Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Центр післядипломної освіти
(повна назва)
Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Технології інтелектуального аналізу мамограм в онкології

(тема)

Виконав:
здобувач другого року навчання,
групи СШІздм-24-1
Богдан ФЕДАК
(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. Лілія АВЕР'ЯНОВА
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ _____ Лариса ЧАЛА
(підпис) (власне ім'я, прізвище)

2026 р.

Харківський національний університет радіоелектроніки

Факультет Центр післядипломної освіти

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 Федаку Богдану Максимовичу
(прізвище, ім'я, по батькові)

1. Тема роботи Технології інтелектуального аналізу мамограм в онкології

затверджена наказом університету від 1 травня 20 26 р. № 63Стз

2. Термін подання здобувачем роботи до екзаменаційної комісії 26 травня 20 26 р.

3. Вихідні дані до роботи Верифікований набір медичних даних повноформатних цифрових мамограм, цифрові рентгенівські знімки молочної залози у графічних та медичних форматах, клінічні мітки класів патологій, що визначають наявність доброякісних або злоякісних новоутворень, теоретичний та математичний апарат глибокого машинного навчання, методи цифрової обробки зображень, інструментальні засоби розробки та бібліотеки побудови графічного інтерфейсу користувача

4. Перелік питань, що потрібно опрацювати в роботі

1) Проаналізувати технології штучного інтелекту для аналізу мамограм в онкології
2) Дослідити та реалізувати методи попередньої обробки і стандартизації медичних знімків
3) Спроєктувати архітектуру нейронної мережі для класифікації новоутворень
4) Розробити та оптимізувати процес навчання моделі класифікації патологій
5) Програмно реалізувати застосунок із графічним інтерфейсом для лікаря-радіолога
6) Провести тестування системи та оцінити ключові метрики якості класифікації

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / термін виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	01.05.2026	виконано
2	Аналіз предметної області та постановка задачі	01.05.2026 - 05.05.2026	виконано
3	Аналіз методів щодо вирішення задачі	06.05.2026 - 11.05.2026	виконано
4	Вибір методу для вирішення поставленої задачі	12.05.2026 - 15.05.2026	виконано
5	Розробка базового прототипу	16.05.2026 - 18.05.2026	виконано
6	Розробка графічного інтерфейсу	19.05.2026 - 21.05.2026	виконано
7	Підготовка пояснювальної записки	22.05.2026 - 25.05.2026	виконано
8	Захист перед ЕК	26.05.2026	виконано

Дата видачі завдання 1 травня 20 26 р.

Здобувач _____
(підпис)

Керівник роботи _____ доц. Лілія АВЕР'ЯНОВА
(підпис) (посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 65 стор., 16 рис., 2 табл., 1 дод., 23 джерела.

АНАЛІЗ МАМОГРАМ, ІНТЕЛЕКТУАЛЬНА ОБРОБКА МЕДИЧНИХ ЗОБРАЖЕНЬ, КЛАСИФІКАЦІЯ НОВОУТВОРЕНЬ, МАШИННЕ НАВЧАННЯ.

Об’єкт дослідження – процес автоматизованого виявлення та класифікації новоутворень у мамографічних зображеннях.

Предмет дослідження – методи інтелектуального аналізу мамограм із застосуванням алгоритмів машинного навчання для класифікації новоутворень.

Мета роботи – дослідити точність та ефективність сучасних підходів до класифікації новоутворень на мамограмах та обґрунтувати вибір оптимального методу для практичного використання в медичній діагностиці.

Методи дослідження – вивчення наукових публікації, тестування моделей машинного навчання на медичних зображеннях, кількісна оцінка результатів і порівняльний аналіз класифікаційних алгоритмів.

ABSTRACT

Master’s thesis contains: 65 pp., 16 fig., 2 tabl., 1 ann., 23 sources.

INTELLIGENT MEDICAL IMAGE PROCESSING, MACHINE LEARNING, MAMMOGRAM ANALYSIS, TUMOR CLASSIFICATION.

Object of the study – the process of automated detection and classification of tumors in mammographic images.

Subject of the study – methods of intelligent analysis of mammograms using machine learning algorithms for tumor classification.

Aim of the work – to investigate the accuracy and efficiency of modern approaches to tumor classification in mammograms and to justify the selection of the most suitable method for practical use in medical diagnostics.

Research methods – review of scientific literature, testing of machine learning models on medical images, quantitative evaluation of results, and comparative analysis of classification algorithms.

ЗМІСТ

Перелік умовних позначень, символів, одиниць скорочень і термінів 7
Вступ 9
1 Огляд задачі класифікації медичних зображень 13
1.1 Опис задачі класифікації 13
1.2 Постановка задачі класифікації 17
1.3 Огляд методів класифікації зображень 17
2 Огляд алгоритмів та метрик для класифікації новоутворень 21
2.1 Застосування гібридних зображень у класифікації новоутворень 21
2.2 Аналіз алгоритмів класифікації пухлин 26
2.3 Вибір метрик оцінки моделі класифікації пухлин 33
3 Особливості реалізації програмного застосунку 37
3.1 Огляд вибраного набору даних 37
3.2 Попередня обробка даних 44
3.3 Навчання моделі та аналіз метрик 47
3.4 Практична реалізація та тестування програмного застосунку 53
Висновки 59
Перелік джерел посилання 62
Додаток А Відомість кваліфікаційної роботи 65

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ СКОРОЧЕНЬ І ТЕРМІНІВ

КТ – комп’ютерна томографія;

МРТ – магнітно-резонансна томографія;

ОФЕКТ – однофотонна емісійна комп’ютерна томографія;

ПЕТ – позитронно-емісійна томографія;

УЗД – ультразвукове дослідження;

ШІ – штучний інтелект;

BI-RADS – Breast Imaging-Reporting and Data System – система звітності та даних зображень молочної залози;

CBIS-DDSM – Curated Breast Imaging Subset of Digital Database for Screening Mammography – підготовлена підмножина зображень молочної залози із Цифрової бази даних скринінгової мамографії;

CLAHE – Contrast Limited Adaptive Histogram Equalization – адаптивне вирівнювання гістограми з обмеженням контрастності;

CNN – Convolutional Neural Network – згорткова нейронна мережа;

DICOM – Digital Imaging and Communications in Medicine – цифрові зображення та комунікації в медицині;

DL – Deep Learning – глибинне навчання;

DNN – Deep Neural Network – глибока нейронна мережа;

FFDM – Full-Field Digital Mammogram – повноформатна цифрова мамограма;

ROI – Region of Interest – область інтересу (частина зображення, яка підлягає аналізу);

RBF – Radial basis function – радіальна базисна функція;

ReLU – Rectified Linear Unit – випрямлений лінійний вузол;

ResNet – Residual Network – залишкова нейронна мережа;

ROC-крива – Receiver operating characteristic – робоча характеристика приймача;

ROC-AUC – Receiver Operating Characteristic Area Under the Curve – площа під кривою робочої характеристики приймача;

SVM – Support Vector Machine – метод опорних векторів.

ВСТУП

Актуальність теми зумовлена стрімким розвитком медичних технологій та сучасної науки. Зростання кількості випадків раку молочної залози та необхідність в ранньому виявленні новоутворень вимагають сучасних інструментів аналізу медичних знімків. Мамограми, як один з основних методів обстеження, потребують точного та швидкого аналізу. Застосування методів інтелектуальної обробки дозволяє значно підвищити рівень класифікації новоутворень. Особлива значущість цієї теми полягає у тому, що традиційні підходи до аналізу мамографічних зображень не завжди забезпечують необхідну достовірність при складних випадках.

Сфера інтелектуального аналізу медичних зображень набуває дедалі більшого значення у зв’язку з невпинним зростанням кількості діагностичних даних, які потребують якісного та швидкого опрацювання. Застосування сучасних обчислювальних підходів, зокрема глибинного навчання та алгоритмів машинного інтелекту, створює підґрунтя для побудови високоточних систем класифікації новоутворень. Мамограми, як інформативний інструмент раннього виявлення раку молочної залози, потребують інноваційних рішень, які дозволяють автоматизувати процес аналізу та підвищити його ефективність.

Таким чином, застосування інтелектуальних систем у сфері мамографії є важливою складовою сучасної медичної практики. Ці технології не лише розширюють можливості традиційної діагностики, але й створюють передумови для впровадження повністю автоматизованих платформ, здатних працювати у реальному часі. Важливість досліджень у цьому напрямку обумовлюється як клінічними потребами, так і прагненням до підвищення якості життя пацієнтів шляхом своєчасного виявлення онкологічних захворювань.

Проблематика інтелектуального аналізу мамограм із метою класифікації новоутворень охоплює низку важливих аспектів, які

потребують ґрунтового розгляду та вирішення в межах сучасної медичної практики.

Висока складність відмінності між доброякісними та злоякісними утвореннями: Через подібні візуальні характеристики деяких типів пухлин навіть сучасні системи можуть припускатися помилок. Це вимагає залучення складних моделей з багаторівневою обробкою ознак.

Високі вимоги до швидкодії систем: Зважаючи на потребу в оперативній діагностиці, інтелектуальні алгоритми повинні демонструвати не лише точність, але і здатність до роботи в реальному часі або з мінімальними затримками, що є ключовим критерієм для їх інтеграції у клінічні системи.

Неоднорідність мамографічних даних: мамограми можуть суттєво відрізнятись залежно від апаратури, умов обстеження, щільності тканин молочної залози та індивідуальних анатомічних особливостей пацієнтки. Така варіативність ускладнює розробку універсальних алгоритмів класифікації новоутворень.

Потреба в можливості пояснення рішень штучного інтелекту: У медичній сфері критично важливо не лише отримати результат, але й мати можливість інтерпретувати його. Алгоритми повинні супроводжуватись інструментами візуалізації рішень, щоб лікарі могли розуміти логіку класифікації новоутворень.

Низька точність класичних методів аналізу мамограм: Більшість традиційних підходів не забезпечують достатнього рівня достовірності, особливо при класифікації нетипових або ранніх стадій новоутворень. Це створює ризик для постановки некоректного діагнозу, що особливо критично в онкології.

У межах даного дослідження планується розв’язання таких завдань:

– аналіз сучасного рівня розвитку методів інтелектуальної обробки мамограм з метою виявлення новоутворень та класифікації змін тканин;

– проведення систематичного огляду існуючих підходів до автоматизованої діагностики на основі мамографічних зображень;

– визначення найбільш ефективного методу класифікації новоутворень із подальшим порівняльним тестуванням його результативності;

– створення та впровадження обраного підходу для практичного застосування з подальшою перевіркою його точності та продуктивності.

Метою роботи є дослідження точності та ефективності сучасних підходів до класифікації новоутворень на мамограмах та обґрунтування вибору оптимального методу для практичного використання в медичній діагностиці.

Об’єктом дослідження виступає процес автоматизованого виявлення та класифікації новоутворень у мамографічних зображеннях, а предметом є методи інтелектуального аналізу мамограм із застосуванням алгоритмів машинного навчання для класифікації новоутворень.

Об’єкт дослідження – процес автоматизованого виявлення та класифікації новоутворень у мамографічних зображеннях.

Предмет дослідження – методи інтелектуального аналізу мамограм із застосуванням алгоритмів машинного навчання для класифікації новоутворень.

Мета роботи – дослідити точність та ефективність сучасних підходів до класифікації новоутворень на мамограмах та обґрунтувати вибір оптимального методу для практичного використання в медичній діагностиці.

Методи дослідження охоплюють як теоретичні, так і практичні підходи. На першому етапі було здійснено аналіз наукових публікацій, що стосуються сучасних напрямів у галузі комп’ютерного зору, обробки медичних зображень та класифікації новоутворень за мамограмами. Далі проведено порівняння різних алгоритмів машинного навчання, які

застосовуються у задачах автоматизованої діагностики, з особливою увагою до їхньої точності, стійкості та швидкодії.

Особливу увагу приділено розробці та навчанні моделей глибинного навчання з використанням фреймворку TensorFlow. Створена модель проходила тестування на відкритих наборах мамографічних даних з метою оцінювання її здатності класифікувати новоутворення як доброякісні або злоякісні. Важливою частиною дослідження стала перевірка отриманих результатів і визначення ступеня придатності запропонованого підходу для використання у клінічній практиці.

Розроблена модель продемонструвала здатність автоматично класифікувати новоутворення з високою достовірністю, що підтверджує її практичну значущість у медичній галузі. Отримані результати свідчать про те, що застосування штучного інтелекту в аналізі мамограм можу суттєво знизити навантаження на лікарів, мінімізувати кількість діагностичних помилок і покращити своєчасність виявлення онкологічних патологій. У перспективі можливе розширення функціональності розробленої системи, зокрема інтеграція додаткових діагностичних ознак, використання мультизадачних архітектур та розробка інтерфейсів для безпосереднього використання в умовах медичних установ.

1 ОГЛЯД ЗАДАЧІ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ

1.1 Опис задачі класифікації

Класифікація зображень є однією з базових задач у сфері комп'ютерного зору, яка полягає у визначенні категорії, до якої належить усе зображення. Система аналізує вхідне зображення і на основі його візуальних характеристик відносить його до одного з наперед заданих класів. Наприклад, класи можуть означати тип об'єкта, його стан або будь-яку іншу категорію, залежно від мети застосування.

Процес класифікації зазвичай включає три основні етапи: попередня обробка зображення, виділення ознак та класифікація. Попередня обробка зображення включає зменшення шуму, нормалізацію яскравості або зміну розміру, що забезпечує стабільність аналізу. На етапі виділення ознак зображення аналізується на предмет візуальних патернів, текстур, форм або кольорів. У класичних підходах виділення ознак виконується вручну, але сучасні системи на основі глибинного навчання вміють виділяти ознаки автоматично. Протягом етапу класифікації система використовує алгоритми машинного навчання або нейронні мережі для прийняття рішення про те, до якого класу належить зображення.

Класифікація зображень на основі систем штучного інтелекту використовується в багатьох галузях. Наприклад, у сфері безпеки та спостереження класифікація дозволяє виявляти підозрілі об'єкти або поведінки в записах камер відеоспостереження. Автомобільна промисловість застосовує класифікацію для розпізнавання дорожніх знаків, пішоходів та інших транспортних засобів, що складає важливу складову автомобілів з керуванням в режимі автопілот (рисунок 1.1) [1]. Галузь роздрібної торгівлі та маркетингу за допомогою класифікації автоматично ідентифікує товари на полицях та відстежує рух покупців. Сільське господарство визначає вид рослини або стан посівів за знімками з дронів, а

мистецтво та культура класифікує картини за стилем, автором або жанром. Останнім часом все більше зростають обсяги використання класифікації зображень у соціальних мережах та медіа. Наприклад, для автоматичного сортування зображень, фільтрації вмісту стрічки новин та розпізнавання обличь.



Рисунок 1.1 – Класифікація учасників дорожнього руху в системі автономного керування транспортним засобом

У контексті медичної діагностики задача класифікації передбачає автоматичне визначення, чи є в зображенні ознаки доброякісної чи злоякісної пухлини, або ж патологія відсутня. Таких підхід дозволяє оперативно здійснювати первинне обстеження, підвищувати ефективність діагностики, знижувати ймовірність людської помилки та забезпечувати допоміжний інструмент для лікаря-рентгенолога. Завдяки застосуванню класифікації у медичних зображеннях з’являється можливість масштабного

автоматизованого оброблення даних, що особливо актуально у великих скринінгових програмах. Крім того, системи класифікації можуть служити у ролі другого незалежного експерта, особливо в умовах обмеженого доступу до висококваліфікованих спеціалістів, тобто лікарів.

Задачі класифікації можна поділити на кілька основних типів, кожен з яких має свої особливості.

