

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Дослідження методів обчислювального інтелекту
для детекції аномалій на медичних зображеннях
(тема)

Виконав:
здобувач другого року навчання,
групи СШМ-23-1

Ірина Дерев'янку
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту
(повна назва освітньої програми)

Керівник доц. Олег Золотухін
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ _____
(підпис)

Олег ЗОЛОТУХІН
(власне ім'я, прізвище)

2025 р.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук _____

Кафедра _____ Штучного інтелекту _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 122 Комп'ютерні науки _____
(код і повна назва)

Тип програми _____ освітньо-наукова _____
(освітньо-професійна або освітньо-наукова)

Освітня програма _____ Системи штучного інтелекту _____
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
«_____» _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Дерев'янку Ірині Ігорівні _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Дослідження методів обчислювального інтелекту для детекції аномалій на медичних зображеннях _____

затверджена наказом університету від 21 квітня 2025 р. № 295Ст

2. Термін подання студентом роботи до екзаменаційної комісії 4 червня 2025 р.

3. Вихідні дані до роботи Науково-технічні публікації, Інтернет-джерела щодо інтелектуальних методів обробки медичних даних, алгоритмів детекції аномалій та доповнення даних, набір даних з платформи Kaggle, специфікація мови програмування Python з використанням фреймворку PyTorch навчання та бібліотек машинного навчання _____

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Аналіз предметної галузі і формалізація задачі _____

2) Теоретичне дослідження автокодувальних нейромережових методів для детекції аномалій _____

3) Теоретичне дослідження методів об'єктного детектування для пошуку аномалій _____

4) Експериментальні дослідження та оцінка ефективності розглянутих методів _____

РЕФЕРАТ

Пояснювальна записка: 82 с., 23 рис., 2 табл., 2 дод., 46 джерел.

АВТОКОДУВАЛЬНИК, ВАРІАЦІЙНИЙ АВТОКОДУВАЛЬНИК, ВИЯВЛЕННЯ АНОМАЛІЙ, МРТ, НЕКОНТРОЛЬОВАНЕ НАВЧАННЯ, ОБ'ЄКТНЕ ДЕТЕКТУВАННЯ, ПЕРЦЕПЦІЙНА ВТРАТА.

Об'єктом дослідження є процес автоматизованого виявлення аномалій на МРТ-зображеннях опорно-рухового апарату з використанням автокодувальних нейромереж.

Предметом дослідження є методи та архітектури автокодувальних нейромереж, інтегровані з детекцією об'єктів, для виявлення аномалій на МРТ-зображеннях опорно-рухового апарату.

Метою даної роботи є дослідження, реалізація та порівняльний аналіз архітектур автокодувальних нейромереж для вирішення задачі виявлення аномалій на прикладі набору даних захворювань опорно-рухової системи.

Методи дослідження – аналіз технічної літератури та новісних досліджень в сфері неконтрольованого навчання, експериментальний підбір архітектури та конфігурацій, порівняльний аналіз результатів. Використання мови Python та бібліотек PyTorch, scikit-learn.

У результаті виконання роботи було проведено аналіз предметної галузі, визначено проблеми та обмеження вирішення проблеми виявлення аномалій медичних даних. Було розроблено методологію виявлення аномалій на МРТ-зображеннях опорно-рухового апарату, що поєднує детекцію об'єктів з автокодувальними нейромережами. Було розроблено базовий автокодувальник, автокодувальник із перцепційною функцією втрат та варіаційний автокодувальник; проведено порівняльний аналіз розробленої системи обчислювального інтелекту із використанням набору даних дегенеративних захворювань поперекового відділу хребта.

ABSTRACT

Master's thesis contains: 82 pp., 23 fig., 2 tabl., 2 ann., 46 references.

ANOMALY DETECTION, AUTOENCODER, MRI, OBJECT DETECTION, PERCEPTUAL LOSS, UNSUPERVISED LEARNING, VARIATIONAL AUTOENCODER.

The object of the study is automated anomaly detection for MRI of the musculoskeletal system using autoencoders.

The subject of the study is methods and architectures of autoencoding neural networks integrated with object detection for detecting anomalies in MRI images of the musculoskeletal system.

The aim of the paper is to investigate, implement and comparatively analyze the architectures of auto-coding neural networks for solving the problem of anomaly detection. The dataset of diseases of the musculoskeletal system was considered as a demonstrative example.

The research methods consist in the analysis of technical literature and recent research in the field of unsupervised learning, experimental selection of architectures and configurations, comparative analysis of results. Python language and PyTorch library have been used.

As a result of the work, the subject area was analysed, the problems and limitations of solving the problem of medical data anomaly detection were identified. A methodology for detecting anomalies in MRI images of the musculoskeletal system was developed, combining object detection with autoencoding neural networks. A basic autoencoder, an autoencoder with a perceptual loss function, and a variational autoencoder were developed; a comparative analysis of the developed computational intelligence system was performed using a dataset of degenerative diseases of the lumbar spine.

ЗМІСТ

| | |
|---|----|
| Перелік умовних позначень, символів, одиниць, скорочень і термінів | 8 |
| Вступ..... | 9 |
| 1 Аналіз предметної галузі і формалізація задачі..... | 11 |
| 1.1 Аналіз предметної галузі..... | 11 |
| 1.1.1 Проблематика детекції аномалій методами ШП..... | 11 |
| 1.1.2 Обмеження детекції аномалій на медичних зображеннях | 13 |
| 1.2 Огляд і аналіз сучасних методів обчислювального інтелекту для обробки медичних зображеннях..... | 14 |
| 1.3 Актуальність та мета дослідження | 18 |
| 1.4 Постановка задачі..... | 19 |
| 2 Теоретичне дослідження автокодувальних нейромережових методів для детекції аномалій..... | 20 |
| 2.1 Визначення та архітектура автокодувальника..... | 20 |
| 2.2 Функції втрат на реконструкцію | 22 |
| 2.2.1 Середньоквадратична втрата | 22 |
| 2.2.2 Перцепційна втрата..... | 23 |
| 2.3 Регуляризація автокодувальника..... | 24 |
| 2.4 Варіаційні автокодувальники | 25 |
| 2.5 Пороговий підхід до детекції аномалій | 27 |
| 2.6 Метрики тестування та оцінки моделі реконструкції зображень | 30 |
| 3 Теоретичне дослідження методів об'єктного детектування для пошуку аномалій..... | 33 |
| 3.1 Застосування об'єктного детектування в медичній галузі | 33 |
| 3.2 Визначення та архітектура моделі uolo | 34 |
| 4 Експериментальні дослідження та оцінка ефективності розглянутих методів..... | 36 |
| 4.1 Попередня обробка, аналіз даних та визначення обмежень даних.... | 36 |
| 4.2 Запропонована методологія | 41 |

| | |
|---|----|
| 4.3 Обрані технології для реалізації | 43 |
| 4.4 Детектування хребців засобами yolo | 44 |
| 4.5 Імплементация автокодувальних нейромереж для виявлення аномалій хребців | 50 |
| 4.5.1 Розробка, реалізація базового автокодувальника | 50 |
| 4.5.2 Розробка, реалізація автокодувальника з перцепційною функцією втрат | 57 |
| 4.5.3 Розробка, реалізація варіаційного автокодувальника | 61 |
| 4.6 Тестування та порівняльний аналіз результатів | 65 |
| 4.7 Перспективи подальшого дослідження | 67 |
| Висновки | 68 |
| Перелік джерел посилання | 70 |
| Додаток А Програмний код | 77 |
| Додаток Б Відомість кваліфікаційної роботи | 82 |

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

MPT – магнітно-резонансна томографія;

ШІ – штучний інтелект;

Adam – Adaptive Moment Estimation – метод адаптивної оцінки моментів;

CNN – Convolutional Neural Network – згорткові нейронні мережі;

MAE – Mean Absolute Error – середня абсолютна помилка;

MSE – Mean Squared Error – середньоквадратична помилка;

PSNR – Peak Signal-to-Noise Ratio – пікове відношення сигнал-шум;

SSIM – Structural Similarity Index – індекс структурної подібності;

SVM – Support Vector Machine – методи опорних векторів;

VAE – Variational Autoencoder – варіаційний автокодувальник.

ВСТУП

У сучасному світі методи обчислювального інтелекту активно впроваджено у різні сфери людської діяльності. Медична галузь стрімко трансформується під впливом технологічного прогресу, відкриваючи нові можливості для діагностики, лікування та профілактики захворювань. У цьому контексті методи обчислювального інтелекту, зокрема машинне навчання та штучні нейронні мережі, відіграють ключову роль, надаючи можливість аналізувати такі медичні зображення, як скани рентгену, комп'ютерної та магнітно-резонансної томографії.

Захворювання опорно-рухового апарату є однією з основних причин болю, обмеження рухливості та інвалідності у сучасному світі. Виявлення аномалій з високою точністю та швидкістю є наразі однією з провідних та найскладніших задач при розробці інтелектуальних систем підтримки прийняття рішень у медичній галузі, вирішення якої відкриває шлях до значного покращення якості медичної допомоги та підвищення ефективності клінічних процесів.

Однак обробка медичних зображень характеризується низкою обмежень, що ускладнюють їхнє застосування в моделях штучного інтелекту. Одним із ключових викликів є обмеженість обсягу доступних даних. Порівняно з іншими галузями, де ШІ демонструє значні успіхи, медичні набори даних часто є відносно невеликими, особливо у випадках рідкісних захворювань або специфічних патологій. Іншою проблемою є притаманна медичним зображенням варіативність. Зображення можуть значно відрізнятися залежно від використовуваного обладнання, протоколів сканування, індивідуальних анатомічних особливостей пацієнтів та інших факторів. Застосування технік доповнення даних, стандартних для покращення продуктивності інтелектуальних моделей, також має обмеження у контексті медичних зображень. Також часто спостерігається дисбаланс між кількістю нормальних та аномальних прикладів у медичних

наборах даних. Аномальні приклади, що відображають патологічні стани, зазвичай є менш поширеними, ніж нормальні.

Враховуючи ці обмеження, розробка моделей обчислювального інтелекту для виявлення аномалій медичних зображень вимагає ретельного дослідження та застосування спеціалізованих підходів, спрямованих на забезпечення стійкості до варіативності даних та ефективної роботи з обмеженими обсягами даних.

Основною ідеєю даної роботи є дослідження використання методів обчислювального інтелекту з метою покращення процесу виявлення аномалій опорно-рухової системи з урахуванням обмежень даних.

У даній роботі буде проведено аналіз предметної галузі, визначено проблеми та обмеження вирішення проблеми виявлення аномалій медичних даних. Буде розроблено методологію виявлення аномалій на МРТ-зображеннях опорно-рухового апарату, що поєднує детекцію об'єктів засобами трансферного навчання під наглядом з неконтрольованим навчанням автокодувальних нейромереж. Буде розроблено базовий автокодувальник, автокодувальник із перцепційною функцією втрат та варіаційний автокодувальник та проведено порівняльний аналіз розробленої системи обчислювального інтелекту із використанням набору даних дегенеративних захворювань поперекового відділу хребта.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ І ФОРМАЛІЗАЦІЯ ЗАДАЧІ

1.1 Аналіз предметної галузі

1.1.1 Проблематика детекції аномалій методами ШІ

Виявлення аномалій – важлива задача в області машинного навчання та штучного інтелекту, яка полягає в ідентифікації відхилень або аномальних патернів у даних. Аномалії визначаються як відхилення, які значно відрізняються від більшості спостережень у даних і часто мають великий потенціал для інтерпретації в контексті небажаних подій, помилок або інших рідкісних явищ. Це також може означати, що дані, що містять аномалії, не підпадають під типовий або нормальний розподіл, що часто спостерігається у великих наборах даних [1].

Виявлення аномалій застосовується в різних сферах, таких як виявлення шахрайства, моніторинг безпеки, діагностика технічних неполадок, або виявлення рідкісних захворювань в медичних даних. Однак цей процес має низку проблем і викликів, які пов'язані зі специфікою та складністю даних.

По-перше, аномалії можуть бути різними за своєю природою. Іноді відхилення можуть бути корисними і навіть необхідними для виявлення небезпечних подій, таких як шахрайські транзакції або технічні поломки. Однак іноді аномалії можуть бути неважливими або навіть спричинені помилками збору даних. Тому чітке визначення, що є «нормальним», а що є «аномалією», є складним завданням, яке потребує контекстуального підходу. Аномалії можуть бути одноразовими (наприклад, одинична помилка) або системними (наприклад, постійні помилки в роботі сенсорів).

По-друге, зміни в даних (так званий дрейф даних) можуть значно ускладнити детекцію аномалій. Наприклад, в системах фінансових транзакцій можуть з'являтися нові методи шахрайства, що потребує

постійного оновлення моделей для збереження їх ефективності. Для адаптації моделей до нових даних необхідно застосовувати методи навчання на змінних даних [2].

Існує безліч методів для виявлення аномалій, таких як методи класифікації, кластеризації (наприклад, методи К-середніх, DBSCAN), методи на основі відстаней (наприклад, локальний фактор відхилення), а також методи глибинного навчання (наприклад, автоенкодера, генеративні моделі). Вибір найбільш підходящої моделі залежить від специфіки задачі та типу даних, що вимагає детального аналізу і тестування різних підходів [3].

Існують два основні підходи до вирішення цієї задачі: підхід з наглядом (supervised anomaly detection) і підхід без нагляду (unsupervised anomaly detection).

У підході з наглядом модель машинного навчання навчається на маркованих даних, де кожен спостережуваний елемент має мітку, що вказує на його приналежність до класу «нормальний» або «аномальний». Це дозволяє застосовувати традиційні методи класифікації, такі як методи опорних векторів (SVM), логістичну регресію, дерева рішень, а також нейронні мережі. Даний підхід вимагає наявності великої кількості маркованих даних, що може бути важким або недоцільним завданням для багатьох прикладних сфер. У більшості випадків аномалії складають дуже малу частину загального набору даних, що створює проблему для моделі, яка часто схильна до переважного прогнозування класу «нормальний», що може призвести до зниження загальної ефективності моделі.

У підході без нагляду модель працює з не маркованими даними і намагається виявити аномалії на основі їх відмінностей від більшості спостережень. Основна ідея полягає в тому, що аномальні дані значно відрізняються від нормальних, і це відхилення можна визначити через структуру чи патерни даних. Моделі без нагляду не мають чіткої мети, яка б вказувала на аномалії, і тому вони використовують методи кластеризації,

аналізу відстаней між спостереженнями, статистичні методи або автоенкодери.

Моделі без нагляду можуть працювати з не маркованими даними, що є значною перевагою у випадках, коли доступ до маркованих даних обмежений або неможливий. Однак, оскільки модель не має інформації про «правильність» класів, точність визначення аномалій часто є нижчою порівняно з підходом з наглядом. Для багатьох методів без нагляду, наприклад, для методів на основі відстаней, важливим є правильний вибір метрики, що може бути складним для деяких типів даних.

