

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА ШЕВЧЕНКА

Кваліфікаційна наукова  
праця на правах рукопису

**СУЧКОВ Валентин Іванович**

УДК 004.93

**ДИСЕРТАЦІЯ**  
**МОДЕЛІ ТА МЕТОДИ ОБРОБКИ**  
**МЕДИЧНИХ ЗОБРАЖЕНЬ ГРУДНОЇ КЛІТИНИ**

124 – Системний аналіз

12 – Інформаційні технології

Подається на здобуття наукового ступеня  
доктора філософії

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів має посилання на відповідне джерело.

\_\_\_\_\_ Сучков

Науковий керівник: **Пашко Анатолій Олексійович**,  
доктор фізико-математичних наук, професор

Київ – 2026

## АНОТАЦІЯ

*Сучков В.І.* Моделі та методи обробки медичних зображень грудної клітини. — Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 124 "Системний аналіз" (12 — Інформаційні технології). — Київський національний університет імені Тараса Шевченка, Київ, 2026.

Дисертаційна робота присвячена дослідженню, розробленню та реалізації методів автоматизованої обробки й аналізу медичних зображень грудної клітини. Зростання кількості медичних зображень і потреба у швидкому аналізі результатів обстежень зумовлюють актуальність розроблення методів їх автоматизованої обробки. Пандемія COVID-19 додатково підкреслила потребу у швидкому аналізі великої кількості рентгенівських зображень грудної клітини та зображень комп'ютерної томографії.

У роботі застосовано методи попередньої обробки рентгенівських зображень, класифікації зображень за допомогою згорткової нейронної мережі, сегментації області легень та виділення області ураження інфекцією. Особливу увагу приділено пороговим методам сегментації, методу k-середніх та нейромережевим підходам до сегментації області ураження. Дослідження спрямоване на розвиток наявних підходів до аналізу медичних зображень грудної клітини.

Розглядаються анатомічно орієнтовані показники для оцінювання результатів сегментації області легень, що можуть використовуватися для аналізу результатів за відсутності еталонної розмітки. На основі даних показників сформовано інтегральну оцінку для вибору результату сегментації серед альтернативних порогових методів.

Розроблені підходи формують цілісну послідовність автоматизованого аналізу медичних зображень грудної клітини, у якій попередня обробка, класифікація, сегментація та оцінювання результатів розглядаються як взаємопов'язані елементи системного аналізу процесу обробки медичних

зображень. Дані підходи можуть бути використані як складові інформаційної технології підтримки прийняття рішень.

**Метою** дисертаційної роботи є: дослідження, розроблення та реалізація методів автоматизованої обробки медичних зображень грудної клітини для сегментації області легень, сегментації ділянок ураження інфекцією та класифікації за станами дихальної системи із застосуванням системного аналізу, методів комп'ютерного зору та нейромережевих архітектур.

**Об'єктом** дослідження є процеси аналізу та інтелектуальної обробки медичних зображень грудної клітини в інформаційно-аналітичних медичних системах.

**Предметом** дослідження є моделі, методи та алгоритми обробки, сегментації, класифікації та інтерпретації медичних зображень грудної клітини із застосуванням методів системного аналізу, комп'ютерного зору та штучного інтелекту.

**Методика дослідження:** у роботі використано методи системного аналізу, методи глибокого навчання та класичні методи обробки зображень, зокрема порогову сегментацію, кластеризацію і морфологічну обробку.

На першому етапі виконується підготовка медичних зображень грудної клітини до подальшого аналізу. Для цього застосовуються методи попередньої обробки, зокрема фільтрація шуму, підсилення локального контрасту та аналіз гістограм інтенсивності. Дані методи використовуються для покращення якості вхідних рентгенівських зображень та дослідження їх впливу на результати класифікації.

Для задачі класифікації рентгенівських зображень грудної клітини використовується згортова нейронна мережа. Модель виконує класифікацію зображень за трьома класами: COVID-19, пневмонія та відсутність захворювання. Оцінювання результатів класифікації здійснюється за показниками Ассурасу, Recall, Precision та F1-міри.

Для сегментації області легень застосовуються класичні порогові ме-

тоди, зокрема метод Оцу, метод Капура та модифікований метод збалансованого порогового відсікання гістограми. До отриманого результату застосовуються морфологічні операції для уточнення форми сегментованої області.

Окремо розглядається оцінювання результатів сегментації за допомогою анатомічно орієнтованих показників: відносна площа сегментованої області, вертикальна симетрія, контраст між областю легень і фоном та стандартне відхилення інтенсивності пікселів у межах сегментованої області. На основі даних показників формується інтегральна оцінка, що використовується для вибору результату сегментації серед альтернативних порогових методів. Додатково для оцінювання збереження структурної інформації після попередньої обробки використовується показник SSIM.

Для сегментації області ураження інфекцією використовується нейромережева архітектура U-Net з енкодером ResNet18. Додатково досліджується застосування методу k-середніх для виділення області ураження за показником інтенсивності зображення.

Наведені методи класифікації, сегментації та оцінювання результатів формують послідовність пов'язаних елементів системного аналізу автоматизованої обробки медичних зображень грудної клітини. На основі розглянутих методів побудовано програмні засоби для обробки медичних зображень грудної клітини, що є складовими інформаційної технології підтримки прийняття рішень.

**Наукова новизна одержаних результатів** полягає у наступному:

*Вперше:*

- застосовано модифікований метод збалансованого порогового відсікання гістограми у задачі сегментації області легень на рентгівських зображеннях та проведено порівняльний аналіз його ефективності порівняно з класичними пороговими методами;
- запропоновано метод для непрямого оцінювання якості сегментації

області легень на рентгенівських зображеннях грудної клітини на основі анатомічно орієнтованих показників;

- розроблено механізм багатокритеріального вибору результату сегментації серед альтернативних порогових методів на основі інтегральної оцінки анатомічно орієнтованих показників.

*Удосконалено:*

- модель сегментації області ураження інфекцією на рентгенівських зображеннях грудної клітини за допомогою нейронної мережі з попереднім обмеженням вхідного зображення маскою області легень;
- підхід до застосування згорткових нейронних мереж для класифікації рентгенівських зображень грудної клітини з використанням методів попередньої обробки.

*Набуло подальшого розвитку:*

- алгоритм сегментації області ураження на зображеннях комп'ютерної томографії грудної клітини за допомогою попереднього виділення області легень пороговим методом та кластеризації пікселів за значеннями інтенсивності методом k-середніх у межах отриманої області легень.

**Практична цінність одержаних результатів** полягає у розробленні програмних засобів для обробки та аналізу медичних зображень грудної клітини. Реалізовані методи дають змогу виконувати попередню обробку зображень та класифікацію рентгенівських зображень грудної клітини за допомогою згорткової нейронної мережі. Розроблені програмні засоби включають реалізацію сегментації області легень, сегментацію області ураження інфекцією та розрахунок анатомічно орієнтованих показників.

**Ключові слова:** дані рентгенографії грудної клітини, дані комп'ютерної томографії грудної клітини, нейронні мережі, попередня обробка зображень, порогові методи сегментації, анатомічно орієнтоване оцінювання сегментації, сегментація області легень, сегментація області ураження інфе-

кцією, ураження типу матового скла, метод кластеризації k-середніх, інтегральна оцінка, оцінювання, гібридні методи, машинне та глибоке навчання.

## ANNOTATION

*Suchkov V.I.* Models and methods for medical chest image processing. — Qualifying scientific work on the rights of a manuscript.

Thesis for a scientific degree of Doctor of Philosophy in specialty 124 “System Analysis” (12 — Information Technologies). — Taras Shevchenko National University of Kyiv, Kyiv, 2026.

The research is devoted to the investigation, development and implementation of methods for automated processing and analysis of medical chest images. The growing number of medical images and the need for fast analysis of examination results increase the importance of automated processing methods. The COVID-19 pandemic also increased the need for rapid analysis of large numbers of chest X-ray and chest computed tomography images.

The work applies methods of preprocessing chest X-ray images, image classification using a convolutional neural network, lung region segmentation, and infection lesion segmentation. The research focuses on threshold-based segmentation methods, the k-means method, and neural network approaches to infection lesion segmentation. The study contributes to improving existing approaches to the analysis of medical chest images.

Anatomically oriented indicators for evaluating lung region segmentation results are considered. These indicators can be used to analyze segmentation results in cases where manually annotated reference data is unavailable. Based on these indicators, an integral score is formed for selecting the segmentation result among alternative threshold-based methods.

The developed approaches form an automated medical image analysis pipeline, where preprocessing, classification, segmentation, and result evaluation are considered as interconnected stages of a system analysis approach to medical image processing. These approaches can be used as components of an information technology for decision support.

**The aim** of the dissertation work is to investigate, develop and implement

methods for automated processing of medical chest images for lung region segmentation, infection lesion segmentation and classification of respiratory system conditions using system analysis, computer vision methods, and neural network architectures.

**The object** of the research is the process of automated processing and analysis of medical chest images.

**The subject** of the research is chest X-ray image classification and preprocessing methods, lung region segmentation methods and anatomically oriented evaluation of segmentation results, as well as methods for infection lesion segmentation.

**Research methods:** the research uses methods of system analysis, deep learning, and classical image processing, including threshold-based segmentation, clustering, and morphological processing.

At the first stage, medical chest images are prepared for further analysis. For this purpose, preprocessing methods are applied, including noise filtering and local contrast enhancement. These methods are used to improve the quality of input chest X-ray images and to study their influence on classification results.

For chest X-ray image classification, a convolutional neural network is used. The model performs image classification into three classes: COVID-19, pneumonia, and normal cases. Classification results are evaluated using Accuracy, Recall, Precision, and F1-score.

Classical threshold-based methods are used for lung region segmentation, in particular Otsu's method, Kapur's method, and a modified balanced histogram thresholding method. Morphological operations are applied to the obtained results to refine the shape of the segmented region.

Segmentation results are evaluated using anatomically oriented indicators: relative area of the segmented region, vertical symmetry, contrast between the lung region and the background, and standard deviation of pixel intensity within the segmented region. Based on these indicators, an integral score is formed and used to select the segmentation result among alternative threshold-based

methods. In addition, the SSIM index is used to evaluate the preservation of structural information after image preprocessing.

For infection lesion segmentation, a U-Net neural network architecture with a ResNet18 encoder is used. In addition, the k-means method is studied for lesion region extraction based on image intensity characteristics.

The presented methods of classification, segmentation and result evaluation form a sequence of interconnected elements within a system analysis approach to the automated processing of medical chest images. Based on the considered methods, software tools for processing medical chest images were developed as components of an information technology for decision support.

**Scientific novelty** of the study is as follows:

*For the first time:*

- the modified balanced histogram thresholding method was applied to lung region segmentation in chest X-ray images and compared with classical threshold-based methods;
- the method for indirect evaluation of lung region segmentation results in chest X-ray images was proposed based on anatomically oriented indicators;
- a mechanism for multicriteria selection of a segmentation result among alternative threshold-based methods was developed based on the integral evaluation of anatomically oriented indicators.

*The following was improved:*

- the model for infection lesion segmentation in chest X-ray images using a neural network model, where the input image is restricted by the lung region mask;
- the approach to applying convolutional neural networks for chest X-ray image classification using image preprocessing methods.

*The following idea was further researched:*

- the algorithm for infection lesion segmentation in chest CT images usi-

ng lung region extraction by a threshold-based method and k-means clustering of pixels by intensity values within the obtained lung region.

**Practical value** of the obtained results is related to development of software tools for processing and analyzing medical chest images. The implemented methods allow performing image preprocessing and chest X-ray image classification using a convolutional neural network. The developed software tools include lung region segmentation, infection lesion segmentation, and calculation of anatomically oriented indicators.

**Key words:** chest radiography data, chest computed tomography data, neural networks, image preprocessing, threshold-based segmentation methods, anatomically oriented segmentation evaluation, lung region segmentation, infection lesion segmentation, ground-glass opacity lesions, k-means clustering method, integral evaluation, evaluation, hybrid methods, machine learning and deep learning.

## СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА:

*Наукові праці, в яких опубліковані основні наукові результати дисертації:*

1. В. І. Сучков та А. О. Пашко, «Згорткова нейронна мережа для класифікації рентген-знімків грудної клітини», *Журнал обчислювальної та прикладної математики*, вип. 2, с. 77–86, Груд. 2025.  
<https://doi.org/10.17721/2706-9699.2025.2.06>
2. А. О. Пашко та В. І. Сучков, «Сегментація легень на рентген-знімках грудної клітини з анатомічно орієнтованою оцінкою», *Наукові праці Вінницького національного технічного університету*, вип. 1, с. 161–171, Бер. 2026.  
<https://doi.org/10.31649/2307-5376-2026-1-161-171>
3. В. І. Сучков, «Методи попереднього оброблення рентген-знімків грудної клітини в задачі класифікації», *Наука, технології, інновації*, вип. 1(37), с. 110–115, 2026.  
<https://doi.org/10.35668/2520-6524-2026-1-11>
4. В. І. Сучков, «Застосування методу збалансованого порогового відсікання гістограми у задачі сегментації легень на рентгенівських зображеннях грудної клітини», *Журнал обчислювальної та прикладної математики*, вип. 1, с. 99–108, Квіт. 2026.  
<https://doi.org/10.17721/2706-9699.2026.1.07>

**Наукові праці, які засвідчують апробацію матеріалів дисертації:**

1. V. I. Suchkov and A. O. Pashko, "COVID-19 Computed Tomography Image Processing Based on Statistical Segmentation Methods," in *Abstracts of the XXXIX International Conference "Problems of Decision Making Under Uncertainties" (PDMU-2024)*, Brno, Czech Republic, Sept. 9–10, 2024, pp. 133–134.
2. В. І. Сучков, "Штучний інтелект у сфері охорони здоров'я II Всеукраїнська науково-практична конференція з міжнародною участю "PROКиїв", Київ, Україна, 3–4 грудня 2024, с. 477–479.
3. А. О. Пашко та В. І. Сучков, "Застосування згорткових нейронних мереж для класифікації рентген-знімків легень XIII Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2024, с. 235–239.
4. В. І. Сучков та А. О. Пашко, "Сегментація області легень на рентген-знімках грудної клітини XIV Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2025, с. 346–348.

## ЗМІСТ

|                                                                                                              |           |
|--------------------------------------------------------------------------------------------------------------|-----------|
| <b>Вступ</b>                                                                                                 | <b>17</b> |
| <b>Розділ 1. Аналіз сучасних методів обробки медичних зображень грудної клітини</b>                          | <b>23</b> |
| 1.1. Методи класифікації рентген-зображень грудної клітини . . .                                             | 24        |
| 1.2. Попередня обробка як покращення якості даних у задачі класифікації . . . . .                            | 27        |
| 1.3. Сегментація області легень та зони ураження інфекцією на медичних зображеннях грудної клітини . . . . . | 29        |
| 1.3.1. Методи машинного та глибокого навчання . . . . .                                                      | 29        |
| 1.3.2. Класичні та гібридні методи . . . . .                                                                 | 34        |
| 1.3.3. Підходи до оцінювання та валідації результатів сегментації . . . . .                                  | 37        |
| Висновки до розділу 1 . . . . .                                                                              | 39        |
| <b>Розділ 2. Моделі, методи та дані дослідження</b>                                                          | <b>41</b> |
| 2.1. Архітектура моделі класифікації рентген-зображень грудної клітини . . . . .                             | 41        |
| 2.2. Порогові методи сегментації області легень . . . . .                                                    | 44        |
| 2.3. Модель оцінювання та вибору результатів сегментації області легень . . . . .                            | 51        |
| 2.3.1. Анатомічно орієнтовані показники оцінювання сегментації . . . . .                                     | 51        |
| 2.3.2. Постановка задачі багатокритеріального вибору результату сегментації . . . . .                        | 54        |

|                                                                                                                            |            |
|----------------------------------------------------------------------------------------------------------------------------|------------|
| 2.3.3. Метод вибору результату сегментації на основі інтегральної оцінки . . . . .                                         | 55         |
| 2.4. Архітектура моделі сегментації області ураження на рентген-зображеннях . . . . .                                      | 58         |
| Висновки до розділу 2 . . . . .                                                                                            | 61         |
| <b>Розділ 3. Експериментальна перевірка запропонованих моделей і методів</b>                                               | <b>63</b>  |
| 3.1. Оцінювання якості класифікації . . . . .                                                                              | 63         |
| 3.2. Оцінювання порогових методів сегментації області легень . .                                                           | 70         |
| 3.3. Застосування анатомічно орієнтованих показників для сегментації області легень . . . . .                              | 75         |
| 3.3.1. Дослідження анатомічно орієнтованого оцінювання сегментації . . . . .                                               | 75         |
| 3.3.2. Аналіз критеріїв оцінювання результатів сегментації .                                                               | 81         |
| 3.4. Вибір результату сегментації на основі інтегральної оцінки .                                                          | 86         |
| 3.5. Постобробка сегментованої області за допомогою морфологічних методів . . . . .                                        | 96         |
| 3.6. Сегментація області ураження інфекцією на рентген-зображеннях грудної клітини за допомогою нейронної мережі . . . . . | 101        |
| 3.7. Сегментація області ураження за допомогою методу кластеризації k-середніх . . . . .                                   | 109        |
| 3.8. Застосування класичних методів сегментації до КТ-зображень легень . . . . .                                           | 111        |
| Висновки до розділу 3 . . . . .                                                                                            | 115        |
| <b>Розділ 4. Програмна реалізація</b>                                                                                      | <b>117</b> |
| 4.1. Сегментація області легень . . . . .                                                                                  | 118        |
| 4.2. Сегментація області ураження інфекцією за допомогою нейронних мереж . . . . .                                         | 126        |

|                                                                                                                        |            |
|------------------------------------------------------------------------------------------------------------------------|------------|
| 4.3. Сегментація області ураження інфекцією на рентгенівських зображеннях за допомогою методу кластеризації k-середніх | 129        |
| 4.4. Сегментація області ураження на КТ-зображеннях за допомогою методу кластеризації k-середніх . . . . .             | 132        |
| 4.5. Класифікація рентген-зображень грудної клітини . . . . .                                                          | 136        |
| Висновки до розділу 4 . . . . .                                                                                        | 137        |
| <b>Висновки</b>                                                                                                        | <b>140</b> |
| <b>Список використаних джерел</b>                                                                                      | <b>142</b> |
| <b>Додаток — Список публікацій здобувача</b>                                                                           | <b>154</b> |

**Список умовних позначень:**

Грецькі літери:  $\alpha$  — альфа,  $\beta$  — бета,  $\delta$  — дельта,  $\epsilon$  — епсилон,  $\mu$  — мю,  $\sigma$  — сигма,  $\omega$  — омега.

Константи:  $e$  — експонента.

Скорочення: КТ — комп'ютерна томографія; COVID-19 — коронавірусна хвороба 2019 року.

## ВСТУП

### **Актуальність теми.**

Швидкий розвиток методів штучного інтелекту та комп'ютерного зору створює нові можливості для автоматизованого аналізу медичних зображень. Рентгенівські зображення грудної клітини є одним із найбільш поширених методів медичної візуалізації, що застосовується для виявлення патологічних змін у легенях. Зростання кількості медичних зображень та потреба у швидкому аналізі результатів обстежень зумовлюють актуальність розроблення методів їх автоматизованої обробки. Особливої актуальності це набуло під час пандемії COVID-19 через потребу у швидкому аналізі великої кількості рентгенівських зображень та зображень комп'ютерної томографії грудної клітини. Методи обробки зображень, комп'ютерного зору та глибокого навчання дають змогу автоматизувати окремі етапи такого аналізу, зокрема попередню обробку, сегментацію області легень, виділення області ураження та класифікацію зображень.

Важливим етапом комп'ютерного аналізу медичних зображень грудної клітини є попередня обробка, яка дає змогу зменшити вплив шуму, нормалізувати інтенсивність та підвищити виразність локальних структур. Використання методів попередньої обробки підвищує якість вхідних даних для задачі класифікації рентгенівських зображень. Окреме значення має сегментація області легень, оскільки вона дозволяє відокремити анатомічно важливу область від фону та інших структур зображення. Коректне виділення області легень може використовуватися як етап підготовки для сегментації області патологічних змін.

У даній роботі сукупність методів обробки медичних зображень грудної клітини розглядається як єдиний інформаційно-аналітичний процес

автоматизованого аналізу медичних зображень та підтримки прийняття рішень, що включає попередню обробку зображень, класифікацію рентген-зображень, сегментацію області легень та її анатомічно орієнтоване оцінювання, багатокритеріальний вибір результату сегментації області легень та сегментацію патологічних областей.

Основний науковий акцент роботи зроблено на формалізації анатомічно орієнтованого оцінювання та багатокритеріального вибору маски області легень за умов відсутності еталонної розмітки.

### **Мета і завдання.**

Метою дисертаційної роботи є розроблення та дослідження методів обробки зображень для автоматизованого аналізу медичних зображень грудної клітини із застосуванням системного аналізу, комп'ютерного зору та нейромережових архітектур для класифікації рентгенівських зображень, сегментації області легень та виділення області ураження інфекцією.

Для досягнення поставленої мети у роботі сформульовано та вирішено наступні завдання:

- провести аналіз сучасних методів обробки медичних зображень грудної клітини та визначити їх переваги, недоліки й обмеження;
- розробити та дослідити моделі класифікації патологій органів грудної клітини із використанням методів глибоких нейронних мереж;
- дослідити методи покращення якості медичних зображень грудної клітини, зокрема методи фільтрації, нормалізації та підвищення контрастності;
- провести системний аналіз процесу обробки медичних зображень з урахуванням невизначеності, шумів та варіативності медичних даних;
- розробити методи сегментації анатомічних структур і патологічних областей на медичних зображеннях грудної клітини;
- розробити програмні складові інформаційної технології підтримки

прийняття рішень для автоматизованого аналізу медичних зображень грудної клітини;

- провести експериментальне дослідження ефективності запропонованих моделей та методів на реальних медичних наборах даних;
- оцінити точність, чутливість, специфічність та обчислювальну ефективність розроблених методів у порівнянні з існуючими підходами;
- розробити програмне забезпечення для реалізації запропонованих моделей і методів обробки медичних зображень грудної клітини.

### **Методи дослідження.**

У дисертаційній роботі використано методи цифрової обробки зображень, зокрема фільтрацію шуму, підсилення локального контрасту, аналіз гістограм інтенсивності, порогову сегментацію та морфологічну обробку сегментації. Дані методи застосовано для попередньої обробки рентгеновських зображень грудної клітини та сегментації області легень.

Для класифікації рентгеновських зображень і сегментації області ураження використано методи глибокого навчання. У задачі класифікації застосовано згорткову нейронну мережу з визначеною архітектурою. Для сегментації області ураження інфекцією – архітектуру U-Net з енкодером ResNet18. Додатково для сегментації області ураження інфекцією використано метод k-середніх.

У роботі використовуються анатомічно орієнтовані показники сегментації, на основі яких сформовано інтегральну оцінку для методу вибору результату сегментації серед альтернативних порогових методів.

**Наукова новизна отриманих результатів.** На захист виносяться модифікований метод збалансованого порогового відсікання гістограми для сегментації області легень на рентгеновських зображеннях, анатомічно орієнтовані показники оцінювання результатів сегментації, метод вибору результату сегментації серед альтернативних порогових методів на основі інтегральної оцінки, удосконалений підхід до застосування згорткових ней-

ронних мереж для класифікації рентгенівських зображень з урахуванням попередньої обробки, а також підходи до сегментації області ураження інфекцією на рентгенівських та КТ-зображеннях із використанням нейромережевої моделі, інформації про область легень та методу k-середніх.

**Особистий внесок здобувача.** Науковому керівнику належить постановка задачі та рекомендації щодо вибору методів розв’язання проміжних задач.

Претендентом опубліковано 8 наукових робіт [1–8]: 4 тези конференцій та 4 наукові статті. Творчий внесок у опубліковані роботи є наступним:

- Статті [5, 6] виконано у співавторстві з науковим керівником. Науковому керівнику належить постановка задачі та вибір загальної концепції алгоритмічного підходу. Стаття [5] присвячена розробленню архітектури згорткової нейронної мережі для класифікації рентгенівських зображень грудної клітини. Стаття [6] присвячена аналізу анатомічно орієнтованого оцінювання результату сегментації рентгенівських зображень грудної клітини за допомогою порогового методу.
- Статті [7, 8] написані без співавторів, постановка задач та рекомендації щодо методів розв’язання отримані від наукового керівника — А.О. Пашко. Стаття [7] присвячена аналізу та застосуванню існуючих методів попередньої обробки для рентгенівських зображень грудної клітини у задачі класифікації. Стаття [8] присвячена застосуванню модифікованого методу збалансованого порогового відсікання гістограми для задачі сегментації легень на рентгенівських зображеннях грудної клітини.
- Постановка задачі та ідеї досліджень, викладені у тезах конференцій, сформульовано за підтримки наукового керівника, виступи на усіх конференціях автор здійснив самостійно.

**Апробація наукових результатів** відбулась на конференціях:

1. V. I. Suchkov and A. O. Pashko, "COVID-19 Computed Tomography Image Processing Based on Statistical Segmentation Methods," in *Abstracts of the XXXIX International Conference "Problems of Decision Making Under Uncertainties" (PDMU-2024)*, Brno, Czech Republic, Sept. 9–10, 2024, pp. 133–134.
2. В. І. Сучков, "Штучний інтелект у сфері охорони здоров'я II Всеукраїнська науково-практична конференція з міжнародною участю "PROКиїв", Київ, Україна, 3–4 грудня 2024, с. 477–479.
3. А. О. Пашко та В. І. Сучков, "Застосування згорткових нейронних мереж для класифікації рентген-знімків легень XIII Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2024, с. 235–239.
4. В. І. Сучков та А. О. Пашко, "Сегментація області легень на рентген-знімках грудної клітини XIV Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2025, с. 346–348.

**Структура та обсяг дисертації.** Дисертація складається зі вступу та чотирьох розділів та має обсяг 155 сторінок, з них 125 основного тексту.

У першому розділі розглянуто сучасний стан досліджень у сфері класифікації та сегментації зображень грудної клітини.

У другому розділі наведено методи та матеріали дослідження, зокрема описано архітектуру згорткової нейронної мережі для класифікації рентген-зображень, методи попередньої обробки, порогові методи сегментації області легень та архітектуру нейронної мережі для сегментації області ураження. Окрему увагу приділено системі анатомічно орієнтованих показників, що використовуються для аналізу отриманої сегментації області легень та методу вибору результату сегментації серед альтернативних порогових методів на основі інтегральної оцінки.

У третьому розділі наведено результати експериментальних досліджень

методів обробки зображень грудної клітини. Досліджено вплив попередньої обробки на якість класифікації рентген-зображень, сегментацію області легень класичними пороговими методами та анатомічно орієнтоване оцінювання отриманої сегментації, сегментацію області ураження за допомогою нейромережевої моделі та методу k-середніх.

У четвертому розділі описано програмну реалізацію розроблених методів та побудову програмних засобів для обробки медичних зображень грудної клітини.

**Зв'язок роботи з науковими програмами.**

## РОЗДІЛ 1

# АНАЛІЗ СУЧАСНИХ МЕТОДІВ ОБРОБКИ МЕДИЧНИХ ЗОБРАЖЕНЬ ГРУДНОЇ КЛІТИНИ

Цифровізація медичної сфери є актуальним на сьогодні напрямом. Особливий поштовх цьому зумовила пандемія COVID-19, з огляду на яку виникла потреба вирішувати медичні проблеми та задачі, що пов'язані зі збором статистичних даних пацієнтів. Розширення застосування інформаційних технологій у сфері медицини є перспективним напрямом, оскільки воно спрямоване на підвищення ефективності обробки медичних даних, підтримку прийняття рішень та покращення якості діагностичного процесу. Основними задачами використання інформаційних технологій у медичній сфері є:

- автоматизація та оптимізація роботи лікаря;
- зменшення кількості діагностичних і організаційних помилок;
- оптимізація зберігання, обробки та передавання медичних даних;
- підвищення якості діагностики та моніторингу перебігу захворювань.