Бінарна класифікація передбачає визначення, чи присутня патологія на зображенні чи ні. Це один із найпростіших варіантів класифікації, де зображення поділяються лише на два класи, наприклад пухлина виявлена чи пухлина відсутня. Таких підхід зручний для реалізації особливо коли обсяг навчальних даних обмежений. Він також дозволяє досягати високої чутливості, що критично важливо у програмах обстеження. Зокрема, під час масового профілактичного скринінгу такий алгоритм виконує роль ефективного первинного фільтра. Він здатний автоматично відсіювати однозначно здорові знімки, що суттєво знижує рутинне навантаження на лікарів-радіологів і дозволяє їм зосередити увагу виключно на підозрілих випадках. Утім, основним недоліком є те, що бінарна класифікація не дає змоги отримати деталізовану інформацію щодо типу новоутворення чи його природи. Такої класифікації може бути недостатньо для повноцінного клінічного рішення.

Мультикласова класифікація дозволяє розпізнавати декілька різних типів новоутворень, наприклад, розрізняти між фіброаденомою, кістою, кальцинатами чи злоякісною пухлиною. Приклад порівняння кісти, фіброаденоми та злоякісної пухлини наведено на рисунку 1.2 [2].

Такий підхід є більш інформативним і забезпечує глибший рівень аналізу, що дозволяє лікарям-радіологам приймати більш точні діагностичні рішення. Водночас реалізація мультикласових моделей складніша, оскільки потребує значно більшої кількості даних для кожного класу, а також здатності алгоритму розпізнавати тонкі візуальні відмінності. Крім того, якщо навчальна вибірка є незбалансованою, деякі класи можуть бути

представлені значно гірше, що негативно впливає на загальну точність моделі.

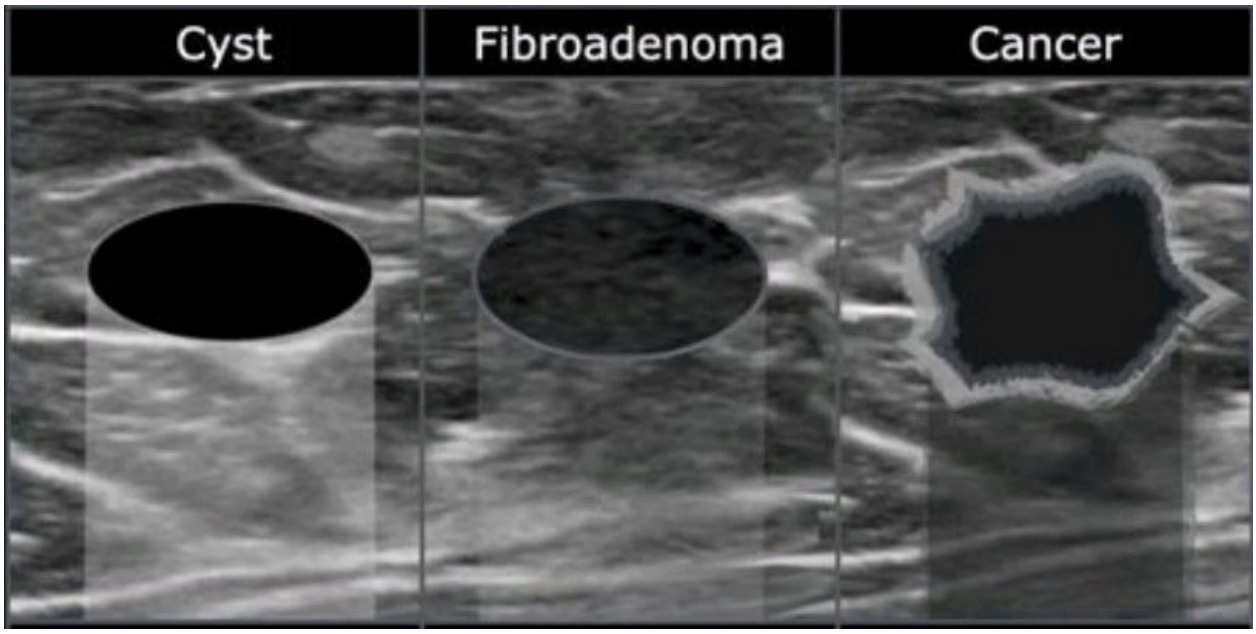


Рисунок 1.2 – Порівняння кісти, фіброаденоми та злоякісної пухлини (Cancer) на ультразвуковій візуалізації

Мультиміткова класифікація дозволяє одній мамограмі відповідати одразу відповідати кільком класам, що особливо актуально у випадках, коли на зображенні присутні декілька утворень різного типу. Така класифікація наближається до реального клінічного сценарію, де пацієнт може мати кілька діагностичних характеристик одночасно. Але мултиміткова класифікація значно складніша з технічної точки зору. Для її навчання потрібні добре анотовані дані з багатьма мітками, а для оцінки якості потрібні спеціалізовані метрики. Також існує ризик, що модель буде плутати класи, коли ті часто з’являються разом.

Класифікація за шкалою BI-RADS передбачає присвоєння зображенню одного з кількох індексів, які вказують на рівень підозри щодо злоякісності новоутворення. Така категорія класифікації широко застосовується у клінічній практиці. Ця класифікація є корисною тим, що

вона вже стандартизована і зрозуміла лікарям, тому може бути безпосередньо інтегрована у клінічну практику. Проте часто складно розрізняти між сусідніми рівнями BI-RADS навіть для досвідчених фахівців, оскільки межі між ними не завжди чіткі.

Класифікація локалізованих регіонів аналізує не повне зображення, а лише попередньо виділені ділянки, де є підозра на патологію. Такий підхід зазвичай поєднується з методами виявлення об'єктів або попередньої сегментації. Його основна перевага – це точність, оскільки аналіз зосереджується лише на релевантних ділянках. Однак він вимагає багатокрокової обробки зображень, що ускладнює побудову та тестування системи, а також підвищує обчислювальні витрати.

1.2 Постановка задачі класифікації

Нехай задано множину зображень $I = \{I_1, I_2, \dots, I_M\}$, де кожне зображення I_m є матрицею пікселів $\{p_{ij}^{(m)}\}$, які характеризуються координатами (i, j) та значеннями кольорових складових. Нехай також задано скінченну множину міток (класів) $C = \{c_1, c_2, \dots, c_K\}$, яка визначає тип або категорію кожного зображення (наприклад, «доброякісне», «злоякісне» тощо). Потрібно побудувати відображення $f: I \to C$, таке що для кожного зображення I_m воно ставить у відповідність єдиний клас $c_k \in C$. Метою класифікації є знайти таке відображення f, яке мінімізує ймовірність неправильного віднесення зображення до класу, тобто $f(I_m) = c_k$ для істинного класу c_k [3].

1.3 Огляд методів класифікації зображень

Нижче наведено основні методи класифікації зображень.

Метод k-ближчих сусідів. Цей метод є одним з найпростіших і водночас ефективних підходів до класифікації зображень, особливо коли

йдеться про невеликі вибірки або задачі з чіткими межами між класами. Ідея методі полягає в тому, що для класифікації нового зразка слід знайти k найближчих до нього об’єктів у просторі ознак і визначити клас більшості серед них.

Формально, маємо множину тренувальних зразків $\{(x_i, y_i)\}_{i=1}^{n}$, де $x_i \in \mathbb{R}^d$ – вектор ознак зображення, а $y_i \in \{1, \dots, C\}$ – його мітка класу. Для нового зразка x, відстань $d(x, x_i)$ обчислюється, найчастіше, за допомогою евклідової метрики:

$$d(x, x_i) = \sqrt{\Sigma_{j=1}^{d}(x_j - x_{ij})^2}. \quad (1.1)$$

Після визначення k найближчих сусідів, результатом класифікації буде клас, який трапляється серед них найчастіше. Однією з переваг методу є його інтерпретованість і простота реалізації. Однак він чутливий до вибору метрики відстані, кількості сусідів k та масштабу ознак. Висока складність обчислень при великій кількості зразків також може бути недоліком.

У контексті класифікації медичних зображень метод k-NN може бути застосований до векторів ознак, отриманих після попереднього етапу сегментації або вилучення дескрипторів зображення, таких як гістограма градієнтів, колірні гістограми чи інші статистичні характеристики текстур.

Підтримувальні векторні машини. Цей метод є потужним інструментом для двокласової і багатокласової класифікації. Основна ідея полягає в побудові гіперплощини, яка максимально розділяє приклади різних класів у просторі ознак. SVM шукає таку площину, яка максимізує відстань до найближчих точок навчальної вибірки – так званих підтримувальних векторів [4].

Для двокласової задачі, де мітки класів $y_i \in \{-1,1\}$, задача полягає у знаходженні вектора ваг w та зміщення b, що для всіх i задовольнають умову:

$$y_i(w^T x_i + b) \geq 1. \quad (1.2)$$

Оптимізаційна задача формулюється як:

$$min_{w,b} \frac{1}{2} \|w\|^2. \quad (1.3)$$

У випадку, коли дані не є лінійно роздільними, вводяться штрафні коефіцієнти або використовуються ярда, такі як RBF або поліноміальне ядро, для переходу у простір вищої розмірності, де розділення можливе [5].

Метод підтримувальних векторних машин добре працює на малих та середніх наборах даних і здатен створювати дуже точні моделі. Він менш ефективний при роботі з великими даними або при високій кількості ознак, якщо не використовуються методи зменшення розмірності. У задачах класифікації медичних зображень даний метод часто застосовується до наборів ознак, вилучених вручну або отриманих за допомогою автоматичних дескрипторів.

Штучні нейронні мережі. Даний метод є потужним інструментом для класифікації зображень, особливо в контексті обробки великих обсягів візуальних даних. Їхня основна перевага полягає у здатності автоматично виявляти складні залежності між вхідними піксельними значеннями та відповідними мітками класів, що дає змогу ефективно вирішувати задачі, з якими традиційні алгоритми не справляються [6].

Нейронна мережа складається з набору взаємопов’язаних обчислювальних одиниць, які називаються нейронами. Ці нейрони організовано в шари: вхідний шар приймає зображення у вигляді вектора або матриці піксельних значень, приховані шари виконують обробку та абстракцію ознак, а вихідний шар повертає передбачуваний клас або ймовірності належності до кількох класів. У типовому випадку нейрон кожного шару отримує на вхід значення з попереднього шару, перемножує їх з ваговими коефіцієнтами, додає зміщення (bias), а результат

обробляється нелінійною функцією активації, такою як ReLU (Rectified Linear Unit) чи сигмоїда [7].

Важливою властивістю штучних нейронних мереж є здатність до навчання, тобто адаптації ваг за допомогою алгоритму зворотного поширення помилки (backpropagation) у поєднанні з градієнтним спуском. Протягом навчання мережа мінімізує функцію втрат між передбаченими класами та реальними мітками. Це дозволяє поступово покращити якість класифікації навіть на дуже складних і високорозмірних вхідних даних.

Базові алгоритми машинного навчання є доведеними математичними інструментами, однак їхня ефективність критично залежить від якості попереднього ручного вилучення векторів ознак чи дескрипторів. У контексті інтелектуального аналізу складних медичних знімків, зокрема повноформатних мамограм, такий підхід є суттєвим обмеженням, оскільки класичні алгоритми часто не здатні вловити складні, приховані текстурні нюанси пухлин. Саме тому для досягнення високої точності в онкологічній діагностиці найбільш доцільним і перспективним є використання сучасних методів глибокого навчання, здатних автоматично виділяти найскладніші візуальні ознаки патологій безпосередньо з матриці пікселів зображення.

2 ОГЛЯД АЛГОРИТМІВ ТА МЕТРИК ДЛЯ КЛАСИФІКАЦІЇ НОВОУТВОРЕНЬ

2.1 Застосування гібридних зображень у класифікації новоутворень

Гібридні зображення в медичній діагностиці є важливим інструментом для підвищення точності аналізу патологічних змін, зокрема новоутворень. Їхня сутність полягає у поєднанні інформації, отриманої з різних джерел візуалізації. Це дозволяє одночасно враховувати кілька аспектів дослідження об’єкта. У контексті інтелектуального аналізу мамограм це відкриває можливості для більш глибокого розуміння структури тканин та характеру патологічних утворень.

Однією з ключових переваг гібридних зображень є можливість об’єднання структурної та функціональної інформації. Традиційні методи візуалізації часто обмежуються лише одним типом даних, що може бути недостатнім для повної характеристики новоутворення. Поєднання різних типів сигналів дозволяє отримати більш комплексне уявлення про об’єкт дослідження, що є критично важливим для задач класифікації [8].

У задачах класифікації новоутворень гібридні зображення забезпечують підвищену інформативність вхідних даних. Це, у свою чергу, сприяє покращенню якості побудови ознак, які використовуються алгоритмами машинного навчання. Чим більш повною є інформація про об’єкт, тим точніше модель може відрізняти різні класи, наприклад, доброякісні та злоякісні утворення.

Важливим аспектом є також підвищення стійкості до шуму та артефактів. Окремі методи візуалізації можуть бути чутливими до певних типів спотворень або втрат даних. Використання гібридного підходу дозволяє частково компенсувати ці недоліки за рахунок додаткової інформації з інших джерел, що підвищує надійність результатів класифікації.

Ще однією перевагою є можливість кращого виділення меж новоутворень та їх внутрішньої структури. Це важливо для формування інформативних ознак, які відображають геометричні, текстурні та інтенсивнісні характеристики об’єктів. У задачах класифікації такі ознаки можуть значно впливати на точність розпізнавання.

Гібридні зображення також сприяють покращенню здатності моделей до узагальнення. Оскільки дані містять більш різноманітну інформацію, алгоритми можуть навчатися на ширшому спектрі характеристик, що дозволяє їм краще працювати на нових, раніше не бачених даних. Це особливо важливо у медичних задачах, де варіативність проявів захворювань є дуже високою.

Разом із тим, використання гібридних зображень пов’язане з низкою викликів. Одним із них є необхідність коректної узгодженості даних у просторі та інтенсивності. Перед об’єднанням інформації необхідно виконати процедури реєстрації та нормалізації, щоб забезпечити точне накладання різних джерел зображень.

Ще однією складністю є збільшення складності обробки обчислень. Об’єднання кількох джерел даних призводить до зростання обсягу інформації, що потребує додаткових ресурсів для зберігання та обробки. Це може ускладнювати застосування алгоритмів у реальному часі або в умовах обмежених ресурсів.

Крім того, важливим є питання вибору оптимального способу інтеграції даних. Існують різні підходи до поєднання інформації, і від правильності цього вибору залежить ефективність подальшої класифікації. Невдале об’єднання може призвести до втрати важливої інформації або, навпаки, до надлишковості ознак [9].

Таким чином, гібридні зображення відіграють важливу роль у задачах класифікації новоутворень, забезпечуючи біль повну та різнобічну інформацію про досліджувані об’єкти. Незважаючи на певні труднощі їх використання, переваги такого підходу роблять його перспективним

напрямом для подальших досліджень у галузі інтелектуального аналізу медичних зображень.

Існуючі гібридні методи візуалізації поєднують у собі різні фізичні принципи отримання медичних зображень, що дозволяє одночасно аналізувати морфологічні та функціональні характеристики тканин. До таких методів можна віднести ПЕТ-КТ, ОФЕКТ-КТ, ПЕТ-МРТ, ОФЕКТ-МРТ, УЗД та МРТ, МРТ та КТ. Розглянемо детальніше основні гібридні методи, які найчастіше застосовуються у сучасній медичні практиці.

ПЕТ-КТ (позитронно-емісійна томографія та комп'ютерна томографія) є одним із найпоширеніших гібридних методів, який поєднує функціональну інформацію про метаболічну активність тканин із анатомічними даними високої деталізації. У ПЕТ використовується радіофармпрепарат, що накопичується у тканинах з підвищеним метаболізмом, характерним для злоякісних пухлин. КТ, у свою чергу, забезпечує точну просторову локалізацію цих ділянок. Перевагою методу є висока чутливість до онкологічних процесів та можливість раннього виявлення новоутворень. Завдяки поєднанню двох типів інформації значно зменшується ймовірність помилкових висновків. Проте метод пов'язаний із променевим навантаженням та високою вартістю, що обмежує його широке використання.