1.1.2 Обмеження детекції аномалій на медичних зображеннях

Відсутність збалансованих даних є однією з основних проблем у задачі детекції аномалій у медичних зображеннях. Аномальні випадки часто є рідкісними і складають невелику частину загального набору даних, що призводить до незбалансованості класів. Моделі, що навчаються на таких наборах даних, можуть мати тенденцію до переважного прогнозування нормальних зображень. Це веде до того, що модель може ігнорувати рідкісні аномалії, що є критично важливим у медичній діагностиці. Зниження чутливості до аномалій може призвести до хибних негативів, коли модель не виявляє патологічні зміни, що може мати серйозні наслідки для пацієнта.

Моделі можуть бути схильні до перенавчання на більшості нормальних даних, що також знижує їх здатність точно класифікувати аномальні зображення. Ця проблема є поширеною в завданнях, де наявність аномалій є рідкісною, що вимагає застосування спеціальних методів балансування класів, таких як підвибір негативних прикладів, доповнення даних або використання різних метрик для оцінки ефективності моделі. У свою чергу надмірна аугментація може призвести до нерелевантних результатів, адже аномалії в медичних зображеннях можуть бути дуже чутливими до змін, і навіть невеликі трансформації зображень можуть

істотно змінити їх структурні або морфологічні характеристики. Аномальні ознаки, такі як пухлини, інфільтрати чи інші патологічні утворення, можуть бути неадекватно відображені в результаті сильної аугментації. Це може призвести до втрати важливих ознак для їх правильної ідентифікації.

Шум на медичних зображеннях є ще однією серйозною проблемою, яка знижує точність моделей ШІ. Шум може виникати через різноманітні фактори, включаючи обмеження обладнання (наприклад, низька роздільна здатність сканерів), помилки при знятті зображень або технічні дефекти під час обробки даних. Шум може суттєво погіршити якість медичних зображень, зокрема, це призводить до розмиття деталей та втрати важливої інформації, що необхідна для точного виявлення аномалій. Моделі ШІ, треновані на зображеннях, що містять значний рівень шуму, можуть схильні до хибнопозитивних спрацьовувань, що веде до зниження ефективності в реальному клінічному середовищі.

1.2. Огляд і аналіз сучасних методів обчислювального інтелекту для обробки медичних зображень

Застосунки для обробки зображень магнітно-резонансної томографії хребта відіграють важливу роль у медичній діагностиці та плануванні лікування. Для чіткої візуалізації анатомії хребта, включаючи хребці, диски і м'які тканини, використовуються такі методи, як сегментація, підсилення і 3D-реконструкція. Вдосконалені алгоритми допомагають з високою точністю виявляти такі патології, як грижі міжхребцевих дисків, спинномозкові стенози або пухлини. Машинне навчання та візуалізація на основі штучного інтелекту ще більше розширюють можливості виявлення та класифікації патологій, дозволяючи ставити швидші та точніші діагнози. Підтримуючи малоінвазивні стратегії лікування і точний моніторинг стану хребта з плином часу, ці програми значно покращують результати лікування пацієнтів.

Відповідно до використовуваних методів, джерела можна розділити на кілька груп.

Перша група статей присвячена підходам, які включають доповнення (аугментацію) та попередню обробку даних. Аугментація передбачає штучне збільшення різноманітності та розміру набору даних шляхом застосування перетворень до МРТ-зображень. Найпоширеніші методи включають обертання, перевертання, трансформацію і масштабування для імітації різних положень і анатомічних варіацій. Автори [4] представили інноваційні методи попередньої обробки, необхідні для моделей глибокого навчання, надавши детальний опис і сценарії використання на прикладі даних МРТ колінного суглоба.

Дослідження [5] описує попередню обробку даних для автоматизованої сегментації печінки з використанням архітектури U-Net. Автори зосереджуються на вікні одиниці Хаунсфілда (Hounsfield Unit), адаптивному вирівнюванні гистограми з обмеженим контрастом (CLAFE), нормалізації z-score, медіанній фільтрації та зіставленні блоків, а також 3D-фільтрації (BM3D).

Використання адаптивного вирівнювання гистограми з обмеженим контрастом (CLAFE) для підвищення контрастності зображень, що призводить до покращення ефективності класифікації, згадується в статті [6].

Стаття [7] містить огляд методів доповнення медичних зображень для алгоритмів глибокого навчання з акцентом на комп'ютерну томографію (КТ) та магнітний резонанс (МРТ). Розглянуто базові методи (наприклад, геометричні перетворення, обрізання, оклюзія, операції з інтенсивністю, введення шуму, фільтрація, комбінування зображень). Розглянуто більш просунуті методи, такі як деформована аугментація (наприклад, рандомізовані поля зміщення, сплайн-інтерполяція, статистичні моделі форми) і методи аугментації на основі генеративно-змагальних мереж (GAN).

Наступна група літератури описує основи та оцінку алгоритмів виявлення викидів. Найвідомішими роботами на цю тему є роботи Домінгес та ін. [8] і Гольдштейн та Учїда [9], які проводять порівняльну оцінку алгоритмів виявлення викидів, аналізуючи їхню продуктивність на різних наборах даних. Ці роботи підкреслюють важливість вибору алгоритму на основі властивостей даних і варіантів використання. Граббс (1969) [10] представив основні статистичні методи для виявлення викидів у наборах даних, які залишаються невід'ємною частиною сучасних підходів. Роннебергер та ін. (2015) [11] представили архітектуру U-Net, яка стала фундаментальною для задач сегментації, підкреслюючи її адаптивність до біомедичного аналізу зображень.

Наступна група робіт пов'язана з методами глибокого навчання для виявлення аномалій. До неї належить робота Вінцента та ін. (2010) [12], де автори представили автокодер з стековим шумозаглушенням, створивши прецедент використання глибоких архітектур для вилучення достовірних зображень для виявлення аномалій. У статті Сан та ін. (2018) [13] використовуються варіаційні автокодер (VAE) для навчання розріджених представлень, пристосованих для виявлення аномалій. Інші дослідження, представлені Узуною та ін. (2019) [14] і Бауром та ін. (2018) [15], адаптують варіаційні автокодер для медичної візуалізації, підкреслюючи їхню корисність у неконтрольованому виявленні патології та сегментації аномалій. Степец та Скочай (2020) [16] використали синтез зображень як підставу для виявлення аномалій, підкресливши корисність неконтрольованого навчання для гістопатологічної діагностики.

Генеративні моделі для виявлення аномалій були широко обговорені Шлеглем та ін. у статті [17], де автори запропонували використовувати генеративні змагальні мережі (Generative Adversarial Networks) для неконтрольованого виявлення аномалій, а пізніше розширили цю роботу за допомогою f-AnoGAN, швидшого варіанту, оптимізованого для виявлення аномалій у медичній візуалізації. Гонг та ін. (2019) [18] представили

автокодеру з розширеною пам'яттю, продемонструвавши їхню чудову продуктивність у захопленні нормальних патернів для неконтрольованого виявлення аномалій. Хан та ін. (2021) [19] розробили MADGAN, використовуючи кілька сусідніх зрізів МРТ мозку для надійного виявлення аномалій за допомогою реконструкції на основі генеративно змагальних мереж.

Більше застосувань у медичній візуалізації можна знайти в статтях Лі та ін. (2015) [20], де запропоновано багатоспектральну діагностичну візуалізацію опіків на основі машинного навчання з використанням виявлення викидів для підвищення точності, а також Мейа та ін. (2017) [21] і Кім та ін. (2021) [22], де автори використовують методи PCA і зменшення розмірності для виявлення викидів у даних медичної візуалізації високої розмірності, включаючи функціональну МРТ і рентгенівські знімки грудної клітки. К. Лі та ін. (2016) [23] зосереджуються на забезпеченні якості сегментації мозочкової ніжки шляхом виявлення викидів.

Оптимізація алгоритмів і забезпечення якості були представлені в роботі Такса та Даина (2001) [24], де досліджувалася оптимізація однокласового класифікатора за допомогою рівномірної генерації об'єктів, в якій висвітлювалися досягнення в області стійкості моделей.

Додатки в конкретних областях візуалізації можна також згрупувати наступним чином. Візуалізація молочної залози: Фуйока та ін. (2020) [25] застосували генеративно змагальні мережі для виявлення аномалій в ультразвукових зображеннях молочної залози, досягнувши ефективної діагностики. Рентгенографія грудної клітки: Накао та ін. (2021) [26] і Шанг та ін. (2020) [27] зосередилися на неконтрольованих методах виявлення аномалій на рентгенівських знімках грудної клітки, застосування яких варіюється від пневмонії до виявлення хронічних захворювань. Оптична когерентна томографія сітківки: Зеебок та ін. (2019) [26] використали епістемічну невизначеність в анатомічній сегментації, продемонструвавши новий підхід для виявлення аномалій при візуалізації сітківки.

Про актуальність проблеми свідчить різноманітна література, присвячена автокодувальникам. Наприклад, група канадських вчених висвітлила автокодери зі стековим денойзингом [12], представивши основу для навчання робастних репрезентацій, які мають вирішальне значення для ідентифікації аномалій. Варіаційні автокодери (VAE) широко застосовуються, як продемонстрували Узунова та ін. [14] для виявлення патології та Зіммерер та ін. [28] для неконтрольованої локалізації.

1.3 Актуальність та мета дослідження

Захворювання опорно-рухового апарату, такі як стенози, остеоартрози, травми та інші патології, є однією з основних причин болю, обмеження рухливості та інвалідності. Зі старінням населення та поширенням малорухливого способу життя, захворюваність на ці патології невідносно зростає, створюючи значне навантаження на систему охорони здоров'я.

Діагностика захворювань опорно-рухового апарату часто є складним процесом, що вимагає ретельного аналізу медичних зображень, зокрема МРТ-зображень.

Автокодувальні нейромережі, як метод неконтрольованого навчання, демонструють високу ефективність у виявленні аномалій на медичних зображеннях. На відміну від контрольованого навчання, вони не потребують маркованих даних, вивчаючи нормальні патерни для ідентифікації відхилень. Незважаючи на складність навчання, особливо при роботі з варіативними даними, вони є цінним інструментом для діагностики захворювань опорно-рухового апарату. У медичних наборах даних, де переважають нормальні зображення, необхідна розробка методів для обробки дисбалансу. Рання та точна діагностика захворювань опорно-рухового апарату дозволяє своєчасно розпочати лікування, запобігти прогресуванню захворювання та покращити якість життя пацієнтів. Тому

дослідження автокодувальних нейромереж для виявлення аномалій на МРТ-зображеннях опорно-рухового апарату є актуальним напрямом наукових досліджень, що сприяє розвитку методів обробки медичних зображень та штучного інтелекту в медицині.

Метою даної роботи є дослідження, реалізація та порівняльний аналіз архітектур автокодувальних нейромереж для вирішення задачі виявлення аномалій на прикладі набору даних захворювань опорно-рухової системи.

Новітність даної роботи полягає в розробці методології виявлення аномалій на МРТ-зображеннях опорно-рухового апарату, що поєднує детекцію об'єктів (YOLO) з автокодувальними нейромережами для ефективного виявлення аномалій в умовах дисбалансу даних, та вирішує ряд обмежень, характерних для аналізу МРТ сканів хребта.

1.4 Постановка задачі

На основі проведеного аналізу предметної галузі можна сформулювати завдання, які необхідно вирішити:

- провести аналіз існуючих методів обчислювального інтелекту для розв'язання задачі детекції аномалій за даними медичних зображень;
- визначити проблеми та обмеження вирішення проблеми обробки медичних даних методами обчислювального інтелекту;
- розробити методологію, що включає методи, що покривають визначені обмеження;
- провести імітаційне моделювання та порівняльний аналіз розробленої системи обчислювального інтелекту із використанням набору даних дегенеративних захворювань поперекового відділу хребта.

2 ТЕОРЕТИЧНЕ ДОСЛІДЖЕННЯ АВТОКОДУВАЛЬНИХ НЕЙРОМЕРЕЖЕВИХ МЕТОДІВ ДЛЯ ДЕТЕКЦІЇ АНОМАЛІЙ

2.1 Визначення та архітектура автокодувальника

Автокодувальники, або Autoencoders (AE), представляють собою клас штучних нейронних мереж, які переважно використовуються для неконтрольованого навчання, де метою є кодування вхідних даних у представлення нижчої розмірності та подальша їх реконструкція з мінімальними втратами. Дані моделі привернули значну увагу в різних сферах застосування, включаючи виявлення аномалій, зменшення розмірності та генеративне моделювання [29].

Найпростіший тип автокодувальника, ванільний автокодувальник, складається з мережі декодувальників, що відновлює вхідні дані зі стисненого представлення після того, як вхідні дані були стиснуті мережею кодувальників. Він був винайдений у 1985 році Д. Х. Аклі та Г. Е. Хінтоном.

Архітектура автокодувальника складається з двох ключових компонентів: кодувальника та декодувальника. Процес кодування та декодування даних можна формалізувати у вигляді наступних кроків.

Введемо вектор або тензор вхідних даних $\mathbf{x} \in R^n$, як правило, у високовимірному просторі, де n є кількість ознак у вхідних даних. Кодувальник $f_\theta(\mathbf{x})$ – це функція з параметром θ , яка відображає вхідні дані \mathbf{x} у латентний простір меншої розмірності. Кодувальник можна записати у вигляді:

$$\mathbf{z} = f_\theta(\mathbf{x}), \quad (2.1)$$

де $\mathbf{z} \in R^d$ – латентний вектор (d зазвичай набагато менший за розмірність \mathbf{x});

θ – параметри (ваги та зсуви) нейронної мережі кодувальника. Дана операція зменшує розмірність даних і іноді розглядається як форма вилучення ознак.

З точки зору нейронних мереж, кодувальник зазвичай реалізовано за допомогою серії шарів, таких як щільні шари, згорткові шари тощо, залежно від характеру вхідних даних (наприклад, зображень або послідовностей). Приклад архітектури згорткового автокодувальника приведено на рисунку 2.1.




Рисунок 2.1 – Архітектура згорткового автокодувальника [30]

Архітектура автокодувальника довгої краткодобої пам'яті, або Long short-term memory, для обробки послідовностей приведена на рисунку 2.2.




Рисунок 2.2 – Архітектура LSTM-автокодувальника [31]

Декодувальник $g_\phi(\mathbf{z})$, що задається параметром ϕ , приймає стиснене представлення \mathbf{z} і намагається відновити вихідний вхідний сигнал $\hat{\mathbf{x}}$. Тут під ϕ ми розуміємо параметри (ваги) нейронної мережі-декодувальника, які також налаштовуються під час навчання. Ці параметри визначають, як латентний простір відображається назад у простір вихідних даних. Розмірність: $\hat{\mathbf{x}} \in \mathbf{R}^n$ відповідає розмірності вхідного вектора \mathbf{x} .