Під час завантаження лікарень хворими, наприклад у разі настання пандемії, якість лікування може знижатися. Широке застосування інформаційних технологій у процесі лікування допомагає вирішити вказану проблему, зокрема, їх застосування автоматизує процес на більшості етапів лікування. Програмне забезпечення з елементами штучного інтелекту у сфері медицини може обробляти дані як числового типу, так і у вигляді зображень. Варто зазначити, що застосування методів штучного інтелекту спрямоване на підвищення якості та швидкості обробки медичних даних [9].

Точність діагностики та визначення структури ураження при аналізі

медичних зображень людиною залежить від суб'єктивних факторів, зокрема кваліфікації лікаря (рентгенолога), завантаженості персоналу лікарні тощо. Автоматизація процесу аналізу медичних зображень допомогла б збільшити точність показників стану пацієнта та постановки діагнозу. Розширення використання штучного інтелекту в медицині не тільки зменшує витрати часу лікаря, але й може підвищити продуктивність, точність та ефективність [10]. Важливим фактором є визначення пріоритету в черзі обробки результатів проведених досліджень пацієнтів. Дослідження, яке було проведене в німецькому університетському госпіталі, змоделювало цю проблему на рентген-зображеннях грудної клітини. Виявлено, що час обробки критичних результатів досліджень скоротився з 80 хвилин до 35-50 хвилин [11]. Застосування методів штучного інтелекту у поєднанні з алгоритмами комп'ютерного зору може допомагати визначати ознаки хвороб на ранніх стадіях для оперативного запровадження лікування.

### **1.1. Методи класифікації рентген-зображень грудної клітини**

В існуючій літературі багато досліджень зорієнтовані на визначення COVID-19 за допомогою застосування нейронних мереж. Багато існуючих робіт ставлять за мету класифікувати наявність COVID-19 на основі КТ-зображень або рентген-зображень грудної клітини, маючи на виході лише дві ознаки: позитивний результат, або негативний. Важливою задачею в контексті класифікації знімків грудної клітини є класифікація різних захворювань.

Дослідники у роботі [12] порівняли три різні архітектури згорткових нейронних мереж у вирішенні задачі класифікації COVID-19 (позитивний чи негативний результат) за рентген-зображеннями грудної клітини. У якості даних автори використовували 50 зображень з датасету “COVID-19 Image Data Collection” [13], та 50 зображень з датасету “Chest x-ray images

(pneumonia)” [14]. Найкраща архітектура показала точність 98%.

Нейромережа CoroNet показала 95% точності при крос-валідації у задачі класифікації за ознаками: COVID-19, пневмонія, відсутність захворювання [15]. У дослідженні використовувалися датасети [13] та [14]. При тестуванні на іншому датасеті було досягнуто показник точності 89.6% для класифікації за трьома вищенаведеними ознаками.

Автори у роботі [16] застосовували згорткову нейронну мережу для обробки рентген-зображень для класифікації на шість різних типів, серед яких: COVID-19, пневмонія, відсутність захворювання, пневмоторакс, інфільтрація, випіт. Зрештою дослідникам вдалось підвищити точність класифікації з 72.13% до 81%.

У роботі [17] автори сформували об’єднаний датасет рентген-знімків з кількох публічних джерел, реалізували композицію моделей CNN та провели оцінку її якості класифікації у трикласовій задачі (COVID-19, пневмонія та відсутність захворювань). Запропонована модель досягла точності 92.74%. У дослідженні використовувалися датасети [13] та [18]. Варто уточнити, що набір Chest X-Ray Images (Pneumonia) [14], розміщений на платформі Kaggle, є публічною версією набору даних, описаного у роботі Kermany et al. [18]. Додатково авторами до робочої вибірки були включені зображення COVID-19 з датасету Figure-1 COVID-19 Chest X-ray Dataset Initiative [19], що містить 58 зображень.

Wang та Wong запропонували модель згорткової нейронної мережі COVID-Net для визначення COVID-19 [20]. У випадку класифікації рентген-знімків за ознаками COVID-19, бактеріальної пневмонії, вірусної пневмонії та відсутності захворювань модель досягала 83.5% точності. Частина робочого датасету містила зображення COVID-19 з датасету [13]

У роботі [21] запропоновано систему глибокого навчання для скринінгу пневмонії, спричиненої COVID-19, на основі КТ-зображень грудної клітини. Дана робота є прикладом застосування нейромережевих методів не

лише до рентген-зображень, але й до КТ-зображень у задачах автоматизованого аналізу патологічних змін у легенях.

У дослідженні [22] досліджено підхід до класифікації рентген-зображень грудної клітини за класами COVID-19, вірусної пневмонії та випадків без захворювань. Автори сформували комбінований відкритий набір даних, що містив 423 зображення COVID-19, 1485 зображень вірусної пневмонії та 1579 нормальних рентген-зображень грудної клітини. Зокрема, частина сформованого датасету містила дані з датасету [13]. Для класифікації було використано попередньо навчені згорткові нейронні мережі MobileNetV2, SqueezeNet, ResNet18, ResNet101, InceptionV3, VGG19, CheXNet і DenseNet201. Для двокласової схеми класифікації результати становили 99.7% за точністю (CheXNet). Для класифікації за трьома класами точність становила 97.9% (DenseNet201). Отримані результати вказують на перспективність застосування попередньо навчених згорткових нейронних мереж для автоматизованого скринінгу вірусної пневмонії та COVID-19 за рентген-зображеннями грудної клітини.

У роботі [23] застосовано трансферне навчання для класифікації рентгенівських зображень грудної клітини на класи COVID-19 та Non-COVID. Автори використали попередньо навчені згорткові нейронні мережі ResNet18, ResNet50, SqueezeNet та DenseNet-121 і адаптували їх до задачі виявлення COVID-19. Подібний напрям дослідження наведено в роботі [24], у якій для класифікації рентгенівських зображень на класи COVID-19, пневмонії та нормального стану використано трансферне навчання на основі згорткових нейронних мереж. У даній роботі експериментальна вибірка була сформована з відкритих джерел, зокрема з колекції COVID-19-зображень [13] та набору даних Kermany et al. [18]. Автори отримали точність класифікації 94.72% для трьох класів: COVID-19, пневмонія та нормальний стан.

У роботі [25] використано підхід для розрізнення COVID-19 та пневмонії на рентген-зображеннях грудної клітини, що ґрунтується на аналізі

кількісних характеристик зображення. Показано, що такі характеристики можуть бути використані для автоматизованого виявлення патологічних змін у легенях. Найкращі результати за значенням площі під ROC-кривою отримано для моделі Light Gradient Boosting Machine (LGBM), для якої цей показник становив 0.9, тоді як найвищу точність 0.808 продемонструвала модель Random Forest.

## **1.2. Попередня обробка як покращення якості даних у задачі класифікації**

У даному розділі увага приділяється порівняльному аналізу впливу різних методів попередньої обробки медичних зображень грудної клітини на результати класифікації. Незважаючи на відмінності між КТ-зображеннями та рентгенівськими зображеннями, для обох типів медичних зображень актуальними залишаються задачі підвищення якості зображення перед подальшим автоматизованим аналізом.

Для покращення якості рентген-зображень чи КТ-зображень грудної клітини перед аналізом застосовуються різні методи попередньої обробки, зокрема фільтр Гауса [26] та медіанна фільтрація (median filtering) для зменшення шуму [27], а також адаптивне вирівнювання гістограми з обмеженням контрасту (CLANE) для підсилення локального контрасту [28].

Дослідження [29] було присвячено задачі використання частотних ознак текстури сегментованих зображень, сформованих на основі матриць суміжності відтінків сірого GLCM. Джерела даних у дослідженні представлені у вигляді КТ-зображень легень. Побудована авторами згортова нейронна мережа з використанням частотних ознак текстури має загальну точність класифікації зображень за типами захворювань у 83%.

В роботі [30] було представлено методологію класифікації зображень за наявністю захворювання COVID-19. Дане дослідження представляє гі-

бридну модель для виявлення COVID-19 на КТ-зображеннях, що включає: згорткову нейронну мережу, графову нейронну мережу та зоровий трансформер (ViTGNN). Попередня обробка зображень включала фільтрацію шуму застосуванням фільтра Гауса та корегування контрасту зображень. Модель досягла точності 95.88%.

Наведені роботи показують, що для КТ-зображень грудної клітини також застосовуються етапи попередньої обробки, зокрема зменшення шуму, нормалізація інтенсивності, корегування контрасту та виділення інформативних ознак. Варто зазначити, що обробка КТ-зображень здебільшого дає якісніші результати, ніж обробка рентген-знімків. У роботі [31] було проведено детальний аналіз, що підтверджує ефективність КТ-діагностики в порівнянні з рентген-діагностикою. Проте, рентген-діагностика має свої переваги: швидша діагностика, менша шкідливість, доступність (особливо в країнах, що розвиваються).

Автори у роботі [32] запропонували модель попередньої обробки рентгенівських зображень під назвою GAN (Generative Adversarial Network) з глибоким трансферним навчанням. У якості даних було використано датасет COVID-19 Image Data Collection [13] та датасет [14]. Для навчання було використано моделі ResNet18, AlexNet, GoogleNet. Модель ResNet18 показала точність 80.6% (класифікація COVID-19, пневмонія, нормальні випадки, бактеріальна пневмонія), модель AlexNet показала точність 85.2% (класифікація COVID-19, нормальні випадки, бактеріальна пневмонія).

У роботі [33] досліджено бінарну класифікацію рентген-зображень грудної клітини на класи пневмонії та відсутності патологічних змін. Запропонований підхід ґрунтується на попередній обробці зображень, виділенні текстурних характеристик та подальшій класифікації за допомогою методів машинного навчання. Експерименти проведено на двох наборах даних. Перший набір даних відповідає датасету, описаному у роботі Kermany et al. [18]. Для даного експерименту найкраща точність становила 91.3%.

Другий набір Josep-NIH було сформовано з датасету COVID-19 collection Joseph Paul Cohen [13] та NIH Chest X-ray dataset. Для цього набору найкраща точність становила 99.0%. Попередня обробка включала вирівнювання гістограми, маскуванню неінформативних ділянок, підсилення контрасту та CLAHE. Для класифікації були використані методи KNN, SVM і Random Forest. Отримані результати підтверджують доцільність використання текстурних характеристик рентген-зображень для автоматизованого аналізу проявів пневмонії та інших патологічних змін у легенях.

Аналіз сучасних досліджень показує, що попередня обробка медичних зображень є важливим етапом при застосуванні методів штучного інтелекту для задач класифікації. Проте у багатьох роботах попередня обробка використовується лише як допоміжний етап підготовки даних. У даній роботі досліджується вплив різних методів попередньої обробки рентген-зображень грудної клітини на результати їх класифікації.

### **1.3. Сегментація області легень та зони ураження інфекцією на медичних зображеннях грудної клітини**

#### **1.3.1. Методи машинного та глибокого навчання.**

У сучасних наукових працях для вирішення задачі сегментації області легень на рентген-зображеннях грудної клітини переважно застосовуються методи глибокого навчання. Базовою архітектурою цього напрямку є U-Net [34] та її численні модифікації, які забезпечують високі показники точності за наявності достатнього обсягу розмічених даних. Ефективність таких підходів значною мірою залежить від складу навчальної вибірки, способу формування еталонних масок, якості вхідних зображень, а також від обчислювальних ресурсів, необхідних для навчання моделей.

Розвиток цього напрямку пов'язаний зі створенням удосконалених архітектур, орієнтованих на підвищення точності сегментації та покращення

узагальнювальної здатності моделей. Зокрема, у роботі [35] запропоновано модель CXR-Seg, у якій використано згорткову нейронну мережу з механізмами покращення представлення ознак, що відображають форму легень, їх межі та розташування в зображенні. Отримані результати характеризуються високими значеннями коефіцієнта Dice та точності: до 97.76% та 98.77% відповідно на наборі даних Montgomery, а також до 96.32% та 96.69% на наборі даних Shenzhen. Дані набори даних представлені у роботі [36], відповідні їм розмічені дані представлені у роботі [37]. Отримані результати підтверджують ефективність сучасних нейромережових підходів у задачі сегментації легень на рентген-зображеннях грудної клітини.

Для сегментації області легень у роботі [38] автори використали модифіковану U-Net з енкодером DenseNet201. Дослідження проводилось на наборі даних Montgomery та на наборі даних Shenzhen. На наборі Montgomery запропонована модель досягла значення IoU 97.77% та DSC 98.87%. На наборі Shenzhen — IoU 90.30% та DSC 94.84%.

У сучасних дослідженнях сегментація часто використовується як попередній етап подальшого аналізу медичних зображень. У роботі [39] сегментація легеневої області застосовується в двоетапній системі класифікації рентген-зображень грудної клітини для виявлення COVID-19 та інших типів пневмонії. На етапі сегментації автори порівнюють моделі UNet та UNet+, а на етапі класифікації — декілька нейромережових архітектур, виконуючи поділ на п'ять класів: COVID-19, вірусна пневмонія, бактеріальна пневмонія, туберкульоз та відсутність захворювання. Такий підхід дає змогу обмежити область аналізу легеневою зоною та зменшити вплив фонових структур на наступний етап класифікації. Найкращі результати сегментації отримано для моделі UNet, для якої досягнуто точність 96.35% та коефіцієнт Dice 94.88%. Найкращі результати класифікації отримано для комбінації UNet+Xception, для якої точність становила 97.45%. Дослідження виконано з використанням комбінованих публічних наборів рентген-

зображень грудної клітини, що містять зображення без наявності захворювань та різні типи пневмонії, зокрема COVID-19.

У роботі [40] для сегментації легеневої області на рентген-зображеннях грудної клітини використано генеративний підхід на основі Pix2Pix-GAN. Навчання моделі виконано на наборі даних Montgomery. Для перевірки узагальнювальної здатності застосовано незалежний датасет Shenzhen. Отримані результати на наборі Montgomery характеризуються високими значеннями точності та коефіцієнта Dice, що становили 98.25% та 98.05% відповідно. Під час перевірки на наборі Shenzhen точність сегментації становила 95.87%, що підтверджує можливість збереження високої якості сегментації при застосуванні моделі до іншого набору рентген-зображень.

У роботі [41] сегментація області легень також використовується як попередній етап подальшого аналізу рентген-зображень грудної клітини. Автори досліджують вплив попередньої обробки зображень та сегментації легень на подальше виявлення COVID-19, порівнюючи стандартну та модифіковану моделі U-Net. Для сегментації найкращі результати отримано для модифікованої U-Net, для якої досягнуто точність 98.63%, коефіцієнт IoU 94.3% та коефіцієнт Dice 96.94%. Подальшу класифікацію виконано на великому наборі рентген-зображень грудної клітини COVQU, що містив 8851 зображення без патологій, 6012 зображень легневих інфекцій без COVID-19 та 3616 зображень COVID-19. Показано, що використання сегментованої легеневої області та попередньої корекції зображення сприяє підвищенню ефективності автоматизованого виявлення патологічних змін у легенях.

Окрім сегментації області легень, подальші дослідження також спрямовані на аналіз патологічних змін на медичних зображеннях грудної клітини.

У роботі [42] запропоновано Anam-Net — полегшену згорткову нейронну мережу для сегментації аномальних областей на КТ-зображеннях паціє-

ентів із COVID-19. У даному підході перед сегментацією області з інфекцією використовується попереднє виділення легень, що дозволяє анатомічно обмежити область аналізу.

У дослідженні [43] для сегментації COVID-19-уражень на КТ-зображеннях запропоновано модель Inf-Net. Реалізований підхід поєднує попереднє виділення області ураження з подальшим уточненням її меж. Для зменшення потреби в ручній розмітці автори додатково використали нерозмічені КТ-зрізи, для яких модель автоматично формує маски сегментації у напівкерованому режимі.

У роботі [44] розглянуто задачу локалізації та сегментації області COVID-19-ураження на рентген-зображеннях грудної клітини. Автори використали набір COVID-QU-Ex, який містить рентген-зображення, маски легень та маски зон з інфекцією. Для сегментації області ураження застосовувалися нейромережеві архітектури з попередньо навченими енкодерами, зокрема варіанти U-Net, U-Net++ та FPN. Важливою особливістю даного підходу є використання маски легень на етапі постобробки: прогнозована маска інфекційної області додатково обмежується областю легень. Для локалізації ураження, що спричинене COVID-19, автори отримали значення  $IoU = 83.05\%$  та  $DSC = 88.21\%$ .

У дослідженні [45] запропоновано архітектуру Co-ERA-Net для сегментації області з інфекцією на рентген-зображеннях та КТ-зображеннях. Автори звертають увагу на те, що моделі, які аналізують усе зображення без урахування меж легеневої області, можуть помилково виділяти зони інфекції за межами легень. Для усунення цієї проблеми в Co-ERA-Net використовується інформація про область легень у вигляді співнавчання, а також механізм Enhanced Region Attention, що поєднує ознаки області легень та інфекційного ураження. Після проведення тестування на датасеті рентген-зображень COVID-QU-Ex автори отримали  $Dice = 0.771$ ,  $IoU = 0.674$ .

У роботі [46] представлено ERGPNet — нейромережеву архітектуру

для сегментації уражень COVID-19 на рентген-зображеннях. Даний підхід спрямований на покращення виділення інфекційних ділянок за рахунок удосконаленої обробки ознак зображення та механізмів уваги. Для набору COVID-QU-Ex автори навели значення  $Accuracy = 0.963$ ,  $Precision = 0.897$ ,  $Recall = 0.906$ ,  $F1-score = 0.893$  та  $MIoU = 0.817$ .

Аналіз наведених робіт показує, що інформація про область легень є важливою для задачі сегментації інфекційного ураження. У роботі [44] дана інформація використовується на етапі постобробки прогнозованої маски. В роботі [45] область легень використовується як додаткове джерело навчального сигналу та уваги в архітектурі нейронної мережі.

Окреме значення має питання узагальнювальної здатності моделей при переході між різними наборами зображень. У роботі [47] показано, що зсув домену, зумовлений відмінностями у параметрах візуалізації, джерелах даних, характеристиках пацієнтських вибірок та особливостях формування розмітки, може істотно знижувати точність сегментації. Високі результати, отримані в межах одного датасету, не гарантують аналогічної ефективності при застосуванні моделі до іншого набору рентген-зображень. У зв'язку з цим є актуальною перевірка моделей на незалежних наборах даних, які часто використовуються для оцінювання перенесення моделі між різними джерелами зображень.

Проблема узагальнювальної здатності моделей сегментації легень також розглядається в дослідженні [48], присвяченому перенесенню моделей, навчених на рентген-зображеннях грудної клітини дорослих пацієнтів, на педіатричний домен. Для цього використано дорослі набори Shenzhen, Montgomery та JSRT, а як цільовий домен — окремий педіатричний набір. Показано, що вікові відмінності форми легень можуть призводити до зниження якості сегментації при прямому перенесенні моделей. Для покращення результатів запропоновано підхід з декількох етапів, що включає вибір найкращої архітектури, навчання на різних комбінаціях дорослих наборів

і подальше об'єднання результатів кількох моделей. Для оцінювання використано коефіцієнт Dice, IoU та додаткові показники, що характеризують структурну подібність і точність відтворення контуру легеневої області. Отримані результати показують, що при перенесенні моделей сегментації на інші набори даних слід враховувати можливий вплив відмінностей у структурі та формі легеневої області.

Відповідно, наведені дослідження показують, що висока точність нейромережевої сегментації в межах одного набору даних не завжди гарантує стабільну роботу моделі на зображеннях з іншого джерела. Це зумовлює потребу в аналізі підходів, які є менш залежними від конкретної навчальної вибірки, не потребують тривалого навчання та забезпечують інтерпретованість отриманого результату.

### **1.3.2. Класичні та гібридні методи.**

Незважаючи на домінування методів глибокого навчання, класичні та гібридні підходи до сегментації не втратили актуальності. Їх використання зумовлене простотою реалізації, інтерпретованістю результатів, а також можливістю застосування без тривалого навчання моделі та без потреби у великому обсязі розмічених даних. Зокрема, у задачах аналізу медичних зображень, за відсутності еталонних масок (сегментованих зон легень), є актуальним застосування підходів, що не потребують попередньої підготовки даних та моделей. До таких підходів належать методи порогування, морфологічної обробки, аналізу контурів та комбіновані схеми, у яких послідовно поєднуються кілька етапів обробки зображення [49].

У роботі [50] запропоновано автоматичний підхід до сегментації легень на рентген-зображеннях грудної клітини, що поєднує підсилення зображення на основі дискретного вейвлет-перетворення, порогування методом Оцу, морфологічну обробку та уточнення меж за допомогою активних контурів. Така схема дає змогу послідовно виділити легеневі області, скоригувати

форму сегментованих об'єктів та підвищити точність визначення меж.

У роботі [51] для сегментації рентгенівських зображень грудної клітини застосовано багаторівневе порогоування з використанням критеріїв Оцу та Капура, а також оптимізації порогових значень. Такі підходи поступаються сучасним нейромережевим архітектурам за гнучкістю представлення ознак, проте залишаються корисними в задачах, де важливо зберегти прозорість процедури сегментації та можливість інтерпретації отриманого результату.

Іншим прикладом застосування порогових методів є виявлення анатомічних структур легень на КТ-зображеннях [52]. У роботі було застосовано метод збалансованого відсікання гістограми для виявлення артерій і бронхів. Після цього відбір об'єктів виконується за їх геометричними характеристиками. Це показує, що порогові методи можуть використовуватися також для виділення окремих анатомічних структур легень на томографічних зображеннях.

Класичні методи також можуть формувати основу для побудови гібридних схем, у яких результати порогоування поєднуються з морфологічною постобробкою, аналізом зв'язних компонент або додатковими критеріями відбору сегментаційної маски. Такий підхід є доцільним у задачах, де необхідно поєднати простоту реалізації з можливістю врахування структурних особливостей сегментованої області.

У ряді досліджень для сегментації рентгенівських знімків грудної клітини застосовуються класичні методи порогоування, зокрема метод Оцу [53] як один з етапів сегментації зображення [54]. Також у задачах сегментації рентгенівських зображень грудної клітини поширене використання ентропійних методів порогоування, зокрема методу Капура [55], у поєднанні з оптимізаційними алгоритмами [56].

У роботі [57] запропоновано підхід до сегментації області легень на КТ-зображеннях COVID-19 на основі імовірнісного моделювання розподі-

лу значень шкали Хаунсфілда. Для уточнення компонентів моделі автори використали модифікований метод  $k$ -середніх, фінальний результат додатково обмежувався морфологічними та анатомічними умовами.

Подальші дослідження показують, що класичні методи можуть бути застосованими й для аналізу патологічних змін на медичних зображеннях грудної клітини.

Автори у роботі [58] застосували кластеризацію  $k$ -середніх з кількістю кластерів  $k = 3$  для сегментації КТ-зображень легень. Один із кластерів використовувався як область інтересу, яка пов'язана з COVID-19-ураженням. Наступним етапом із сегментованих областей виділялися текстурні ознаки GLCM для проведення подальшої класифікації КТ-зображень. У роботі [59] для виділення області ураження COVID-19 на рентгенівських зображеннях використано поєднання  $k$ -середніх з оптимізаційним алгоритмом PSO.

Близький підхід для КТ-зображень реалізовано у рішенні CTLungSeg, призначеному для попереднього виділення області легень та ділянок ураження типу матового скла у пацієнтів з COVID-19 [60]. У даному підході для формування маски легень використовується попередньо навчена U-Net-модель з бібліотеки lungmask. Наступним етапом відбувається пошук уражених ділянок за допомогою кластеризації інтенсивностей методом  $k$ -середніх.

У роботі [61] запропоновано гібридний підхід до аналізу рентгенівських зображень грудної клітини, що включає попередню обробку, сегментацію та подальшу класифікацію. На етапі попередньої обробки автори поєднують denoising autoencoder та CLANET. Сегментація в роботі виконується ансамблевим способом на основі кількох класичних підходів, зокрема виявлення контурів методом Канні з подальшою морфологічною обробкою, пороговання за методом Оцу, автоматичного вибору порогу та сегментації на основі локальних структур зображення. Подальша класифікація здійснюється із

застосуванням моделей машинного навчання, серед яких найкращі результати отримано для методу опорних векторів. Дана робота є прикладом поєднання попередньої обробки, класичної сегментації та класифікації в межах єдиної системи аналізу рентгенівських зображень.

Окремий підхід до автоматичного ранжування методів порогової обробки зображень запропоновано у роботі [62]. Автори розглядають задачу вибору ефективного методу порогоування за відсутності еталонного зображення та формують консенсусне референтне зображення на основі результатів кількох методів порогоування. Обмеженням такого підходу є залежність консенсусного результату від набору використаних методів порогоування.

Використання анатомічно орієнтованих характеристик сегментованої області є перспективним напрямом у даній області робіт. У роботах [63] та [64] для підвищення точності сегментації застосовуються анатомічні орієнтири та моделі, що враховують структурні особливості грудної клітини. Це створює підґрунтя для формування анатомічно орієнтованих показників, які можуть використовуватися не лише у процедурах сегментації, але й під час оцінювання якості отриманих результатів, зокрема в умовах відсутності еталонних масок.

### **1.3.3. Підходи до оцінювання та валідації результатів сегментації.**

Додатковий аспект сучасних досліджень стосується зовнішньої валідації та оцінювання отриманих результатів. Оцінка якості сегментації є окремою складовою задачі аналізу медичних зображень і в більшості досліджень здійснюється шляхом порівняння отриманої сегментованої області з еталонними масками, сформованими на основі експертної розмітки. Для цього найчастіше використовуються метрики перекриття, зокрема Dice та IoU. Окремо застосовуються критерії, орієнтовані на точність відтворення меж сегмента. Зокрема, у роботі [50] для оцінювання результатів сегмента-

ції використовуються показник перекриття сегментованої області з еталонною маскою та середня відстань між їх контурами. Такий підхід дає змогу враховувати не лише ступінь збігу сегментованої області, але й точність відтворення її меж.

У роботі [65] для оцінювання якості сегментації легень застосовано коефіцієнт Dice та поверхнево-орієнтовані геометричні критерії. Додатково результати сегментації було проаналізовано за допомогою радіологічного аналізу клінічної значущості помилок. Даний підхід показує, що оцінювання якості сегментації доцільно здійснювати не лише на основі формальних метрик перекриття та точності межі, але й з урахуванням клінічної значущості виявлених відхилень.

У сучасних дослідженнях якість сегментації розглядається не лише через метрики перекриття, але й з точки зору анатомічної коректності отриманого результату. У роботі [66] це реалізовано шляхом інтеграції анатомічної інформації в архітектуру моделі для формування топологічно коректних сегментацій. Такий підхід підкреслює актуальність урахування анатомічної правдоподібності при оцінюванні результатів сегментації.

У реальних умовах застосування алгоритмів сегментації еталонні маски часто відсутні. У зв'язку з цим класичні метрики порівняння з еталонною розміткою не завжди можуть бути використані безпосередньо, що зумовлює потребу у непрямих підходах до оцінювання якості сегментації. У роботі [67] запропоновано підхід, у якому якість сегментації прогнозується без використання еталонної маски на основі ознак, що описують форму сегментованої області, розподіл інтенсивності всередині неї та характеристики локальних змін яскравості. На основі цих ознак навчається регресійна модель для прогнозування показників похибки сегментації, зокрема помилки перекриття та коефіцієнта Dice. Для випадку сегментації легень автори отримали кореляцію 0.85 між реальними та прогнозованими значеннями помилки перекриття та коефіцієнта Dice. Отримані результати

підтверджують перспективність непрямих підходів до оцінювання якості сегментації в умовах відсутності еталонної розмітки.

