

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО»
ФАКУЛЬТЕТ БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ

(повна назва інституту/факультету)

кафедра БІОМЕДИЧНОЇ КІБЕРНЕТИКИ

(повна назва кафедри)

«До захисту допущено»

В.о. завідувачки кафедри БМК

Світлана АЛХІМОВА

(підпис)

(ініціали, ПРІЗВИЩЕ)

“ ” червня 2025р.

Дипломна робота
на здобуття ступеня бакалавра
за освітньо-професійною програмою
«Комп'ютерні технології в біології та медицині»
зі спеціальності 122 «Комп'ютерні науки»

на тему: Інформаційна система діагностики посттравматичного
стресового розладу на основі аналізу BOLD-сигналів засобами
згорткових мереж

Виконала: студентка IV курсу, групи БС-15

ЙОВСА ДАР'Я ОЛЕКСАНДРІВНА

(прізвище, ім'я, по батькові)

(підпис)

Науковий керівник: *асистент каф. біомедичної кібернетики
(БМК) Алієв Ельдар Ігорович*

(посада, науковий ступінь, вчене звання, прізвище, ім'я, по ініціали)

(підпис)

Консультант з розділів дипломної роботи:

доцент каф. БМК, к.т.н. Павлов Володимир Анатолійович

(назва розділу) (посада, вчене звання, науковий ступінь, прізвище, ініціали)

(підпис)

Рецензент: *доцент каф. біомедичної інженерії, к.т.н., с.н.с.*

Дубко Андрій Григорович

(посада, науковий ступінь, вчене звання, науковий ступінь, прізвище та ініціали)

(підпис)

Засвідчую, що у цій дипломній роботі
немає запозичень з праць інших авторів
без відповідних посилань.

Студентка

(підпис)

(підпис)

Київ – 2025 року

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Інститут (факультет) БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ
(повна назва)

Кафедра БІОМЕДИЧНОЇ КІБЕРНЕТИКИ
(повна назва)

Рівень вищої освіти – перший (бакалаврський)

Спеціальність 122 «Комп'ютерні науки»

Освітньо-професійна програма «Комп'ютерні технології в біології та медицині»
(код і назва)

ЗАТВЕРДЖУЮ

В.о. завідувачки кафедри БМК

Світлана АЛХІМОВА

« » травень 2025 р.

ЗАВДАННЯ
на дипломну роботу студентці

ЙОВСА ДАР'І ОЛЕКСАНДРІВНІ

(прізвище, ім'я, по батькові)

1. Тема роботи Інформаційна система діагностики
посттравматичного стресового розладу на основі аналізу BOLD-сигналів
засобами згорткових мереж

керівник роботи

Алієв Ельдар Ігорович, асистент кафедри БМК

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від «26» травня 2025 р. № 1758-с

2. Термін подання студентом роботи 22-23 травня 2025 року

3. Вихідні дані *Реальні данні – сигнали BOLD-активності, отримані внаслідок фМРТ, надані ДУ «Всеукраїнський центр материнства та дитинства НАМН України».*

4. Зміст роботи *Вступ, Огляд існуючих рішень та діагностики ПТСР, Огляд та обґрунтування вибору засобів реалізації системи, Програмна реалізація та методика роботи нейронної мережі, Узагальнення результатів роботи, Загальні висновки*

5. Перелік ілюстративного матеріалу (із зазначенням плакатів, презентацій тощо) *Презентація з захисту дипломної роботи на 15 слайдах*

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Дипломної роботи	Павлов Володимир Анатолійович, доцент кафедри БМК	14 травня	18 травня

7. Дата видачі завдання 14 травня 2025р.

Календарний план

№ з/п	Назва етапів виконання дипломної роботи	Термін виконання етапів роботи	Примітка
1	Отримати завдання за темою ДР на практику	До 24.12.2024р.	<i>виконано</i>
2	Переддипломна практика. Виконання практичної частини ДР та додаткових розділів	1-4 тиждень за графіком практики	<i>виконано</i>
3	Виконання основних розділів ДР (Вступ, Огляд існуючих рішень та діагностики ПТСР, Огляд та обґрунтування вибору засобів реалізації системи, Програмна реалізація та методика роботи нейронної мережі, Узагальнення результатів роботи, Загальні висновки)	Протягом усієї практики	<i>виконано</i>
4	Перевірка ДР науковим керівником	до 20.05.2025	<i>виконано</i>
5	Подання в електронному вигляді ДР на перевірку нормоконтролера та плагіат (StrikePlagiarism.com). Доопрацювання ДР	Не пізніше 23.05.2025	<i>виконано</i>
6	Отримати відгук від керівника ДР	Не пізніше 05.06.2025	<i>виконано</i>
7	Надати пакету документів по ДР та супровідних до неї документів на засідання кафедри		<i>виконано</i>
8	Подання ДР рецензенту. Отримання рецензії.	09.06 – 13.06.2025	<i>виконано</i>
9	Захист ДР в ЕК	16.06 – 21.06.2025	

Студент


(підпис)

Дар'я ЙОВСА

(ім'я, ПРІЗВИЩЕ)

Керівник ДР


(підпис)

Ельдар АЛІЄВ

(ім'я, ПРІЗВИЩЕ)

Нормоконтролер

(підпис)

Галина КОРНІЄНКО

(ім'я, ПРІЗВИЩЕ)

АНОТАЦІЯ

Дипломна робота за темою «Інформаційна система діагностики посттравматичного стресового розладу на основі аналізу BOLD-сигналів засобами згорткових мереж» виконана студентом кафедри біомедичної кібернетики ФБМІ Йовса Дар'єю Олександрівною зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині» та складається зі: вступу; 4 розділів (Огляд існуючих рішень та діагностики ПТСР, Огляд та обґрунтування вибору засобів реалізації системи, Програмна реалізація та методика роботи нейронної мережі, Узагальнення результатів роботи), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 25 джерел. Загальний обсяг роботи 57 сторінок.

Актуальність теми. Актуальність теми дипломної роботи пов'язана із задачею своєчасної, точної та об'єктивної діагностики посттравматичного стресового розладу (ПТСР).

Мета і завдання роботи.

Метою роботи є підвищення ефективності виявлення ПТСР, на основі аналізу фМРТ даних із використанням згорткових нейронних мереж.

Сформульовано наступні **задачі**:

1. Розглянути методи діагностики ПТСР, фМРТ та BOLD-сигналів.
2. Реалізувати базову модель CNN та провести її тренування.
3. Оптимізувати архітектуру моделі шляхом зміни структури згорток та параметрів.
4. Застосувати методи розвідкового аналізу для вибору найбільш інформативних ознак після Flatten-шару.
5. Провести оцінку якості моделі.

Використані методи. У роботі застосовано методи глибокого навчання, зокрема згорткові нейронні мережі (CNN), для обробки та аналізу BOLD-сигналів, отриманих під час функціональної магнітно-резонансної томографії

(фМРТ). Також реалізовано підхід розвідкового аналізу для відбору інформативних ознак. Для оцінки якості моделі застосовувалися стандартні метрики класифікації — точність, чутливість, специфічність, F1-міра.

Отримані результати. У результаті роботи побудовано модель, здатну класифікувати стан пацієнтів на основі BOLD-сигналів. Модель демонструє потенціал для подальшого застосування у клінічній практиці як допоміжний інструмент для виявлення посттравматичного стресового розладу. Робота виконана згідно договору про співпрацю ДУ «Інститут педіатрії акушерства і гінекології імені академіка О. М. Лук'янової НАМН України» з НТТУ «Київський політехнічний інститут ім. Ігоря Сікорського» № Д/0002.01/3400.02/291/2023 від 27.10.2023 року на даних, наданих ДУ "Всеукраїнський центр материнства та дитинства НАМН України», результати роботи впроваджено у медичну практику.

Апробація результатів роботи. Не заплановано.

Публікації. Не заплановано.

Бібліографічний опис ДР

Йовса Д.О. Інформаційна система діагностики посттравматичного стресового розладу засобами згорткових мереж : дипломна роб. бакалавра : 122 Комп'ютері науки / Йовса Дар'я Олександрівна. – Київ, 2025. – 70 с

ANNOTATION

The bachelor's thesis titled “Information system for diagnosing post-traumatic stress disorder based on the analysis of BOLD signals using convolutional networks” was completed by Daria Yovsa, a student of the Department of Biomedical Cybernetics, Faculty of Biomedical Engineering, specializing in 122 "Computer Science", within the educational and professional program "Computer Technologies in Biology and Medicine". The work consists of an introduction; 4 chapters (Overview of Existing PTSD Diagnostic Solutions, Review and Justification of Tools for System Implementation, Software Implementation and Methodology of Neural Network Operation, Generalization of Results); conclusions for each chapter; general conclusions; a list of references (25 sources). The total length of the thesis is 57 pages.

Relevance of the topic. The relevance of the thesis is linked to the task of timely, accurate, and objective diagnosis of post-traumatic stress disorder (PTSD).

Objective and tasks of the work. The main objective of the thesis is to improve the efficiency of PTSD detection based on fMRI data analysis using convolutional neural networks. The following tasks were defined:

1. To review existing PTSD diagnostic methods, fMRI, and BOLD signals.
2. To implement a baseline CNN model and train it.
3. To optimize the model architecture by adjusting the convolution structure and parameters.
4. To apply exploratory data analysis methods for selecting the most informative features after the Flatten layer.
5. To evaluate the performance of the model.

Methods used. The study employed deep learning methods, particularly convolutional neural networks (CNNs), for processing and analyzing BOLD signals obtained from functional magnetic resonance imaging (fMRI). Exploratory data analysis was applied to select the most informative features. Standard classification

metrics — accuracy, sensitivity, specificity, and F1-score — were used for model evaluation.

Results obtained. As a result of the work, a model was developed that is capable of classifying patients' conditions based on BOLD signals. The model shows potential for further application in clinical practice as a supportive tool for detecting post-traumatic stress disorder. The work was carried out under the cooperation agreement between the State Institution "Institute of Pediatrics, Obstetrics and Gynecology named after Academician O. M. Lukyanova of the National Academy of Medical Sciences of Ukraine" and the National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute" (Agreement No. D/0002.01/3400.02/291/2023 dated October 27, 2023), based on data provided by the State Institution "Institute of Pediatrics, Obstetrics and Gynecology of NAMS of Ukraine". The results of the work have been implemented into medical practice.

Presentation of results. Not planned.

Publications. Not planned.

ЗМІСТ

ВСТУП.....	11
РОЗДІЛ 1 ОГЛЯД ІСНУЮЧИХ РІШЕНЬ ТА МЕТОДІВ ДІАГНОСТИКИ ПТСР	13
1.1 Загальні відомості про ПТСР.....	13
1.2 Традиційні методи діагностики ПТСР	14
1.3 Методи нейровізуалізації у виявленні ПТСР.....	15
1.3.1 Структурні методи нейровізуалізації	15
1.3.2 Функціональні методи нейровізуалізації	17
1.4 Методи машинного навчання для діагностики ПТСР.....	18
1.5 Аналіз BOLD-сигналів: принципи та застосування	19
Висновок до розділу 1.....	20
РОЗДІЛ 2 ОГЛЯД ТА ОБГРУНТУВАННЯ ВИБОРУ ЗАСОБІВ РЕАЛІЗАЦІЇ СИСТЕМИ.....	22
2.1 Основи машинного навчання та глибоких нейронних мереж	22
2.2 Архітектура згорткових нейронних мереж.....	25
2.2.1 Основні елементи архітектури.....	25
2.2.2 Переваги та особливості застосування CNN у медицині	28
2.3 Розвідковий аналіз для вибору інформативних ознак.....	29
2.3.1 Селекція ознак	29
2.3.2 Класифікація на основі бінарних логістичних регресій.....	30
2.4 Технологічний стек реалізації системи	32
2.4.1 Мова програмування Python	32
2.4.2 TensorFlow/Keras	34
2.4.3 Scikit-learn	34
2.4.4 Matplotlib/Seaborn	36
2.4.5 Numpy.....	37

Висновок з розділу 2	38
РОЗДІЛ 3 ПРОГРАМНА РЕАЛІЗАЦІЯ ТА МЕТОДИКА РОБОТИ	
НЕЙРОННОЇ МЕРЕЖІ	40
3.1 Опис вхідних даних.....	40
3.2 Підготовка даних.....	42
3.3 Базова згорткова нейронна мережа	43
3.3.1 Архітектура та реалізація базової моделі.....	43
3.3.2 Результати навчання та оцінка ефективності базової мережі	46
3.4 Оптимізація архітектури	47
3.4.1 Застосування прямокутних фільтрів і підбору параметрів	47
3.4.2 Аналіз ефективності оновленої моделі	49
3.5 Розвідковий аналіз.....	51
3.5.1 Реалізація методу розвідкового аналізу	51
3.5.1.1 Первинна селекція ознак.....	51
3.5.1.2 Класифікація на основі бінарних логістичних регресій.....	52
3.5.1.3 Інтеграція відібраних ознак у нейронну мережу	52
3.5.1.4 Завершення архітектури моделі.....	52
3.5.1.5 Остаточна архітектура моделі.....	53
3.5.2 Результати моделі з урахуванням відібраних ознак	54
3.6 Розрахунок економічного ефекту.....	56
Висновок до розділу 3.....	58
РОЗДІЛ 4 УЗАГАЛЬНЕННЯ РЕЗУЛЬТАТІВ РОБОТИ	
60	
4.1 Опис архітектури та особливості побудованої моделі.....	60
4.2 Аналіз отриманих метрик класифікації	61
4.3 Порівняння обраної нейронної мережі з аналогами.....	63
ЗАГАЛЬНІ ВИСНОВКИ.....	66
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	68

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

fMRI – функціональна магнітно-резонансна томографія; метод нейровізуалізації, що вимірює мозкову активність шляхом виявлення змін кровотоку.

BOLD – blood-oxygen-level-dependent; тип fMRI-сигналу, що залежить від рівня оксигенації крові.