ОФЕКТ-КТ (однофотонна емісійна комп'ютерна томографія та КТ) є аналогом ПЕТ-КТ, але використовує інший тип радіоактивних ізотопів. Цей метод також дозволяє оцінювати функціональні процеси в організмі, зокрема кровопостачання та метаболічну активність тканин. Компонент КТ забезпечує анатомічну прив'язку отриманих функціональних даних. Основною перевагою є відносно нижча вартість у порівнянні з ПЕТ-КТ, а також доступність у клінічній практиці. Водночас, просторове розділення є нижчим, що може впливати на точність локалізації новоутворень. Метод часто використовується як доповнення до інших аналогічних процедур.

ПЕТ-МРТ (позитронно-емісійна томографія та магнітно-резонансна томографія) поєднує функціональні можливості ПЕТ із високою контрастністю м’яких тканин, яку забезпечує МРТ. Таких підхід є особливо корисним для дослідження органів, де важлива деталізація тканинної структури. Наприклад, у молочній залозі або головному мозку. Перевагою є відсутність іонізуючого випромінювання з боку МРТ та висока якість зображення м’яких тканин. Це робить метод перспективним для онкологічної діагностики. Недоліками є висока вартість обладнання та складність технічної реалізації, що обмежує його доступність. На рисунку 2.1 наведено приклад поєднання ПЕТ та МРТ для покращення мамографічних зображень [10].

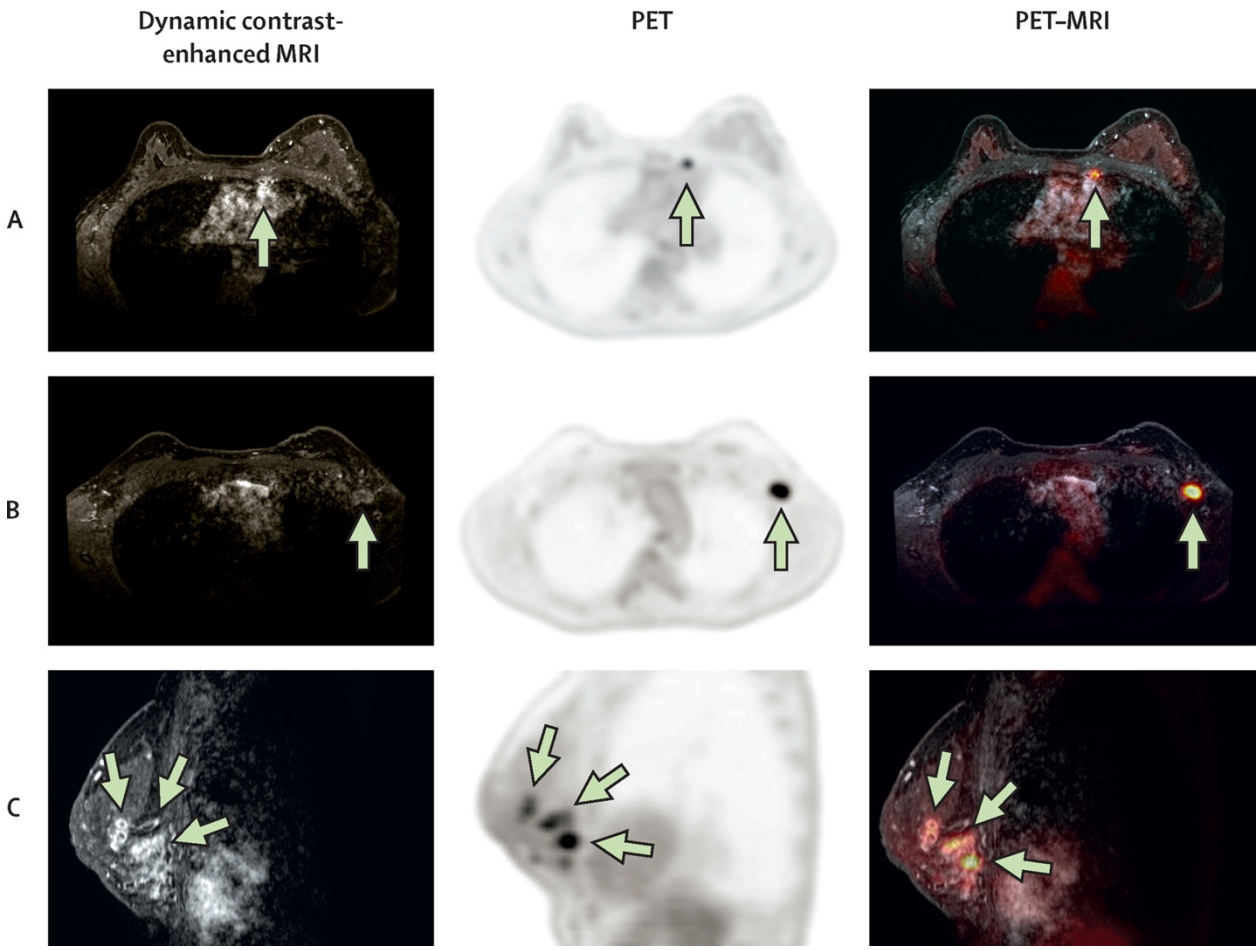


Рисунок 2.1 – Поєднання ПЕТ та МРТ для аналізу мамограм

ОФЕКТ-МРТ (однофотонна емісійна томографія та МРТ) поєднує функціональні можливості ОФЕКТ із морфологічною деталізацією МРТ. Він дозволяє досліджувати як фізіологічні процеси, так і анатомічні особливості тканин, що є важливим для оцінки новоутворень. Основною перевагою є можливість отримання комплексної інформації при зниженому рівні променевого навантаження порівняно з методами, що включають КТ. Однак, як і у випадку ПЕТ-МРТ, технічна складність та висока вартість залишаються суттєвими обмеженнями.

УЗД та МРТ (ультразвукова та МРТ) – це комбінація, що дозволяє поєднати переваги швидкого, доступного та безпечного методу з високою деталізацією м’яких тканин. УЗД забезпечує оперативну оцінку структури тканин у реальному часі, тоді як МРТ надає більш глибоку та точну інформацію. Цей підхід є корисним для уточнення діагнозу, особливо у випадках, коли результати одного методу є неоднозначними. Недоліком є складність інтеграції даних через різну природу сигналів та необхідність спеціалізованого програмного забезпечення.

МРТ та КТ (магнітно-резонансна та комп’ютерна томографія) дозволяє отримати як детальну інформацію про м’які тканини, так і точні дані про кісткові структури та щільність тканин. Такий підхід використовується для комплексного аналізу складних клінічних випадків. Перевагою є висока точність діагностики за рахунок доповнення інформації з різних джерел. Водночас необхідність проведення двох окремих досліджень може збільшувати час діагностики та витрати, а також підвищувати променеве навантаження у випадку використання КТ.

Гібридні методи візуалізації забезпечують суттєве підвищення якості діагностики новоутворень за рахунок поєднання різних типів інформації. Кожен із розглянутих підходів має свої переваги та обмеження, що визначають доцільність його використання у конкретних клінічних умовах. Вибір методу залежить від поставленої задачі, доступності обладнання та вимог до точності діагностики.

2.2 Аналіз алгоритмів класифікації пухлин

Класифікація пухлин на мамографічних знімках є одним із ключових і найскладніших завдань у процесі комп'ютерної діагностики новоутворень молочної залози. Головна мета цього етапу полягає у точному віднесенні виявленої аномалії до певного класу. Найчастіше розглядається бінарна класифікація – поділ на доброякісні за злоякісні пухлини, проте існують і багатокласові задачі, що включають визначення конкретних підтипів утворень. Наприклад, виявлення кальцинатів, мас чи асиметрій.

Історично для вирішення задачі класифікації новоутворень на мамограмах застосовувалися традиційні методи машинного навчання. Ефективність таких алгоритмів безпосередньо залежала від якості попереднього вилучення ознак, що здійснювалося за допомогою спеціалізованих математичних фільтрів або експертних оцінок (аналіз текстури, форми країв пухлини, її розмірів). Серед класичних алгоритмів можна виділити метод опорних векторів, випадковий ліс, метод k-найближчих сусідів. Розглянемо детальніше наведені алгоритми.

Метод опорних векторів (Support Vector Machine, SVM) базується на побудові оптимальної гіперплощини (або набору гіперплощин) у багатовимірному просторі ознак, яка найкраще розділяє класи даних – наприклад, доброякісні та злоякісні утворення. Для медичних завдань SVM є надзвичайно потужним завдяки використанню радіально-базисних функцій, що дозволяє ефективно розділяти лінійно нероздільні дані. У контексті класифікації пухлин на вхід SVM подаються попередньо обчислені вектори ознак. Головною перевагою алгоритму є його висока узагальнююча здатність та ефективність при роботі з відносно невеликими медичними вибірками, де кількість ознак може перевищувати кількість самих зображень.

Випадковий ліс – це ансамблевий алгоритм машинного навчання, який працює шляхом побудови великої кількості дерев рішень під час

навчання. Кожне дерево формується на основі випадкової підвибірки даних та випадкової підмножини ознак пухлини. Остаточне рішення щодо класу новоутворення приймається шляхом усереднення результатів всіх дерев ансамблю. Для медичної діагностики алгоритм випадкового лісу є цінним з двох причин. По-перше, він демонструє високу стійкість до перенавчання та добре справляється із шумовими даними на мамограмах. По-друге, алгоритм має внутрішній механізм оцінки важливості ознак, що забезпечує інтерпретованість моделі: лікарі та дослідники можуть проаналізувати, які саме візуальні характеристики пухлини (наприклад, щільність або нерівність контурів) мали найбільший вплив на рішення алгоритму [11].

Метод k-найближчих сусідів є одним із найпростіших, проте ефективних метричних алгоритмів класифікації, який відноситься до категорії «ледачого навчання». Алгоритм не будує внутрішньої моделі під час навчання, а просто зберігає всі розмічені вектори ознак навчальної вибірки. При надходженні нового зображення пухлини метод обчислює відстань від її вектора ознак до всіх збережених прецедентів. Утворення відноситься до того класу, який найчастіше зустрічається серед k його найближчих сусідів у багатовимірному просторі. У медичній візуалізації метод k-найближчих сусідів часто використовується як базовий метод для порівняння завдяки своїй простоті. Проте, його застосування на практиці обмежується високою обчислювальною складністю на етапі класифікації, оскільки потрібно розрахувати відстань до кожного елемента бази даних, та сильною чутливістю до нерелевантних або надлишкових ознак, що вимагає ретельного попереднього застосування методів зниження розмірності.

Незважаючи на певну успішність класичних підходів у минулому, їхнім головним недоліком залишається залежність від ручного відбору ознак. Цей процес часто є суб’єктивним, трудомістким і не здатним повною мірою охопити всі складні та приховані візуальні патерни на медичних зображеннях.

Останнім часом алгоритми класифікації пухлин зазнали концептуальної трансформації завдяки впровадженню методів глибинного навчання (Deep Learning). Перехід до цих технологій відкриває принципово нові можливості для аналізу мамограм:

Автоматизоване вилучення ознак: алгоритми глибинного навчання здатні самостійно виявляти ієрархічні ознаки – від простих меж і градієнтів тканини до складних текстурних патернів злоякісності, що робить втручання людини на цьому етапі непотрібним.

Наскрізне навчання: процес отримання сирих пікселів зображення до видачі ймовірності належності до класу відбувається в межах єдиної математичної моделі, що суттєво мінімізує втрату інформації.

Стійкість до варіативності: сучасні алгоритми значно краще адаптуються до різного масштабу утворень, артефактів зйомки та різного рівня контрастності на мамографічних знімках.

Відтак, розвиток технологій інтелектуального аналізу вимагає використання алгоритмів, здатних враховувати специфічні виклики мамографії. До таких викликів насамперед належать низький контраст між щільною тканиною молочної залози та пухлиною, високий рівень шуму, а також сильний дисбаланс класів у наборах даних, коли випадки норми або доброякісних утворень кількісно переважають патології.

Отже, аналіз існуючих підходів демонструє чіткий зсув від алгоритмів, що потребують попереднього конструювання ознак, до парадигми глибинного навчання. Вибір оптимального алгоритму або їх комбінації має базуватися на специфіці медичних даних та вимогах до точності діагностики.

Серед сучасних алгоритмів глибинного навчання архітектура ResNet (Residual Network), запропонована дослідниками із Microsoft Research, стала одним із найважливіших проривів у задачах класифікації зображень. Головною проблемою традиційних глибоких згорткових мереж була проблема «затухання градієнта». При збільшенні кількості шарів у

мережі (наприклад, понад 20-30), похибка під час навчання перестала зменшуватися, і точність моделі починала різко падати. Архітектура ResNet успішно вирішила цю проблему, дозволивши тренувати мережі глибиною у 50, 101, 152 і більше шарів.

Фундаментальною інновацією ResNet є використання так званих залишкових блоків із прямими зв'язками. У традиційній нейронній мережі кожен шар намагається вивчити певне базове відображення *H(x)*, де *x* – це вхідні дані шару. У мережі ResNet шар намагається вивчити не саме відображення, а залишкову функцію (різницю) *F(x) = H(x) – x*. Таким чином, вихідне значення блоку формується за формулою:

$$H(x) = F(x) + x. \tag{2.1}$$

Цей процес реалізується шляхом додавання вхідного тензора x безпосередньо до виходу згорткових шарів перед застосуванням функції активації. Завдяки цьому прямому зв'язку градієнт під час зворотного поширення помилки може безперешкодно «перестрибувати» через шари. Якщо певний блок виявляється зайвим, мережа просто обнуляє ваги для F(x), і блок починає працювати як тотожне відображення (*H(x) = x*).

Розглянемо детальніше структуру архітектури ResNet на прикладі мережі ResNet-34. ResNet-34 – це глибока залишкова мережа, побудована на 34-шаровій пласкій мережі, натхненній VGG-19, з короткими з'єднаннями, що утворюють 16 залишкових блоків.

На рисунку 2.2 показана архітектура мережі ResNet-34, що включає різні етапи, які показують її структуроване розташування залишкових блоків [12]. Перший набір має 3 залишкові блоки, кожен з двома згортковими шарами по 64 фільтри та з'єднаннями з пропуском ідентичності. Другий набір включає 4 залишкові блоки, кожен з двома згортковими шарами по 128 фільтрів, що використовують доповнення нулями або проекції 1*1 для зміни розмірності. Третій набір складається з 6

залишкових блоків, кожен з двома згорткомими шарами по 512 фільтрів кожен. Карта ознак проходить через глобальне усереднення, об’єднавши щільний шар з 1000 нейронами та функцією активації softmax.