У дослідженні [68] запропоновано підхід на основі методу зворотної оцінки точності класифікації з метою оцінювання якості сегментації без еталонної розмітки. У даному підході результат автоматичної сегментації використовується як допоміжна розмітка. Після чого прогнозується якість цієї сегментації на основі її узгодженості з референтними прикладами. Проте обмеженням такого підходу є залежність оцінювання від наявності набору референтних прикладів з еталонною розміткою.

## **Висновки до розділу 1**

Аналіз розглянутих робіт показує, що для автоматизованого аналізу медичних зображень грудної клітини широко застосовуються методи класифікації та сегментації. У задачах класифікації рентген-зображень високі результати здебільшого отримують нейромережеві моделі, зокрема попередньо навчені згорткові мережі. Ефективність таких моделей залежить від якості вхідних зображень, тому важливим етапом є попередня обробка, що спрямована на зменшення шуму, нормалізацію інтенсивності та підсилення локального контрасту.

Розглянуті дослідження показують, що попередня обробка може бути корисною й для задач сегментації, зокрема для підсилення меж та локальних структур на зображенні. Для сегментації області легень та області ураження широко застосовуються як нейромережеві, так і класичні методи. Нейромережеві підходи забезпечують високу точність, проте потребують розмічених даних і навчання моделей. Класичні методи залишаються актуальними завдяки простоті реалізації та можливості застосування без навчальної вибірки.

У задачах сегментації області ураження важливим є попереднє виді-

лення області легень з метою зменшення впливу фонових структур. Розглянуті роботи також показують, що кластеризація за інтенсивністю може використовуватися для пошуку ділянок, що відповідають області інфекції, на рентгенівських зображеннях та на КТ-зображеннях грудної клітини.

Оцінювання якості сегментації переважно виконується на основі еталонної розмітки з використанням метрик Dice та IoU, проте у реальних умовах розмітка може бути відсутня. Відповідно, використання непрямих підходів до оцінювання результатів, зокрема анатомічно орієнтованих характеристик сегментованої області, є актуальним.

Аналіз розглянутих робіт показує, що подібні групи методів обробки медичних зображень застосовуються як для рентгенівських зображень, так і для КТ-зображень грудної клітини. Проте відмінності між цими типами зображень зумовлюють необхідність окремого налаштування методів.

Проведений аналіз літератури показує, що, крім використання нейромережних архітектур, актуальним є розроблення інтерпретованих підходів до сегментації області легень, оцінювання анатомічної правдоподібності результату сегментації і виділення патологічних областей. Застосування даних методів є доцільним для підвищення стійкості методів до відмінностей між наборами даних, умовами отримання зображень та особливостями розмітки. Окреме значення має можливість оцінювання результатів у випадках, коли еталонні сегментації недоступні.

Отже, розглянуті методи класифікації, попередньої обробки, сегментації та оцінювання якості результатів доцільно розглядати як взаємопов'язані складові процесу системного аналізу медичних зображень. Даний підхід створює основу для побудови інформаційної технології автоматизованого аналізу медичних зображень грудної клітини, у якій результати обробки зображень можуть використовуватися для подальшої підтримки прийняття рішень.

## РОЗДІЛ 2

### МОДЕЛІ, МЕТОДИ ТА ДАНІ ДОСЛІДЖЕННЯ

#### 2.1. Архітектура моделі класифікації рентген-зображень грудної клітини

Згорткова нейронна мережа (Convolutional Neural Network або CNN) є одним з важливих методів глибокого навчання в комп'ютерному зорі, що забезпечує автоматичне вилучення інформативних ознак із вхідних зображень та їх подальшу класифікацію. CNN широко застосовуються у задачах розпізнавання образів, зокрема і в аналізі медичних зображень для їх класифікації [16].

У даному дослідженні впроваджується глибока архітектура згорткової нейронної мережі для класифікації рентген-знімків за трьома класами: COVID-19, пневмонія та відсутність захворювання.

У якості оптимізатора для нейронної мережі застосовується алгоритм оптимізації Adam [69] зі швидкістю навчання  $5 \times 10^{-4}$ . Навчання моделі проводиться з розміром батчу (batch size) 32.

Для зменшення ефекту перенавчання застосовано метод ранньої зупинки (early stopping), який припиняє навчання моделі за відсутності покращення функції втрат валідаційної вибірки протягом визначеної кількості епох. Метод ранньої зупинки розглядається як форма регуляризації, оскільки дозволяє запобігти надмірному підлаштуванню параметрів нейронної мережі до тренувальних даних та сприяє покращенню узагальнювальної здатності моделі за рахунок зменшення впливу шуму та нерелевантних характеристик тренувальних даних [70].

Загальна кількість параметрів моделі, що тренуються, становить 905 987.

Архітектура згорткової нейронної мережі наведена у табл. 2.1.

Таблиця 2.1


**Архітектура згорткової нейронної мережі.**

| Шар (тип)                   | Розмір виходу              | Кількість параметрів |
|-----------------------------|----------------------------|----------------------|
| Conv2D (32, $5 \times 5$ )  | $176 \times 176 \times 32$ | 2 432                |
| MaxPooling2D                | $88 \times 88 \times 32$   | 0                    |
| Conv2D (64, $5 \times 5$ )  | $84 \times 84 \times 64$   | 51 264               |
| MaxPooling2D                | $42 \times 42 \times 64$   | 0                    |
| Conv2D (64, $5 \times 5$ )  | $38 \times 38 \times 64$   | 102 464              |
| MaxPooling2D                | $19 \times 19 \times 64$   | 0                    |
| Conv2D (128, $5 \times 5$ ) | $15 \times 15 \times 128$  | 204 928              |
| MaxPooling2D                | $7 \times 7 \times 128$    | 0                    |
| Conv2D (128, $5 \times 5$ ) | $3 \times 3 \times 128$    | 409 728              |
| MaxPooling2D                | $1 \times 1 \times 128$    | 0                    |
| Flatten                     | 128                        | 0                    |
| Dense (1024)                | 1024                       | 132 096              |
| Dropout                     | 1024                       | 0                    |
| Dense (3)                   | 3                          | 3 075                |

У дослідженні використовується рентген-зображення з декількох загальнодоступних датасетів. Датасет "COVID-19 Image Data Collection" [13], автором якого є Джозеф Пауль Коен (Joseph Paul Cohen) та ін., містить 577 зображень за класами: вірусна пневмонія, вірусна пневмонія, спричинена саме COVID-19, та бактеріальна пневмонія.

Зображення бактеріальної, вірусної пневмонії та рентгенографії без захворювань були отримані з репозиторію "Chest X-Ray Images (Pneumonia)" [14]. Набір даних містить 2794 зображень. Приклад зображень відповідних класів з робочого датасету наведено на рис. 2.1.

**Попередня обробка.** У багатьох роботах попередня обробка використовується як допоміжний етап підготовки даних перед навчанням нейронної мережі. У даному дослідженні основна увага приділяється порівняльно-



(а) COVID-19      (б) Без захворювань      (в) Пневмонія

Рис. 2.1: Приклад рентген-знімків.

му аналізу впливу різних методів попередньої обробки рентген-зображень на результати класифікації.

Фільтр Гауса застосовується для згладжування зображення та зменшення високочастотного шуму. Причому дрібні деталі на зображенні можуть частково розмиватися. Застосовано фільтр з ядром  $5 \times 5$  пікселів. Приклад застосування відображено на рис. 2.2.




Рис. 2.2: Фільтр Гауса.

Медіанний фільтр є методом обробки зображень, який замінює значення пікселя медіаною значень у його околі, що дозволяє зменшувати імпульсний шум із збереженням меж об'єктів. Застосовано фільтр з ядром  $5 \times 5$  пікселів. Приклад застосування відображено на рис. 2.3.

Метод адаптивного вирівнювання гістограми з обмеженням контрасту (CLAHE) збільшує локальний контраст, що дозволяє зробити структури (легені, ребра тощо) на зображенні більш виразними. До зображення за-




Рис. 2.3: Фільтр Медіанний.

стосовано сітку розміром  $8 \times 8$ . Приклад застосування відображено на рис. 2.4.




Рис. 2.4: Фільтр CLAHE.

## 2.2. Порогові методи сегментації області легень

**Алгоритм сегментації.** Процес сегментації полягає у розбитті вихідного зображення  $I(t \times n)$  на множину областей (сегментів)  $R_1, R_2, \dots, R_l$ . Кожний сегмент формується таким чином, щоб його елементи задовольняли певний критерій однорідності, який може базуватися на значеннях яскравості, кольору або інших характеристиках зображення.

Сегментація зображення передбачає виконання наступних основних умов [71], що наведені нижче.

**Умова відокремленості.** Жоден піксель не може належати двом сегментам одночасно:

$$R_i \cap R_j = \emptyset, \quad i, j = 1, \dots, l, \quad i \neq j. \quad (2.1)$$

**Умова повноти.** Об'єднання всіх сегментів повинно утворювати вихідне зображення:

$$R_1 \cup R_2 \cup \dots \cup R_l = I. \quad (2.2)$$

**Умова однорідності.** Для всіх пікселів, що належать одному сегменту, виконується певний критерій однорідності:

$$\forall p = (i, j) \in R_k, \quad i = 1, \dots, m, \quad j = 1, \dots, n. \quad (2.3)$$

Одним із найбільш поширених підходів до сегментації є метод пороговання. У загальному випадку порогове значення визначається як [72]

$$T(i, j) = M[i, j, f(i, j), p(i, j)], \quad i = 1, \dots, m, \quad j = 1, \dots, n, \quad (2.4)$$

де  $f(i, j)$  — значення інтенсивності пікселя  $(i, j)$  у відтінках сірого, а  $p(i, j)$  описує певну локальну характеристику, наприклад середнє значення інтенсивності сусідніх пікселів.

Якщо порогове значення  $T(i, j)$  не залежить від локальних характеристик  $p(i, j)$ , то такий метод пороговання називається *глобальним*.

Бінаризація зображення ґрунтується на застосуванні порогового значення, яке дозволяє розділити пікселі зображення на два класи — об'єкт та фон. Бінарне зображення визначається таким чином:

$$b(i, j) = \begin{cases} 0, & I(i, j) \leq T(i, j), \\ 1, & I(i, j) > T(i, j), \end{cases} \quad i = 1, \dots, m, \quad j = 1, \dots, n, \quad (2.5)$$

де  $b(i, j)$  — бінарне зображення, отримане в результаті порогової сегментації.

Важливим інструментом аналізу зображення при задачах порогової сегментації є гістограма інтенсивності. Гістограма зображення являє собою графік статистичного розподілу кількості пікселів за значеннями їх яскравості. Кожне значення гістограми відповідає кількості пікселів з певною інтенсивністю.

Чим більшою є різниця між яскравістю об'єкта та фону, тим більш вираженою є бімодальність гістограми. У такому випадку на гістограмі можна виділити два максимуми, які відповідають фону та об'єкту зображення (рис. 2.5).




Рис. 2.5: Приклад гістограми інтенсивності зображення

Визначення порогового значення за гістограмою є одним із найпростіших методів сегментації зображень. У цьому випадку гістограма поділяється на дві частини за допомогою глобального порогового значення  $T$ , що дозволяє розділити пікселі зображення на дві групи: фон та об'єкт.

**Метод порогової сегментації Оцу.** Метод Оцу є одним із найбільш поширених методів автоматичного визначення порогового значення при бі-

наризації зображень. Метод ґрунтується на аналізі гістограми інтенсивностей зображення та дозволяє визначити глобальний поріг, що забезпечує найкраще розділення пікселів на два класи: об'єкт та фон [53].

Нехай зображення має  $L$  можливих рівнів яскравості. Гістограма інтенсивностей нормалізується таким чином:

$$p_i = \frac{h_i}{H}, \quad i = 1, \dots, L \quad (2.6)$$

де  $h_i$  - кількість пікселів із яскравістю  $i$ ,  $H$  - загальна кількість пікселів зображення. При цьому виконується умова

$$\sum_{i=1}^L p_i = 1, \quad p_i \geq 0. \quad (2.7)$$

Пікселі зображення поділяються на два класи  $C_0$  та  $C_1$  за допомогою порогового значення  $t$ . Ймовірності належності пікселів до кожного з класів визначаються як

$$\omega_0(t) = \sum_{i=1}^t p_i \quad (2.8)$$

$$\omega_1(t) = \sum_{i=t+1}^L p_i = 1 - \omega_0(t). \quad (2.9)$$

Середні значення яскравості для кожного класу обчислюються за формулами

$$\mu_0(t) = \frac{1}{\omega_0(t)} \sum_{i=1}^t ip_i \quad (2.10)$$

$$\mu_1(t) = \frac{1}{\omega_1(t)} \sum_{i=t+1}^L ip_i. \quad (2.11)$$

Середня яскравість всього зображення визначається як

$$\mu_T = \sum_{i=1}^L i p_i. \quad (2.12)$$

Міжкласова дисперсія визначається виразом

$$\sigma_B^2(t) = \omega_0(t) \omega_1(t) (\mu_0(t) - \mu_1(t))^2. \quad (2.13)$$

Загальна дисперсія зображення дорівнює

$$\sigma_T^2 = \sum_{i=1}^L (i - \mu_T)^2 p_i. \quad (2.14)$$

Оптимальний поріг визначається як значення, що максимізує міжкласову дисперсію:

$$t^* = \arg \max_{1 \leq t \leq L} \sigma_B^2(t). \quad (2.15)$$

Таким чином, метод Оцу дозволяє автоматично визначити порогове значення, яке забезпечує найкраще розділення класів пікселів на основі їх статистичних характеристик.

**Метод ентропійного порогування Капура.** Метод Капура є ентропійним методом автоматичного визначення порогового значення, який базується на максимізації сумарної ентропії двох класів пікселів [55].

Нехай  $p_i$  - нормалізована гістограма інтенсивностей зображення:

$$p_i = \frac{h_i}{H}, \quad i = 0, \dots, L - 1. \quad (2.16)$$

Пікселі зображення поділяються на два класи  $C_0$  та  $C_1$  за порогом  $t$ .

Ймовірності класів визначаються як

$$\omega_0(t) = \sum_{i=0}^t p_i, \quad (2.17)$$

$$\omega_1(t) = \sum_{i=t+1}^{L-1} p_i. \quad (2.18)$$

Умовні ймовірності для кожного класу:

$$p_i^{(0)} = \frac{p_i}{\omega_0(t)}, \quad i = 0, \dots, t, \quad (2.19)$$

$$p_i^{(1)} = \frac{p_i}{\omega_1(t)}, \quad i = t+1, \dots, L-1. \quad (2.20)$$

Ентропія кожного класу визначається як

$$H_0(t) = - \sum_{i=0}^t p_i^{(0)} \ln p_i^{(0)}, \quad (2.21)$$

$$H_1(t) = - \sum_{i=t+1}^{L-1} p_i^{(1)} \ln p_i^{(1)}. \quad (2.22)$$

Сумарна ентропія системи:

$$H(t) = H_0(t) + H_1(t). \quad (2.23)$$

Оптимальне порогове значення визначається як

$$t^* = \arg \max_{0 \leq t \leq L-1} H(t). \quad (2.24)$$

Таким чином, метод Капура визначає поріг, що забезпечує максимальну інформаційну відокремленість класів пікселів.

**Модифікована реалізація методу збалансованого порогового відсікання гістограми.** Метод збалансованого порогового відсікання гістограми (Balanced Histogram Thresholding, ВНТ) належить до класу методів глобального порогоування, у яких використовується балансування мас гістограми інтенсивностей [73].

У класичному варіанті методу ВНТ порогове значення визначається як центральна точка гістограми, яка коригується у процесі ітераційного балансування мас відносно цієї точки.

У даній роботі використано модифіковану (спрощену) реалізацію методу ВНТ, яка не передбачає явного введення центральної точки та визначає порогове значення шляхом двостороннього накопичення мас гістограми від її країв до точки рівноваги.

Нехай  $h_i$  - гістограма інтенсивностей зображення, де  $i = 0, \dots, L - 1$ .

Спочатку визначаються крайні ненульові межі гістограми:

$$l = \min\{i \mid h_i > 0\}, \quad r = \max\{i \mid h_i > 0\}. \quad (2.25)$$

Початкові накопичені ваги задаються як

$$W_L = h_l, \quad W_R = h_r. \quad (2.26)$$

Далі виконується ітераційне зближення меж гістограми. Якщо ліва накопичена вага менша за праву, ліва межа зсувається праворуч:

$$l = l + 1, \quad W_L = W_L + h_l. \quad (2.27)$$

В іншому випадку права межа зсувається ліворуч:

$$r = r - 1, \quad W_R = W_R + h_r. \quad (2.28)$$

Ітераційний процес триває до виконання умови

$$l \geq r. \quad (2.29)$$

Отримане значення використовується як порогове:

$$t^* = l. \quad (2.30)$$

Таким чином, у запропонованій реалізації порогове значення визначається як точка гістограми, при якій досягається рівновага накопичених мас.

Для кожного з розглянутих методів визначене порогове значення використовується для бінаризації рентгенівського зображення. Наступним етапом до отриманого результату сегментації можуть застосовуватися морфологічні операції, що спрямовані на покращення геометричних характеристик сегментованої області.

## **2.3. Модель оцінювання та вибору результатів сегментації області легень**

### **2.3.1. Анатомічно орієнтовані показники оцінювання сегментації.**

Сучасні підходи до сегментації переважно спираються на методи глибокого навчання, які демонструють високі показники точності. Проте їх застосування часто потребує значних обчислювальних ресурсів та великих обсягів розмічених даних (експертно сформованих еталонних масок області легень). На практиці отримання таких даних є складним і ресурсомістким процесом. У зв'язку з цим є актуальним впровадження ефективних підходів до сегментації, які не потребують попереднього навчання моделей і можуть забезпечувати інтерпретованість отриманих результатів. Крім того, відсутність розмічених даних ускладнює не лише навчання моделей, але й об'єктивне оцінювання якості сегментації. Розрахунок традиційних метрик, таких як коефіцієнт Dice або індекс Жаккара (IoU), залежить від наявності розмічених даних з сегментованими областями легень. Це зумовлює необхідність пошуку альтернативних підходів до оцінки результатів сегментації, зокрема на основі анатомічних характеристик досліджуваних структур. Зокрема, показник відносної площі сегментованих областей та коефіцієнт вертикальної симетрії дозволяють оцінити, чи відповідає шука-

на площа легень очікуваним анатомічним пропорціям.

Для оцінки якості фільтрації шумів та збереження структурної інформації використовується індекс структурної подібності (SSIM — Structural Similarity Index Measure), що враховує локальні характеристики яскравості, контрасту та структури [74]. Значення SSIM змінюється в діапазоні від -1 до 1, де значення 1 відповідає повній структурній відповідності між зображенням, що було отримано після застосування фільтра Гауса, та оригінальним зображенням.

Оцінка якості відокремлення області легень проводиться за допомогою наступних геометричних показників: симетрія легень по вертикалі та відносна площа сегментованої області. Додатково виконується фотометрична оцінка якості відокремлення області легень за показниками контрасту між областю легень та фоном. Для оцінки внутрішньої текстурної неоднорідності використовується стандартне відхилення інтенсивності пікселів у межах сегментованої області [71].

Нехай  $I(x, y)$  - інтенсивність пікселя рентген-зображення,  $M(x, y) \in \{0, 1\}$  - бінарне зображення сегментованої області легень,  $H$  та  $W$  - висота та ширина рентген-зображення відповідно. Площа зображення визначається як

$$A_{\text{img}} = HW, \quad (2.31)$$

а площа сегментованої області легень:

$$A_{\text{lung}} = \sum_{x=1}^W \sum_{y=1}^H M(x, y). \quad (2.32)$$

**Коефіцієнт відносної площі сегментованої області.** Відносна площа сегментованої області легень визначається як

$$K_{\text{area}} = \frac{A_{\text{lung}}}{A_{\text{img}}}. \quad (2.33)$$

Показник характеризує частку області легень на зображенні та дозволяє оцінити повноту сегментації.

Площі лівої та правої частин сегментованої області визначаються як

$$A_L = \sum_{x < W/2} M(x, y), \quad A_R = \sum_{x \geq W/2} M(x, y). \quad (2.34)$$

**Коефіцієнт вертикальної симетрії.** Коефіцієнт вертикальної симетрії обчислюється за формулою

$$K_{\text{sym}} = \begin{cases} 1 - \frac{|A_L - A_R|}{A_L + A_R}, & A_L + A_R > 0, \\ 0, & A_L + A_R = 0. \end{cases} \quad (2.35)$$

Вищенаведений показник дозволяє оцінити анатомічну узгодженість сегментованої області відносно вертикальної осі зображення.

**Коефіцієнт контрасту області легень відносно фону.** Середня інтенсивність області легень визначається за формулою:

$$\mu_{\text{lung}} = \frac{1}{A_{\text{lung}}} \sum_{M(x,y)=1} I(x, y), \quad (2.36)$$

середня інтенсивність фону визначається як

$$\mu_{\text{bg}} = \frac{1}{A_{\text{img}} - A_{\text{lung}}} \sum_{M(x,y)=0} I(x, y). \quad (2.37)$$

Показник контрасту області легень відносно фону дозволяє оцінити різницю їх інтенсивностей та обчислюється за формулою:

$$K_{\text{contrast}} = |\mu_{\text{lung}} - \mu_{\text{bg}}|. \quad (2.38)$$

Показник характеризує ступінь відокремлення легеневої тканини від навколишніх анатомічних структур за інтенсивністю у відтінках сірого у шкалі  $[0; 255]$ . Високі значення показника свідчать про чітку сегментацію області легень від фону. Низькі значення вказують на часткове змішування областей або недостатню якість сегментації.

### Стандартне відхилення інтенсивності сегментованої області.

Стандартне відхилення (STD) інтенсивності пікселів у межах сегментованої області легень визначається як

$$\sigma_{\text{lung}} = \sqrt{\frac{1}{A_{\text{lung}}} \sum_{M(x,y)=1} (I(x,y) - \mu_{\text{lung}})^2}. \quad (2.39)$$

Показник характеризує неоднорідність розподілу інтенсивностей пікселів у відтінках сірого у шкалі  $[0; 255]$  та відображає збереження внутрішньої текстури легеневої області.

Малі значення стандартного відхилення можуть свідчити про зовелику однорідність сегментованої області, зокрема про можливе включення ділянок фону або втрату дрібних анатомічних елементів в області легень. У свою чергу, підвищені значення показника можуть бути пов'язані із захопленням висококонтрастних анатомічних структур фону: серце або кісткові елементи грудної клітини тощо.

У роботі реалізовано механізм сегментації області легень на рентгензнімках грудної клітини за допомогою методу Оцу з використанням фільтра Гауса. Запропоновано систему показників, що забезпечує комплексне оцінювання якості сегментації. Поєднання структурних, геометричних та фотометричних критеріїв дозволяє здійснювати перевірку правдоподібності результатів сегментації області легень за відсутності еталонної розмітки.

### 2.3.2. Постановка задачі багатокритеріального вибору результату сегментації.

У процесі сегментації рентгенівських зображень грудної клітини різні методи пороговання формують альтернативні результати, що можуть відрізнятися за площею, формою, симетрією та відповідністю анатомічній області легень. У рамках даного дослідження задача вибору результату сегментації розглядається як задача багатокритеріального прийняття рішень за сукупністю анатомічно орієнтованих показників.

Нехай  $X$  — вхідне рентген-зображення грудної клітини.

$A_{\text{seg}} = \{A_{\text{Otsu}}, A_{\text{Kapur}}, A_{\text{ВНТ}}\}$  — множина альтернативних методів сегментації. Кожен метод  $A_i \in A_{\text{seg}}$  формує відповідну бінарну маску сегментованої області:

$$M_i = A_i(X). \quad (2.40)$$

Для кожного вхідного зображення формується множина початкових масок:

$$M_{\text{seg}} = \{M_{\text{Otsu}}, M_{\text{Kapur}}, M_{\text{ВНТ}}\}. \quad (2.41)$$

До кожної початкової маски застосовується морфологічна постобробка, спрямована на уточнення форми сегментованої області, видалення малих артефактів, заповнення внутрішніх отворів та збереження найбільших зв'язних компонентів, що відповідають області легень.

Морфологічну постобробку подано у вигляді оператора  $P$ , який застосовується до кожної альтернативної маски:

$$M_i^p = P(M_i), \quad (2.42)$$

де  $M_i^p$  — маска, отримана після морфологічної постобробки результату методу  $A_i$ .

Процес та засоби морфологічної постобробки наведено у розділі експериментальних досліджень.

У загальному вигляді послідовність формування альтернативних результатів можна записати наступним чином:

$$X \rightarrow \{M_{\text{Otsu}}, M_{\text{Kapur}}, M_{\text{ВНТ}}\} \rightarrow \{M_{\text{Otsu}}^p, M_{\text{Kapur}}^p, M_{\text{ВНТ}}^p\}. \quad (2.43)$$

Таким чином, альтернативами для подальшого багатокритеріального оцінювання є сегментація з постобробкою  $M_i^p$ .

**2.3.3. Метод вибору результату сегментації на основі інтегральної оцінки.**

З метою вибору результату сегментації, що найбільшою мірою відповідає анатомічним характеристикам легеневої області, запропоновано комбінований підхід, який ґрунтується на інтегральній оцінці анатомічно орієнтованих показників.

У якості критеріїв оцінювання використано коефіцієнт відносної площі легеневої області, показник вертикальної симетрії та стандартне відхилення інтенсивності пікселів у межах сегментованої області. Для кожного з цих показників попередньо визначено референтні значення на основі розмічених даних.

Для кожної сегментації з постобробкою  $M_i^p$  формується вектор часткових оцінок:

$$\mathbf{S}(M_i^p) = [S_{\text{area}}(M_i^p), S_{\text{sym}}(M_i^p), S_{\text{std}}(M_i^p)], \quad (2.44)$$

де  $S_{\text{area}}(M_i^p)$  характеризує відповідність площі сегментованої області референтному значенню,  $S_{\text{sym}}(M_i^p)$  — відповідність вертикальної симетрії області легень, а  $S_{\text{std}}(M_i^p)$  — відповідність стандартного відхилення інтенсивності пікселів у межах маски.

Інтегральний показник якості для сегментації з постобробкою  $M_i^p$  визначається як зважена сума часткових оцінок:

$$Q(M_i^p) = w_1 \cdot S_{\text{area}}(M_i^p) + w_2 \cdot S_{\text{sym}}(M_i^p) + w_3 \cdot S_{\text{std}}(M_i^p), \quad (2.45)$$

де  $w_1, w_2, w_3$  — вагові коефіцієнти відповідних показників, для яких виконується умова:

$$w_1 + w_2 + w_3 = 1, \quad w_j \geq 0. \quad (2.46)$$

Часткові оцінки визначаються за формулами:

$$S_{\text{area}}(M_i^p) = \max \left( 0, 1 - \frac{|K_{\text{area}}(M_i^p) - K_{\text{area}}^{\text{ref}}|}{K_{\text{area}}^{\text{ref}}} \right), \quad (2.47)$$

$$S_{\text{sym}}(M_i^p) = \max \left( 0, 1 - \frac{|K_{\text{sym}}(M_i^p) - K_{\text{sym}}^{\text{ref}}|}{K_{\text{sym}}^{\text{ref}}} \right), \quad (2.48)$$

$$S_{\text{std}}(M_i^p) = \max \left( 0, 1 - \frac{|\sigma_{\text{lung}}(M_i^p) - \sigma_{\text{lung}}^{\text{ref}}|}{\sigma_{\text{lung}}^{\text{ref}}} \right), \quad (2.49)$$

де  $K_{\text{area}}(M_i^p)$ ,  $K_{\text{sym}}(M_i^p)$ ,  $\sigma_{\text{lung}}(M_i^p)$  — значення відповідних анатомічно орієнтованих показників для сегментації з постобробкою  $M_i^p$ , а  $K_{\text{area}}^{\text{ref}}$ ,  $K_{\text{sym}}^{\text{ref}}$ ,  $\sigma_{\text{lung}}^{\text{ref}}$  — їх референтні значення.