CNN – Convolutional Neural Network, згорткова нейронна мережа; архітектура глибокого навчання для аналізу зображень або матриць.

ПТСР – посттравматичний стресовий розлад; психічний стан, що виникає після травматичних подій.

ROI – Region of Interest; область інтересу, виділена для аналізу у структурі мозку.

SCID, MINI, CAPS-5, PCL-5, IES-R – стандартизовані психометричні інструменти для діагностики ПТСР.

ВСТУП

Посттравматичний стресовий розлад (ПТСР) є серйозною проблемою охорони психічного здоров'я, особливо в умовах зростання кількості людей, які пережили травматичні події. Традиційні методи діагностики базуються переважно на опитуваннях і суб'єктивних оцінках, що не завжди забезпечує достатню точність.

Аналіз BOLD-сигналів із функціональної МРТ дозволяє отримати об'єктивні дані про мозкову активність, проте їх інтерпретація потребує автоматизованих інструментів. У цьому контексті перспективним є використання згорткових нейронних мереж, які ефективно працюють із просторово-часовими даними.

Мета і завдання роботи

Метою роботи є підвищення ефективності виявлення ПТСР, на основі аналізу фМРТ даних із використанням згорткових нейронних мереж.

Сформульовано наступні **задачі**:

1. Розглянути методи діагностики ПТСР, фМРТ та BOLD-сигналів.
2. Реалізувати базову модель CNN та провести її тренування.
3. Оптимізувати архітектуру моделі шляхом зміни структури згорток та параметрів.
4. Застосувати методи розвідкового аналізу для вибору найбільш інформативних ознак після Flatten-шару.
5. Провести оцінку якості моделі.

Використані методи. У роботі застосовано методи глибокого навчання, зокрема згорткові нейронні мережі (CNN), для обробки та аналізу BOLD-сигналів, отриманих під час функціональної магнітно-резонансної томографії (фМРТ). Також реалізовано підхід розвідкового аналізу для відбору інформативних ознак. Для оцінки якості моделі застосовувалися стандартні метрики класифікації — точність, чутливість, специфічність, F1-міра.

Отримані результати. У результаті роботи побудовано модель, здатну класифікувати стан пацієнтів на основі BOLD-сигналів. Модель демонструє потенціал для подальшого застосування у клінічній практиці як допоміжний інструмент для виявлення посттравматичного стресового розладу. Проведено також розрахунок економічної ефективності системи, що підтвердив доцільність її впровадження з практичної точки зору.

Апробація результатів роботи. Не заплановано.

Публікації. Не заплановано

Структура роботи

Дипломна робота за темою «Інформаційна система діагностики посттравматичного стресового розладу на основі аналізу BOLD-сигналів засобами згорткових мереж» виконана студентом Йовса Дар'єю Олександрівною зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині», побудована за класичним типом та викладена на 57 сторінках машинописного тексту. Вона складається з: вступу; 4 розділів (Огляд існуючих рішень та діагностики ПТСР, Огляд та обґрунтування вибору засобів реалізації системи, Програмна реалізація та методика роботи нейронної мережі, Узагальнення результатів роботи), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 25 джерел (25 – на латиниці). В роботі представлено 14 рисунків і 2 таблиці.

РОЗДІЛ 1

ОГЛЯД ІСНУЮЧИХ РІШЕНЬ ТА МЕТОДІВ

ДІАГНОСТИКИ ПТСР

Даний розділ присвячений загальному огляду існуючих підходів до діагностики посттравматичного стресового розладу. У підрозділі 1.1 розглянуто, що таке ПТСР, як він проявляється в симптомах і яку шкоду може завдати фізичному та психічному здоров'ю людини. У 1.2 описано традиційні клінічні інтерв'ю (CAPS-5, ITI) і швидкі опитувальники (PCL-5, IES-R), що дозволяють як глибоко вивчити симптоматику, так і оперативно охопити великий контингент пацієнтів. Підрозділ 1.3 показує, як за допомогою нейровізуалізаційних методик (структурної МРТ, DTI, fMRI, PET/SPECT, MRS) можна виявляти зміни в будові й функції мозку, пов'язані з ПТСР. А в 1.4 детально розглянуто, як працює аналіз BOLD-сигналів у fMRI-дослідженнях, які етапи попередньої обробки даних застосовують.

1.1 Загальні відомості про ПТСР

Посттравматичний стресовий розлад (ПТСР) — це стан, який може виникнути після подій, що загрожували життю чи здоров'ю. Наприклад, війна, аварія, напад чи стихійне лихо. Після такого досвіду людина може неначе знову і знову «переживати» те, що сталося: у вигляді нав'язливих спогадів чи нічних кошмарів [22].

Крім того, пацієнти з ПТСР можуть уникати будь-яких ситуацій, що нагадують про травмуючу подію, можуть стати емоційно відчуженими у стосунках із близькими, а також демонструють підвищену дратівливість, спалахи гніву чи зловживання психоактивними речовинами. Поряд із психологічними проявами спостерігаються фізіологічні зміни: порушення серцево-судинної та імунної систем, що можуть призвести до серйозних

медичних ускладнень [22].

Історично схожі стани описували ще під час великих війн, але саме після війни у В'єтнамі цю проблему почали називати «посттравматичним стресовим розладом». За сучасними даними, близько кожна п'ята жінка та кожен дванадцятий чоловік, які пережили серйозний стрес, можуть зіткнутися з ПТСР [22].

ПТСР впливає не лише на психіку: з часом через постійний стрес організм починає працювати на знос, що може призвести до проблем із серцем, імунітетом та іншими системами. Саме тому важливо розуміти, як працює цей механізм на стику психології, нейрофізіології та імунології, щоб своєчасно допомогти людині відновитися [22].

1.2 Традиційні методи діагностики ПТСР

У сучасній клінічній практиці діагностика ПТСР базується передусім на структурованому інтерв'ю та стандартизованих опитувальниках, які відповідають критеріям міжнародних номенклатур.

По-перше, це структуровані клінічні інтерв'ю, що дають змогу фахівцю ретельно опитати пацієнта за визначеним алгоритмом. Найпоширеніші з них — CAPS-5, який оцінює 20 ключових симптомів за шкалою від 0 до 4 балів, та International Trauma Interview (ITI), що охоплює як класичні симптоми ПТСР, так і додаткові порушення саморегуляції (DSO). Обидва інструменти вимагають не лише фіксації наявності симптомів, а й їхньої “травмо-релевантності”, тобто підтвердження зв'язку з подією, що спричинила розлад [3].

По-друге, часто застосовують прості опитувальники, які дають змогу швидко оцінити, як людина почувалася після травми. Наприклад, у PCL-5 є 20 запитань, де потрібно зазначити, наскільки та чи інша скарга заважала протягом останнього місяця. А IES-R пропонує 22 пункти для самооцінки нав'язливих спогадів, уникнення і підвищеного напруження за тиждень. Щоб

скласти повнішу картину, інколи додають короткі інтерв'ю для виявлення інших психічних розладів (наприклад, MINI чи SCID-II) і шкали на кшталт WHODAS 2.0, яка показує, наскільки складно людині справлятися з повсякденними справами. Поєднуючи детальне інтерв'ю з цими швидкими тестами, клініцисти отримують і глибоке розуміння симптомів, і можливість охопити велику кількість пацієнтів [3].

1.3 Методи нейровізуалізації у виявленні ПТСР

Нейровізуалізація стала ключовим напрямом у сучасному дослідженні психічних розладів, зокрема посттравматичного стресового розладу (ПТСР), який виникає внаслідок дії сильного стресового чинника і характеризується порушеннями емоційного стану, пам'яті, поведінки та фізіологічної регуляції. Впродовж останніх трьох десятиліть було накопичено значний обсяг даних щодо змін у структурі та функціонуванні головного мозку у пацієнтів з ПТСР, що дало змогу сформулювати нейробіологічну основу розуміння цього стану.

1.3.1 Структурні методи нейровізуалізації

До провідних методів структурної візуалізації головного мозку належать магнітно-резонансна томографія (МРТ) та дифузійно-тензорна томографія (DTI). МРТ дозволяє з високою просторовою точністю визначати морфологічні особливості сірої та білої речовини. За результатами численних досліджень, при ПТСР виявляються зменшення об'єму гіпокампа (рис. 1.1), мигдалеподібного тіла (мигдалини) а також передньої поясної кори. Ці ділянки мозку тісно пов'язані з обробкою емоцій, навчанням страху, регуляцією стресу та консолідацією пам'яті. Зокрема, зменшення об'єму гіпокампа у осіб з ПТСР корелює з погіршенням здатності до пригнічення страху та порушенням епізодичної пам'яті. Аналогічно, зменшення товщини кори у префронтальних відділах, особливо в медіальній префронтальній корі, асоціюється з труднощами у когнітивному контролі емоційних реакцій [12, 16].




Рисунок 1.1 — Порівняння об'єму гіпокампу у пацієнта з ПТСР та без на МРТ [5]

DTI (рис. 1.2) в свою чергу, дає змогу оцінити стан білої речовини шляхом вимірювання дифузії води в напрямку аксонів. У пацієнтів із ПТСР спостерігається зниження фракційної анізотропії (FA). Ці показники свідчать про зниження цілісності провідних шляхів, що пов'язано з труднощами в інтеграції емоційної інформації та формуванні відповідей на загрозливі стимули [12, 16].




Рисунок 1.2 — Результат дифузійно-тензорної візуалізації [9]

Особливої уваги заслуговують дані лонгітюдних досліджень, які показують, що деякі структурні зміни, наприклад у гіпокампі, можуть бути

наслідком перенесеної травми, тоді як інші — можливо, передують розвитку ПТСР і є маркерами вразливості. Наприклад, у ветеранів, які не розвинули ПТСР після бойових дій, об'єм гіпокампа був достовірно більшим, ніж у тих, хто зазнав розладу. Це вказує на потенційну роль нейровізуалізації як інструменту передбачення ризику розвитку ПТСР [12, 16].

1.3.2 Функціональні методи нейровізуалізації

Функціональна магнітно-резонансна томографія (фМРТ) є методом, що дозволяє оцінити активність різних мозкових регіонів під час виконання когнітивних або емоційно навантажених завдань, а також у стані спокою. Цей метод ґрунтується на аналізі змін кровотоку, пов'язаних з варіаціями рівня оксигенації крові — ефект BOLD (blood-oxygen-level dependent) (рис. 1.3). У пацієнтів із ПТСР було виявлено гіперактивність мигдалини при перегляді емоційно загрозливих зображень, що відображає підвищену реактивність на подразники, пов'язані з травмою. Поряд із цим, відзначено гіпоактивність медіальної префронтальної кори, що свідчить про порушення механізмів гальмування емоційних реакцій [12, 16].




Рисунок 1.3 – фМРТ головного мозку [20]

Значний інтерес викликає вивчення функціональної зв'язності (functional connectivity) — синхронізації активності між різними ділянками мозку. Зниження зв'язності між гіпокампом та префронтальною

корою вказує на порушення регуляції пам'яті та афективних процесів. Водночас посилена зв'язність у салієнтній мережі (salience network), до якої входять острівець, передня поясна кора та мигдалина, асоціюється з підвищеною увагою до загрозливих сигналів і гіперзбудливістю [12, 16].

1.4 Методи машинного навчання для діагностики ПТСР

Зараз дедалі частіше в психіатрії, зокрема у діагностиці посттравматичного стресового розладу (ПТСР), застосовують методи машинного навчання. Їх популярність зростає не просто так — ці технології вміють "бачити" складні закономірності там, де традиційні методи пасують. Ідеться передусім про роботу з великими масивами різномірних даних — нейровізуалізація, медичні записи, навіть записи з соцмереж [6].

Серед моделей, які використовують найчастіше, — метод опорних векторів, випадкові ліси, логістична регресія, згорткові нейронні мережі та моделі обробки природної мови. Наприклад, CNN-моделі вже показали непогану точність у розпізнаванні особливостей мозкової активності, які можуть свідчити про ПТСР — у межах від 67 до 83,6%. Цікаво, що дослідники з NYU Langone Health пішли далі й запропонували систему, яка діагностує ПТСР просто за голосом. Вона оцінює акустичні характеристики мови і має точність близько 89% [6].

Але машинне навчання не обмежується лише медичними зображеннями. Алгоритми навчилися працювати й з текстом — аналізують клінічні записи, розмови пацієнтів, пости в соцмережах, і навіть генетичну інформацію. Такий підхід допомагає виявляти людей із підвищеним ризиком розвитку ПТСР ще до появи явних симптомів. Наприклад, в одному з досліджень вдалось проаналізувати фактори, що впливали на психічний стан військових після служби в Афганістані [6].

Окремий, надзвичайно актуальний, напрям — персоналізоване прогнозування перебігу ПТСР і реакції пацієнта на терапію. Сучасні моделі,

підсилені інструментами пояснюваної аналітики (зокрема SHAP), не лише обчислюють ризики, а й показують, які саме фактори «штовхають» прогноз угору чи вниз. Клініцист, маючи таку «прозору» картину, може точніше коригувати схему лікування та своєчасно помічати зміни стану [6].

Паралельно розвиваються мобільні застосунки-помічники. PTSD Coach, Wysa та подібні сервіси інтегрують алгоритми обробки мови й емоційного аналізу, щоб фіксувати настрій, вести щоденник симптомів і відразу ж пропонувати підтримку. Такі інструменти переносять частину терапевтичної роботи з кабінету лікаря у повсякденність пацієнта [6].

Найбільша проблема — це обмежена кількість якісних даних. Досі багато моделей тестуються на малих вибірках, не завжди добре працюють поза лабораторією, і часто їм важко узгоджувати різні типи інформації [6].

Незважаючи на це, машинне навчання вже показало, що може суттєво розширити можливості діагностики ПТСР, а саме зробити її точнішою, швидшою й більш орієнтованою на конкретну людину. Наступним етапом є масштабування досліджень і краща інтеграцією цих рішень у реальну медичну практику.