Задача декодування визначається наступним чином:

$$\hat{\mathbf{x}} = g_\phi(\mathbf{z}). \quad (2.2)$$

2.2 Функції втрат на реконструкцію

2.2.1 Середньоквадратична втрата

Основною метою автокодувальника є мінімізація втрат при реконструкції, яка вимірює, наскільки добре декодувальник може відтворити вхідний сигнал із закодованого латентного представлення. Найчастіше використовують середньоквадратичну похибку реконструкції (Mean Squared Error, MSE), яка формулюється як:

$$\mathcal{L}_{recon} = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2, \quad (2.3)$$

де x_i – оригінальні вхідні дані;

\hat{x}_i – реконструйовані вихідні дані.

Це гарантує, що модель буде штрафовано за великі розбіжності між вхідними даними і реконструйованими, сприяючи навчанню кодуванню, яке фіксує основну інформацію в даних.

2.2.2 Перцепційна втрата

Перцепційна втрата (Perceptual Loss) є підходом до вимірювання помилки реконструкції у глибоких нейронних мережах, що враховує семантичну подібність між вхідним та реконструйованим зображенням, на відміну від традиційних піксельних метрик, таких як середньоквадратична похибка (MSE). Вперше цей підхід був запропонований Джонсоном та співавторами [32] для задач стилізації зображень та суперрезолуції.

На відміну від MSE, яка обчислює піксельну різницю між зображеннями, перцепційна втрата використовує проміжні активації попередньо навченої глибокої нейромережі (зазвичай VGG-16 або VGG-19) для оцінки візуальної якості реконструкції. Формально вона визначається як:

$$L_{perc} = \frac{1}{n} \sum_{i=1}^n \sum_l \omega_l \|\phi_l(x_i) - \phi_l(\hat{x}_i)\|^2, \quad (2.4)$$

де x_i – вхідні зображення;

\hat{x}_i – реконструйовані вихідні дані;

$\phi_l(\cdot)$ – активації на l -му шарі попередньо навченої нейромережі;

ω_l – вагові коефіцієнти, що визначають внесок кожного рівня у функцію втрат.

Перцепційна втрата дозволяє отримувати візуально якісніші результати, оскільки вона краще враховує структуру зображення. Вона забезпечує семантичну узгодженість, оскільки модель навчається зберігати не тільки локальні деталі, але й загальну структуру об'єкта. На відміну від середньоквадратичної похибки (MSE), яка часто призводить до згладжених і розмитих зображень, перцепційна втрата сприяє збереженню текстур і дрібних деталей, що особливо важливо для високоякісної реконструкції.

Крім того, вона демонструє стійкість до невеликих змін: незначні варіації яскравості або кольору мають мінімальний вплив на значення функції втрат, що робить її більш надійною для складних завдань обробки зображень.

2.3 Регуляризація автокодувальника

У базових автокодувальниках до латентного простору не застосовується явна регуляризація. Іноді це може призвести до перенавчання або поганого узагальнення, особливо якщо розмірність латентного простору занадто велика або навчальні дані обмежені. Модель може навчитися тривіальним кодуванням, таким як відображення ідентичності. Для подолання цього обмеження часто використовують методи регуляризації, такі як зменшення ваги (L_2 -регуляризація) або розріджені автокодувальники (які забезпечують розрідженість латентного простору). L_2 -регуляризація сприяє зменшенню складності моделі, оскільки вона обмежує величину ваг нейронної мережі. Це знижує здатність моделі запам'ятовувати окремі зразки з навчальної вибірки, що запобігає перенавчанню та сприяє кращому узагальненню знань. Завдяки цьому автокодувальник демонструє високу продуктивність навіть на нових, невідомих зразках.

Ще одним важливим аспектом є запобігання перенавчанню. Автокодувальники, особливо ті, що мають велику кількість параметрів, можуть легко адаптуватися до навчальних даних, що призводить до низької ефективності на тестових прикладах. L_2 -регуляризація накладає обмеження на складність функції, яку наближає модель, що дозволяє зменшити цю проблему. Крім того, регуляризація сприяє покращенню стійкості до шуму у вхідних даних. Вона допомагає формувати згладжені латентні представлення, що зменшує вплив випадкових флуктуацій у навчальних зразках та підвищує стабільність моделі. Окремо варто відзначити її роль у

контролі розподілу латентного простору. У глибоких автокодувальниках регуляризація сприяє отриманню компактних та осмислених представлень у латентному просторі. Це є особливо корисним для задач кластеризації, візуалізації та інших методів аналізу даних, що залежать від якісного кодування інформації.

2.4 Варіаційні автокодувальники

Варіаційні автокодувальники, або Variational Autoencoders (VAEs), вводять імовірнісну основу в архітектуру автокодувальника, де замість прямого кодування входів у фіксований латентний код, кодувальник виводить параметри розподілу, як правило, гауссівського. Це дозволяє моделі генерувати більш різноманітні виходи і забезпечувати структуру в латентному просторі, що особливо корисно для генеративних задач.

У VAE кодувальник є не детермінованим, а імовірнісним. Замість того, щоб відображати вхідні дані \mathbf{x} в єдиний прихований вектор \mathbf{z} , кодувальник вивчає параметри розподілу $q(\mathbf{z}|\mathbf{x})$ (як правило, гауссівського):

$$q(\mathbf{z}|\mathbf{x}) = \mathcal{N}(\mu_{\theta}(\mathbf{x}), \sigma_{\theta}^2(\mathbf{x})), \quad (2.5)$$

де $\mu_{\theta}(\mathbf{x})$ – середній вектор;

$\sigma_{\theta}^2(\mathbf{x})$ – дисперсія (діагональна коваріаційна матриця) розподілу.

Кодувальник виводить параметри μ і σ , і з них ми виділяємо латентну змінну \mathbf{z} для подальшого декодування. який підхід запроваджує стохастичність у процес кодування, що забезпечує здатність моделі генерувати різноманітні виходи навіть для одного і того ж вхідного прикладу. Це особливо важливо для задач генерації, де необхідна варіативність результатів при збереженні узгодженості зі вхідними даними.

Схему варіаційного автокодувальника приведено на рисунку 2.3.

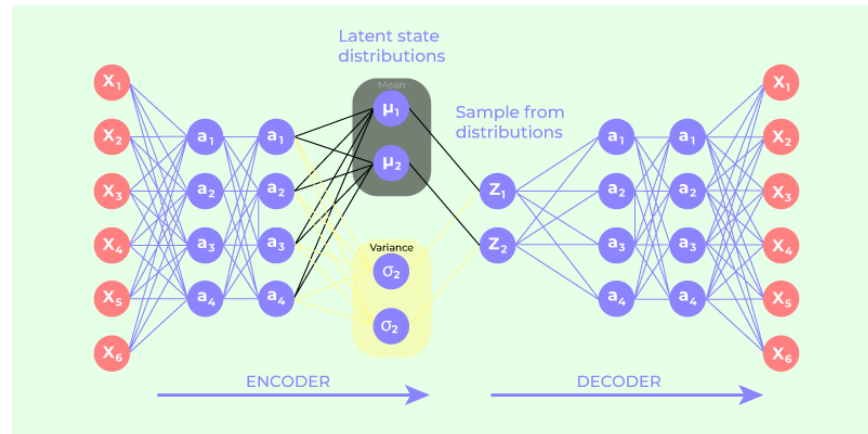


Рисунок 2.3 – Схема варіаційного автокодувальника [33]

Приєм репараметризації використовується під час навчання для зворотного розповсюдження градієнтів через крок стохастичної дискретизації. Він дозволяє репараметризувати латентну змінну як:

$$\mathbf{z} = \mu_{\theta}(\mathbf{x}) + \sigma_{\theta}(\mathbf{x}) \odot \varepsilon. \quad (2.6)$$

У даному випадку $\varepsilon \sim \mathcal{N}(0, I)$ – випадковий вектор шуму (випадкова величина, вибрана зі стандартного нормального розподілу), що дозволяє градієнту протікати через детерміновані параметри $\mu_{\theta}(\mathbf{x})$ і $\sigma_{\theta}(\mathbf{x})$. Через \odot позначено поелементне множення.

Декодувальник $g_{\phi}(\mathbf{z})$ залишається подібним до автокодувальників, де він бере латентну змінну \mathbf{z} і відновлює з неї $\hat{\mathbf{x}}$. Декодувальник навчається максимізувати ймовірність спостережуваних даних відповідно до розподілу латентної змінної, тобто ймовірність $p(\mathbf{x}|\mathbf{z})$. Зазвичай він моделюється як гаусівський, а для неперервних даних цей член зазвичай апроксимується середньоквадратичною похибкою між \mathbf{x} і $\hat{\mathbf{x}}$.

Втрати при реконструкції у VAE, як правило, з двох частин: реконструкційна втрата \mathcal{L}_{recon} та Куллбек-Лейблерова дивергенція \mathcal{L}_{KL} . Реконструкційна втрата обчислюється за допомогою середньоквадратичної помилки (MSE), яка порівнює вихід декодера з вхідними даними. Куллбек-Лейблерова (KL) дивергенція:

$$\mathcal{L}_{KL} = -\frac{1}{2} \sum_{i=1}^d (1 + \log \sigma_i^2 - \mu_i^2 - \sigma_i^2), \quad (2.7)$$

де μ – середнє значення латентної змінної;

σ^2 – дисперсія латентної змінної;

d – розмірність латентного простору.

Ця компонента заохочує латентні змінні z наближатися до стандартного нормального розподілу, що сприяє регуляризації латентного простору та покращує генеративні властивості моделі.

Підсумкова функція втрат має вигляд:

$$\mathcal{L} = \mathcal{L}_{recon} + \mathcal{L}_{KL}. \quad (2.8)$$

2.5 Пороговий підхід до детекції аномалій

При виявленні аномалій на основі автокодувальника, класифікація екземпляра як нормального або аномального визначається на основі помилки реконструкції, яка кількісно визначає розбіжність між вхідними даними та їх реконструйованим виходом. Якщо автокодувальник демонструє низьку ефективність реконструкції для заданих вхідних даних, це означає, що вхідні дані не відповідають базовому розподілу нормальних даних, на яких навчалася модель. Ця невідповідність виникає через те, що автокодувальник навчився кодувати і декодувати лише ті патерни, які

присутні в нормальних даних, що призводить до мінімальної помилки реконструкції для таких випадків. І навпаки, при попаданні на аномальний зразок, який значно відхиляється від вивченого розподілу, модель не може точно його реконструювати, що призводить до високої помилки реконструкції. Ця підвищена втрата є індикатором того, що вхідні дані, ймовірно, є аномалією. Нагадаємо, що на основі набору даних X автокодувальник навчається функції $f: X \rightarrow X$, яка намагається відновити вхідні дані. Похибка реконструкції R визначається як:

$$R(x) = d(x, \hat{x}), \quad (2.9)$$

де x – вхідний зразок;

\hat{x} – відновлений зразок;

$d(\cdot, \cdot)$ – метрика відстані (наприклад, середня квадратична помилка (MSE), середня абсолютна помилка (MAE) або індекс структурної подібності (SSIM)).

Щоб класифікувати вхідні дані x як нормальні чи аномальні, ми порівнюємо $R(x)$ з пороговим значенням τ :

$$\text{Label}(x) = f(x) = \begin{cases} \text{Normal}, & R(x) \leq \tau \\ \text{Anomalous}, & R(x) > \tau \end{cases} \quad (2.10)$$

Вибір порогового значення τ є дуже важливим та може бути обрано одним з наступних методів: статистичні методи, підходи на основі процентилів (наприклад, вибір τ як 95-й перцентиль нормальних помилок реконструкції даних), оптимізація на основі валідації, де τ налаштовується для максимізації таких показників ефективності, як точність, пригадування або оцінка F1.

До статистичних можна віднести налаштування τ як добуток стандартного відхилення від середньої похибки нормальних вибірок.

Обмеженням є те, що дані методи припускають нормально розподілені помилки, що може не відповідати складним наборам даних, фіксований поріг може не адаптуватися до зміни структури даних.

Добуток стандартного відхилення від середньої похибки нормальних вибірок виражено наступною формулою:

$$\tau = \mu_R + k\sigma_R, \quad (2.11)$$

де μ_R – середня помилка реконструкції на нормальних навчальних даних;

σ_R – середньоквадратичне відхилення помилок реконструкції;

k – коефіцієнт чутливості (наприклад, $k = 2$).

Серед переваг даного порогу варто відзначити те, що він добре працює, коли помилка реконструкції має гауссівський розподіл, параметр k контролює чутливість (вищий k зменшує кількість хибних позитивних, але збільшує кількість негативних екземплярів).

Визначимо частки вірно позитивних прогнозів (TPR) та хибно негативних прогнозів (FPR):

$$\text{TPR}(\text{TruePositiveRate}) = \frac{TP}{TP + FN}, \quad (2.12)$$

де TP – кількість вірно позитивних прогнозів;

FN – кількість хибно негативних прогнозів.

$$\text{FPR}(\text{FalsePositiveRate}) = \frac{FP}{FP + TN}, \quad (2.13)$$

де FP – кількість хибно позитивних прогнозів;

TN – кількість вірно негативних прогнозів.

До методів оптимізації на основі валідації відноситься J-статистика Юдена, за якою поріг визначається наступним чином:

$$\tau = \arg \max(\text{TPR} - \text{FPR}). \quad (2.14)$$

Даний поріг максимізує розділення між нормальними та аномальними даними та не потребує попередніх знань про розподіл даних. У той самий час він потребує мічених даних для перевірки та чутливий до дисбалансу класів.

2.6 Метрики тестування та оцінки моделі реконструкції зображень

Метрики для оцінки методів реконструкції зображень використовуються для кількісного вимірювання якості відновленого зображення порівняно з оригінальним. Основні метрики, які використовуються для оцінки методів реконструкції зображень:

- середньоквадратична помилка (Mean Squared Error);
- пікове відношення сигнал-шум (Peak Signal-to-Noise Ratio);
- індекс структурної подібності (Structural Similarity Index);
- середня абсолютна помилка (Mean Absolute Error).

Середньоквадратична помилка (MSE) є однією з найпоширеніших метрик для оцінки якості відновлення зображень; вона характеризує ступінь відхилення реконструкції від оригіналу, зберігаючи чутливість до як локальних, так і глобальних змін в інтенсивності пікселів. Однією з ключових особливостей MSE є її підвищена чутливість до великих відхилень: завдяки піднесенню різниці до квадрату, поодинокі великі помилки суттєво впливають на загальне значення метрики. Тому MSE є корисним інструментом для виявлення помітних дефектів реконструкції, однак потенційно менш надійним у випадках, коли візуально незначні зміни

сприймаються людським зором як неістотні, але значно впливають на числове значення метрики.

