

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

(повна назва інституту/факультету)

кафедра БІОМЕДИЧНОЇ КІБЕРНЕТИКИ  
(повна назва кафедри)

«На правах рукопису»  
УДК \_\_\_\_\_

«До захисту допущено»  
В.о.завідувача кафедри БМК

\_\_\_\_\_ Світлана АЛХІМОВА  
(підпис) (ініціали, ПРИЗВИЩЕ)

“ \_\_\_ ” *грудня* 2025р.

**Магістерська дисертація**  
на здобуття ступеня магістра  
за освітньо-професійною програмою «Комп'ютерні технології в біології та  
медицині»  
зі спеціальності 122 «Комп'ютерні науки»

на тему: Визначення ступеню фіброзу на основі аналізу  
ультразвукових зображень паренхіми печінки

Виконала: студентка II курсу, групи ЗК-41мп

**БУДНІК ЮЛІЯ СЕРГІЇВНА**

(прізвище, ім'я, по батькові)

(підпис)

Науковий керівник: ст. викл. каф. біомедичної кібернетики  
Бовсуновська Катерина Сергіївна

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

(підпис)

Консультант з розділів магістерської дисертації:

доцент каф. біомедичної кібернетики,

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

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

(підпис)

Рецензент: доцент кафедри біомедичної інженерії,  
к.т.н., доцент Сичик Марина Михайлівна

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

(підпис)

Засвідчую, що у цій магістерській дисертації  
немає запозичень з праць інших авторів без  
відповідних посилань.

Студентка

(підпис)

Київ – 2025 року

**Національний технічний університет України**  
**«Київський політехнічний інститут імені Ігоря Сікорського»**  
**Факультет біомедичної інженерії**  
**Кафедра біомедичної кібернетики**

Рівень вищої освіти – другий (магістерський)

Спеціальність – 122 «Комп’ютерні науки»

Освітньо-професійна програма «Комп’ютерні технології в біології та медицині»

ЗАТВЕРДЖУЮ

В.о.завідувача кафедри БМК

\_\_\_\_\_ Світлана АЛХІМОВА

«\_\_\_\_\_» листопада 2025 р.

**ЗАВДАННЯ**  
**на магістерську дисертацію студентці**

**БУДНІК ЮЛІЇ СЕРГІЇВНИ**

(прізвище, ім’я, по батькові)

1. Тема дисертації \_\_\_\_\_ ***Визначення ступеню фіброзу на основі аналізу***  
***ультразвукових зображень паренхіми печінки***

науковий керівник дисертації

***Бовсуновська Катерина Сергіївна***

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

затверджені наказом по університету від «03» листопада 2025 р. №4751-с\_

2. Термін подання студентом дисертації \_\_\_\_\_ ***20-22 листопада 2025 року***

3. Об’єкт дослідження ***ультразвукові знімки паренхіми печінки***

4. Вихідні дані: ***Реальні данні для виконання роботи отримано від «Всеукраїнський центр материнства та дитинства національної академії медичних наук України» (довідка від №2.7-04/302)***

5. Перелік завдань, які потрібно розробити ***Аналіз методів діагностики фіброзу печінки та текстурних характеристик в вітчизняних та зарубіжних джерелах, огляд можливих аналогів із класифікації ступеня фіброзу печінки, створення каналів текстурних характеристик зображень та створення архітектури нейронної мережі, тренування та об’єднання моделей у мета-класифікатор, розробка програмного інтерфейсу користувача.***

6. Орієнтовний перелік графічного (ілюстративного) матеріалу ***64 рисунка, 2 таблиці, презентація з захисту МД на 14 слайдах***

7. Орієнтовний перелік публікацій ***не передбачено***

8. Консультанти розділів дисертації

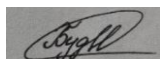
Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Магістерська дисертація	Павлов Володимир Анатолійович, доцент каф. БМК, доц., к.т.н.	28.08.2025	17.11.2025

9. Дата видачі завдання **28 серпня 2025р.**

### Календарний план

№ з/п	Назва етапів виконання магістерської дисертації	Термін виконання етапів МД	Примітка
1	Отримати завдання на МД	До 28.08.2025	<b>виконано</b>
2	Завершення виконання практичної частина МД	До 25.10.2025	<b>виконано</b>
3	Завершення оформлення розділів МД (Вступ, Основні розділи та висновки до них, Загальні висновки, Список використаних джерел)	До 24.11.2025	<b>виконано</b>
4	Апробація та публікація результатів дослідження МД (отримати підтвердження про прийняття до друку)	До 01.12.2025	<b>виконано</b>
5	Перевірка МД науковим керівником	24.11.2025	<b>виконано</b>
6	Подання в електронному вигляді МД на перевірку нормоконтролера	До 01.12.2025	
7	Подання в електронному вигляді МД на перевірку подібності Strike Plagiarism com. Отримати позитивний звіт подібності.	До 05.12.2025	
8	Підготовка Експертної оцінки до звіту подібності.	До 10.12.2025	
9	Отримати відгук наукового керівника	10.12.2025	
10	Надати на кафедру пакет документів в паперовому та електронному вигляді (МД, відгук керівника, звіт подібності, Експертної оцінки до звіту подібності )	10-11.12.2025	
11	Отримати допуск до захисту МД в ЕК та направлення до рецензента (засідання кафедри)	Засідання кафедри	
12	Подання МД рецензенту. Отримати на надання рецензію до ЕК / на кафедру	До 19.12.2025	
13	Подання супровідного пакету документів по МД до захисту в ЕК	До 19.12.2025	
14	Захист МД в ЕК	22 – 26.12.2025	

Студентка



(підпис)

**Юлія БУДНІК**

(ім'я, ПРІЗВИЩЕ)

Науковий керівник



(підпис)

**КАТЕРИНА БОВСУНОВСЬКА**

(ім'я, ПРІЗВИЩЕ)

Нормоконтролер

(підпис)

**Галина КОРНІЄНКО**

(ім'я, ПРІЗВИЩЕ)

## РЕФЕРАТ

Магістерська дисертація за темою «Визначення ступеню фіброзу на основі аналізу ультразвукових зображень паренхіми печінки» виконана студенткою кафедри біомедичної кібернетики ФБМІ Буднік Юлією Сергіївною зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині» та складається зі: вступу; 5 розділів (*Аналіз аналогів системи визначення ступеня фіброзу печінки. Сучасні підходи діагностики фіброзу печінки. Обґрунтування вибору програмного середовища. Програмна реалізація та методика роботи системи визначення фіброзу печінки*), розділу зі стартап проєкту, висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 53 джерела. Загальний обсяг роботи 100 сторінка.

**Актуальність теми.** Хронічні захворювання печінки залишаються однією з провідних медичних проблем, а фіброз є ключовим показником їх прогресування. Біопсія, хоча й точна, є інвазивною та непригодною для частого моніторингу. Ультразвукова діагностика доступна й безпечна, однак її результати залежать від досвіду лікаря та можуть бути неоднозначними. Застосування методів глибинного навчання та текстурного аналізу дає змогу підвищити об'єктивність і точність оцінки фіброзу на основі стандартних ультразвукових зображень, не потребуючи спеціалізованого обладнання. Комплексний підхід із використанням мета-класифікатора забезпечує можливість детальнішої класифікації стадій фіброзу та створює підґрунтя для практичного програмного рішення, придатного до використання в клінічній практиці.

### **Мета і задачі дослідження.**

Метою роботи є підвищення точності автоматичного визначення ступеня фіброзу печінки на основі аналізу ультразвукових зображень паренхіми із застосуванням нейронних мереж.

Сформульовано наступні задачі:

1. Аналіз методів діагностики фіброзу печінки та текстурних характеристик в вітчизняних та зарубіжних джерелах
2. Огляд можливих аналогів із класифікації ступеня фіброзу печінки
3. Створення каналів текстурних характеристик зображень та створення архітектури нейронної мережі.
4. Тренування та об'єднання моделей у мета-класифікатор, розробка програмного інтерфейсу користувача.

**Об'єкт дослідження.** Ультразвукові знімки паренхіми печінки

**Предмет дослідження.** Розпізнавання ступеня фіброзу по ультразвуковому знімку паренхіми печінки

**Методи дослідження.** Глибинне навчання, згорткові нейронні мережі, мета-класифікація, текстурний аналіз ультразвукових зображень

**Практичне значення одержаних результатів.** Магістерська дисертація виконана з використанням реальної бази лабораторних даних ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України» (довідка використання №2.7-04/302).

Магістерська дисертація виконана на замовлення ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України» (акт впровадження від 13.06.2024р.).

**Апробація результатів дослідження** Не передбачені

**Публікації.** Не передбачені

**Ключові слова.** Класифікація, ультразвукове зображення, фіброз печінки, текстурний аналіз, нейронні мережі

**Бібліографічний опис МД**

Буднік, Ю. С. Визначення ступеню фіброзу на основі аналізу ультразвукових зображень паренхіми печінки : магістерська дис. : 122 Комп'ютері науки / Буднік Юлія Сергіївна. – Київ, 2025. – 126 с

## ABSTRACT

Master's thesis on “Determining the degree of fibrosis based on the analysis of ultrasound images of the liver parenchyma” was completed by Yulia Budnik, a student of the Department of Biomedical Cybernetics, Faculty of Biomedical Engineering, majoring in 122 “Computer Science” under the educational and professional program “Computer Technologies in Biology and Medicine” and consists of: an introduction; 5 chapters (Analysis of analogues of the system for determining the degree of liver fibrosis. Modern approaches to the diagnosis of liver fibrosis. Justification of the choice of software environment. Software implementation and methodology of the liver fibrosis determination system), a section on the start-up project, conclusions for each of these sections; general conclusions; a list of 53 sources used. The total volume of the work is 100 pages.

**Relevance of the topic.** Chronic liver diseases remain one of the leading medical problems, and fibrosis is a key indicator of their progression. Although accurate, biopsy is invasive and unsuitable for frequent monitoring. Ultrasound diagnostics is accessible and safe, but its results depend on the experience of the physician and can be ambiguous. The use of deep learning and texture analysis methods makes it possible to increase the objectivity and accuracy of fibrosis assessment based on standard ultrasound images without the need for specialized equipment. A comprehensive approach using a meta-classifier provides the possibility of a more detailed classification of fibrosis stages and creates the basis for a practical software solution suitable for use in clinical practice.

### **Purpose and objectives of the study.**

The aim of the work is to improve the accuracy of automatic determination of the degree of liver fibrosis based on the analysis of ultrasound images of the parenchyma using neural networks.

### **The following objectives have been formulated:**

1. Analysis of methods for diagnosing liver fibrosis and texture characteristics in domestic and foreign sources

2. Review of possible analogues for the classification of the degree of liver fibrosis
3. Creation of channels of texture characteristics of images and creation of a neural network architecture.
4. Training and combining models into a meta-classifier, development of a user interface.

**Object of study.** Ultrasound images of liver parenchyma

**Subject of study.** Recognition of the degree of fibrosis based on ultrasound images of liver parenchyma

**Research methods.** Deep learning, convolutional neural networks, meta-classification, texture analysis of ultrasound images

**Practical significance of the results obtained.** The master's thesis was completed using a real database of laboratory data from the State Institution "Institute of Pediatrics, Obstetrics and Gynecology named after Academician O.M. Lukyanova of the National Academy of Medical Sciences of Ukraine" (certificate of use No. 2.7- 04/302).

The master's thesis was commissioned by the State Institution "Institute of Pediatrics, Obstetrics and Gynecology named after Academician O.M. Lukyanova of the National Academy of Medical Sciences of Ukraine" (implementation act dated 06/13/2024).

**Approval of research results.** Not provided

**Publications.** Not provided

**Keywords.** Classification, ultrasound imaging, liver fibrosis, texture analysis, neural networks

## ЗМІСТ

<b>ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ .....</b>	<b>12</b>
<b>ВСТУП.....</b>	<b>13</b>
<b>РОЗДІЛ 1 АНАЛІЗ АНАЛОГІВ СИСТЕМИ ВИЗНАЧЕННЯ СТУПЕНЯ ФІБРОЗУ ПЕЧІНКИ.....</b>	<b>15</b>
1.1 КЛАСИФІКАЦІЯ УЛЬТРАЗВУКОВИХ ЗОБРАЖЕНЬ НА ОСНОВІ СТАТИСТИКИ ЕХО-ОГИНАЮЧОЇ.....	15
1.2 ГЛИБОКЕ НАВЧАННЯ ЕЛАСТОГРАФІЇ ЗСУВНИХ ХВИЛЬ.....	17
1.3 КЛАСИФІКАЦІЯ ФІБРОЗУ ПЕЧІНКИ НА ОСНОВІ ЧАСТОТНИХ СПЕКТРІВ РАДІОЧАСТОТНИХ СИГНАЛІВ .....	18
1.4 ОЦІНКА ФІБРОЗУ ПЕЧІНКИ НА ОСНОВІ УЛЬТРАЗВУКОВИХ- РАДІОЧАСТОТНИХ СИГНАЛІВ .....	19
1.5 РОЗВИТОК МЕТОДІВ У КОНТЕКСТІ ПОПЕРЕДНІХ ДОСЛІДЖЕНЬ .....	20
ВИСНОВОК З РОЗДІЛУ 1.....	21
<b>РОЗДІЛ 2 СУЧАСНІ ПІДХОДИ ДІАГНОСТИКИ ФІБРОЗУ ПЕЧІНКИ.....</b>	<b>22</b>
2.1 АУТОІМУННІ ЗАХВОРЮВАННЯ ПЕЧІНКИ ТА ЇХ РОЛЬ У ФОРМУВАННІ ФІБРОЗУ .....	22
2.2 МЕТОДИ ДІАГНОСТИКИ ФІБРОЗУ ПЕЧІНКИ.....	25
2.3 ЗАДАЧА КЛАСИФІКАЦІЇ В КОНТЕКСТІ ДІАГНОСТИКИ ФІБРОЗУ .....	27
2.4 ПРИНЦИПИ РОБОТИ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ.....	29
2.5 ПОНЯТТЯ ТЕКСТУРИ В МЕДИЧНИХ ЗОБРАЖЕННЯХ .....	31
2.6 ПОНЯТТЯ ГІСТОГРАМИ ЗОБРАЖЕННЯ.....	33
2.7 МАТРИЦЯ СУМІЖНОСТІ ВІДТІНКІВ СІРОГО.....	40
2.8 МАТРИЦЯ ДОВЖИН СЕРІЙ ВІДТІНКІВ СІРОГО.....	45
ВИСНОВОК З РОЗДІЛУ 2.....	49

<b>РОЗДІЛ 3 ОБҐРУНТУВАННЯ ВИБОРУ ПРОГРАМНОГО СЕРЕДОВИЩА .....</b>	<b>50</b>
3.1 ВИБІР МОВИ ПРОГРАМУВАННЯ .....	50
3.2 БІБЛІОТЕКИ ДЛЯ ОБРОБКИ ТА АНАЛІЗУ ЗОБРАЖЕНЬ .....	51
3.2.1 <i>OpenCV</i> .....	51
3.2.2 <i>Scikit-image</i> .....	51
3.3 БІБЛІОТЕКИ ДЛЯ ЧИСЕЛЬНИХ ОБЧИСЛЕНЬ ТА СТАТИСТИКИ .....	52
3.3.1 <i>NumPy</i> .....	52
3.3.2 <i>SciPy</i> .....	52
3.3.3 <i>Pandas</i> .....	52
3.4 БІБЛІОТЕКИ ДЛЯ МАШИННОГО НАВЧАННЯ .....	53
3.4.1 <i>TensorFlow та Keras</i> .....	53
3.4.2 <i>Scikit-learn</i> .....	53
3.5 БІБЛІОТЕКИ ДЛЯ ВІЗУАЛІЗАЦІЇ .....	54
3.6 БІБЛІОТЕКИ ДЛЯ РОЗРОБКИ ГРАФІЧНОГО ІНТЕРФЕЙСУ.....	54
3.7 АЛЬТЕРНАТИВНІ РІШЕННЯ ТА ОБҐРУНТУВАННЯ ВИБОРУ .....	55
Висновки з розділу 3.....	55
 <b>РОЗДІЛ 4 ПРОГРАМНА РЕАЛІЗАЦІЯ ТА МЕТОДИКА РОБОТИ СИСТЕМИ ВИЗНАЧЕННЯ СТЕПЕНЯ ФІБРОЗУ ПЕЧІНКИ .....</b>	 <b>57</b>
4.1 АНАЛІЗ ТА ОБРОБКА ДАНИХ.....	57
4.2 ТЕКСТУРНІ ХАРАКТЕРИСТИКИ ЗОБРАЖЕНЬ.....	61
4.2.1 <i>Гістrograma відтінків сірого</i> .....	61
4.2.2 <i>Матриця суміжності відтінків сірого</i> .....	64
4.2.3 <i>Матриця довжин відтінків сірого</i> .....	65
4.3 ГРУПОВІ БІНАРНІ КЛАСИФІКАТОРИ.....	66
4.3.1 <i>Визначення архітектури згорткової нейронної мережі</i> .....	66
4.3.2 <i>Тренування моделі класифікатора №1</i> .....	69
4.3.3 <i>Тренування моделі класифікатора №2</i> .....	70
4.3.4 <i>Тренування моделі класифікатора №3</i> .....	72