1.5 Аналіз BOLD-сигналів: принципи та застосування

Сигнал BOLD (blood-oxygen-level-dependent) відображає локальні зміни співвідношення оксигенованого та дезоксигенованого гемоглобіну, що виникають внаслідок нейрональної активації. Коли нейрони починають працювати, вони споживають більше кисню, проте система кровопостачання реагує надлишком артеріальної крові, який перевищує фактичну потребу тканини. В результаті концентрація дезоксигенованого гемоглобіну в капілярах знижується, що призводить до підвищення MR-сигналу в T2*-режимі [11].

Нейроваскулярне сполучення — це сукупність клітинних механізмів, що зв'язують активність нейронів із реакцією судин. У цьому процесі беруть

участь гліальні астроцити, які за допомогою кальцієвих хвиль передають сигнал до перицитів на стінці капілярів, змушуючи їх регулювати тонус мікросудин. Роль також відіграють ендотеліальні клітини, які можуть посилювати чи стримувати розширення судини, і інтернейрони, які безпосередньо модулюють церебральний кровотік. Ця складна «ланцюгова реакція» починається вже за кілька сотень мілісекунд після активації нейронів і досягає піку приблизно через 3–5 с [11].

Попередня обробка BOLD-даних передбачає корекцію руху голови, просторову нормалізацію до загальноприйнятих атласів, згладжування сигналу й видалення низькочастотних дрейфів. Для завдань на пам'ять чи емоційну обробку зазвичай застосовують статистичні моделі, які зіставляють часові ряди функціональної активності з очікуваним «гемодинамічним відгуком». У режимі спокою аналізують взаємну кореляцію сигналів між віддаленими ділянками мозку, що дає інформацію про функціональні мережі (наприклад, пасивного стану чи уваги) [11].

У дослідженнях ПТСР аналіз BOLD-сигналів дозволив виявити характерні відмінності в реакції на травматичні стимули: надмірну активацію мигдалеподібного тіла та знижену функцію медіальної префронтальної кори, а також зміну зв'язності між ними в режимі спокою. Значення цього підходу полягає в тому, що кількісна оцінка BOLD-відгуку дає змогу об'єктивно визначати тяжкість порушень, прогнозувати ефективність терапії та відстежувати відновлення функцій мозку при психотерапевтичних втручаннях [11].

Висновок до розділу 1

У даному розділі систематизовано та узагальнено сучасні підходи до діагностики посттравматичного стресового розладу, підкресливши необхідність інтеграції клінічних і інструментальних методів. Викладено сутність ПТСР, охарактеризовано його симптоматику й показано, як

хронічний стрес впливає не лише на психіку, а й на фізіологічні системи організму. Описано традиційні методики діагностики — структуровані інтерв'ю (CAPS-5, ITI) та опитувальники самооцінки (PCL-5, IES-R) — що забезпечують стандартизовану оцінку симптомів.

Одночасно в розділі розглянуто нейровізуалізаційні технології (структурна MPT, DTI, fMRI, PET/SPECT, MRS), які дають змогу виявити анатомічні, мікроструктурні та метаболічні зміни мозку, пов'язані з ПТСР. Окрему увагу приділено аналізу BOLD-сигналу, що дозволяє об'єктивно виміряти нейроваскулярні відгуки на травматичні стимули та в стані спокою. Такий багатовимірний підхід створює цілісну картину розладу — від суб'єктивних проявів до конкретних нейробіологічних маркерів.

РОЗДІЛ 2

ОГЛЯД ТА ОБГРУНТУВАННЯ ВИБОРУ ЗАСОБІВ РЕАЛІЗАЦІЇ СИСТЕМИ

Розділ присвячено огляду теоретичних засад і ключових інструментів, які було обрано для подальшої реалізації системи діагностики на основі аналізу BOLD-сигналів. Метою є логічне обґрунтування вибору методів, бібліотек, мов програмування та підходів, що забезпечують відповідність поставленим завданням дослідження.

У межах розділу розглянуто фундаментальні поняття машинного навчання, зокрема глибоких нейронних мереж і особливостей їхньої архітектури. Окрема увага приділена згортковим нейронним мережам, які є ключовим елементом сучасного підходу до аналізу медичних зображень і сигналів. Також здійснено аналіз методів розвідкового аналізу даних, способів селекції ознак.

Окремий підпункт присвячено технічному інструментарію — мові програмування Python і бібліотекам, які використовуються для реалізації алгоритмів машинного навчання (TensorFlow, Keras, Scikit-learn), а також візуалізації (Matplotlib, Seaborn).

2.1 Основи машинного навчання та глибоких нейронних мереж

Машинне навчання (ML) сьогодні стало однією з ключових технологій, яка змінює не лише науку, а й наше повсякденне життя. В основі цього підходу лежить ідея, що комп'ютерна система здатна робити інтелектуальні передбачення на основі великого обсягу даних. Ці дані можуть включати мільйони унікальних прикладів, і саме завдяки сучасним досягненням у сфері алгоритмів, комп'ютерної потужності й доступності великих наборів даних, машинне навчання отримало можливість знаходити закономірності, які

раніше були недоступні навіть для людини-експерта [17].

Суть машинного навчання полягає в побудові моделі — певного алгоритму, який підбирається під особливості задачі та даних. Якщо даних багато, доцільно використовувати складніші моделі, наприклад, глибокі нейронні мережі. Якщо ж обсяг даних обмежений, часто ефективніше працюють класичні підходи, такі як лінійна регресія чи методи рішень на основі дерев. Дуже важливо враховувати тип даних: це можуть бути зображення, часові ряди або ж просто числові чи текстові таблиці [17].

У машинному навчанні розрізняють два основні підходи: навчання з учителем (supervised learning) і без учителя (unsupervised learning). У першому випадку моделі навчаються на даних із відомими правильними відповідями, наприклад, для задач класифікації зображень. У другому випадку система сама знаходить структуру в даних, наприклад, виявляє кластери або шукає закономірності. В сучасних дослідженнях широко використовують і змішані підходи, наприклад, змагальне навчання (reinforcement learning) [17].

Типовою задачею машинного навчання є класифікація — визначення, до якого класу належить об'єкт. Для цього модель "навчається" на частині даних, а потім її перевіряють на нових, раніше не бачених прикладах. Дуже важливо ділити дані на навчальну, валідаційну та тестову вибірки, щоб уникнути перенавчання й адекватно оцінити якість роботи моделі [17].

Окреме місце в сучасному машинному навчанні займає глибоке навчання (deep learning) та штучні нейронні мережі. Вони натхненні біологією — імітують спосіб, яким нервові клітини в мозку передають сигнали одна одній. У штучних нейромережах дані проходять через кілька шарів — від простих до складних, де кожен шар автоматично вчиться виділяти важливі ознаки для вирішення задачі. Однією з найпотужніших архітектур є згорткові нейронні мережі (CNN), які особливо добре працюють із зображеннями. Вони автоматично навчаються знаходити прості й складні патерни, наприклад, краї, текстури чи навіть цілі об'єкти [17].

Навчання глибоких моделей — процес непростий. Для цього

використовують функції втрат, які визначають, наскільки передбачення моделі відрізняються від правильних відповідей, і спеціальні алгоритми оптимізації, такі як стохастичний градієнтний спуск. Досить часто застосовується метод перенавчання (transfer learning), коли модель спочатку навчається на великому наборі даних, а потім донавчається під конкретну задачу [17].

Важливим етапом є оцінка якості моделі. Окрім звичних метрик для класифікації (чутливість, специфічність, площа під ROC-кривою), необхідно слідкувати за проблемою перенавчання — коли модель занадто добре “запам’ятовує” навчальні дані, але погано працює з новими. Для цього використовують різні методи регуляризації, крос-валідації та спеціальні архітектурні прийоми, наприклад, dropout [17].

Зараз машинне навчання стає справжнім проривом для медицини, і це не перебільшення. Кількість даних у цій сфері просто колосальна: це й знімки, і результати аналізів, і електронні медичні картки. Людині складно охопити й проаналізувати все це — а ось алгоритми машинного навчання справляються із цим швидко й точно. Вони вміють знаходити такі закономірності, які лікарю часто навіть не спадають на думку.

Один із найбільших плюсів — це вміння “бачити” на знімках те, що може залишитися непоміченим навіть досвідченим спеціалістом. Наприклад, комп’ютерна система може виявити ознаки раку на МРТ або рентгені, допомогти з діагностикою патологій на гістологічних препаратах. Це не просто економить час лікаря — це буквально рятує життя, бо дозволяє помітити хворобу на ранній стадії.

Ще важливо, що машинне навчання бере на себе рутинні завдання: автоматично аналізує знімки, сортує результати, підказує можливі діагнози. Лікарі ж завдяки цьому можуть більше уваги приділяти складним, нестандартним випадкам і пацієнтам, які справді цього потребують.

Не менш важливо й те, що сучасні моделі можуть об’єднувати дані з різних джерел — результати аналізів, історію хвороби, навіть генетичну

інформацію — і допомагають підібрати індивідуальне лікування саме для цієї людини.

І що цікаво, у багатьох завданнях, наприклад у розпізнаванні хвороб шкіри чи аналізі знімків, моделі глибокого навчання вже показують точність на рівні, а інколи й вище за кращих лікарів. Тож машинне навчання поступово стає не просто корисним інструментом, а невід'ємною частиною сучасної медицини, яка допомагає робити діагностику швидшою, точнішою та більш об'єктивною.

2.2 Архітектура згорткових нейронних мереж

У сучасних дослідженнях з аналізу зображень, зокрема в медичній діагностиці, однією з найефективніших і водночас найцікавіших архітектур штучних нейронних мереж вважається згорткова нейронна мережа (Convolutional Neural Network, CNN). Вона базується на принципах, які певною мірою імітують обробку інформації в мозку людини. Це стало справжнім проривом у розпізнаванні образів, оскільки такі моделі можуть самостійно "навчатися" знаходити найінформативніші ознаки у зображеннях, не потребуючи від дослідника ручного виділення особливостей.

2.2.1 Основні елементи архітектури

Першим у мережі є вхідний шар. Він не виконує ніяких обчислень, але приймає зображення у вигляді багатовимірного масиву (наприклад, матриці розміром висота $\times$ ширина $\times$ кількість каналів). Саме це зображення стає «матеріалом» для подальшого аналізу [2].

Згортковий шар — це ключова частина архітектури, яка дозволяє мережі виділяти локальні просторові ознаки (рис. 2.1). Тут застосовуються спеціальні фільтри (ядра, kernels), які мають невеликий розмір (наприклад, 3×3 або 5×5) порівняно із самим зображенням, але охоплюють усю його глибину (всі канали) [2].




Рисунок 2.1 – Згортковий шар [13]

Цей фільтр проходить по зображенню з певним кроком (stride) та на кожному положенні виконує згортку: тобто перемножує значення пікселів під ядром із вагами фільтра, підсумовує отримані значення і формує елемент нової карти ознак. Так для кожної позиції формується масив чисел, що описує локальні властивості фрагмента зображення [2].

Цікаво, що на перших шарах згорткові фільтри часто «навчаються» виявляти найпростіші структури: горизонтальні й вертикальні краї, кути, зміни яскравості. Зі збільшенням глибини мережі фільтри починають розпізнавати дедалі складніші патерни — текстури, частини об'єктів, а далі й цілісні об'єкти або аномалії (наприклад, пухлини на медичних знімках). Саме це і дозволяє CNN працювати з багаторівневими особливостями даних, не потребуючи ручної інженерії ознак [2].

Згорткові шари також мають важливу властивість — локальність з'єднань. Кожен нейрон цього шару під'єднаний не до всіх виходів попереднього шару, а лише до невеликої області (рецептивного поля). Така локальність зменшує кількість параметрів у моделі, що особливо актуально для аналізу великих зображень [2].

Після згорткового шару результати передаються на шар активації, головним чином для введення нелінійності у модель. Найбільш популярна функція — ReLU (Rectified Linear Unit), яка працює за принципом: якщо значення позитивне — воно залишається без змін, якщо від’ємне — замінюється на нуль [2].

Ця простота дозволяє уникати багатьох проблем класичних функцій активації, зокрема явища «затухаючого градієнта», і суттєво прискорює процес навчання. Однак у ReLU є і певний недолік — іноді окремі нейрони можуть повністю втратити здатність до навчання, якщо на них постійно потрапляють лише від’ємні значення (так звані «мертві нейрони»). Попри це, саме ReLU стала стандартом для глибоких згорткових мереж [2].

Після одного чи кількох згорткових та активаційних шарів дані зазвичай надходять до пулінгового шару (рис. 2.2). Його основне призначення — зменшення розмірності карт ознак (feature maps) при збереженні найбільш важливої інформації. Найчастіше застосовується max pooling: з кожного невеликого блока (наприклад, 2×2) вибирається максимальне значення. Такий підхід дозволяє зберігати найяскравіші ознаки, ігноруючи другорядні деталі [2].




Рисунок 2.2 – Шар пулінгу [19]

Пулінг дає змогу зменшити кількість параметрів і обсяг обчислень, а також зробити модель менш чутливою до невеликих зсувів чи змін на зображенні — це називається локальною трансляційною інваріантністю. Крім max pooling, іноді використовують average pooling (береться середнє значення блоку), однак для задач комп'ютерного зору max pooling, як правило, дає кращі результати [2].

У сучасних реалізаціях CNN часто додають допоміжні шари для підвищення якості навчання:

- Batch Normalization — нормалізує дані всередині шару, прискорює й стабілізує навчання;
- Dropout — випадковим чином «вимикає» частину нейронів під час навчання, що дозволяє знизити ризик перенавчання моделі [2].

Після проходження через послідовність згорткових, активаційних і пулінгових шарів отримані карти ознак перетворюються у вектор (операція flatten). Цей вектор подається на один або кілька повнозв'язних шарів. Тут кожен нейрон з'єднаний з усіма значеннями попереднього шару. Саме ці шари відповідають за остаточну інтерпретацію ознак і прийняття рішення — наприклад, класифікацію зображення як «здорове» чи «патологія» [2].