Референтні значення визначаються на основі попередньо розмічених даних та використовуються як узагальнені орієнтири для оцінювання анатомічної правдоподібності результату сегментації.

Кінцевий вибір результату сегментації здійснюється за правилом максимізації інтегрального показника:

$$i^* = \arg \max_i Q(M_i^p), \quad (2.50)$$

$$M^* = M_{i^*}^p. \quad (2.51)$$

Таким чином, результатом роботи комбінованого методу є бінарна маска  $M^*$ , що має найбільше значення інтегральної оцінки серед альтернативних результатів сегментації.

Загальну схему вибору результату сегментації можна подати у вигляді:

$$X \rightarrow M_{\text{seg}} \rightarrow \{M_{\text{Otsu}}^p, M_{\text{Kapur}}^p, M_{\text{BHT}}^p\} \rightarrow M^*. \quad (2.52)$$

У даній схемі на першому етапі формуються альтернативні результати сегментації. На другому етапі відбувається процедура морфологічної постобробки кожної альтернативної маски. На третьому етапі здійснюється їх багатокритеріальне оцінювання та вибір кінцевого результату.

Отже, процедура вибору маски області легень формалізується як задача багатокритеріального вибору. Альтернативами у цій задачі є результати порогових методів після морфологічної постобробки, критеріями — анатомічно орієнтовані показники сегментованої області.

## 2.4. Архітектура моделі сегментації області ураження на рентген-зображеннях

U-Net є однією з поширених архітектур глибокого навчання для задач сегментації медичних зображень [34]. Особливістю цієї архітектури є наявність енкодера, який виконує вилучення ознак із вхідного зображення, та декодера, який відновлює просторову роздільну здатність і формує піксельну маску. Використання пропускових з'єднань між відповідними рівнями енкодера та декодера дозволяє поєднати високорівневі семантичні ознаки з локальною просторовою інформацією.

Архітектура нейронної мережі, використаної для сегментації області ураження інфекцією, наведена у табл. 2.2. Модель побудована на основі архітектури U-Net з енкодером ResNet18 [75]. Подібна конфігурація розглядається у роботі [44] для сегментації області ураження інфекцією на рентген-зображеннях грудної клітини. Використання попередньо навченого енкодера дозволяє застосувати ознаки, отримані під час навчання на великому наборі зображень, та підвищити стабільність навчання на медичних даних.

Таблиця 2.2

### Архітектура нейронної мережі для сегментації області ураження

| Компонент                   | Параметр                  |
|-----------------------------|---------------------------|
| Вхідне зображення           | $256 \times 256 \times 3$ |
| Енкодер                     | ResNet18                  |
| Попереднє навчання енкодера | ImageNet                  |
| Декодер                     | U-Net                     |
| Вихідний шар                | 1 канал                   |
| Порогування                 | 0.5                       |

Енкодер ResNet18 виконує вилучення інформативних ознак із вхідного рентген-зображення, зокрема локальних контурів, текстурних характери-

стик та структурних особливостей області легень. Використання попередньо навчених ваг ImageNet [76] забезпечує ініціалізацію параметрів моделі на основі ознак, отриманих під час навчання на великому наборі зображень. Декодер U-Net послідовно відновлює просторову роздільну здатність карти ознак та формує карту ймовірностей належності пікселів до області ураження.

Пропускні з'єднання між енкодером і декодером забезпечують передачу локальної просторової інформації, що є важливим для точнішого відновлення меж області ураження. На виході модель формує одноканальну карту ймовірностей, яка після застосування порогу перетворюється у бінарну маску області ураження.

Для навчання моделі використано функцію втрат, що поєднує бінарну крос-ентропію та втрати показника Dice. Такий підхід дозволяє одночасно враховувати піксельну відповідність між прогнозом і еталонною маскою області ураження та ступінь просторового перекриття між ними.

У якості оптимізатора застосовано Adam зі швидкістю навчання  $10^{-4}$  та ваговою регуляризацією  $5 \times 10^{-4}$ . Розмір батчу становить 8. Для зменшення ефекту перенавчання застосовано метод ранньої зупинки, який припиняє навчання за відсутності покращення якості на валідаційній вибірці. Також використовується зменшення швидкості навчання при відсутності покращення функції втрат на валідаційній вибірці.

У дослідженні використано набір даних COVID-QU-Ex, що доступний у репозиторії Kaggle [77]. Датасет містить рентген-зображення грудної клітини за класами: COVID-19, інші захворювання та зображення випадків без захворювання. У даному наборі наявні бінарні маски області легень. Для класу COVID-19 також наявні маски інфекційних ділянок. Відповідно, структура набору дозволяє використовувати його для задач класифікації рентген-зображень, сегментації легень та сегментації області ураження інфекцією.

Формування та використання набору COVID-QU-Ex пов'язане з роботами [22, 41, 44, 78], у яких розглядалася задача класифікації COVID-19, проводилась підготовка і використання бінарних масок області легень та зони ураження інфекцією.

Приклад вхідних зображень та масок легень з датасету наведено на рис. 2.6.




Рис. 2.6: Приклади рентген-зображень та масок легень.

Приклад масок області ураження наведено на рис. 2.7.




Рис. 2.7: Приклади масок області ураження.

## Висновки до розділу 2

У даному розділі досліджено основні методи обробки та аналізу рентген-зображень грудної клітини:

- Наведено основні етапи обробки рентген-зображень, зокрема попередню обробку, сегментацію та класифікацію.
- Описано методи попередньої обробки зображень: фільтр Гауса, медіанна фільтрація та CLANE. Дані методи можуть використовуватися для зменшення шуму та підвищення контрастності зображень.
- Наведено класичні методи сегментації зображень, зокрема методи пороговання Оцу, Капура. Наведено алгоритм модифікованого методу збалансованого порогового відсікання гістограми.
- Запропоновано анатомічно орієнтовані показники для оцінювання результатів сегментації області легень, що включають коефіцієнт відносної площі сегментованої області, коефіцієнт вертикальної симетрії, коефіцієнт контрасту між областю легень і фоном та стандартне відхилення інтенсивності пікселів у межах сегментованої області.
- Сформульовано задачу вибору результату сегментації серед альтернативних порогових методів як задачу багатокритеріального вибору на основі інтегральної оцінки анатомічно орієнтованих показників.
- Описано метод вибору результату сегментації серед альтернативних порогових методів на основі інтегральної оцінки анатомічно орієнтованих показників.
- Наведено архітектуру нейронних мереж для класифікації та сегментації медичних зображень, зокрема згорткові нейронні мережі та архітектуру U-Net.

У розділі сформовано теоретичну основу для подальших експериментальних досліджень методів класифікації та сегментації рентген-зображень

грудної клітини. Розглянуті методи та моделі формують основу для системного аналізу процесу обробки медичних зображень з урахуванням невизначеності, шумів та варіативності медичних даних. На їх основі визначено складові інформаційної технології підтримки прийняття рішень для автоматизованого аналізу медичних зображень грудної клітини.

## РОЗДІЛ 3

### ЕКСПЕРИМЕНТАЛЬНА ПЕРЕВІРКА ЗАПРОПОНОВАНИХ МОДЕЛЕЙ І МЕТОДІВ

#### 3.1. Оцінювання якості класифікації

У цьому розділі наведено результати експериментальних досліджень згорткової нейронної мережі запропонованої архітектури для класифікації рентген-зображень грудної клітини з метою класифікації на класи: COVID-19, пневмонія, без захворювань. Для формування вибірки використано зображення COVID-19 з датасету "COVID-19 Image Data Collection" [13].

Рентген-зображення бактеріальної, вірусної пневмонії та рентгенографії без захворювань були отримані з репозиторію "Chest X-Ray Images (Pneumonia)" [14].

З метою вирішення проблеми незбалансованості даних для робочого датасету були обрані випадковим чином 391 зображень COVID-19, 391 зображень без захворювань та 371 зображень пневмонії (бактеріальної та вірусної без урахування COVID-19) методом зменшення кількості зображень у переважаючих класах. Розподіл робочого датасету наведений у табл. 3.1.

*Таблиця 3.1*

**Розподіл рентген-знімків за класами**

| Клас            | Всього | Тренувальна вибірка | Тестувальна вибірка |
|-----------------|--------|---------------------|---------------------|
| COVID-19        | 391    | 301                 | 91                  |
| Без захворювань | 391    | 301                 | 91                  |
| Пневмонія       | 371    | 301                 | 70                  |
| Всього          | 1154   | 903                 | 251                 |

В якості попередньої обробки до кожного рентген-знімку було застосо-

вано фільтр Гауса з ядром  $3 \times 3$  для зменшення рівня шуму на зображенні [71].

Для тренувальної вибірки використовувались стандартні методи аугментації зображень з метою підвищення узагальнювальної здатності моделі. До зображень застосовувалися випадкові повороти у межах  $5^\circ$ , незначні горизонтальні та вертикальні зсуви (до 2% від розміру зображення) та масштабування в межах 5% від початкового розміру зображення.

Оцінювання результатів проводилося за допомогою методу чотирикратної крос-валідації ( $k$ -fold). Для цього робочий датасет було розділено на чотири рівнозначних підвибірки, до яких послідовно застосовано процедуру крос-валідації. Для оцінки якості класифікації обчислювались такі показники: *Accuracy* (точність), *Precision* (прогностична цінність позитивного результату), *Recall* (чутливість), *Specificity* (специфічність) та  $F_1$ -score ( $F_1$ -міра). Наведемо визначення відповідних показників:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}, \quad (3.1)$$

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (3.2)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (3.3)$$

$$\text{Specificity} = \frac{TN}{TN + FP}, \quad (3.4)$$

$$F_1\text{-score} = \frac{2TP}{2TP + FP + FN}, \quad (3.5)$$

де  $TP$  — кількість істинно позитивних результатів,  $TN$  — кількість істинно негативних,  $FP$  — кількість хибно позитивних,  $FN$  — хибно негативних.

Для кожної ітерації процедури крос-валідації було сформовано оцінки якості класифікації, на основі яких обчислено середній результат. Отримані показники відображено у табл. 3.2.

Таблиця 3.2

### Результати чотирикратної крос-валідації CNN

| Підвибірка | Precision, % | Recall, % | Specificity, % | F-measure, % | Accuracy, % |
|------------|--------------|-----------|----------------|--------------|-------------|
| 1          | 96.10        | 96.07     | 97.99          | 96.08        | 96.02       |
| 2          | 97.59        | 97.59     | 98.59          | 97.59        | 97.35       |
| 3          | 95.72        | 96.04     | 98.04          | 95.87        | 96.02       |
| 4          | 92.00        | 91.75     | 96.00          | 91.83        | 92.00       |
| Середнє    | 95.35        | 95.36     | 97.66          | 95.34        | 95.35       |
| Ст. відх.  | 2.33         | 2.34      | 1.15           | 2.34         | 2.33        |

На рис. 3.1 наведено залежність значень функції втрат і точності класифікації від кількості епох навчання на тренувальній та валідаційній вибірках підвибірки №4.

Для моделі, яка була тренована на підвибірці №4, було проведено тестування. Отримано загальну точність класифікації 94%. Обчислено оцінки якості класифікації, які вказано в табл. 3.3.


Таблиця 3.3

### Показники якості класифікації на тестовій вибірці


| Клас            | Precision, % | Recall, % | $F_1$ -score, % | Кількість зразків |
|-----------------|--------------|-----------|-----------------|-------------------|
| COVID-19        | 97           | 96        | 96              | 92                |
| Без захворювань | 93           | 96        | 95              | 90                |
| Пневмонія       | 93           | 91        | 92              | 70                |

Матриця плутанини для проведеного тестування зображена на рис. 3.2.

З метою дослідження впливу попередньої обробки на результати класифікації було проведено серію експериментів із застосуванням вищевказаних



(а) Графік точності



(б) Графік функції втрат

Рис. 3.1: Динаміка тренування та валідації моделі для підвибірки №4.




Рис. 3.2: Матриця плутанини.

методів обробки зображень: фільтр Гауса, медіанний фільтр та метод адаптивного вирівнювання гістограми з обмеженням контрасту (CLAHE). При цьому архітектура нейронної мережі та склад робочого датасету залишалися незмінними.

Проведено класифікацію рентген-зображень за трьома класами (COVID-19, пневмонія, відсутність захворювання) окремо для кожного з методів попередньої обробки зображень та обчислено середній результат отриманих метрик точності.

Експеримент виконано для оригінального переліку зображень та окремо для переліку зображень, до яких була застосована процедура попередньої обробки. Результати обчислення метрик для вказаних експериментів наведено у табл. 3.4.

Для класифікації рентген-знімків грудної клітини за трьома класами: COVID-19, пневмонія та відсутність захворювання, було використано архітектуру згорткової нейронної мережі. Для оцінки ефективності моделі застосовано чотирикратну крос-валідацію, що дозволило отримати узго-

Таблиця 3.4

### Результати класифікації для різних методів попередньої обробки

| Метод                                | Accuracy, % | Precision, % | Recall, % | Specificity, % | F1, % |
|--------------------------------------|-------------|--------------|-----------|----------------|-------|
| Оригінальне зображення (без обробки) | 92.86       | 93.12        | 92.19     | 96.35          | 92.51 |
| Фільтр Гауса                         | 95.24       | 95.02        | 94.93     | 97.64          | 94.97 |
| Медіанна фільтрація                  | 93.25       | 93.07        | 92.88     | 96.63          | 92.97 |
| CLANE                                | 97.22       | 97.12        | 97.20     | 98.62          | 97.15 |

джені результати на різних підвбірках даних. Реалізована модель продемонструвала високі значення основних метрик якості класифікації, зокрема точності, чутливості та  $F_1$ -міри. Отримані результати характеризують ефективність застосованої архітектури в задачі розпізнавання рентгенологічних ознак відповідних класів знімків.

Окрім оцінювання за допомогою чотирикратної крос-валідації, було проведено додаткове тестування моделі на окремій тестовій вибірці, яка не використовувалася під час тренування нейронної мережі. Це дозволило перевірити здатність моделі до узагальнення.

За результатами тестування на незалежній вибірці модель досягла загальної точності 94 %. Значення прогностичної цінності позитивного результату (*Precision*), чутливості (*Recall*) та  $F_1$ -міри для окремих класів перебувають у межах 0.92–0.97, що свідчить про стабільну якість класифікації для всіх трьох класів.

Використання зображень без попередньої обробки забезпечило точність класифікації 92.86 %. Застосування фільтра Гауса підвищило точність до 95.24 %, що пов'язано зі зменшенням високочастотного шуму. Медіанна фільтрація забезпечила точність 93.25 %, що відповідає незначному при-

росту у порівнянні з оригінальними зображеннями. Метод адаптивного вирівнювання гістограми з обмеженням контрасту (CLAHSE) забезпечив найвище значення точності — 97.22 %. Підвищення ефективності класифікації при використанні CLAHSE можна пояснити збільшенням локального контрасту, що покращує виділення текстурних та анатомічних структур легень.

Отримані в даному дослідженні результати є порівнянними або перевищують показники, які наведені в інших розглянутих роботах, у яких розглядалася трьохкласова класифікація рентгенівських зображень грудної клітини на комбінації датасетів [13] та [14].

У роботі CoroNet [15] для класифікації COVID-19, пневмонії та нормального стану було отримано 95% точності. У роботі [17] для трьохкласової класифікації COVID-19, нормального стану та пневмонії отримано точність 92.74%. У роботі [24] для трьох класів COVID-19, пневмонії та нормального стану точність становила 94.72%.

У роботі [32] для трьохкласової класифікації COVID-19, нормального стану та бактеріальної пневмонії отримана точність становила 85.2%, що є нижчим за результати, отримані в даному дослідженні.

Окремо слід зазначити роботи [20] та [22], які мають більш розширений робочий датасет. У дослідженні [20] застосовано набір COVIDx, сформований із кількох відкритих джерел, зокрема COVID-19 Image Data Collection [13], Fig.1 COVID-19 Chest X-ray Dataset Initiative, ActualMed COVID-19 Chest X-ray Dataset Initiative, RSNA Pneumonia Detection Challenge та COVID-19 Radiography Database. Для класифікації за трьома класами модель, що була реалізована в розглянутій роботі, досягла точності 93.3%.

У роботі Chowdhury et al. [22] використано комбінований набір даних, до якого входили зображення з COVID-19 Image Data Collection [13] та дані з інших відкритих джерел, зокрема RSNA Pneumonia Detection Challenge та Chest X-Ray Images (Pneumonia) [14]. Для трьохкласової класифікації

COVID-19, вірусної пневмонії та нормального стану найкращий результат становив 97.9% при використанні DenseNet201.

Проте пряме зіставлення значень точності є обмеженим через відмінності у складі вибірок, кількості зображень COVID-19, способах розбиття даних тощо.

Отримані результати показали, що застосування попереднього оброблення дає змогу покращити показники класифікації в порівнянні з використанням оригінальних зображень без оброблення. Зокрема застосування фільтра Гауса забезпечило помітне підвищення точності класифікації. Найкращі результати серед досліджених методів продемонстрував метод адаптивного вирівнювання гістограми з обмеженням контрасту (CLANE), що забезпечив максимальні значення показників точності класифікації. Це вказує на доцільність використання методів вирівнювання контрасту для підвищення ефективності класифікації рентгенівських зображень. Отримані результати підтверджують важливість етапу попереднього оброблення в задачах аналізу медичних зображень та можуть бути використані для подальшого вдосконалення систем автоматичної діагностики.

### **3.2. Оцінювання порогових методів сегментації області легень**

В даному розділі проводиться дослідження застосування модифікованого методу збалансованого порогового відсікання гістограми (ВНТ) для сегментації легень на рентгенівських зображеннях грудної клітини та оцінювання його ефективності у порівнянні з методами Оцу і Капура.

У рамках обчислювального експерименту виконано порівняльний аналіз модифікованого методу збалансованого порогового відсікання гістограми (Balanced Histogram Thresholding, ВНТ) та класичних методів глобального порогування, зокрема методів Оцу (Otsu) та Капура (Kapur).

У дослідженні використано рентген-зображення грудної клітини з датасету Shenzhen Chest X-ray dataset, описаного у роботі [36]. Еталонні маски легеневої області отримано з відкритого датасету Lung Masks for Shenzhen Hospital Chest X-ray Set [37]. Даний датасет містить 566 зображень, для яких наявні еталонні бінарні маски легень (ground truth masks). Приклад зображень грудної клітини з датасету наведено на рис. 3.3.





Рис. 3.3: Приклад рентген-зображень та відповідних їм еталонних масок.

Проведено два експерименти, що відрізняються наявністю попередньої обробки зображень. У першому випадку сегментація здійснюється без змін вихідних даних. У другому випадку застосовується метод адаптивного вирівнювання гістограми з обмеженням контрасту (Contrast Limited Adaptive Histogram Equalization, CLAHE) [79], що дозволяє оцінити вплив попередньої обробки на результати сегментації. Використання CLAHE підвищує локальний контраст зображення та покращує відділення легеневої області від фону. У якості параметра методу CLAHE використано розбиття зображення на сітку розміром 8x8.

На рис. 3.4 наведено гістограми рентген-зображення до та після засто-

сування фільтра CLANE зі знайденими порогами відповідних методів, що розглядаються у розділі.



(а) Гістограма зображення №2

(б) Гістограма зображення №2 (CLANE)

Рис. 3.4: Гістограма зображення №2 та пороги.

Для усунення фонових артефактів у результатах сегментації як етап постобробки здійснюється видалення малих зв'язаних компонент, площа яких становить менше 20% площі зображення та які дотичні до його меж або розташовані на відстані до 10 px від них.

Оцінювання ефективності підходів здійснюється на основі кількісних метрик якості сегментації, зокрема коефіцієнта Dice, повноти (Recall), показника надлишкової сегментації (OSI) та показника відносної площі сегментованої області (Area Ratio).

$$Dice = \frac{2|M \cap G|}{|M| + |G|} \quad (3.6)$$

$$Recall = \frac{|M \cap G|}{|G|} \quad (3.7)$$

$$OSI = \frac{|M \setminus G|}{|G|} \quad (3.8)$$

де  $I(x)$  — інтенсивність яскравості пікселя  $x \in I$ ,  $I$  — множина пікселів вхідного зображення,  $M$  — бінарна маска області інтересу, отримана в

результаті сегментації,  $G$  — еталонна маска легеневої області,  $M \setminus G$  — множина пікселів, що належать побудованій масці, але не входять до еталонної області,  $|\cdot|$  — кількість пікселів у відповідній множині.

Коефіцієнт Dice характеризує ступінь перекриття між побудованою бінарною маскою та еталонною областю легень і відображає узгодженість результату сегментації з еталонною розміткою. Повнота (Recall) характеризує ступінь покриття легеневої області побудованою бінарною маскою та визначає частку еталонної області, що була коректно включена до області інтересу. Показник надлишкової сегментації (Over-segmentation Index, OSI) характеризує рівень включення фонових структур та артефактів до області інтересу.

На рис. 3.5 наведено приклад застосування методів глобального пороговування Оцу, Капура та методу ВНТ без застосування методу попередньої обробки CLANE.





Рис. 3.5: Приклад застосування порогових методів до зображення №2.

На рис. 3.6 наведено приклад застосування методів глобального пороговування Оцу, Капура та модифікованого методу ВНТ з застосуванням методу попередньої обробки CLANE.

Для кожного зображення з датасету обчислено показники якості сегментації відносно еталонної розмітки, на основі яких визначено середні значення. Всього зображень — 566. Отримані результати наведено в табл. 3.5.



(а) Метод Оцу (б) Метод Капура (в) Модифікований метод ВНТ

Рис. 3.6: Приклад застосування порогових методів до зображення №2 (CLANE).

Модифікований метод збалансованого порогового відсікання гістограми підписано як ВНТ-м.

Таблиця 3.5

### Результати сегментації

| Метод | Фільтр | Dice              | Recall            | OSI               |
|-------|--------|-------------------|-------------------|-------------------|
| Otsu  | -      | $0.457 \pm 0.330$ | $0.386 \pm 0.297$ | $0.128 \pm 0.369$ |
| Kapur | -      | $0.480 \pm 0.281$ | $0.417 \pm 0.280$ | $0.200 \pm 0.471$ |
| ВНТ-м | -      | $0.654 \pm 0.206$ | $0.790 \pm 0.181$ | $0.740 \pm 0.674$ |
| Otsu  | CLANE  | $0.731 \pm 0.123$ | $0.675 \pm 0.071$ | $0.231 \pm 0.436$ |
| Kapur | CLANE  | $0.704 \pm 0.115$ | $0.636 \pm 0.087$ | $0.229 \pm 0.466$ |
| ВНТ-м | CLANE  | $0.704 \pm 0.160$ | $0.802 \pm 0.102$ | $0.600 \pm 0.656$ |

Отримані результати демонструють різну ефективність досліджуваних методів у задачі сегментації області легень. Без застосування попередньої обробки (фільтра CLANE) методи Оцу та Капура характеризуються низькими значеннями коефіцієнта Dice ( $0.457$  та  $0.48$  відповідно), що вказує на недостатню точність виділення області легень. Застосування модифікованого методу ВНТ забезпечує вище значення коефіцієнта Dice ( $0.654$ ) та підвищення значення повноти сегментації (Recall), яке становить  $0.79$ . Проте даний підхід характеризується високим рівнем надлишкової сегментації (OSI), який становить  $0.74$ , що вказує на включення фонових структур до

області інтересу.

Застосування методу адаптивного вирівнювання гістограми з обмеженням контрасту (CLANE) для методів Оцу та Капура призводить до суттєвого зростання коефіцієнта Dice (до 0.731 і 0.704 відповідно) та підвищення значення Recall (до 0.675 і 0.636 відповідно), тоді як показник OSI змінюється незначно. Для модифікованого методу ВНТ також відмічається підвищення значень Dice (до 0.704) та Recall (до 0.802), при цьому спостерігається зменшення рівня надлишкової сегментації (OSI до 0.6), що свідчить про зниження кількості помилково включених пікселів.

Модифікований метод ВНТ демонструє найвище значення повноти сегментації (Recall) серед розглянутих підходів, що визначає здатність методу виділяти область легень якомога повніше.

Варто зазначити, що використані еталонні маски з датасету [37] відрізняються за принципами розмітки, зокрема включенням або виключенням серцевої області та інших структур, що відображено на рис. 2.1. Вказана неоднорідність розмітки може впливати на значення метрик якості сегментації.

### **3.3. Застосування анатомічно орієнтованих показників для сегментації області легень**

#### **3.3.1. Дослідження анатомічно орієнтованого оцінювання сегментації.**

Для оцінки застосування анатомічно орієнтованих показників сегментації у цьому розділі проводиться дослідження на датасеті Shenzhen [36], що містить рентген-зображення грудної клітини та відповідні еталонні маски легеневої області з датасету [37]. Для кожного зображення виконується процес сегментації області легень з обчисленням коефіцієнта відносної площі, коефіцієнта вертикальної симетрії, стандартного відхилення інтенсив-

ності сегментованої області та коефіцієнта контрасту області легень відносно фону. Якість сегментації оцінювалася за коефіцієнтом Dice відносно еталонної маски області легень.

Для аналізу результатів маски було поділено на три групи: маски з високою якістю сегментації ( $Dice > 0.8$ ), маски із середньою якістю ( $0.6 < Dice \leq 0.8$ ) та маски з низькою якістю ( $Dice \leq 0.6$ ). Узагальнені значення показників для цих груп наведено в табл. 3.6.

Окремо було обчислено індекс структурної подібності SSIM між початковим зображенням та зображенням після застосування попередньої обробки. Цей показник використовується не для прямого оцінювання якості сегментованої області, а для контролю збереження структурної інформації на етапі фільтрації та контрастного підсилення. У розділі 3.2 було показано, що застосування попередньої обробки, зокрема CLANE, сприяє покращенню результатів порогової сегментації. Тому додаткове обчислення SSIM дозволяє оцінити, чи не супроводжується дане покращення суттєвим спотворенням структури вхідного рентген-зображення.

Таблиця 3.6

### Значення показників сегментації для груп з різним рівнем Dice

| Група                 | SSIM              | $K_{\text{area}}$ | $K_{\text{sym}}$  | $\sigma_{\text{lung}}$ | $K_{\text{contrast}}$ | К-сть |
|-----------------------|-------------------|-------------------|-------------------|------------------------|-----------------------|-------|
| $Dice > 0.8$          | $0.942 \pm 0.027$ | $0.261 \pm 0.044$ | $0.952 \pm 0.035$ | $26.191 \pm 5.815$     | $27.661 \pm 15.206$   | 278   |
| $0.6 < Dice \leq 0.8$ | $0.942 \pm 0.025$ | $0.345 \pm 0.120$ | $0.936 \pm 0.061$ | $37.693 \pm 12.483$    | $49.683 \pm 30.069$   | 96    |
| $Dice \leq 0.6$       | $0.945 \pm 0.022$ | $0.432 \pm 0.098$ | $0.841 \pm 0.210$ | $53.328 \pm 9.454$     | $86.233 \pm 25.008$   | 192   |
| Еталон                | $0.943 \pm 0.025$ | $0.253 \pm 0.058$ | $0.905 \pm 0.074$ | $28.992 \pm 5.874$     | $23.226 \pm 14.769$   | 566   |

Результати, наведені у табл. 3.6, показують, що застосована попередня обробка не призводить до суттєвого порушення структурних характеристик рентген-зображень. Значення SSIM у всіх групах залишаються високими та близькими між собою: 0.943 для еталонних зображень, 0.942 для групи  $Dice > 0.8$ , 0.942 для групи  $0.6 < Dice \leq 0.8$  та 0.945 для групи  $Dice \leq 0.6$ .