	10
4.3.5	<i>Тренування моделі класифікатора №4</i> ..... 73
4.3.6	<i>Тренування моделі класифікатора №5</i> ..... 74
4.3.7	<i>Тренування моделі класифікатора №6</i> ..... 75
4.3.8	<i>Тренування моделі класифікатора №7</i> ..... 76
4.4	БАГАТОКЛАСОВІ МОДЕЛІ НА ОСНОВІ ТЕКСТУРНИХ ХАРАКТЕРИСТИК ... 77
4.4.1	<i>Модель на основі гістограми відтінків сірого</i> ..... 77
4.4.2	<i>Модель на основі матриці суміжності відтінків сірого</i> ..... 81
4.4.3	<i>Модель на основі матриці довжин відтінків сірого</i> ..... 84
4.5	МОДЕЛІ З РОЗБИТТЯМ НА ОБЛАСТІ ІНТЕРЕСУ ..... 89
4.6	ОБ'ЄДНАННЯ АРХІТЕКТУРИ МОДЕЛЕЙ..... 93
4.6.1	<i>Отримання векторів ймовірностей навчених моделей</i> ..... 93
4.6.2	<i>Навчання на мета-рівні</i> ..... 94
4.7	СТВОРЕННЯ ПРОГРАМНОГО ЗАСТОСУНКУ ..... 96
	Висновок з розділу 4..... 99
<b>РОЗДІЛ 5 УЗАГАЛЬНЕННЯ РЕЗУЛЬТАТІВ РОБОТИ ..... 101</b>	
5.1	АНАЛІЗ ТА ІНТЕРПРЕТАЦІЯ ОТРИМАНИХ РЕЗУЛЬТАТІВ ..... 101
5.1.1	<i>Результати групових бінарних класифікаторів</i> ..... 102
5.1.2	<i>Результати багатокласових моделей на основі текстурних характеристик</i> ..... 102
5.1.3	<i>Оцінка моделей з розбиттям на області інтересу</i> ..... 103
5.1.4	<i>Ефективність мета-класифікатора</i> ..... 104
5.2	ПОРІВНЯННЯ З ІСНУЮЧИМИ ПІДХОДАМИ ТА ОБГОВОРЕННЯ АКТУАЛЬНОСТІ..... 104
5.3	ОБМЕЖЕННЯ ДОСЛІДЖЕННЯ ТА НАПРЯМИ ПОДАЛЬШОГО РОЗВИТКУ .. 106
	Висновки з розділу 5..... 106
<b>РОЗДІЛ 6 СТАРТАП-ПРОЄКТ ЗА ТЕМОЮ МАГІСТЕРСЬКОГО ДОСЛІДЖЕННЯ ..... 108</b>	
6.1	НАЗВА ПРОЄКТУ ..... 108
6.2	КОРОТКИЙ ОПИС ПРОЄКТУ ..... 108

	11
6.3 БІЗНЕС МОДЕЛЬ.....	109
6.3.1 Цінність продукту.....	109
6.3.2 Виконання вимог користувачів.....	109
6.3.3 Сегмент споживачів .....	109
6.3.4 Канали збуту .....	110
6.3.5 Взаємодія з користувачами .....	110
6.3.6 Дохід проєкту.....	111
6.3.7 Ключові види діяльності.....	111
6.4 КЛЮЧОВІ РЕСУРСИ.....	111
6.4.1 Матеріальні ресурси.....	111
6.4.2 Інтелектуальні ресурси.....	111
6.4.3 Людські ресурси .....	112
6.4.4 Фінансові ресурси.....	113
6.4.5 Ключові партнери .....	113
6.4.6 Витрати.....	113
6.4.7 Споживчі властивості товару .....	114
6.5 ДОСЛІДЖЕННЯ РИНКУ .....	114
6.6 ЕЛЕМЕНТИ ФІНАНСОВОГО ПЛАНУ .....	115
6.6.1 Опис бізнес-проєкту.....	115
6.6.2 Опис товару/послуги/технології .....	115
6.6.3 Маркетинг та продаж.....	116
6.6.4 Фінансовий план .....	116
<b>ЗАГАЛЬНІ ВИСНОВКИ .....</b>	<b>118</b>
<b>СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ .....</b>	<b>120</b>

## **ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ**

ROI – області інтересу

CNN – згорткова нейронна мережа

GLCM – матриця суміжності відтінків сірого

GLRLM – матриця довжин відтінків сірого

## ВСТУП

Хронічні захворювання печінки залишаються однією з провідних медичних проблем, а фіброз є ключовим показником їх прогресування. Біопсія, хоча й точна, є інвазивною та непригодною для частого моніторингу. Ультразвукова діагностика доступна й безпечна, однак її результати залежать від досвіду лікаря та можуть бути неоднозначними. Застосування методів глибинного навчання та текстурного аналізу дає змогу підвищити об'єктивність і точність оцінки фіброзу на основі стандартних ультразвукових зображень, не потребуючи спеціалізованого обладнання. Комплексний підхід із використанням мета-класифікатора забезпечує можливість детальнішої класифікації стадій фіброзу та створює підґрунтя для практичного програмного рішення, придатного до використання в клінічній практиці.

### *Мета і завдання роботи*

Метою роботи є підвищення точності автоматичного визначення ступеня фіброзу печінки на основі аналізу ультразвукових зображень паренхіми із застосуванням нейронних мереж.

Сформульовано наступні **задачі**:

1. Аналіз методів діагностики фіброзу печінки та текстурних характеристик в вітчизняних та зарубіжних джерелах
2. Огляд можливих аналогів із класифікації ступеня фіброзу печінки
3. Створення каналів текстурних характеристик зображень та створення архітектури нейронної мережі.
4. Тренування та об'єднання моделей у мета-класифікатор, розробка програмного інтерфейсу користувача.

**Використані методи.** Глибинне навчання, згорткові нейронні мережі, мета-класифікація, текстурний аналіз ультразвукових зображень

**Отримані результати.** Створено архітектуру нейронних мереж, побудовано текстурні характеристики на ультразвукових зображеннях

паренхіми печінки, натреновано моделі нейронних мереж, об'єднано моделі у мета-класифікатор, розроблено програмний інтерфейс користувача

*Апробація результатів дослідження Не передбачено*

*Публікації. Не передбачено*

***Структура роботи***

Магістерська дисертація за темою «Визначення ступеню фіброзу на основі аналізу ультразвукових зображень паренхіми печінки» виконана студенткою Буднік Юлією Сергіївною зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині», побудована за класичним типом та викладена на 126 сторінок машинописного тексту. Вона складається з: вступу; 5 розділів (*Аналіз аналогів системи визначення ступеня фіброзу печінки. Сучасні підходи діагностики фіброзу печінки. Обґрунтування вибору програмного середовища. Програмна реалізація та методика роботи системи визначення фіброзу печінки*), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 53 джерела (9 – на кирилиці, 44 – на латиниці). В роботі представлено 64 рисунка і 2 таблиці.

# РОЗДІЛ 1

## АНАЛІЗ АНАЛОГІВ СИСТЕМИ ВИЗНАЧЕННЯ СТУПЕНЯ ФІБРОЗУ ПЕЧІНКИ

У цьому розділі розглянуто сучасні підходи до автоматизованої оцінки фіброзу печінки, що базуються на аналізі ультразвукових зображень та радіочастотних сигналів із застосуванням методів глибинного навчання. Проаналізовано основні тенденції розвитку технологій, їх сильні сторони та обмеження, а також визначено місце запропонованої системи серед існуючих рішень. Особливу увагу приділено порівнянню різних методів обробки медичних зображень і структурних ознак тканини, а також розвитку підходів від попередніх досліджень до створення багатокомпонентної архітектури, що використовується в межах магістерської роботи.

### **1.1 Класифікація ультразвукових зображень на основі статистики ехо-огинаючої**

У 2023 році група дослідників під керівництвом Шінносіке Хірата представила роботу “Convolutional Neural Network Classification of Ultrasound Images by Liver Fibrosis Stages based on Echo-Envelope Statistics” [1], яка стала однією з перших спроб інтеграції статистичних характеристик ехосигналу безпосередньо у вхідні дані для глибинного навчання. На відміну від традиційних методів, що покладаються виключно на сірі В-mode зображення, автори запропонували використання вищих статистичних моментів ехосигналу – зокрема скошеності (skewness) та куртозису (kurtosis), які є важливими індикаторами мікроструктурних змін у тканинах печінки. Ці параметри відображають не лише розподіл яскравостей, а й більш тонкі відхилення в структурі тканини, які складно, а інколи й неможливо оцінити візуально.

У ході дослідження використовувалися реальні клінічні дані пацієнтів з хронічними ураженнями печінки, включно з гепатитом В та гепатитом С. З

кожного ультразвукового зображення виділялися стандартизовані ROI, які проходили нормалізацію з метою зменшення впливу шумів та апаратних відмінностей між пристроями. Дослідники розробили методику створення багатоканального зображення, де один канал містив оригінальні дані B-mode, а інші канали – нормалізовані статистичні моменти ехосигналу. Таким чином формувалася кольорова структура ROI, яка поєднувала макроскопічні особливості зображення з мікроструктурними параметрами.

Модель VGG-16, попередньо навчена на ImageNet, була донавчена для класифікації чотирьох стадій фіброзу за шкалою METAVIR (F1–F4). За результатами експериментів точність класифікації зросла з 47,5 % (при використанні лише вихідних сірих зображень) до близько 59 % у разі інтеграції статистичних каналів. Для бінарних задач ( $\geq F2$ ,  $\geq F3$ ,  $\geq F4$ ) точність досягала 91 %, 80 % і 78 % відповідно. Особливої уваги заслуговує той факт, що саме середні стадії – такі як F2 – класифікувалися найгірше, що збігається з клінічними даними про труднощі їх диференціації.

Порівнюючи цей підхід із розроблюваною системою, слід наголосити на принципових відмінностях. Якщо в методиці Хірати багатоканальність забезпечувалася виключно статистичними моментами ехосигналу, то в запропонованому рішенні передбачено комплексніший аналіз текстурних характеристик. Система оперує не двома додатковими параметрами, а цілим гістограмами яскравостей, GLCM, GLRLM. Кожен тип текстурної ознаки обробляється окремою моделлю CNN, після чого всі результати інтегруються у метамодель, здатну враховувати різнорівневі структури ультразвукових даних. Крім того, система виконує класифікацію не за 4, а за 8 класами, що дозволяє детальніше розрізняти проміжні стадії фіброзу. Додатковою перевагою є наявність програмного інтерфейсу, який забезпечує можливість інтеграції у медичні робочі процеси. Таким чином, запропонована система суттєво розширює ідеї Хірати, застосовуючи більш гнучку багатомодельну архітектуру та ширший спектр дескрипторів.

## 1.2 Глибоке навчання еластографії зсувних хвиль

У 2019 році Кун Ван із колегами опублікували роботу “Deep learning-based radiomics of two-dimensional shear wave elastography significantly improved diagnostic performance for fibrosis staging in chronic hepatitis B: a prospective multicentre study” [2]. Дане дослідження стало одним із ключових у сфері застосування глибокого навчання до еластографії зсувних хвиль (2D-SWE). На відміну від традиційних B-mode зображень, еластографія дає змогу оцінити механічні властивості тканини, зокрема її жорсткість, яка безпосередньо корелює зі ступенем фіброзних змін.

У дослідженні була використана велика мультицентрова вибірка пацієнтів із 12 медичних установ Китаю, що дозволило забезпечити високу варіативність та репрезентативність даних. Зображення SWE піддавалися попередній обробці: видалення артефактів, стандартизація ROI, нормалізація даних. Паралельно з обчисленням радіомічних ознак використовувалась глибока CNN, яка автоматично навчалася виявляти характерні патерни жорсткості, пов’язані з конкретними стадіями фіброзу.

Результати були багатообіцяючими: запропонована модель значно перевершила традиційні кількісні методи еластографії та навіть деякі відомі біомаркери. Особливо це стосувалося стадій F3–F4, де звичайна еластографія часто демонструє широку варіативність через вплив артефактів та технічних обмежень.

У порівнянні з розроблюваною системою можна виділити кілька важливих відмінностей. По-перше, підхід Вана працює з єдиним типом даних – SWE-картами жорсткості. У той час як запропонована система ґрунтується на стандартних ультразвукових B-mode знімках та їхніх текстурних характеристиках, що дозволяє працювати з даними, доступними у значно ширшому колі медичних установ, оскільки SWE-модулі є дорогими і не завжди доступні. По-друге, у нашому випадку аналіз здійснюється одразу кількома незалежними CNN-моделями, кожна з яких спеціалізується на певному типі

текстурної інформації, після чого формується спільний висновок метамоделі. По-третє, система виконує класифікацію за 8 детальними класами ступеня фіброзу, надаючи точнішу градацію, ніж класичні підходи, орієнтовані на грубе поділення. Таким чином, продукт розширює можливості ультразвукової діагностики без потреби у спеціалізованому еластографічному обладнанні.

### **1.3 Класифікація фіброзу печінки на основі частотних спектрів радіочастотних сигналів**

Цікавим напрямом розвитку методів оцінки фіброзу є аналіз радіочастотних сигналів, які містять значно більше інформації, ніж реконструйовані B-mode зображення. Саме такий підхід був запропонований у роботі Х. Ай “Ultrasound assessment of liver fibrosis using one-dimensional convolutional neural networks based on frequency spectra of RF signals with B-mode segmentation by deep learning” [3]. Дослідники запропонували дворівневу структуру обробки: спочатку за допомогою 2D CNN виконувалася автоматична сегментація печінкових областей на B-mode зображеннях, а потім по кожному сегменту формувалися частотні спектри RF-сигналів, які подавалися до 1D CNN для класифікації ступеня фіброзу.

Підхід був реалізований на великій вибірці: сегментаційну модель навчали на 613 пацієнтах, класифікаційну – на 237. Результуючі значення AUC були високими для більшості задач: 0,957 для  $\geq F1$ , 0,808 для  $\geq F2$  та 0,876 для  $\geq F4$ . Це демонструє великий потенціал RF-аналізу, особливо у випадках ранніх та проміжних стадій фіброзу, які є найбільш проблемними.

Порівнюючи з розробленим продуктом, головна відмінність полягає у природі вхідних даних. Підхід Ай використовує RF-сигнали, які вимагають спеціального доступу до «сирих» даних ультразвукового апарата, що суттєво обмежує можливість його використання у звичайних клініках. Натомість розроблена система працює з доступними B-mode знімками, що не потребують спеціального обладнання. Додаткові CNN-модулі формують окремі прогнози

на основі гістограм яскравостей, GLCM та GLRLM-характеристик, а метамодель інтегрує ці результати зі стандартною класифікаційною CNN. Таким чином забезпечується підхід, який є водночас гнучким, масштабованим та універсально застосовним у різних клінічних умовах.

#### **1.4 Оцінка фіброзу печінки на основі ультразвукових-радіочастотних сигналів**

У 2022 році Йонг Хуан із колегами представили ще один важливий крок у напрямі аналізу RF-сигналів, запропонувавши методику на основі 1D CNN [4]. Дослідження ґрунтувалося на ідеї, що RF-сигнали є значно інформативнішими щодо мікроструктури тканини, ніж B-mode зображення, які є лише непрямою їх реконструкцією. Автори вручну виділяли області печінки, після чого нормалізовані RF-сигнали подавалися до CNN, яка містила чотири шари згортки, чотири шари макс-пулінгу та кілька повнозв'язних шарів. Для збільшення обсягу даних застосовувалося ковзне вікно, що забезпечувало багатократне семплювання RF-послідовностей.

Дослідження проводилося на вибірці з 230 пацієнтів (від F0 до F4), і показало високу точність, особливо для пізніх стадій фіброзу, де RF-підхід демонструє найбільшу інформативність.

У контексті порівняння з розроблюваним продуктом можна виділити кілька важливих аспектів. Рішення Хуана, так само як і підхід Ай, базується на RF-сигналах, які не завжди доступні в умовах стандартного ультразвукового обстеження. Крім того, моделі Хуана орієнтовані на класифікацію за основними стадіями (F0–F4), тоді як розроблена система реалізує деталізовану класифікацію за 8 класами, охоплюючи також проміжні стани (F1–2, F2–3, F3–4). У нашій системі кожен клас має окреме клінічне значення, що дозволяє більш точно прогнозувати прогресування захворювання. Також наявність багатокомпонентного підходу – окремих CNN для роботи з текстурними характеристиками, метамоделі для інтеграції результатів та готового

програмного інтерфейсу – дозволяє забезпечити комплексне, масштабоване та практичне рішення для ультразвукової діагностики.

### **1.5 Розвиток методів у контексті попередніх досліджень**

Варто окремо зазначити, що запропонована в магістерській роботі система є суттєвим розвитком та логічним продовженням попередніх досліджень, виконаних на етапі бакалаврських напрацювань. У бакалаврській роботі розроблялися переважно бінарні моделі класифікації, що працювали з ультразвуковими зображеннями судин печінки, а не паренхіми [5]. Тодішній підхід був орієнтований на виявлення наявності чи відсутності патологічних змін і базувався на аналізі відносно локалізованих структур, які мають інші характеристики, ніж паренхіма печінки. Крім того, в межах бакалаврської роботи використовувалися лише базові CNN-моделі без врахування текстурних характеристик, які є критично важливими для диференціації тонких фібротичних змін у тканинах.

Додатково, розроблялася трирівнева система з метакласифікатором, що певною мірою передбачало ідею інтеграції кількох моделей. Проте цей підхід також спирався переважно на аналіз вихідних ультразвукових зображень і не включав текстурних характеристик, таких як гістограми яскравостей, GLCM чи GLRLM.

На відміну від цих попередніх напрацювань, у магістерській роботі запропоновано комплексну метамодель, яка об'єднує одразу кілька незалежних CNN, кожна з яких спеціалізується на певному наборі текстурних характеристик, а також виконується розширена 8-класова класифікація ступенів фіброзу. Такий підхід дозволяє аналізувати саме паренхіму печінки, тобто той анатомічний компонент, у якому безпосередньо відбуваються фібротичні зміни. Крім того, впроваджено програмний інтерфейс, що робить систему завершеним програмним продуктом, придатним для подальшої клінічної апробації.

## Висновок з розділу 1

Аналіз сучасних підходів до автоматизованої оцінки фіброзу печінки показує, що методи глибинного навчання активно розвиваються у різних напрямках – від використання статистичних характеристик ехосигналу та радіомічних ознак еластографії до аналізу радіочастотних сигналів. Кожен із цих підходів розширює можливості ультразвукової діагностики, проте зазвичай потребує спеціалізованого обладнання або не забезпечує достатньої точності для проміжних стадій фіброзу.

У цьому контексті розроблена система вирізняється універсальністю та кращою адаптованістю до реальних клінічних умов, оскільки працює зі стандартними B-mode зображеннями та поєднує широкий спектр текстурних характеристик. Використання кількох CNN-модулів і метамоделі дозволяє інтегрувати різні типи ознак та підвищувати точність класифікації, особливо у складних проміжних класах.

Порівняння з попередніми бакалаврськими напрацюваннями демонструє суттєвий перехід від простих бінарних моделей до комплексної багатоканальної архітектури з деталізованою 8-класовою класифікацією та програмним інтерфейсом. Це підтверджує еволюцію підходу та актуальність обраного напрямку розвитку системи діагностики фіброзу печінки.

## РОЗДІЛ 2

### СУЧАСНІ ПІДХОДИ ДІАГНОСТИКИ ФІБРОЗУ ПЕЧІНКИ

Розділ присвячено теоретичним засадам побудови системи автоматизованої діагностики фіброзу печінки за даними ультразвукових досліджень. Спочатку розглядаються особливості аутоімунних уражень печінки та механізми формування фіброзу, а також основні підходи до його діагностики – від інвазивної біопсії до сучасних неінвазивних методів. Окрему увагу приділено обґрунтуванню використання ультразвукової візуалізації як доступної, безпечної та придатної для подальшої автоматизованої обробки.