На фінальному шарі часто використовується функція softmax (у багатокласових задачах), яка перетворює вихідні значення на ймовірності для кожного класу, або sigmoid (у бінарній класифікації) [2].

2.2.2 Переваги та особливості застосування CNN у медицині

Головною перевагою згорткових мереж є те, що вони самостійно навчаються виділяти релевантні ознаки, які не завжди очевидні навіть досвідченим спеціалістам. У медичній діагностиці це дозволяє знаходити складні та малопомітні патологічні зміни, які важко ідентифікувати традиційними методами. Такі моделі застосовують для автоматичного розпізнавання аномалій на МРТ, КТ, рентгенівських знімках, а також у гістопатології чи дерматології.

Значного розвитку ця галузь набула завдяки появі великих наборів даних із розміченими медичними зображеннями, покращенню алгоритмів оптимізації та розвитку апаратного забезпечення для обробки великих обсягів даних. Відомі приклади впровадження CNN у клінічній практиці — це автоматичне визначення типу шкірних утворень, класифікація пухлин, пошук метастазів на гістологічних зрізах та багато іншого.

2.3 Розвідковий аналіз для вибору інформативних ознак

Метою розвідкового аналізу є зменшення розмірності простору ознак, виділення найінформативніших характеристик та формування стійкого класифікатора. У межах цієї роботи розвідковий аналіз реалізовано у два ключові етапи: селекція ознак та класифікація на основі бінарних логістичних регресій.

2.3.1 Селекція ознак

У задачах медичної діагностики, особливо при класифікації патологій за зображеннями, ключову роль відіграє відбір інформативних ознак. У багатовимірних просторах, де кількість ознак значно перевищує кількість об'єктів навчання ($N \gg M$), класичні методи відбору втрачають ефективність через надлишкову кореляцію, шум та перенавчання моделі. У цьому контексті доцільним є застосування клас-орієнтованого підходу до селекції ознак, який забезпечує побудову стійкого класифікатора завдяки поетапному відбору найбільш релевантних характеристик із урахуванням їхнього внеску у розрізнення класів [18].

Розглянута технологія передбачає процес селекції, що складається з п'яти етапів. Перший етап спрямований на попередню фільтрацію ознак на основі міжкласової відмінності. Використовується критерій порівняння середніх значень ознак у різних класах, із відсіканням тих, що не перевищують певний поріг. Це дозволяє усунути ознаки з низькою дискримінативною здатністю вже на старті [18].

Другий етап полягає в раціоналізації відбору на основі крокового перебору значень незалежної змінної, наприклад, відтінків сірого у текстурних матрицях. Тут застосовується припущення про близьку ефективність сусідніх ознак, що дає змогу уникнути надлишкової кореляції й зменшити обсяг вибірки без втрати інформативності [18].

На третьому етапі проводиться тонкий аналіз внутрішньокласової варіативності, з метою залишити лише ті ознаки, які забезпечують максимальну міжкласову відстань і мінімальну внутрішньокласову дисперсію. Таким чином, зберігаються ознаки, найбільш стійкі до коливань у межах одного класу, що критично важливо в медичних задачах [18].

Четвертий етап — перехід до формування ансамблів ознак за критерієм mRMR (Minimum Redundancy — Maximum Relevance), що забезпечує відбір найменш залежних між собою ознак з одночасною максимальною кореляцією з цільовою змінною. Для пошуку оптимального набору використовується елітарний генетичний алгоритм, що значно зменшує обчислювальні витрати при переборі великих комбінацій [18].

Нарешті, на п'ятому етапі здійснюється об'єднання каналів у єдиний класифікатор. Реалізація можлива як через оптимізацію ансамблю ознак перед побудовою моделі на основі Random Forest, так і через побудову окремих дерев рішень по кожному каналу з наступним об'єднанням у Random Forest та оптимізацією функції голосування за методом групового урахування аргументів (GMDH) [18].

Застосування цієї технології в задачі диференціації хіміочутливого та хіміорезистентного туберкульозу за КТ-зображеннями дозволило досягти точності класифікації до 85% на валідаційній вибірці. Це підтверджує високу ефективність клас-орієнтованої селекції ознак у задачах медичного розпізнавання образів [18].

2.3.2 Класифікація на основі бінарних логістичних регресій

Ансамблеві методи стали невід'ємною частиною сучасного машинного навчання, особливо в медичних задачах, де важливими є точність і прозорість

прийняття рішень. Серед них метод випадкового лісу (Random Forest) залишається класикою, однак останні дослідження демонструють, що вдосконалення структури голосування та оптимізація внутрішньої логіки моделей дозволяють суттєво підвищити якість класифікації. Одним із таких підходів є побудова самонавчального ансамблю рішень на основі модифікованого алгоритму покрокової логістичної регресії з використанням методу позиційного голосування [15].

На відміну від класичного підходу, де результат подається від усього дерева, у запропонованій архітектурі кожне дерево представляється не як єдина сутність, а як набір «експертів», які приймають рішення незалежно. Кожна гілка має свою компетентність, визначену за точністю класифікації на валідаційній вибірці. Таким чином формується матриця об'єкт-ознака, в якій кожен елемент відображає передбачення певного експерта з відповідним рівнем довіри [15].

Для побудови агрегуючої функції голосування використовується логістична регресія, що синтезується на основі покращеного покрокового алгоритму з урахуванням методу групового врахування аргументів (GMDH). У процесі відбору ознак, що формують модель, враховується зовнішній критерій — баланс точності класифікації на тренувальній і тестовій вибірках, а також симетрія класифікації між класами. Алгоритм має двонаправлений характер, тобто враховує як включення, так і виключення предикторів, що забезпечує гнучку адаптацію структури моделі до конкретної задачі [15].

Особливістю реалізації є використання сітки значень рівнів значущості (α_1 , α_2) для кроків додавання й видалення ознак. Для кожної комбінації генерується модель, що оцінюється за зовнішнім критерієм. Обирається та, яка демонструє найкраще співвідношення точності між класами й наборами даних [15].

Під час зростання лісу зберігаються лише ті дерева (і гілки), що покращують загальну класифікацію. Якщо після додавання чергового дерева точність на об'єднаній вибірці не підвищується, процес зупиняється. Таким

чином формується адаптивний ансамбль — самонавчальний ліс оптимальної складності [15].

У тестуванні на реальних медичних даних така система показала приріст точності класифікації у порівнянні з класичним Random Forest до 97% F1-міри, що підтверджує дієвість концепції використання гілок дерев як експертів і глибокої регресійної агрегації [15].

Перевага цієї архітектури — не лише в підвищенні точності, а й у прозорості прийнятих рішень: можна чітко визначити, які саме "гілки-експерти" вплинули на підсумкову класифікацію об'єкта, що робить її особливо корисною у чутливих сферах, як-от медицина [15].

2.4 Технологічний стек реалізації системи

2.4.1 Мова програмування Python

Python — це мова програмування високого рівня, яка є інтерпретованою та об'єктно-орієнтованою. Вона відзначається простою та зрозумілою синтаксичною структурою, має зручні вбудовані типи даних і забезпечує гнучке опрацювання інформації завдяки динамічній типізації. Python ідеально підходить для швидкої розробки програм, а також для автоматизації та об'єднання різних компонентів у одну систему [25].

Головна перевага Python — простий синтаксис, завдяки якому код легко читати та підтримувати. Мова підтримує модулі та пакети, що дозволяє розбивати великі програми на менші частини й використовувати код повторно. Окрім цього, Python оснащений великою стандартною бібліотекою, яка є безкоштовною та доступна на всіх основних операційних системах [25].

Переваги мови програмування Python:

- Синтаксис Python простий і зрозумілий, що робить код легко читабельним і зручним для написання навіть для початківців. Це сприяє швидкому засвоєнню мови та допомагає уникати помилок, пов'язаних із надмірною складністю коду.

- У Python велика стандартна бібліотека, а також тисячі сторонніх пакетів для різноманітних задач: обробки даних, машинного навчання, автоматизації, створення графіки та багатьох інших напрямків. Це значно прискорює розробку програм, оскільки більшість необхідних інструментів вже є готовими.
- Мова дає можливість швидко розробляти і тестувати програми. Завдяки простоті синтаксису та наявності численних бібліотек процес створення прототипів і подальшого вдосконалення програм відбувається значно швидше, ніж на багатьох інших мовах.
- Python кросплатформений, тобто написані на ньому програми можуть працювати на різних операційних системах — Windows, Linux, macOS — без необхідності змінювати код. Це зручно для розробки універсальних рішень.
- Мова підтримує різні парадигми програмування: можна використовувати як процедурний, так і об'єктно-орієнтований чи функціональний підхід, залежно від завдань і вподобань розробника.
- У Python одна з найбільших і найактивніших спільнот у світі програмування. Це означає, що завжди легко знайти відповіді на запитання, приклади коду або отримати пораду. Постійно з'являються нові бібліотеки, оновлення й навчальні матеріали.
- Python є безкоштовною та відкритою мовою програмування. Її можна вільно використовувати, змінювати та поширювати як у комерційних, так і в навчальних або наукових цілях.
- Завдяки своїм властивостям Python став стандартом у галузі аналізу даних, машинного навчання, штучного інтелекту, автоматизації та наукових досліджень. Більшість сучасних проєктів у цих сферах виконуються саме на цій мові.

2.4.2 TensorFlow/Keras

У даній роботі для побудови нейронної мережі використовувались бібліотеки TensorFlow та Keras. Обидві вони добре зарекомендували себе в задачах, де йдеться про глибоке навчання. TensorFlow — це потужний інструмент, який створений і підтримується компанією Google. Його часто застосовують у дослідницьких проєктах, і не тільки. Це середовище дозволяє створювати досить складні архітектури моделей і керувати процесом тренування з високим рівнем контролю.

Але, щоб працювати швидше й зручніше, найчастіше використовують Keras — зручну надбудову над TensorFlow. Саме вона значно спрощує створення моделей, особливо коли йдеться про стандартні шари, як-от згорткові, повнозв'язні чи шар активації. Замість великої кількості коду, все можна описати компактно й зрозуміло. Це суттєво полегшує не лише початок роботи, але й подальші зміни в архітектурі.

Крім цього, TensorFlow підтримує прискорення за допомогою графічних процесорів. Це особливо зручно, коли модель навчається на великому обсязі даних, як у випадку з аналізом медичних зображень чи сигналів. Програма працює швидше, і не доводиться годинами чекати на результати.

Важливо й те, що за потреби модель можна зберегти, зупинити тренування, а потім продовжити. Це дуже зручно, коли обчислення займають багато часу. Також бібліотека дозволяє експортувати готову модель у спрощеному форматі, наприклад, для мобільних застосунків або вебсервісів.

Загалом, поєднання TensorFlow та Keras дає можливість працювати як просто, так і гнучко. Ці бібліотеки підходять як для базових задач, так і для складніших експериментів. Саме тому вони були обрані як основа для реалізації моделі в цій роботі.

2.4.3 Scikit-learn

Scikit-learn, або просто sklearn, — це одна з найзручніших та найвідоміших бібліотек Python для задач машинного навчання. Вона надає широкий набір інструментів, які дозволяють працювати з алгоритмами

класифікації, регресії, кластеризації, а також реалізовувати попередню обробку даних, масштабування, вибір ознак і, що особливо важливо — оцінювати якість побудованих моделей [4].

Серед усього функціоналу окреме місце займає модуль `metrics`, який відповідає за обчислення показників ефективності моделей. Він є надзвичайно корисним на етапі аналізу результатів, адже дозволяє не лише побачити загальний рівень точності, але й зрозуміти, як саме поводить ся модель у різних ситуаціях — наприклад, чи вона вміє розпізнавати рідкісні класи, чи переважно вгадує найчастіші.

У класифікаційних задачах `sklearn` пропонує цілу низку метрик, які допомагають подивитися на модель з різних боків. Наприклад, точність (accuracy) показує, скільки передбачень виявилися правильними. Але в задачах з нерівномірним розподілом класів набагато інформативнішими стають `precision`, `recall` і `F1-score` — саме вони дозволяють виявити, наскільки модель "влучає" саме туди, куди треба, і наскільки пропускає важливі об'єкти. Іноді одне тільки значення `F1` вже дає чітке уявлення, чи є модель хоча б приблизно придатною до реального використання [4].

У задачах регресії працюють трохи інші метрики. Наприклад, середня абсолютна помилка або середня квадратична помилка показують, наскільки сильно передбачення відрізняються від справжніх значень. А коефіцієнт детермінації R^2 дозволяє зрозуміти, чи справді модель захопила якусь структуру в даних, чи лише імітує результат. Якщо R^2 близький до одиниці — це гарний знак, якщо ж значення від'ємне, то модель працює гірше за банальне середнє.

Зручність полягає ще й у тому, що всі ці метрики реалізовані у вигляді простих функцій. Їх легко інтегрувати в код, швидко протестувати різні варіанти моделей і отримати звіт, який можна інтерпретувати вже безпосередньо. Наприклад, функція `classification_report` одразу показує основні показники по кожному класу — що значно полегшує аналіз результатів, особливо коли класів багато [4].

Загалом `sklearn` — це бібліотека, яка дає змогу не просто побудувати модель, а й по-справжньому зрозуміти, як вона працює. Метрики — це не сухі числа, а спосіб подивитись на модель як на інструмент, оцінити її поведінку, сильні й слабкі сторони. І саме це дозволяє приймати обґрунтовані рішення під час роботи з машинним навчанням.

2.4.4 Matplotlib/Seaborn

Під час роботи з даними часто виникає потреба щось побачити наочно — не просто цифри чи статистику, а картинку, яка допомагає зрозуміти, що відбувається. Для цього в Python є два добре відомі інструменти — `Matplotlib` і `Seaborn`. Обидві бібліотеки створені для побудови графіків, але підходять до цього по-різному.