Середньоквадратичну помилку виражено наступною формулою:

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2, \quad (2.15)$$

де x_i – значення пікселя оригінального зображення;

\hat{x}_i – значення пікселя відновленого зображення;

N – загальна кількість пікселів у зображенні.

Пікове відношення сигнал-шум (PSNR) використовується для оцінки якості зображень, зокрема, в умовах компресії або реконструкції. PSNR являє собою логарифмічне відношення між максимально можливим пікселем і рівнем шуму (помилки) у зображенні, вимірюється в децибелах (dB). Високе значення *PSNR* означає високу якість зображення.

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right), \quad (2.16)$$

де *MAX* – максимальна піксельна інтенсивність;

MSE – середньоквадратична помилка.

Індекс структурної подібності (SSIM) є більш складною метрикою, що оцінює структурну схожість між двома зображеннями. Вона враховує три основні фактори: яскравість, контраст і структуру.

$$SSIM(x, \hat{x}) = \frac{(2\mu_x \mu_{\hat{x}} + c_1)(2\sigma_{x\hat{x}} + c_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + c_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + c_2)}, \quad (2.17)$$

де μ_x і $\mu_{\hat{x}}$ – середнє значення інтенсивності пікселів для зображень x і y ;

σ_x^2 і $\sigma_{\hat{x}}^2$ – дисперсії пікселів для двох зображень;

$\sigma_{x\hat{x}}$ – коваріація між зображеннями;

c_1 і c_2 – малі константи для стабілізації результатів.

Середня абсолютна помилка (MAE) є метрикою, що вимірює середню абсолютну різницю між пікселями оригінального зображення та відновленого.

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i|, \quad (2.18)$$

де x_i – значення пікселя в оригінальному зображенні;

\hat{x}_i – значення пікселя в реконструйованому зображенні;

N – загальна кількість пікселів.

На відміну від MSE, MAE не підвищує вплив великих помилок, оскільки використовує абсолютні значення відмінностей. Дана особливість може бути корисною для моделей, які повинні мінімізувати середнє відхилення, а не великий вплив окремих великих помилок.

3 ТЕОРЕТИЧНЕ ДОСЛІДЖЕННЯ МЕТОДІВ ОБ'ЄКТНОГО ДЕТЕКТУВАННЯ ДЛЯ ПОШУКУ АНОМАЛІЙ

3.1 Застосування об'єктного детектування в медичній галузі

Алгоритми виявлення об'єктів призначені для ідентифікації та локалізації певних особливостей на зображеннях. У медичній діагностиці це завдання є особливо важливим, оскільки воно полегшує виявлення патологічних відхилень, таких як пухлини, пошкодження та структурні аномалії. Проблема виявлення об'єктів на медичних зображеннях виникає через варіативність анатомічних структур, наявність шумів і необхідність точної локалізації для прийняття клінічних рішень. На відміну від традиційної класифікації зображень, яка присвоює зображенню одну мітку, виявлення об'єктів надає просторову інформацію про декілька об'єктів на одному зображенні. Це особливо важливо в медичній діагностиці, де на одному знімку можуть бути присутніми кілька аномалій. Системи виявлення медичних об'єктів вимагають високої точності та запам'ятовування через критичний характер хибнонегативних (пропущені діагнози) і хибнопозитивних (непотрібні спостереження або лікування) результатів.

Можна виділити наступні найпоширеніші методи:

- You Only Look Once (YOLO);
- Region-Based Convolutional Neural Networks (R-CNN);
- Single Shot MultiBox Detector (SSD).

Алгоритм YOLO, відомий своєю швидкістю і точністю, був адаптований для медичних застосувань. Його здатність обробляти зображення в режимі реального часу робить його придатним для сценаріїв, де швидка оцінка має вирішальне значення. Наприклад, в радіології моделі на основі YOLO були розроблені для виявлення легеневих вузликів на рентгенівських знімках грудної клітки та пухлин на мамографічних знімках.

У дослідженні [34] представлено Neural Architecture Search (NAS), зокрема AutoNAS, для оптимізації моделей YOLO для виявлення рентгенівських аномалій грудної клітини. Дослідження [35] присвячене проблемі виявлення та класифікації пухлин головного мозку на медичних зображеннях МРТ. Завдяки точному налаштуванню моделі YOLOv8 для виявлення пухлин і використанню трансформатора зору (ViT) для класифікації, дослідження демонструє багатообіцяючі результати в надійній діагностиці пухлин, пропонуючи потенційний прогрес в медичній візуалізації. MedYOLO [36] представляє фреймворк для виявлення 3D-об'єктів, що використовує методологію YOLO, адаптовану для сканів комп'ютерної томографії. Протестований на багатьох наборах даних, включаючи BRATS і LIDC, фреймворк демонструє високу продуктивність у виявленні середніх і великих структур, що свідчить про його застосовність у різних медичних контекстах.

3.2 Визначення та архітектура моделі YOLO

У 2015 році Редмон та ін. представили першу версію YOLO (You Only Look Once) [37], що наразі відомий своєю здатністю до об'єктного детектування.

Модель YOLO формулює виявлення об'єктів як одно етапну регресійну задачу, прогнозуючи граничні області та ймовірності класів безпосередньо з вхідного зображення $I \in \mathbb{R}^{H \times W \times C}$, де H, W, C позначають висоту, ширину та кількість каналів зображення відповідно. Модель розбиває зображення на сітку розміром $S \times S$, де кожна клітинка сітки відповідає за виявлення об'єктів, чий центри потрапляють у цю клітинку.

Нехай ми маємо сітку розміру $S \times S$. Кожна клітинка сітки (i, j) асоціюється з обмежувальними коробками (bounding boxes) B та розподілом ймовірностей класів $\mathbf{p} = (p_1, p_2, \dots, p_C)$, де C – це кількість класів об'єктів.

Обмежувальні коробки можна представити як $\mathbf{b}_k = (x_k, y_k, w_k, h_k, c_k)$, де (x_k, y_k) – координати центра коробки, нормалізовані відносно клітинки сітки, (w_k, h_k) – ширина та висота, нормалізовані до розмірів зображення, а $c_k \in [0,1]$. Вихід кожної клітинки сітки має розмірність $B \times 5 + C$.

Модель YOLO застосовує згорткову нейронну мережу для перетворення вхідного зображення на характеристичну карту \mathbf{F} , після чого застосовуються повнозв'язні шари для створення тензора $\mathbf{Y} \in \mathbb{R}^{s \times s \times (B \times 5 + C)}$, де $\mathbf{Y}_{ij} = [\mathbf{b}_1, b_2, \dots, \mathbf{b}_B, \mathbf{p}] \in \mathbb{R}^{s \times s \times (B \times 5 + C)}$. Тут коефіцієнт впевненості c_k для кожної обмежувальної коробки визначається як:

$$c_k = P(\text{об'єкт}) \times IOU(\hat{b}_k, b_k), \quad (3.1)$$

де $P(\text{об'єкт})$ – ймовірність наявності об'єкта в клітинці;

$IOU(\hat{b}_k, b_k)$ – це інтерсекція над об'єднанням (Intersection over Union) між передбаченою та реальною коробками.

Цільова функція тренування мінімізує функцію втрат YOLO, яка складається з втрат для локалізації, впевненості та класифікації.

З метою уточнення прогнозів YOLO застосовує алгоритм ненадмірного подавлення (Non-Maximum Suppression, NMS), при якому зайві обмежувальні коробки з високим значенням IoU видаляються, і зберігається лише коробка з найвищим коефіцієнтом впевненості.

4 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА ОЦІНКА ЕФЕКТИВНОСТІ РОЗГЛЯНУТИХ МЕТОДІВ

4.1 Попередня обробка, аналіз даних та визначення обмежень даних

Набір даних, що було обрано для дослідження – «RSNA 2024 Lumbar Spine Degenerative Classification» («Класифікація дегенеративних захворювань поперекового відділу хребта») [38] – представляє колекцію знімків магнітно-резонансної томографії (МРТ) поперекового відділу хребта, розроблену для полегшення виявлення та класифікації дегенеративних захворювань хребта за допомогою машинного навчання. Набір даних був створений завдяки спільним зусиллям Радіологічного товариства Північної Америки (RSNA) та Американського товариства нейрорадіологів (ASNR) і включає зображення з понад восьми медичних установ на п'яти континентах, забезпечуючи таким чином різноманітне представлення демографічних даних пацієнтів та протоколів візуалізації. МРТ-зображення хребта можуть бути отримані в трьох основних площинах: аксіальній, сагітальній та корональній. Для даного дослідження основними площинами є аксіальна та сагітальна. Аксіальна площина створює зображення горизонтальних зрізів (перпендикулярних до хребта), які проходять через усе тіло з напрямку зверху вниз. У свою чергу, сагітальна площина формує вертикальні зрізи (паралельні хребту), що проходять зліва направо.

МРТ-зображення можна класифікувати на два основні типи залежно від ваги сигналу: T1-зважені та T2-зважені зображення. На T1-зважених зображеннях жир виглядає яскравіше, а внутрішня частина кісток має підвищену інтенсивність, що дозволяє чітко візуалізувати структури хребта. T2-зважені зображення мають іншу характеристику: на них вода виглядає яскравіше, що дозволяє краще розрізняти спинномозковий канал, який має високу інтенсивність на таких зображеннях. МРТ-зображення не

стандартизовані щодо значень пікселів, що може ускладнювати подальший аналіз, на відміну від зображень, отриманих за допомогою комп'ютерної томографії (КТ). У зв'язку з цим, одним із завдань є стандартизація зображень для подальшої обробки та аналізу.

Анотації були надані експертами-нейрорадіологами до кожного сканування; виділено три конкретних дегенеративних стана:

- звуження нейронного отвору/форамінальний стеноз;
- субартикулярний стеноз;
- стеноз хребетного каналу.

Візуальне представлення вищезазначених аномалій приведено на рисунку 4.1.




Рисунок 4.1 – Візуалізація аномалій (типів стенозу) поперекової зони хребта [39]

Стеноз хребта в поперековій (люмбальній) зоні може мати кілька варіантів, що визначаються конкретними локалізаціями звуження, що призводить до компресії нервових структур. Найпоширенішими типами стенозу в цій зоні є субартикулярний, форамінальний та стеноз хребетного каналу. Кожен з цих видів стенозу має свої клінічні прояви, патогенез і методи лікування, що вимагають специфічного підходу.

Форамінальний стеноз відбувається, коли міжхребцевий отвір (форамен), через який виходять нервові корінці, звужується. Це може

бути результатом дегенерації диска, утворення остеофітів або гіпертрофії жовтих зв'язок [40].

Субартикулярний стеноз характеризується звуженням каналу в області, де нервові корінці виходять з спинного каналу, поблизу суглобів міжхребцевих дисків. Це звуження часто спричинене дегенеративними змінами в міжхребцевих дисках і суглобах (артрозами), що призводить до компресії нервових корінців [41].

Стеноз хребетного каналу в поперековому відділі хребта включає звуження самого каналу, через який проходить спинний мозок і нервові корінці. Причинами можуть бути дегенеративні зміни в міжхребцевих дисках, утворення остеофітів, гіпертрофія жовтих зв'язок або зміщення хребців [42].

Кожен стан був оцінений і класифікований за ступенем тяжкості на п'яти рівнях міжхребцевих дисків. Зображення збережено у форматі DICOM (Digital Imaging and Communications in Medicine) для виділених площин (аксіальної та сагітальної T1- та T2-зваженої) для кожного з 1975 пацієнтів.

Після попередньої обробки зріз метаданих виглядає наступним чином (рисунок 4.2).

| | study_id | condition | level | severity | instance_number | x | y | series_description |
|-------|------------|-----------------------------|-------|-------------|-----------------|------------|------------|--------------------|
| 11421 | 1013589491 | Spinal Canal Stenosis | L1/L2 | Normal/Mild | 10 | 245.476038 | 189.689334 | Sagittal T2/STIR |
| 11422 | 1013589491 | Spinal Canal Stenosis | L2/L3 | Normal/Mild | 10 | 235.251580 | 250.434645 | Sagittal T2/STIR |
| 11423 | 1013589491 | Spinal Canal Stenosis | L3/L4 | Moderate | 10 | 232.381129 | 310.201597 | Sagittal T2/STIR |
| 11424 | 1013589491 | Spinal Canal Stenosis | L4/L5 | Moderate | 10 | 238.435979 | 366.511699 | Sagittal T2/STIR |
| 11425 | 1013589491 | Spinal Canal Stenosis | L5/S1 | Normal/Mild | 10 | 257.921341 | 421.652869 | Sagittal T2/STIR |
| 11440 | 1013589491 | Left Subarticular Stenosis | L5/S1 | Normal/Mild | 7 | 277.947591 | 296.033812 | Axial T2 |
| 11445 | 1013589491 | Right Subarticular Stenosis | L5/S1 | Normal/Mild | 7 | 231.484002 | 293.409742 | Axial T2 |
| 11439 | 1013589491 | Left Subarticular Stenosis | L4/L5 | Moderate | 13 | 266.694844 | 257.081995 | Axial T2 |
| 11444 | 1013589491 | Right Subarticular Stenosis | L4/L5 | Normal/Mild | 13 | 228.060888 | 255.755492 | Axial T2 |
| 11438 | 1013589491 | Left Subarticular Stenosis | L3/L4 | Moderate | 19 | 262.366864 | 246.262046 | Axial T2 |
| 11443 | 1013589491 | Right Subarticular Stenosis | L3/L4 | Normal/Mild | 19 | 215.835482 | 245.486151 | Axial T2 |

Рисунок 4.2 – Зріз вхідних метаданих віділений бібліотекою pandas

На зрізі приведено наступні атрибути:

- study_id – номер пацієнту;
- condition – хвороба. Представлена наступними: звуження лівого нервового отвору, звуження правого нервового отвору, лівий субартикулярний стеноз, правий субартикулярний стеноз і стеноз хребетного каналу;
- level – рівень хребців поперекової зони. Представлений: L1/L2, L2/L3, L3/L4, L4/L5, L5/S1;
- severity – стан хвороби: Normal/Mild, Moderate, Severe;
- instance_number – номер зрізу (для кожного пацієнта для кожної площини може бути 1-40 зрізів, їх кількість варіюється від анатомічних особливостей);
- x, y – координати хребців;
- series_description – анатомічні площини (аксіальна, сагітальна T1-зважена та сагітальна T2-зважена).

Приклади відповідних зрізів МРТ-зображень приведено на рисунку 4.3.