Далі вводиться постановка задачі класифікації ступеня фіброзу та розглядаються принципи роботи згорткових нейронних мереж у контексті медичних зображень, із акцентом на їх здатності виявляти слабо помітні структурні зміни паренхіми. Завершальним елементом є виклад основ текстурного аналізу на основі гістограм, GLCM та GLRLM, які у подальших розділах слугують базою для формування інформативних ознак та побудови моделей глибинного навчання.

#### 2.1 Аутоімунні захворювання печінки та їх роль у формуванні фіброзу

Аутоімунні захворювання печінки – це група хвороб, при яких імунна система людини помилково атакує власні клітини печінки, сприймаючи їх як чужорідні об'єкти. У нормальному стані імунна система має захищати організм від вірусів, бактерій та інших загроз. Однак при аутоімунних захворюваннях відбувається збій у цьому механізмі, і захисні клітини починають знищувати здорові тканини печінки [6].

До основних аутоімунних захворювань печінки належать: аутоімунний гепатит, первинний біліарний холангіт, первинний склерозуючий. [7]

Симптоми аутоімунного гепатиту варіюються від людини до людини і можуть з'являтися раптово. Деякі люди мають мало або взагалі не мають

помітних проблем на ранніх стадіях захворювання, тоді як інші відчувають такі симптоми, як: втома, дискомфорт у животі, пожовтіння шкіри та білків очей, яке називається жовтяницею, збільшення печінки, наявність павутинних ангіом (доброякісне судинне утворення, що виглядає як червона пляма з променями, які нагадують павутинку), шкірний висип, біль у суглобах, втрата менструального циклу. [8]

На сьогодні точні причини розвитку аутоімунних захворювань печінки остаточно не встановлені. Дослідники вважають, що захворювання розвивається внаслідок комбінації кількох факторів: генетична схильність, екологічні фактори, порушення імунної регуляції, гормональні фактори [6,9].

Процес перетворення аутоімунного захворювання у фіброз печінки можна описати як послідовність подій, що відбуваються протягом місяців і років: все починається з запалення і переходить в хронічне запалення, потім активуються зірчасті клітини, що при хронічному запаленні перетворюються у фібропласти і активно виробляють колаген, колаген накопичується і відбувається розростання сполучної тканини. Це і є фіброз - надмірне розростання сполучної тканини. Цей процес можна порівняти з шрамуванням шкіри після поранення: якщо травма одноразова, утворюється невеликий шрам, який не заважає нормальній роботі шкіри. Але якщо одне й те саме місце травмується знову і знову, шрамована тканина розростається все більше, втрачається еластичність, і ця ділянка перестає нормально функціонувати [10].

Тобто, фіброз печінки – це патологічний процес, при якому нормальна тканина печінки поступово заміщується сполучною (рубцевою) тканиною. Печінка має унікальну здатність до регенерації, але при тривалому пошкодженні (аутоімунні захворювання, вірусні гепатити, алкоголь, токсини) процеси відновлення не встигають за процесами руйнування, і в органі накопичується все більше "неробочої" тканини [10].

Для оцінки ступеня фіброзу печінки медики використовують кілька систем класифікації. Одна з найпоширеніших – шкала METAVIR. У 1993 році група з десяти французьких патологів на чолі з П'єром Бедосса, які

спеціалізувалися на захворюваннях печінки, створила кооперативну групу METAVIR. Група була сформована для обговорення питань, пов'язаних з патологічною оцінкою хронічного гепатиту С. Metavir є акронімом від «метааналіз гістологічних даних при вірусному гепатиті». З самого початку група мала намір оцінювати гістологічні зразки від пацієнтів клінічних випробувань та їх кореляцію з іншими біомедичними параметрами. [11]

За шкалою METAVIR виділяють 5 стадій фіброзу (від F0 до F4) [12]:

- F0 – відсутність фіброзу;
- F1 – мінімальний фіброз (портальний фіброз);
- F2 – помірний фіброз (портосептальний фіброз);
- F3 – значний фіброз (численні септи);
- F4 – цироз печінки (див. рис. 2.1) [5].




Рисунок 2.1 – Стадії фіброзу печінки [13]

Ключовим моментом є те, що стадії F1-F2 вважаються оборотними при своєчасному лікуванні, якщо усунути причину пошкодження, печінка здатна поступово розщепити надлишок сполучної тканини і відновити свою структуру, тоді як стадії F3-F4 призводять до незворотних змін [14]. Тому ранне

виявлення та моніторинг фіброзу є критично важливими для збереження здоров'я пацієнта.

## 2.2 Методи діагностики фіброзу печінки

Протягом багатьох десятиліть біопсія печінки вважалася єдиним надійним методом визначення ступеня фіброзу. Ця процедура полягає в тому, що за допомогою спеціальної голки через шкіру береться маленький шматочок тканини печінки (зразок розміром приблизно 1-2 см). Потім цей зразок досліджують під мікроскопом, де патолог оцінює ступінь фіброзу, кількість запальних клітин та інші характеристики [15].

Переваги біопсії:

- Дозволяє безпосередньо побачити структуру тканини печінки;
- Дає можливість оцінити не тільки фіброз, але й інші патологічні зміни;
- Забезпечує детальну гістологічну інформацію для точної діагностики [16].

Однак біопсія має численні серйозні недоліки. Вона є інвазивною процедурою, що супроводжується ризиком кровотеч, болю, інфекцій та навіть смертельних ускладнень. Вона викликає значний дискомфорт для пацієнта, потребує госпіталізації та має високу вартість. Крім того, результати можуть бути неточними через вибіркковість зразка і суб'єктивність оцінки патолога, а через ризики та складність проведення її неможливо часто повторювати, що робить біопсію непридатною для регулярного моніторингу стану печінки [17].

Враховуючи всі перелічені недоліки біопсії, медики активно шукає альтернативні, неінвазивні методи оцінки фіброзу печінки.

Існують неінвазивні методи оцінки фіброзу печінки, серед яких серологічні тести (наприклад FibroTest, APRI, FIB-4), що базуються на аналізі біохімічних показників крові, та ультразвукова еластографія, яка визначає

жорсткість тканини печінки [18,19]. Серологічні методи є простими, безпечними й доступними, проте мають обмежену точність, тоді як еластографія забезпечує більш об'єктивну оцінку структури органу, хоча потребує дорогого обладнання. У цілому, найінформативнішим і перспективним напрямом діагностики фіброзу залишається ультразвукова візуалізація, яка дозволяє безпечно та точно оцінювати стан печінкової тканини [19]. Порівняння методів діагностики фіброзу представлені у табл. 2.1.

Таблиця 2.1 – Порівняння методів діагностики фіброзу печінки

Тип обстеження	Біопсія	Фібросканування	УЗД еластографія	МРТ еластографія
<b>Пояснення</b>	Лікар вводить довгу порожнисту голку у живіт, щоб взяти тканини з печінки	Використовуються звукові хвилі для визначення жорсткості печінки (жорсткість вказує на фіброз). Для отримання зображення маленький зонд переміщуються по животу.	Використовуються детальніші звукові хвилі для відображення жорсткості в режимі реального часу. Для отримання зображення маленький зонд переміщується по животу.	Використовується магнітно-резонансна томографія для відображення жорсткості печінки з високою точністю. Апарат МРТ – це довга «капсула», в якій лежить людина, поки магніти рухаються навколо неї для отримання зображення.
<b>Точність</b>	Відмінна	Добра	Дуже добра	Відмінна
<b>Досліджувана ділянка</b>	Дуже мала	Мала	Велика	Дуже велика
<b>Спостереження в реальному часі</b>	Так	Ні	Так	Так
<b>Інвазивність</b>	Інвазивна	Неінвазивна	Неінвазивна	Неінвазивна
<b>Час</b>	Декілька годин(разом із седациєю)	5 хвилин	5 хвилин	45 хвилин
<b>Вартість</b>	Дорого	Дешево	Дешево	Дуже дорого

Ультразвукова візуалізація найперспективніший напрямок, який активно розвивається останніми роками. Метод базується на тому, що фіброз змінює

структуру паренхіми (тканини) печінки, і ці зміни можна побачити на звичайних ультразвукових зображеннях.

При фіброзі в печінці відбуваються зміни, які впливають на те, як ультразвукові хвилі відбиваються від тканини:

- Змінюється розподіл великих судин та жовчних проток;
- Порушується однорідність тканини через формування вузлів та перегородок;
- Змінюється ехогенність (яскравість) різних ділянок печінки;
- З'являються характерні візуальні патерни (візерунки) [20].

На основі ультразвукових зображень можна робити текстурний аналіз УЗ зображень або просто класифікувати наявні зображення за допомогою нейронних мереж [21]. Цей підхід є наразі найактуальнішим у цій сфері, так як використовується стандартне обладнання УЗД обладнання, вартість дослідження низька, є неінвазивним методом.

Головна проблема текстурного аналізу УЗ зображень полягає в тому, що людському оку важко або взагалі неможливо оцінити всі тонкі відмінності в текстурі печінки на різних стадіях фіброзу [22]. Зміни часто настільки незначні, що навіть досвідчений лікар УЗД не може точно визначити стадію фіброзу лише за зовнішнім виглядом зображення. Саме тут на допомогу приходить класифікація за допомогою нейронних мереж.

### **2.3 Задача класифікації в контексті діагностики фіброзу**

Класифікація є однією з фундаментальних задач машинного навчання, яка полягає в тому, щоб навчити комп'ютер автоматично відносити об'єкти до певних категорій або класів на основі їх характеристик [5]. У контексті медичної діагностики фіброзу печінки задача класифікації формулюється наступним чином: маючи ультразвукове зображення паренхіми печінки, необхідно визначити, до якої стадії фіброзу за шкалою METAVIR (F0, F1, F2,

F3 або F4) та проміжних стадій (F1-2, F2-3, F3-4) належить стан печінки пацієнта.

Класифікація відрізняється від інших типів задач машинного навчання тим, що результатом роботи алгоритму є дискретна мітка класу, а не числове значення. Наприклад, алгоритм не намагається передбачити точний відсоток фіброзної тканини в печінці (це була б задача регресії), а визначає конкретну стадію захворювання. Це робить задачу більш прикладною з медичної точки зору, оскільки лікарі саме так і працюють з діагнозами – вони ставлять конкретний діагноз, який потім визначає стратегію лікування.

Задачу класифікації фіброзу можна розглядати як багатокласову класифікацію, оскільки існує вісім можливих класів. Її можна спростити до бінарної класифікації, коли необхідно лише визначити, чи є у пацієнта значний фіброз (F3-F4) чи ні (F0-F2). Водночас детальніша класифікація на всі вісім стадій дає більше інформації для моніторингу прогресування захворювання та оцінки ефективності лікування.

Побудова класифікатора для діагностики фіброзу на основі УЗ зображень є технічно складною задачею з кількох причин:

- УЗ зображення паренхіми печінки мають досить однорідну структуру, і відмінності між різними стадіями фіброзу можуть бути дуже тонкими;
- якість УЗ зображень може варіюватися в залежності від обладнання, налаштувань апарату та кваліфікації оператора;
- індивідуальні особливості пацієнта можуть впливати на характеристики зображення.

Саме тому класичні методи комп'ютерного зору та прості статистичні підходи часто показують недостатню точність, і виникає необхідність у застосуванні більш потужних методів, зокрема глибокого навчання.

## 2.4 Принципи роботи згорткових нейронних мереж

Згорткові нейронні мережі представляють собою спеціалізований тип архітектури нейронних мереж, який був розроблений спеціально для роботи з зображеннями. На відміну від звичайних повнозв'язних нейронних мереж, де кожен нейрон з'єднаний з усіма нейронами попереднього шару, згорткові мережі використовують локальні з'єднання та спільні ваги, що дозволяє їм ефективно виявляти просторові патерни в зображеннях [23].

Ідея згорткових мереж була частково натхненна біологічною організацією зорової кори головного мозку, де різні нейрони реагують на стимули в обмежених областях зорового поля, які називаються рецептивними полями [24]. Аналогічно, згорткові нейронні мережі обробляють зображення, аналізуючи невеликі локальні ділянки і поступово будуючи більш складне уявлення про вміст зображення.

Основною операцією в згорткових мережах є операція згортки, яка дала назву цьому типу архітектури. Суть згортки полягає в тому, що невелике вікно, яке називається фільтром або ядром, ковзає по всьому зображенню, і в кожній позиції обчислюється скалярний добуток між значеннями пікселів у вікні та вагами фільтра [25].

Типова згорткова нейронна мережа для класифікації зображень складається з декількох типів шарів, кожен з яких виконує специфічну функцію в процесі обробки та аналізу зображення (див. рис. 2.2) [26].

Головні елементи:

- Згортковий шар (Convolutional Layer) – головний будівельний блок CNN. Він застосовує набір навчуваних фільтрів (зазвичай  $3 \times 3$  або  $5 \times 5$ ) до зображення, виділяючи різні типи ознак — від простих контурів до складних текстур. Кожен фільтр створює свою карту ознак [26];

- Функція активації (Activation Function) – вносить нелінійність у модель. Найчастіше використовується ReLU, яка замінює від'ємні значення на нуль, прискорюючи навчання і підвищуючи ефективність [26];

- Шар пулінгу (Pooling Layer) – зменшує розмір карт ознак, зберігаючи найважливішу інформацію. Зазвичай застосовується max pooling (наприклад,  $2 \times 2$ ), що зменшує просторові розміри та забезпечує стійкість до невеликих зсувів і деформацій [26];
- Шар розплющення (Flatten Layer) – перетворює багатовимірні карти ознак у одновимірний вектор, підготовлений для подальшої класифікації [26];
- Повнозв'язні шари (Fully Connected Layers) – поєднують усі витягнуті ознаки для прийняття остаточного рішення. Використовуються один або кілька таких шарів із активацією ReLU [26];
- Вихідний шар (Output Layer) – формує кінцевий прогноз. Для класифікації застосовується softmax, що перетворює виходи в ймовірності приналежності до класів (наприклад, F0–F4 при класифікації стадій фіброзу) [26].

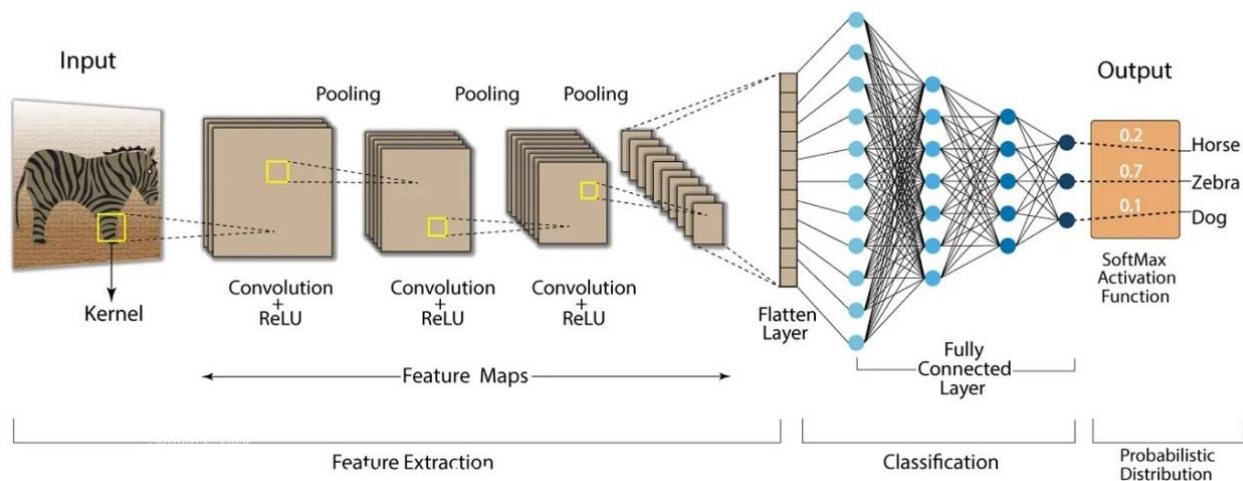


Рисунок 2.2 – Структура згорткової нейронної мережі [27]

Застосування згорткових нейронних мереж для медичної діагностики, зокрема для визначення ступеня фіброзу печінки, має свої особливості та виклики, які необхідно враховувати при розробці системи. Одна з найбільших проблем у медичному машинному навчанні – це обмежена кількість даних. Збір

великого набору УЗ зображень печінки з підтвердженими діагнозами фіброзу є складним завданням, оскільки це вимагає наявності результатів біопсії або інших надійних методів діагностики для кожного пацієнта. При цьому сучасні CNN, особливо глибокі архітектури, зазвичай потребують тисяч або навіть десятків тисяч прикладів для належного навчання.

Валідація моделі має проводитися на незалежному наборі даних, який не використовувався під час навчання і налаштування гіперпараметрів [28]. В ідеалі бажано тестувати модель на даних з інших медичних центрів, отриманих на різному обладнанні, щоб переконатися в її надійності та можливості застосування в реальній клінічній практиці. Також важливо оцінити, наскільки добре модель працює для різних груп пацієнтів, які можуть відрізнятися за віком, статтю, індексом маси тіла та іншими характеристиками [28]. Але в нашій задачі класифікації дані використовуються з одного медичного центру та одного апарату.

## **2.5 Поняття текстури в медичних зображеннях**

Текстура є одним з найважливіших понять у комп'ютерному аналізі зображень, особливо коли мова йде про медичну діагностику. Якщо спростити, текстура описує те, як розподілені відтінки сірого по зображенню, які закономірності у їх розташуванні, наскільки однорідною або хаотичною є структура. Людське око здатне розрізняти різні текстури інтуїтивно – ми легко відрізняємо гладку поверхню від шорсткої, однорідну від неоднорідної, навіть якщо вони мають схожі середні відтінки. Однак для комп'ютерного аналізу необхідно перетворити це інтуїтивне розуміння у набір числових характеристик, які можна виміряти та порівняти [29].

У контексті ультразвукових зображень печінки текстура відображає мікроструктуру паренхіми - тобто те, як організовані клітини печінки, кровоносні судини, жовчні протоки та сполучна тканина. Здорова печінка має досить однорідну текстуру з тонким зернистим патерном, який виникає

внаслідок розсіювання ультразвукових хвиль на численних дрібних структурах всередині органу. При розвитку фіброзу ця текстура змінюється - з'являються ділянки з підвищеною або зниженою ехогенністю, порушується однорідність, можуть формуватися грубші текстурні патерни. Саме ці зміни і намагаються виявити за допомогою текстурного аналізу [30].