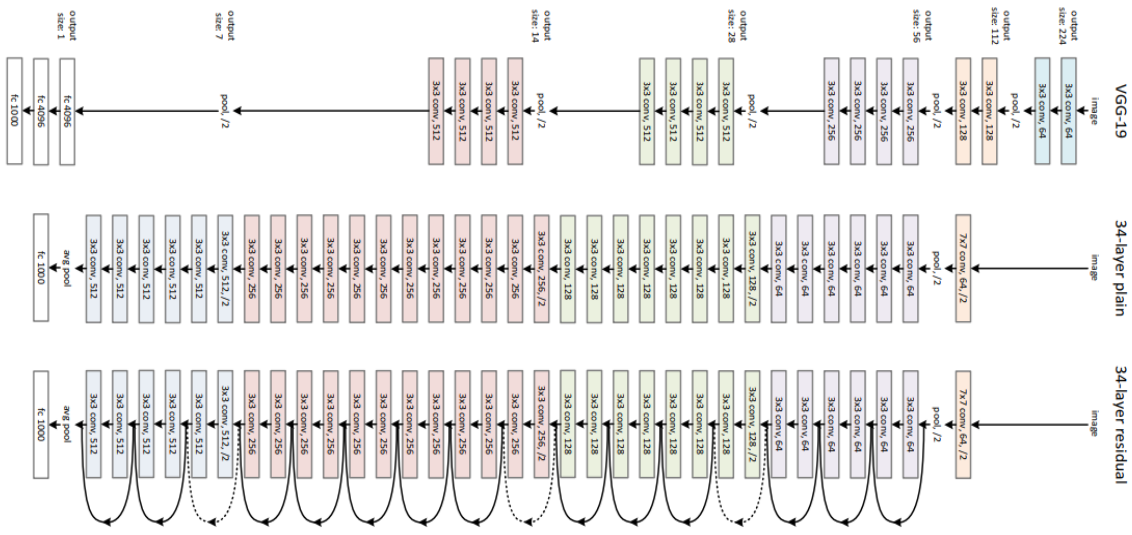


Рисунок 2.2 – Архітектура ResNet-34

Для класифікації складних медичних знімків, таких як мамограми, найчастіше використовується модифікація ResNet-50. Вона використовує архітектуру типу «пляшкове горлечко» (bottleneck), щоб зменшити обчислювальні витрати при великій глибині. Мережа складається з наступних етапів: вхідний шар, згорткові стадії, глобальна усереднююча агрегація та вихідний шар класифікації. На рисунку 2.3 зображено схему архітектури моделі ResNet-50 [13].

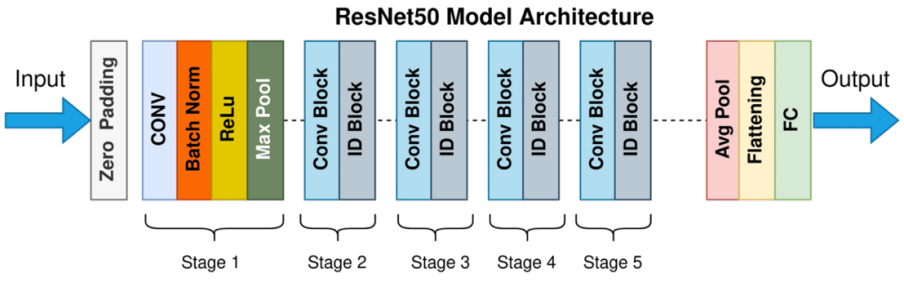


Рисунок 2.3 – Архітектура ResNet-50

Потік обробки зображення починається з нульового заповнення. Цей крок додає межу з нульових пікселів навколо вхідного зображення. Це робиться для того, щоб підготувати дані до першої згортки та запобігти втраті крайової інформації, оскільки згортки з великими ядрами можуть зменшувати розмір тензора. Завданням першого шару згортки (CONV) є виділення початкових, низькорівневих ознак, таких як краї, лінії та прості текстури. Пакетна нормалізація (Batch Norm) стабілізує та прискорює навчання. Вона нормалізує вхідні дані до кожного шару, що робить навчання менш чутливим до початкових ваг та запобігає проблемі затухання градієнтів. Максимальне об'єднання зменшує просторові розміри ознак. Воно зберігає лише найбільше значення з кожної ділянки, що робить ознаки менш змінними та зменшує обчислювальну складність.

Повторювані залишкові блоки є основною інновацією ResNet. Замість того, щоб змушувати кожен шар вивчати пряме відображення, ці блоки вчаться виправляти та уточнювати існуючі ознаки (залишкове навчання). Блоки згортки використовуються, коли просторові розміри та кількість каналів ознак повинні змінитися. Блок ідентифікації використовується, коли розміри залишаються незмінними.

Після чотирьох стадій витягування ознак, мережа переходить до класифікації. Функція Avg Pool усереднює всі ознаки з кожної карти, зменшуючи розмірність багатовимірного тензора до єдиного вектора. Функція Flattening перетворює багатовимірний вектор ознак у одновимірний вектор. На відміну від старих мереж, які використовували масивні повнозв'язні шари наприкінці, ResNet бере кожну двовимірну карту ознак із фінального згроткового шару і перетворює її на одне число. Це кардинально зменшує кількість параметрів мережі та запобігає перенавчанню, що є критично важливим при роботі з обмеженими медичними датасетами.

Кінцевий шар приймає цей вектор і виконує класифікацію. Для задачі бінарної класифікації (наприклад, «норма/доброякісна» проти «злоякісна

пухлина») цей шар має один вихідний нейрон із функцією активації Sigmoid. У випадку багатокласової задачі застосовується функція softmax, яка надає вектор імовірностей належності мамограми до кожного з досліджуваних класів.

Хоча обидві моделі належать до родини згорткових мереж із залишковими зв'язками, між ними існує фундаментальна архітектурна різниця, що безпосередньо впливає на їхнє застосування в медичній візуалізації. Головна відмінність полягає у типі залишкового блоку. Архітектура ResNet-34 використовує базовий блок, який складається з двох послідовних згорткових шарів розміром 3×3, які оминає прямий зв'язок. Натомість при збільшенні глибини мережі до 50 шарів, використання таких блоків стає занадто складним в обчисленні. Тому ResNet-50 застосовує блок типу «пляшкове горлечко», що складається з трьох шарів: згортки 1×1 для зменшення кількості каналів, основної згортки 3×3 та ще однієї згортки 1×1 для відновлення розмірності. Це інженерне рішення дозволяє моделі бути значно глибшою без експоненціального зростання кількості параметрів, яких у ResNet-50 налічується близько 25,6 мільйонів параметрів порівняно з 21,8 мільйонами у ResNet-34 [14].

У контексті аналізу мамографічних зображень, які характеризуються високою роздільною здатністю та часто обмеженим обсягом розмічених баз даних, кожна з архітектур має свої сильні та слабкі сторони. Менш глибока модель ResNet-34 виявляється надзвичайно ефективною при роботі з невеликими медичними вибірками. Завдяки меншій кількості параметрів вона має значно нижчий ризик перенавчання, коли алгоритм запам'ятовує навчальні дані замість виявлення загальних закономірностей. Крім того, її тренування вимагає менше відеопам'яті, що дозволяє обробляти зображення вищої роздільної здатності без надмірного стиснення. Однак обмежена глибина може стати перешкодою для вилучення надзвичайно складних, багаторівневих візуальних залежностей, характерних для прихованих патологій.

З іншого боку, архітектура ResNet-50 здатна створювати набагато абстрактніші та глибші карти ознак. Це є критично важливим для диференціації доброякісних утворень від злоякісних, де різниця часто полягає у мікроскопічних змінах текстури тканин або наявності дрібних мікрокальцинатів. Додатковою і дуже вагомою перевагою цієї моделі є високий потенціал перенесення навчання. Оскільки ResNet-50 є загальновизнаним стандартом у галузі комп'ютерного зору, попередньо натреновані на великих наборах даних ваги є надзвичайно якісними і дають кращий приріст точності під час донавчання на мамограмах. Разом з тим, використання такої глибокої мережі вимагає потужніших обчислювальних ресурсів та застосування інтенсивних методів аугментації даних для запобігання перенавчанню.

Відтак, вибір між цими двома моделями залежить від умов експерименту та обсягу доступних даних. Для невеликих вибірок надійнішим базовим алгоритмом виступає ResNet-34, тоді як за умови використання великих публічних баз даних та залучення методів перенесення навчання оптимальним вибором залишається архітектура ResNet-50.

2.3 Вибір метрик оцінки моделі класифікації пухлин

Усі найбільш поширені метрики оцінки моделей класифікації медичних зображень, включаючи мамограми, ґрунтуються на результатах матриці помилок (Confusion Matrix) [15]. Вона є фундаментальним інструментом для об'єктивного аналізу того, наскільки точно алгоритм розрізняє злоякісні новоутворення, доброякісні пухлини та здорові тканини.

Розглянемо детальніше кожен елемент матриці помилок у контексті раку молочної залози.

TP (True Positive – істинно позитивні): кількість випадків, коли модель правильно класифікувала наявність злоякісної пухлини.

TN (True Negative – істинно негативні): кількість випадків, коли алгоритм правильно підтвердив відсутність злоякісного утворення (здорова тканина або норма).

FP (False Positive – хибно позитивні): помилка I роду. Модель класифікувала пухлину як злоякісну, але насправді пацієнт здоровий (або пухлина доброякісна). Це призводить до хибної тривоги та непотрібних додаткових обстежень (наприклад, біопсії).

FN (False Negative – хибно негативні): помилка II роду. Алгоритм пропустив злоякісну пухлину, класифікувавши знімок як норму. У медичній практиці це найнебезпечніша помилка, оскільки вона затримує початок лікування.

Розглянемо метрики оцінки, які доцільно використовувати для оцінки класифікації пухлин.

Точність (Precision) обчислюється як відношення правильно передбачених позитивних результатів (дійсних пухлин) до загальної кількості результатів, які модель назвала позитивними:

$$Precision = \frac{TP}{TP+FP}. \quad (2.2)$$

При використанні точності ми оцінюємо, наскільки правильно модель визначає саме злоякісні новоутворення серед усіх знімків, які вона класифікувала як підозрілі. Іншими словами, ця метрика показує ступінь довіри до системи, коли вона сигналізує про наявність раку.

Повнота (Recall) визначається як відношення кількості правильно класифікованих злоякісних пухлин до загальної кількості фактичних злоякісних пухлин у досліджуваному наборі даних:

$$Recall = \frac{TP}{TP+FN}. \quad (2.3)$$

При використанні повноти ми оцінюємо, наскільки ефективно модель виявляє всі існуючі патології. Для задач аналізу мамограм ця метрика часто є пріоритетною, оскільки важливо мінімізувати кількість пропущених захворювань (FN).

Оцінка загальної точності (Accuracy) – це відношення кількості всіх правильно класифікованих зразків до загальної кількості досліджених зображень

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}. \quad (2.4)$$

Ця метрика дає загальне уявлення про працездатність моделі. Проте в медичних даних часто зустрічається дисбаланс класів. Здорових пацієнтів значно більше, ніж хворих. Тому покладатися виключно на Accuracy не рекомендується.

Специфічність (Specificity) показує здатність алгоритму правильно ідентифікувати негативні випадки (здорові тканини):

$$Specificity = \frac{TN}{TN+FP}. \quad (2.5)$$

Вона демонструє, наскільки успішно модель уникає хибних діагнозів у здорових пацієнтів.

F1-міра (F1-Score) є гармонійним середнім між Точністю (Precision) та Повнотою (Recall):

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision+Recall}. \quad (2.6)$$

Цей показник є ідеальним для вибору найкращої моделі класифікації у випадках, коли набір даних незбалансований і необхідно знайти

оптимальний компроміс між хибно позитивними та хибно негативними результатами.

Крім того, для комплексного оцінювання алгоритмів класифікації новоутворень, таких як ResNet та SVM, широко використовується площа під ROC-кривою (ROC-AUC). Вона показує здатність моделі розрізняти класи при зміні порогу прийняття рішень, що є критично важливим для налаштування чутливості медичної діагностичної системи.

Отже, для всебічної та об’єктивної оцінки алгоритмів класифікації новоутворень на мамограмах недостатньо спиратися лише на один показним. Враховуючи специфіку медичної діагностики, найвищий пріоритет має максимізація Повноти (Recall), що дозволяє звести до мінімуму небезпеку пропущених злоякісних пухлин. Водночас, для зменшення кількості хибних тривог і психологічного навантаження на пацієнтів, систему необхідно балансувати належним рівнем Точності (Precision) та Специфічністю (Specificity). Саме тому найоптимальнішим підходом для порівняння та вибору фінальної моделі (зокрема, між розглянутими архітектурами ResNet) є використання комплексних метрик – F1-міри для роботи з незбалансованими медичними даними та площі під кривою ROC-AUC для оцінки загальної здатності алгоритму безпомилково розрізняти класи.

3 ОСОБЛИВОСТІ РЕАЛІЗАЦІЇ ПРОГРАМНОГО ЗАСТОСУНКУ

3.1 Огляд вибраного набору даних

В результаті дослідження алгоритмів класифікації новоутворень було реалізовано програмний застосунок, що класифікує цифрові мамограми. Застосунок розроблено з інтегрованому середовищі розробки PyCharm з використанням мови програмування Python, бібліотеки Keras для роботи з нейронними мережами та бібліотеки TensorFlow для реалізації та навчання глибоких нейронних мереж. Зокрема, архітектур сімейства ResNet. Мінімальні системні вимоги: 64-бітна операційна система Windows, Python 3.8.

Вхідні дані: цифрові рентгенівські зображення мамограм (формату DICOM, PNG або JPEG).

Вихідні дані: передбачений клас зображення (діагноз) та ймовірність належності до цього класу у відсотках.

Для реалізації моделі класифікації новоутворень був використаний загальнодоступний набір даних CBIS-DDSM (Curated Breast Imaging Subset of DDSM). Цей набір містить скринінгові мамограми, де кожен випадок зазвичай представлений змінками у двох стандартних проєкціях: краніокаудальній (CC) та медіолатеральній косій (MLO). На рисунку 3.1 наведено порівняння стандартних проєкцій мамографічних знімків [16].

Краніокаудальна проєкція – це прямий знімок зверху вниз. Ця проєкція є ключовою для візуалізації центральних, внутрішніх (медіальних) та зовнішніх (латеральних) ділянок молочної залози. Вона дозволяє добре розгледіти структури, які можуть перекриватися на бокових знімках, але не охоплює найвищі та найглибші ділянки тканини біля самої грудної клітки.

Медіолатеральна коса проєкція – це знімок, зроблений під кутом, зазвичай 45–60 градусів від центру грудної клітки до зовнішньої сторони. Ця проєкція є найважливішою у скринінгу, оскільки охоплює максимальний

обсяг тканин, включаючи пахвову ділянку та грудний м’яз. Згідно з медичною статистикою, більшість злоякісних новоутворень виникають саме у верхньому зовнішньому квадранті, який найкраще візуалізується на медіолатеральній косій проєкції.