Рисунок 4.3 – Приклади зрізів МРТ-зображень та аномалій поперекової зони хребта. Ліворуч: Тяжка стадія лівого субартикулярного стенозу хребця L4/L5 аксіальної площини зрізу 34. Праворуч: Тяжка стадія стенозу хребетного каналу сагітальної площини зрізу 10 [38]

Із розподілу даних даних аномалій (приведено на рисунку 4.4) видно, що більшість зображень не містять аномалій, тобто належать до групи «Normal/Mild».




Рисунок 4.4 – Розподіл даних аномалій [38]

Під час аналізу літератури та наведеного набору даних було виявлено, що на конкретних анатомічних площинах сагітальні T1-зважені зображення використовують для діагностики на звуження нервового отвору, аксіальні T2-зважені – субартікулярного стенозу, сагітальні T2-зважені – хребетного каналу. Оскільки різні анатомічні площини містять суттєво відмінну інформацію, та діагностика наведених аномалій виконується на конкретних площинах, використання багатозадачного навчання є недоцільним.

На одному зрізі сагітальної анатомічної площини можуть бути присутніми кілька хребців, кожен із яких може мати різний ступінь патологічних змін або бути в межах норми. Аналогічно із аксіальною площиною та детекцією аномалій на правій та лівій стороні хребта. Це ускладнює визначення єдиного цільового атрибута severity (ступеня вираженості патології) для всього зображення.

Альтернативний підхід, що передбачає додавання інформації про рівень хребців (level) та номер зрізу (instance_number) або створення складного цільового атрибута, також має значні недоліки. По-перше, розподіл патологій у вибірці є нерівномірним, що ускладнює навчання моделей. По-друге, можливості аугментації медичних зображень є обмеженими через ризик втрати критично важливої анатомічної інформації. Це створює труднощі для мультикласової класифікації, оскільки не вдається побудувати добре збалансовані підвибірки.

На одному зрізі можуть одночасно бути представлені кілька хребців, що створює додаткові труднощі при анотуванні даних та побудові навчальних вибірок. Якщо патологічні зміни стосуються лише частини структур на зображенні, це ускладнює точну класифікацію всього зрізу. Для коректного аналізу необхідно виконувати локалізацію та окремий розгляд кожного хребця, що значно ускладнює побудову автоматизованої системи аналізу.

4.2 Запропонована методологія

З урахуванням встановлених обмежень даних було розроблено методологічний підхід, що представлений нижче. Оскільки різні анатомічні площини містять суттєво відмінну діагностичну інформацію, а виявлення зазначених аномалій здійснюється на специфічних площинах, запропоновано використання окремих концептуальних структур для кожної з розглянутих анатомічних площин: аксіальної, сагітальної T1-зваженої та сагітальної T2-зваженої.

Для вирішення проблеми ідентифікації кількох аномалій на одному скані певної площини було запропоновано застосування підходу об'єктного детектування. Це дає можливість локалізувати конкретні зони для діагностики, що є особливо важливим, наприклад, для

сагітальної T2-зваженої площини, де через анатомічні особливості необхідно чітко ідентифікувати п'ять окремих хребців.

Виділення окремих структур на зображеннях дозволяє вирішити одразу кілька завдань. По-перше, це сприяє збільшенню кількості зображень і їхньої варіативності, що є критично важливим фактором для ефективного функціонування моделей глибинного навчання. По-друге, отримані локалізовані зображення містять меншу кількість вторинних деталей, текстур і фонових варіацій. Це підвищує ефективність згорткових нейронних мереж (CNN), оскільки згорткові шари оптимально виявляють локальні патерни (кути, градієнти, текстурні особливості), а спрощена структура зображень дозволяє мережі точніше навчатися розпізнаванню релевантних особливостей навіть у неглибоких архітектурах. Такий підхід не лише прискорює процес навчання, а й знижує обчислювальні витрати моделі.

Наступним етапом є вирішення задачі виявлення аномалій. Традиційно ця проблема формулюється як задача бінарної класифікації, однак у випадках, коли спостерігається значний дисбаланс між класами (із суттєвим переважанням нормальних зразків), використання цього підходу є недоцільним. Тому було запропоновано застосування автокодувальних нейронних мереж, що навчаються реконструкції ознак сканів, які не містять аномалій. Це дозволяє виявляти аномальні випадки на основі відхилень у реконструкційних помилках.

Для оцінки ефективності підходу локалізовані структурні зображення були подані до кількох варіацій автокодувальних нейронних мереж з метою аналізу доцільності їх застосування та порівняння продуктивності на вибірці хребців у сагітальній T2-зваженій площині.

Схему запропонованої методології представлено на рисунку 4.5.

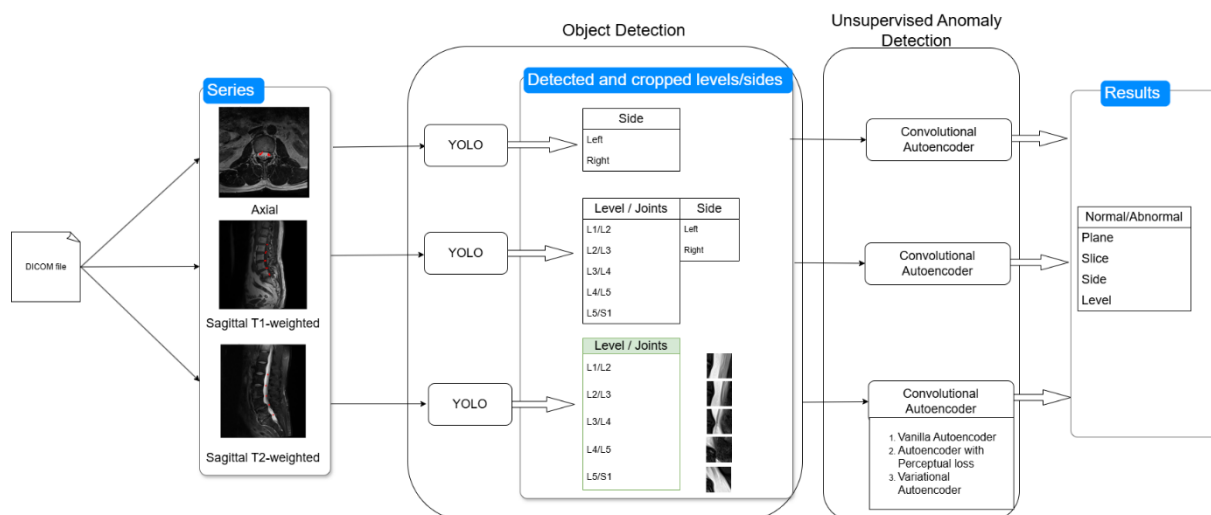


Рисунок 4.5 – Запропонована методологія [44]

4.3 Обрані технології для реалізації

Для програмної реалізації даного дослідження була обрана мова програмування Python 3, яка є динамічною мовою високого рівня з відкритим вихідним кодом. Її популярність серед дослідників та розробників обумовлена розвинутою екосистемою для машинного навчання та наявністю численних бібліотек, що забезпечують ефективне вирішення широкого спектра задач. Наявність багатого інструментарію для машинного навчання, математичних обчислень та обробки даних стали основними чинниками вибору Python як основної мови програмування для реалізації даного дослідження.

Для розв'язання поставлених завдань були використані наступні бібліотеки:

– `scikit-learn` – популярна бібліотека для машинного навчання з відкритим вихідним кодом, яка надає імплементацію найбільш відомих алгоритмів машинного навчання, а також корисні інструменти для попередньої обробки даних, зокрема для масштабування та розподілу даних;

– PyTorch – потужний фреймворк для глибокого навчання з відкритим вихідним кодом, який дозволяє зручно створювати кастомізовані блоки, шари та моделі, а також розробляти індивідуальні алгоритми навчання;

– Matplotlib – бібліотека для візуалізації даних, що дозволяє створювати різноманітні графіки та діаграми, що сприяє наочному представленню результатів досліджень;

– NumPy – основний пакет для наукових обчислень на мові Python, що забезпечує ефективну обробку масивів та матриць, а також реалізує численні функції для математичних та статистичних обчислень;

– Процедуру навчання було проведено на комп'ютері AMD Ryzen 7 5700U з графікою Radeon.

4.4 Детектування хребців засобами YOLO

Для вирішення задачі детектування хребців було використано технологію трансферного навчання, а саме – попередньо навчену модель Yolo8. Набір даних було оброблено та для подальшого дослідження обрано сагітальну T2-зважену площину. Оскільки скани даної площини містять декілька хребців на одному зрізі, постала задача детектування та виділення хребців в окремий набір даних.

У таблиці 4.1 приведено процес налаштування найважливіших гіперпараметрів моделі.

Таблиця 4.1 – Обрані для дослідження гіперпараметри моделі Yolo

| Параметр | Значення | Значення за замовчуванням |
|-------------------|----------|---------------------------|
| imgsz | 384 | 640 |
| batch | 16 | 16 |
| epochs | 100 | 50-300 |
| patience | 15 | 10 |
| optimizer | AdamW | SGD |
| pretrained | TRUE | TRUE |

Продовження таблиці 4.1

| | | |
|------------------------|--------|--------|
| deterministic | TRUE | FALSE |
| dropout | 0.2 | 0.5 |
| lr0 | 0.001 | 0.01 |
| lrf | 0.01 | 0.1 |
| momentum | 0.940 | 0.9 |
| weight_decay | 0.0005 | 0.0005 |
| warmup_epochs | 10 | 0 |
| warmup_momentum | 0.8 | 0.9 |
| box | 07.V | 07.V |
| cls | 0.5 | 0.5 |
| dfl | 01.V | 01.V |
| amp | TRUE | FALSE |

Параметр `batch` відповідає кількості зразків, що обробляються разом на кожному кроці тренування, він контролює стабільність і швидкість тренування. `patience` визначає кількість епох без покращення валідаційної продуктивності перед припиненням тренування, допомагає запобігти перенавчанню, зупиняючи тренування, якщо немає покращень. У якості оптимізатору замість стохастичний градієнтного спуску (SGD) було обрано модифікацію оптимізатора Adam – AdamW. Оптимізатор AdamW є вдосконаленою версією популярного оптимізатора Adam, яка додає регуляризацію L2 (так званий `weight decay`) без змішування зі швидкістю навчання. Adam (Adaptive Moment Estimation) використовує адаптивну зміну швидкості навчання для кожного параметра, що дозволяє йому швидше досягати мінімуму в порівнянні з традиційними оптимізаторами, такими як SGD (Stochastic Gradient Descent). Dropout було знижено із значення за замовчуванням, `lr0` (початкову швидкість навчання) та `lrf` (фактор масштабування швидкості навчання) зменшено для стабільного тренування. Моментум – метод, що допомагає оптимізатору зберігати напрямок оновлень градієнтів, використовуючи інформацію з попередніх кроків. Це дозволяє моделі швидше йти в правильному

напрямку, знижуючи коливання у напрямку градієнта. Досить високе задане значення сприяє швидкому сходженню оптимізатора до глобального мінімуму. Такий параметр дозволяє використовувати пам'ять про попередні оновлення, щоб допомогти моделі подолати «плато» або місцеві мінімімуми.

Графіки тренування моделі Yolo8 для детектування хребців сагітальної T2-зваженої площини приведено на рисунку 4.6.

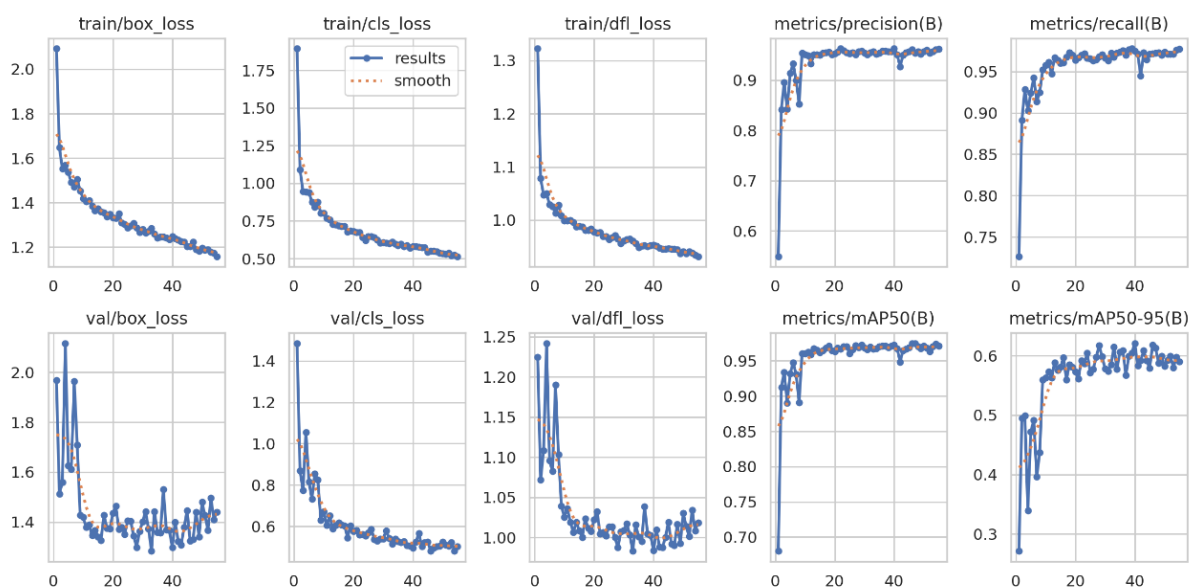


Рисунок 4.6 – Графіки тренування моделі Yolo8 для детектування хребців сагітальної T2-зваженої площини

Box Loss вимірює похибку у визначенні координат обмежувальних рамок (bounding boxes). Зниження цієї метрики свідчить про покращення точності локалізації об'єктів. У валідаційному наборі (val/box_loss) присутні коливання, що вказує на варіативність вхідних даних. Classification Loss оцінює точність класифікації об'єктів. Як і Box Loss, ця метрика поступово знижується під час навчання, що підтверджує покращення здатності моделі правильно ідентифікувати об'єкти. Коливання у валідаційній вибірці можуть свідчити про різноманітність даних або певну чутливість моделі до

змін у вибірці. DFL Loss (Distribution Focal Loss) використовується в YOLOv8 для покращення локалізації об'єктів шляхом оптимізації розподілу ймовірностей навколо координат рамок. Спостерігається аналогічне зниження значень у процесі навчання, що вказує на покращення локалізації.

Протягом навчання спостерігається поступове зниження всіх типів loss-функцій, що вказує на стабільну конвергенцію моделі.

Наявність регулярних коливань у метриках може бути пов'язана з особливостями семплів у батчах або структурними відмінностями між підвбірками. Структура навчальних даних відіграє ключову роль у досягненні стабільності – якісна анотація та збалансованість класів сприяють підвищенню загальної точності. Загалом, динаміка метрик свідчить про ефективне навчання моделі та її здатність узагальнювати на нових даних.