Важливо розуміти, що текстурний аналіз не намагається виміряти якусь одну властивість зображення. Натомість він обчислює множину різних характеристик, кожна з яких описує певний аспект текстури. Деякі характеристики відображають загальну яскравість та контрастність зображення, інші – наскільки регулярною або хаотичною є структура, треті – наявність певних спрямованих патернів. Комбінація всіх цих характеристик створює багатовимірний опис текстури, який може бути використаний для класифікації зображень за допомогою методів машинного навчання [31].

Текстурний аналіз медичних зображень має довгу історію і широко використовується не тільки для УЗД, але й для аналізу рентгеновських знімків, комп'ютерної томографії, магнітно-резонансної томографії. Успіх цього підходу пояснюється тим, що багато патологічних процесів призводять до змін на мікроскопічному рівні, які проявляються як зміни текстури на медичних зображеннях, навіть коли ці зміни важко помітити неозброєним оком .

Існує декілька фундаментально різних підходів до кількісного опису текстури зображень. Кожен з них базується на певних математичних концепціях і дозволяє виявити різні аспекти текстурних характеристик [32]:

- Статистичні методи є найпоширенішими і базуються на аналізі розподілу значень яскравості пікселів та їх просторових взаємозв'язків. Ці методи можна поділити на методи першого порядку, які розглядають кожен піксель незалежно, і методи вищих порядків, які аналізують співвідношення між пікселями. До статистичних методів належать аналіз гістограм, матриці суміжності відтінків сірого, матриці довжин серій однакових відтінків та інші підходи, які будуть детально розглянуті далі [32];

- Структурні методи намагаються описати текстуру як композицію з простих елементів, які повторюються за певними правилами. Цей підхід добре працює для регулярних текстур, де можна виділити базові елементи та описати їх просторове розташування. Однак для медичних зображень, які зазвичай мають складну нерегулярну структуру, структурні методи застосовуються рідше [32];

- Спектральні методи аналізують текстуру в частотній області за допомогою різних математичних перетворень, таких як перетворення Фур'є або вейвлет-перетворення. Ідея полягає в тому, що різні текстури мають різний частотний спектр – дрібнозерниста текстура характеризується переважанням високих частот, а грубозерниста – низьких частот. Спектральні методи особливо корисні для виявлення періодичних структур або для аналізу текстур на різних масштабах [32];

- Модельні методи намагаються побудувати математичну модель процесу формування текстури. Найвідомішим прикладом є моделі Маркова, які описують, як значення яскравості в певній точці залежить від значень у сусідніх точках. Якщо вдається побудувати адекватну модель, то параметри цієї моделі можуть служити характеристиками текстури [32].


У медичному аналізі зображень найчастіше використовуються статистичні методи через їх універсальність, обчислювальну ефективність та добру інтерпретованість. Саме тому далі ми детально розглянемо три основні статистичні підходи до текстурного аналізу, які широко застосовуються для аналізу ультразвукових зображень печінки.

## **2.6 Поняття гістограми зображення**

Гістограма є найпростішим і водночас надзвичайно інформативним способом опису розподілу яскравостей у зображенні. По суті, гістограма показує, скільки пікселів у зображенні мають кожне з можливих значень

яскравості. Для типових цифрових зображень, які зберігаються у восьмибітному форматі, існує 256 можливих відтінків сірого – від нуля (чорний) до двохсот п'ятдесяти п'яти (білий). Гістограма будується шляхом підрахунку кількості пікселів для кожного з цих значень [33].

Математично гістограму можна визначити як функцію  $h(i)$ , де  $i$  – це значення відтінку сірого (від 0 до 255), а  $h(i)$  – кількість пікселів у зображенні, які мають це значення. Графічно гістограма зображується у вигляді стовпчикової діаграми, де по горизонтальній осі відкладені значення відтінків сірого, а по вертикальній – кількість (або частка) пікселів з відповідним відтінком. Форма гістограми дає багато інформації про зображення. Наприклад, якщо гістограма зміщена вліво (у бік темних відтінків), зображення в цілому темне. Якщо гістограма має вузький пік, зображення має низький контраст. Якщо гістограма рівномірно розподілена по всьому діапазону, зображення має високий контраст та використовує весь доступний діапазон яскравостей (див. рис. 2.3) [33].



А)

Рисунок 2.3 – Зображення (а) та його гістограма відтінків сірого (б)




Рисунок 2.4, аркуш 2

У контексті аналізу ультразвукових зображень печінки форма гистограми може дати важливу інформацію про стан органу. Здорова печінка зазвичай має відносно вузьку гистограму з піком у середньому діапазоні сірого, що відповідає однорідній ехогенності паренхіми. При розвитку фіброзу гистограма може розширюватися, оскільки з'являються ділянки з різною ехогенністю. Може змінюватися положення піку, асиметрія розподілу або з'являтися додаткові піки, що вказує на неоднорідність структури печінки.

Хоча гистограма сама по собі містить повну інформацію про розподіл яскравостей, для практичного використання в алгоритмах класифікації зручніше мати набір числових характеристик, які узагальнюють цю інформацію. Ці характеристики називаються статистичними моментами або параметрами першого порядку, оскільки вони розглядають кожен піксель незалежно, не враховуючи його просторові відношення з сусідніми пікселями [33].

Середнє значення (Mean) є найпростішою характеристикою і показує середню яскравість зображення. Воно обчислюється як арифметичне середнє всіх значень пікселів (2.1) [34].

$$\mu = \sum_{i=1}^N g_i p_i \quad (2.1)$$

де

$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)}$  - нормалізована гистограма

$\text{hist}(i)$  - кількість пікселів, що попали в  $i$ -й проміжок гистограми  $g_i$  – центр  $i$ -го проміжку ( $g_i \in [0,1]$ )

$N$  - кількість бінів.

Середнє значення дає уявлення про загальну яскравість зображення. Для ультразвукових зображень печінки зміна середньої ехогенності може вказувати на патологічні процеси – наприклад, при жировій інфільтрації печінка стає більш яскравою (гіперехогенною).

Дисперсія (Variance) (2.2) і її квадратний корінь – стандартне відхилення (Standard Deviation) (2.3) – характеризують розкид значень яскравості навколо середнього [34].

$$\sigma^2 = \sum_{i=1}^N (g_i - \mu)^2 p_i \quad (2.2)$$

де

$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)}$  - нормалізована гистограма

$\text{hist}(i)$  - кількість пікселів, що попали в  $i$ -й проміжок гистограми,  $g_i$  – центр  $i$ -го проміжку ( $g_i \in [0,1]$ )

$N$  - кількість бінів

$\mu$  – середнє значення.

$$\sigma = \sqrt{\sigma^2} = \sqrt{\sum_{i=1}^N (g_i - \mu)^2 p_i} \quad (2.3)$$

де

$$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)} - \text{нормалізована гистограма}$$

$\text{hist}(i)$  - кількість пікселів, що попали в  $i$ -й проміжок гистограми,  $g_i$  – центр  $i$ - го проміжку ( $g_i \in [0,1]$ )

$N$  - кількість бінів

$\mu$  – середнє значення.

Дисперсія показує, наскільки сильно значення яскравості відрізняються від середнього. Високе стандартне відхилення вказує на високий контраст зображення – наявність як дуже темних, так і дуже світлих ділянок. Низьке стандартне відхилення характерне для однорідних зображень з невеликою варіацією яскравості. У контексті фіброзу печінки збільшення дисперсії може вказувати на зростання неоднорідності паренхіми через формування фіброзних перегородок та вузлів.

Асиметрія (Skewness) описує симетричність розподілу яскравостей відносно середнього значення (2.4) [34].

$$\text{Skew} = \frac{\sum_{i=1}^N (g_i - \mu)^3 p_i}{\sigma^3} \quad (2.4)$$

де

$$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)} - \text{нормалізована гистограма}$$

$\text{hist}(i)$  - кількість пікселів, що попали в  $i$ -й проміжок гистограми,  $g_i$  – центр  $i$ - го проміжку ( $g_i \in [0,1]$ )

$N$  - кількість бінів

$\mu$  – середнє значення

$\sigma$  – дисперсія.

Асиметрія може бути додатною, від'ємною або близькою до нуля. Нульова асиметрія відповідає симетричному розподілу (наприклад, нормальному розподілу Гауса). Додатна асиметрія (правостороння) означає, що хвіст розподілу витягнутий у бік високих значень – у зображенні переважають темніші відтінки, але є невелика кількість дуже яскравих пікселів. Від'ємна

асиметрія (лівостороння) характерна для зображень, де переважають яскраві відтінки з невеликою кількістю темних пікселів. Зміни асиметрії при фіброзі можуть відображати появу нових структур із відмінною ехогенністю.

Ексцес (Kurtosis) характеризує "гостроту" піку розподілу та товщину його хвостів (2.5) [34].

$$\text{Kurtosis} = \frac{\sum_{i=1}^N (g_i - \mu)^4 p_i}{\sigma^4} - 3 \quad (2.5)$$

де

$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)}$  - нормалізована гістограма

hist(i) - кількість пікселів, що попали в i-й проміжок гістограми,  $g_i$  - центр i-го проміжку ( $g_i \in [0,1]$ )

N - кількість бінів

$\mu$  - середнє значення

$\sigma$  - дисперсія.

Віднімання трьох виконується для того, щоб ексцес нормального розподілу дорівнював нулю (така нормалізація називається надлишковим ексцесом). Додатний ексцес вказує на гострий пік із товстими хвостами - більшість значень зосереджена близько до середнього, але є значна кількість екстремальних значень. Від'ємний ексцес характерний для більш рівномірного розподілу з плоским піком. У медичному контексті високий ексцес може вказувати на наявність аномальних структур, які різко відрізняються за ехогенністю від основної паренхіми.

Енергія або однорідність (Energy/Uniformity) вимірює, наскільки розподіл яскравостей є рівномірним або зосередженим (2.6) [34].

$$E = \sum_{i=1}^N p_i^2 \quad (2.6)$$

де

$$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)} - \text{нормалізована гистограма}$$

hist(i) - кількість пікселів, що попали в i-й проміжок гистограми

N - кількість бінів.

Енергія досягає максимального значення, коли всі пікселі мають однаковий відтінок (абсолютно однорідне зображення), і мінімального – коли яскравості рівномірно розподілені по всьому діапазону. Для ультразвукових зображень печінки висока енергія відповідає однорідній паренхімі, що характерно для здорової печінки.

Ентропія (Entropy) є мірою невизначеності або хаотичності розподілу яскравостей (2.7) [34].

$$H = - \sum_{i=1}^N p_i \log_2(p_i + \varepsilon) \quad (2.7)$$

де

$$p_i = \frac{\text{hist}(i)}{\sum_j \text{hist}(j)} - \text{нормалізована гистограма}$$

hist(i) - кількість пікселів, що попали в i-й проміжок гистограми

N - кількість бінів

$$\varepsilon \approx 10^{-8}$$

Ентропія має протилежну інтерпретацію порівняно з енергією. Низька ентропія характерна для однорідних зображень з передбачуваною структурою, висока ентропія – для складних, хаотичних текстур. При розвитку фіброзу ентропія зазвичай зростає через збільшення різноманітності текстурних елементів.

Статистичні характеристики першого порядку мають кілька важливих переваг для медичного аналізу зображень. По-перше, вони дуже прості у обчисленні – для їх розрахунку достатньо один раз пройти по всіх пікселях зображення. По-друге, вони мають ясну фізичну інтерпретацію і можуть бути

легко зрозумілі лікарям без глибоких знань математики. По-третє, вони досить стійкі до невеликих шумів та артефактів у зображеннях.

Однак у цих характеристик є суттєвий недолік – вони не враховують просторове розташування пікселів. Два зображення з абсолютно різною текстурою можуть мати ідентичні гістограмні характеристики, якщо вони мають однаковий розподіл яскравостей. Наприклад, зображення з випадково розташованими світлими та темними пікселями матиме таку саму гістограму, як зображення з чіткою структурою із світлих та темних смуг, хоча текстири цих зображень кардинально відрізняються .

Саме тому для повноцінного текстурного аналізу необхідно доповнити характеристики першого порядку параметрами вищих порядків, які враховують просторові співвідношення між пікселями. Найважливішими з таких методів є матриця суміжності відтінків сірого та матриця довжин серій, які будуть розглянуті далі.

## **2.7 Матриця суміжності відтінків сірого**

Матриця суміжності відтінків сірого, яка часто позначається аббревіатурою GLCM, є одним з найпотужніших та найпоширеніших методів текстурного аналізу зображень. Цей метод був запропонований Робертом Хараліком та його колегами у 1973 році і з тих пір став стандартним інструментом у комп'ютерному зорі та медичному аналізі зображень [35].

Основна ідея GLCM полягає в аналізі того, як часто пари пікселів з певними значеннями яскравості розташовані поруч одне з одним у зображенні. На відміну від простої гістограми, яка розглядає кожен піксель окремо, GLCM враховує просторові взаємозв'язки між пікселями, що дозволяє виявити організацію текстури (див. рис. 2.4) [35].

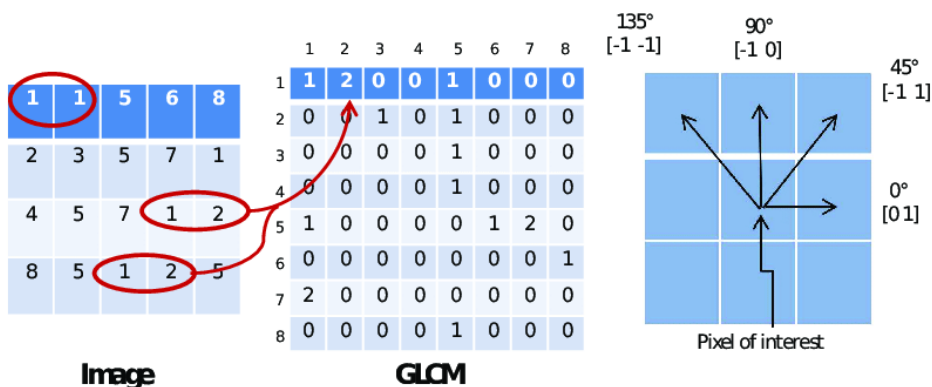


Рисунок 2.5 – Алгоритм матриці суміжності відтінків сірого

Формально, матриця суміжності показує, скільки разів у зображенні піксель зі значенням яскравості  $i$  розташований на відстані  $d$  у напрямку  $\theta$  від пікселя зі значенням яскравості  $j$ . Тут  $i$  та  $j$  – це відтінки сірого (зазвичай від 0 до 255),  $d$  – відстань між пікселями (зазвичай 1, 2 або 3 пікселі),  $\theta$  – кут напрямку (зазвичай  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  або  $135^\circ$ ) [35].

Така матриця містить інформацію про локальну структуру текстури. Якщо зображення має однорідну текстуру, де сусідні пікселі зазвичай мають схожі значення, то в матриці суміжності будуть великі значення на головній діагоналі і малі значення поза діагоналлю. Якщо ж текстура має високий контраст з різкими переходами між яскравими та темними ділянками, то в матриці будуть великі значення далеко від діагоналі [35].

Процес побудови GLCM для реального зображення включає кілька кроків. Спочатку необхідно визначити параметри: відстань  $d$  та напрямок  $\theta$ . Відстань  $d$  зазвичай вибирають невеликою (1-3 пікселі), оскільки текстурні властивості найбільш виражені на локальному рівні. Напрямок може бути  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  або  $135^\circ$ . Часто обчислюють матриці для всіх чотирьох напрямків і потім усереднюють їх [35].

Для зображень медичної діагностики, включаючи ультразвукові зображення печінки, часто виконують квантування рівнів яскравості перед побудовою GLCM. Замість використання всіх 256 можливих відтінків сірого, діапазон яскравостей розділяють на менше число рівнів, наприклад 16, 32 або

64. Це робиться з кількох причин: зменшується розмір матриці суміжності (матриця 64x64 замість 256x256), що прискорює обчислення, квантування діє як фільтр шуму, згладжуючи випадкові флуктуації яскравості, менша кількість рівнів дає більш стабільну статистику [35].

Після підрахунку всіх пар пікселів матриця суміжності зазвичай нормалізується шляхом ділення всіх елементів на їх суму, щоб перетворити абсолютні частоти у відносні ймовірності. Нормалізована матриця може інтерпретуватися як спільний розподіл ймовірностей для пар сусідніх пікселів [35].

З матриці суміжності можна обчислити численні статистичні характеристики, які описують різні аспекти текстури. Роберт Харалик у своїй оригінальній роботі запропонував 14 текстурних ознак, які стали класичними у комп'ютерному зорі [36]. Розглянемо найважливіші з них детально.

Енергія вимірює однорідність текстури (2.8)

$$ASM = \sum_{i=1}^N \sum_{j=1}^N P(i, j)^2 \quad (2.8)$$

де

$P(i, j)$  – нормалізоване значення ймовірності появи пари пікселів із рівнями сірого  $i$  та  $j$  у матриці GLCM

$N$  – кількість рівнів сірого.

Енергія досягає максимального значення для константного зображення, де всі пікселі мають однаковий відтінок. Для складних текстур з багатьма різними парами значень енергія буде низькою. У медичному контексті висока енергія відповідає однорідній паренхімі, що характерно для здорової печінки або ранніх стадій фіброзу [36].

Контраст вимірює інтенсивність відмінностей між пікселем та його сусідами (2.9).

$$Contrast = \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 P(i, j) \quad (2.9)$$

де

$P(i, j)$  – елемент нормалізованої матриці спільних рівнів сірого (GLCM), що описує ймовірність сумісної появи значень  $i$  та  $j$

$N$  – кількість рівнів сірого.

Контраст приймає високі значення, коли в зображенні є різкі перепади яскравості між сусідніми пікселями. Низький контраст характерний для гладких, поступово змінюваних текстур. При розвитку фіброзу печінки контраст зазвичай зростає через формування неоднорідної структури з чергуванням ділянок різної ехогенності [36].

Кореляція вимірює лінійну залежність між значеннями сусідніх пікселів (2.10)

$$Correlation = \frac{\sum_{i=1}^N \sum_{j=1}^N (i - \mu_i)(j - \mu_j) P(i, j)}{\sigma_i \sigma_j} \quad (2.10)$$

де

$P(i, j)$  – елемент нормалізованої матриці співпадиння рівнів сірого (GLCM)  
 $\mu_i, \mu_j$  – середні значення по рядках  $i$  стовпцях відповідно

$\sigma_i, \sigma_j$  – стандартні відхилення

$N$  – кількість рівнів сірого.