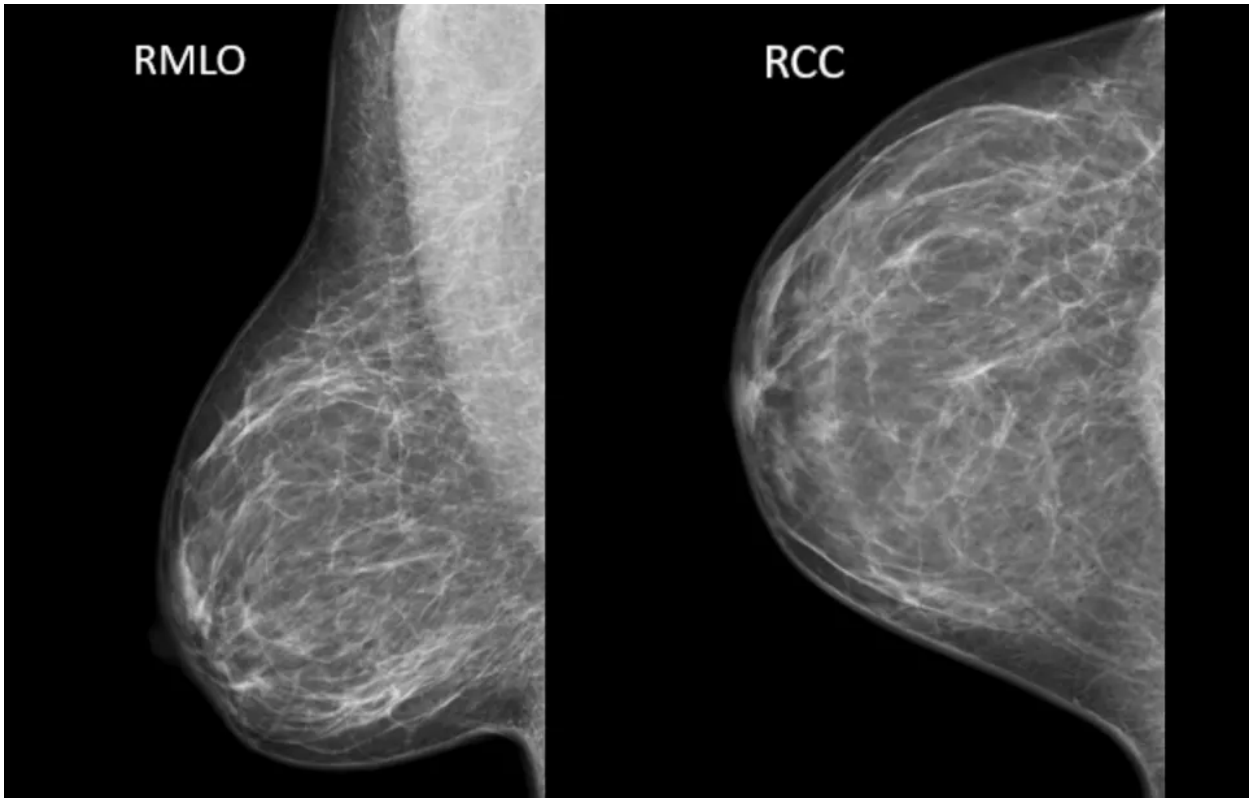


Рисунок 3.1 – Проєкції мамографічних знімків:
медіолатеральна коса RMLO (ліворуч), та краніокаудальна RCC (праворуч)

Для лікаря-радіолога критично важливо аналізувати обидві проєкції одночасно для точної просторової локалізації патології та підтвердження присутності або відсутності пухлини. Проте, з точки зору архітектури нейронних мереж, створення моделі, яка приймає на вхід одразу два зображення, є складним завданням, що значно підвищує вимоги до обчислювальної потужності та оперативної пам’яті комп’ютера.

Тому для навчання моделі класифікації в даному дослідженні застосовано підхід, за якого знімки обох проєкцій обробляються

алгоритмом як незалежні зображення. Це дозволяє зробити процес навчання більш швидким та ефективним. Крім того, такий підхід фактично подвоює обсяг навчальної вибірки, дозволяючи нейромережі краще вивчити загальні візуальні ознаки патологій, такі як мікрокальцинати чи порушення архітектоніки тканин.

Усі зображення в наборі даних були верифіковані та класифіковані на основі гістологічних досліджень (біопсії) або тривалого клінічного спостереження, а їхні анотації були підтверджені досвідченими лікарями-радіологами. Під час обробки набору даних кожне зображення віднесене до одного з двох основних класів патології. Приклади класифікації новоутворень на мамограмах наведено на рисунку 3.2 [17].

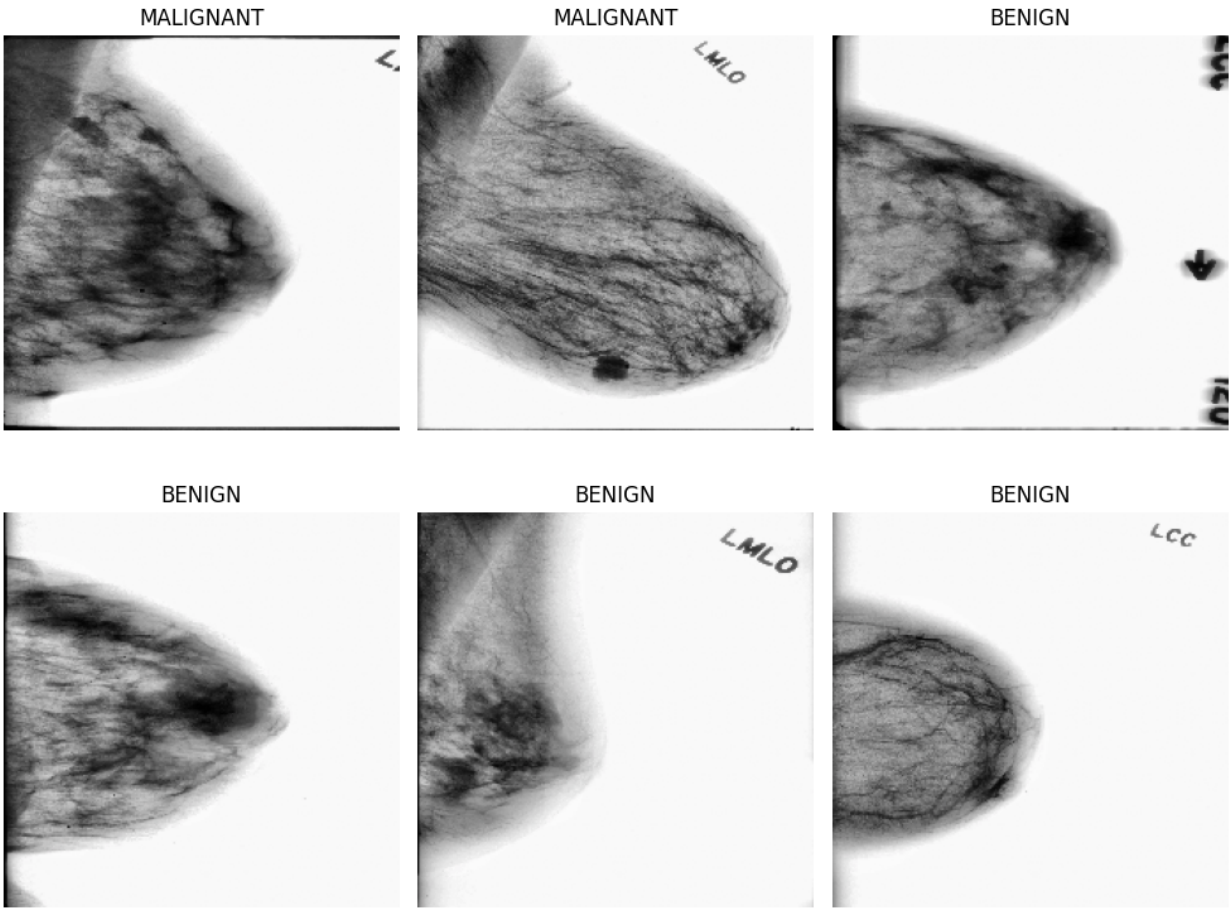


Рисунок 3.2 – Мамограми віднесені до доброякісних (benign) або злоякісних (malignant) новоутворень.

Розглянемо детальніше кожний з класів новоутворень.

Клас 0 (Доброякісне новоутворення / Benign) – відображає наявність патології (наприклад, типова фіброаденома або просто кіста), клітини якої не є раковими. Такі утворення зазвичай мають чіткі контури, не проростають у сусідні тканини і потребують лише планового спостереження.

Клас 1 (Злоякісне новоутворення / Malignant) – відображає наявність ракової пухлини (карциноми). На мамограмах такі новоутворення часто характеризуються нерівними, зірчастими краями або скупченням підозрілих мікрокальцинатів і вимагають негайного призначення лікування.

Отже, анотації включають вище наведені класи (доброякісні та злоякісні новоутворення), як описано в документації до набору даних CBIS-DDSM. Надані цифрові мамограми проходять етап попередньої обробки: вони масштабуються до єдиної роздільної здатності (наприклад 224×224 або 512×512 пікселів, залежно від архітектури мережі), нормалізуються за контрастністю та очищаються від фонових рентгенографічних артефактів (написів, міток). Також важливим кроком є сегментація та видалення (маскування) ділянки великого грудного м’яза, щоб модель під час класифікації фокусувалася виключно на тканинах молочної залози.

Набір даних CBIS-DDSM містить понад 10 000 файлів у форматі DICOM (Digital Imaging and Communications in Medicine) або попередньо конвертованих для машинного навчання у формати PNG/JPEG. Формат DICOM – це міжнародний медичний стандарт для створення, зберігання, передачі та візуалізації медичних зображень. Мамограми являють собою двовимірні проєкційні рентгенівські знімки. Тому кожне зображення у наборі є двовимірною матрицею пікселів високої роздільної здатності. Оригінальні мамограми можуть мати розміри до 3000×4000 пікселів, проте для навчання згорткових нейронних мереж їх зазвичай масштабують до розмірності 224×224 або 512×512.

У цифрових мамограмах використовується лише два просторові виміри: ширина та висота. Третій канал, який в кольорових зображеннях відповідає за RGB-палітру, тут дорівнює одиниці, оскільки знімок є монохромним, у градаціях сірого. Кожен піксель цієї матриці містить значення інтенсивності, яке відображає електронну щільність тканини молочної залози, що визначає ступінь ослаблення рентгенівського випромінювання. Чим щільніша тканина (наприклад, фіброгландулярна тканина, кальцинати або злоякісна пухлина), тим інтенсивніше вона ослаблює енергію рентгенівських променів, і тим світлішим є відповідний піксель на зображенні. Жирова тканина поглинає менше променів і виглядає на знімку темнішою. Це залежить від співвідношення легких (H, C, O) та більш важких (Ca) хімічних елементів у біологічних тканинах.

Для того, щоб краще зрозуміти, які саме дані подаються на вхід нейронної мережі для класифікації, представимо типовий зразок з набору даних. Приклад візуалізації повноформатної цифрової мамограми (Full-Field Digital Mammogram, FFDM) та виділеної області інтересу (Region of Interest, ROI) із пухлиною представлено на рисунку 3.3 [18]. Оскільки оригінальний знімок містить багато чорного фону (повітря) та артефактів, під час попередньої обробки зображення часто обрізається по контуру молочної залози, щоб сфокусувати увагу алгоритму класифікації виключно на значущих тканинах.

Оскільки набори медичних даних, такі як CBIS-DDSM, є відносно невеликими порівняно зі стандартними датасетами для комп’ютерного зору, критично важливим етапом перед навчанням згорткової нейронної мережі є аугментація даних (Data Augmentation). Цей процес полягає у штучному збільшенні тренувальної вибірки шляхом застосування випадкових геометричних трансформацій до оригінальних мамограм. Зокрема, використання повороту, віддзеркалення та зсуву дозволяє імітувати природні варіації позиціонування пацієнток під час реального обстеження

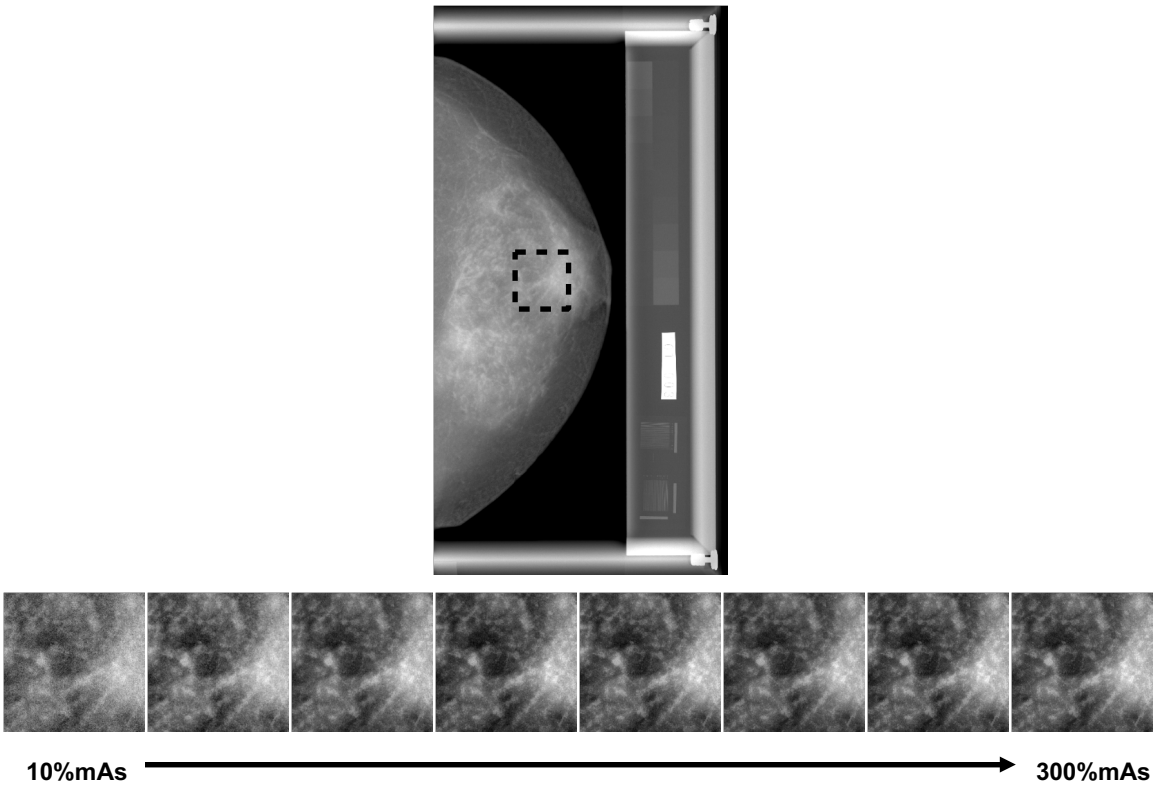


Рисунок 3.3 – Зображення повноформатної цифрової мамограми (FFDM). Область інтересу (ROI) окреслена та відображається нижче

У даному дослідженні до зображень застосовувалися такі перетворення: випадкове горизонтальне та вертикальне відображення, невеликі повороти на кут до 15 градусів, а також незначне масштабування. Завдяки аугментації модель вчиться розпізнавати ознаки пухлин незалежно від їхнього розташування чи орієнтації на знімку, що суттєво підвищує здатність алгоритму до узагальнення на нових, раніше не бачених даних.

Специфікою рентгенографічних зображень молочної залози є низький контраст між щільною фіброгландулярною тканиною та злоякісними новоутвореннями або мікрокальцинатами. Для вирішення цієї проблеми на етапі попередньої обробки часто використовується метод адаптивного вирівнювання гістограми з обмеженням контрастності (CLAHE – Contrast Limited Adaptive Histogram Equalization). На відміну від звичайного вирівнювання гістограми, алгоритм CLAHE обчислює гістограми для окремих невеликих ділянок зображення, посилюючи локальний контраст,

але при цьому запобігаючи надмірному посиленню фонового шуму. Застосування цього методу дозволяє зробити контури пухлин більш виразними для фільтрів згорткової нейронної мережі. На рисунку 3.4 показано зображення, покращене за допомогою алгоритму CLAHE [19].