`Matplotlib` — це гнучкий інструмент, який дозволяє створювати графіки з нуля. У ній усе налаштовується вручну: кольори, підписи, осі, легенди, стиль ліній, масштабування, можна змінити майже будь-який елемент (рис. 2.3). Якщо потрібно побудувати щось нестандартне або оформити графік для публікації, `Matplotlib` дає повний контроль. Але за це доводиться платити часом — написання коду займає більше зусиль, особливо якщо треба зробити багато подібних візуалізацій.




Рисунок 2.3 – Структура графіка в `Matplotlib` [14]

Seaborn спрощує цю задачу. Це бібліотека, яка працює поверх Matplotlib, але приховує більшість технічних деталей. У неї інший підхід: замість того щоб налаштовувати графік вручну, достатньо вказати, які саме змінні слід візуалізувати. Наприклад, для побудови графіка розподілу потрібно буквально одна команда — і результат вже готовий. Виглядає все досить естетично, навіть без додаткових налаштувань.

Те, що робить Seaborn особливо зручним, — це його взаємодія з Pandas. Графіки будуються прямо з датафрейму, без додаткових перетворень. Можна швидко подивитись розподіл, порівняти групи, побачити кореляції. Іноді такі візуалізації дають більше розуміння, ніж багато сторінок числових звітів.

Matplotlib і Seaborn часто використовують разом. Один дає точність і контроль, другий — швидкість і зручність. У комплексі це дозволяє будувати як базові графіки для аналізу, так і більш складні візуалізації, які підходять для презентацій або наукових публікацій.

Обидві бібліотеки постійно оновлюються, мають добру документацію й підтримуються спільнотою. Для тих, хто працює з даними, ці інструменти стали стандартними, тому, що вони зручні й ефективні.

2.4.5 Numpy

NumPy — це одна з ключових бібліотек, що лежать в основі наукового програмування мовою Python. Вона створена спеціально для роботи з великими масивами числових даних і дозволяє виконувати обчислення значно швидше, ніж за допомогою стандартних засобів мови. Основним типом об'єктів у бібліотеці є `ndarray` — багатовимірний масив, який підтримує операції векторизації.

Ці масиви зберігають усі елементи одного типу, що позитивно впливає на ефективність використання пам'яті. Крім того, багато математичних операцій — наприклад, додавання, множення, обчислення середнього значення — виконуються над усім масивом одразу, без необхідності писати цикли. Завдяки цьому код стає не лише коротшим, а й швидшим у виконанні.

У цій роботі бібліотека використовується на етапі підготовки даних: для

зчитування та обробки числових масивів, а також для формування вхідних даних для згорткової нейронної мережі.

Варто додати, що бібліотека добре інтегрується з іншими інструментами Python. Наприклад, дані з NumPy легко передати до TensorFlow або Keras — без додаткового перетворення форматів. Це особливо зручно при побудові моделей машинного навчання, де важлива узгодженість усіх компонентів.

У підсумку можна сказати, що NumPy — це не просто зручна, а справді необхідна частина інструментарію для будь-якого проєкту, який передбачає роботу з великими обсягами чисел. Саме завдяки їй багато складних речей — як-от матричні обчислення чи фільтрація даних — реалізуються дуже просто.

Висновок з розділу 2

У ході теоретичного аналізу було розглянуто низку концепцій, методів і технологій, які є основою для побудови системи автоматизованої діагностики. Розділ дав змогу систематизувати знання про сучасні підходи в галузі машинного навчання, зокрема глибоких згорткових нейронних мереж, що довели свою ефективність при роботі з візуальними та часовими даними медичного характеру.

Обґрунтування вибору CNN як базової архітектури базується на її здатності автоматично виділяти значущі ознаки, адаптуватися до складних вхідних структур і забезпечувати високу точність при мінімальному втручанні людини в процес підготовки ознак. Розглянуті елементи архітектури, такі як згортки, активаційні функції, пулінг, нормалізація та регуляризація, становлять основу побудови гнучкої та стійкої моделі.

Водночас розвідковий аналіз і підходи до селекції ознак забезпечують можливість оптимізації простору вхідних даних, що є критично важливим у задачах з великою кількістю параметрів. Вибір методів відбору змінних та комбінування моделей, зокрема на основі логістичних регресій, дозволяє забезпечити інтерпретованість і стійкість класифікації.

З технічного погляду, обрана мова програмування Python та набір бібліотек покривають усі потреби розробки — від побудови моделей до візуалізації та оцінювання результатів. Їхня поширеність, документація та активна підтримка спільноти є додатковими аргументами на користь цього вибору.

Таким чином, у межах даного розділу було сформовано повноцінне теоретичне підґрунтя, яке дозволяє перейти до наступного етапу — практичної реалізації системи на основі обґрунтованих рішень і перевірених технологій.

РОЗДІЛ 3

ПРОГРАМНА РЕАЛІЗАЦІЯ ТА МЕТОДИКА РОБОТИ НЕЙРОННОЇ МЕРЕЖІ

У цьому розділі описано реалізацію програмної частини системи діагностики посттравматичного стресового розладу на основі аналізу BOLD-сигналів. Основна увага приділяється етапам підготовки даних, побудові структури згорткової нейронної мережі, її навчанню та оцінці якості роботи. Розглянуто, як із початкових матриць функціональних зв'язків формуються вхідні тензори, які параметри моделі використовуються, як налаштовується розподіл даних на навчальну, валідаційну та тестову вибірки.

Також у межах розділу представлено результати тестування моделі, зокрема значення метрик точності, повноти, F1-міри, а також графіки навчання, що відображають динаміку змін функції втрат. Наприкінці наведено приклад інтерпретації отриманих результатів і короткий аналіз обмежень та потенційних напрямів вдосконалення моделі.

3.1 Опис вхідних даних

У дослідженні використовувалися дані функціональної МРТ у стані спокою, які після попередньої обробки були представлені у вигляді двох матриць: матриці коефіцієнтів кореляції між регіонами мозку та матриці параметрів моделей першого порядку. Всі сигнали були приведені до простору MNI152 та сегментовані відповідно до Гарвардсько-Оксфордського атласу. У процесі обробки було застосовано стандартні методи фільтрації, зокрема видалення шумів та артефактів, пов'язаних із рухами голови та іншими фізіологічними джерелами, а також смугову фільтрацію в межах 0,008–0,09 Гц для виділення релевантної активності [8].

Першою матрицею є матриця C , що має розмірність 164×164 . Вона

містить коефіцієнти кореляції Пірсона між парами очищених часових рядів BOLD-сигналів, які були отримані з різних структур мозку (рис. 3.1). Після обчислення кореляцій усі значення проходили перетворення Фішера (z-трансформацію) для покращення статистичних властивостей. Ця матриця є симетричною, а її елементи відображають ступінь функціональної зв'язності між відповідними регіонами мозку. Таким чином, матриця C характеризує синхронізовану активність між мозковими структурами в стані спокою [8].




Рисунок 3.1 – Матриця зв'язності структур головного мозку [8]

Другою є матриця A_0 , також розміром 164×164 , яка містить параметри лінійних моделей першого порядку. У цій моделі коефіцієнт A_0 є вільним членом для кожної пари структур головного мозку було побудовано моделі першого порядку виду (3.1) де параметри A_0 та A_1 визначають залежність між сигналами у вибраних структурах [8].

$$y = A_0 + Ax \quad (3.1)$$

Обидві матриці — C і A_0 — виступають вхідними даними для подальшого етапу моделювання. На їх основі виконувалася побудова діагностичної моделі. Застосування обох типів матриць дозволяє поєднати інформацію про ступінь синхронності та структурну асиметрію взаємодії між мозковими регіонами, що є важливим для точного розпізнавання змін, пов'язаних із ПТСР.

3.2 Підготовка даних

На етапі попередньої обробки для кожного пацієнта з наявної вибірки були сформовані дві матриці розмірності 164×164 , які містили інформацію про функціональну та модельовану взаємодію між мозковими структурами. Обидві матриці репрезентують різні аспекти зв'язності мозку: симетрична матриця C відображає ступінь синхронізації активності, тоді як несиметрична матриця A_0 вказує на потенційні спрямовані залежності. З метою збереження повноти інформації ці матриці подавались у модель одночасно як двоканальний вхід, аналогічно до обробки RGB-зображень, де кожен канал несе окрему інформативність. Такий підхід дозволяє моделі аналізувати комплексну функціональну взаємодію в мозкових мережах, що особливо важливо при роботі з нейровізуалізаційними даними.

Для забезпечення якості навчання згорткової нейронної мережі весь датасет було поділено на три підвибірки: тренувальну, валідаційну та тестову. На відміну від випадкового розбиття, у цьому дослідженні було застосовано алгоритм стратифікованого поділу з урахуванням метрики Махаланобіса. Такий метод дозволяє забезпечити збалансованість вибірок не лише за кількістю пацієнтів у кожному класі, але й за статистичними характеристиками ознак у багатовимірному просторі. Зокрема, метрика Махаланобіса враховує коваріаційну структуру даних, що дозволяє точно

оцінити відстань між об'єктами з урахуванням внутрішніх залежностей між змінними.

Цей підхід є доцільним при роботі з BOLD-сигналами, оскільки такі дані зазвичай мають високу корельованість між ознаками, складну структуру та значну варіативність. Використання Евклідової метрики в такому випадку може призвести до того, що різні підвибірки будуть суттєво відрізнятись за розподілом ознак, що знижує якість узагальнення моделі. Натомість, завдяки метриці Махаланобіса, вдалося досягти високого рівня статистичної подібності між тренувальною, валідаційною та тестовою вибірками, що підтверджується відповідним аналізом дисперсій.

Алгоритм, який забезпечував цей тип розбиття, був спеціально реалізований у рамках даного дослідження з урахуванням обмеженого обсягу вибірки та необхідності збалансованого представлення класів. Підсумковий розподіл пацієнтів за підвибірками наведено у табл. 3.1.

Таблиця 3.1

Розбиття вибірки

Клас	Розмір тренувальної вибірки	Розмір валідаційної вибірки	Розмір тестової вибірки	Загальна кількість
Пацієнти з ПТСР	17	8	5	30
Здорові пацієнти	17	8	5	30
Всього	34	16	10	60

3.3 Базова згорткова нейронна мережа

3.3.1 Архітектура та реалізація базової моделі

Базова модель згорткової нейронної мережі була реалізована за допомогою бібліотеки Keras, що входить до складу фреймворку TensorFlow. Архітектура моделі є послідовною (тип Sequential), тобто кожен шар передає

свої результати безпосередньо наступному, формуючи лінійну обробку даних. Такий підхід дозволяє створити компактну та зручну для аналізу структуру моделі, особливо актуальну для задач класифікації.

На вхід моделі подається тривимірний масив розміром (164, 164, 2), де 164×164 — це розмірність двох матриць, сформованих для кожного пацієнта: матриці коефіцієнтів кореляції між BOLD-сигналами з різних ділянок мозку та матриці параметрів регресійної моделі першого порядку. Кожна з них подається в окремому каналі, аналогічно до трьох кольорових каналів у зображеннях. Такий двоканальний підхід дозволяє мережі одночасно враховувати як ступінь синхронності активності між регіонами мозку (матриця кореляції), так і можливі спрямовані взаємодії (матриця A_0).

Першим шаром мережі є згортковий (Conv2D) з 32 фільтрами розміром 3×3 і функцією активації ReLU, яка вводить у модель здатність до нелінійного відображення ознак. Далі йде шар нормалізації (BatchNormalization), що стабілізує навчання, та шар підвибірки (MaxPooling2D) розміром 2×2 , який зменшує просторову розмірність карт ознак, залишаючи найхарактерніші патерни. Другий згортковий блок повторює подібну структуру, але вже використовує 64 фільтри розміром 2×2 . Знову після згортки додається нормалізація та підвибірка. У третьому згортковому блоці кількість фільтрів збільшується до 128, після чого результати передаються у шар глобального середнього згортання (GlobalAveragePooling2D). Цей шар обчислює середнє значення по кожному фільтру, стискаючи дані у вектор фіксованої довжини та значно зменшуючи кількість параметрів перед класифікаційними шарами.

Після етапу виділення ознак вектор подається у повнозв'язний (Dense) шар із 64 нейронами, функцією активації ReLU та регуляризацією L2 (з коефіцієнтом 0.0001), яка "штрафує" великі ваги, допомагаючи уникнути перенавчання. Для додаткового захисту від перенавчання використано шар Dropout, що випадково "вимикає" 40 % нейронів під час кожної ітерації навчання. На виході мережі стоїть ще один Dense-шар із одним нейроном та функцією активації sigmoid, що перетворює результати в імовірність

належності до класу ПТСР (1 — наявність розладу, 0 — відсутність).

Для навчання моделі було обрано оптимізатор Adagrad із початковою швидкістю навчання 0.0005. Цей оптимізатор автоматично адаптує швидкість оновлення ваг для кожного параметра окремо, що є корисним у задачах із нерівномірно масштабованими ознаками. Як функцію втрат було використано бінарну крос-ентропію (`binary_crossentropy`), яка ідеально підходить для задач двокласової класифікації. Для оцінки якості навчання застосовано дві метрики: точність (`accuracy`) та F1-міра (`f1_score`), яка особливо важлива при аналізі незбалансованих даних, оскільки враховує як повноту, так і точність класифікації.