Висока кореляція вказує на те, що значення яскравості сусідніх пікселів передбачувані одне з одного, що характерно для структурованих текстур. Низька кореляція відповідає більш випадковим текстурам.

Дисперсія розкид значень у матриці суміжності (2.11).

$$Variance = \sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 P(i, j) \quad (2.11)$$

де

$P(i, j)$  – нормалізоване значення матриці співпадиння рівнів сірого (GLCM)

$\mu$  – середнє значення сірого рівня

$N$  – кількість рівнів інтенсивності.

Дисперсія характеризує варіабельність текстури і зростає при наявності великої кількості різних текстурних елементів [36].

Однорідність (Homogeneity) вимірює близькість розподілу елементів GLCM до діагоналі (2.12).

$$IDM = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1 + (i - j)^2} \quad (2.12)$$

де

$P(i, j)$  – нормалізований елемент матриці співпадіння рівнів сірого (GLCM)

$N$  – кількість рівнів інтенсивності.

Висока однорідність означає, що більшість пар пікселів мають схожі значення яскравості. Ця характеристика протилежна за змістом до контрасту – текстури з високою однорідністю мають низький контраст і навпаки. Для здорової печінки характерна висока однорідність через рівномірну структуру паренхіми [36].

Ентропія вимірює складність або хаотичність текстури (2.13)

$$Entropy = - \sum_{i=1}^N \sum_{j=1}^N P(i, j) \log_2 (P(i, j) + \epsilon) \quad (2.13)$$

де

$P(i, j)$  – нормалізований елемент матриці співпадіння рівнів сірого (GLCM)

$N$  – кількість рівнів інтенсивності

$\epsilon$  – мале додатне число, яке запобігає логарифмуванню нуля.

Ентропія досягає максимуму для випадкових текстур і мінімуму для однорідних. Вона є мірою інформаційного вмісту текстури – чим більш складною та непередбачуваною є текстура, тим вища ентропія. При фіброзі печінки ентропія зазвичай зростає через збільшення складності текстурних патернів [36].

Дослідження показали, що характеристики GLCM є високоінформативними для оцінки фіброзу печінки за ультразвуковими зображеннями. При прогресуванні фіброзу спостерігаються наступні закономірності у зміні текстурних параметрів: контраст зазвичай зростає від стадії F0 до F4, оскільки формування фіброзних перегородок та регенераційних вузлів створює неоднорідність з чергуванням ділянок різної ехогенності; однорідність, навпаки, зменшується, відображаючи втрату нормальної однорідної структури паренхіми; ентропія зростає через збільшення складності та непередбачуваності текстурного патерну; кореляція може змінюватися неоднозначно в залежності від типу фіброзу та стадії захворювання.

## **2.8 Матриця довжин серій відтінків сірого**

Матриця довжин серій відтінків сірого є альтернативним підходом до текстурного аналізу, який фокусується на іншому аспекті текстури порівняно з GLCM. Замість аналізу пар сусідніх пікселів, GLRLM розглядає послідовності пікселів з однаковим або близьким значенням яскравості, які розташовані вздовж певного напрямку. Така послідовність називається серією або пробігом [37].

Серія визначається трьома параметрами: значенням відтінку сірого  $i$ , довжиною серії  $j$  (кількість послідовних пікселів з цим відтінком), та напрямком  $\theta$ , вздовж якого розглядається послідовність. Матриця довжин серій показує, скільки разів у зображенні зустрічається серія з довжиною  $j$  пікселів, які мають відтінок  $i$ , у напрямку  $\theta$  [37].

Інтуїтивно, матриця довжин серій відображає грубість або тонкість текстури. Текстури з довгими серіями (великі значення в стовпцях з великими  $j$ ) є більш грубими, з великими однорідними ділянками. Текстури з короткими серіями (великі значення в стовпцях з малими  $j$ ) є більш тонкими, зернистими, з частими змінами яскравості. Для ультразвукових зображень печінки здорова паренхіма зазвичай має відносно довгі серії через однорідність структури, тоді

як фіброзна печінка характеризується коротшими серіями через зростання неоднорідності [37].

Процес побудови GLRLM починається з визначення напрямку аналізу. Як і для GLCM, зазвичай використовують чотири основні напрямки:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  та  $135^\circ$ . Для кожного напрямку алгоритм проходить через все зображення, виділяючи серії послідовних пікселів з однаковим або близьким відтінком [37].

Важливим питанням є визначення того, що вважати "однаковим" відтінком. У найпростішому варіанті до однієї серії належать тільки пікселі з абсолютно ідентичним значенням яскравості. Однак через шум в ультразвукових зображеннях такий підхід може призводити до фрагментації серій. Альтернативний підхід – дозволити невелику толерантність, наприклад вважати пікселі частиною однієї серії, якщо їх яскравості відрізняються не більше ніж на певне порогове значення.

Як і для GLCM, часто виконують квантування рівнів яскравості перед побудовою GLRLM. Це зменшує розмір матриці та робить статистику більш надійною. Зазвичай використовують від 16 до 64 рівнів квантування.

Розмір матриці GLRLM залежить від кількості рівнів яскравості та максимальної довжини серії. Максимальна довжина серії теоретично може дорівнювати розміру зображення (якщо все зображення складається з пікселів одного відтінку), але на практиці довгі серії зустрічаються рідко, і матрицю зазвичай обмежують розумною максимальною довжиною, наприклад 20 або 30 пікселів [37].

Після побудови матриці для всіх напрямків їх можна усереднити для отримання ротаційно-інваріантних характеристик, або використовувати окремо для виявлення анізотропії текстури.

З матриці довжин серій можна обчислити численні статистичні характеристики, кожна з яких описує певний аспект текстури. Розглянемо найважливіші з них:

Короткість серій (Short Run Emphasis, SRE) надає більшу вагу коротким серіям (2.14).

$$SRE = \sum_{i \in N_g} \sum_{j \in N_r} \frac{P_{ij}}{j^2} / \sum_{i \in N_g} \sum_{j \in N_r} P_{ij} \quad (2.14)$$

де

$P_{ij}$ – значення елементів матриці GLRLM

$N_g$ – кількість рівнів сірого

$N_r$ – кількість довжин пробігів.

Ця характеристика приймає високі значення для тонких текстур з частими змінами яскравості. Для ультразвукових зображень печінки високе значення SRE може вказувати на фіброз через збільшення неоднорідності паренхіми [37].

Довжина серій (Long Run Emphasis, LRE) надає більшу вагу довгим серіям (2.15).

$$LRE = \sum_{i \in N_g} \sum_{j \in N_r} j^2 P_{ij} / \sum_{i \in N_g} \sum_{j \in N_r} P_{ij} \quad (2.15)$$

де

$P_{ij}$ – елемент матриці GLRLM

$N_g$ – кількість рівнів сірого

$N_r$ – кількість довжин пробігів.

Ця характеристика протилежна за змістом до SRE і приймає високі значення для грубих текстур з великими однорідними ділянками. Здорова печінка зазвичай має вищі значення LRE порівняно з фіброзною [37].

Неоднорідність відтінків сірого (Gray Level Non-uniformity, GLN) вимірює розподіл сірих рівнів (2.16).

$$GLN = \sum_{i \in N_g} \left( \sum_{j \in N_r} P_{ij} \right)^2 / \sum_{i \in N_g} \sum_{j \in N_r} P_{ij} \quad (2.16)$$

де

$P_{ij}$ – значення елементів матриці GLRLM

$N_g$ – кількість рівнів сірого

$N_r$ – кількість довжин пробігів.

Низьке значення GLN означає, що серії рівномірно розподілені по різних рівнях яскравості, високе – що певні рівні яскравості домінують [37].

Неоднорідність довжин серій (Run Length Non-uniformity, RLN) вимірює розподіл довжин серій (2.17).

$$RLN = \sum_{j \in N_r} \left( \sum_{i \in N_g} P_{ij} \right)^2 / \sum_{i \in N_g} \sum_{j \in N_r} P_{ij} \quad (2.17)$$

де

$P_{ij}$ – елемент матриці GLRLM

$N_g$ – кількість рівнів сірого

$N_r$ – кількість довжин пробігів.

Високе значення RLN вказує на те, що серії певної довжини домінують у текстурі [37].

Відсоток серій (Run Percentage, RP) показує, яка частка пікселів не є частиною довгих однорідних серій (2.18).

$$RP = \sum_{i \in N_g} \sum_{j \in N_r} P_{ij} / N \quad (2.18)$$

де

$P_{ij}$ – елемент матриці GLRLM

$N_g$ – кількість рівнів сірого

$N_r$ – кількість довжин пробігів

$N$  – загальна кількість пікселів або пробігів (залежно від визначення в моделі).

Високий відсоток серій означає, що в зображенні багато коротких серій і часті зміни яскравості. Це характерно для тонких, деталізованих текстур. При фіброзі печінки RP зазвичай зростає [37].

Матриці довжин серій та матриці суміжності надають комплементарну інформацію про текстуру зображення. GLCM фокусується на локальних

взаємозв'язках між парами сусідніх пікселів і добре виявляє дрібномасштабні текстурні особливості. GLRLM аналізує більш протяжні структури та краще відображає грубість текстури на середньому масштабі.

Для ультразвукових зображень печінки обидва методи показали свою ефективність у виявленні фіброзу. Дослідження демонструють, що найкращі результати класифікації досягаються при використанні комбінації характеристик з обох методів, доповнених статистичними параметрами першого порядку. Така комбінація дозволяє описати текстуру паренхіми печінки з різних перспектив і максимізувати інформативність для класифікації.

## **Висновок з розділу 2**

У підсумку розділу показано, що фіброз печінки є наслідком тривалого ушкодження тканини при аутоімунних та інших захворюваннях і потребує раннього виявлення для запобігання незворотним змінам. Класичні методи оцінки фіброзу, насамперед біопсія, хоча й залишаються «золотим стандартом», мають суттєві обмеження, що стимулює розвиток неінвазивних підходів на основі ультразвукових зображень. Обґрунтовано доцільність використання згорткових нейронних мереж у поєднанні з текстурними характеристиками (гістограми, GLCM, GLRLM), які дозволяють формалізувати малопомітні для ока зміни структури паренхіми та створюють теоретичне підґрунтя для подальшої розробки програмної частин системи.

## РОЗДІЛ 3

### ОБҐРУНТУВАННЯ ВИБОРУ ПРОГРАМНОГО СЕРЕДОВИЩА

Розділ присвячений вибору програмних засобів, необхідних для створення системи класифікації фіброзу печінки на основі ультразвукових зображень. У ньому розглядаються основні інструменти, що забезпечують реалізацію алгоритмів обробки зображень, текстурного аналізу та глибокого навчання, а також засоби організації даних, візуалізації результатів і побудови графічного інтерфейсу. Обґрунтовується доцільність використання конкретних мов програмування, бібліотек та фреймворків, враховуючи вимоги до точності, продуктивності та зручності розробки медичних програмних систем.

#### 3.1 Вибір мови програмування

Для реалізації системи класифікації ступеня фіброзу печінки на основі ультразвукових зображень було обрано мову програмування Python версії 3.11. Цей вибір зумовлений кількома ключовими факторами, що робить Python оптимальним інструментом для розробки систем машинного навчання в медичній діагностиці [38]:

- Python є найпопулярнішою мовою програмування в галузі машинного навчання та аналізу даних, що підтверджується дослідженнями Stack Overflow Developer Survey [39]. Така популярність забезпечує доступ до величезної кількості бібліотек, готових рішень та активної спільноти розробників, що суттєво прискорює процес розробки;
- Python характеризується простим та зрозумілим синтаксисом, що дозволяє зосередитися на логіці алгоритмів класифікації, а не на технічних особливостях мови. Це особливо важливо при реалізації складних архітектур згорткових нейронних мереж та багатоетапних систем обробки зображень;
- Python має потужну екосистему спеціалізованих бібліотек для машинного навчання, комп'ютерного зору та обробки медичних зображень [40].

Наявність оптимізованих бібліотек з підтримкою GPU-обчислень забезпечує високу продуктивність при тренуванні глибоких нейронних мереж;

- Python підтримує різні парадигми програмування (об'єктно-орієнтовану, функціональну, процедурну), що дозволяє гнучко структурувати код системи та забезпечити його модульність.

## **3.2 Бібліотеки для обробки та аналізу зображень**

### **3.2.1 OpenCV**

Бібліотека OpenCV (open source computer vision library) використовувалася для базової передобробки ультразвукових зображень. OpenCV є однією з найпотужніших та найпоширеніших бібліотек комп'ютерного зору з відкритим вихідним кодом, що містить понад 2500 оптимізованих алгоритмів [41].

В контексті даного дослідження OpenCV застосовувалася для виконання таких операцій: завантаження та збереження зображень у різних форматах; зміна розміру зображень для приведення до уніфікованого формату входу нейронних мереж; конвертація колірних просторів; нормалізація контрасту зображень.

### **3.2.2 Scikit-image**

Бібліотека scikit-image (skimage) застосовувалася для витягнення текстурних ознак із ультразвукових зображень. Ця бібліотека є частиною екосистеми SciPy та спеціалізується на алгоритмах обробки зображень наукового рівня.

Основні можливості skimage, використані в роботі: обчислення матриці суміжностей градацій сірого для аналізу текстури; витягнення статистичних характеристик текстури (контраст, кореляція, енергія, гомогенність).

Використання текстурних ознак є критично важливим для аналізу ультразвукових зображень печінки, оскільки фіброз проявляється саме через зміну текстурних характеристик тканини.

### **3.3 Бібліотеки для чисельних обчислень та статистики**

#### **3.3.1 NumPy**

NumPy (Numerical Python) є фундаментальною бібліотекою для наукових обчислень у Python [42]. Вона використовувалася для ефективної роботи з багатовимірними масивами та векторними операціями над зображеннями.

Ключові переваги NumPy в контексті дослідження: підтримка n-вимірних масивів з ефективним використанням пам'яті; векторизовані операції, що значно прискорюють обчислення порівняно з циклами Python; широкий набір математичних функцій [42].

NumPy слугує базисом для більшості інших бібліотек наукових обчислень, включаючи TensorFlow, що забезпечує їх сумісність та ефективну взаємодію.

#### **3.3.2 SciPy**

Бібліотека SciPy розширює можливості NumPy додатковими модулями для наукових та інженерних обчислень [43]. У даній роботі SciPy застосовувалася для обчислення статистичних характеристик розподілу гістограми зображень.

Основні використані функції: статистичний аналіз розподілів (`scipy.stats`); обчислення моментів розподілу, асиметрії та ексцесу.

Статистичні характеристики гістограм доповнюють текстурні ознаки та надають додаткову інформацію про структуру тканини печінки.

#### **3.3.3 Pandas**

Бібліотека Pandas використовувалася для роботи з фінальними ймовірностями класифікації та структурування результатів експериментів. Pandas надає високорівневі структури даних (`DataFrame`, `Series`) та інструменти для аналізу даних.

Функціональність Pandas, застосована в дослідженні: організація результатів прогнозування у табличному форматі; агрегація ймовірностей від різних моделей; обчислення метрик якості класифікації; експорт результатів у різні формати (`CSV`, `Excel`); статистичний аналіз розподілу класів.

### **3.4 Бібліотеки для машинного навчання**

#### **3.4.1 TensorFlow та Keras**

TensorFlow є провідним фреймворком з відкритим кодом для машинного навчання, розробленим компанією Google. Keras, що інтегрована в TensorFlow як високорівневий API, використовувалася для побудови та тренування згорткових нейронних мереж.

Обґрунтування вибору TensorFlow/Keras:

- можливість побудови як стандартних, так і кастомізованих архітектур CNN для обробки як оригінальних зображень, так і текстурних карт;
- підтримка GPU-прискорення через CUDA, що критично важливо для тренування глибоких мереж на великих наборах медичних зображень [44];
- доступ до претренованих моделей (VGG, ResNet, Inception, EfficientNet) через Keras Applications, що дозволяє застосовувати трансферне навчання [45];
- високорівневий інтерфейс Keras спрощує процес створення, компіляції та тренування моделей, зберігаючи при цьому можливість низькорівневого контролю;
- вбудовані механізми callbacks для відстеження процесу навчання, збереження найкращих моделей та раннього зупинення;
- інтегрована система візуалізації для аналізу метрик навчання, архітектури моделі та активацій нейронів.

В роботі TensorFlow/Keras застосовувалися для: тренування CNN на оригінальних ультразвукових зображеннях; тренування спеціалізованих CNN на текстурних картах; реалізації ансамблевих методів;

#### **3.4.2 Scikit-learn**

Бібліотека scikit-learn є одним з найпопулярніших інструментів машинного навчання для Python. У даному дослідженні scikit-learn використовувалася для двох основних цілей: оцінювання якості моделей

класифікації( обчислення метрик точності, побудова матриць помилок, крос-валідація для оцінки стабільності моделей) та реалізація мета-моделі з логістичною регресією.

Перевагою scikit-learn є уніфікований API для всіх алгоритмів, що полегшує експериментування з різними підходами та порівняння результатів.

### **3.5 Бібліотеки для візуалізації**

Matplotlib є базовою бібліотекою для створення статичних, анімованих та інтерактивних візуалізацій у Python [46]. В контексті даної роботи Matplotlib застосовувалася для візуалізації процесу навчання моделей (графіки зміни функції втрат (loss) під час тренування та валідації, динаміка метрик якості (accuracy, precision, recall) по епохах, порівняльні діаграми результатів різних моделей, візуалізація розподілу класів у наборі даних, гістограми розподілу прогнозованих ймовірностей).

### **3.6 Бібліотеки для розробки графічного інтерфейсу**

Для реалізації програмного інтерфейсу системи класифікації фіброзу печінки було обрано фреймворк PySide6 – офіційний Python-біндинг до Qt 6. Qt є одним з найпотужніших кросплатформних фреймворків для розробки графічних інтерфейсів [47].

Обґрунтування вибору PySide6:

- можливість запуску на Windows, Linux та macOS без змін коду;
- нативний вигляд інтерфейсу для кожної платформи та підтримка сучасних дизайнерських рішень;
- готові компоненти для завантаження зображень, відображення результатів, прогрес-барів та діалогових вікон;
- наявність Qt Designer – графічного інструменту для візуального проектування інтерфейсу з автоматичною генерацією коду;

- інтеграція з OpenCV та NumPy;
- PySide6 розповсюджується під ліцензією LGPL, що дозволяє використання в комерційних проектах [48].

Функціональні можливості інтерфейсу, реалізовані за допомогою PySide6: завантаження та попередній перегляд ультразвукових зображень, відображення процесу обробки зображення, показ результатів класифікації з ймовірностями для кожного класу.