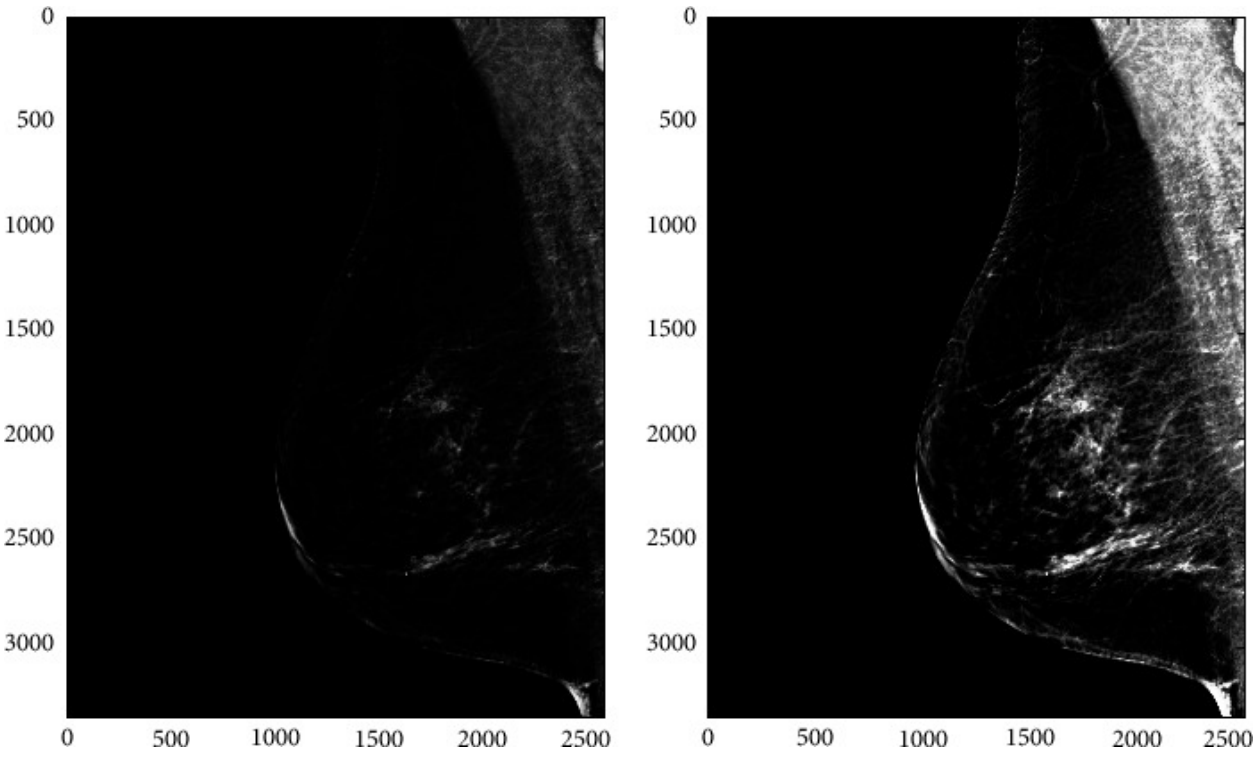


Рисунок 3.4 – Посилення контрастності для покращення видимості

Характерною проблемою медичних наборів даних є дисбаланс класів: кількість мамограм без патологій або з доброякісними утвореннями значно перевищує кількість знімків з підтвердженою карциномою. Для того, щоб модель не зміщувалась у бік мажоритарного класу під час навчання, було застосовано метод зважування класів у функції втрат. Крім того, весь набір даних був розділений на три незалежні вибірки: тренувальну (70% даних) для налаштування ваг мережі, валідаційну (15%) для підбору гіперпараметрів та запобігання перенавчанню, і тестову (15%) для об’єктивної оцінки фінальних метрик (Precision, Recall, F1-Score) на даних, які модель раніше не обробляла.

Отже, вибір та правильна підготовка набору даних є фундаментальним етапом у розробці систем інтелектуального аналізу мамограм. Використання верифікованої бази медичних зображень, яка містить знімки у двох ключових проєкціях (краніокаудальній та медіолатеральній косій), забезпечує високу достовірність вхідної інформації. Водночас, специфіка рентгенівських знімків вимагає ретельної попередньої обробки: маскування фонових артефактів, підвищення локальної контрастності тканин та штучного розширення вибірки методами аугментації. Комплексне застосування цих підходів, разом із вирішенням проблеми дисбалансу класів, дозволяє нівелювати базові обмеження медичних наборів даних. Таким чином формується якісне та репрезентативне підґрунтя для подальшого ефективного навчання згорткових нейронних мереж.

3.2 Попередня обробка даних

Ефективність роботи згорткових нейронних мереж у сфері медичної візуалізації безпосередньо залежить від якості вхідних даних. Оскільки оригінальні цифрові мамограми містять значну кількість надлишкової інформації, фонового шуму та апаратних артефактів, використання необроблених рентгенівських знімків є недоцільним. Тому перед подачею зображень на вхід архітектури класифікатора було реалізовано комплексний конвеєр попередньої підготовки даних.

Першочерговим етапом обробки є локалізація області інтересу (Region of Interest, ROI) та алгоритмічне очищення зображень. Оригінальні мамограми зазвичай охоплюють великі ділянки порожнього чорного фону, а також містять рентгеноконтрастні мітки і зображення великого грудного м’яза. Ці елементи не несуть діагностичної цінності для ідентифікації пухлин, проте можуть генерувати хибні ознаки для нейромережі. Шляхом застосування методів цифрового маскування та

кадрування, зображення були обрізані таким чином, щоб сфокусувати увагу моделі виключно на фіброгландулярній та жировій тканинах молочної залози.

Наступним кроком є просторова стандартизація. Медичні сенсори генерують знімки з надвисокою роздільною здатністю. Обробка матриць такого розміру вимагає колосальних обчислювальних ресурсів і призводить до швидкого переповнення оперативної пам'яті графічних процесорів. З огляду на архітектурні вимоги сучасних нейромереж, усі відібрані зображення були жорстко масштабовані до уніфікованого розміру 224×224 пікселів. Таке зменшення розмірності є оптимальним компромісом: воно значно пришвидшує обчислення тензорних операцій, але при цьому зберігає ключові морфологічні особливості новоутворень, такі як нерівність контурів пухлини.

Ще одним критичним кроком попередньої обробки масиву цифрових мамограм стала нормалізація інтенсивності пікселів. В оригінальних чорно-білих зображеннях значення пікселів варіюються від 0 (чорний) до 255 (білий). Для пришвидшення збіжності градієнтного спуску та підвищення стабільності навчання моделі всі ці значення були масштабовані до діапазону [0, 1] шляхом ділення кожного значення пікселя на 255.

Паралельно з трансформацією самих зображень відбулася підготовка цільових міток класів. Оскільки алгоритм виконує задачу категоріальної класифікації (ідентифікація доброякісної або злоякісної патології), клінічні діагнози було перетворено у математичний векторний формат за допомогою унітарного кодування (One-Hot Encoding). Цей метод дозволяє перетворити текстові або порядкові категоріальні змінні у векторний формат, який правильно сприймається функцією втрат нейронної мережі. З математичної точки зору, використання звичайних чисел (наприклад, 1 для доброякісної і 2 для злоякісної пухлини) може змусити мережу помилково вважати, що між класами існує кількісний зв'язок, ніби другий клас математично

більший за перший. Однократне кодування усуває цю ієрархію, перетворюючи мітки на масиви з нулів та одиниць: наприклад, один клас кодується вектором [1, 0], а інший – [0, 1]. Це дозволяє вихідному шару моделі незалежно прогнозувати відсоткову ймовірність належності мамограми до кожної з категорій.

Фінальним етапом попередньої обробки є стратифіковане розбиття загального пулу підготовлених даних на незалежні підвибірки. Для забезпечення об'єктивного навчання та запобігання перенавчанню, весь масив мамограм було поділено на три частини: тренувальну (70%), валідаційну (15%) та тестову (15%). На рисунку 3.5 наведено фінальний розподіл мамографічних зображень. Тренувальна множина використовується безпосередньо для оновлення вагових коефіцієнтів мережі. Валідаційна вибірка дозволяє контролювати точність моделі після кожної епохи навчання та оптимізувати гіперпараметри. Тестова ж вибірка залишається повністю ізольованою протягом усього циклу розробки і застосовується виключно на фінальному етапі для неупередженої оцінки здатності класифікатора працювати з новими, раніше не баченими даними.



Рисунок 3.5 – Розподіл даних для навчання моделі класифікації

Таким чином, етап попередньої обробки є критично важливим кроком для адаптації сирих мамограм до архітектури згорткових нейронних мереж. Проведені процедури очищення зображень від фонових артефактів, просторового стандартизування, нормалізації значень пікселів та унітарного кодування міток класів дозволяють перетворити медичні знімки на оптимізований математичний формат. Своєю чергою, стратифіковане розділення підготовленого масиву на тренувальну, валідаційну та тестову вибірки формує надійне підґрунтя для коректного навчання класифікатора та об’єктивної оцінки його здатності до узагальнення на нових клінічних даних.

3.3 Навчання моделі та аналіз метрик

Задача ідентифікації патологій на мамограмах є задачею глобальної класифікації зображення. Для вирішення цієї проблеми найбільш доцільним є використання глибоких згорткових нейронних мереж, зокрема архітектур сімейства ResNet. Ця архітектура відмінно зарекомендувала себе в аналізі двовимірних медичних знімків завдяки використанню залишкових блоків. Такі блоки дозволяють будувати глибокі нейронні мережі без ризику затухання градієнтів, що є критично важливим для виявлення складних і дрібних патернів, таких як скупчення мікрокальцинатів або нерівні (зірчасті) краї злоякісних пухлин.

Для оптимізації вагових коефіцієнтів моделі було обрано відповідну функцію втрат. Враховуючи, що на етапі попередньої обробки цільові мітки діагнозів були перетворені за допомогою унітарного кодування (One-Hot Encoding), найоптимальнішим математичним апаратом є категоріальна перехресна ентропія. Вона вимірює розбіжність між прогнозованим розподілом ймовірностей нейромережі та фактичним закодованим діагнозом.

Для того, щоб перетворити числові виходи мережі на зрозумілий розподіл ймовірностей для кожного класу, до останнього пов’язаного шару класифікатора було застосовано функцію активації Softmax. Вона трансформує вихідні значення таким чином, що кожному діагнозу присвоюється ймовірність від 0 до 1, а їхня загальна сума завжди дорівнює одиниці. Відповідно, під час навчання оптимізатор алгоритм Adam ітеративно підлаштовує ваги мережі так, щоб мінімізувати перехресну ентропію, тим самим максимізуючи ймовірність правильного класу.

Для автоматизації процесу тренування, підвищення його стабільності та запобігання ефекту перенавчання на тренувальних даних, у програмному застосунку було використано механізми зворотного виклику:

ReduceLROnPlateau: динамічно адаптує швидкість навчання. Якщо показник функції втрат на валідаційній вибірці перестає знижуватися протягом визначеної кількості епох, алгоритм автоматично зменшує швидкість навчання. Це дозволяє моделі здійснювати менші кроки градієнтного спуску на фінальних етапах оптимізації, щоб точніше знайти глобальний мінімум похибки.

ModelCheckpoint: безперервно моніторить метрики валідації та зберігає параметри лише тієї версії моделі, яка продемонструвала найнижче значення втрат на валідаційних даних. Це гарантує, що для фінального тестування не буде випадково використана перенавчена мережа з останньої епохи.

EarlyStopping: примусово перериває процес навчання, якщо якість моделі на валідаційному наборі стабільно не покращується, що значно економить обчислювальні ресурси та час.

Процес навчання вимагає постійного моніторингу не лише функції втрат, але й оціночних метрик. Хоча загальна точність є базовим індикатором успішності навчання, її використання для медичних наборів даних може бути оманливим через природний дисбаланс класів. Здорових знімків значно більше, ніж знімків з патологіями. Тому для об’єктивного

аналізу під час тренування паралельно обчислювалися й інші показники, детально розглянуті у розділі 2.3: Точність, Повнота та Специфічність.

Процес навчання класифікатора був налаштований на 50 епох. Фрагмент системного журналу навчання для фінальних ітерацій моделі, де зафіксовано стабілізацію ключових метрик, наведено на рисунку 3.6.

```
Epoch 46/50
 68/100 ━━━━━━━━━━━━━━━━━━━━ 3s 106ms/step - accuracy: 0.9930 - loss: 0.1852
Epoch 46: val_accuracy did not improve from 0.74631
100/100 ━━━━━━━━━━━━━━━━━━━━ 8s 79ms/step - accuracy: 0.9940 - loss: 0.1846 - val_accuracy: 0.
7463 - val_loss: 0.7617 - learning_rate: 1.0000e-05
Epoch 47/50
 68/100 ━━━━━━━━━━━━━━━━━━━━ 3s 106ms/step - accuracy: 0.9922 - loss: 0.1802
Epoch 47: val_accuracy did not improve from 0.74631
100/100 ━━━━━━━━━━━━━━━━━━━━ 8s 80ms/step - accuracy: 0.9933 - loss: 0.1797 - val_accuracy: 0.
7434 - val_loss: 0.7580 - learning_rate: 1.0000e-05
Epoch 48/50
 68/100 ━━━━━━━━━━━━━━━━━━━━ 3s 106ms/step - accuracy: 0.9935 - loss: 0.1811
Epoch 48: val_accuracy did not improve from 0.74631
100/100 ━━━━━━━━━━━━━━━━━━━━ 8s 78ms/step - accuracy: 0.9939 - loss: 0.1800 - val_accuracy: 0.
7463 - val_loss: 0.7610 - learning_rate: 1.0000e-05
Epoch 49/50
 68/100 ━━━━━━━━━━━━━━━━━━━━ 3s 106ms/step - accuracy: 0.9969 - loss: 0.1700
Epoch 49: val_accuracy did not improve from 0.74631
100/100 ━━━━━━━━━━━━━━━━━━━━ 8s 79ms/step - accuracy: 0.9967 - loss: 0.1703 - val_accuracy: 0.
7375 - val_loss: 0.7510 - learning_rate: 1.0000e-05
Epoch 50/50
 68/100 ━━━━━━━━━━━━━━━━━━━━ 3s 106ms/step - accuracy: 0.9958 - loss: 0.1635
Epoch 50: val_accuracy did not improve from 0.74631
100/100 ━━━━━━━━━━━━━━━━━━━━ 8s 79ms/step - accuracy: 0.9957 - loss: 0.1636 - val_accuracy: 0.
7404 - val_loss: 0.7470 - learning_rate: 1.0000e-05
```

Рисунок 3.6 – Журнал фінальних епох навчання моделі класифікації

Для даного дослідження було використано підготовлений набір даних CBIS-DDSM. Відповідно до методології, детально описаної у розділі 3.2, усі мамограми попередньо пройшли етапи очищення від артефактів, масштабування та нормалізації. Розподіл даних також було виконано згідно з розробленою стратегією: 70% зображень склали тренувальну вибірку, 15% – валідаційну, а решта 15% використовувалися як ізольований тестовий набір. Згодом із підготовлених зразків вилучалися просторові ознаки за допомогою згорткових шарів, а фінальна класифікація на два

класи (доброякісні та злоякісні новоутворення) здійснювалася на базі архітектури ResNet-50.

Запропонований метод глибокого навчання показав високу ефективність у класифікації мамограм. У таблиці 3.1 наведено порівняння точності класифікації, досягнутої розробленою моделлю ResNet-50 на базі датасету CBIS-DDSM, з існуючими алгоритмами, що досліджувалися іншими авторами. Результативна загальна точність склала 93.0%. Запропонований підхід продемонстрував перевагу над більшістю існуючих рішень, забезпечивши високі показники специфічності, повноти та F1-міри.

Таблиця 3.1 – Зведені результати виявлення раку молочної залози на різних наборах мамографічних даних

Автори	Набір даних	Метод	Точність	Специ-фічність	Чутли-вість
Carniero та ін. [20]	INbreast	AlexNet	86.0	-	-
Dhungel та ін. [21]	INbreast	AlexNet	91.0	-	-
Zhang та ін. [22]	INbreast	AdaBoost	87.93	97.73	57.2
Pezeshki та ін. [23]	MIAS	ANN	61.0	77.0	95.03
Zhang та ін. [22]	DDSM	AdaBoost	90.91	97.38	82.96
Запропонований підхід	CBIS-DDSM	ResNet-50	93.0	93.86	93.83

Як видно з таблиці 3.1, запропонований підхід на базі ResNet-50 демонструє покращені результати з точністю 93.0%, специфічністю 93.86% та чутливістю 93.83%. Варто зазначити, що хоча специфічність у методі Zhang et al. (AdaBoost) на базі оригінального DDSM є дещо вищою, їхня модель суттєво програє у чутливості (82.96%), що є критичним недоліком для медичних задач, де пропуск злоякісної пухлини має найвищу ціну. У порівнянні з існуючими методами, запропонована модель забезпечує більш збалансовану та надійну продуктивність.

Для більш детальної оцінки ефективності розробленого підходу були проаналізовані матриця помилок та крива робочої характеристики приймача. На рисунку 3.7 проілюстровано матрицю помилок для тестової вибірки.