Група “Еталон” відповідає значенням показників, обчисленим для еталонних масок області легень. Дані значення використовуються як орієнтир для порівняння з результатами порогової сегментації.


З табл. 3.6 видно, що для групи  $Dice > 0.8$  значення коефіцієнта відносної площі є найближчим до еталонного. Для еталонних масок середнє значення цього показника становить 0.253, а для групи  $Dice > 0.8$  — 0.261. Для груп із нижчим  $Dice$  спостерігається збільшення відносної площі сегментованої області: 0.345 для групи  $0.6 < Dice \leq 0.8$  та 0.432 для групи  $Dice \leq 0.6$ . Це вказує на те, що для невдалих результатів сегментації характерним є надмірне збільшення площі маски.

Для коефіцієнта вертикальної симетрії найвище середнє значення спостерігається у групі  $Dice > 0.8$  і становить 0.952. У групі  $Dice \leq 0.6$  середнє значення симетрії зменшується до 0.841, а стандартне відхилення зростає до 0.210. Це означає, що зі зниженням коефіцієнта вертикальної симетрії значення  $Dice$  має тенденцію до зменшення.

Фотометричні показники також змінюються між групами. Для групи  $Dice > 0.8$  середнє значення стандартного відхилення інтенсивності сегментованої області становить 26.191, а коефіцієнта контрасту області легень відносно фону — 27.661. Ці значення є близькими до відповідних еталонних значень: 28.992 та 23.226. Для груп із нижчим  $Dice$  значення фотометричних показників зростають. Зокрема, у групі  $Dice \leq 0.6$  середнє значення стандартного відхилення інтенсивності сегментованої області становить 53.328, а коефіцієнта контрасту області легень відносно фону — 86.233.

Для візуального аналізу зв'язку між окремими показниками та коефіцієнтом  $Dice$  було побудовано діаграми розсіювання. На рис. 3.7 наведено графіки для геометричних показників.

На рис. 3.7а показано, що більшість масок із високими значеннями  $Dice$  се зосереджена поблизу області еталонних значень площі. Зі збільшенням



(а) Коефіцієнт відносної площі

(б) Коефіцієнт вертикальної симетрії

Рис. 3.7: Зв'язок геометричних показників із коефіцієнтом Dice.


площі сегментованої області кількість точок із низькими значеннями Dice зростає. Це відповідає характерній для порогової сегментації проблемі надмірного захоплення фонових ділянок або структур поза легеневою областю.

На рис. 3.7б показано, що високі значення Dice здебільшого відповідають високим значенням вертикальної симетрії. Проте наявні також точки з високою симетрією та нижчим Dice. Це означає, що коефіцієнт вертикальної симетрії не є достатнім окремим показником якості, але може доповнювати оцінювання геометричної правдоподібності маски.

На рис. 3.8 наведено графіки для фотометричних показників. Стандартне відхилення інтенсивності сегментованої області позначено як STD.

На рис. 3.8а показано, що максимальні значення коефіцієнта контрасту частіше відповідають нижчим значенням Dice. Сегментації з високими значеннями Dice зосереджені переважно в області помірних значень контрасту. Це означає, що збільшення контрасту між сегментованою областю та фоном саме по собі не є ознакою кращої відповідності еталонній масці. Високий контраст може виникати також у випадках надмірного захоплення фонових або реберних структур, що знижує точність сегментації.

На рис. 3.8б показано, що найбільші значення стандартного відхилення



(а) Коефіцієнт контрасту області легень відносно фону та Dice

(б) Стандартне відхилення інтенсивності сегментованої області та Dice

Рис. 3.8: Зв'язок фотометричних показників із коефіцієнтом Dice.

інтенсивності сегментованої області переважно відповідають нижчим значенням Dice. Зростання стандартного відхилення може бути пов'язане з внутрішньою неоднорідністю виділеної області, а також із включенням до маски сторонніх структур або ділянок за межами легень.

Коефіцієнт контрасту та стандартне відхилення інтенсивності сегментованої області можуть використовуватися як допоміжні фотометричні характеристики результату сегментації, проте дані показники окремо не є достатніми для оцінювання якості отриманої маски.

Додатково було побудовано графік зв'язку між стандартним відхиленням інтенсивності сегментованої області та коефіцієнтом контрасту області легень відносно фону, наведений на рис. 3.9.

На рис. 3.9 показано, що між стандартним відхиленням інтенсивності сегментованої області та коефіцієнтом контрасту області легень відносно фону наявний виражений прямий зв'язок. Відповідно, обидва фотометричні показники частково описують близькі властивості отриманої маски.

Для кількісного уточнення зв'язку між фотометричними показниками було обчислено коефіцієнт кореляції Пірсона та отримано значення  $r = 0.917$  при  $p < 0.001$ , що характеризує сильну додатню лінійну кореля-




Рис. 3.9: Зв'язок стандартного відхилення інтенсивності сегментованої області з коефіцієнтом контрасту області легень відносно фону.

цію. Обидва показники обчислюються на основі характеристик інтенсивності зображення, проте описують різні властивості: стандартне відхилення характеризує внутрішню неоднорідність сегментованої області, а коефіцієнт контрасту — різницю між середньою інтенсивністю сегмента та фону.

Для подальшого формування часткового фотометричного критерію використано стандартне відхилення інтенсивності сегментованої області. Даний показник враховує відхилення кожного пікселя сегментованої області від середнього значення інтенсивності всередині цієї області і характеризує внутрішню неоднорідність виділеної маски. Коефіцієнт контрасту сегментованої області характеризує загальну відмінність між двома областями і не враховує розкид інтенсивностей усередині сегментованої маски. Крім того, значення контрасту залежить від складу фонові області, що може змінюватися при помилках сегментації.

Отримані результати показують, що значення коефіцієнта відносної площі, коефіцієнта вертикальної симетрії, стандартного відхилення інтенсивності сегментованої області та коефіцієнта контрасту області легень від-

носно фону змінюються залежно від рівня Dice. Найбільш помітна відмінність між групами спостерігається для коефіцієнта відносної площі та стандартного відхилення інтенсивності сегментованої області. Коефіцієнт контрасту також змінюється між групами, однак через виражений зв'язок зі стандартним відхиленням інтенсивності його подальше використання як окремого часткового критерію може призводити до дублювання близької фотометричної інформації. Тому в подальшому аналізі як фотометричний компонент використовується стандартне відхилення інтенсивності сегментованої області. Геометричний частковий критерій формується на основі коефіцієнтів відносної площі та вертикальної симетрії.

### 3.3.2. Аналіз критеріїв оцінювання результатів сегментації.

Анатомічно орієнтовані показники мають різні діапазони значень, тому для подальшого аналізу використовувалися часткові критерії оцінювання, що відображають близькість відповідного показника до еталонного значення. Визначення часткових критеріїв  $S_{area}$ ,  $S_{sym}$  та  $S_{std}$  наведено в розділі 2.3.3.

Для детальнішого аналізу геометричної складової було побудовано діаграми розсіювання для часткових оцінок  $S_{area}$  та  $S_{sym}$  відносно коефіцієнта Dice. Відповідні графіки наведено на рис. 3.10.

На рис. 3.10а відображено зв'язок часткової оцінки відносної площі з коефіцієнтом Dice. Точки з високими значеннями Dice переважно зосереджені в області високих значень  $S_{area}$ , що відповідає близькості площі отриманої маски до еталонного рівня. За нижчих значень  $S_{area}$  частіше спостерігаються результати із середніми або нижчими значеннями Dice.

На рис. 3.10б відображено зв'язок часткової оцінки вертикальної симетрії з коефіцієнтом Dice. Високі значення  $S_{sym}$  спостерігаються як для якісних, так і для менш якісних результатів сегментації. Це показує, що вертикальна симетрія у загальному випадку не є достатнім критерієм для




Рис. 3.10: Зв'язок часткових геометричних оцінок із коефіцієнтом Dice.

оцінювання якості сегментації.

Оскільки часткова оцінка відносної площі має більш виражений зв'язок із Dice, а часткова оцінка вертикальної симетрії виконує допоміжну роль, для подальшого аналізу розглядається інтегральна геометрична оцінка, яка поєднує обидва геометричні показники. У цьому розділі інтегральна геометрична оцінка визначається як:

$$S_{geom} = 0.5S_{area} + 0.5S_{sym} \quad (3.9)$$

Для аналізу зв'язку часткових критеріїв із якістю сегментації було побудовано діаграми розсіювання для  $S_{geom}$  та  $S_{std}$  відносно коефіцієнта Dice. Відповідні графіки наведено на рис. 3.11.

На рис. 3.11а відображено зв'язок інтегральної геометричної оцінки з коефіцієнтом Dice. Точки з високими значеннями Dice переважно зосереджені в області високих значень інтегральної геометричної оцінки. Найщільніше скупчення якісних результатів спостерігається при  $S_{geom}$  приблизно від 0.75 до 1, де значення Dice здебільшого перевищують 0.8.

На рис. 3.11б відображено зв'язок оцінки стандартного відхилення інтенсивності сегментованої області з коефіцієнтом Dice. Значна частина результатів із високим Dice відповідає високим значенням  $S_{std}$ , тобто близь-




Рис. 3.11: Зв'язок часткових критеріїв оцінювання з коефіцієнтом Dice.

кості стандартного відхилення до еталонного рівня. Проте цей зв'язок є менш однозначним, ніж для інтегральної геометричної оцінки.

Для уточнення ролі стандартного відхилення інтенсивності сегментованої області було додатково розділено результати за належністю цього показника до інтервалу  $20 \leq \sigma_{\text{lung}} \leq 40$ . Відповідні діаграми наведено на рис. 3.12.

Даний інтервал було обрано на основі аналізу діаграми розсіювання стандартного відхилення інтенсивності сегментованої області та Dice (рис. 3.11б), на якій основна частина точок із вищими значеннями Dice зосереджена саме в цьому діапазоні. Межі 20 та 40 використовуються як емпіричний робочий діапазон для додаткового аналізу, а не як жорсткий критерій якості сегментації.

На рис. 3.12а відображено зв'язок інтегральної геометричної оцінки з Dice для випадків, у яких стандартне відхилення інтенсивності сегментованої області знаходиться в межах  $20 \leq \sigma_{\text{lung}} \leq 40$ . Більшість точок зосереджена в області високих значень  $S_{\text{geom}}$  та Dice. Основне скупчення результатів розташоване приблизно при  $S_{\text{geom}} > 0.7$  та  $Dice > 0.75$ . Проте на графіку присутні окремі точки з нижчими значеннями Dice. Для таких ви-




Рис. 3.12: Зв'язок  $S_{\text{geom}}$  із Dice для різних діапазонів стандартного відхилення інтенсивності сегментованої області.

падків значення  $S_{\text{geom}}$  також є нижчим, що показує здатність геометричної оцінки додатково виявляти невдалі сегментації, які не можна однозначно визначити за фотометричним показником.

На рис. 3.12б відображено зв'язок інтегральної геометричної оцінки з Dice для випадків, у яких стандартне відхилення інтенсивності сегментованої області виходить за межі інтервалу  $20 \leq \sigma_{\text{lung}} \leq 40$ . На графіку наявна значна кількість точок із високими значеннями Dice. Це означає, що вихід стандартного відхилення за вказаний інтервал не можна розглядати як однозначну ознаку низької якості сегментації.

Порівняння двох діаграм показує, що стандартне відхилення інтенсивності сегментованої області доцільно використовувати як не жорсткий критерій якості сегментації. Належність цього показника до інтервалу  $20 \leq \sigma_{\text{lung}} \leq 40$  краще узгоджується з компактним скупченням точок із високими значеннями  $S_{\text{geom}}$  та Dice. Проте поза цим інтервалом також можуть спостерігатися окремі результати з високим Dice. Тому стандартне відхилення доцільно використовувати як допоміжну фотометричну ознаку, яка уточнює інтерпретацію геометричної оцінки.

Для кількісного уточнення зв'язку часткових оцінок із якістю сегмен-

тації було обчислено коефіцієнт кореляції Пірсона. Отримані значення наведено в табл. 3.7.

Таблиця 3.7

**Коефіцієнти кореляції Пірсона між показниками сегментації та Dice**

| Пара показників   | $r$   | $p$       |
|-------------------|-------|-----------|
| $S_{area}$ , Dice | 0.838 | $< 0.001$ |
| $S_{sym}$ , Dice  | 0.177 | $< 0.001$ |
| $S_{std}$ , Dice  | 0.821 | $< 0.001$ |
| $S_{geom}$ , Dice | 0.862 | $< 0.001$ |

Для часткової оцінки відносної площі  $S_{area}$  отримано значення  $r = 0.838$  ( $p < 0.001$ ), що відповідає сильному додатному лінійному зв'язку з коефіцієнтом Dice. Для часткової оцінки вертикальної симетрії  $S_{sym}$  отримано значення  $r = 0.177$  ( $p < 0.001$ ), що вказує на слабкий додатний зв'язок. Тому вертикальна симетрія сама по собі не є достатньо інформативною для оцінювання якості сегментації, однак може виконувати допоміжну роль у складі геометричного критерію.

Для інтегральної геометричної оцінки  $S_{geom}$  отримано найвище значення серед геометричних критеріїв:  $r = 0.862$  ( $p < 0.001$ ). Це показує, що спільне врахування близькості відносної площі та вертикальної симетрії до еталонних значень краще узгоджується з коефіцієнтом Dice, ніж використання окремих геометричних показників. Отже,  $S_{geom}$  доцільно розглядати як основний геометричний критерій у подальшому інтегральному оцінюванні результатів сегментації.

Окремо було проаналізовано часткову оцінку стандартного відхилення інтенсивності сегментованої області  $S_{std}$ . Для даного показника отримано значення коефіцієнта кореляції Пірсона  $r = 0.821$  ( $p < 0.001$ ), що також відповідає сильному додатному лінійному зв'язку з коефіцієнтом Dice.

Таким чином, аналіз часткових критеріїв показує, що інтегральна гео-

метрична оцінка  $S_{geom}$  має більш чіткий зв'язок із коефіцієнтом Dice. Часткова оцінка  $S_{std}$  та відповідний фотометричний показник мають допоміжний характер. У подальшому інтегральному оцінюванні результатів сегментації стандартне відхилення інтенсивності сегментованої області використовується як додаткова фотометрична складова.

### 3.4. Вибір результату сегментації на основі інтегральної оцінки

До рентгенівських зображень застосовано попередню обробку з використанням методу адаптивного вирівнювання гістограми з обмеженням контрасту (CLANE) [79]. Використання CLANE дозволяє підвищити локальний контраст зображення та покращити відділення легеневої області від фону. У роботі використано CLANE з параметром розбиття зображення на сітку розміром  $8 \times 8$ .

Наступним етапом до зображень застосовано методи глобального порогового відсікання гістограми з метою побудови бінарних масок легеневої області. У рамках дослідження використано три методи порогоування: метод Оцу (Otsu) [53], метод Капура (Kapur) [55] та модифікований метод збалансованого порогового відсікання гістограми (ВНТ-м). Кожен з методів порогоування застосовується до зображень кожного класу (COVID-19, вірусна пневмонія та відсутність захворювань) окремо. На етапі постобробки видаляються малі зв'язані компоненти (менше 20% площі зображення), що дотичні до меж зображення або розташовані на відстані до 10 px від них. Для отриманих бінарних масок обчислюється коефіцієнт Dice шляхом порівняння з відповідними еталонними масками, що дозволяє кількісно оцінити якість сегментації для кожного методу в межах конкретного класу.

Таким чином, для кожного зображення формуються альтернативні варіанти сегментації, отримані за допомогою методів Оцу, Капура та ВНТ-м.

У роботі запропоновано комбінований підхід вибору результату сегментації на основі анатомічно орієнтованих показників, що дозволяє визначити найбільш узгоджений з анатомічними характеристиками варіант сегментації. У якості критеріїв оцінювання використано коефіцієнт відносної площі легеневої області, показник вертикальної симетрії та стандартне відхилення інтенсивності пікселів у межах сегментованої області. Для кожного з цих показників попередньо обчислено медіанні референтні (еталонні) значення на підвибірці зображень з еталонними масками.

Для кожного результату сегментації обчислюється інтегральний показник за методом вибору результату сегментації на основі інтегральної оцінки.

Референтні значення показників визначаються на основі розмічених даних: для кожного показника ( $K_{\text{area}}$ ,  $K_{\text{sym}}$ ,  $\sigma_{\text{lung}}$ ) обчислюються медіанні значення для кожного класу зображень. Після чого формуються глобальні референтні значення для кожного показника ( $K_{\text{area}}^{\text{ref}}$ ,  $K_{\text{sym}}^{\text{ref}}$ ,  $\sigma_{\text{lung}}^{\text{ref}}$ ) як середні значення відповідних медіан.

Результатом сегментації за комбінованим підходом є бінарна маска області легень, для якої значення інтегрального анатомічно орієнтованого показника є максимальним серед результатів, отриманих методами Оцу, Капура та модифікованого методу ВНТ.

Нижче наведено результати дослідження, яке проведено для даних з датасету COVID-19 Radiography Database [22, 41]. У якості робочої вибірки було використано версію даного датасету, яка розміщена на платформі Kaggle [80].

На рис. 3.13 наведено приклад зображень грудної клітини з вищенаведеного датасету.

У табл. 3.8 наведено медіанні значення відповідних показників для кожного класу зображень. Також відображено загальні референтні значення, що визначені як середні значення по вказаним класам. Кожен клас рефе-




Рис. 3.13: Приклад зображень грудної клітини з датасету COVID-19 Radiography Database.

рентної підвибірки містить по 1000 зображень.

Таблиця 3.8

#### Референтні значення анатомічно орієнтованих показників

| Клас              | $\tilde{K}_{\text{area}}$ | $\tilde{K}_{\text{sym}}$ | $\tilde{\sigma}_{\text{lung}}$ |
|-------------------|---------------------------|--------------------------|--------------------------------|
| COVID             | $0.252 \pm 0.084$         | $0.905 \pm 0.073$        | $29.28 \pm 9.91$               |
| Без захворювання  | $0.235 \pm 0.057$         | $0.897 \pm 0.067$        | $30.82 \pm 4.92$               |
| Вірусна пневмонія | $0.230 \pm 0.050$         | $0.819 \pm 0.086$        | $27.31 \pm 5.71$               |
| Середнє значення  | 0.239                     | 0.874                    | 29.14                          |

У таблиці наведено медіанні значення анатомічно орієнтованих показників для кожного класу та їх стандартні відхилення, обчислені на основі 1000 еталонних масок. Отримані значення свідчать, що відхилення референтних показників є відносно невеликим.

У табл. 3.9 наведено відсоток зображень, для яких при застосуванні методів Оцу (Otsu), Капура (Kapur) та ВНТ-м коефіцієнт Dice перевищує задані порогові значення. Значення показника обчислено на тестовій підвибірці, що містить по 300 зображень для кожного класу. Отримані результати показують, що ефективність методів залежить від класу зображень. Окремо у таблиці наведено результати для комбінованого методу, що базується на інтегральному анатомічно орієнтованому показнику.

Таблиця 3.9

**Розподіл якості сегментації за значенням коефіцієнта Dice на  
датасеті COVID-19 Radiography Database**

| Метод        | Клас              | Dice > 0.8, % | Dice > 0.6, % |
|--------------|-------------------|---------------|---------------|
| BHT-m        | COVID             | 16.7          | 34.7          |
| BHT-m        | Без захворювання  | 31.0          | 63.3          |
| BHT-m        | Вірусна пневмонія | 6.3           | 22.0          |
| Капул        | COVID             | 17.0          | 48.7          |
| Капул        | Без захворювання  | 43.3          | 73.7          |
| Капул        | Вірусна пневмонія | 3.7           | 27.3          |
| Otsu         | COVID             | 29.7          | 62.0          |
| Otsu         | Без захворювання  | 56.3          | 82.0          |
| Otsu         | Вірусна пневмонія | 1.7           | 38.0          |
| Комбінований | COVID             | 38.7          | 67.7          |
| Комбінований | Без захворювання  | 62.0          | 88.7          |
| Комбінований | Вірусна пневмонія | 7.7           | 47.7          |

Вагові коефіцієнти інтегрального показника якості сегментації встановлено на рівні 0.4 для відносної площі, 0.4 для вертикальної симетрії та 0.2 для стандартного відхилення інтенсивності. Такий розподіл ваг зумовлений результатами аналізу анатомічно орієнтованих показників, наведеного у розділі 3.3. Зокрема, відносна площа та вертикальна симетрія безпосередньо характеризують геометричну відповідність сегментованої області легеневій анатомії, тому їм надано більшу вагу. Стандартне відхилення інтенсивності використовується як допоміжний фотометричний критерій, що доповнює геометричну оцінку. Додатково було проведено експеримент із автоматичним визначенням ваг на основі відхилення анатомічно орієнтованих показників від референтних значень, але отримані результати не продемонстрували суттєвого покращення якості сегментації.

Отримані результати демонструють різну ефективність досліджуваних методів порогової сегментації залежно від класу рентгенівських зображень.

Для датасету COVID-19 Radiography Database найвищі значення коефіцієнта Dice серед окремих методів пороговування забезпечує метод Оцу. Зокрема, для класу COVID частка зображень із  $\text{Dice} > 0.8$  становить 29.7%, а з  $\text{Dice} > 0.6$  — 62.0%. Для класу без захворювання відповідні значення становлять 56.3% та 82.0%. Метод Оцу є найбільш стабільним серед окремих порогових методів для даної вибірки.

Метод Капура демонструє нижчі результати порівняно з методом Оцу. Проте для класу без захворювання також забезпечує прийнятну частку зображень із  $\text{Dice} > 0.6$ , яка становить 73.7%. Водночас для класу вірусної пневмонії ефективність усіх окремих методів знижується. Найменша частка зображень із  $\text{Dice} > 0.8$  для цього класу спостерігається для методу Оцу і становить 1.7%. Для методів ВНТ-т та Капура даний показник становить 6.3% та 3.7% відповідно. Це може бути пов'язано зі складнішою структурою зображень даного класу, нижчою контрастністю меж легеневої області або наявністю патологічних змін, які впливають на розподіл інтенсивності.

Комбінований підхід, що базується на інтегральному анатомічно орієнтованому показнику, забезпечує покращення результатів для всіх розглянутих класів. Для класу COVID частка зображень із  $\text{Dice} > 0.8$  зростає до 38.7%, а з  $\text{Dice} > 0.6$  — до 67.7%. Для класу без захворювання відповідні значення становлять 62.0% та 88.7%, що є найкращим результатом серед усіх розглянутих підходів. Для класу вірусної пневмонії комбінований метод також забезпечує підвищення частки зображень із  $\text{Dice} > 0.6$  до 47.7%, проте частка сегментацій із  $\text{Dice} > 0.8$  залишається відносно невеликою.

Таким чином, використання інтегрального показника дозволяє зменшити залежність результату від одного конкретного методу пороговування. Запропонований підхід не змінює структуру отриманих бінарних масок, а виконує вибір найбільш анатомічно узгодженого результату серед альтернативних варіантів сегментації. Це дозволяє використати переваги окремих

методів у тих випадках, коли вони формують більш коректну маску для конкретного зображення.

У табл. 3.10 наведено порівняння методів сегментації за часткою зображень усіх класів, для яких Dice перевищує вказані порогові значення, а також за середнім значенням коефіцієнта Dice на всій робочій вибірці.

*Таблиця 3.10*

**Порівняння методів сегментації за коефіцієнтом Dice на датасеті  
COVID-19 Radiography Database**

| Метод        | Dice > 0.8, % | Dice > 0.6, % | Dice              |
|--------------|---------------|---------------|-------------------|
| ВНТ-m        | 18.0          | 40.0          | $0.546 \pm 0.229$ |
| Капура       | 21.3          | 49.9          | $0.571 \pm 0.244$ |
| Otsu         | 29.2          | 60.7          | $0.631 \pm 0.225$ |
| Комбінований | 36.1          | 68.0          | $0.668 \pm 0.206$ |

Загальне порівняння методів на тестовій вибірці підтверджує ефективність запропонованого підходу. Для комбінованого методу частка зображень із  $\text{Dice} > 0.8$  становить 36.1%. Для методів ВНТ-m, Капура та Оцу відповідні значення становлять 18.0%, 21.3% та 29.2%. Аналогічна тенденція спостерігається і для порогу  $\text{Dice} > 0.6$ : комбінований метод забезпечує 68.0%, окремі методи забезпечують 40.0%, 49.9% та 60.7% відповідно. Середнє значення коефіцієнта Dice для комбінованого підходу становить 0.668, що перевищує відповідні значення для всіх окремих методів пороговування.

Для оцінювання впливу вибору вагових коефіцієнтів на роботу комбінованого методу було додатково проведено аналіз.

Досліджено декілька конфігурацій ваг для трьох складових інтегрального показника: відносної площі, вертикальної симетрії та стандартного відхилення інтенсивності. У наведених комбінаціях значення коефіцієнтів змінюються в помірних межах, без виключення окремих показників з інтегральної оцінки.

Результати аналізу наведено в табл. 3.11.

Таблиця 3.11

**Аналіз впливу вагових коефіцієнтів на результат комбінованого методу**

| $w_{area}$ | $w_{sym}$ | $w_{std}$ | Dice $\geq 0.8$ , % | Dice $\geq 0.6$ , % | Dice              |
|------------|-----------|-----------|---------------------|---------------------|-------------------|
| 0.30       | 0.30      | 0.40      | 35.3                | 66.4                | $0.664 \pm 0.207$ |
| 0.30       | 0.50      | 0.20      | 36.2                | 68.0                | $0.664 \pm 0.214$ |
| 0.33       | 0.33      | 0.34      | 36.0                | 67.3                | $0.667 \pm 0.206$ |
| 0.40       | 0.30      | 0.30      | 36.0                | 67.3                | $0.668 \pm 0.203$ |
| 0.40       | 0.40      | 0.20      | 36.1                | 68.0                | $0.668 \pm 0.206$ |
| 0.50       | 0.30      | 0.20      | 36.0                | 67.2                | $0.668 \pm 0.203$ |

Частка зображень із Dice  $\geq 0.8$  змінюється в межах 35.3–36.2%, а частка зображень із Dice  $\geq 0.6$  — у межах 66.4–68%. Середнє значення Dice також змінюється незначно та перебуває в межах 0.664–0.668.

Додатково було розглянуто граничні випадки, коли в інтегральній оцінці використовується лише один із трьох показників. Як видно з таблиці 3.12, застосування лише одного показника призводить до зниження як середнього значення Dice, так і частки зображень із Dice  $\geq 0.6$  та Dice  $\geq 0.8$ .

Таблиця 3.12

**Аналіз результатів комбінованого методу при використанні одного вагового коефіцієнта**

| $w_{area}$ | $w_{sym}$ | $w_{std}$ | Dice $\geq 0.8$ , % | Dice $\geq 0.6$ , % | Dice              |
|------------|-----------|-----------|---------------------|---------------------|-------------------|
| 1.00       | 0.00      | 0.00      | 33.9                | 61.3                | $0.648 \pm 0.209$ |
| 0.00       | 1.00      | 0.00      | 26.4                | 58.9                | $0.615 \pm 0.231$ |
| 0.00       | 0.00      | 1.00      | 28.1                | 55.4                | $0.624 \pm 0.211$ |

Отримані результати підтверджують доцільність комплексного врахування анатомічно орієнтованих показників. Використання лише одного з них призводить до зниження якості сегментації.

З метою перевірки узагальнювальної здатності запропонованого підходу проведено додаткове оцінювання на датасеті Shenzhen [36] та на осно-

ві відповідних еталонних масок, що містяться в датасеті [37]. У даному експерименті використано референтні значення анатомічно орієнтованих показників (середні значення за класами), що були визначені на датасеті COVID-19 Radiography Database (табл. 3.8).