На рис. 3.2 представлено графічну схему згорткової мережі, де відображено структуру шарів, кількість фільтрів, їх розміри, а також розмірність виходу кожного шару. Це дозволяє наочно простежити трансформацію вхідних даних у процесі проходження мережею.

```
model = tf.keras.Sequential([

    tf.keras.layers.Input(shape=(164, 164, 2)),
    tf.keras.layers.Conv2D(32, (3, 3), activation='relu'),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.MaxPooling2D((2, 2)),

    tf.keras.layers.Conv2D(64, (2, 2), activation='relu'),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.MaxPooling2D((2, 2)),

    tf.keras.layers.Conv2D(128, (2, 2), activation='relu'),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.GlobalAveragePooling2D(),

    tf.keras.layers.Dense(units=64, activation='relu',
                           kernel_regularizer=tf.keras.regularizers.l2(0.0001)),
    tf.keras.layers.Dropout(0.4),
    tf.keras.layers.Dense(units=1, activation='sigmoid')

])

model.compile(
    optimizer=tf.keras.optimizers.Adagrad(learning_rate=0.0005),
    loss='binary_crossentropy',
    metrics=['accuracy', self.f1_score]
)
```

Рисунок 3.2 – Архітектура базової згорткової нейронної мережі

Ця модель є відправною точкою для подальших експериментів із її покращенням, зокрема — через зміну структури фільтрів та застосування розвідкового аналізу.

3.3.2 Результати навчання та оцінка ефективності базової мережі

На першому етапі розробки системи діагностики ПТСР була реалізована базова згортова нейронна мережа, опис архітектури якої наведено у попередньому підрозділі. Ця модель виступала відправною точкою для подальших експериментів з оптимізації структури мережі та обробки вхідних BOLD-сигналів. Основною метою побудови базової архітектури було перевірити працездатність підходу до двоканального представлення функціональних зв'язків у мозку та визначити початковий рівень якості класифікації наявних даних.

Навчання моделі проводилося з використанням оптимізатора Adagrad та функції втрат `binary_crossentropy`, що є стандартним вибором для задач двокласової класифікації. У процесі тренування спостерігалось поступове зниження функції втрат, однак воно супроводжувалось значними коливаннями в метриках точності, що вказує на нестабільність моделі.

Після завершення навчання було отримано наступні результати на тестовому наборі даних:

- точність (accuracy) — 50%;
- чутливість (recall) — 1.0;
- специфічність (precision) — 0.5;
- F1-міра — 0.667.

Аналіз метрик показує, що хоча модель здатна правильно виявляти всі випадки ПТСР (recall = 1.0), її здатність розрізняти хворих та здорових є низькою (precision = 0.5). Це означає, що модель класифікує всіх пацієнтів як хворих, що призводить до великої кількості хибнопозитивних результатів. Така поведінка характерна для моделей, які зіштовхуються з класовим дисбалансом або відсутністю виражених ознак у вибірці здорових.

Графік функції втрат (рис. 3.3) демонструє поступове зменшення помилки на тренувальному наборі, однак на валідаційному наборі крива втрат залишається вищою та менш стабільною. Така поведінка є типовим індикатором перенавчання: модель добре запам'ятовує тренувальні дані, але не здатна узагальнювати закономірності на нові приклади.




Рисунок 3.3 — Графік функції втрат

3.4 Оптимізація архітектури

3.4.1 Застосування прямокутних фільтрів і підбору параметрів

Базова версія згорткової нейронної мережі, розроблена на початковому етапі дослідження, дозволила перевірити загальну працездатність підходу, однак виявила низку обмежень, які унеможливлювали досягнення бажаних показників точності. Аналіз динаміки навчання продемонстрував, що модель схильна до перенавчання, нестійка до флуктуацій метрик та, ймовірно, не

здатна захоплювати глибинні просторові закономірності у структурі вхідних даних.

Оскільки у цій роботі вхідні дані подаються у вигляді двоканального тензора розміром (164, 164, 2), що включає дві матриці — коефіцієнтів кореляції між регіонами мозку та параметрів лінійних моделей першого порядку — було запропоновано новий підхід до обробки такої структури: застосування прямокутних фільтрів згортки. На відміну від класичних квадратних фільтрів (наприклад, 3×3 чи 5×5), які симетрично обробляють локальні ділянки у двох просторових вимірах одночасно, прямокутні фільтри (1×164 та 164×1) дозволяють виділити й проаналізувати ознаки вздовж одного виміру, ігноруючи вплив другого. Така операція є надзвичайно корисною при роботі з матрицями, де один вимір репрезентує набір мозкових регіонів, а інший — їхні взаємозв'язки.

Перший згортковий шар у новій архітектурі використовує ядро розміром (1×164). Це означає, що кожен фільтр ковзає горизонтально вздовж всієї ширини матриці, охоплюючи інформацію по всіх регіонах мозку одночасно, але в межах одного вертикального вікна. Такий підхід дозволяє фіксувати глобальні горизонтальні шаблони — наприклад, загальну активність певного набору регіонів у кожному ряді. Це можна інтерпретувати як аналіз локальних залежностей по осі "одної зони інтересу головного мозку — у контексті всієї карти його взаємодій".

Другий згортковий шар, навпаки, використовує фільтри розміром (164×1), що дозволяє аналізувати вертикальні залежності: як кожен стовпець (тобто певна взаємодія між регіонами) проявляється упродовж усіх регіонів мозку. Таким чином, поєднання цих двох фільтрів — горизонтального та вертикального — дає змогу моделі послідовно фокусуватися на обох основних напрямках просторової організації BOLD-сигналів, не спотворюючи статистичну структуру вхідних матриць.

Для забезпечення гнучкості та контролю за складністю моделі було додано шари нормалізації (BatchNormalization) та регуляризації (Dropout), а

також щільні шари з активацією LeakyReLU, що краще справляється з мікроактиваціями у BOLD-сигналах порівняно зі звичайною ReLU.

Ще одним важливим елементом оптимізації стала автоматична настройка гіперпараметрів за допомогою бібліотеки Keras Tuner, яка дозволила протестувати широкий спектр значень для кількості фільтрів, нейронів у щільних шарах, dropout-коефіцієнтів та швидкості навчання. Це дало змогу уникнути суб'єктивного ручного підбору архітектури та підвищити шанси знайти конфігурацію, яка найкраще узгоджується з наявними даними.

У результаті сформована модель, побудована на основі перехресних прямокутних фільтрів, продемонструвала покращену стабільність метрик під час тренування, меншу різницю між тренувальними та валідаційними показниками, а також кращу здатність до узагальнення, що свідчить про її адаптацію до складної просторової структури BOLD-сигналів.

Таким чином, впровадження архітектури з прямокутними фільтрами стало критичним етапом в еволюції моделі — від простої CNN до структурно обґрунтованої моделі, чутливої до функціональної організації мозку. Це дало підґрунтя для подальших експериментів, зокрема — застосування розвідкового аналізу та побудови інтерпретованих діагностичних рішень на основі відібраних ознак.

3.4.2 Аналіз ефективності оновленої моделі

У процесі оптимізації структури згорткової нейронної мережі було здійснено заміну традиційних квадратних фільтрів на прямокутні: з ядрами розміром (1×164) та (164×1) . Такий підхід дозволив моделі фокусуватись на виявленні горизонтальних і вертикальних закономірностей у матрицях функціональної зв'язності, які подаються на вхід у вигляді двоканального тензора. З урахуванням специфіки BOLD-сигналів, що мають складну просторову структуру, застосування прямокутних фільтрів стало доцільним кроком для покращення здатності моделі виявляти латентні зв'язки між регіонами мозку.

Після внесення архітектурних змін було проведено навчання моделі із

використанням механізму ранньої зупинки. На 15-й епосі спостерігалось найнижче значення функції втрат на валідаційному наборі — приблизно 0.68, після чого крива почала демонструвати ознаки перенавчання. Тренувальна крива знижувалася більш стабільно, але без критичного розриву між тренувальним і валідаційним loss, що свідчить про достатньо збалансований характер навчання. Повна динаміка втрат представлена на рис. 3.4.




Рисунок 3.4 — Графік функції втрат

Після завершення навчання модель була протестована на окремій тестовій вибірці, що включала 10 пацієнтів: 5 здорових та 5 з діагнозом ПТСР. За результатами цього тестування було отримано такі метрики:

- точність (Accuracy): 0.66;
- специфічність (Precision): 0.67;
- чутливість (Recall): 0.40;
- F1-міра: ≈ 0.50 .

Отримані результати свідчать про те, що модель набула більш обережного стилю класифікації: вона рідше видає хибнопозитивні відповіді, однак значна частина пацієнтів із ПТСР залишаються невиявленими. Це підтверджує зниження recall до 0.40 при збереженні помірно високого precision. Матриця помилок підтверджує цей висновок: з 5 хворих лише 2 були правильно ідентифіковані, а серед здорових 4 класифіковані вірно, ще 1 — хибно.

Хоча використання прямокутних фільтрів дозволило досягти стабільнішого навчання та покращення загальної точності, зниження recall вказує на необхідність подальшої оптимізації, зокрема шляхом відбору інформативних ознак та адаптації класифікаційної частини мережі. Саме цим питанням присвячено наступний етап — реалізацію розвідкового аналізу.

3.5 Розвідковий аналіз

3.5.1 Реалізація методу розвідкового аналізу

Розвідковий аналіз у цій роботі був реалізований як окремий етап із метою зменшення розмірності ознак, що надходять після згорткових та згладжувальних (flatten) шарів нейронної мережі. Такий підхід дозволив не лише скоротити кількість вхідних параметрів для класифікації, а й визначити найбільш інформативні з них, що сприяло підвищенню як точності, так і інтерпретованості моделі.

Після застосування шару Flatten до двоканального вхідного тензора (що містить інформацію про мозкові зв'язки), було сформовано вектор ознак, що агрегував просторову інформацію із попередніх згорткових операцій. Саме цей вектор став основою для подальшої селекції ознак.

3.5.1.1 Первинна селекція ознак

У першій фазі аналізу було застосовано статистичний метод відбору ознак, що дозволив відібрати 28 найінформативніших компонентів із повного простору Flatten-векторів. Відбір базувався на індексах найбільш варіативних і класифікаційно релевантних компонентів за результатами попередніх

тренувань. Це дозволило значно зменшити кількість ознак, що подавалися на вхід логістичної моделі, при цьому не втрачаючи суттєвої інформації.

3.5.1.2 Класифікація на основі бінарних логістичних регресій

На наступному етапі було проведено серію класифікаційних експериментів із використанням бінарної логістичної регресії, яка виконувалась послідовно на комбінаціях ознак. Зокрема:

- спочатку класифікацію здійснювали лише на 2 обраних ознаках;
- потім до них поступово додавалися інші ознаки, і повторно проводився аналіз;
- процес повторювався до використання усіх 28 відібраних ознак.

Кожна ітерація давала змогу оцінити якість класифікації при певній кількості ознак. За результатами такого поступового аналізу було виявлено, що найкращі метрики класифікації (F1-міра, точність, recall) досягаються при використанні 14 ознак. Саме ця кількість була обрана як оптимальна для подальшого використання у згортковій нейронній мережі.

3.5.1.3 Інтеграція відібраних ознак у нейронну мережу

Після завершення розвідкового аналізу та визначення індексів 14 ключових ознак, було реалізовано кастомний підхід до їх інтеграції у модель. Зокрема, створено спеціальний клас-обгортку, який:

- приймає на вхід вектор Flatten-ознак;
- відбирає 14 компонентів за заздалегідь визначеними індексами;
- виконує попередньо визначені математичні операції між парами ознак, виявленими логістичною регресією.

У результаті формується новий вектор ознак, що вже включає трансформовані зв'язки між ключовими характеристиками, що виявили себе як найінформативніші під час розвідкового аналізу.

3.5.1.4 Завершення архітектури моделі

Після вибору та трансформації 14 ознак модель повертається до класичної глибокої архітектури на базі щільних (Dense) шарів, що

відповідають за остаточну класифікацію (рис. 3.5).

```
x = Dense(units=32, activation="leaky_relu")(x)
x = Dropout(0.2)(x)

x = Dense(units=16, activation="leaky_relu")(x)
x = Dropout(0.1)(x)
outputs = Dense(1, activation="sigmoid")(x)
```

Рисунок 3.5 — Щільні шари мережі

3.5.1.5 Остаточна архітектура моделі

Остаточна структура моделі поєднує згорткову частину з прямокутними фільтрами, етап розвідкового аналізу ознак у вигляді кастомного шару та класичні щільні (Dense) шари для фінальної класифікації. На вхід модель отримує тензор розміром (164, 164, 2), що містить двоканальні матриці функціональної зв'язності. Після початкової нормалізації даних відбувається обробка згортковими шарами, які мають прямокутні фільтри — спочатку з ядром (1×164), що аналізує горизонтальні зв'язки, а потім з ядром (164×1), що виявляє вертикальні залежності. Обидва згорткові шари супроводжуються нормалізацією та Dropout-регуляризациєю.

Після згорткових шарів тензор переходить у плоский вектор за допомогою шару Flatten. На цьому етапі вектор передається в спеціальний користувацький шар CustomFeatureLayer, який реалізує результати розвідкового аналізу: відбирає 14 найбільш інформативних ознак за фіксованими індексами та виконує над ними математичні операції, зокрема обчислення відношень між певними парами ознак (наприклад, x_4/x_5 , x_{10}/x_2 , x_{13}/x_9 та інші), які виявилися найбільш ефективними під час логістичної регресії.