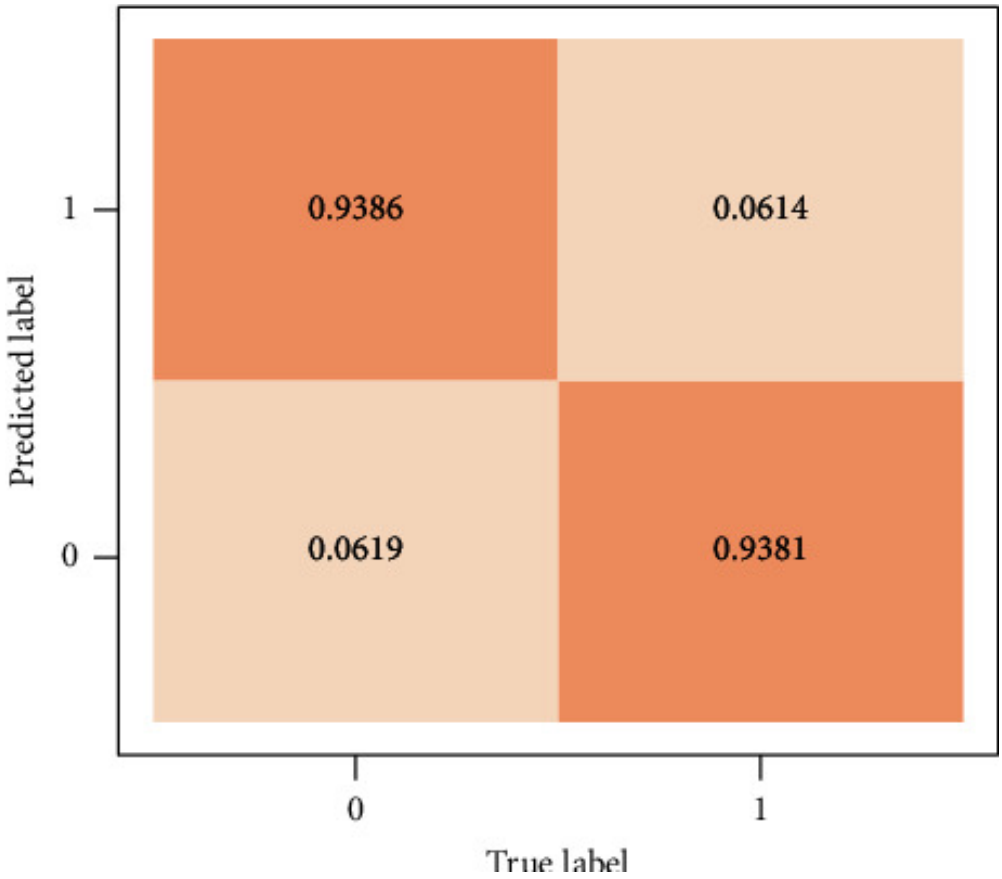


Рисунок 3.7 – Матриця помилок запропонованого підходу класифікації

Крім того, на основі відношення істинно позитивних результатів (чутливість) та хибно позитивних результатів (специфічність) при різних порогах ймовірності була побудована ROC-крива, яку наведено на рисунку 3.8.

Важливим статистичним показником ROC-кривої є площа під нею (AUC), яка демонструє загальну здатність алгоритму розрізняти класи незалежно від обраного порогу. У таблиці 3.2 підсумовано фінальні результати роботи запропонованої системи виявлення новоутворень.

Модель досягла показників F1-міри та AUC на рівні 93.03% та 93.02% відповідно.

Таблиця 3.2 – Фінальні результати запропонованої методології виявлення та класифікації новоутворень

Метрика продуктивності	Отриманий результат (%)
Точність (Accuracy)	93.0
Чутливість (Sensitivity)	93.83
Специфічність (Specificity)	93.86
F1-міра (F1-score)	93.03
Площа під ROC-кривою (AUC)	93.02

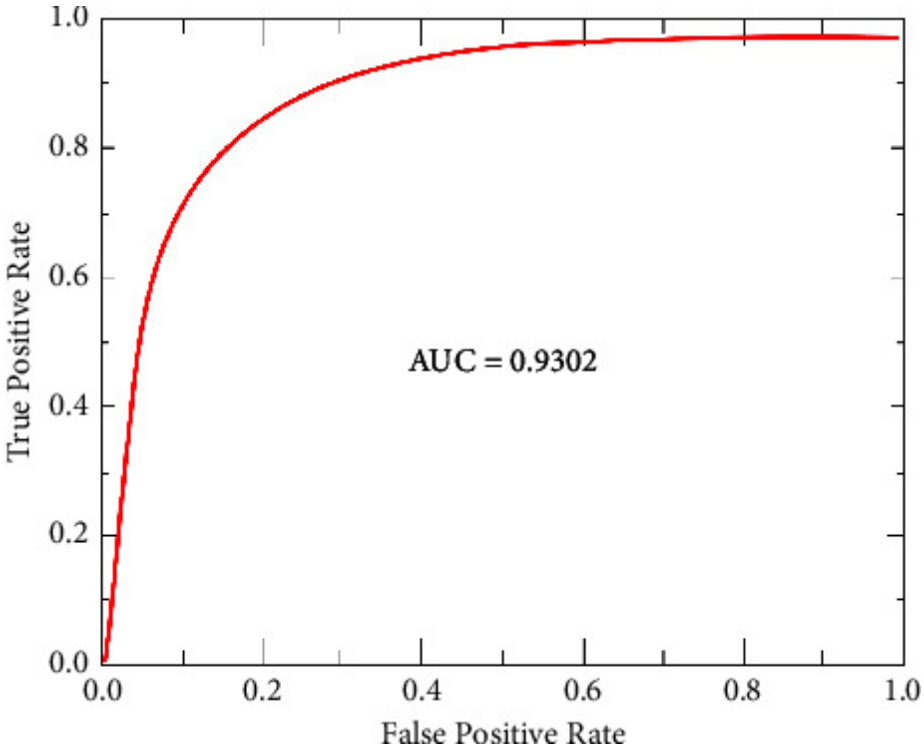


Рисунок 3.8 – ROC-крива класифікатора та тестовому наборі даних

В останні роки системи виявлення та класифікації раку молочної залози набувають усе більшого поширення в медичній сфері, роблячи процес діагностики точнішим і швидшим. Головною метою

запропонованого алгоритму є підвищення якості клінічної діагностики. Підсумовуючи, можна стверджувати, що застосування оптимізованої архітектури ResNet-50 демонструє покращену продуктивність порівняно з існуючими методами. Такий підхід може бути ефективно інтегрований у медичні інформаційні системи для оцінки знімків у режимі реального часу, допомагаючи лікарям-радіологам автоматизувати рутинний аналіз мамограм і зменшити ймовірність лікарської помилки через людський фактор.

3.4 Практична реалізація та тестування програмного застосунку

Після успішного завершення етапу навчання та тестування нейромережевої моделі, ключовим завданням стала інтеграція розробленого алгоритму в зручний користувацький інтерфейс. Робота програмного застосунку розглядається не з позиції інженера з машинного навчання, а з точки зору кінцевого користувача – лікаря-радіолога. Програма функціонує в експлуатаційному режимі (режимі інференсу): навчання виконано заздалегідь, а застосунок використовує збережений класифікатор як допоміжний інструмент підтримки прийняття медичних рішень.

Логіку роботи системи побудовано таким чином, щоб мінімізувати кількість дій з боку лікаря та максимально автоматизувати процеси обчислення. На рисунку 3.9 наведено загальну блок-схему алгоритму аналізу мамографічного знімка всередині розробленого застосунку.

Відповідно до наведеної схеми, життєвий цикл обробки одного медичного знімка складається з таких послідовних кроків.

Завантаження вхідного знімка. Робота починається з того, що лікар завантажує мамограму з локального файлового сховища. Застосунок підтримує роботу зі стандартними медичними та графічними форматами (DICOM, PNG, JPG).

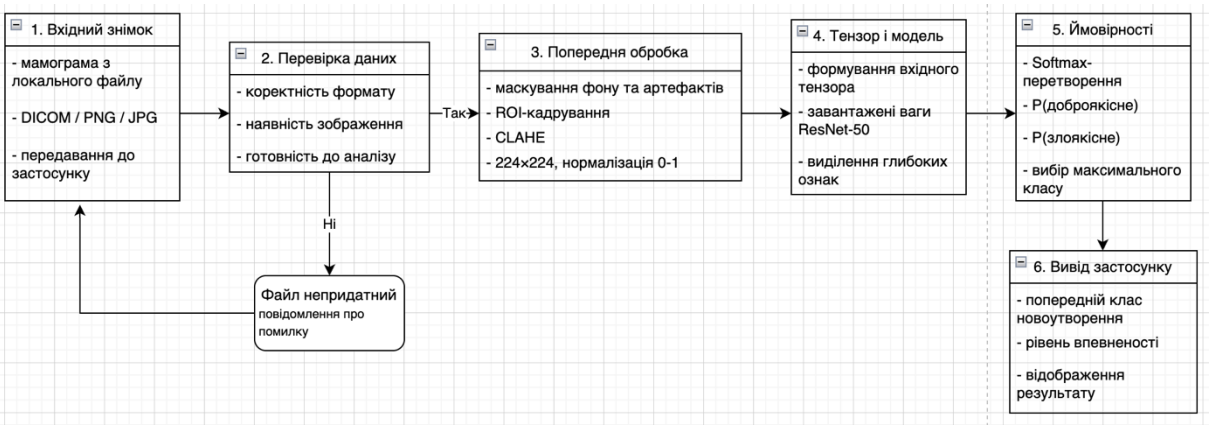


Рисунок 3.9 – Схема роботи програмного застосунку для класифікації мамограм

Перевірка даних (Валідація). Перед початком обчислень система автоматично перевіряє коректність формату файлу, наявність самого зображення та його готовність до аналізу. Якщо файл пошкоджено або формат не підтримується: програма перериває процес, виводить повідомлення про помилку та пропонує лікарю повторно завантажити коректний знімок. Якщо дані валідні: система переходить до наступного кроку.

Автоматична попередня обробка. Цей етап прихований від користувача і відбувається у фоновому режимі. Для того, щоб нове зображення відповідало формату, на якому навчалася модель, застосунок виконує маскування фону, видалення артефактів та кадрування області інтересу (ROI). Далі до знімка застосовується фільтр CLAHE для підвищення контрастності тканин. Зображення масштабується до розміру 224×224 пікселів, а значення його інтенсивності нормалізуються в діапазоні від 0 до 1.

Тензор і виділення ознак моделі. Оброблене зображення конвертується у багатовимірний масив (вхідний тензор) і передається до згорткової нейронної мережі. Програма завантажує попередньо збережені

ваги моделі ResNet-50, яка здійснює прохід даних через усі свої шари, виділяючи глибокі ієрархічні ознаки патологій.

Обчислення ймовірностей. На останньому етапі архітектури застосовується математичне перетворення Softmax. Воно генерує відсотковий розподіл ймовірностей приналежності знімка до одного з двох вихідних класів: P(доброякісне) та P(злоякісне). Алгоритм порівнює ці значення і обирає клас із максимальною ймовірністю.

Формування виходу застосунку. На екран користувача виводиться фінальний результат: попередній діагноз (клас новоутворення) та рівень впевненості нейромережі у відсотках. Завершальним кроком є можливість для лікаря зберегти отриманий результат у базу даних або передати його для подальшого оформлення медичного висновку.

Такий конвеєр забезпечує високу швидкість обробки інформації, дозволяючи отримувати результати аналізу практично миттєво після завантаження знімка.

Для безпосередньої взаємодії лікаря з розробленою нейромережевою моделлю було створено графічний інтерфейс користувача під назвою «MammoAnalyzer». Головною вимогою до інтерфейсу була його простота, інтуїтивність та відсутність зайвих технічних деталей, які могли б відволікати медичного спеціаліста від аналізу знімка.

На рисунку 3.10 наведено зовнішній вигляд головного вікна програмного застосунку під час експлуатації та продемонстровано результати успішної класифікації реальної мамограми.

Вікно програми візуально та логічно розділене на дві основні функціональні зони. Зона візуалізації у лівій частині займає більшу частину екрана і призначена для відображення завантаженого рентгенівського знімка. Програма зберігає та виводить оригінальні пропорції файлу, що дозволяє лікарю детально розгледіти структуру молочної залози. Панель керування та результатів у правій частині містить інструменти для взаємодії з алгоритмом та виведення метрик. У блоці «Вхідні дані» розташована

кнопка вибору файлу та головний тригер «Аналізувати», який запускає конвеєр обробки. Нижче наведено системні статуси, які підтверджують, що зображення пройшло масштабування (224×224), нормалізацію (0-1) і було успішно оброблено моделлю ResNet-50.

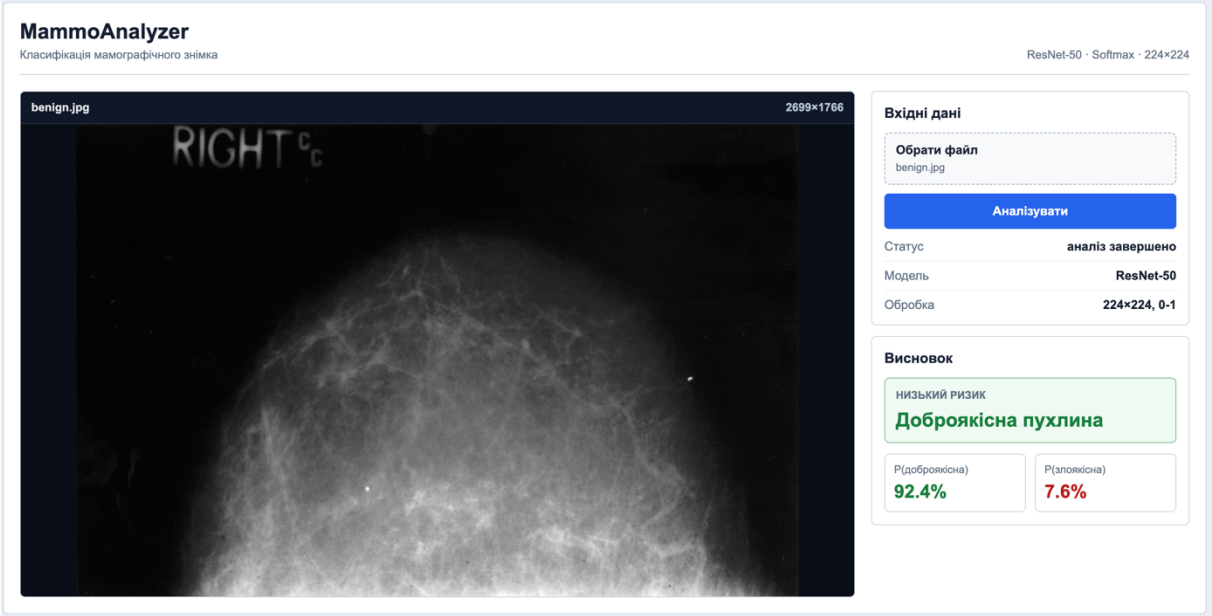


Рисунок 3.10 – Інтерфейс застосунку «MammoAnalyzer» та приклад класифікації доброякісного новоутворення

Найважливішим елементом інтерфейсу є інформаційний блок «Висновок», розташований у правому нижньому куті. У наведеному прикладі на вхід системи було подано мамограму з наявною патологією. Після проходження тензора через усі шари згорткової нейронної мережі, алгоритм успішно ідентифікував візуальні ознаки, характерні для безпечних патологій (наприклад, чіткі контури утворення без зірчастої структури).