### **3.7 Альтернативні рішення та обґрунтування вибору**

При виборі інструментів розглядалися альтернативні варіанти:

PyTorch проти TensorFlow: PyTorch має більш інтуїтивний API для дослідницьких завдань, проте TensorFlow обрано через кращу підтримку продакшн-розгортання, більш стабільний Keras API та ширшу екосистему інструментів;

Tkinter проти PySide6: Tkinter є вбудованою бібліотекою Python, але PySide6 надає значно більше можливостей для створення сучасного професійного інтерфейсу;

PIL/Pillow проти OpenCV: Pillow простіша у використанні, але OpenCV обрано через значно ширший набір функцій комп'ютерного зору та кращу продуктивність.

Seaborn проти Matplotlib: Seaborn надає більш естетичні візуалізації "з коробки", проте Matplotlib обрано через більший контроль над деталями відображення та ширші можливості кастомізації.

### **Висновки з розділу 3**

Обрана комбінація мови програмування Python та спеціалізованих бібліотек (OpenCV, NumPy, TensorFlow/Keras, Pandas, Matplotlib, SciPy,

skimage, scikit-learn, PySide6) формує потужну та гнучку платформу для розробки системи класифікації ступеня фіброзу печінки.

Ключові переваги обраного технологічного стеку: покриття всіх етапів від обробки зображень до візуалізації результатів, підтримка GPU-обчислень та оптимізованих алгоритмів, можливість розширення функціональності без зміни архітектури, робота на різних операційних системах без модифікацій, прозорість алгоритмів, відсутність ліцензійних обмежень для дослідницьких цілей.

Обрані інструменти забезпечують можливість реалізації складної багатоетапної системи класифікації, що включає обробку зображень, витягнення ознак, тренування нейронних мереж, побудову ансамблевих моделей та створення зручного користувацького інтерфейсу.

## **РОЗДІЛ 4**

### **ПРОГРАМНА РЕАЛІЗАЦІЯ ТА МЕТОДИКА РОБОТИ СИСТЕМИ ВИЗНАЧЕННЯ СТЕПЕНЯ ФІБРОЗУ ПЕЧІНКИ**

У цьому розділі представлено повний цикл реалізації програмної системи, створеної для автоматизованої класифікації ступеня фіброзу печінки. Робота охоплює послідовну побудову всіх ключових компонентів застосунку. Спочатку розглядається підготовка даних: імпорт ультразвукових зображень, їх очищення, нормалізація та приведення до єдиного формату для подальшої обробки. Далі подано етап формування та побудови моделей – від вибору структури нейронних мереж до реалізації алгоритмів формування текстурних ознак і запуску ансамблевого підходу. Наступним кроком є навчання моделей і перевірка їхньої якості, що включає розрахунок метрик, аналіз помилок і порівняння отриманих результатів між різними архітектурами. Завершальним елементом є створення графічного інтерфейсу користувача та інтеграція всього функціоналу у єдиний програмний застосунок, здатний працювати з реальними медичними зображеннями та формувати підсумковий діагностичний висновок.

#### **4.1 Аналіз та обробка даних**

Початковими вхідними даними для задачі класифікації були ультразвукові зображення паренхіми печінки (див. рис. 4.1) реальних пацієнтів з різними степенями фіброзу, отримані від лікаря всеукраїнського центру материнства та дитинства національної академії медичних наук України [5].




Рисунок 4.1 – Ультразвукове зображення паренхіми печінки

База отриманих зображень містить в собі 8 класів, кожний клас це певна стадія фіброзу або проміжна стадія (тобто F1-2, F2-3, F3-4) [5]. Загалом маємо 128 зображень від 120 пацієнтів (зображень більше ніж пацієнтів тому що деяким пацієнтам зроблено два знімки під різними кутами огляду). На рис. 4.2 зображено розподіл зображень по класам [5].




Рисунок 4.2 – Розподіл кількості зображень по класам

Не всі вхідні зображення були коректними для подачі на вхід нейронної мережі, деякі містили «чорні залишки» від інтерфейсу апарату на якому

проводилось УЗД, що можна помітити на рис. 4.3 з правої сторони [5]. Виходячи з цього було прийнято рішення вручну обрізати усі зображення від цих недоліків, так як вони не містять цінної інформації та призвели б до некоректного навчання моделі [5].




Рисунок 4.3 – Недолік на вхідних зображеннях

Наступним кроком обробки було зведення всіх знімків до одного розміру та розбивання цілісного знімку на фрагменти [5].

Усі зображення мали різні розмірні параметри, які варіювалися від 150 до 400 пікселів за висотою та від 300 до 550 по ширині, тож перша необхідність це корегування зображень до однакових розмірів [5]. Було вираховано середній розмір усіх зображень і висота – 290 та ширина 350. Також було виведено функцію, що нормалізує яскравість зображення до усереднених показників по всім зображенням набору даних. Ще одним важливим кроком обробки даних є нормалізація [5]. Говорячи про обробку зображень, нормалізацію відносять до процесу зміни діапазону значень інтенсивності пікселів [5]. Зазвичай, як і в даному дослідженні, нормалізація зображень виконується тоді, коли інтенсивність пікселів знаходиться у різних діапазонах сірого [5]. Для цього процесу було використано функцію «rescale» [5]. rescale - це значення, на яке ми будемо множити дані перед будь-якою іншою обробкою [5]. Наші вихідні зображення складаються з коефіцієнтів RGB в діапазоні від 0 до 255, але такі

значення занадто високі для обробки нашими моделями (враховуючи типову швидкість навчання), тому замість цього ми орієнтуємося на значення від 0 до 1, масштабуючи за допомогою  $1/255$  коефіцієнт [5]. Цей процес було виконано за допомогою класу `ImageDataGenerator` наданого `tf.keras` [5].

Окрім зведенням до одного розміру, альтернативно було зроблено розбиття зображення на фрагменти, по алгоритму розробленому у бакалаврській роботі [5]. Розбивка була з перекриттям зображення 70% і розбивалось на 12 частин.

Для подальшої роботи з отриманими зображенням необхідно розбити дані по класам [5].

Ще одним важливим кроком обробки даних є нормалізація [5]. Говорячи про обробку зображень, нормалізацію відносять до процесу зміни діапазону значень інтенсивності пікселів [5]. Зазвичай, як і в даному дослідженні, нормалізація зображень виконується тоді, коли інтенсивність пікселів знаходиться у різних діапазонах сірого [5]. Для цього процесу було використано функцію «`rescale`» [5]. `rescale` - це значення, на яке ми будемо множити дані перед будь-якою іншою обробкою [5]. Наші вихідні зображення складаються з коефіцієнтів RGB в діапазоні від 0 до 255, але такі значення занадто високі для обробки нашими моделями (враховуючи типову швидкість навчання), тому замість цього ми орієнтуємося на значення від 0 до 1, масштабуючи за допомогою  $1/255$  коефіцієнт [5]. Цей процес було виконано за допомогою класу `ImageDataGenerator` наданого `tf.keras` [5].

Як відомо з теорії, для конструювання моделі необхідно розділити вхідні дані на тестові та тренувальні [5]. Для нашої задачі було обрано поділ даних у розмірі 30% на тестові та 70% на тренувальні [5]. У програмній реалізації міститься функція, котра з загальної директорії кожного класу бере усі зображення і розміщає їх до завчасно створеної директорії для тренувальних даних [5]. Далі дана функція підраховує кількість зображень у кожному класі, відбирає 30% з кожного та переміщає ці 30% до директорії створеної для

тестових даних [5]. Таким чином автоматично дані діляться на тестову та тренувальну вибірку [5].

## **4.2 Текстурні характеристики зображень**

Текстурні характеристики зображень відіграють важливу роль у задачах класифікації ультразвукових зображень печінки, оскільки вони дозволяють кількісно описати просторову структуру тканин, яку складно оцінити лише за інтенсивністю пікселів. На відміну від звичайних статистичних або колірних ознак, текстурні показники відображають взаємозв'язки між сусідніми пікселями, їхню однорідність, шорсткість, контрастність та ступінь регулярності структур, що є важливим для розпізнавання патологічних змін.

У даній роботі використано три основні підходи для опису текстури УЗ-зображень печінки: гістограму відтінків сірого, матрицю довжин відтінків сірого (GLRLM - Gray Level Run Length Matrix) та матрицю суміжності відтінків сірого (GLCM - Gray Level Co-occurrence Matrix).

### **4.2.1 Гістограма відтінків сірого**

В процесі роботи було розроблено програмний модуль для автоматичного виділення текстурних характеристик з ультразвукових зображень печінки на основі аналізу гістограм відтінків сірого. Реалізований алгоритм здійснює попереднє перетворення зображення у відтінки сірого та його нормалізацію, що забезпечує коректність подальших обчислень незалежно від різниці у яскравості або контрастності вихідних даних. Для кожного зображення виконується поділ на локальні блоки фіксованого розміру, усередині яких формується гістограма розподілу яскравості пікселів. На основі отриманої гістограми для кожної області обчислюється набір статистичних показників, що описують локальні властивості текстури.

Розмір карт ознак є найважливішим фактором. Розглянуто різні варіанти побудови карт ознак:  $32 \times 32$ ,  $64 \times 64$  та  $128 \times 128$ . Для обробки ультразвукових зображень розміри текстурних карт  $32 \times 32$ ,  $64 \times 64$  та  $128 \times 128$  є оптимальними,

оскільки вони забезпечують баланс між збереженням локальних структурних деталей і обчислювальною ефективністю. Менші карти (32×32) дозволяють узагальнити текстурні особливості й зменшити шум, тоді як більші (64×64 або 128×128) зберігають більше просторової інформації, важливої для точного аналізу тканин. Було обрано оптимальний розмір - 64×64 (див. рис. 4.5), тому що 32×32 (див. рис. 4.4) занадто узагальнені, а на 128×128 (див. рис. 4.6) дуже багато шуму. Для наочності було побудовано текстурні карти в кольорі, щоб бачити відмінності між різними розмірами.




Рисунок 4.4 – Приклад текстурної карти Mean розміром 32×32




Рисунок 4.5 – Приклад текстурної карти Mean розміром 64×64




Рисунок 4.6 - Приклад текстурної карти Mean розміром 128×128

Параметр `block_size = 8` визначає розмір локальної області, у межах якої обчислюються текстурні характеристики; вибір саме такого значення дозволяє зберегти достатньо деталей при помірних обчисленнях. `hist_bins = 32` задає кількість інтервалів гистограми відтінків сірого, що забезпечує оптимальний баланс між точністю опису розподілу яскравості та стійкістю до шуму на ультразвукових зображеннях.

У межах розробленого методу формуються такі карти ознак, як середнє значення, середньоквадратичне відхилення, дисперсія, асиметрія (*skewness*), ексцес (*kurtosis*), енергія та ентропія. Кожен із цих параметрів обчислюється окремо для кожного блоку, після чого отримані карти нормалізуються та масштабуються до єдиного розміру, що забезпечує їхню сумісність у подальшому аналізі.

Згенеровані багатоканальні карти текстурних ознак зберігаються у форматі `.pru` для кожного зображення.

Приклад сформованих всіх текстурних карт можна побачити на рис. 4.7.




Рисунок 4.7 - Приклад текстурних карт розміром  $128 \times 128$

#### 4.2.2 Матриця суміжності відтінків сірого

Далі було реалізовано програмний модуль для побудови текстурних карт ультразвукових зображень печінки на основі матриці суміжності відтінків сірого (GLCM). Алгоритм виконує перетворення зображення у відтінки сірого та нормалізацію інтенсивностей пікселів, після чого зображення поділяється на локальні блоки розміром  $8 \times 8$  пікселів. Для кожного блоку формується матриця суміжності, яка описує частоту спільної появи пар рівнів яскравості на заданій відстані та в різних напрямках ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  та  $135^\circ$ ). На основі цієї матриці для кожного блоку обчислюються основні текстурні характеристики – контраст, несхожість, однорідність, енергія та кореляція. Для підвищення стійкості до напрямленості текстур результати усереднюються за всіма кутами, після чого кожна з отриманих характеристик формується у вигляді окремої карти ознак. Згенеровані карти нормалізуються та масштабуються до єдиного розміру  $64 \times 64$  пікселів, що забезпечує однакові параметри для подальшої обробки. Усі карти ознак зберігаються у форматі *.nru* із прив'язкою до відповідних оригінальних зображень. Для наочності текстурні карти зображено на рис. 4.8.




Рисунок 4.8 – Текстурні карти на основі матриці суміжності відтінків сірого розміром  $64 \times 64$

#### 4.2.3 Матриця довжин відтінків сірого

Надалі було реалізовано програмний модуль для побудови текстурних карт ультразвукових зображень печінки на основі матриці довжин відтінків сірого (GLRLM). Алгоритм виконує перетворення зображення у відтінки сірого, нормалізацію інтенсивностей та квантування рівнів яскравості до 32 градацій, що забезпечує уніфікацію даних для подальшого аналізу. Зображення поділяється на локальні блоки розміром  $8 \times 8$  пікселів, для кожного з яких обчислюється матриця довжин пробігів у чотирьох напрямках ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  і  $135^\circ$ ). У межах кожного блоку формується GLRLM, що відображає кількість послідовних пікселів з однаковим рівнем сірого для різних довжин пробігів. На основі цієї матриці обчислюються основні текстурні характеристики – short run emphasis (SRE), long run emphasis (LRE), gray level non-uniformity (GLN), run length non-uniformity (RLN), run percentage (RP), low gray level run emphasis (LGRE) та high gray level run emphasis (HGRE) [49]. Для кожного блоку обчислені значення формують окремі карти ознак, які нормалізуються та

масштабуються до єдиного розміру  $64 \times 64$  пікселів. Для наочності текстурні карти на основі матриці довжин відтінків сірого зображено на рис. 4.9.




Рисунок 4.9 – Текстурні карти на основі матриці довжин відтінків сірого розміром  $64 \times 64$

### 4.3 Групові бінарні класифікатори

#### 4.3.1 Визначення архітектури згорткової нейронної мережі

Розроблена архітектура є компактною CNN-моделлю, що складається з 2 згорткових шарів із підвибіркою, шару згладжування (Flatten), одного повнозв'язного прихованого шару та вихідного шару [5]. Далі розглянемо компоненти детальніше. Перший згортковий блок зображено на рис. 4.10.

```
model = Sequential([
    Conv2D(32, (3,3), activation='relu', input_shape=(img_size_h, img_size_w, 1)),
    MaxPooling2D(),
```

Рисунок 4.10 – Перший згортковий шар

Згортковий шар Conv2D застосовується для вилучення базових візуальних ознак зі зображень [5]. У нашій моделі перший шар має 32 фільтри з ядрами  $3 \times 3$  та активацією ReLU. Вхідними даними є одноканальні (grayscale) зображення розміру  $290 \times 352$  пікселі. Після згортки застосовується максимальний пулінг MaxPooling2D (розмір вікна за замовчуванням  $2 \times 2$ ), який зменшує просторові розміри ознак і підвищує інваріантність до локальних зсувів. Другий згортковий блок подано на рис. 4.11.

```
Conv2D(64, (3,3), activation='relu'),
MaxPooling2D(),
```

Рисунок 4.11 – Другий згортковий шар

У другому шарі кількість фільтрів збільшується до 64, зберігаючи розмір ядра  $3 \times 3$  та активацію ReLU. Як і раніше, після згортки застосовується MaxPooling2D для подальшого агрегування просторової інформації. Таким чином послідовність двох «Conv2D → MaxPooling2D» формує каскад ознак від простіших до складніших.

Після двох згорткових шарів у створеній архітектурі додається шар Flatten, який перетворює тензор ознак у одномірний вектор, придатний для подальшої обробки повнозв'язними шарами.

Далі використовуються повнозв'язні шари. Основна роль повнозв'язного шару – інтегрувати виділені згортками ознаки у дискримінативне представлення для класифікації.

У моделі присутній один прихований повнозв'язний шар Dense із 64 нейронами та активацією ReLU. Для боротьби з перенавчанням після нього застосовується Dropout=0.4, який випадково «вимикає» 40% нейронів під час навчання, покращуючи здатність до узагальнення.

Оскільки розв'язується бінарне завдання класифікації, вихідний шар має 1 нейрон з сигмоїдною функцією активації. Вихідне значення лежить у діапазоні  $[0, 1]$  і інтерпретується як імовірність належності зразка до

позитивного класу. Початкове зміщення вихідного нейрона ініціалізовано константою (`bias_initializer=Constant(bias_init)`), де `bias_init` розраховано з фактичної частки позитивного класу у тренувальній вибірці. Така ініціалізація пришвидшує збіжність за наявності дисбалансу класів.

Завантаження даних здійснюється з директорій тренувального та валідаційного наборів, причому зображення приводяться до відтінків сірого та розміру  $290 \times 352$ . Для тренувального набору використано легку аугментацію — масштабування інтенсивностей до  $[0,1]$  (`rescale=1./255`) і горизонтальні віддзеркалення (`horizontal_flip=True`). Для валідаційного набору виконується лише `rescale`. Спочатку генератори завантажують 8 початкових класів, однак подальшим кроком здійснюється ремапінг міток до бінарного формату: усі зразки початкового класу 0 залишаються класом 0, а решта класів об'єднуються в клас 1. Після ремапінгу в обох наборах встановлюється `num_classes = 2` та відповідні `class_indices`. Компіляція моделі зображена на рис. 4.12.

```
model.compile(  
    optimizer=Adam(learning_rate=0.0003),  
    loss='binary_crossentropy',  
    metrics=['accuracy']  
)
```

Рисунок 4.12 – Компіляція моделі

Моделі компілюється з оптимізатором Adam зі швидкістю навчання 0.0003, функцією втрат `binary_crossentropy` та метрикою `accuracy`. На відміну від еталонної версії, Batch Normalization у даній реалізації не використовується, а активації ReLU задані безпосередньо в шарах Conv2D і Dense.

Додатково для компенсації дисбалансу класів обчислюються ваги класів (`compute_class_weight`) і передаються у виклик навчання. Це зменшує зміщення моделі в бік більш представленого класу. Навчання моделі зображено на рис. 4.13.

```

|
| history = model.fit(
|     train_data,
|     validation_data=test_data,
|     epochs=epochs,
|     class_weight=class_weight_dict,
|     callbacks=[early_stopping]
| )

```

Рисунок 4.13 – Навчання моделі

Процес тренування виконується методом `model.fit()` з `batch_size=32` та верхньою межею `epochs=200`. Увімкнено ранню зупинку (`EarlyStopping`) з моніторингом `val_loss`, `patience=5` та відновленням найкращих ваг. На практиці це запобігає перенавчанню та зупиняє тренування, щойно валідаційна втрата перестане покращуватися протягом п'яти епох.