Після цього новий вектор ознак передається до класифікаційної частини моделі, яка складається з двох щільних шарів з активацією leaky ReLU, кожен з яких супроводжується Dropout, та фінального шару з активацією sigmoid, що

виконує бінарну класифікацію — визначає наявність або відсутність посттравматичного стресового розладу. Уся модель зображена на рис. 3.6.

```

3 inputs = Input(shape=(164, 164, 2))
4
5 x = normalizer(inputs)
6
7 x = Conv2D(filters=64, kernel_size=(1, 164), activation="leaky_relu")(x)
8 x = BatchNormalization()(x)
9 x = Dropout(0.2)(x)
10
11 x = Conv2D(filters=64, kernel_size=(164, 1), activation="leaky_relu")(x)
12 x = BatchNormalization()(x)
13 x = Dropout(0.2)(x)
14
15 x = Flatten(name="flatten")(x)
16 x = CustomFeatureLayer()(x)
17
18 x = Dense(units=32, activation="leaky_relu")(x)
19 x = Dropout(0.2)(x)
20
21 x = Dense(units=16, activation="leaky_relu")(x)
22 x = Dropout(0.1)(x)
23 outputs = Dense(1, activation="sigmoid")(x)

```

Рисунок 3.6 – Остаточна архітектура моделі

3.5.2 Результати моделі з урахуванням відібраних ознак

Після впровадження розвідкового аналізу ознак у структуру нейронної мережі було виконано повторне навчання моделі з урахуванням лише найбільш інформативних характеристик, виявлених у попередньому етапі. Як було описано у підрозділі 4.5.1, до подальшої обробки були допущені лише 14 ознак, обраних із вектору, сформованого після шару Flatten. Додатково в CustomFeatureLayer було реалізовано обчислення відношень між деякими парами ознак, що відповідали найкращим комбінаціям, визначеним під час тестування логістичних класифікаторів. Це дозволило не лише зменшити розмірність простору ознак, а й підвищити його інформативність за рахунок

включення емпірично значущих взаємозв'язків.

Навчання оновленої моделі також здійснювалося із використанням стратегії ранньої зупинки. Найменше значення валідаційної функції втрат було досягнуто на 16-й епосі й склало приблизно 0.68. Після цієї точки крива втрат на валідаційній вибірці почала поступово зростати, що свідчить про досягнення оптимального стану узагальнення (рис. 3.7). Варто зазначити, що крива втрат на тренувальному наборі залишалась нижчою, але динаміка обох кривих була загалом узгодженою, що вказує на стабільність навчання та помірну складність моделі.



Рисунок 3.7 – Графік функції втрат

За результатами тестування на незалежному наборі з 10 пацієнтів (5 здорових та 5 з ПТСР) модель з урахуванням відібраних ознак продемонструвала покращення загальних показників. Зокрема, точність класифікації підвищилась до 70%, що на 4% вище порівняно з попереднім

етапом. Оцінки інших метрик також підтверджують зростання ефективності моделі:

- точність (Accuracy): 0.70;
- специфічність (Precision): 0.75;
- чутливість (Recall): 0.60;
- F1-міра: ≈ 0.67 .

Аналіз матриці невідповідностей показав, що модель правильно класифікувала 3 з 5 пацієнтів з ПТСР ($TP = 3$) та 4 з 5 здорових ($TN = 4$), що свідчить про покращення збалансованості класифікації. Водночас два хворих були класифіковані як здорові ($FN = 2$), а один здоровий — хибно визначений як пацієнт з ПТСР ($FP = 1$). Така конфігурація є цілком прийнятною для задачі попереднього скринінгу психічного стану пацієнтів, де важливо як уникати пропусків, так і обмежувати кількість хибних результатів.

Отримані результати демонструють, що застосування розвідкового аналізу дозволило суттєво підвищити ефективність класифікації без ускладнення архітектури мережі. Таким чином, інтеграція методів селекції ознак у структуру згорткової моделі підтвердила свою доцільність у контексті задачі діагностики ПТСР за BOLD-сигналами.

3.6 Розрахунок економічного ефекту

У цьому розділі було розглянуто економічну доцільність створення програмного забезпечення для діагностики посттравматичного стресового розладу на основі аналізу BOLD-сигналів із використанням згорткових нейронних мереж. Розробка подібної системи вимагає не лише технічного обґрунтування, а й аналізу її вартості, трудомісткості й ефективності з урахуванням можливих варіантів реалізації.

На початковому етапі було визначено ключові функції, від яких

залежить якість та функціональність майбутнього програмного продукту. Серед них — мова програмування, інструменти для побудови моделі глибокого навчання, а також методи оцінювання точності класифікації. Кожна з цих функцій має кілька варіантів реалізації, що дозволяє створити декілька комбінацій архітектури системи. Для систематизації можливих рішень було побудовано морфологічну карту, яка демонструє всі розглянуті варіанти (рис. 3.8).




Рисунок 3.8 – Морфологічна карта реалізації основних функцій системи

Аналізуючи карту, було порівняно сильні та слабкі сторони кожного з варіантів. Python виявився найкращим серед мов програмування завдяки своїй простоті, швидкості розробки й наявності великої кількості бібліотек. У випадку з бібліотеками для глибокого навчання найбільш збалансованим виявився TensorFlow/Keras — він забезпечує високу гнучкість, GPU-підтримку та стабільність роботи. Для оцінювання точності класифікації було

обрано спеціалізовані метрики, які дозволяють виявляти сильні й слабкі сторони моделі набагато точніше, ніж загальні універсальні показники або експертна верифікація.

Після обрання конкретної конфігурації системи було проведено економічні розрахунки. Вони охоплювали визначення трудомісткості етапів розробки, розрахунок заробітної плати залучених фахівців, у тому числі програміста й консультанта з медичним досвідом, а також оцінку витрат на машинний час, електроенергію, амортизацію техніки та супутні експлуатаційні витрати. Вартість однієї машино-години була визначена з урахуванням усіх зазначених чинників, включно з відрахуваннями на соціальне страхування та накладними витратами. Остаточна собівартість реалізації першого варіанту програмного продукту склала приблизно 657 812.42 грн.

Проведений аналіз показав, що обраний варіант із використанням Python, TensorFlow/Keras і спеціальних метрик не лише забезпечує найвищий технічний рівень, а й є економічно обґрунтованим. Він дозволяє досягти високої точності класифікації при мінімальних затратах ресурсів. Така реалізація демонструє оптимальне співвідношення ефективності та вартості, а отже, є доцільною для подальшого впровадження у практику клінічної діагностики.

Висновок до розділу 3

У цьому розділі було реалізовано повний процес побудови та вдосконалення нейронної мережі для задачі класифікації BOLD-сигналів при діагностиці ПТСР. Базова модель продемонструвала обмежену ефективність, зокрема високий рівень recall при недостатній точності, що свідчило про потребу в подальшій оптимізації. Застосування модифікованих фільтрів та методів селекції ознак дозволило підвищити збалансованість моделі: точність класифікації досягла 70 %, а значення F1-міри наблизилось до 0.57, що є

прийнятним результатом з огляду на обмежений обсяг тестової вибірки. Візуалізація функції втрат підтвердила покращення узагальнювальної здатності моделі та ефективність використаних підходів. У підсумку доведено доцільність інтеграції структурного аналізу BOLD-даних із глибинними нейронними мережами в рамках клінічної задачі.

РОЗДІЛ 4

УЗАГАЛЬНЕННЯ РЕЗУЛЬТАТІВ РОБОТИ

У даному розділі узагальнюються основні результати, отримані в процесі побудови, навчання та тестування моделі для діагностики ПТСР, а саме: описано архітектуру запропонованої згорткової нейронної мережі, її особливості та вдосконалення, які покращили якість класифікації; проаналізовано, як змінювалися ключові метрики на кожному етапі розробки моделі; представлено порівняння розробленої системи з традиційними методами діагностики та іншими алгоритмами машинного навчання. Це дозволяє оцінити, наскільки ефективною та конкурентною є побудована модель на фоні існуючих підходів.

4.1 Опис архітектури та особливості побудованої моделі

У рамках даної роботи було реалізовано згорткову нейронну мережу, адаптовану під специфіку BOLD-сигналів, отриманих з функціональної МРТ. Основною метою побудови моделі було не лише забезпечити високу точність класифікації, а й досягти певної інтерпретованості та гнучкості при роботі з різними пацієнтами.

Архітектура моделі побудована за принципами класичних CNN, однак зазнала низки модифікацій, продиктованих природою вхідних даних. На вхід мережа отримує матриці, що відображають просторово-часову активність мозкових ділянок у вигляді BOLD-сигналів. Для того, щоб краще врахувати цю специфіку, було впроваджено прямокутні згорткові фільтри (наприклад, 1×164 , 164×1), які дозволяють виявляти просторові закономірності уздовж певних анатомічних напрямків мозку. Такий підхід виявився ефективним для збереження топологічних зв'язків між зонами активності.

Модель включає декілька послідовних блоків:

- згорткові шари з нелінійністю ReLU для виділення просторових ознак;
- пулінгові шари (max pooling), що зменшують розмірність і виділяють найбільш виразні патерни;
- шар нормалізації (Batch Normalization) для стабілізації навчання;
- операція Flatten для переходу до векторного представлення;
- додатковий модуль розвідкового аналізу ознак, який дозволяє обрати найбільш інформативні компоненти з отриманого вектору.

Однією з ключових інновацій моделі є інтеграція методу селекції ознак після Flatten-шару. Замість подачі всього вектора активацій у повнозв'язний шар, було реалізовано відбір підмножини найбільш релевантних ознак на основі їхнього внеску у розподіл класів. Це дозволило зменшити обсяг зайвих обчислень та уникнути перенавчання.

Кінцева частина моделі складається з одного або двох повнозв'язних шарів, що виконують класифікацію. Для бінарного поділу («ПТСР» / «контроль») на виході використано функцію активації sigmoid. Навчання відбувалося з використанням функції втрат binary crossentropy та оптимізатора Adam.

Для підвищення узагальнюючої здатності мережі були застосовані техніки dropout і ранньої зупинки (early stopping), що дозволили уникнути перенавчання на обмеженій вибірці.

4.2 Аналіз отриманих метрик класифікації

Оцінювання побудованих моделей здійснювалося за чотирма основними метриками: точність, чутливість, специфічність та F1-міра. Усі значення розраховано на незалежній тестовій вибірці, що дозволяє об'єктивно порівняти ефективність різних архітектур. Результати наведено в табл. 4.1.

Таблиця 4.1

Порівняння якості класифікації

Архітектура моделі	Точність	Чутливість	Специфічність	F1-міра
Базова нейронна мережа	0.50	1.0	0.5	0.667
Оптимізована нейронна мережа	0.66	0.4	0.67	0.5
Оптимізована нейронна мережа з розвідковим аналізом	0.7	0.6	0.75	0.67

На основі вище наведених метрик, можна дійти висновку, що кожен наступний етап покращення архітектури моделі призводив до зростання якості класифікації.

Базова модель, побудована без урахування специфіки структури сигналів, показала максимальну чутливість (1.0), але при цьому мала дуже низьку загальну точність (0.50) та специфічність (0.50). Тобто вона виявляла майже всі випадки ПТСР, але при цьому часто помилялася у класифікації здорових пацієнтів.

Оптимізована модель, де були використані прямокутні згорткові фільтри та налаштовані гіперпараметри, значно покращила точність (до 0.66) і специфічність (до 0.67), що свідчить про більш точне розмежування класів. Проте чутливість знизилася (0.40), що вказувало на часткову втрату здатності виявляти всі випадки ПТСР.

Найкращі результати досягнуті після інтеграції розвідкового аналізу ознак. Завдяки ретельному відбору найбільш інформативних компонентів після Flatten-шару вдалося збалансувати модель: точність зросла до 0.70, специфічність — до 0.75, а чутливість — до 0.60. При цьому F1-міра також покращилася порівняно з попередньою версією і досягла рівня базової моделі,

але вже за умов кращого балансу між позитивними і негативними класами.

Отже, результати чітко демонструють, що послідовне вдосконалення архітектури — від базової згорткової нейронної мережі до моделі з розвідковим аналізом — дало змогу суттєво підвищити загальну ефективність класифікації. Кожен новий етап покращував якість системи: спочатку — за рахунок кращої архітектури, потім — за рахунок використання більш інформативних ознак після згорткових шарів. Отже, побудована модель не лише є ефективною, але й підтверджує, що гібридний підхід із поетапною оптимізацією є дієвим у задачах медичної діагностики на основі BOLD-сигналів.

4.3 Порівняння обраної нейронної мережі з аналогами

Класичні методи діагностики ПТСР, зокрема опитувальники PCL-5, IES-R та структуровані інтерв'ю CAPS-5, зарекомендували себе як широко застосовувані інструменти в клінічній практиці. Їх перевага полягає у високій стандартизації, доступності та простоті використання. Проте, вони значною мірою покладаються на суб'єктивні відповіді пацієнта та клінічну інтерпретацію фахівця. У ряді випадків це може призводити до недооцінки симптомів, особливо коли пацієнт не готовий або не здатен відверто говорити про свій стан.

Розроблена модель на основі CNN працює з об'єктивними нейрофізіологічними даними, зокрема BOLD-сигналами з фМРТ, що відображають реальні зміни у функціонуванні мозку. Це забезпечує незалежність діагностики від суб'єктивних факторів та відкриває можливості для виявлення ПТСР навіть у тих пацієнтів, які не демонструють класичної симптоматики або свідомо її приховують. Такий підхід є перспективним доповненням до клінічних методів, особливо в складних або сумнівних випадках.

Методи структурної (МРТ, DTI) та функціональної (фМРТ, PET/SPECT)

нейровізуалізації широко використовуються у дослідженнях ПТСР. Вони дозволяють виявляти як анатомічні зміни, так і порушення функціональної активності мозку. Проте класичний аналіз таких даних часто передбачає ручне виділення регіонів інтересу (ROI), побудову моделей першого рівня, зведення сигналів до середніх значень у масках тощо. Це вимагає експертної участі та значного часу.

Розроблена в дипломній роботі система автоматично обробляє дві повноформатні матриці зв'язності, які відображають як симетричні, так і напрямні взаємозв'язки між регіонами мозку. Модель сприймає їх як двоканальний вхід, подібно до зображень із кількома каналами, що дозволяє їй зберігати просторово-логічні взаємозв'язки між регіонами.

Таким чином, порівняно з класичними фМРТ-підходами, запропонована система є менш залежною від ручних налаштувань і припущень, що робить її більш масштабованою та зручною для автоматизованого використання.