Як наслідок, система вивела діагноз «Доброякісна пухлина» із зеленим маркером «низький ризик». Завдяки використанню функції активації Softmax на останньому шарі класифікатора, застосунок надає лікарю не лише кінцевий клас, але й відсотковий розподіл впевненості

моделі: ймовірність наявності доброякісного новоутворення 92.4%, ймовірність наявності злоякісного новоутворення 7.6%

Такий високий рівень впевненості (понад 90%) свідчить про те, що виділені моделлю глибокі ознаки є однозначними. Для лікаря-радіолога подібний результат, виданий системою як «друга думка», є вагомим аргументом на користь того, що пацієнтка не потребує термінової інвазивної біопсії, а може бути направлена на планове спостереження.

Для демонстрації здатності алгоритму виявляти небезпечні патології, розглянемо другий приклад тестування системи. На рисунку 3.11 наведено результати обробки мамограми, що містить підтверджену карциному.

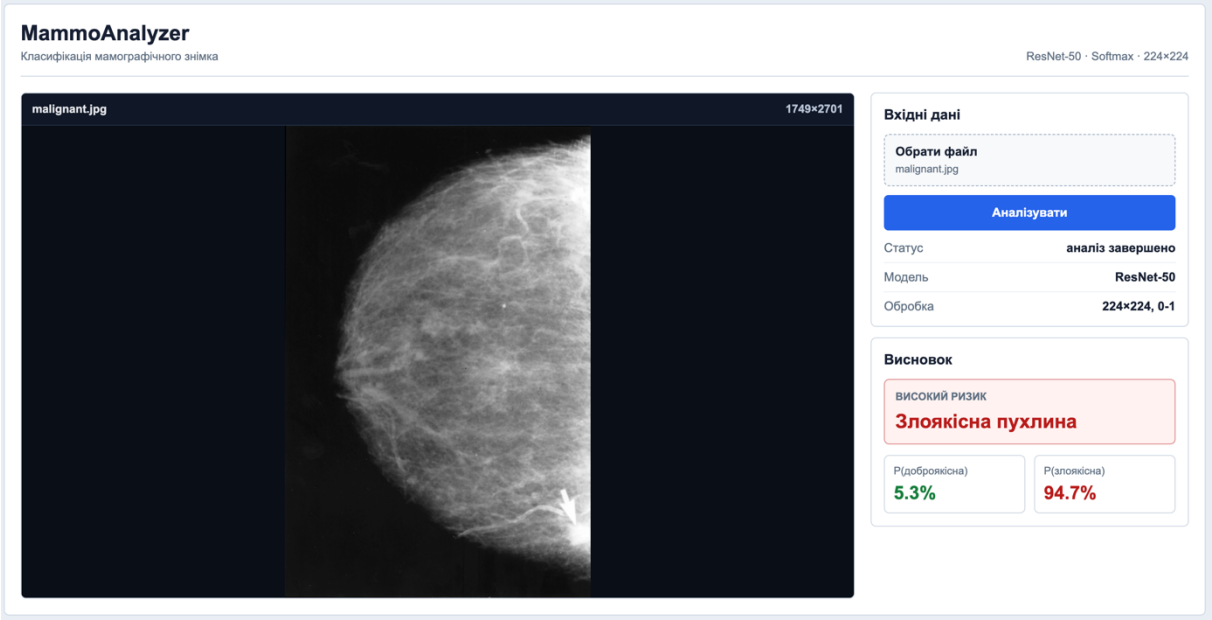


Рисунок 3.11 – Приклад класифікації злоякісного новоутворення в застосунку «MammoAnalyzer»

На завантаженому знімку у нижній частині молочної залози чітко візуалізується гіперінтенсивна ділянка з високою щільністю тканини. У клінічній практиці такі утворення, особливо якщо вони мають нерівні краї або супроводжуються скупченням мікрокальцинатів, є первинною ознакою злоякісного процесу.

Після проходження стандартного конвеєра попередньої обробки та аналізу тензора моделлю ResNet-50, застосунок успішно ідентифікував патологію як небезпечну. Блок «Висновок» миттєво відреагував на зміну прогнозу: інтерфейс застосував червоне кольорове маркування з позначкою «високий ризик» та вивів відповідний діагноз – «Злоякісна пухлина».

Розподіл ймовірностей, обчислений функцією Softmax, у цьому випадку становить: ймовірність наявності злоякісного новоутворення 94.7%, ймовірність наявності доброякісного новоутворення 5.3%.

Для лікаря-радіолога подібне критичне сповіщення від програмного застосунку відіграє роль надійного інструменту підстраховки. Воно гарантує, що підозріла ділянка не залишиться непоміченою через втому медичного працівника або замиленість ока під час масового скринінгу. Отримавши такий прогноз від системи, лікар має підстави для негайного направлення пацієнтки на додаткові діагностичні процедури (наприклад, УЗД, МРТ або трепан-біопсію), що є критично важливим для своєчасного початку лікування.

Логічним завершенням дослідження та розробки системи класифікації стала її успішна інтеграція у програмний застосунок із графічним інтерфейсом користувача «MammoAnalyzer». Практичне тестування на реальних мамограмах підтвердило, що розроблена програма здатна ефективно та швидко автоматизувати весь прихований конвеєр обробки медичних даних. Завдяки інтуїтивно зрозумілому інтерфейсу, кольоровому маркуванню ризиків та виведенню відсоткового розподілу ймовірностей, система забезпечує високий рівень інтерпретованості прогнозу. Це підтверджує готовність розробленого застосунку до використання як допоміжної клінічної системи підтримки прийняття рішень, що сприятиме пришвидшенню рутинного скринінгу та мінімізації ризику пропуску злоякісних новоутворень через людський фактор.

ВИСНОВКИ

У кваліфікаційній робот і вирішено актуальне науково-прикладне завдання, яке полягає у розробці та дослідженні системи інтелектуального аналізу мамограм для автоматизованої класифікації новоутворень молочної залози з використанням методів глибокого машинного навчання. Завдання на кваліфікаційну роботу виконано в повному обсязі, усі поставлені цілі досягнуто, а розроблений програмний застосунок повністю відповідає початковим вимогам.

В результаті виконання роботи спроєктовано, навчено та протестовано модель класифікації на базі згорткової нейронної мережі архітектури ResNet-50. Для забезпечення високої якості роботи алгоритму було реалізовано комплексний конвеєр попередньої обробки медичних зображень з набору даних CBIS-DDSM, який включав маскування фонових артефактів, просторову стандартизацію до уніфікованого розміру, нормалізацію інтенсивності пікселів та стратифікований розподіл даних (70% – тренувальна, 15% – валідаційна, 15% – тестова вибірки).

Аналіз досягнутих кількісних показників на незалежній тестовій вибірці підтверджує високу ефективність розробленої системи. Загальна точність моделі склала 93,0%, F1-міра досягла 93,03%, а площа під кривою помилок (ROC-AUC) – 93,02%. Особливу увагу було приділено аналізу якісних показників, критично важливих для медичної діагностики. Модель продемонструвала чутливість на рівні 93,83%, що свідчить про високу здатність алгоритму мінімізувати кількість хибно негативних результатів, тобто пропущених злоякісних пухлин. Водночас висока специфічність підтверджує здатність системи ефективно відфільтровувати здорові тканини та доброякісні новоутворення, мінімізуючи стрес для пацієнтів через хибні діагнози.

Проведений порівняльний аналіз показав, що розроблена система є конкурентоспроможною на тлі існуючих світових аналогів, зокрема

моделей на базі AlexNet, AdaBoost та традиційних штучних нейронних мереж. Більшість рішень у вільному доступі базуються на методах класичного машинного навчання з ручним виділенням ознак, що знижує їхню здатність до узагальнення. Натомість запропонований підхід на базі ResNet-50 автоматизує процес виділення глибоких ознак, таких як мікрокальцинати чи порушення побудови тканин. У порівнянні з аналогами, які тестувалися на наборах DDSM та INbreast, запропонована архітектура усуває проблему дисбалансу між чутливістю та специфічністю, демонструючи стабільно високі показники за обома векторами без зміщення в бік мажоритарного класу.

Тематика виконаної кваліфікаційної роботи тісно пов’язана з пріоритетними напрямками науково-дослідної роботи кафедри штучного інтелекту Харківського національного університету радіоелектроніки у межах вивчення проблематики обробки великих біомедичних даних, штучного інтелекту та комп’ютерного зору. Результати дослідження доповнюють існуючу наукову базу кафедри в галузі інтелектуального аналізу сигналів та зображень.

Наукова новизна отриманих результатів полягає у вдосконаленні процесу адаптації архітектури ResNet-50 для аналізу рентгенографічних мамографічних проєкцій через застосування оптимізованого конвеєра обробки та унітарного кодування міток, що дозволило підвищити точність ідентифікації карцином в умовах незбалансованих даних. Рекомендації щодо подальшої роботи в даному напрямку включають перехід від аналізу поодиноких двовимірних зображень до одночасної мультимодальної класифікації відразу двох проєкцій в одній тензорній структурі, інтеграцію алгоритмів детекції об’єктів для не лише класифікації мамограм в цілому, але й візуального виділення контурів підозрілих новоутворень для лікаря, а також розширення навчальної вибірки за рахунок локальних медичних установ для адаптації моделі до специфіки роботи місцевого рентгенографічного обладнання.

Практичним результатом роботи стала розробка та впровадження програмного застосунку з графічним інтерфейсом користувача «MammoAnalyzer». Завдяки інтеграції навченої моделі ResNet-50 у зручне клієнтське середовище, вдалося повністю автоматизувати складний конвеєр тіньової обробки даних: від попереднього поліпшення якості рентгенівського знімка до математичної оцінки тензорів. Практична апробація застосунку довела його ефективність як допоміжної клінічної системи підтримки прийняття рішень. Програма здатна в режимі реального часу надавати лікарю-радіологу «другу думку» з відсотковим рівнем впевненості, що сприятиме зниженню когнітивного навантаження на медичний персонал та зменшенню ймовірності пропуску злоякісних патологій під час масового скринінгу.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1) A comprehensive survey on the application of deep and reinforcement learning approaches in autonomous driving / B. B. Elallid et al. *Journal of king saud university - computer and information sciences*. 2022. URL: https://doi.org/10.1016/j.jksuci.2022.03.013 (date of access: 25.05.2026).

2) Beremauro S., Girio-Fragkoulakis C. Imaging techniques in breast cancer. *Surgery (oxford)*. 2022. Vol. 40, no. 2. P. 94–103. URL: https://doi.org/10.1016/j.mpsur.2021.11.014 (date of access: 25.05.2026).

3) A survey on deep learning in medical image analysis / G. Litjens et al. *Medical image analysis*. 2017. Vol. 42. P. 60–88. URL: https://doi.org/10.1016/j.media.2017.07.005 (date of access: 25.05.2026).

4) Support vector machines / M. A. Hearst et al. *IEEE intelligent systems and their applications*. 1998. Vol. 13, no. 4. P. 18–28. URL: https://doi.org/10.1109/5254.708428 (date of access: 25.05.2026).

5) A new approach to radial basis function approximation and its application to QSAR / A. V. Zakharov et al. *Journal of chemical information and modeling*. 2014. Vol. 54, no. 3. P. 713–719. URL: https://doi.org/10.1021/ci400704f (date of access: 25.05.2026).

6) Roman V. I., Buhaichuk M. I., Ostrei Y. S. Methodology of artificial neural networks application for the enhancement ultrasonic flow meters accuracy (Ukr). *Scientific works of vinnytsia national technical university*. 2025. No. 2. URL: https://doi.org/10.31649/2307-5376-2025-2-1-10 (date of access: 25.05.2026).

7) Agarap A. F. Deep learning using rectified linear units (relu). 2018. URL: https://doi.org/10.48550/arXiv.1803.08375 (date of access: 25.05.2026).

8) Hybrid transformer-based model for mammogram classification by integrating prior and current images / A. A. Jeny et al. *Medical physics*. 2025. URL: https://doi.org/10.1002/mp.17650 (date of access: 25.05.2026).

9) High-resolution breast cancer screening with multi-view deep convolutional neural networks / J. G. Krzysztof et al. 2011. URL: https://doi.org/10.48550/arXiv.1703.07047 (date of access: 25.05.2026).

10) Fowler A. M., Strigel R. M. Clinical advances in PET–MRI for breast cancer. *The lancet oncology*. 2022. Vol. 23, no. 1. P. e32-e43. URL: https://doi.org/10.1016/s1470-2045(21)00577-5 (date of access: 25.05.2026).

11) Salman H. A., Kalakech A., Steiti A. Random forest algorithm overview. *Babylonian journal of machine learning*. 2024. Vol. 2024. P. 69–79. URL: https://doi.org/10.58496/bjml/2024/007 (date of access: 25.05.2026).

12) Brain stroke lesion segmentation using computed tomography images based on modified u-net model with resnet blocks / A. Tursynova et al. *International journal of online and biomedical engineering (ijoe)*. 2022. Vol. 18, no. 13. P. 97–112. URL: https://doi.org/10.3991/ijoe.v18i13.32881 (date of access: 25.05.2026).

13) Exploring the efficacy of group normalization in deep learning models for alzheimer's disease classification / G. Habib et al. *SN computer science*. 2026. Vol. 7, no. 2. URL: https://doi.org/10.1007/s42979-025-04622-w (date of access: 25.05.2026).

14) Kaiming H., Xiangyu Z., Shaoqing R. Deep residual learning for image recognition. 2013. URL: https://doi.org/10.48550/arXiv.1512.03385 (date of access: 25.05.2026).

15) Fawcett T. An introduction to ROC analysis. *Pattern recognition letters*. 2006. Vol. 27, no. 8. P. 861–874. URL: https://doi.org/10.1016/j.patrec.2005.10.010 (date of access: 25.05.2026).

16) Content-based retrieval of mammograms using visual features related to breast density patterns / S. K. Kinoshita et al. *Journal of digital imaging*. 2007. Vol. 20, no. 2. P. 172–190. URL: https://doi.org/10.1007/s10278-007-9004-0 (date of access: 25.05.2026).

17) An explainable transfer learning framework for breast cancer histopathology classification using cnns / H. H. Hai et al. *2025 IEEE 7th international conference on computing, communication and automation (ICCCA)*, Greater Noida, India, 28–30 November 2025. 2025. P. 1–7. URL: https://doi.org/10.1109/iccca66364.2025.11325662 (date of access: 25.05.2026).

18) FFDM image quality assessment using computerized image texture analysis / R. Berger et al. *SPIE medical imaging*, San Diego, California, United States. 2010. URL: https://doi.org/10.1117/12.845297 (date of access: 25.05.2026).

19) Efficient breast cancer diagnosis from complex mammographic images using deep convolutional neural network / H. Rahman et al. *Computational intelligence and neuroscience*. 2023. Vol. 2023. P. 1–11. URL: https://doi.org/10.1155/2023/7717712 (date of access: 25.05.2026).

20) Carneiro G., Nascimento J., Bradley A. P. Automated analysis of unregistered multi-view mammograms with deep learning. *IEEE transactions on medical imaging*. 2017. Vol. 36, no. 11. P. 2355–2365. URL: https://doi.org/10.1109/tmi.2017.2751523 (date of access: 25.05.2026).

21) Dhungel N., Carneiro G., Bradley A. P. A deep learning approach for the analysis of masses in mammograms with minimal user intervention. *Medical image analysis*. 2017. Vol. 37. P. 114–128. URL: https://doi.org/10.1016/j.media.2017.01.009 (date of access: 25.05.2026).

22) DE-Ada*: a novel model for breast mass classification using cross-modal pathological semantic mining and organic integration of multi-feature fusions / H. Zhang et al. *Information sciences*. 2020. Vol. 539. P. 461–486. URL: https://doi.org/10.1016/j.ins.2020.05.080 (date of access: 25.05.2026).

23) Extraction of spiculated parts of mammogram tumors to improve accuracy of classification / H. Pezeshki et al. *Multimedia tools and applications*. 2019. Vol. 78, no. 14. P. 19979–20003. URL: https://doi.org/10.1007/s11042-019-7185-4 (date of access: 25.05.2026).