У табл. 3.13 наведено порівняння методів сегментації за часткою зображень, для яких коефіцієнт Dice перевищує задані порогові значення, а також за середнім значенням показника на всій вибірці. Окремо у таблиці наведено результати для комбінованого методу, що базується на інтегральному анатомічно орієнтованому показнику.

Таблиця 3.13

**Порівняння методів сегментації за коефіцієнтом Dice для датасету Shenzhen**


| Метод        | Dice > 0.8, % | Dice > 0.6, % | Dice              |
|--------------|---------------|---------------|-------------------|
| ВНТ-m        | 49.1          | 66.1          | $0.704 \pm 0.160$ |
| Kapur        | 11.8          | 83.2          | $0.704 \pm 0.115$ |
| Otsu         | 27.6          | 85.0          | $0.731 \pm 0.123$ |
| Комбінований | 44.5          | 86.7          | $0.751 \pm 0.125$ |

Медіанні значення референтних анатомічно орієнтованих показників за датасетом Shenzhen [36] та на основі відповідних еталонних масок, що містяться в датасеті [37], становлять:  $\tilde{K}_{\text{area}} = 0.25$ ,  $\tilde{K}_{\text{sym}} = 0.92$ ,  $\tilde{\sigma}_{\text{lung}} = 28.93$ .

Отримані результати показують, що референтні значення, визначені на основі COVID-19 Radiography Database, можуть бути використані для вибору результату сегментації на іншому датасеті. Для датасету Shenzhen медіанні (референтні) значення анатомічно орієнтованих показників є близькими до референтних значень, отриманих на основному датасеті, зокрема для відносної площі та стандартного відхилення інтенсивності.

На рис. 3.14 наведено приклад застосування методів глобального порогоування Оцу, Капура та модифікованого методу ВНТ для сегментації. Для наведеного зображення значення інтегрального анатомічно орієнтованого

показника становили:  $Q = 0.694$  для методу Оцу,  $Q = 0.708$  для методу Капура та  $Q = 0.844$  для ВНТ-м. Найбільше значення інтегрального показника отримано для ВНТ-м. Відповідно, у межах запропонованого механізму вибору саме цей результат сегментації було обрано як найбільш анатомічно узгоджений.



(а) Метод Оцу      (б) Метод Капура      (в) Модифікований метод ВНТ

Рис. 3.14: Приклад сегментації.

Додатковий експеримент на датасеті Shenzhen показує, що запропонований підхід може бути застосований для вибору результату сегментації на незалежній вибірці зображень. На даному датасеті найвище середнє значення Dice серед окремих методів показує метод Оцу (0.731). Методи ВНТ-м та Капура мають однакове середнє значення Dice (0.704), але відрізняються за розподілом результатів. Метод ВНТ-м забезпечує більшу частку зображень із  $\text{Dice} > 0.8$  (49.1%). Методи Капура та Оцу забезпечують більшу частку зображень із  $\text{Dice} > 0.6$ .

Комбінований метод на датасеті Shenzhen забезпечує найвище середнє значення Dice, що становить 0.751, та найбільшу частку зображень із  $\text{Dice} > 0.6$  — 86.7%. При цьому частка зображень із  $\text{Dice} > 0.8$  становить 44.5%, що є нижчим за відповідне значення для методу ВНТ-м, але вищим за значення для методів Капура та Оцу. Проте комбінований підхід забезпечує найбільшу частку зображень із  $\text{Dice} > 0.6$  та найвище середнє значення Dice, що свідчить про покращення загального рівня якості сегментації на

вибірці.

Для додаткової перевірки узгодженості референтних значень обчислено анатомічно орієнтовані показники еталонних масок області легень для кількох наборів даних. Дослідження проведено безпосередньо за еталонними бінарними масками області легень з датасетів, що були накладені на оригінальні зображення. Результати наведено у табл. 3.14.

Таблиця 3.14

**Анатомічно орієнтовані характеристики еталонних масок  
області легень для різних наборів даних**

| Набір даних | К-сть | $\tilde{K}_{\text{area}}$ | $\tilde{K}_{\text{sym}}$ | $\tilde{\sigma}_{\text{lung}}$ |
|-------------|-------|---------------------------|--------------------------|--------------------------------|
| COVID-19 RD | 3000  | $0.239 \pm 0.066$         | $0.874 \pm 0.085$        | $29.14 \pm 7.33$               |
| COVID-QU-Ex | 2913  | $0.236 \pm 0.082$         | $0.910 \pm 0.076$        | $29.75 \pm 9.44$               |
| Montgomery  | 138   | $0.257 \pm 0.061$         | $0.925 \pm 0.046$        | $40.84 \pm 5.52$               |
| Shenzhen    | 566   | $0.248 \pm 0.058$         | $0.915 \pm 0.074$        | $28.93 \pm 5.87$               |

Медіанні значення коефіцієнта відносної площі та коефіцієнта вертикальної симетрії для розглянутих наборів даних є відносно близькими. Для датасетів COVID-19 Radiography Database (у таблиці позначений як COVID-19 RD) [41], COVID-QU-Ex [77] та Shenzhen [36] з еталонними масками [37] спостерігаються близькі медіанні значення стандартного відхилення інтенсивності. Вищий показник стандартного відхилення інтенсивності для Montgomery [36] пов'язаний з більшим контрастом зображень. Отримані значення вказують на певну узгодженість розглянутих характеристик між різними наборами даних, що дає можливість використовувати їх і для інших датасетів. Проте фотометричні показники можуть залежати від властивостей конкретного датасету.

Результати експериментів підтверджують доцільність використання інтегральної оцінки для вибору результату сегментації серед альтернативних порогових методів. Запропонований підхід дозволяє підвищити середнє

значення коефіцієнта Dice та збільшити частку зображень із прийнятною якістю сегментації. Проте ефективність підходу залежить від коректності вибору референтних значень анатомічно орієнтованих показників.

### **3.5. Постобробка сегментованої області за допомогою морфологічних методів**

У задачі сегментації області легень результати глобального порогоування можуть містити фонові компоненти, окремі ізольовані ділянки, розриви в межах легеневої області або внутрішні порожнини. У цьому розділі продовжуються дослідження, наведені у розділі 3.4, та проаналізовано вплив морфологічної постобробки на якість отриманих бінарних масок.

Морфологічна постобробка розглядається як окремий етап формування бінарних масок, отриманих після порогової сегментації. Її застосування спрямоване на усунення дрібних артефактів, зменшення впливу фонових компонент та формування більш цілісної області легень [71, 81].

На першому етапі до бінарної маски застосовується морфологічна ерозія з еліптичним структурним елементом розміром  $5 \times 5$ . Ерозія зменшує бінарну область відповідно до форми структурного елемента та використовується для зменшення дрібних фонових фрагментів.

Після цього виконується видалення малих зв'язаних компонент, площа яких становить менше 20% площі зображення та які дотичні до меж зображення або розташовані на відстані до 10 px від них. У межах даної процедури кожній групі суміжних пікселів маски присвоюється окрема мітка, що дозволяє обчислити площу кожної компоненти та визначити її розташування відносно меж зображення. Такий етап спрямований на зменшення впливу фонових артефактів, які можуть залишатися після порогового перетворення.

Після цього застосовується морфологічна дилатація з еліптичним стру-

ктурним елементом розміром  $7 \times 7$ . Дилатація використовується для розширення сегментованої області та часткового відновлення меж маски після попередньої операції ерозії. На відміну від дилатації з більшими ядрами, такий варіант зменшує частку пікселів, помилково включених до сегментованої області.

Після дилатації виконується відбір двох найбільших зв'язаних компонентів маски. Такий етап відповідає анатомічній структурі області легень, яка зазвичай представлена правою та лівою легеневими областями, і дозволяє вилучити залишкові фонові фрагменти після морфологічного розширення маски.

На завершальному етапі виконується заповнення внутрішніх порожнин у межах отриманої бінарної маски. Фонова область зображення заповнюється, починаючи з лівого верхнього кута. Після інверсії результату заливки визначаються ділянки, які не мають контакту з межами зображення та повністю оточені пікселями маски. Такі ділянки додаються до початкової маски, що дозволяє сформувати більш цілісну сегментовану область.

Таким чином, морфологічна постобробка поєднує операції очищення, відбору основних компонент, розширення області та заповнення порожнин. Це дозволяє зменшити кількість фонових артефактів і сформувати більш цілісну бінарну маску перед обчисленням метрик якості сегментації.

Для порівняння з базовими результатами сегментації, наведеними у табл. 3.10, додатково проведено оцінювання після застосування морфологічної постобробки. У випадку комбінованого методу морфологічна обробка проводиться до процедури вибору конкретного методу. У табл. 3.15 наведено узагальнені результати для загальної тестової вибірки обсягом 900 зображень без деталізації за класами.

Порівняння з базовими результатами показує, що морфологічна постобробка має різний вплив на окремі методи порогоування. Для ВНТ-м середнє значення Дісе зростає з 0.546 до 0.622, а для методу Капура — з

Таблиця 3.15

**Порівняння методів сегментації після морфологічної  
постобробки за коефіцієнтом Dice на датасеті COVID-19  
Radiography Database**

| Метод        | Dice $\geq 0.8$ , % | Dice $\geq 0.6$ , % | Dice              |
|--------------|---------------------|---------------------|-------------------|
| BHT-m        | 34.3                | 60.2                | $0.622 \pm 0.249$ |
| Kapur        | 43.7                | 73.1                | $0.682 \pm 0.225$ |
| Otsu         | 49.2                | 85.3                | $0.742 \pm 0.181$ |
| Комбінований | 56.6                | 89.7                | $0.765 \pm 0.161$ |

0.571 до 0.682. Для методу Оцу середнє значення Dice зростає з 0.631 до 0.742. Отриманий результат вказує на те, що морфологічна постобробка не є універсальним способом покращення результатів для всіх порогових методів.

Для комбінованого методу після застосування морфологічної постобробки середнє значення Dice зростає з 0.668 до 0.765. Частка зображень із Dice  $\geq 0.8$  збільшується з 36.1% до 56.6%. Частка зображень із Dice  $\geq 0.6$  збільшується з 68.0% до 89.7%. Отримані результати показують, що морфологічну постобробку доцільно розглядати як допоміжний етап формування бінарних масок області. Застосування морфологічної постобробки до результатів, обраних механізмом вибору сегментації на основі інтегрального анатомічно орієнтованого показника, забезпечує відносно високі значення Dice та підвищує частку зображень із якісною сегментацією.

Додатково було проаналізовано розподіл рішень комбінованого підходу. Із 900 тестових зображень метод Otsu було обрано у 438 випадках, Kapur — у 274 випадках, а BHT-m — у 188 випадках. Отже, комбінований метод не зводиться до вибору одного домінуючого алгоритму, а використовує результати різних методів залежно від значень анатомічно орієнтованих показників.

У табл. 3.16 наведено узагальнені результату на основі датасету Shenzhen

[36] та на основі відповідних еталонних масок, що містяться в датасеті [37]. Для даного експерименту застосовується морфологічна дилатація з еліптичним структурним елементом розміром  $11 \times 11$ .

Таблиця 3.16

**Порівняння методів сегментації після морфологічної  
постобробки на датасеті Shenzhen**

| Метод        | Dice $\geq 0.8$ , % | Dice $\geq 0.6$ , % | Dice              | OSI               |
|--------------|---------------------|---------------------|-------------------|-------------------|
| ВНТ-m        | 68.7                | 96.8                | $0.812 \pm 0.073$ | $0.493 \pm 0.134$ |
| Карур        | 32.5                | 76.1                | $0.693 \pm 0.153$ | $0.421 \pm 0.192$ |
| Otsu         | 48.2                | 90.3                | $0.757 \pm 0.130$ | $0.478 \pm 0.183$ |
| Комбінований | 73.7                | 97.7                | $0.817 \pm 0.075$ | $0.503 \pm 0.129$ |

Порівняння з базовими результатами, наведеними у табл. 3.13, показує, що дана морфологічна постобробка по-різному впливає на окремі порогові методи. Для ВНТ-m середнє значення Dice зростає з 0.704 до 0.812, для методу Оцу — з 0.731 до 0.757. Для методу Капура середнє значення Dice зменшується і становить 0.693, що вказує на меншу застосовність використаної постобробки для масок, отриманих даним методом. Для методу ВНТ-m морфологічна постобробка дала змогу зменшити значення OSI з  $0.600 \pm 0.656$  до  $0.493 \pm 0.134$ , що вказує на зменшення надлишкової сегментації.

Для комбінованого методу середнє значення Dice становить 0.817, що є найвищим серед розглянутих підходів. Частка зображень із Dice  $\geq 0.6$  також є найбільшою і становить 97.7%. Частка зображень із Dice  $\geq 0.8$  для комбінованого методу становить 73.7% та є більшою, ніж значення для окремих методів.

Аналіз розподілу рішень комбінованого підходу показує, що з 566 тестових зображень ВНТ-m було обрано у 462 випадках, Otsu — у 64 випадках, а Карур — у 40 випадках.

Отримані результати показують, що морфологічна постобробка є доцільним допоміжним етапом уточнення бінарних масок області легень. Застосування механізму вибору результату сегментації на основі інтегрального анатомічно орієнтованого показника дозволяє підвищити стабільність результатів і зменшити кількість випадків із низькою якістю сегментації порівняно з використанням окремих порогових методів.

На рис. 3.15 наведено застосування морфологічних методів до зображень датасету Shenzhen.



Рис. 3.15: Приклад застосування порогових методів до зображення №2 (CLANE).

Варто зазначити, що морфологічна постобробка у даному випадку розглядається як допоміжний технічний етап. Даний підхід не є універсальним методом покращення сегментації. Ефективність застосування морфологічної постобробки залежить від початкової структури бінарної маски, наявності фонових компонент, розривів та внутрішніх порожнин. Тому параметри морфологічних операцій мають підбиратися з урахуванням властивостей конкретної вибірки зображень та характеру помилок сегментації.

У практичному застосуванні такий етап може виконуватися в напів-автоматичному режимі або потребувати візуального контролю результатів. Надмірно агресивна постобробка може змінювати межі сегментованої області та погіршувати результат для окремих зображень.

### 3.6. Сегментація області ураження інфекцією на рентген-зображеннях грудної клітини за допомогою нейронної мережі

У цьому розділі досліджується архітектура нейронної мережі для сегментації області ураження інфекцією на рентгенівських зображеннях грудної клітини. Модель побудована на основі архітектури U-Net з енкодером ResNet18. Кількість епох навчання — 80. У дослідженні використано рентгенівські зображення COVID-19 з датасету COVID-QU-Ex [77], які мають еталонні маски області ураження. Загальний обсяг вибірки становить 2913 рентген-зображень, що розділені на підвибірки: навчальна — 1864 зображень, валідаційна — 466 зображень, тестова — 583 зображень. Усі зображення та маски приводяться до розміру  $256 \times 256$  пікселів.

Метою експериментів є оцінка впливу інформації про область легень на якість сегментації зони ураження інфекцією. Для цього досліджено три варіанти подання вхідних даних.

У першому експерименті (Original) використовується оригінальне рентгенівське зображення, подане у триканальному форматі для сумісності з попередньо навченим енкодером ResNet18.

У другому експерименті (Original+lung mask) до оригінального зображення додається еталонна маска легень як окремий вхідний канал. У цьому випадку вхідне зображення формується з трьох каналів: двох копій оригінального рентген-зображення та еталонної маски легень у якості третього каналу.

У третьому експерименті (Masked image) оригінальне зображення попередньо обмежується маскою легень. Обмеження проводиться процедурою накладання бінарної маски області легень на оригінальне зображення. Після цього отримане одноканальне зображення подається у триканальному форматі на вхід ResNet18-енкодера.

Приклад зображень, що подаються на вхід до нейронної мережі, наведено на рис. 3.16.




Рис. 3.16: Приклади вхідних зображень.

Таким чином, експеримент з використанням тільки оригінального зображення використовується для оцінювання якості сегментації без додаткової анатомічної інформації. Експеримент з використанням оригінального зображення та маски легень перевіряє, чи може нейронна мережа використати маску легень як окрему допоміжну ознаку. Експеримент із попередньо обмеженим зображенням передбачає анатомічне обмеження самого вхідного рентген-зображення, за якого модель аналізує тільки область легень.

Окремо оцінюється вплив анатомічної постобробки результатів сегментації. У дослідженні з постобробкою маска області ураження, що була спрогнозована, обмежується еталонною маскою легень з датасету. В цьому випадку пікселі отриманої маски області ураження, які розташовані поза межами легеневої області, вилучаються з кінцевої маски. Даний підхід відповідає припущенню, що зона інфекційного ураження локалізується в межах області легень.

Оцінювання якості сегментації виконується за двома групами метрик. До першої групи належать метрики класифікації пікселів: Accuracy, Precision та Recall. Вони характеризують коректність віднесення пікселів до класу

інфікованої області або фону. До другої групи належать метрики просторового перекриття прогнозованої та еталонної масок:  $MIoU$ ,  $Dice$ ,  $IoU_{inf}$  та  $DSC$ . Позитивним класом вважається область ураження, а негативним класом — фон.

Показник  $IoU_{inf}$  характеризує відношення площі перетину прогнозованої та еталонної масок інфікованої області до площі їх об'єднання:

$$IoU_{inf} = \frac{TP}{TP + FP + FN}. \quad (3.10)$$

де  $TP$  — кількість пікселів області ураження, коректно віднесених до позитивного класу;  $FP$  — кількість фонових пікселів, помилково віднесених до області ураження;  $FN$  — кількість пікселів області ураження, які не знайдені моделлю.

Коефіцієнт  $Dice$  обчислюється окремо для кожного окремого зображення тестової вибірки з подальшим визначенням середнього значення та стандартного відхилення.

Додатково обчислюється коефіцієнт  $DSC$  на рівні всієї тестової вибірки, причому  $TP$ ,  $FP$  та  $FN$  визначаються як загальні кількості відповідних пікселів для всіх зображень тестового набору:

$$DSC = \frac{2TP}{2TP + FP + FN}. \quad (3.11)$$

Показник  $DSC$  характеризує узагальнене перекриття прогнозованих та еталонних масок на рівні всієї тестової вибірки.

Для контролю процесу навчання моделі проаналізовано зміну коефіцієнта  $Dice$  та функції втрат на навчальній і валідаційній вибірках, що дозволяє оцінити збіжність навчання. Відповідні графіки наведено на рис. 3.17.

Навчання моделі завершується за критерієм ранньої зупинки. Найвище значення  $Dice$  на валідаційній вибірці отримано на 22-й епосі. Відповідний стан моделі використовується для подальшого тестування.




Рис. 3.17: Динаміка навчання моделі з попереднім обмеженням рентген-зображення маскою легень.

Для кожного зображення тестової вибірки обчислюються показники якості сегментації відносно еталонної маски області ураження. Для експерименту лише з використанням оригінального рентген-зображення (Original) результати наведено окремо без постобробки та з анатомічною постобробкою маскою легень. Для експерименту з використанням оригінального зображення і маски легень (Original+lung mask) та для експерименту з попереднім обмеженням рентген-зображення маскою легень (Masked image) результати наведено без застосування постобробки, оскільки її застосування не змінює значення метрик.

У табл. 3.17 наведено значення метрик класифікації пікселів.

Таблиця 3.17

### Результати сегментації області ураження за метриками класифікації пікселів

| Експеримент        | Постобробка  | <i>Accuracy</i>   | <i>Precision</i>  | <i>Recall</i>     |
|--------------------|--------------|-------------------|-------------------|-------------------|
| Original           | -            | $0.960 \pm 0.032$ | $0.796 \pm 0.222$ | $0.836 \pm 0.184$ |
| Original           | Маска легень | $0.963 \pm 0.032$ | $0.812 \pm 0.228$ | $0.836 \pm 0.184$ |
| Original+lung mask | -            | $0.960 \pm 0.034$ | $0.773 \pm 0.239$ | $0.878 \pm 0.151$ |
| Masked image       | -            | $0.965 \pm 0.033$ | $0.803 \pm 0.222$ | $0.855 \pm 0.184$ |

У табл. 3.18 наведено значення метрик перекриття прогнозованої та еталонної масок.

Таблиця 3.18

**Результати сегментації області ураження за метриками  
перекриття масок**

| Експеримент        | Постобробка  | $MIoU$            | $Dice$            | $IoU_{inf}$       |
|--------------------|--------------|-------------------|-------------------|-------------------|
| Original           | -            | $0.816 \pm 0.120$ | $0.784 \pm 0.193$ | $0.679 \pm 0.224$ |
| Original           | Маска легень | $0.825 \pm 0.125$ | $0.792 \pm 0.196$ | $0.692 \pm 0.231$ |
| Original+lung mask | -            | $0.821 \pm 0.127$ | $0.789 \pm 0.192$ | $0.687 \pm 0.232$ |
| Masked image       | -            | $0.831 \pm 0.127$ | $0.799 \pm 0.193$ | $0.703 \pm 0.234$ |

Для експерименту з використанням лише оригінального зображення значення DSC становить 0.857 без постобробки та 0.866 після обмеження прогнозованої маски областю легень. Для експерименту з використанням оригінального зображення та маски легень значення DSC становить 0.861. Для експерименту з попереднім обмеженням рентген-зображення маскою легень отримано найвище значення DSC, що становить 0.875.

Аналіз результатів показує, що постобробка за допомогою маски легень позитивно впливає на експеримент Original, у якому на вхід моделі подається лише оригінальне рентген-зображення. У цьому випадку обмеження допомагає підвищити значення  $Dice$  з  $0.784 \pm 0.193$  до  $0.792 \pm 0.196$ ,  $IoU_{inf}$  — з  $0.679 \pm 0.224$  до  $0.692 \pm 0.231$ , DSC — з 0.857 до 0.866. Використання маски легень на етапі постобробки дозволяє видалити з прогнозованої маски елементи, що розташовані за межами області легень, і покращити результат сегментації.

Отриманий результат узгоджується з підходом у роботі [44], у якому для сегментації області інфекційного ураження застосовується обмеження прогнозованої маски ураження інфекцією за допомогою еталонної маски легень на етапі постобробки. Даний підхід відповідає анатомічному припущенню про те, що зона ураження інфекцією розташовується в межах

області легень. Тому обмеження прогнозованої маски областю легень є доцільним етапом уточнення результату сегментації.

В експерименті з використанням оригінального зображення та маски легень як окремого вхідного каналу (Original+lung mask) якість сегментації є вищою порівняно з базовим експериментом без постобробки. Для цього режиму Dice становить  $0.789 \pm 0.192$ ,  $IoU_{inf} = 0.687 \pm 0.232$ , а DSC — 0.861. Значення Recall становить  $0.878 \pm 0.151$  і є вищим порівняно з базовим експериментом (Original) як без постобробки, так і після анатомічної постобробки та вказує на ширше покриття області ураження. Проте значення Precision, Dice,  $IoU_{inf}$  та DSC є нижчими, ніж у базовому експерименті після постобробки, що вказує на включення елементів, які не належать до еталонної області ураження. Відповідно, подання маски легень як окремого каналу підвищує повноту виділення інфікованої області, але не забезпечує додаткового покращення метрик перекриття масок.

Найкращі результати отримано в експерименті з попереднім обмеженням рентген-зображення маскою легень (Masked image). У цьому випадку Dice становить  $0.799 \pm 0.193$ , MIoU —  $0.831 \pm 0.127$ ,  $IoU_{inf} = 0.703 \pm 0.234$ , а DSC — 0.875. Попереднє обмеження зображення залишає виключно область легень у якості вхідних даних, тому модель зосереджується переважно на аналізі легеневої області.

Отримані результати підтверджують, що використання інформації про межі легень є доцільним для задачі сегментації зони ураження інфекцією та може використовуватися як на етапі формування вхідних даних, так і на етапі постобробки прогнозованої маски. При цьому найбільш ефективним у проведеному експерименті є попереднє анатомічне обмеження рентген-зображення маскою легень.

З метою порівняння нижче наведено результати досліджень, у яких проводилася сегментація області ураження COVID-19 на рентген-зображеннях із набору COVID-QU-Ex, що використовується і в даній роботі. В наведе-

них дослідженнях експеримент проводиться для тієї самої схеми поділу вибірки: 1864 зображення для навчання, 466 — для валідації та 583 — для тестування.

У роботі [44] при сегментації області з інфекцією було отримано значення  $DSC = 0.882$ . У даному дослідженні для експерименту з попереднім обмеженням рентген-зображення маскою легень отримано  $DSC = 0.875$ , що є близьким до наведеного результату.

У дослідженні [45] для методу Co-ERA-Net автори отримали  $Dice = 0.771$  та  $IoU = 0.674$ . У даному дослідженні найвище середнє значення  $Dice$  становило 0.799, а  $IoU_{inf} = 0.703$ . Відповідно, отримані значення показників якості сегментації у даній роботі є порівнюваними з результатами сучасних підходів до сегментації області інфекції на рентген-зображеннях.


У роботі [46] для набору COVID-QU-Ex наведено значення  $MIoU = 0.817$  та  $F1-score = 0.893$ . У даному дослідженні значення  $MIoU$  становить 0.831,  $DSC$  (що відповідає значенню  $F1-score$  у роботі [46]) становить 0.875. Проте показник  $MIoU$  враховує якість сегментації як області з інфекцією, так і фонового класу. Відповідно, збільшення показника  $MIoU$  може бути пов'язане з точнішим віднесенням пікселів до фонового класу. У роботі [46] наведено вищі значення  $Precision = 0.897$  та  $Recall = 0.906$ , що вказує на вищу точність і повноту виділення інфікованої області, ніж у даній роботі.

Важливою перевагою дослідженого підходу у роботі є простота реалізації. Маска області легень може бути використана без ускладнення архітектури нейронної мережі як додаткова вхідна інформація у вигляді анатомічного обмеження рентген-зображення. Подібний підхід реалізований у роботі [42] для сегментації області ураження інфекцією на КТ-зображеннях пацієнтів із COVID-19.

Отримані значення у даній роботі є порівнюваними з результатами робіт, у яких використовувався набір даних COVID-QU-Ex. Проте резуль-

тати нейромережевого навчання можуть залежати від порядку подання зображень, параметрів навчання та інших деталей реалізації архітектури. Відповідно, невеликі відмінності між числовими показниками потребують обережної інтерпретації.

Результат проведеного експерименту також має практичне значення для підготовки навчальних вибірок. У частині рентген-зображень зона ураження інфекцією може займати значну площу області легень та наближатися до меж легень. Приклади подібних зображень наведено на рис. 3.18. В таких випадках використання маски області легень під час ручного формування еталонної розмітки може бути корисним для обмеження області у якій проводиться виділення зони ураження інфекцією.



(а) Зображення №1 (б) Зображення №2 (в) Зображення №3

Рис. 3.18: Приклади зон ураження інфекцією.

Відповідно, маска області легень може використовуватися у якості анатомічного орієнтира під час підготовки даних для навчальних вибірок з метою застосування у нейромережевих архітектурах. При чому для попереднього виділення області легень можуть використовуватися порогові методи сегментації, що розглядалися у попередніх розділах даної роботи.

### 3.7. Сегментація області ураження за допомогою методу кластеризації k-середніх

У даному розділі досліджується можливість виділення області ураження інфекцією на рентген-зображеннях грудної клітини за допомогою методу k-середніх. На відміну від нейромережових підходів, даний метод не потребує попереднього навчання моделі та може бути використаний як спрощений спосіб аналізу розподілу інтенсивностей у межах області легень.

Для експерименту використано рентген-зображення COVID-19 з датасету COVID-QU-Ex [77], який застосовувався у попередньому розділі для сегментації області ураження інфекцією за допомогою нейронної мережі. Оцінювання застосування методу проведено на валідаційній вибірці, що містить 466 зображень, та на тестовій, що містить 583 зображення. Для кожного рентген-зображення використовується еталонна маска області легень, що знаходиться в наведеному датасеті.

Сегментація на основі застосування методу k-середніх виконується в межах еталонної маски легень. Для пікселів, що знаходяться в області легень, застосовується метод k-середніх з кількістю кластерів  $k = 3$ , що проводиться їх кластеризація за значенням інтенсивності.