На графіку влучність (precision) швидко зростає та стабілізується на рівні ~ 0.9 , що свідчить про мінімальну кількість хибно позитивних передбачень. Висока повнота (~ 0.95) свідчить про те, що майже всі об'єкти успішно ідентифікуються.

Метрика Mean Average Precision (mAP) оцінює загальну продуктивність моделі за допомогою середнього значення точності при різних порогах Intersection over Union (IoU). Дана метрика обчислюється для $\text{IoU} \geq 0.5$, що означає, що рамка передбаченого об'єкта має перекривати реальну рамку на $\geq 50\%$ для того, щоб вважатися правильною. Значення mAP50 швидко зростає до ~ 0.95 , що демонструє високий рівень детекції об'єктів. mAP50-95 розраховується для різних порогів IoU (від 0.5 до 0.95).

Аналіз нормалізованої матриці плутанини виявив високу ефективність моделі у класифікації досліджуваних класів, що підтверджується високими значеннями діагональних елементів. Зокрема, відсоток правильних передбачень для класів L1/L2, L2/L3, L3/L4, L4/L5

та L5/S1 перевищує 97%, що свідчить про високу точність класифікації. Низький відсоток помилкових передбачень між сусідніми класами ($\leq 1\%$) вказує на чітку диференціацію класів та мінімальну плутанину між ними. Однак, спостерігається певне зміщення класифікації в сторону класу «фон», особливо для класу L3/L4, де 9% зразків були помилково віднесені до фону.

Матрицю плутанини приведено на рисунку 4.7.




Рисунок 4.7 – Нормалізована матриця плутанини тестування YOLO8 для детектування хребців сагітальної T2-зваженої площини

Приклад детектування хребців сагітальної T2-зваженої площини навченою моделлю YOLO8 приведено на рисунку 4.8. Кожен хребець декількох зрізів сагітальної T2-зваженої площини виявлено моделлю із високим рівнем упевненості. Оцінка впевненості є числовим значенням

між 0 і 1, яке вказує на ймовірність того, що виявлений об'єкт дійсно є хребцем. Значення, близькі до 1, вказують на високу впевненість, тоді як значення, близькі до 0, вказують на низьку впевненість. На зображенні оцінки впевненості варіюються, але загалом вони досить високі (наприклад, 0.7, 0.8. Важливо зазначити, що зображення у прикладі можуть відрізнятися за якістю, контрастністю та орієнтацією. Це може бути пов'язано з різними параметрами сканування МРТ, анатомічними варіаціями між пацієнтами або іншими факторами. Незважаючи на ці варіації, наведена модель досить надійно виявляє хребці на різних зображеннях.




Рисунок 4.8 – Приклад детектування хребців сагітальної T2-зваженої площини навченою моделлю Yolo8

4.5 Імплементація автокодувальних нейромереж для виявлення аномалій хребців

Отримані у минулому пункті скани окремих хребців та їхні метадані будуть використані для навчання, валідації та тестування моделі автокодувальника для виявлення аномалій хребців поперекової зони хребта.

Було імплементовано клас для завантаження та попередньої обробки дани для подальшого навчання згорткової нейронної мережи. Обробка включає зміну розміру до стандартного 64x64 пікселів, що дозволяє зменшити обчислювальні витрати при обробці; перетворення зображення у тензор для подальшої обробки в рамках PyTorch; та нормалізацію значення пікселів: зображення нормалізуються до діапазону $[-1, 1]$, що забезпечує кращу стабільність навчання, оскільки значення в такому діапазоні працюють ефективніше з багатьма моделями глибинного навчання. Під час проведення Explanatory Data Analysis (EDA) було виявлено, що розподіл даних не є нормальним – кількість аномальних сканів хребців є близькою 7%. Через даний розподіл проблему неможливо вирішити шляхом навчання із вчителем і формалізації задачі бінарної класифікації. Тому далі буде досліджено задачу навчання без учителя (unsupervised learning) для детектування аномалії; буде запроєктовано та імплементовано базовий автокодувальник, автокодувальник із перцепційною втратою та варіаційний автокодувальник.

4.5.1 Розробка, реалізація базового автокодувальника

Запроєктована модель базового автокодувальника приведена на рисунку 4.9. В основі частини кодувальника лежить шість згорткових шарів, що реалізовано функцією `torch.nn.Conv2d`. Вона застосовує згортковий фільтр (ядро) до вхідного зображення або тензору, здійснюючи операцію на кожному регіоні зображення. Це дозволяє нейронній мережі вивчати

локальні особливості вхідних даних, такі як краї, текстури або інші важливі патерни.

У якості активаційної функції було обрано гіперболічний тангенс (`torch.nn.Tanh`). Завдяки нелінійності дана функція дозволяє нейронним мережам моделювати складніші взаємозв'язки в даних.

Подане вхідне зображення має розмір 64x64 пікселів, до латентного простору воно буде згорнуто до розміру 2x2, далі передано на симетрично визначені шість згорткових шарів декодувальника.

| Layer (type) | Output Shape | Param # |
|--------------------|------------------|-----------|
| Conv2d-1 | [-1, 16, 32, 32] | 160 |
| Tanh-2 | [-1, 16, 32, 32] | 0 |
| Conv2d-3 | [-1, 32, 16, 16] | 4,640 |
| Tanh-4 | [-1, 32, 16, 16] | 0 |
| Conv2d-5 | [-1, 64, 8, 8] | 18,496 |
| Tanh-6 | [-1, 64, 8, 8] | 0 |
| Conv2d-7 | [-1, 128, 4, 4] | 73,856 |
| Tanh-8 | [-1, 128, 4, 4] | 0 |
| Conv2d-9 | [-1, 256, 2, 2] | 295,168 |
| Tanh-10 | [-1, 256, 2, 2] | 0 |
| Conv2d-11 | [-1, 512, 1, 1] | 1,180,160 |
| Tanh-12 | [-1, 512, 1, 1] | 0 |
| ConvTranspose2d-13 | [-1, 256, 2, 2] | 1,179,904 |
| Tanh-14 | [-1, 256, 2, 2] | 0 |
| ConvTranspose2d-15 | [-1, 128, 4, 4] | 295,040 |
| Tanh-16 | [-1, 128, 4, 4] | 0 |
| ConvTranspose2d-17 | [-1, 64, 8, 8] | 73,792 |
| Tanh-18 | [-1, 64, 8, 8] | 0 |
| ConvTranspose2d-19 | [-1, 32, 16, 16] | 18,464 |
| Tanh-20 | [-1, 32, 16, 16] | 0 |
| ConvTranspose2d-21 | [-1, 16, 32, 32] | 4,624 |
| Tanh-22 | [-1, 16, 32, 32] | 0 |
| ConvTranspose2d-23 | [-1, 1, 64, 64] | 145 |
| Tanh-24 | [-1, 1, 64, 64] | 0 |

Total params: 3,144,449
 Trainable params: 3,144,449
 Non-trainable params: 0

Рисунок 4.9 – Топологія базового автокодувальника

Для оцінки якості моделі в цьому контексті використовується функція втрат середньоквадратичної помилки (Mean Squared Error, MSE_{Loss}). Мінімізація цієї функції дозволяє зменшити відмінності між оригінальними та реконструйованими даними, що є основною метою автоенкодерів.

У якості оптимізатору використано Adam – адаптивний метод оптимізації, який поєднує переваги двох інших алгоритмів: AdaGrad та RMSprop. Adam використовує не лише перший момент (середнє значення) градієнтів, а й другий момент (квадрати градієнтів), що дозволяє більш точно коригувати швидкість навчання для кожного параметра. Це дає можливість Adam адаптивно регулювати кроки оновлення ваг для різних параметрів, забезпечуючи більш стабільне та швидке навчання в порівнянні з іншими стандартними оптимізаторами, такими як стохастичний градієнтний спуск (SGD). Таким чином, Adam здатний більш ефективно уникати проблеми затримок в оновленнях ваг та коливань при великих градієнтах, що є критичним для навчання великих глибинних моделей.

Моніторинг ефективності навчання є важливим аспектом процесу тренування. Виведення значень середніх втрат на кожній епісі для тренувального та валідаційного наборів дозволяє оперативно оцінювати прогрес моделі. Це дає можливість вчасно виявити проблеми, такі як перенавчання, або *overfitting* (модель занадто добре підлаштовується під навчальний набір даних, захоплюючи шум і випадкові коливання) та недонавчання, або *underfitting* (модель не здатна добре відтворювати дані на тренувальних даних, що призводить до високої помилки як на тренувальному, так і на валідаційному наборах даних). Прогресивний моніторинг дозволяє адаптувати гіперпараметри моделі, такі як швидкість навчання чи кількість епох, в реальному часі, що сприяє досягненню кращих результатів. У результаті, після кожної епохи виводяться значення середніх втрат для тренувальних і валідаційних даних, що забезпечує важливу зворотний зв'язок для подальших коригувань процесу тренування.

На початкових етапах і втрати при навчанні, і втрати при валідації демонструють стрімке падіння, що свідчить про швидке навчання суттєвих ознак (рисунок 4.10).

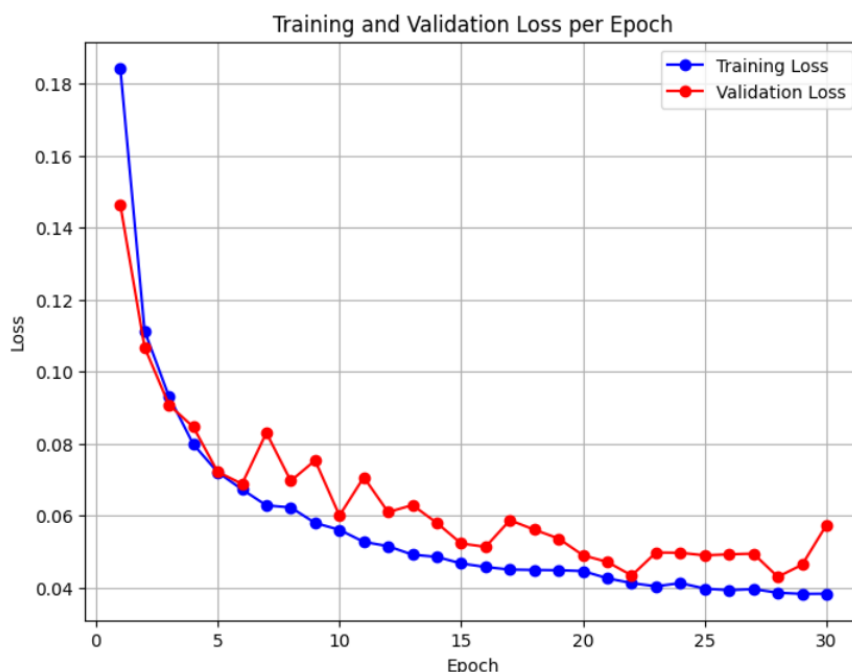


Рисунок 4.10 – Графік залежності навчання та валідації базового автокодувальника

Втрати при валідації близькі до втрат при навчанні, що свідчить про те, що модель ефективно виокремлює значущі закономірності з даних без значного перенавчання. Однак спостерігаються незначні відхилення між втратами при навчанні та валідації, які можна пояснити стохастичною природою оновлення вагових коефіцієнтів або ефектом пакетної нормалізації. У пізніші епохи невеликі піки втрат при валідації стають більш помітними, тоді як втрати при навчанні продовжують зменшуватися. Це явище свідчить про те, що модель починає перенавчатися, оскільки вона далі оптимізується під навчальну вибірку. Величина цих флуктуацій залишається відносно невеликою, що означає, що перенавчання не є серйозним.

Вхідні та реконструйовані за допомогою автокодувальника скани хребців приведено на рисунку 4.11.



Рисунок 4.11 – Вхідні та реконструйовані за допомогою автокодувальника скани хребців

Автокодувальники за своєю природою схильні до згладжування зображень, оскільки вони навчаються представляти дані у зменшеному латентному просторі. Високочастотні компоненти, такі як чіткі контури та текстурні деталі, можуть бути втрачені під час кодування-декодування, особливо якщо латентний простір занадто малий. Розмиття реконструйованих зображень вказує на певні обмеження автокодувальника у збереженні високочастотної інформації. Для покращення результатів реконструкції у подальших дослідженнях запропоновано:

- збільшити розмір латентного простору для кращого представлення деталей;
- використовувати більш складні архітектури декодера, такі як U-Net або глибші згорткові мережі;
- застосувати перцепційні втрати (perceptual loss) або комбінацію MSE і SSIM, щоб модель зберігала не лише піксельну подібність, але й структурні особливості;

– використовувати додаткові методи післяобробки, такі як суперрезолюція, для покращення чіткості відновлених зображень.

Після навчання, валідації та тестування автокодувальника важливим етапом у вирішенні задачі детекції аномалій є визначання порогу втрат реконструкції моделі. Для цього використаємо J-статистику Юдена, що максимізує розділення між нормальними та аномальними даними та не потребує попередніх знань про розподіл даних. Гістограма розподілу значень функції втрат для виявлення аномалій за J-статистикою Юдена приведено на рисунку 4.12.