Після завершення навчання модель зберігається у файл, а також проводиться кількісна оцінка на тренувальному та тестовому наборах із виведенням точності. Для детальнішого аналізу будуються графіки динаміки втрат і точності на тренуванні/валідації, обчислюється матриця помилок та формується класифікаційний звіт (`precision`, `recall`, `F1-score`) за результатами передбачень на тестовому наборі.

### 4.3.2 Тренування моделі класифікатора №1

Нагадаю, що класифікатор №1 містить в собі два класи, що діляться як:

- Клас «0» – F0;
- Клас «1» – F1, F1-2, F2, F2-3, F3, F3-4, F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 5 класу «0» та 12 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.14) та метрик `accuracy`, `precision`, `recall`, `f1-score`, а також матриці помилок (`confusion matrix`) (див. рис. 4.15) [5].

Маємо точність моделі (`accuracy`) – 0.87

	precision	recall	f1-score	support
0	0.00	0.00	0.00	5
1	0.87	1.00	0.93	33
accuracy			0.87	38
macro avg	0.43	0.50	0.46	38
weighted avg	0.75	0.87	0.81	38

Рисунок 4.14 – Звіт про класифікації класифікатора №1




Рисунок 4.15 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 0/5 зображень і до класу «1» класифікувало 33/33 [5]. Такий малий відсоток класифікації до класу «0» обумовлений тим, що стадії фіброзу F0 та F1-2 мало чим відрізняються [5]. До того ж розподіл кількості даних між класами не є рівномірним [5].

### 4.3.3 Тренування моделі класифікатора №2

Класифікатор №2 містить в собі два класи, що діляться як:

- Клас «0» – F0, F1;
- Клас «1» – F1-2, F2, F2-3, F3, F3-4, F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 8 класу «0» та 30 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.16) та метрик accuracy, precision, recall, f1-score, а також матриці помилок (confusion matrix) (див. рис. 4.17) [5].

Маємо точність моделі (accuracy) – 0.82.

	precision	recall	f1-score	support
0	0.67	0.25	0.36	8
1	0.83	0.97	0.89	30
accuracy			0.82	38
macro avg	0.75	0.61	0.63	38
weighted avg	0.79	0.82	0.78	38

Рисунок 4.16 – Звіт про класифікації класифікатора №2




Рисунок 4.17 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 2/8 зображень і до класу «1» класифікувало 29/30 [5]. Малий відсоток точності класифікації класу «0» все ще обумовлено схожістю ознак у стадіях фіброзу [5].

#### 4.3.4 Тренування моделі класифікатора №3

Класифікатор №3 містить в собі два класи, що діляться як:

- Клас «0» – F0, F1, F1-2;
- Клас «1» – F2, F2-3, F3, F3-4, F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 10 класу «0» та 28 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.18) та метрик accuracy, precision, recall, f1-score, а також матриці помилок (confusion matrix) (див. рис. 4.19) [5].

Маємо точність моделі (accuracy) – 0.82.

	precision	recall	f1-score	support
0	1.00	0.30	0.46	10
1	0.80	1.00	0.89	28
accuracy			0.82	38
macro avg	0.90	0.65	0.68	38
weighted avg	0.85	0.82	0.78	38

Рисунок 4.18 – Звіт про класифікації класифікатора №3




Рисунок 4.19 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 3/10 зображень і до класу «1» класифікувало 28/28 [5].

#### 4.3.5 Тренування моделі класифікатора №4

Класифікатор №4 містить в собі два класи, що діляться як:

- Клас «0» – F0, F1, F1-2, F2;
- Клас «1» – F2-3, F3, F3-4, F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 15 класу «0» та 23 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.20) та метрик accuracy, precision, recall, f1-score, а також матриці помилок (confusion matrix) (див. рис. 4.21) [5].

Маємо точність моделі (accuracy) – 0.63.

	precision	recall	f1-score	support
0	0.53	0.60	0.56	15
1	0.71	0.65	0.68	23
accuracy			0.63	38
macro avg	0.62	0.63	0.62	38
weighted avg	0.64	0.63	0.63	38

Рисунок 4.20 – Звіт про класифікації класифікатора №4




Рисунок 4.21 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 9/15 зображень і до класу «1» класифікувало 15/23 [5].

#### 4.3.6 Тренування моделі класифікатора №5

Класифікатор №5 містить в собі два класи, що діляться як:

- Клас «0» – F0, F1, F1-2, F2, F2-3;
- Клас «1» – F3, F3-4, F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 19 класу «0» та 19 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.22) та метрик accuracy, precision, recall, f1-score, а також матриці помилок (confusion matrix) (див. рис. 4.23) [5].

Маємо точність моделі (accuracy) – 0.63.

	precision	recall	f1-score	support
0	0.62	0.68	0.65	19
1	0.65	0.58	0.61	19
accuracy			0.63	38
macro avg	0.63	0.63	0.63	38
weighted avg	0.63	0.63	0.63	38

Рисунок 4.22 – Звіт про класифікації класифікатора №5




Рисунок 4.23 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 13/19 зображень і до класу «1» класифікувало 11/19 [5].

#### 4.3.7 Тренування моделі класифікатора №6

Класифікатор №6 містить в собі два класи, що діляться як:

- Клас «0» – F0, F1, F1-2, F2, F2-3, F3;
- Клас «1» – F3-4, F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 25 класу «0» та 13 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.24) та метрик accuracy, precision, recall, f1-score, а також матриці помилок (confusion matrix) (див. рис. 4.25) [5].

Маємо точність моделі (accuracy) – 0.76.

	precision	recall	f1-score	support
0	0.74	1.00	0.85	25
1	1.00	0.31	0.47	13
accuracy			0.76	38
macro avg	0.87	0.65	0.66	38
weighted avg	0.83	0.76	0.72	38

Рисунок 4.24 – Звіт про класифікації класифікатора №6




Рисунок 4.25 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 25/25 зображень і до класу «1» класифікувало 4/13 [5].

#### 4.3.8 Тренування моделі класифікатора №7

Класифікатор №7 містить в собі два класи, що діляться як:

- Клас «0» – F0, F1, F1-2, F2, F2-3, F3, F3-4;
- Клас «1» –F4 [5].

Відповідно до кількості зображень у кожному класі валідаційній виборці надходить 30%, в даному випадку 31 класу «0» та 7 класу «1» [5].

Загалом на валідацію пішло 38 зображень та 90 на тренування [5].

Оцінка моделі відбувається на основі звіту класифікації (див. рис. 4.26) та метрик accuracy, precision, recall, f1-score, а також матриці помилок (confusion matrix) (див. рис. 4.27) [5].

Маємо точність моделі (accuracy) – 0.84.

	precision	recall	f1-score	support
0	0.84	1.00	0.91	31
1	1.00	0.14	0.25	7
accuracy			0.84	38
macro avg	0.92	0.57	0.58	38
weighted avg	0.87	0.84	0.79	38

Рисунок 4.26 – Звіт про класифікації класифікатора №7




Рисунок 4.27 – Матриця помилок

З матриці помилок помітно, що до класу «0» класифікувало 31/31 зображень і до класу «1» класифікувало 1/7 [5]. Малий відсоток точності класифікації класу «1» є наслідком нерівномірно розподілених даних між класами [5].

Кожна з отриманих моделей була збережена та надалі використовувалась у системі визначення ступеню фіброзу печінки на ультразвукових зображеннях паренхіми печінки [5].

## 4.4 Багатокласові моделі на основі текстурних характеристик

### 4.4.1 Модель на основі гістограми відтінків сірого

Розроблена архітектура являє собою компактну згорткову нейронну мережу (CNN), що складається з трьох згорткових блоків із підвибіркою, шару Flatten, одного повнозв'язного прихованого шару та вихідного шару Softmax. Далі розглянемо компоненти детальніше. Перший згортковий блок подано на рис. 4.28.

```
layers.Conv2D(32, (3,3), activation='relu', padding='same'),  
layers.BatchNormalization(),  
layers.MaxPooling2D((2,2)),  
layers.Dropout(0.3),
```

Рисунок 4.28 – Перший згортковий блок

На вхід мережі подаються тензори розміру  $64 \times 64 \times 7$ . Канальність  $C=7$  відповідає семи картам ознак. Перший шар — Conv2D(32, 3×3, padding='same', activation='relu') — вилучає базові локальні патерни. Далі застосовується нормалізація пакетів BatchNormalization, що стабілізує розподіли активацій і прискорює збіжність, потім максимальний пулінг MaxPooling2D(2×2) для зменшення просторових розмірів і Dropout=0.3 для регуляризації.

Другий згортковий блок зображено на рис. 4.29.

```
layers.Conv2D(64, (3,3), activation='relu', padding='same'),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.3),
```

Рисунок 4.29 – Другий згортковий блок

Другий шар згортки збільшує кількість фільтрів до 64: Conv2D(64, 3×3, ReLU, same) → BatchNormalization → MaxPooling2D(2×2) → Dropout=0.3 [50]. На цьому етапі мережа формує більш абстрактні ознаки, зберігаючи стабільність тренування завдяки BatchNormalization та зменшуючи перенавчання завдяки Dropout.

Третій згортковий блок показано на рис. 4.30.

```
layers.Conv2D(128, (3,3), activation='relu', padding='same'),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.4),
```

Рисунок 4.30 – Третій згортковий блок

Поглиблення представлено третім шаром Conv2D(128, 3×3, ReLU, same) із подальшими BatchNormalization, MaxPooling2D(2×2) та посиленою регуляризацією Dropout=0.4 [50]. На виході формується компактний, інформативний тензор ознак.

Після згорткових блоків застосовується шар перетворення у вектор.

Flatten конвертує тривимірний тензор ознак у одномірний вектор, придатний для подальшої обробки повнозв'язними шарами.

Далі додається повнозв'язна частина. Використовується один прихований шар Dense(128, activation='relu'), після якого розміщено Dropout=0.5. Така комбінація забезпечує достатню виразність для багатокласової задачі при стриманій складності моделі.

Останній елемент архітектури — вихідний шар (див. рис. 4.31).

```
layers.Flatten(),
layers.Dense(128, activation='relu'),
layers.Dropout(0.5),
layers.Dense(num_classes, activation='softmax')
```

Рисунок 4.31 – Вихідний шар

Оскільки маємо вісім класів, вихідний шар — `Dense(NUM_CLASSES=8, activation='softmax')`. Функція `Softmax` перетворює логіти у вектор імовірностей, сума яких дорівнює 1; кожна компонента інтерпретується як імовірність належності до відповідного класу.

Дані зберігаються у структурі директорій `train/` та `val/`, де кожна підпапка відповідає одному класу. Для кожного `.pru`-файла завантажуються тензори  $64 \times 64 \times 7$  та відповідна цільова мітка. Порядок класів фіксується словником `class_map` (лексикографічно відсортовані назви папок), що гарантує стабільну відповідність індекс  $\leftrightarrow$  назва класу між тренувальним і валідаційним наборами.

Модель компілюється оптимізатором `Adam` зі швидкістю навчання 0.0005, функцією втрат `sparse_categorical_crossentropy` (оскільки мітки зберігаються як цілі числа, а не `one-hot`) та метрикою `accuracy` (див. рис. 4.32).

```
model.compile(optimizer=keras.optimizers.Adam(learning_rate=LEARNING_RATE),
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
```

Рисунок 4.32 – Компіляція моделі

Навчання запускається методом `model.fit()` з `BATCH_SIZE=4` і максимальною кількістю `EPOCHS=1000`, але з увімкненою ранньою зупинкою (див. рис. 4.33).

`EarlyStopping` зупиняє тренування, якщо точність на валідації не поліпшується протягом 100 епох, і відновлює найкращі ваги. `ModelCheckpoint` зберігає найкращу за `val_accuracy` модель до файлу. Така комбінація дозволяє стартувати з великої верхньої межі епох, але фактично зупинитися тоді, коли покращення метрики припиняється.

```

history = model.fit(
    datagen.flow(X_train, y_train, batch_size=BATCH_SIZE),
    validation_data=(X_val, y_val),
    epochs=EPOCHS,
    callbacks=callbacks
)

```

Рисунок 4.33 – Навчання моделі

Для якісної оцінки по класах обчислюється матриця помилок (див. рис. 4.34). та формується класифікаційний звіт (precision, recall, F1-score) (див. рис. 4.35) з іменами класів, успадкованими з підпапок classes




Рисунок 4.34 – Матриця помилок (8 класів)

	precision	recall	f1-score	support
1	0.40	0.40	0.40	5
2	1.00	0.67	0.80	3
3	0.00	0.00	0.00	2
4	0.33	0.40	0.36	5
5	0.00	0.00	0.00	4
6	1.00	0.50	0.67	6
7	0.27	0.67	0.38	6
8	0.50	0.43	0.46	7
accuracy			0.42	38
macro avg	0.44	0.38	0.38	38
weighted avg	0.47	0.42	0.41	38

Рисунок 4.35 – Класифікаційний звіт

Отримана точність моделі на основі гістограми відтінків сірого – 42%.

З матриці помилок бачимо що вона доволі непогано класифікує основні «грубі» класи.

#### 4.4.2 Модель на основі матриці суміжності відтінків сірого

Розроблена архітектура – компактна CNN, що складається з трьох згорткових блоків із підвibrкою, шару Flatten, одного повнозв'язного прихованого шару та вихідного шару Softmax. Далі — покроковий розбір.

Перший згортковий блок подано на рис. 4.36.

```
layers.Conv2D(32, (3,3), activation='relu', padding='same'),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.3),
```

Рисунок 4.36 – Перший згортковий блок

На вхід мережі подається тензор  $64 \times 64 \times 5$ . П'ять каналів – це попередньо обчислені GLCM-карти ознак (типово включають контраст, однорідність, енергію, кореляцію, ASM/ентропію тощо; конкретний склад залежить від етапу препроцесингу). Перший шар — Conv2D(32, 3×3, padding='same', activation='relu') — вилучає базові локальні патерни з текстурних карт. Далі застосовується BatchNormalization для стабілізації розподілів активацій, MaxPooling2D(2×2) для зменшення розмірів ознак та Dropout=0.3 для регуляризації [50].

Другий згортковий блок подано на рис. 4.37.

```
layers.Conv2D(64, (3,3), activation='relu', padding='same'),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.3),
```

Рисунок 4.37 – Другий згортковий блок

Кількість фільтрів зростає до 64: Conv2D(64, 3×3, ReLU, same) → BatchNormalization → MaxPooling2D(2×2) → Dropout=0.3 [50]. Мережа формує більш абстрактні інваріантні представлення текстур.

Третій згортковий блок подано на рис. 4.38.

```
layers.Conv2D(128, (3,3), activation='relu', padding='same'),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.4),
```

Рисунок 4.38 – Третій згортковий блок

Поглиблення ознак за рахунок Conv2D(128, 3×3, ReLU, same) з подальшими BatchNormalization, MaxPooling2D(2×2) та посиленням Dropout=0.4 [50]. Отримуємо компактний та інформативний тензор ознак для класифікації.

Після згорткових блоків використовується перетворення у вектор. Flatten перетворює тривимірний тензор у одномірний вектор для подальшої обробки щільними шарами. Далі додається повнозв'язна частина.

Один прихований шар Dense(128, ReLU) із Dropout=0.5 забезпечує достатню виразність при контрольованій складності моделі.

Завершує архітектуру вихідний шар (див. рис. 4.39).

```
layers.Flatten(),
layers.Dense(128, activation='relu'),
layers.Dropout(0.5),
layers.Dense(num_classes, activation='softmax')
```

Рисунок 4.39 – Вихідний шар

Оскільки завдання багатокласове (8 класів), вихідний шар – Dense(NUM\_CLASSES=8, activation='softmax'). Softmax перетворює логіти у вектор імовірностей, сума яких дорівнює 1; кожне значення інтерпретується як імовірність належності до відповідного класу.

Компіляція моделі базується на таких же параметрах, як і модель на основі гістограми відтінків сірого.

Параметри навчання. BATCH\_SIZE=7, максимальна кількість EPOCHS=2000 із ввімкненими колбеками. ModelCheckpoint зберігає найкращу за val\_accuracy модель у файл. EarlyStopping запас епох із автоматичною

зупинкою, щойно валідаційна точність не покращується протягом 100 епох (див. рис. 4.40).

```

checkpoint_path = "/content/drive/MyDrive/fibrosis_texture_cnn_best64_2.keras"
checkpoint = ModelCheckpoint(
    checkpoint_path,
    monitor='val_accuracy',
    verbose=1,
    save_best_only=True,
    mode='max'
)
earlystop = EarlyStopping(
    monitor='val_accuracy',
    patience=100,
    verbose=1,
    restore_best_weights=True
)
callbacks = [checkpoint, earlystop]

# ==== Обучение модели ====
history = model.fit(
    datagen.flow(X_train, y_train, batch_size=BATCH_SIZE),
    validation_data=(X_val, y_val),
    epochs=EPOCHS,
    callbacks=callbacks
)

```

Рисунок 4.40 – Навчання моделі

Обчислюється матриця помилок (див. рис. 4.41) і виводиться класифікаційний звіт (див. рис. 4.42) з іменами класів, успадкованими з підпапок.




Рисунок 4.41 – Матриця помилок (8 класів)

	precision	recall	f1-score	support
1	0.43	0.60	0.50	5
2	0.00	0.00	0.00	3
3	0.00	0.00	0.00	2
4	0.38	0.60	0.46	5
5	1.00	0.50	0.67	4
6	0.36	0.67	0.47	6
7	0.50	0.33	0.40	6
8	0.50	0.43	0.46	7
accuracy			0.45	38
macro avg	0.40	0.39	0.37	38
weighted avg	0.44	0.45	0.42	38

Рисунок 4.42 – Класифікаційний звіт

Отримана точність моделі на основі гістограми відтінків сірого – 45%.

В порівнянні з минулою моделлю точність підвищилась на 3%.

#### 4.4.3 Модель на основі матриці довжин відтінків сірого

Розроблена архітектура виконує багатокласову класифікацію за вісьмома класами на основі текстурних характеристик, отриманих із матриці довжин відтінків сірого. Вхідні дані для моделі представлені як тензори розміру  $64 \times 64 \times 7$  у форматі .пру, де кожен із семи каналів відповідає різним картам ознак GLRLM.