У межах даного експерименту як потенційну область ураження було обрано два найсвітліші кластери. Ділянки ураження інфекцією на рентген-зображеннях частіше проявляються як області з підвищеною яскравістю [44]. Варто зазначити, що область патологічних змін може знаходитися у найсвітлішому та у проміжному кластері. Відповідно, об'єднання двох світліших кластерів дозволяє зберегти більшу частину потенційної зони ураження. Кількість кластерів та кількість обраних світліших кластерів є налаштовуваними параметрами методу.

Оцінювання якості сегментації виконується відносно еталонної маски області ураження. Для аналізу використано коефіцієнт Dice, Precision, Recall,

а також частку зображень, для яких значення Dice перевищує 0.8 та 0.6. Результати аналізу наведено в табл. 3.19. Валідаційна вибірка вказана у таблиці як val, тестова — test.

Таблиця 3.19

### Результати сегментації області ураження методом k-середніх

| Вибірка | Dice $\geq 0.8$ , % | Dice $\geq 0.6$ , % | Dice              | Precision         | Recall            |
|---------|---------------------|---------------------|-------------------|-------------------|-------------------|
| val     | 22.53               | 65.24               | $0.632 \pm 0.201$ | $0.612 \pm 0.293$ | $0.798 \pm 0.130$ |
| test    | 22.13               | 63.46               | $0.628 \pm 0.212$ | $0.608 \pm 0.299$ | $0.803 \pm 0.128$ |

Отримані результати показують, що метод k-середніх забезпечує близькі значення показників якості на валідаційній та тестовій вибірках. На валідаційній вибірці середнє значення Dice становить  $0.632 \pm 0.201$ , на тестовій —  $0.628 \pm 0.212$ . Частка зображень з Dice не менше 0.6 становить 65.24% для валідаційної вибірки та 63.46% для тестової вибірки.

Значення Recall становить  $0.803 \pm 0.128$  на тестовій вибірці та  $0.798 \pm 0.130$  на валідаційній, що вказує на здатність методу k-середніх охоплювати значну частину еталонної області ураження. Значення Precision є нижчим і становить  $0.608 \pm 0.299$  на тестовій вибірці та  $0.612 \pm 0.293$  на валідаційній. Це вказує на те, що сформована сегментація є занадто розширеною та може включати надлишкові ділянки.

Порівняно з нейромережовим підходом, розглянутим у попередньому розділі, метод k-середніх поступається за точністю формування кінцевої маски. У розділі 3.7 для моделі ResNet18-UNet з попереднім обмеженням рентгенівського зображення маскою легень було отримано Dice  $0.799 \pm 0.193$ . У роботі [45] для вказаного датасету COVID-QU-Ex [77] було отримано  $Dice = 0.771$ . Для методу k-середніх на тестовій вибірці Dice становить  $0.628 \pm 0.212$ . Відповідно, значення Dice є меншим ніж на 0.2 від нейромережових підходів, що є відносно прийнятним результатом для методу без навчання нейромереж.


Узагальнюючи отримані результати, можна сказати, що метод k-середніх може бути використаний як допоміжний інструмент для попереднього виділення області ураження інфекцією.

### 3.8. Застосування класичних методів сегментації до КТ-зображень легень

У даному розділі досліджено можливість застосування класичних методів сегментації для аналізу КТ-зображень легень. На відміну від рентгівських зображень грудної клітини, КТ-зображення відображають легені у вигляді окремих зрізів. Відповідно, під час обробки таких зображень простіше аналізувати форму легень і область ураження інфекцією, що є важливим для задачі сегментації [82].

У дослідженні розглядаються дані з датасету COVID-19 CT Lung and Infection Segmentation Dataset [83], що містить КТ-зображення пацієнтів із COVID-19 та еталонні маски легень і зон ураження інфекцією. У якості робочої вибірки було використано версію даного датасету, яка містить зображення у форматі PNG та розміщена на платформі Kaggle [84].

На рис. 3.19 наведено приклад вхідного КТ-зображення.



(а) Оригінальне зображення

Рис. 3.19: Приклад КТ-зображення та відповідних еталонних масок.

Для виділення області легень було застосовано пороговий метод Оцу, що розглядався у попередніх розділах. Додатково було проведено проце-

дуру морфологічної обробки за принципом, який описаний у розділі 3.5. Виконується видалення малих зв'язаних компонент, які дотичні до меж зображення або розташовані на відстані до 3 px від них. Після цього застосовується морфологічна дилатація з еліптичним структурним елементом розміром  $7 \times 7$  та відбір двох найбільших зв'язаних компонентів маски. На завершальному етапі виконується заповнення внутрішніх порожнин у межах отриманої бінарної маски.

Для виділення області інфекції було застосовано алгоритм  $k$ -середніх у межах попередньо виділеної області легень. У даному випадку пікселі КТ-зображення, що належать до сформованої маски легень, групуються за значеннями інтенсивності на три кластери. Подібний кластеризаційний підхід було використано в роботі [58]. Проте у даній розглянутій роботі алгоритм  $k$ -середніх застосовувався до всього КТ зображення для виділення області інтересу, пов'язаної з зоною ураження легень на КТ-зображеннях.

У даному дослідженні кластеризація застосовується в межах попередньо сформованої області легень за допомогою методу Оцу. Для формування маски області інфекції було використано середній за інтенсивністю кластер, що відповідає характеристикам ураженої інфекцією області на розглянутому КТ-зображенні. Даний вибір пов'язаний з тим, що на КТ-зображеннях область ураження COVID-19 характеризується зонами типу “матового скла” [85].

Після цього застосовується морфологічне замикання з еліптичним структурним елементом розміром  $5 \times 5$  з метою зменшення дрібних розривів у межах знайденої області інфекції.

Результати застосування розглянутого методу сегментації наведено на рис. 3.20. Додатково наведено еталонну маску легень та еталонну маски області інфекції для даного вхідного зображення.

Для кількісного оцінювання результатів було використано коефіцієнт Dice, IoU, Precision та Recall. Значення показників наведено в табл. 3.20.




Рис. 3.20: Приклад застосування класичних методів сегментації до КТ-зображення легень.

Таблиця 3.20

**Показники сегментації для КТ-зображення**

| Сегментація      | Метод               | Dice   | IoU    | Precision | Recall |
|------------------|---------------------|--------|--------|-----------|--------|
| Область легень   | Оцу                 | 0.9597 | 0.9226 | 0.9231    | 0.9994 |
| Область ураження | Оцу + $k$ -середніх | 0.8993 | 0.8170 | 0.8762    | 0.9236 |
| Область ураження | $k$ -середніх       | 0.7867 | 0.6484 | 0.7546    | 0.8216 |

Отримані результати показують, що метод Оцу з морфологічною постобробкою забезпечив точне виділення області легень на розглянутому КТ-зображенні. Значення Dice для маски легень становило 0.9597, Recall — 0.9994, що характеризує повне покриття еталонної області легень.

Для виділення області ураження було порівняно два способи застосування алгоритму  $k$ -середніх. У даному дослідженні метод Оцу використовується для попереднього формування області легень, у межах якої виконується кластеризація пікселів за інтенсивністю. Для порівняння реалізовано підхід за аналогією з роботою [58], у якому алгоритм  $k$ -середніх застосовується до всього КТ-зображення. Для формування маски області інфекції використовується середній за інтенсивністю кластер.

Результати аналізу показують, що обмеження кластеризації попередньо виділеною областю легень дає кращий результат. Для запропонованого способу знаходження області інфекції з обмеженням маскою легень значення Dice становить 0.8993, IoU — 0.8170, Precision — 0.8762, Recall — 0.9236. Для кластеризації всього КТ-зображення з використанням середнього кластера значення Dice становить 0.7867, IoU — 0.6484, Precision — 0.7546, Recall — 0.8216. Відповідно, попереднє формування області легень зменшує вплив фонових зон на результат кластеризації та підвищує якість виділення області ураження.

Отримані результати показують, що класичні методи сегментації можуть бути застосовані до КТ-зображень легень. У розглянутому прикладі метод Оцу забезпечив високе перекриття з еталонною маскою легень, що дозволяє досить точно виділити область легень на КТ-зображенні. Застосування алгоритму  $k$ -середніх дає змогу виділити з відносно прийнятною точністю область, що за інтенсивністю відповідає зоні ураження інфекцією.

### Висновки до розділу 3

У даному розділі проведено експериментальні дослідження методів класифікації та сегментації рентген-зображень грудної клітини. Додатково було проведено аналіз КТ-зображень грудної клітини. За результатами проведених експериментів сформульовано наступні висновки:

- Для класифікації рентген-зображень грудної клітини за трьома класами: COVID-19, пневмонія та відсутність захворювання, було застосовано згорткову нейронну мережу. За результатами чотирикратної крос-валідації отримано середню точність класифікації 95.35%.
- Дослідження впливу попередньої обробки показало, що найкращі результати класифікації отримано при використанні CLANE. У цьому випадку точність класифікації становила 97.22%, що вище порівняно з оригінальними зображеннями, фільтром Гауса та медіанною фільтрацією.
- Для сегментації області легень було досліджено порогові методи Оцу, Капура та модифікований метод ВНТ.
- Проведено аналіз анатомічно орієнтованих показників сегментації: відносної площі, вертикальної симетрії, стандартного відхилення інтенсивності сегментованої області та контрасту.
- На основі анатомічно орієнтованих показників запропоновано підхід вибору результату сегментації за інтегральним показником. Даний підхід дозволяє автоматично обирати найбільш узгоджений з анатомічними характеристиками результат порогоування.
- Для сегментації області ураження інфекцією було застосовано нейромережеву модель U-Net з енкодером ResNet18. Найкращий результат отримано для експерименту, у якому на вхід моделі подавалося оригінальне рентгенівське зображення, що було обмежене маскою області легень. Це підтверджує доцільність використання

анатомічної інформації у даній задачі.

- Додатково досліджено застосування методу k-середніх для попереднього виділення області ураження в межах області легень. Метод не потребує навчання моделі та показує достатньо високе значення Recall, що дає можливість застосовувати його як простий інструмент для попереднього виділення області з інфекцією.

Таким чином, у даному розділі показано, що поєднання класичних методів обробки зображень, анатомічно орієнтованих показників та нейромережових підходів дозволяє розв'язувати задачі класифікації, сегментації області легень та сегментації області ураження на рентгенівських зображеннях грудної клітини. Окремі складові запропонованого підходу можуть бути адаптовані для аналізу КТ-зображень грудної клітини. Отримані результати підтверджують доцільність використання запропонованих методів як складових моделі системного аналізу процесу обробки медичних зображень та інформаційної технології підтримки прийняття рішень для автоматизованого аналізу медичних зображень грудної клітини.

## РОЗДІЛ 4

### ПРОГРАМНА РЕАЛІЗАЦІЯ

Основні експериментальні дослідження з наборами даних та навчання неймереж виконувалися в середовищі Kaggle Notebooks [86]. Даний підхід також дозволяє використовувати датасети, що розміщені на платформі Kaggle, без додаткової підготовки чи завантаження. Для демонстрації роботи програмного комплексу та реалізованих методів було створено вебзастосунок на платформі Hugging Face Spaces [87], що дозволяє запускати рішення без локального встановлення та налаштування. Для побудови інтерактивного інтерфейсу завантаження зображень, вибору методу сегментації та відображення результатів використано бібліотеку Gradio [88].

Розроблений програмний комплекс складається з чотирьох основних складових, що відповідають задачам автоматизованого аналізу медичних зображень грудної клітини:

- складова сегментації області легень на рентген-зображеннях грудної клітини на основі порогових методів та автоматичного вибору результату сегментації за інтегральним анатомічно орієнтованим показником;
- складова сегментації області ураження інфекцією на рентгенівських зображеннях грудної клітини за допомогою неймережевої моделі U-Net з енкодером ResNet18;
- складова сегментації області ураження інфекцією за допомогою методу  $k$ -середніх на рентгенівських зображеннях та КТ-зображеннях грудної клітини;
- складова класифікації рентген-зображень грудної клітини за трьома класами: COVID-19, пневмонія та відсутність захворювання.

#### 4.1. Сегментація області легень

У даному розділі наведено опис додатку для сегментації області легень на рентген-зображеннях грудної клітини. Програма дає змогу завантажити вхідне зображення, обрати метод сегментації, застосувати попередню обробку та морфологічну постобробку, переглянути отриману маску і раховані показники.

Реалізовано порогові методи сегментації Оцу, Капура та модифікований метод ВНТ. Додатково реалізовано метод автоматичного вибору результату на основі інтегрального анатомічно орієнтованого показника за коефіцієнтами відносної площі, вертикальної симетрії та стандартного відхилення інтенсивності (STD) сегментованої області.

На рис. 4.1 наведено загальний вигляд додатку для сегментації області легень.

Інтерфейс містить поле для завантаження рентген-зображення, параметри використання CLANE і морфологічної постобробки, поле вибору методу сегментації та кнопку запуску обробки.

На рис. 4.2 наведено приклад завантаженого зображення в систему.

На рис. 4.3 наведено блок розширених налаштувань попередньої обробки та морфологічної постобробки.

У даному блоці задаються параметри CLANE, зокрема параметр підсилення локального контрасту та розмір сітки (у пікселях), за якою зображення поділяється на локальні області підсилення контрасту.

Реалізовано налаштування параметрів ядра ерозії та ядра дилатації у пікселях, порогу площі для видалення граничних компонент (у відсотках від всього зображення), відстані від границі зображення (у пікселях) для видалення граничних компонент та кількості найбільших компонент, що залишаються.

На рис. 4.4 наведено блок налаштування параметрів комбінованого ме-

Додаток виконує порогову сегментацію області легень на рентген-зображеннях грудної клітини методами Оцу, Капура, модифікованим методом ВНТ або комбінованим методом.

Selector використовує анатомічно орієнтовані показники: відносну площу, вертикальну симетрію та STD інтенсивності сегментованої області.

☒ Вхідне рентген-зображення



Перетягніть зображення сюди  
- або -  
Натисніть, щоб завантажити



Метод сегментації

☒ Selector ☐ Otsu ☐ Kapur ☐ ВНТ

☒ Використати CLANE ☒ Використати морфологічну постобробку

Запустити сегментацію

Рис. 4.1: Загальний вигляд додатку для сегментації області легень.



Рис. 4.2: Приклад зображення в системі.

Розширені налаштування

Попередня обробка

Обмеження контрасту CLAHE 2 ↺

0.5 ————— 5

Розмір сітки CLAHE 8 ↺

4 ————— 16

Морфологічна постобробка

Ядро ерозії 5 ↺

1 ————— 31

Ядро дилатації 7 ↺

1 ————— 31

Поріг площі для видалення граничних компонент 0,2 ↺

0.01 ————— 0.5

Відстань від границі зображення для видалення граничних компонент 10 ↺

1 ————— 50

Кількість найбільших компонент, що залишаються 2 ↺

1 ————— 5

Прозорість накладання маски 0,35 ↺

0.1 ————— 0.8

Рис. 4.3: Розширені налаштування попередньої обробки та морфологічної постобробки.

тоду порогоування (селектора).




Рис. 4.4: Розширені налаштування параметрів селектора.

В інтерфейсі присутня можливість зміни еталонну відносну площу, еталонну вертикальну симетрію, еталонне стандартне відхилення інтенсивності сегментованої області, ваги площі, симетрії та стандартного відхилення інтенсивності. Дані значення використовуються для обчислення інтегрального показника і вибору результату сегментації порогового методу.

На рис. 4.5 наведено приклад візуальних результатів аналізу зображень за допомогою додатку.

У даному інтерфейсі відображаються зображення після попередньої обробки та отримана сегментація після застосування порогового методу.

На рис. 4.6 наведено приклад подальшого аналізу зображень за допомогою додатку.

В інтерфейсі відображається фінальна маска після морфологічної постобробки та накладання маски на вихідне рентген-зображення.

На рис. 4.7 та рис. 4.8 наведені значення показників у вигляді таблиці, розрахованих для кожного методу сегментації.

## Візуальні результати




Рис. 4.5: Результати сегментації області легень.




Рис. 4.6: Фінальні результати сегментації області легень.


У таблиці подано значення порогу, відносної площі, вертикальної симетрії, стандартного відхилення інтенсивності сегментованої області, контрасту, часткових анатомічно орієнтованих оцінок та інтегрального показника.

### Показники

Порівняння методів

| Метод | Поріг | Відносна площа | Верт. симетрія | STD інтенс. сегмент. |
|-------|-------|----------------|----------------|----------------------|
| Otsu  | 123   | 0.1798         | 0.8409         | 23.2181              |
| Карни | 126   | 0.1832         | 0.8398         | 23.7663              |
| ВНТ   | 163   | 0.2904         | 0.9843         | 36.8829              |

Рис. 4.7: Таблиця значень анатомічно орієнтованих показників сегментації.



| Контраст | Оцінка площі | Оцінка симетрії | Оцінка STD | Інтегр. показник |
|----------|--------------|-----------------|------------|------------------|
| 70.9308  | 0.7192       | 0.914           | 0.8026     | 0.8138           |
| 70.2695  | 0.7329       | 0.9128          | 0.8215     | 0.8226           |
| 49.0019  | 0.8383       | 0.9301          | 0.7251     | 0.8524           |

Рис. 4.8: Таблиця значень анатомічно орієнтованих показників сегментації (продовження).

На рис. 4.9 наведено розширений перелік показників результату сегментації.

У даному блоці наведено обраний метод, значення порогу, статус використання CLANE та морфологічної постобробки, параметри селектора і анатомічно орієнтовані показники для отриманої сегментованої області легень.

### Результат сегментації

Обраний метод: **ВНТ**

Поріг: **163**

CLAHE: **увімкнено**

Морфологічна постобробка: **увімкнено**

### Параметри селектора

Еталонна відносна площа: **0.2500**

Еталонна вертикальна симетрія: **0.9200**

Еталонне STD інтенсивності сегментованої області: **28.9300**

Вага площі: **0.40**

Вага симетрії: **0.40**

Вага STD: **0.20**

### Анатомічно орієнтовані показники для отриманої маски

Відносна площа: **0.2904**

Вертикальна симетрія: **0.9843**

STD інтенсивності сегментованої області: **36.8829**

Контраст: **49.0019**


Інтегральний показник: **0.8524**

Рис. 4.9: Розширений перелік показників сегментації.

## 4.2. Сегментація області ураження інфекцією за допомогою нейронних мереж

У даному розділі наведено опис функціоналу для сегментації області ураження на рентген-зображеннях грудної клітини класу COVID-19. Програма отримує на вхід вхідне рентген-зображення та маску області легень (опціонально) та дозволяє виконати сегментацію за допомогою нейромережі U-Net з енкодером ResNet18, переглянути ймовірнісну карту, отриману маску та накладання маски на початкове зображення.

Приклад вхідних даних, що використовуються для сегментації області ураження, наведено на рис. 4.10.



(а) Оригінальне зображення (б) Бінарна маска області легень (в) Бінарна маска області ураження

Рис. 4.10: Приклад зображення з датасету.

На рис. 4.11 наведено загальний початковий вигляд додатку для сегментації області ураження.

Загальний інтерфейс містить поле для завантаження рентген-зображення, поле для завантаження маски області легень та кнопку запуску обробки.

Реалізовано два режими роботи. За відсутності маски області легень сегментація виконується виключно за вхідним рентгеновським зображенням. Якщо користувач додатково завантажує маску області легень, то формується зображення, обмежене границями даної області. Отримане зображення подається на вхід нейромережі для сегментації області ураження.

Сегментація області ураження на рентген-зображеннях грудної клітини класу COVID-19




Рис. 4.11: Загальний вигляд додатку для сегментації області ураження.

На рис. 4.12 наведено приклад результатів сегментації без використання завантаженої маски легень.

У даному режимі сегментація виконується за початковим рентгеновським зображенням. В інтерфейсі відображаються зображення, ймовірнісна карта області ураження, маска-прогноз та накладання отриманої маски на рентген-зображення.




Рис. 4.12: Результати сегментації області ураження без використання маски легень.

На рис. 4.13 наведено приклад результатів сегментації з використанням маски області легень.

У цьому режимі додатково використовується маска області легень, на

основі якої формується зображення, обмежене межами легеневої області. Це дає змогу зменшити вплив ділянок за межами легень під час формування результату сегментації.




Рис. 4.13: Результати сегментації області ураження з використанням маски легень.

Порівняння рис. 4.12 та рис. 4.13 з урахуванням еталонної розмітки, що відображена на рис. 4.10, показує відмінність між режимами роботи додатку. Без використання маски області легень нейромережа аналізує все рентген-зображення. Відповідно, у фінальній масці області інфекції можуть з'являтися зайві ділянки за межами області легень. У режимі з маскою області легень результат додатково уточнюється анатомічними межами легень.

На рис. 4.14 наведено значення показників результату сегментації.

У даному блоці відображаються режим використаної моделі, частка маски-прогнозу, частка фінальної маски та назва нейромережевої моделі.




Рис. 4.14: Показники результату сегментації області ураження.

### 4.3. Сегментація області ураження інфекцією на рентгенівських зображеннях за допомогою методу кластеризації k-середніх

У даному розділі наведено опис функціоналу для сегментації області ураження на рентгенівських зображеннях грудної клітини за допомогою методу k-середніх. На етапі застосування алгоритму виконується кластеризація за інтенсивністю у межах області легень.

На рис. 4.15 наведено загальний вигляд додатку для сегментації області ураження за допомогою методу k-середніх.

Інтерфейс містить поле для завантаження рентген-зображення, поле для завантаження маски області легень, блок додаткових параметрів та кнопку запуску обробки.

На рис. 4.16 наведено блок додаткових параметрів методу k-середніх.

У даному блоці задається кількість кластерів, кількість найсвітліших кластерів, що використовуються для формування маски області ураження інфекцією, параметр видалення малих компонент за площею та прозорість накладання маски на рентген-зображення. Кластеризація виконується в межах маски області легень.

На рис. 4.17 наведено приклад результатів сегментації області ураження за допомогою методу k-середніх.

У даному інтерфейсі відображаються зображення, обмежене маскою

### Сегментація області ураження на рентген-зображеннях грудної клітини за допомогою методу k-середніх




Рис. 4.15: Загальний вигляд додатку для сегментації області ураження за допомогою методу k-середніх.




Рис. 4.16: Додаткові параметри сегментації області ураження за допомогою методу k-середніх.

легень, карта кластерів, бінарна маска області ураження та накладання отриманої маски на початкове рентген-зображення.



Рис. 4.17: Результати сегментації області ураження за допомогою методу k-середніх.

На рис. 4.18 наведено блок показників результату сегментації.

У даному блоці відображаються кількість кластерів, кількість найсвітліших кластерів, використаних для формування маски, та частка отриманої маски у відсотках від площі зображення.




Рис. 4.18: Показники результату сегментації області ураження за допомогою методу k-середніх.

#### 4.4. Сегментація області ураження на КТ-зображеннях за допомогою методу кластеризації $k$ -середніх

У даному розділі наведено опис частини програмної системи для сегментації області ураження на КТ-зображеннях за допомогою методу  $k$ -середніх. Маска області легень формується автоматично за методом Оцу. Кластеризація з метою знаходження області інфекції виконується в межах отриманої маски легень.

На рис. 4.19 наведено загальний вигляд інтерфейсу для сегментації області ураження на КТ-зображеннях.

Інтерфейс містить поле для завантаження КТ-зображення, параметри морфологічної обробки та кнопку запуску сегментації. Для формування маски легень використовується метод Оцу, після чого в межах отриманої області застосовується метод  $k$ -середніх з кількістю кластерів  $K = 3$ . Для побудови маски області ураження використовується середній за інтенсивністю кластер.

У блоці параметрів наявні наступні налаштування: розмір ядра дилатації маски легень, розмір ядра морфологічного замикання маски ураження та прозорість накладання отриманої маски на КТ-зображення. Зміна розміру ядра морфологічного замикання дає змогу регулювати ступінь згладжування та об'єднання фрагментів маски ураження, які близько розташовані один від одного.

На рис. 4.20 наведено приклад сформованих масок після застосування методу Оцу та  $k$ -середніх.

У результаті роботи програми відображається маска легень, сформована методом Оцу, бінарна маска області ураження та накладання отриманої маски на початкове КТ-зображення.

На рис. 4.21 наведено приклад накладання маски області ураження на КТ-зображення та блок показників результату сегментації.

## Сегментація області ураження на КТ-зображеннях

Метод формує маску легень за методом Оцу та застосовує  $k$ -середніх у межах отриманої маски.  $K = 3$ . Для маски ураження




Рис. 4.19: Загальний вигляд інтерфейсу для сегментації області ураження на КТ-зображеннях.




Рис. 4.20: Маска легень за методом Оцу та маска області ураження, отримана за допомогою методу k-середніх.




Рис. 4.21: Накладання маски області ураження на КТ-зображення та показники результату сегментації.

У блоці показників відображаються центри трьох кластерів, отриманих методом k-середніх, кількість пікселів у масці легень, кількість пікселів у масці області ураження та відносна площа ураження в межах маски легень. Дані показники використовуються для кількісного опису отриманого результату та контролю роботи алгоритму на КТ-зображенні.

#### 4.5. Класифікація рентген-зображень грудної клітини

У даному розділі наведено опис додатку для класифікації рентген-зображень грудної клітини за допомогою згорткової нейронної мережі для трьох класів: COVID-19, пневмонія та норма. Програма дає змогу завантажити вхідне рентген-зображення, виконати класифікацію та отримати значення ймовірності класифікації.

На рис. 4.22 наведено загальний вигляд додатку для класифікації рентген-зображень грудної клітини.




Рис. 4.22: Загальний вигляд додатку для класифікації рентген-зображень грудної клітини.

Інтерфейс містить поле для завантаження рентген-зображення та кнопку запуску процесу класифікації. Вхідне зображення приводиться до роз-

міру входу моделі та нормалізується за значеннями інтенсивності пікселів. Після цього зображення подається до згорткової нейронної мережі, яка формує ймовірності належності до кожного з класів. Архітектура застосованої нейронної мережі наведена у попередніх розділах.

На рис. 4.23 наведено приклад результату класифікації рентген-зображення грудної клітини.

У даному блоці відображається прогнозований клас зображення та значення ймовірностей для кожного з трьох класів.




Рис. 4.23: Приклад результату класифікації рентген-зображення грудної клітини.

## Висновки до розділу 4

У даному розділі наведено складові розробленого програмного комплексу для обробки рентгенівських зображень грудної клітини. За результатами реалізації сформульовано наступні висновки:

- Для виконання експериментальних досліджень, навчання нейромережних моделей та роботи з наборами даних було використано середовище Kaggle Notebooks. Дане хмарне рішення спрощує доступ до датасетів та дозволяє виконувати обчислення без локального налаштування середовища, що прискорює перевірку застосованих методів.
- Для демонстрації розроблених методів було використано платформу Hugging Face Spaces, що дає змогу реалізувати інтерфейси програмного комплексу без потреби локального встановлення програмного забезпечення.
- Для побудови інтерфейсів програмного комплексу застосовано бібліотеку Gradio. Стандартні компоненти даної бібліотеки дають змогу реалізувати завантаження рентгенівських зображень, вибір параметрів обробки, запуск алгоритмів та відображення результатів у вигляді зображень, таблиць і текстових показників.
- Реалізовано функціонал для сегментації області легень на основі порогових методів Оцу, Капура, модифікованого ВНТ та автоматичного вибору результату за інтегральним анатомічно орієнтованим показником.
- Реалізовано функціонал для сегментації області ураження інфекцією за допомогою нейромережі U-Net з енкодером ResNet18, що може працювати в двох режимах роботи: без використання маски легень та з її використанням як додаткового анатомічного обмеження.
- Додатково реалізовано механізм виділення потенційних ділянок ураження інфекцією за допомогою методу k-середніх. Даний підхід не потребує навчання моделі та виконує кластеризацію пікселів за інтенсивністю в межах області легень.
- Реалізовано функціонал класифікації рентген-зображень грудної клітини за трьома класами: COVID-19, пневмонія та випадки без за-

хворювання.