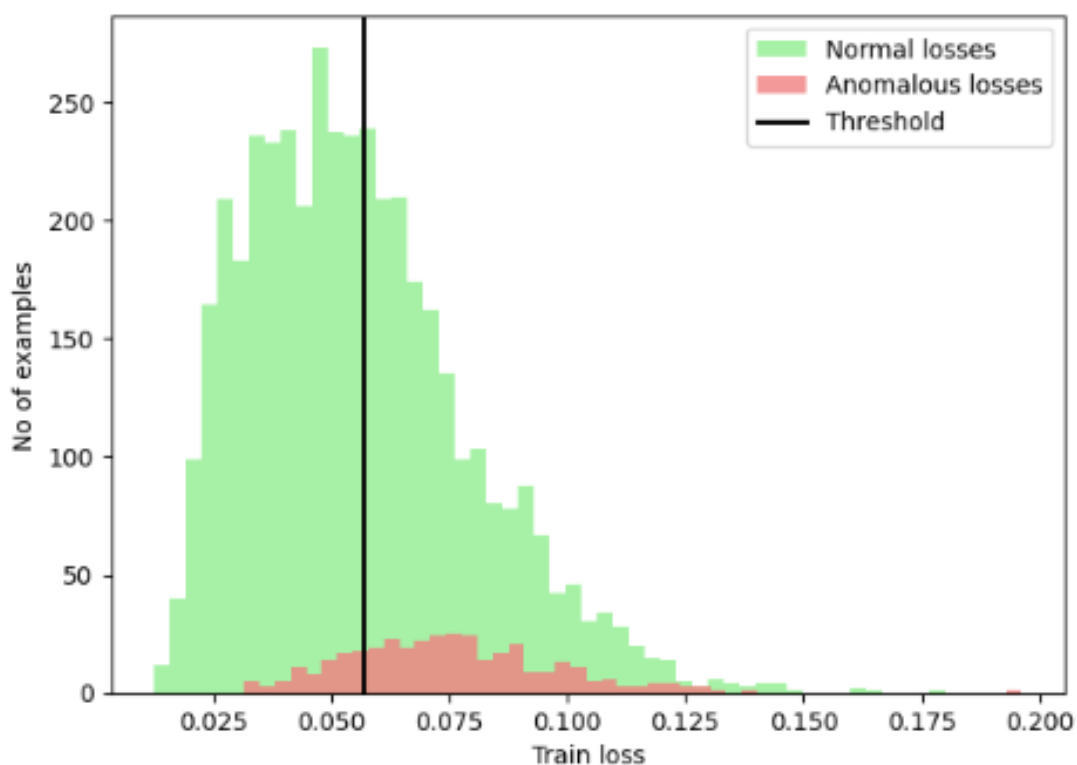


Рисунок 4.12 – Гістограма розподілу значень функції втрат для виявлення аномалій

Основна маса нормальних зразків має низькі втрати, з піком приблизно на рівні 0.05. Втрати розподілені асиметрично, із довгим правим хвостом, що свідчить про наявність частини нормальних зразків з дещо

вищими втратами. Аномальні зразки мають значно вищі втрати, що вказує на їхню суттєву відмінність від нормальних. Втрати аномалій варіюються в широкому діапазоні, що може свідчити про різний ступінь їхнього відхилення від нормального розподілу. Встановлений поріг (~ 0.056) розділяє нормальні та аномальні зразки. На рисунку N приведено ROC (Receiver Operating Characteristic) – графік, що показує, як змінюється співвідношення між чутливістю (Sensitivity), або TPR, та специфічністю (Specificity), або FPR.

Значення метрики AUC (Area Under the Curve) (рисунок 4.13), розрахованої як площа під графіком ROC, було досягнуто 0.7374%.




Рисунок 4.13 – Графік співвідношення між чутливістю та специфічністю

4.5.2 Розробка, реалізація автокодувальника з перцепційною функцією втрат

Із метою реалізації автокодувальника із перцепційною функцією втрат у якості екстрактору ознак використано попередньо навчену модель VGG16. Перші кілька згорткових шарів VGG16 зберігаються для вилучення ознак середнього рівня, як приведено у лістину 4.1. Екстрактор ознак заморожено, щоб запобігти його оновленню під час навчання. Оскільки VGG16 навчається на RGB-зображеннях, зображення у відтінках сірого перетворено на триканальні шляхом повторення одноканального зображення. Перцепційна втрата обчислюється як середньоквадратична похибка між цими зображеннями ознак. Функцією сумарних втрат у даному випадку буде зважена комбінація втрат MSE (для точності на рівні пікселів) і перцептивних втрат (для високого рівня схожості).

Лістинг 4.1 – Програмний код перцептивної функції втрат

```
class PerceptualLoss(nn.Module):
    def __init__(self):
        super(PerceptualLoss, self).__init__()
        vgg = models.vgg16(pretrained=True).features
        self.vgg_layers = nn.Sequential(*list(
            vgg.children())[:9])
        for param in self.vgg_layers.parameters():
            param.requires_grad = False
        self.criterion = nn.MSELoss()

    def forward(self, x, y):
        x = torch.cat([x] * 3, dim=1)
        y = torch.cat([y] * 3, dim=1)
        x_features = self.vgg_layers(x)
        y_features = self.vgg_layers(y)
        return self.criterion(x_features, y_features)
```

На рисунку 4.14 наведено графік залежності навчання та валідації автокодувальника із перцептивною функцією втрат. Із графіку видно, що втрати тренування та валідації стабільно зменшуються із кількістю епох. Приблизно на епосі 10–15 втрати при навчанні стабілізуються, що свідчить про те, що модель навчилася розпізнавати більшість ознак, які вона може виділити. Однак із графіка видно, що 30 епох недостатньо для навчання наведеної моделі автокодувальника на вхідних даних через використання більш складної перцептивної функції втрат (underfitting). Це вказує на те, що модель потребує більшої кількості епох для повної адаптації до високорівневих ознак, які враховуються при обчисленні перцептивної помилки.




Рисунок 4.14 – Графік залежності навчання та валідації автокодувальника із перцептивною функцією втрат

Вхідні та реконструйовані за допомогою автокодувальника скани хребців та розподіл значень функції втрат приведено на рисунках 4.15, 4.16.



Рисунок 4.15 – Вхідні та реконструйовані за допомогою автокодувальника із перцептивними втратами скани хребців




Рисунок 4.16 – Гістограма розподілу значень функції втрат для виявлення аномалій автокодувальником із перцепційними втратами

З гістограми (рисунок 4.16) видно, що більшість вибірок мають низькі втрати при реконструкції, що свідчить про те, що автокодувальник успішно реконструює більшість точок даних. Більшість нормальних зразків мають

втрати в діапазоні 0.005 – 0.02, що означає, що модель добре реконструює ці зразки. Аномальні втрати здебільшого починаються після порогового значення (≈ 0.02), що може вказувати на суттєві відмінності між аномальними та нормальними прикладами. Автокодувальник ефективно розрізняє нормальні та аномальні приклади, оскільки розподіли втрат для цих двох класів чітко розділені. Поріг, встановлений на значенні втрат близько 0.02, є ефективним для класифікації прикладів як аномальних чи нормальних, однак є деяке перекриття між розподілами втрат, що може призвести до помилкової класифікації деяких прикладів.

Спостережуване значення $AUC=0.8571$ (рисунок 4.17) свідчить про те, що автокодувальник добре диференціює нормальні та аномальні випадки.




Рисунок 4.17 – ROC-крива автокодувальником із перцепційними втратами

4.5.3 Розробка, реалізація варіаційного автокодувальника

Варіаційний автокодувальник є генеративною моделлю, що поєднує автокодувальники та байєсівські методи. Основною відмінністю від класичних автокодувальників є стохастична природа латентного простору, що забезпечує здатність до генерації нових зразків. Відмінністю від класичного автокодувальника (AE) є те, що замість прямого кодування в латентний простір, VAE апроксимує латентне представлення за допомогою розподілів і застосовує «прийом репараметризації», або «прийом перетворення» (приведено у лістингу 4.2) для вибірки латентних змінних. Після кодувальника модель містить два лінійних шари, які обчислюють середнє та логарифм дисперсії для кожного елемента в латентному просторі. Ці значення будуть використані для вибірки латентного вектора за допомогою прийому перетворення (reparameterization trick).

Лістинг 4.2 – Програмний код репаратметризації у варіаційному автокодувальнику

```
def reparameterize(self, mu, logvar):
    """Reparameterization trick to sample from N(mu,
    sigma)"""
    std = torch.exp(0.5 * logvar)
    eps = torch.randn_like(std)
    return mu + eps * std

def forward(self, x):
    encoded = self.encoder(x)
    encoded = encoded.view(encoded.size(0), -1)
    mu = self.fc_mu(encoded)
    logvar = self.fc_logvar(encoded)
    z = self.reparameterize(mu, logvar)
    decoded = self.fc_decode(z).view(-1, 256, 2, 2)
    decoded = self.decoder(decoded)
    return decoded, mu, logvar
```

Продовження лістингу 4.2

```
def loss_function(self, recon_x, x, mu, logvar):
    recon_loss=F.mse_loss(recon_x,x, reduction='sum')
    kl_div = -0.5 * torch.sum(1 + logvar - mu.pow(2) -
    logvar.exp())
    return recon_loss + kl_div
```

Графік залежності навчання та валідації варіаційного автокодувальника із сумарної втратою MSE та відносною ентропією (KL-дивергенція) приведено на рисунку 4.18.




Рисунок 4.18 – Графік залежності навчання та валідації варіаційного автокодувальника із сумарної втратою MSE та відносною ентропією

Із графіку видно, що втрати тренування та валідації стабільно зменшуються із кількістю епох. Втрати при навчанні стабілізуються, що свідчить про те, що модель навчилася розпізнавати більшість ознак, які вона може виділити.

Вхідні та реконструйовані за допомогою варіаційного автокодувальника скани хребців приведено на рисунку 4.19.



Рисунок 4.19 – Вхідні та реконструйовані за допомогою варіаційного автокодувальника скани хребців

З гістограми (рисунку 4.20) видно, що більшість вибірок мають низькі втрати при реконструкції, що свідчить про те, що автокодувальник успішно реконструює більшість точок даних.




Рисунок 4.20 – Гістограма розподілу значень функції втрат для виявлення аномалій варіаційним автокодувальником

Аномальні приклади мають значно вищі значення втрат порівняно з нормальними прикладами; розподіл аномальних прикладів зміщений вправо, з більшою кількістю прикладів у діапазоні від 0.02 до 0.04. Існує значне перекриття між розподілами нормальних та аномальних прикладів, особливо в діапазоні від 0.02 до 0.03. Варіаційний автокодувальник демонструє деяку здатність розрізняти нормальні та аномальні приклади, але з меншою чіткістю порівняно з автокодувальником із перцепційними втратами. Значне перекриття між розподілами нормальних та аномальних прикладів свідчить про те, що VAE може мати труднощі з точним виявленням деяких аномалій.

Поріг, встановлений на значенні втрат близько 0.022, може призвести до високого рівня помилкових негативних результатів (аномальні приклади, класифіковані як нормальні). Спостережуване значення $AUC=0.839$ (рисунок 4.21) свідчить про те, що автокодувальник добре диференціює нормальні та аномальні випадки.




Рисунок 4.21 – ROC-крива варіаційного автокодувальника

4.6 Тестування та порівняльний аналіз результатів

Наведені вище автокодувальні нейромережеві моделі було натреновано та протестовано; для об'єктивної оцінки продуктивності моделей було використано додаткові метрики, а саме: середньоквадратична помилка (MSE), пікове відношення сигнал-шум (PSNR), індекс структурної подібності (SSIM) та середня абсолютна помилка (MAE). З метою визначення порога детектування аномалій для зазначених моделей було використано J-статистику Юдена, що максимізує розділення між нормальними та аномальними даними та не потребує попередніх знань про розподіл даних. Зазначені метрики для кожної з моделей наведено у таблиці 4.2.

Таблиця 4.2 – Ефективність роботи обраних методів ШІ

| Model/Metric | AUC | MSE | PSNR [dB] | SSIM | MAE |
|---|-------|-------|--------------|-------|-------|
| Vanilla Autoencoder | 0.737 | 0.057 | 18.65 | 0.409 | 0.173 |
| Autoencoder with Perceptual loss | 0.857 | 0.019 | 23.59 | 0.640 | 0.098 |
| Variational autoencoder | 0.839 | 0.025 | 22.35 | 0.570 | 0.114 |

Згідно з проведеним аналізом, моделі продемонстрували різні рівні ефективності за кожною з оцінюваних метрик.

Базовий автокодувальник показав найгірші результати за всіма метриками. Значення AUC для цієї моделі становить 0.737, MSE - 0.057, MAE - 0.173, PSNR - 18.65 дБ, SSIM - 0.409. Дані показники свідчать про низьку здатність моделі розрізняти позитивні та негативні випадки, високий рівень помилок у прогнозуванні та низьку якість відновлених зображень. Базовий автокодувальник є базовою

архітектурою, яка не враховує перцептивні особливості даних або ймовірнісні аспекти, що обмежує її здатність ефективно відновлювати складні структури та деталі зображень. Розмиття реконструйованих зображень вказує на певні обмеження автокодувальника у збереженні високочастотної інформації.

Автокодувальник з перцепційною функцією втрат виявився найбільш ефективним, демонструючи найкращі результати за всіма метриками. Зокрема, ця модель досягла найвищого значення AUC (0.857), що свідчить про її високу здатність розрізняти позитивні та негативні випадки. Крім того, вона показала найнижчі значення MSE (0.019) та MAE (0.098), що вказує на мінімальні середні помилки у прогнозуванні. Високі значення PSNR (23.59 дБ) та SSIM (0.640) підтверджують високу якість відновлених зображень з точки зору низького рівня шуму та високої структурної подібності з оригінальними зображеннями. Покращення продуктивності цієї моделі можна обґрунтувати використанням перцептивної функції втрат, яка враховує особливості предметної галузі, що дозволяє моделі ефективніше зберігати контури, рівень стиснення/стенозу мозкового каналу, відповідно присутність та важкість аномалії.

Варіаційний автокодувальник також продемонстрував позитивні результати, але дещо поступається автокодувальнику з перцепційною функцією втрат. Значення AUC для цієї моделі становить 0.839, MSE - 0.025, MAE - 0.114, PSNR - 22.35 дБ, SSIM - 0.570. Варіаційний автокодувальник використовує ймовірнісний підхід до кодування та декодування даних, що може призводити до деяких втрат деталей при відновленні зображень, але забезпечує можливість генерації нових зразків. Варіаційний автокодувальник генерує більш розмиті контури, що призводить до меншої точності у вимірюванні тяжкості каналного стенозу.

4.7 Перспективи подальшого дослідження

Результати проведеного дослідження демонструють перспективність застосування автокодувальних нейромереж у поєднанні з детекцією об'єктів для автоматизованого виявлення аномалій на МРТ-зображеннях опорно-рухового апарату. З метою подальшого розвитку та впровадження даної технології в клінічну практику у подальших дослідженнях запропоновано:

- розробка та інтеграція 3D-детекторів об'єктів для аналізу просторових МРТ-даних;
- дослідження та адаптація новітніх архітектур автокодувальників, таких як трансформери та графові нейронні мережі, генеративних змагальних нейромереж;
- застосування методів пояснювального ШІ (XAI) для візуалізації та інтерпретації результатів виявлення аномалій;
- розробка карт активації та використання механізмів уваги з метою виділення важливих областей МРТ-зображень;
- застосувати перцепційні втрати (perceptual loss) або комбінацію MSE і SSIM, щоб модель зберігала не лише піксельну подібність, але й структурні особливості.

ВИСНОВКИ

В процесі виконання даної кваліфікаційної роботи було досліджено проблему виявлення аномалій захворювань опорно-рухової системи засобами обчислювального інтелекту. Було проведено огляд та аналіз існуючих методів обробки медичних зображень, визначено проблеми та обмеження обробки зображень магнітно-резонансної томографії методами обчислювального інтелекту.