У попередніх дослідженнях для діагностики ПТСР застосовувалися такі алгоритми, як метод опорних векторів (SVM), випадкові ліси (Random Forest), логістична регресія та інші статистичні моделі. Їх основною перевагою є швидкість обчислень і відносна прозорість результатів. Проте, для досягнення високої точності ці алгоритми вимагають ретельного ручного відбору ознак (feature engineering), що у випадку з нейровізуалізацією є нетривіальним завданням.

Висновок до розділу 4

У даному розділі було проведено всебічний аналіз побудованої діагностичної системи на основі згорткової нейронної мережі для виявлення посттравматичного стресового розладу за BOLD-сигналами фМРТ. Було детально розглянуто архітектуру моделі, особливості її побудови, результати оцінювання точності класифікації та порівняння з існуючими аналогами.

Розроблена модель продемонструвала, що поетапне вдосконалення архітектури дозволяє суттєво підвищити якість класифікації: кожен новий етап — від базової архітектури до інтеграції розвідкового аналізу ознак — забезпечував покращення показників точності, специфічності та F1-міри. Найкраща версія моделі досягла збалансованих результатів, що робить її перспективною для використання у реальних діагностичних сценаріях.

Порівняння з традиційними клінічними методами показало, що запропонована система має значну перевагу в об'єктивності та здатності працювати незалежно від людського чинника. У порівнянні з класичними методами нейровізуалізації та алгоритмами машинного навчання, запропонована нейронна мережа демонструє кращу гнучкість і здатність виявляти складні просторово-часові патерни.

Отже, отримані результати підтверджують доцільність застосування глибоких моделей у задачах діагностики психічних розладів. Запропонована архітектура може стати початком для створення більш складних систем у майбутньому.

ЗАГАЛЬНІ ВИСНОВКИ

У межах цієї роботи здійснено комплексне дослідження можливості використання згорткових нейронних мереж для виявлення посттравматичного стресового розладу (ПТСР) на основі аналізу BOLD-сигналів, отриманих із функціональної МРТ. Робота поєднала теоретичний аналіз, технічну реалізацію та експериментальну перевірку результатів. Основна мета — побудувати ефективний підхід до автоматизованої діагностики ПТСР — була досягнута.

На початковому етапі було проведено огляд сучасних клінічних і технічних методів діагностики. Зокрема, розглянуто традиційні інтерв'ю, структурну та функціональну нейровізуалізацію, а також сучасні підходи на основі штучного інтелекту. Виявлено, що BOLD-сигнал — це потужне джерело інформації про функціональний стан мозку, яке, при правильному аналізі, може дати цінні діагностичні ознаки.

Одним із ключових досягнень роботи стало налаштування архітектури згорткової нейронної мережі з урахуванням особливостей просторово-часових даних. Замість класичних квадратних фільтрів було використано прямокутні, що дозволило краще захопити характерну структуру BOLD-сигналів. Цей підхід дав змогу мережі більш точно вловлювати відмінності між сигналами пацієнтів із ПТСР та контрольної групи.

Окремо слід відзначити впровадження розвідкового аналізу на етапі після Flatten-шару. Це дало можливість виділити найбільш інформативні ознаки, зменшити обсяг непотрібних параметрів і знизити ризик перенавчання. Завдяки цьому підхід став не тільки точнішим, а й більш інтерпретованим, що особливо важливо в медицині.

Ключові метрики — точність, чутливість, F1-міра — показали, що модель здатна відтворювати складні закономірності в даних і робити корисні діагностичні висновки.

Всі поставлені завдання були виконані. Було підтверджено, що поєднання fMRI-даних і методів глибокого навчання відкриває нові можливості для точнішої, об'єктивнішої і персоналізованої діагностики психічних розладів, зокрема ПТСР.

Надалі логічним кроком буде перевірка моделі на нових вибірках, її адаптація під клінічні умови та можлива інтеграція з іншими джерелами медичних даних — наприклад, електронними картками чи психометричними шкалами. Це дозволить ще більше наблизити такі системи до реального впровадження в практику.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Artificial intelligence in medicine / A. Ramesh et al. *Annals of the royal college of surgeons of england*. 2004. Vol. 86, no. 5. P. 334–338. URL: <https://doi.org/10.1308/147870804290>
2. Ayeni J. A. Convolutional Neural Network (CNN): the architecture and applications. *Applied journal of physical science*. 2022. Vol. 4, no. 4. P. 42–50. URL: <https://doi.org/10.31248/ajps2022.085>
3. Bondjers K., Willebrand M., Arnberg F. K. Similarity in symptom patterns of posttraumatic stress among disaster-survivors: a three-step latent profile analysis. *European journal of psychotraumatology*. 2018. Vol. 9, no. 1. P. 1546083. URL: <https://doi.org/10.1080/20008198.2018.1546083>
4. Clark B. What is Scikit-Learn (Sklearn)? | IBM. *IBM - United States*. URL: <https://www.ibm.com/think/topics/scikit-learn>
5. Cohen D. J., Cicchetti D. Developmental psychopathology, volume 2: developmental neuroscience. Wiley & Sons, Incorporated, John, 2015. (pp.656- 676)
6. Current status and future directions of artificial intelligence in post-traumatic stress disorder: a literature measurement analysis / R. Wan et al. *Behavioral sciences*. 2024. Vol. 15, no. 1. P. 27. URL: <https://doi.org/10.3390/bs15010027>
7. Deep learning method for malaria parasite evaluation from microscopic blood smear / A. Dahiya et al. *Artificial intelligence in medicine*. 2025. Vol. 163. P. 103114. URL: <https://doi.org/10.1016/j.artmed.2025.103114>
8. Determining Predictors for Patient Diagnosis with PTSD using the Parameters of One-Dimensional First-Order Models for BOLD Signals from Brain Structures and GMDH / E. I. Aliiev et al. *Control systems and computers*. 2024. No. 3 (307). P. 60–67. URL: <https://doi.org/10.15407/csc.2024.03.060>
9. Diffusion tensor imaging traumatic brain injury - woodard kendall lehmkuhl rennie, LLP. *Woodard Kendall Lehmkuhl Rennie, LLP*.

URL: <https://www.wkrlaw.com/blog/diffusion-tensor-imaging-traumatic-brain-injury>

10. Editorial board. *Artificial intelligence in medicine*. 2025. Vol. 163. P. 103120.
URL: [https://doi.org/10.1016/s0933-3657\(25\)00055-7](https://doi.org/10.1016/s0933-3657(25)00055-7)
11. Hillman E. M. C. Coupling mechanism and significance of the BOLD signal: a status report. *Annual review of neuroscience*. 2014. Vol. 37, no. 1. P. 161–181.
URL: <https://doi.org/10.1146/annurev-neuro-071013-014111>
12. Hinojosa C. A., George G. C., Ben-Zion Z. Neuroimaging of posttraumatic stress disorder in adults and youth: progress over the last decade on three leading questions of the field. *Molecular psychiatry*. 2024.
URL: <https://doi.org/10.1038/s41380-024-02558-w>
13. IBM. What are convolutional neural networks? | IBM. *IBM - United States*.
URL: <https://www.ibm.com/think/topics/convolutional-neural-networks>
14. Introduction to Matplotlib - GeeksforGeeks. *GeeksforGeeks*.
URL: <https://www.geeksforgeeks.org/python-introduction-matplotlib/>
15. Multiclass classifier based on binary logistic regressions obtained according to the principles of GMDH / O. V. Radchenko et al. *Control systems and computers*. 2023. No. 3 (303). P. 24–32.
URL: <https://doi.org/10.15407/csc.2023.03.024>
16. Neuroimaging in post-traumatic stress disorder (PTSD): a narrative review / I. Stoklosa et al. *Archives of medical science*. 2024.
URL: <https://doi.org/10.5114/aoms/188377>
17. Nichols J. A., Herbert Chan H. W., Baker M. A. B. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical reviews*. 2018. Vol. 11, no. 1. P. 111–118.
URL: <https://doi.org/10.1007/s12551-018-0449-9>
18. O. Matviichuk, O. Davydko, O. Nosovets, V. Pavlov, M. Linnik, and I. Nastenکو, Class-Oriented Features Selection Technology in Medical Images Classification Problem on the Example of Distinguishing Between Tuberculosis Sensitive and Resistant Forms, 2021

19. Papers with code - max pooling explained. *The latest in Machine Learning | Papers With Code*. URL: <https://paperswithcode.com/method/max-pooling>
20. Pedersen T. What is fmri? Uses, how it works, duration, and what to expect. *Psych Central*. URL: <https://psychcentral.com/lib/what-is-functional-magnetic-resonance-imaging-fmri>
21. Posttraumatic stress disorder (PTSD) prevalence: an umbrella review / A. Schincariol et al. *Psychological medicine*. 2024. P. 1–14. URL: <https://doi.org/10.1017/s0033291724002319>
22. Post-Traumatic stress disorder: evidence-based research for the third millennium / J. Iribarren et al. *Evidence-Based complementary and alternative medicine*. 2005. Vol. 2, no. 4. P. 503–512. URL: <https://doi.org/10.1093/ecam/neh127>
23. Revolutionizing healthcare: the role of artificial intelligence in clinical practice / S. A. Alowais et al. *BMC medical education*. 2023. Vol. 23, no. 1. URL: <https://doi.org/10.1186/s12909-023-04698-z>
24. Watkins L. E., Sprang K. R., Rothbaum B. O. Treating PTSD: a review of evidence-based psychotherapy interventions. *Frontiers in behavioral neuroscience*. 2018. Vol. 12. URL: <https://doi.org/10.3389/fnbeh.2018.00258>
25. What is python? Executive summary. *Python.org*. URL: <https://www.python.org/doc/essays/blurb/>

РЕАЛІЗАЦІЯ МАТЕРІАЛІВ ЗА ТЕМОЮ ДИПЛОМНОЇ РОБОТИ

Практичне значення одержаних результатів. Дипломна робота виконана згідно договору про співпрацю ДУ «Інститут педіатрії акушерства і гінекології імені академіка О. М. Лук'янової НАМН України» з НТТУ «Київський політехнічний інститут ім. Ігоря Сікорського» № Д/0002.01/3400.02/291/2023 від 27.10.2023 року на даних, наданих ДУ "Всеукраїнський центр материнства та дитинства НАМН України», результати роботи впроваджено у медичну практику.

Апробація результатів роботи. Не заплановано.

Публікації. Не заплановано.

«ЗАТВЕРДЖУЮ»
Заступник генерального директора
з наукової роботи ДУ «Всеукраїнський
центр материнства
та дитинства НАМН України»
доктор медичних наук Наталя ГОРБАНЬ

«15» травня 2025 р.

Акт

впровадження в практичну охорону здоров'я матеріалів наукових досліджень

Найменування пропозиції для провадження: «Система підтримки прийняття діагностичних рішень при посттравматичному стресовому розладі (ПТСР), наслідках травми (НТ) за даними фМРТ» у державній установі «Всеукраїнський центр материнства та дитинства НАМН України», розробленої згідно договору про співпрацю Д/0002.01/3400.02/291/2023 від 27.10.2023 року з НТТУ «Київський політехнічний інститут ім. Ігоря Сікорського»

Ким запропоновано:

ДУ «Всеукраїнський центр материнства та дитинства НАМН України», Тарасюк Б.А., Омельченко О.М., Дикан І.М., Закоморний О.С., НТТУ «Київський політехнічний інститут ім. Ігоря Сікорського», Алієв Е.І., Гайовський О.В., Павлов В.А., Пенковський Д.Ю., Михайленко С.А., Йовса Д. О., Разумовська І.В., Голєусов Е.К.

Джерело інформації:

1. Aliiev E., Omelchenk O., Tarasiuk B., Zakomorny O., Matviichuk O., Pavlov V. "Determining of Predictors for Diagnostic Conclusion for Patients with Post-Traumatic Stress Disorder Using Class-Oriented Features Selection Technology and Group Method of Data Handling", 2024 IEEE 19th International Conference on Computer Science and Information Technologies (CSIT), Conference Paper, Lviv, Ukraine, 16-19 October, 2024
2. Determining Predictors for Patient Diagnosis with PTSD using the Parameters of One-Dimensional First-Order Models for BOLD Signals from Brain Structures and GMDH / Aliiev E., Bovsunovskaya K., Dykan I., Omelchenko O., Mykhailenko S., Pavlov V. // *Control Systems and Computers Ukraine*, №3, October, 2024

Рекомендовано впровадити: «Система підтримки прийняття діагностичних рішень при посттравматичному стресовому розладі (ПТСР), наслідках травми (НТ) за даними фМРТ»

Строки впровадження: з січня 2025 року.

Результати впровадження : проведено дослідження 70 пацієнтів з травматичними ушкодженнями головного мозку (ПТСР). На основі обраних фМРТ критеріїв розроблена система диференціальної діагностики, яка дозволила з ефективністю 96-100% проводити визначення ПТСР / схильності до ПТСР у порівнянні з групою здорових осіб. Результати дослідження об'єктивізували клінічні прояви патології мозку при даній патології.

Пропозиції та зауваження відсутні

Старший науковий співробітник
зав.відділенням променевої діагностики
дітей та дорослих, доктор медичних наук



Б.А. Тарасюк

№ _____

ДОВІДКА

Надана ЙОВСІ Дар'ї Олександрівні студентці 4 курсу, гр БС-15 в тому що Вона виконувала тему дипломної роботи «Система діагностики посттравматичного стресового розладу на основі аналізу BOLD-сигналів засобами згорткових мереж» з використанням реальної бази лабораторних даних навчального закладу ДУ «Всеукраїнський центр материнства та дитинства НАМН України».

Дирекція ДУ «Всеукраїнський центр материнства та дитинства НАМН України» не заперечує в використанні даних в дипломній роботі ЙОВСИ Дар'ї Олександрівни та залишає за собою право використати результати дипломної роботи в роботі ДУ «Всеукраїнський центр материнства та дитинства НАМН України».

**Заступник генерального директора
з наукової роботи державної
установи «Всеукраїнський центр
материнства та дитинства НАМН
України»**



Наталія ГОРБАНЬ

МП

«__» травня 2025р.