Розроблена система реалізована у вигляді демонстраційного середовища та поєднує методи сегментації та класифікації рентгенівських зображень грудної клітини, що були розглянуті у даному дослідженні. Додатково реалізовано функціонал для сегментації області легень та області ураження інфекцією на КТ-зображеннях грудної клітини. Система розглядається як програмна складова інформаційної технології підтримки прийняття рішень для автоматизованого аналізу медичних зображень грудної клітини.

## ВИСНОВКИ

У роботі досліджено та розроблено методи обробки, класифікації та сегментації медичних зображень грудної клітини:

- Проаналізовано сучасні підходи до обробки медичних зображень, зокрема методи попередньої обробки, порогової сегментації, кластеризації та нейромережеві моделі для класифікації і сегментації рентген-зображень грудної клітини.
- Досліджено вплив методів попередньої обробки на якість класифікації рентген-зображень. Показано, що адаптивне вирівнювання гістограми з обмеженням контрасту забезпечує кращі результати класифікації порівняно з іншими розглянутими методами попередньої обробки.
- Для задачі сегментації області легень досліджено порогові методи Оцу, Капура та модифікований метод збалансованого порогового відсікання гістограми. Встановлено, що модифікований метод збалансованого порогового відсікання гістограми може забезпечувати більш повне покриття області легень.
- Запропоновано використання анатомічно орієнтованих показників для оцінювання результатів сегментації області легень: відносну площу, вертикальну симетрію та стандартне відхилення інтенсивності сегментованої області.
- Розроблено метод вибору результату сегментації за інтегральним показником на основі анатомічно орієнтованих показників. Даний метод дозволяє автоматично обирати найбільш узгоджену з анатомічними характеристиками маску області легень.
- Для сегментації області ураження інфекцією було застосовано ней-

ромережеву модель U-Net з енкодером ResNet18. Використання зображення, отриманого шляхом обмеження вихідного рентгенівського зображення маскою області легень, допомогло підвищити точність сегментації.

- Досліджено застосування методу k-середніх для попереднього виділення області ураження в межах області легень. Даний метод показав прийнятний рівень якості та не потребує навчання нейромережевої моделі.
- Розроблено програмні засоби для демонстрації основних методів обробки медичних зображень грудної клітини. Реалізована система поєднує сегментацію області легень, сегментацію області ураження інфекцією та класифікацію рентген-зображень.

Отримані результати показують, що поєднання класичних методів обробки зображень, анатомічно орієнтованих показників та нейромережевих моделей є доцільним для аналізу рентген-зображень грудної клітини. Відповідно, попередня обробка, класифікація, сегментація та оцінювання результатів розглядаються у роботі як взаємопов'язані складові системного аналізу процесу обробки медичних зображень. Розроблені методи та програмні засоби можуть бути використані як складові інформаційної технології підтримки прийняття рішень для автоматизованого аналізу медичних зображень грудної клітини.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. V. I. Suchkov and A. O. Pashko, "COVID-19 Computed Tomography Image Processing Based on Statistical Segmentation Methods," in *Abstracts of the XXXIX International Conference "Problems of Decision Making Under Uncertainties" (PDMU-2024)*, Brno, Czech Republic, Sept. 9–10, 2024, pp. 133–134.
2. В. І. Сучков, "Штучний інтелект у сфері охорони здоров'я II Всеукраїнська науково-практична конференція з міжнародною участю "PROКиїв", Київ, Україна, 3–4 грудня 2024, с. 477–479.
3. А. О. Пашко та В. І. Сучков, "Застосування згорткових нейронних мереж для класифікації рентген-знімків легень XIII Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2024, с. 235–239.
4. В. І. Сучков та А. О. Пашко, "Сегментація області легень на рентген-знімках грудної клітини XIV Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2025, с. 346–348.
5. В. І. Сучков та А. О. Пашко, «Згорткова нейронна мережа для класифікації рентген-знімків грудної клітини», *Журнал обчислювальної та прикладної математики*, вип. 2, с. 77–86, Груд. 2025.  
<https://doi.org/10.17721/2706-9699.2025.2.06>
6. А. О. Пашко та В. І. Сучков, «Сегментація легень на рентген-знімках грудної клітини з анатомічно орієнтованою оцінкою», *Наукові праці Вінницького національного технічного університету*, вип. 1, с. 161–171, Бер. 2026.  
<https://doi.org/10.31649/2307-5376-2026-1-161-171>

7. В. І. Сучков, «Методи попереднього оброблення рентген-знімків грудної клітини в задачі класифікації», *Наука, технології, інновації*, вип. 1(37), с. 110–115, 2026.  
<https://doi.org/10.35668/2520-6524-2026-1-11>
8. В. І. Сучков, «Застосування методу збалансованого порогового відсікання гістограми у задачі сегментації легень на рентгенівських зображеннях грудної клітини», *Журнал обчислювальної та прикладної математики*, вип. 1, с. 99–108, Квіт. 2026.  
<https://doi.org/10.17721/2706-9699.2026.1.07>
9. G. Briganti and O. Le Moine, "Artificial intelligence in medicine: today and tomorrow," *Frontiers in Medicine*, vol. 7, article 27, 2020.  
<https://doi.org/10.3389/fmed.2020.00027>
10. Amisha, P. Malik, M. Pathania and V. K. Rathaur, "Overview of artificial intelligence in medicine," *Journal of Family Medicine and Primary Care*, vol. 8, no. 7, pp. 2328–2331, 2019.  
[https://doi.org/10.4103/jfmpe.jfmpe\\_440\\_19](https://doi.org/10.4103/jfmpe.jfmpe_440_19)
11. I. Baltruschat, L. Steinmeister, H. Nickisch, A. Saalbach, M. Grass, T. Knopp and H. Ittrich, "Smart chest X-ray worklist prioritization using artificial intelligence: a clinical workflow simulation," *European Radiology*, vol. 31, pp. 3837–3845, 2021. <https://doi.org/10.1007/s00330-020-07480-7>
12. A. Narin, C. Kaya and Z. Pamuk, "Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks," *Pattern Analysis and Applications*, vol. 24, no. 3, pp. 1207–1220, 2021. <https://doi.org/10.1007/s10044-021-00984-y>
13. J. P. Cohen, P. Morrison, L. Dao, K. Roth, T. Duong and M. Ghassem, "COVID-19 Image Data Collection: Prospective Predictions are the Future," *Journal of Machine Learning for Biomedical Imaging*, vol. 1, pp. 1–38, 2020. <https://doi.org/10.59275/j.melba.2020-48g7>

14. P. Mooney, "Chest X-ray Images (Pneumonia)", Kaggle, 2020. [Электронный ресурс]. Режим доступа: <https://kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>
15. A. I. Khan, J. L. Shah and M. M. Bhat, "CoroNet: A Deep Neural Network for Detection and Diagnosis of COVID-19 from Chest X-ray Images," *Computer Methods and Programs in Biomedicine*, vol. 196, art. no. 105581, 2020. <https://doi.org/10.1016/j.cmpb.2020.105581>
16. A. Chowdhury and H. Zhang, "Radiography Image Classification Using Deep Convolutional Neural Networks," *Journal of Computer and Communications*, vol. 12, pp. 199–209, 2024. <https://doi.org/10.4236/jcc.2024.126012>
17. M. Gour and S. Jain, "Stacked Convolutional Neural Network for Diagnosis of COVID-19 Disease from X-ray Images," *arXiv preprint arXiv:2006.13817*, 2020. <https://arxiv.org/abs/2006.13817>
18. D. S. Kermany et al., "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," *Cell*, vol. 172, no. 5, pp. 1122–1131.e9, 2018. <https://doi.org/10.1016/j.cell.2018.02.010>
19. A. Chung, "Figure 1 COVID-19 Chest X-ray Dataset Initiative", GitHub, 2020. [Электронный ресурс]. Режим доступа: <https://github.com/agchung/Figure1-COVID-chestxray-dataset>
20. L. Wang, Z. Q. Lin and A. Wong, "COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-ray Images," *Scientific Reports*, vol. 10, art. no. 19549, 2020. <https://doi.org/10.1038/s41598-020-76550-z>
21. X. Xu et al., "A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia," *Engineering*, vol. 6, no. 10, pp. 1122–1129, 2020. <https://doi.org/10.1016/j.eng.2020.04.010>
22. M. E. H. Chowdhury et al., "Can AI Help in Screening Viral and COVID-19 Pneumonia?," *IEEE Access*, vol. 8, pp. 132665–132676, 2020.

- <https://doi.org/10.1109/ACCESS.2020.3010287>
23. S. Minaee, R. Kafieh, M. Sonka, S. Yazdani and G. Jamalipour Soufi, "Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning," *Medical Image Analysis*, vol. 65, article 101794, 2020. <https://doi.org/10.1016/j.media.2020.101794>
  24. I. D. Apostolopoulos and T. A. Mpesiana, "Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks," *Physical and Engineering Sciences in Medicine*, vol. 43, no. 2, pp. 635–640, 2020. <https://doi.org/10.1007/s13246-020-00865-4>
  25. Y. J. Kim, "Machine Learning Model Based on Radiomic Features for Differentiation between COVID-19 and Pneumonia on Chest X-ray," *Sensors*, vol. 22, no. 17, article 6709, 2022. <https://doi.org/10.3390/s22176709>
  26. M.-A. Zolya, C. Baltag, D.-V. Bratu, S. Coman and S.-A. Moraru, "COVID-19 detection and diagnosis model on CT scans based on AI techniques," *Bioengineering*, vol. 11, no. 1, article 79, 2024. <https://doi.org/10.3390/bioengineering11010079>
  27. S. Goyal and R. Singh, "Detection and classification of lung diseases for pneumonia and COVID-19 using machine and deep learning techniques," *Journal of Ambient Intelligence and Humanized Computing*, vol. 14, pp. 3239–3259, 2023. <https://doi.org/10.1007/s12652-021-03464-7>
  28. E. M. F. El Houby, "COVID-19 detection from chest X-ray images using transfer learning," *Scientific Reports*, vol. 14, no. 1, article 11639, 2024. <https://doi.org/10.1038/s41598-024-61693-0>
  29. О. Б. Давидько та ін., "Класифікація уражень легень при COVID-19 на основі текстурних ознак та згорткової нейронної мережі", *Біомедична інженерія і технологія*, вип. 6, с. 19–28, 2021. <https://doi.org/10.20535/2617-8974.2021.6.231887>
  30. K. Amuda, A. Wakili, T. Amoo, L. Agbetu, Q. Wang and J. Feng, "Detecting SARS-CoV-2 in CT Scans Using Vision Transformer and

- Graph Neural Network,"*Algorithms*, vol. 18, no. 7, article 413, 2025.  
<https://doi.org/10.3390/a18070413>
31. A. Borakati, A. Perera, J. Johnson and T. Sood, "Diagnostic accuracy of X-ray versus CT in COVID-19: a propensity-matched database study,"*BMJ Open*, vol. 10, no. 11, article e042946, 2020.  
<https://doi.org/10.1136/bmjopen-2020-042946>
  32. M. Loey, F. Smarandache and N. E. M. Khalifa, "Within the lack of chest COVID-19 X-ray dataset: a novel detection model based on GAN and deep transfer learning,"*Symmetry*, vol. 12, no. 4, article 651, 2020.  
<https://doi.org/10.3390/sym12040651>
  33. C. Ortiz-Toro, A. García-Pedrero, M. Lillo-Saavedra and C. Gonzalo-Martín, "Automatic detection of pneumonia in chest X-ray images using textural features,"*Computers in Biology and Medicine*, vol. 145, article 105466, 2022. <https://doi.org/10.1016/j.compbiomed.2022.105466>
  34. O. Ronneberger, P. Fischer and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation,"in *Medical Image Computing and Computer-Assisted Intervention – MICCAI*, pp. 234–241, 2015.  
[https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
  35. S. Din, M. Shoaib and E. Serpedin, "CXR-Seg: A Novel Deep Learning Network for Lung Segmentation from Chest X-Ray Images,"*Bioengineering*, vol. 12, no. 2, article 167, 2025.  
<https://doi.org/10.3390/bioengineering12020167>
  36. S. Jaeger et al., "Two public chest X-ray datasets for computer-aided screening of pulmonary diseases,"*Quantitative Imaging in Medicine and Surgery*, vol. 4, no. 6, pp. 475–477, 2014.  
<https://doi.org/10.3978/j.issn.2223-4292.2014.11.20>
  37. S. Stirenko et al., "Chest X-Ray Analysis of Tuberculosis by Deep Learning with Segmentation and Augmentation,"in *2018 IEEE 38th Internati-*

- onal Conference on Electronics and Nanotechnology*, pp. 422–428, 2018. <https://doi.org/10.1109/ELNANO.2018.8477564>
38. W. Tam, P. Babyn and J. Alirezaie, "Robust lung segmentation in Chest X-ray images using modified U-Net with deeper network and residual blocks," *Computer Methods and Programs in Biomedicine Update*, vol. 8, article 100211, 2025. <https://doi.org/10.1016/j.cmpbup.2025.100211>
  39. Nillmani et al., "Segmentation-Based Classification Deep Learning Model Embedded with Explainable AI for COVID-19 Detection in Chest X-ray Scans," *Diagnostics*, vol. 12, no. 9, article 2132, 2022. <https://doi.org/10.3390/diagnostics12092132>
  40. S. Akter, "Generative AI: A Pix2pix-GAN-Based Machine Learning Approach for Robust and Efficient Lung Segmentation," *arXiv preprint arXiv:2412.10826*, 2024. <https://doi.org/10.48550/arXiv.2412.10826>
  41. T. Rahman et al., "Exploring the Effect of Image Enhancement Techniques on COVID-19 Detection Using Chest X-ray Images," *Computers in Biology and Medicine*, vol. 132, article 104319, 2021. <https://doi.org/10.1016/j.compbiomed.2021.104319>
  42. N. Paluru et al., "Anam-Net: Anamorphic Depth Embedding-Based Lightweight CNN for Segmentation of Anomalies in COVID-19 Chest CT Images," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 32, no. 3, pp. 932–946, 2021. <https://doi.org/10.1109/TNNLS.2021.3054746>
  43. D.-P. Fan et al., "Inf-Net: Automatic COVID-19 Lung Infection Segmentation From CT Images," *IEEE Transactions on Medical Imaging*, vol. 39, no. 8, pp. 2626–2637, 2020. <https://doi.org/10.1109/TMI.2020.2996645>
  44. A. M. Tahir et al., "COVID-19 Infection Localization and Severity Grading from Chest X-ray Images," *Computers in Biology and Medicine*, vol. 139, article 105002, 2021. <https://doi.org/10.1016/j.compbiomed.2021.105002>

45. Z. He, A. N. N. Wong and J. S. Yoo, "Co-ERA-Net: Co-Supervision and Enhanced Region Attention for Accurate Segmentation in COVID-19 Chest Infection Images," *Bioengineering*, vol. 10, no. 8, article 928, 2023. <https://doi.org/10.3390/bioengineering10080928>
46. G. Yue, C. Yang, Z. Zhao, Z. An and Y. Yang, "ERGPNet: lesion segmentation network for COVID-19 chest X-ray images based on embedded residual convolution and global perception," *Frontiers in Physiology*, vol. 14, article 1296185, 2023. <https://doi.org/10.3389/fphys.2023.1296185>
47. Z. Xue, F. Yang, S. Rajaraman, G. Zamzmi and S. Antani, "Cross Dataset Analysis of Domain Shift in CXR Lung Region Detection," *Diagnostics*, vol. 13, no. 6, article 1068, 2023. <https://doi.org/10.3390/diagnostics13061068>
48. S. Rajaraman, F. Yang, G. Zamzmi, Z. Xue and S. Antani, "Generalizability of Deep Adult Lung Segmentation Models to the Pediatric Population: A Retrospective Study," *CoRR*, abs/2211.02475, 2022. <https://doi.org/10.48550/arXiv.2211.02475>
49. Y. Xu, R. Quan, W. Xu, Y. Huang, X. Chen and F. Liu, "Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches," *Bioengineering*, vol. 11, no. 10, art. no. 1034, 2024. <https://doi.org/10.3390/bioengineering11101034>
50. D. A. Vital, B. T. Sais and M. C. Moraes, "Robust Pulmonary Segmentation for Chest Radiography, Combining Enhancement, Adaptive Morphology and Innovative Active Contours," *Research on Biomedical Engineering*, vol. 34, no. 3, pp. 234–245, 2018. <https://doi.org/10.1590/2446-4740.180035>
51. J. Murillo-Olmos et al., "Thresholding Algorithm Applied to Chest X-Ray Images with Pneumonia," in *Metaheuristics in Machine Learning: Theory and Applications*, vol. 967, pp. 359–407, 2021. [https://doi.org/10.1007/978-3-030-70542-8\\_16](https://doi.org/10.1007/978-3-030-70542-8_16)
52. S. Azam et al., "An Automated Broncho-Arterial (BA) Pair Segmentation

- Process and Assessment of BA Ratios in Children with Bronchiectasis Using Lung HRCT Scans: A Pilot Study," *Biomedicines*, vol. 11, no. 7, article 1874, 2023. <https://doi.org/10.3390/biomedicines11071874>
53. N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62–66, 1979. <https://doi.org/10.1109/TSMC.1979.4310076>
  54. V. Rajinikanth et al., "Harmony-search and Otsu based system for coronavirus disease (COVID-19) detection using lung CT scan images," *arXiv preprint arXiv:2004.03431*, 2020. <https://doi.org/10.48550/arXiv.2004.03431>
  55. J. N. Kapur, P. K. Sahoo and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Computer Vision, Graphics, and Image Processing*, vol. 29, no. 3, pp. 273–285, 1985. [https://doi.org/10.1016/0734-189X\(85\)90125-2](https://doi.org/10.1016/0734-189X(85)90125-2)
  56. Y. Han, W. Chen, A. A. Heidari, M. Wang and H. Chen, "Multi-verse Optimizer with Rosenbrock and Diffusion Mechanisms for Multi-level Threshold Image Segmentation from COVID-19 Chest X-Ray Images," *Journal of Bionic Engineering*, vol. 20, pp. 1198–1262, 2023. <https://doi.org/10.1007/s42235-022-00295-w>
  57. A. Sharafeldeen, M. Elsharkawy, N. S. Alghamdi, A. Soliman and A. El-Baz, "Precise Segmentation of COVID-19 Infected Lung from CT Images Based on Adaptive First-Order Appearance Model with Morphological/Anatomical Constraints," *Sensors*, vol. 21, no. 16, article 5482, 2021. <https://doi.org/10.3390/s21165482>
  58. B. Guhan, L. Almutairi, S. Sowmiya et al., "Automated system for classification of COVID-19 infection from lung CT images based on machine learning and deep learning techniques," *Scientific Reports*, vol. 12, article no. 17417, 2022. <https://doi.org/10.1038/s41598-022-20804-5>
  59. R. Kumari, N. Gupta and N. Kumar, "Segmentation of Covid-19 Affected

- X-Ray Image using K-means and DPSO Algorithm,"*International Journal of Mathematical, Engineering and Management Sciences*, vol. 6, no. 5, pp. 1255–1275, 2021. <https://doi.org/10.33889/IJMEMS.2021.6.5.076>
60. R. Biondi et al., "Classification Performance for COVID Patient Prognosis from Automatic AI Segmentation—A Single-Center Study,"*Applied Sciences*, vol. 11, no. 12, article 5438, 2021. <https://doi.org/10.3390/app11125438>
  61. V. Thamilarasi, A. Asaithambi and R. Roselin, "Enhanced Ensemble Segmentation of Lung Chest X-Ray Images by Denoising Autoencoder and CLAHE,"*ICTACT Journal on Image and Video Processing*, vol. 15, no. 3, pp. 3501–3508, 2025. <https://doi.org/10.21917/ijivp.2025.0496>
  62. S. K. Panigrahi and S. Gupta, "Automatic Ranking of Image Thresholding Techniques Using Consensus of Ground Truth,"*Traitement du Signal*, vol. 35, no. 2, pp. 121–136, 2018. <https://doi.org/10.3166/ts.35.121-136>
  63. S. Candemir et al., "Lung Segmentation in Chest Radiographs Using Anatomical Atlases With Nonrigid Registration,"*IEEE Transactions on Medical Imaging*, vol. 33, no. 2, pp. 577–590, 2014. <https://doi.org/10.1109/TMI.2013.2290491>
  64. V. Bosdelekidis and N. S. Ioakeimidis, "Lung Field Segmentation in Chest X-rays: A Deformation-Tolerant Procedure Based on the Approximation of Rib Cage Seed Points,"*Applied Sciences*, vol. 10, no. 18, article 6264, 2020. <https://doi.org/10.3390/app10186264>
  65. K. Dwivedi et al., "External validation, radiological evaluation, and development of deep learning automatic lung segmentation in contrast-enhanced chest CT,"*European Radiology*, vol. 34, no. 4, pp. 2727–2737, 2024. <https://doi.org/10.1007/s00330-023-10235-9>
  66. N. Gaggion et al., "Improving anatomical plausibility in medical image segmentation via hybrid graph neural networks: applications to chest x-ray analysis,"*IEEE Transactions on Medical Imaging*, 2022.

- <https://doi.org/10.1109/TMI.2022.3224660>
67. T. Kohlberger, V. Singh, C. Alvino, C. Bahlmann and L. Grady, "Evaluating Segmentation Error Without Ground Truth," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2012*, vol. 7510, pp. 528–536, 2012. [https://doi.org/10.1007/978-3-642-33415-3\\_65](https://doi.org/10.1007/978-3-642-33415-3_65)
  68. M. Cosarinsky et al., "ConfIC-RCA: Statistically Grounded Efficient Estimation of Segmentation Quality," *arXiv*, arXiv:2503.04522, 2026. <https://doi.org/10.48550/arXiv.2503.04522>
  69. D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," 2014. <https://doi.org/10.48550/arXiv.1412.6980>
  70. L. Prechelt, "Early Stopping — But When?," in *Neural Networks: Tricks of the Trade*, Springer, 1998. [https://doi.org/10.1007/3-540-49430-8\\_3](https://doi.org/10.1007/3-540-49430-8_3)
  71. R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 4th ed. Pearson, 2018.
  72. F. L. Alt, M. Rubinoff and M. C. Yovits, "Advances in Computers," *Academic Press*, vol. 32, pp. 111–113, 1991.
  73. A. Anjos and H. Shahbazkia, "Bi-level image thresholding – a fast method," in *Proceedings of the International Conference on Bio-inspired Systems and Signal Processing*, vol. 2, pp. 70–76, 2008. <https://doi.org/10.5220/0001064300700076>
  74. Z. Wang, A. C. Bovik, H. R. Sheikh and E. P. Simoncelli, "Image Quality Assessment: From Error Visibility to Structural Similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, 2004. <https://doi.org/10.1109/TIP.2003.819861>
  75. O. Russakovsky et al., "ImageNet Large Scale Visual Recognition Challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211–252, 2015. <https://doi.org/10.1007/s11263-015-0816-y>
  76. K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conference on Computer Vision and Pattern*

- Recognition*, pp. 770–778, 2016. <https://doi.org/10.1109/CVPR.2016.90>
77. A. M. Tahir et al., "COVID-QU-Ex Dataset," Kaggle, 2021. <https://doi.org/10.34740/kaggle/dsv/3122958>
  78. A. Degerli et al., "COVID-19 Infection Map Generation and Detection from Chest X-ray Images," *Health Information Science and Systems*, vol. 9, article 15, 2021. <https://doi.org/10.1007/s13755-021-00146-8>
  79. K. Zuiderveld, "Contrast Limited Adaptive Histogram Equalization," in *Graphics Gems IV*, Academic Press, pp. 474–485, 1994.
  80. T. Rahman, M. E. H. Chowdhury and A. Khandakar, "COVID-19 Radiography Database," Kaggle, 2021. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>
  81. P. Soille, *Morphological Image Analysis: Principles and Applications*, 2nd ed. Berlin, Heidelberg: Springer, 2003. <https://doi.org/10.1007/978-3-662-05088-0>
  82. S. Heidarian et al., "CT-CAPS: Feature Extraction-based Automated Framework for COVID-19 Disease Identification from Chest CT Scans using Capsule Networks," *arXiv preprint arXiv:2010.16043*, 2020. <https://doi.org/10.48550/arXiv.2010.16043>
  83. J. Ma et al., "COVID-19 CT Lung and Infection Segmentation Dataset (Version 1.0)", Zenodo, 2020. [Электронный ресурс]. Режим доступа: <https://doi.org/10.5281/zenodo.3757476>
  84. T. D. Nguyen, "COVID-19 CT Lung and Infection Segmentation", Kaggle, 2024. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com/datasets/nguyentienda32143/covid-19-ct-lung-and-infection-segmentation>
  85. M. Parekh, A. Donuru, R. Balasubramanya and S. Kapur, "Review of the Chest CT Differential Diagnosis of Ground-Glass Opacities

- in the COVID Era," *Radiology*, vol. 297, no. 3, pp. E289–E302, 2020.  
<https://doi.org/10.1148/radiol.2020202504>
86. Kaggle, "Notebooks," Kaggle documentation. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com/docs/notebooks>
  87. Hugging Face, "Spaces Overview," Hugging Face Hub documentation. [Электронный ресурс]. Режим доступа: <https://huggingface.co/docs/hub/spaces-overview>
  88. Gradio, "Quickstart," Gradio documentation. [Электронный ресурс]. Режим доступа: <https://www.gradio.app/guides/quickstart>

## ДОДАТОК — СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

1. V. I. Suchkov and A. O. Pashko, "COVID-19 Computed Tomography Image Processing Based on Statistical Segmentation Methods," in *Abstracts of the XXXIX International Conference "Problems of Decision Making Under Uncertainties" (PDMU-2024)*, Brno, Czech Republic, Sept. 9–10, 2024, pp. 133–134.
2. В. І. Сучков, "Штучний інтелект у сфері охорони здоров'я II Всеукраїнська науково-практична конференція з міжнародною участю "ПРОКиїв", Київ, Україна, 3–4 грудня 2024, с. 477–479.
3. А. О. Пашко та В. І. Сучков, "Застосування згорткових нейронних мереж для класифікації рентген-знімків легень XIII Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2024, с. 235–239.
4. В. І. Сучков та А. О. Пашко, "Сегментація області легень на рентген-знімках грудної клітини XIV Міжнародна науково-практична конференція "Глушковські читання. Сучасна кібернетика", Київ, Україна, 2025, с. 346–348.
5. В. І. Сучков та А. О. Пашко, «Згорткова нейронна мережа для класифікації рентген-знімків грудної клітини», *Журнал обчислювальної та прикладної математики*, вип. 2, с. 77–86, Груд. 2025.  
<https://doi.org/10.17721/2706-9699.2025.2.06>
6. А. О. Пашко та В. І. Сучков, «Сегментація легень на рентген-знімках грудної клітини з анатомічно орієнтованою оцінкою», *Наукові праці Вінницького національного технічного університету*, вип. 1, с. 161–171, Бер. 2026.  
<https://doi.org/10.31649/2307-5376-2026-1-161-171>

7. В. І. Сучков, «Методи попереднього оброблення рентген-знімків грудної клітини в задачі класифікації», *Наука, технології, інновації*, вип. 1(37), с. 110–115, 2026.  
<https://doi.org/10.35668/2520-6524-2026-1-11>
8. В. І. Сучков, «Застосування методу збалансованого порогового відсікання гістограми у задачі сегментації легень на рентгенівських зображеннях грудної клітини», *Журнал обчислювальної та прикладної математики*, вип. 1, с. 99–108, Квіт. 2026.  
<https://doi.org/10.17721/2706-9699.2026.1.07>