В результаті виконання даної роботи було розроблено методологію виявлення аномалій на МРТ-зображеннях опорно-рухового апарату, що поєднує детекцію об'єктів засобами архітектури YOLOv8 з автокодувальними неймережами. З урахуванням визначених обмежень було реалізовано методи неконтрольованого навчання: розроблено базовий автокодувальник, автокодувальник із перцепційною функцією втрат та варіаційний автокодувальник. Для визначення порогу задачі детекції аномалій використано J-статистику Юдена, що максимізує розділення між нормальними та аномальними даними та не потребує попередніх знань про розподіл даних. Проведено порівняльний аналіз розробленої системи обчислювального інтелекту із використанням набору даних дегенеративних захворювань поперекового відділу хребта. Базовий автокодувальник продемонстрував найгірші результати у виявленні аномалій, що підтверджує його обмежену здатність до ефективного відновлення складних структур зображень. Використання автокодувальника з перцепційною функцією втрат істотно покращило якість відновлення, що свідчить про важливість врахування особливостей предметної галузі. Зокрема, ця модель досягла найвищого значення AUC (0.857), що свідчить про її високу здатність розрізняти позитивні та негативні випадки. Крім того, вона показала найнижчі значення MSE (0.019) та MAE (0.098), що вказує на мінімальні середні помилки у прогнозуванні. Варіаційний автокодувальник, попри його здатність до генерації нових зразків, показав дещо нижчі

результати порівняно з перцепційним автокодувальником, що вказує на компроміс між генеративною здатністю та точністю відновлення. Варіаційний автокодувальник генерує більш розмиті контури, що призводить до меншої точності у вимірюванні тяжкості каналного стенозу.

Новітність даної роботи полягає в розробленій методології виявлення аномалій на МРТ-зображеннях опорно-рухового апарату, що поєднує детекцію об'єктів (YOLO) з автокодувальними неймережами для ефективного виявлення аномалій в умовах дисбалансу даних, та враховує ряд обмежень, характерних для аналізу МРТ сканів хребта.

Запропоновану методологію реалізовано мовою програмування Python. З метою вирішення задачі об'єктного детектування було використано технологію трансферного навчання, а саме – натреновано модель YOLOv8 для детектування хребців сагітальної площини хребта. Моделі неконтрольованого навчання було реалізовано та протестовано з використанням бібліотек PyTorch, scikit-learn.

В результаті виконання роботи було досліджено та вирішено поставлену проблему і розглянуто перспективи подальшого розвитку.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1) Chandola V., Banerjee A., Kumar V. Anomaly detection. *ACM computing surveys*. 2009. Т. 41, № 3. С. 1–58. URL: <https://doi.org/10.1145/1541880.1541882> (дата звернення: 15.09.2024).

2) A survey on concept drift adaptation / J. Gama та ін. *ACM computing surveys*. 2014. Т. 46, № 4. С. 1–37. URL: <https://doi.org/10.1145/2523813> (дата звернення: 21.10.2024).

3) Ahmed M., Naser Mahmood A., Hu J. A survey of network anomaly detection techniques. *Journal of network and computer applications*. 2016. Т. 60. С. 19–31. URL: <https://doi.org/10.1016/j.jnca.2015.11.016> (дата звернення: 21.10.2024).

4) Botnari A., Kadar M., Patrascu J. M. Considerations on image preprocessing techniques required by deep learning models. the case of the knee mris. *Maedica - A journal of clinical medicine*. 2024. Т. 19, № 3. URL: <https://doi.org/10.26574/maedica.2024.19.3.526> (дата звернення: 21.10.2024).

5) Islam M., Khan K. N., Khan M. S. Evaluation of preprocessing techniques for u-net based automated liver segmentation. *2021 international conference on artificial intelligence (ICAI)*, м. Islamabad, Pakistan, 5–7 квіт. 2021 р. 2021. URL: <https://doi.org/10.1109/icai52203.2021.9445204> (дата звернення: 03.11.2024).

6) A review of deep learning in medical imaging: imaging traits, technology trends, case studies with progress highlights, and future promises / S. K. Zhou та ін. *Proceedings of the IEEE*. 2021. Т. 109, № 5. С. 820–838. URL: <https://doi.org/10.1109/jproc.2021.3054390> (дата звернення: 03.11.2024).

7) A review of medical image data augmentation techniques for deep learning applications / P. Chlap та ін. *Journal of medical imaging and radiation*

oncology. 2021. Т. 65, № 5. С. 545–563. URL: <https://doi.org/10.1111/1754-9485.13261> (дата звернення: 03.11.2024).

8) A comparative evaluation of outlier detection algorithms: experiments and analyses / R. Domingues та ін. *Pattern recognition*. 2018. Т. 74. С. 406–421. URL: <https://doi.org/10.1016/j.patcog.2017.09.037> (дата звернення: 03.11.2024).

9) Goldstein M., Uchida S. A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data. *Plos one*. 2016. Т. 11, № 4. С. e0152173. URL: <https://doi.org/10.1371/journal.pone.0152173> (дата звернення: 03.11.2024).

10) Grubbs F. E. Procedures for detecting outlying observations in samples. *Technometrics*. 1969. Т. 11, № 1. С. 1–21. URL: <https://doi.org/10.1080/00401706.1969.10490657> (дата звернення: 07.12.2024).

11) Ronneberger O., Fischer P., Brox T. U-Net: convolutional networks for biomedical image segmentation. *Lecture notes in computer science*. Cham, 2015. С. 234–241. URL: https://doi.org/10.1007/978-3-319-24574-4_28 (дата звернення: 07.12.2024).

12) Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion / P. Vincent et al. *Journal of machine learning research*. 2010. Vol. 11, no. 12. URL: <https://jmlr.org/papers/v11/vincent10a.html> (дата звернення: 11.01.2025).

13) Learning sparse representation with variational auto-encoder for anomaly detection / J. Sun та ін. *IEEE access*. 2018. Т. 6. С. 33353–33361. URL: <https://doi.org/10.1109/access.2018.2848210> (дата звернення: 07.12.2024).

14) Unsupervised pathology detection in medical images using conditional variational autoencoders / H. Uzunova та ін. *International journal of computer assisted radiology and surgery*. 2018. Т. 14, № 3. С. 451–461. URL: <https://doi.org/10.1007/s11548-018-1898-0> (дата звернення: 07.03.2025).

15) Deep Autoencoding Models for Unsupervised Anomaly Segmentation in Brain MR Images / С. Baur та ін. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham, 2019. С. 161–169. URL: https://doi.org/10.1007/978-3-030-11723-8_16 (дата звернення: 07.03.2025).

16) Štepec D., Skočaj D. Image synthesis as a pretext for unsupervised histopathological diagnosis. *Simulation and synthesis in medical imaging*. Cham, 2020. С. 174–183. URL: https://doi.org/10.1007/978-3-030-59520-3_18 (дата звернення: 07.03.2025).

17) Unsupervised anomaly detection via generative adversarial networks / H. Wang та ін. *IPSN '19: the 18th international conference on information processing in sensor networks*, м. Montreal Quebec Canada. New York, NY, USA, 2019. URL: <https://doi.org/10.1145/3302506.3312605> (дата звернення: 07.03.2025).

18) Memorizing normality to detect anomaly: memory-augmented deep autoencoder for unsupervised anomaly detection / D. Gong та ін. *2019 IEEE/CVF international conference on computer vision (ICCV)*, м. Seoul, Korea (South), 27 жовт. – 2 листоп. 2019 р. 2019. URL: <https://doi.org/10.1109/iccv.2019.00179> (дата звернення: 09.02.2025).

19) MADGAN: unsupervised medical anomaly detection GAN using multiple adjacent brain MRI slice reconstruction / С. Хан та ін. *BMC bioinformatics*. 2021. Т. 22, S2. URL: <https://doi.org/10.1186/s12859-020-03936-1> (дата звернення: 09.02.2025).

20) Outlier detection and removal improves accuracy of machine learning approach to multispectral burn diagnostic imaging / W. Li та ін. *Journal of biomedical optics*. 2015. Т. 20, № 12. С. 121305. URL: <https://doi.org/10.1117/1.jbo.20.12.121305> (дата звернення: 09.02.2025).

21) PCA leverage: outlier detection for high-dimensional functional magnetic resonance imaging data / A. F. Mejia та ін. *Biostatistics*. 2017. Т. 18,

№ 3. С. 521–536. URL: <https://doi.org/10.1093/biostatistics/kxw050> (дата звернення: 09.02.2025).

22) Kim C.-M., Hong E. J., Park R. C. Chest x-ray outlier detection model using dimension reduction and edge detection. *IEEE access*. 2021. Т. 9. С. 86096–86106. URL: <https://doi.org/10.1109/access.2021.3086103> (дата звернення: 09.02.2025).

23) Burn injury diagnostic imaging device's accuracy improved by outlier detection and removal / W. Li та ін. *SPIE defense + security*, м. Baltimore, Maryland, United States / ред.: M. Velez-Reyes, F. A. Kruse. 2015. URL: <https://doi.org/10.1117/12.2177433> (дата звернення: 09.02.2025).

24) Tax D. M. J., Duin R. P. W. Uniform object generation for optimizing one-class classifiers // *Journal of machine learning research*. – 2001. – Т. 2. – №. Dec. – С. 155-173.

25) Efficient anomaly detection with generative adversarial network for breast ultrasound imaging / T. Fujioka та ін. *Diagnostics*. 2020. Т. 10, № 7. С. 456. URL: <https://doi.org/10.3390/diagnostics10070456> (дата звернення: 09.02.2025).

26) A novel dynamic hyper-graph inference framework for computer assisted diagnosis of neuro-diseases / Y. Zhu та ін. *Lecture notes in computer science*. Cham, 2017. С. 158–169. URL: https://doi.org/10.1007/978-3-319-59050-9_13 (дата звернення: 23.03.2025).

27) Viral pneumonia screening on chest x-rays using confidence-aware anomaly detection / J. Zhang та ін. *IEEE transactions on medical imaging*. 2020. С. 1. URL: <https://doi.org/10.1109/tmi.2020.3040950> (дата звернення: 23.03.2025).

28) Unsupervised anomaly detection via generative adversarial networks / H. Wang та ін. *IPSN '19: the 18th international conference on information processing in sensor networks*, м. Montreal Quebec Canada. New York, NY, USA, 2019. URL: <https://doi.org/10.1145/3302506.3312605> (дата звернення: 09.02.2025).

29) Applications of generative adversarial networks in anomaly detection: a systematic literature review / М. Sabuhi та ін. *IEEE access*. 2021. Т. 9. С. 161003–161029. URL: <https://doi.org/10.1109/access.2021.3131949> (дата звернення: 23.03.2025).

30) Convolutional Autoencoders URL: <https://swarbrickjones.wordpress.com/2015/04/29/convolutional-autoencoders-in-pythontheanolasagne/> (дата звернення: 09.09.2024).

31) Li J., Luong T., Jurafsky D. A hierarchical neural autoencoder for paragraphs and documents. Proceedings of the 53rd annual meeting of the association for computational linguistics and the 7th international joint conference on natural language processing (volume 1: long papers), м. Beijing, China. Stroudsburg, PA, USA, 2015. URL: <https://doi.org/10.3115/v1/p15-1107> (дата звернення: 23.03.2025).

32) Johnson L. Localisation and management of respiratory distress. *BSAVA congress proceedings 2016*. С. 192. URL: <https://doi.org/10.22233/9781910443446.18.4> (дата звернення: 23.03.2025).

33) Variational Autoencoder URL: <https://www.geeksforgeeks.org/variational-autoencoders/> (дата звернення: 23.03.2025)

34) J L. S., Joy E., M S S. R. Enhanced radiological anomaly detection using optimized YOLO-NAS model. *2024 international conference on advances in modern age technologies for health and engineering science (AMATHE)*, м. Shivamogga, India, 16–17 трав. 2024 р. 2024. URL: <https://doi.org/10.1109/amathe61652.2024.10582157> (дата звернення: 23.03.2025).

35) Hashemi S. M. H., Safari L., Taromi A. D. Realism in action: anomaly-aware diagnosis of brain tumors from medical images using YOLOv8 and DeiT //arXiv preprint arXiv:2401.03302. – 2024.

36) Sobek J. et al. MedYOLO: a medical image object detection framework // *Journal of Imaging Informatics in Medicine*. 2024. С. 1–9.

37) You only look once: unified, real-time object detection / J. Redmon та ін. *2016 IEEE conference on computer vision and pattern recognition (CVPR)*, м. Las Vegas, NV, USA, 27–30 черв. 2016 р. 2016. URL: <https://doi.org/10.1109/cvpr.2016.91> (дата звернення: 23.01.2025).

38) «RSNA 2024 Lumbar Spine Degenerative Classification». URL: <https://www.kaggle.com/competitions/rsna-2024-lumbar-spine-degenerative-classification/data> (дата звернення: 09.09.2024).

39) Spinal Stenosis. URL: <https://lakeeffectchiro.com/blog/all-about-spinal-stenosis> (дата звернення: 11.10.2024).

40) Lumbar spinal stenosis: review update 2022 / J.-w. Kwon та ін. *Asian spine journal*. 2022. URL: <https://doi.org/10.31616/asj.2022.0366> (дата звернення: 15.03.2025).

41) Smith Z. A., Asgarzadie F., Khoo L. T. Minimally invasive spinal surgery (MISS) techniques for the decompression of lumbar spinal stenosis. *The comprehensive treatment of the aging spine*. 2011. С. 388–395. URL: <https://doi.org/10.1016/b978-1-4377-0373-3.10059-4> (дата звернення: 23.03.2025).

42) Classification of the normal variation in the sagittal alignment of the human lumbar spine and pelvis in the standing position / P. Roussouly та ін. *Spine*. 2005. Т. 30, № 3. С. 346–353. URL: <https://doi.org/10.1097/01.brs.0000152379.54463.65> (дата звернення: 17.12.2024).

43) Derevianko I., Bondarev S., Zolotukhin O. Research on unsupervised anomaly detection in spinal mri: advancing autoencoder-based reconstruction methods //The 9th International scientific and practical conference “Development of innovation systems: trends, challenges, prospects”(March 04–07, 2025) Hamburg, Germany. International Science Group. 2025. 364 p. – 2025. – С. 51.

44) Аврунін О. Г., Бодянський Є. В., Семенець В. В., Філатов В. О., Шушляпіна Н. О. Інформаційні технології підтримки прийняття рішень при

визначенні порушень носового дихання: монографія: – Харків: ХНУРЕ, 2018. – 132 с.

45) Руденко О. Г. Штучні нейронні мережі : навч. посібник / Є. В. Бодянський, О. Г. Руденко. – Харків : СМІТ, 2006. – 404 с.

46) Дерев'янку І., Бондарев С. Практичне дослідження алгоритмів перехресної перевірки (Cross-validation) з використанням інструментарію Scikit-learn на Python // *Scientific Collection «InterConf»*. – 2022. – №. 136. – С. 382-390.