAM; 1992.
- 24 Cohen A, Kovacevic J. Wavelets: the mathematical background. *Proc IEEE* 1996;84:514–22.
- 25 Daubechies I. Ten lectures on wavelets. CBMS-NSF regional series in applied mathematics. Philadelphia, PA: SIAM; 1992.
- 26 Rioul O, Vetterli M. Wavelet and signal processing. *IEEE Signal Processing Magazine* (October); 1991. p. 14–46.
- 27 Khahill M, Duchene J. Detection and classification of multiple events in piecewise stationary signals. *J Signal Process* 1999;98:236–9.
- 28 Adeli H, Zhou Z, Dadmehr N. Analysis of EEG records in an epileptic patient using wavelet transform. *J Neurosci Methods* 2003;123:69–87
- 29 Basheer IA, Hajmeer M. Artificial neural networks: fundamentals, computing, design, and application. *J Microbiol Methods* 2000;43:3–31
- 30 Fausett L. Fundamentals of neural networks architectures, algorithms, and applications. Englewood Cliffs, NJ: Prentice Hal
- 31 Haykin S. Neural networks: a comprehensive foundation. New York: Macmillan; 1994
- 32 Sun M, Sclabassi RJ. The forward EEG solutions can be computed using Artificial neural networks. *IEEE Trans Biomed Eng* 2000;47:1044–50.
- 33 Jung TP, Makeig S, Stensmo M, Sejnowski TJ. Estimating alertness from the EEG power spectrum. *IEEE Trans Biomed Eng* 1997;44:60–9.
- 34 Doghramji K, Merrill MM, Sangal SB. A normative study of the maintenance of

- wakefulness test (MWT). *Electroenceph Clin Neurophysiol* 1997;103:554–62.
- 35 McKeown MJ, Humphries C, Achermann P, Borbely AA, Sejnowski TJ. A new method for detecting state changes in EEG: exploratory application to sleep data. *J Sleep Res* 1997;7:48–56
- 36 Jang, J.-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685.
- 37 Subasi, A. (2005). Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients. *Expert Systems with Applications*, 28, 701–711
- 38 Juri D. Kropotov, in *Functional Neuromarkers for Psychiatry*, 2016;89-105
- 39 Knyazeva MG, Barzegaran E, Vildavski VY, Demonet JF. Aging of human alpha rhythm. *Neurobiol Aging*. 2018 Sep;69:261-273
- 40 Леонтьев А. Н. Развитие памяти. Экспериментальное исследование высших психологических функций: Учпедгиз, 1931. — 280 с
- 41 Juri D. Kropotov, in *Functional Neuromarkers for Psychiatry*, 2016: 89-105
- 42 Maria G. Knyazeva a,b, *, Elham Barzegaran a,b , Vladimir Y. Vildavski c , Jean-François Demonet. Aging of human alpha rhythm, 2018: 261-273
- 43 Ramkumar, P., Parkkonen, L., Hari, R., Hyvärinen, A., 2012. Characterization of neuromagnetic brain rhythms over time scales of minutes using spatial independent component analysis. *Hum. Brain Mapp.* 33, 1648e1662.
- 44 Reiman, E.M., 2007. Linking brain imaging and genomics in the study of Alzheimer's disease and aging. *Ann. N Y Acad. Sci.* 1097, 94e113.
- 45 Rickham, P.P., 1964. Human experimentation: code of ethics of the World Medical Association. Declaration of Helsinki. *Br. Med. J.* 2, 177e177.
- 46 Robinson, P., Whitehouse, R., Rennie, C., 2003. Nonuniform corticothalamic continuum model of electroencephalographic spectra with application to split-alpha peaks. *Phys. Rev. E Stat. Nonlin. Soft Matter Phys.* 68, 021922.
- 47 Rogalski, E.J., Gefen, T., Shi, J., Samimi, M., Bigio, E., Weintraub, S., Geula, C., Mesulam, M.M., 2013. Youthful memory capacity in old brains: anatomic and genetic clues from the Northwestern SuperAging Project. *J. Cogn. Neurosci.* 25, 29e36.
- 48 Shigeta, M., Julin, P., Almkvist, O., Basun, H., Rudberg, U., Wahlund, L.-O.,

49 1995. EEG in successful aging; a 5 year follow-up study from the eighth to ninth decade of life. *Electroencephalogr. Clin. Neurophysiol.* 95, 77e83.

ДОДАТОК А
Matlab Fuzzy Logic Toolbox

ДОДАТОК Б
Фрагмент лістингу