Перший згортковий блок подано на рис. 4.43. Перший шар Conv2D із 16 фільтрами та ядром  $3 \times 3$  з падінгом same і активацією ReLU здійснює початкове вилучення локальних текстурних патернів із GLRLM-каналів. Після згортки застосовується нормалізація BatchNormalization, що стабілізує статистики активацій і полегшує оптимізацію на багатоканальному вході, а далі MaxPooling2D із вікном  $2 \times 2$  зменшує розміри ознак, акумулюючи найінформативніші відгуки. Для стримування перенавчання використано Dropout із імовірністю 0.4, який випадково зануляє частину активацій під час тренування. В параметрах шару згортки додатково передбачено L2-регуляризацію ваг із коефіцієнтом  $1e-4$ , що дисциплінує параметри та зменшує ризик перенавчання на обмежених текстурних даних.

```
layers.Conv2D(16, (3,3), activation='relu', padding='same', kernel_regularizer=keras.regularizers.l2(1e-4)),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.4),
```

Рисунок 4.43 – Перший згортковий блок

Другий згортковий блок показано на рис. 4.44. На цьому етапі кількість фільтрів збільшується до 32, зберігаючи розмір ядра  $3 \times 3$ , активацію ReLU та паддінг same, що дозволяє моделі оперувати більш абстрактними дескрипторами текстури та узагальнювати патерни різної протяжності пробігів сірого. Як і в першому блоці, після згортки послідовно застосовуються BatchNormalization для стабілізації розподілів, MaxPooling2D для компактного подання просторових карт і Dropout=0.4 як засіб регуляризації. L2-регуляризація ваг повторюється й у другому згортковому шарі, завдяки чому модель утримує ваги у помірних межах і зберігає стійкість до шуму в ознаках.

```
layers.Conv2D(32, (3,3), activation='relu', padding='same', kernel_regularizer=keras.regularizers.l2(1e-4)),
layers.BatchNormalization(),
layers.MaxPooling2D((2,2)),
layers.Dropout(0.4),
```

Рисунок 4.44 – Другий згортковий блок

Після двох згорткових блоків, замість традиційного Flatten, у моделі використано глобальне усереднення просторових ознак. Шар GlobalAveragePooling2D агрегує кожен карту ознак у одне значення, що суттєво зменшує кількість параметрів і робить модель менш чутливою до локальних зсувів і неістотних варіацій текстури. Такий вибір особливо доречний для GLRLM-представлень, де важить не стільки точне розташування локальних деталей, скільки їх частотні та масштабні характеристики.

Після глобального усереднення додається шар Dense із 64 нейронами та активацією ReLU, який виконує інтеграцію агрегованих дескрипторів у компактне, але інформативне представлення для класифікації; для підвищення стійкості моделі до перенавчання у ньому також використано L2-регуляризацію ваг  $1e-4$ . Далі застосовується Dropout=0.5, що забезпечує додаткову регуляризацію шляхом стохастичного вимикання половини активацій, у такий спосіб стимулюючи мережу спиратися на розподілені ознаки, а не на окремі «сильні» нейрони.

Останнім компонентом є вихідний шар, наведений на рис. 4.45. Оскільки вирішується багатокласова задача з вісьмома класами, вихід містить вісім нейронів із функцією активації softmax, що перетворює логіти у нормований вектор імовірностей, сума якого дорівнює одиниці. Кожна компонента інтерпретується як ймовірність належності зразка до відповідного класу, а під час навчання використовується функція втрат sparse categorical crossentropy, сумісна з цілими індексами міток.

```
layers.GlobalAveragePooling2D(),  
layers.Dense(64, activation='relu', kernel_regularizer=keras.regularizers.l2(1e-4)),  
layers.Dropout(0.5),  
layers.Dense(num_classes, activation='softmax')
```

Рисунок 4.45 – Вихідний шар

Для оптимізації параметрів використовується Adam зі швидкістю навчання 0.0009. Як основна метрика обрана точність класифікації, що дозволяє безпосередньо відстежувати частку правильних рішень на тренуванні та валідації.

Тренування запускається з розміром пакета 5 та максимальною кількістю епох 2000, але з двома запобіжниками від перенавчання. По-перше, використано ModelCheckpoint, який відстежує найкраще значення валідаційної точності та зберігає ваги моделі з максимальним показником, по-друге,

застосовано EarlyStopping із моніторингом val\_accuracy, терпимістю 300 епох і відновленням найкращих ваг, що дає можливість почати з великого ліміту епох, але фактично зупинитися тоді, коли поліпшення на валідації стабільно відсутнє (див. рис. 4.46).

```
checkpoint_path = "/content/drive/MyDrive/fibrosis_glrlm_cnn_best_2.keras"
checkpoint = ModelCheckpoint(
    checkpoint_path,
    monitor='val_accuracy',
    verbose=1,
    save_best_only=True,
    mode='max'
)
earlystop = EarlyStopping(
    monitor='val_accuracy',
    patience=300,
    verbose=1,
    restore_best_weights=True
)
callbacks = [checkpoint, earlystop]

history = model.fit(
    datagen.flow(X_train, y_train, batch_size=BATCH_SIZE),
    validation_data=(X_val, y_val),
    epochs=EPOCHS,
    callbacks=callbacks
)
```

Рисунок 4.46 – Навчання моделі з контрольними колбеками

Після завершення тренування модель обчислює передбачення для валідаційних даних, з яких формується матриця помилок (див. рис. 4.47). На основі тих самих передбачень друкується класифікаційний звіт (див. рис. 4.48) із показниками precision, recall та F1-score для кожного класу, а також зі зведеними середніми значеннями.




Рисунок 4.47 – Матриця помилок (8 класів)

	precision	recall	f1-score	support
1	0.42	1.00	0.59	5
2	0.00	0.00	0.00	3
3	0.00	0.00	0.00	2
4	1.00	0.40	0.57	5
5	0.00	0.00	0.00	4
6	0.60	0.50	0.55	6
7	0.75	0.50	0.60	6
8	0.43	0.86	0.57	7
accuracy			0.50	38
macro avg	0.40	0.41	0.36	38
weighted avg	0.48	0.50	0.44	38

Рисунок 4.48 – Класифікаційний звіт

Дана модель має точність 50%. Покращення точності на 8% і 5% відповідно в порівнянні з попередніми багатокласовими моделями.

#### 4.5 Моделі з розбиттям на області інтересу

Для покращення точності системи класифікації фіброзу печінки, розглядається варіант створення багаторівневого класифікатора навченого спочатку на областях інтересу, а потім на загальних знімках.

Для реалізації розбиття повноцінного зображення на фрагменти областей інтересу було застосовано алгоритм, створений під час написання бакалаврської роботи. Нагадаю: алгоритм приймав повноцінні зображення, потім обрізав їх до потрібного розміру і розбив зображення на фіксовану кількість фрагментів з перекриттям.

На даному етапі було встановлено розмір зображень  $352 \times 290$ , перекриття – 70%, кількість фрагментів – 12. Приклад отриманих зображень після такого фрагментування можна побачити на рис. 4.49.




Рисунок 4.49 – Поділене зображення на фрагменти

Отримання текстурних характеристик з усіх зображень відбувалось таким же чином як і для цілих зображень. Розмір встановлений для текстурних карт –  $64 \times 64$ .

Навчання згорткової нейромережі відбувалось на попередньо фрагментованих зображеннях, які збережені у форматі .png у вигляді тензорів розміру  $64 \times 64 \times 7$  (для текстурних характеристик на основі матриці довжин відтінків сірого та на основі гістограми відтінків сірого) та  $64 \times 64 \times 5$  (для текстурних характеристик на основі матриці суміжності відтінків сірого). Кожен такий фрагмент є частиною вихідного зображення й містить сім каналів ознак – їх мережа сприймає як багатоканальний вхід. Дані попередньо розподілені по класах у папках train і val, тому під час завантаження кожен фрагмент автоматично отримує відповідну мітку. Аугментація використовується в мінімальному обсязі – лише генератор потоку подачі даних без додаткових перетворень. Модель побудована як послідовність чотирьох згорткових блоків із поступовим збільшенням кількості фільтрів (32, 64, 128, 224), кожен з яких містить згортку з активацією ReLU, шар BatchNormalization, підвибірку MaxPooling2D та Dropout для запобігання перенавчанню. Після згорткових шарів вихід перетворюється через Flatten, далі проходить через щільний шар на 224 нейрони з Dropout і переходить у вихідний шар Softmax для класифікації восьми класів. Для оптимізації використовується Adam з невеликою швидкістю навчання, а функцією втрат є sparse categorical crossentropy. Навчання виконується з батчами по 12 зображень, з контролем якості на валідаційних даних і механізмом дострокової зупинки при відсутності покращення точності, а також зі збереженням найкращої моделі.

Оцінка отриманих моделей проводилась за допомогою матриці помилок (див. рис. 4.50) та класифікаційного звіту (див. рис. 4.51).




Рисунок 4.50 – Матриця помилок для моделі на основі гістограми відтінків сірого з фрагментацією зображень

	precision	recall	f1-score	support
1	0.18	0.23	0.21	60
2	0.32	0.17	0.22	36
3	0.33	0.04	0.07	24
4	0.28	0.28	0.28	60
5	0.18	0.04	0.07	48
6	0.24	0.12	0.16	72
7	0.30	0.40	0.35	72
8	0.27	0.49	0.35	84
accuracy			0.26	456
macro avg	0.26	0.22	0.21	456
weighted avg	0.26	0.26	0.24	456

Рисунок 4.51 – Класифікаційний звіт для моделі на основі гістограми відтінків сірого з фрагментацією зображень

На цьому етапі тренування моделей з використанням текстурних характеристик зображень областей інтересу виникли труднощі.

Моделі групових бінарних класифікацій мали майже однакову якість з моделями бінарних класифікацій натренованих на цільних зображеннях, але все ж таки трохи нижче. Але якість моделей на основі текстурних характеристик дали набагато гірші результати. Точності багатокласових моделей натренованих на різних текстурних характеристиках фрагментованих

зображень в порівнянні з багатокласовими моделями натренованих на різних текстурних характеристиках цільних зображень представлено на рис. 4.52.




Рисунок 4.52 – Порівняння точності моделей

Зниження точності під час класифікації фрагментів ультразвукових зображень печінки порівняно з повними зображеннями пов'язане насамперед із втратою глобального контексту та структурної цілісності. Повнорозмірне зображення містить макроструктури, такі як розподіл ехогенності по всій паренхімі, межі сегментів, які модель може враховувати при прийнятті рішення. Коли ж зображення розбивається на невеликі фрагменти, кожен із них містить лише локальну ділянку тканини без анатомічної прив'язки чи просторових залежностей, тому характерні зміни, притаманні патологічним станам, можуть просто не потрапити до вибірки. Додатково кожен фрагмент може бути неоднорідним за текстурою або навпаки надто однорідним, що знижує дискримінативність ознак і підсилює шум.

У результаті текстурні дескриптори, які на повних зображеннях відображають закономірності поширення патології, на окремих фрагментах стають статистично нестабільними, а модель починає плутати класи. Крім того, через варіативність ехоструктури всередині одного класу та ймовірну появу

«здорових» ділянок у патологічних випадках зростає внутрішньокласовий розкид і падає контрастність між класами.

Розподіл на області інтересу був дуже актуальний для зображень з судинами печінки, але з зображеннями повної тканини печінки перестав давати результат. Для подальшого створення системи класифікації моделі навчені на областях інтересу не будуть застосовані, через їх погану якість і сожливість негативно вплинути на роботу системи.

#### 4.6 Об'єднання архітектури моделей

Мета-класифікатор створюється як другий рівень ансамблю: спочатку для кожного зображення обчислюються сім ймовірностей із сімох бінарних порогових моделей, потім з трьох багатокласових ймовірностей обчислюється по вісім ймовірностей на кожне зображення (див. рис. 4.53). Ці всі ймовірності утворюють вектор ознак фіксованої довжини, який подається на другий етап. На другому етапі потрібно навчити окрему модель другого рівня – багатокласову логістичну регресію чи нейромережу.



Рисунок 4.53 – Структура розроблюваного мета-класифікатора

##### 4.6.1 Отримання векторів ймовірностей навчених моделей

Ймовірності базових моделей отримувалися так: зображення для тренувального й тестового наборів відкривалися генератором інференсу без

аугментацій і без перемішування, щоб зафіксувати стабільний порядок. Для кожної порогової моделі створювався окремий потік даних із двокласним ремапом міток, що відповідає саме цьому порогу (ліва група об'єднаних «нижчих» класів проти правої групи «вищих»), після чого завантажувалася навчена модель і виконувалося передбачення для всіх зразків у каталозі. Оскільки вихідний шар бінарний із сигмоїдою, кожен прогноз безпосередньо інтерпретувався як ймовірність належності до правої групи. Для багатокласових моделей алгоритм такий же: запускається передбачення на тренувальній та валідаційній, унаслідок чого для кожного зображення генерується вектор із восьми ймовірностей, де кожен елемент відповідає своїй цільовій категорії.

Отримані масиви ймовірностей додавалися як окрема колонка до таблиці разом (див. рис. 4.54), початковим восьмикласовим ярликом і міткою належності до тренувального чи тестового піднабору; після проходження всіх моделей таблиця зберігалася у єдиний CSV для подальшого тренування мета-класифікатора.

dat	y_true	p_thr_1	p_thr_2	p_thr_3	p_thr_4	p_thr_5	p_thr_6	p_thr_7	s_c0	s_c1	s_c2	s_c3	s_c4	s_c5
train	1	0.84676075	0.025919013	0.019503905	0.33524308	0.34385955	0.16043325	0.015649268	0.99999984	5.141476e-15	1.01025e-12	7.3868564e-11	5.5865074e-10	2.387766e-13
train	1	0.797475	0.1606624	0.23541422	0.43983328	0.4112526	0.27560323	0.13724728	0.9999813	3.121246e-10	1.8618092e-10	1.4161196e-10	8.999008e-13	1.1009041e-13
train	1	0.8405457	0.12101636	0.11240941	0.33682778	0.23604842	0.08498356	0.028729144	0.99998426	3.1869126e-07	2.8276746e-08	1.3598845e-05	3.752473e-09	1.4280042e-09
train	1	0.7979989	0.23791748	0.15033808	0.49466807	0.5020139	0.35320508	0.060735647	1.0	1.0399812e-17	2.219383e-16	5.1024836e-13	1.7129876e-14	3.9753982e-19
train	1	0.8364202	0.10289274	0.12817235	0.38653052	0.32998496	0.16653913	0.10841366	0.999941	5.707386e-06	3.734842e-07	1.5833503e-06	7.371484e-09	1.7579306e-10
train	1	0.8491265	0.12234173	0.101233505	0.22615731	0.20567359	0.0791422	0.03405634	0.9993274	0.0005821866	7.9175135e-07	7.653286e-05	1.2446937e-08	8.990227e-07
train	1	0.8210645	0.16799442	0.18073547	0.38922152	0.34835503	0.14935869	0.100358196	0.99983394	2.3784762e-07	0.00016388558	1.8781365e-10	1.3111856e-10	3.5132255e-11
train	1	0.8785758	0.04027256	0.027934197	0.46269384	0.52196753	0.1601557	0.05833463	0.9999999	1.9294782e-08	4.7115996e-08	4.4720166e-10	2.3489792e-12	9.920686e-08
train	1	0.77830138	0.1040995	0.11746736	0.32420078	0.2853881	0.12451279	0.023991117	0.9997147	1.07280775e-05	5.2242323e-05	0.00020229061	5.5113895e-07	7.1545266e-08
train	1	0.76897866	0.31262118	0.24986349	0.42232513	0.3956851	0.26182368	0.07957765	0.99999356	8.654886e-08	4.291654e-07	3.772088e-08	4.13561e-08	1.8659381e-10
train	1	0.7552875	0.18382387	0.2804693	0.4334264	0.40335882	0.19324234	0.08550427	0.9999596	7.109584e-09	9.4846047e-07	3.8456844e-10	2.3904045e-13	5.489539e-15
train	1	0.8238211	0.19913256	0.24600026	0.4228693	0.45147613	0.25642008	0.16638626	0.99999654	1.6085541e-09	3.4151873e-10	2.5575317e-09	4.576238e-13	3.1633765e-12
train	2	0.8265038	0.20678411	0.27293506	0.3866279	0.35830185	0.27967522	0.13152365	1.4853964e-13	0.9999974	8.1151974e-10	1.4094127e-06	1.3541985e-07	7.9654984e-07
train	2	0.8431623	0.11799559	0.17247422	0.38962093	0.29272723	0.1835184	0.06936032	1.3803243e-10	0.9999683	1.1434129e-06	2.5300856e-05	9.4026234e-07	3.0372887e-06
train	2	0.9069011	0.08633404	0.06783722	0.60667485	0.3502677	0.08752968	0.039253786	2.6780855e-18	0.99995816	3.645505e-12	4.312e-06	1.4620231e-09	3.7488326e-05
train	2	0.86842203	0.22784889	0.15311922	0.39896277	0.36720654	0.2548098	0.056579154	1.4554764e-09	0.99987626	3.007114e-08	1.7730724e-06	8.968307e-08	9.048829e-05
train	2	0.832592	0.13862118	0.16244559	0.35215938	0.31329677	0.11774808	0.039685648	1.4692206e-07	0.9999614	7.6078804e-06	1.6777443e-05	4.243034e-06	2.9371202e-07
train	2	0.8746598	0.19434246	0.2817575	0.4020717	0.35995826	0.19404846	0.12564772	6.2311166e-22	0.99999976	1.1261732e-12	3.6931517e-15	3.6288087e-14	2.2023792e-13
train	3	0.84957135	0.8063078	0.472574	0.3624714	0.31765133	0.15343468	0.061595146	4.207474e-12	1.7601151e-13	1.0	4.6548143e-09	3.2655674e-15	1.24424e-15
train	3	0.84097344	0.70143455	0.16555108	0.39375734	0.3446373	0.15217745	0.05425267	1.2926705e-05	0.0002642386	0.97102237	0.002812014	0.01652012	0.0035996558
train	3	0.9077815	0.9827803	0.108352646	0.4023303	0.28393805	0.110064685	0.042218603	2.8539736e-07	7.440443e-06	0.9927804	0.0005822814	0.0052658725	0.0006837528
train	3	0.8583181	0.7208566	0.16342334	0.42366683	0.30103126	0.17805368	0.14262217	1.8802768e-05	1.208267e-10	0.99996793	2.8135583e-13	3.5565668e-07	4.450298e-09
train	3	0.87111884	0.83015513	0.32483445	0.3645343	0.31747183	0.13980884	0.1307246	0.00011282863	2.8985863e-09	0.99952483	1.1847431e-09	5.244291e-08	6.6683475e-10
train	3	0.8300828	0.8290281	0.18031237	0.4509758	0.40143532	0.147987	0.056230374	2.0866924e-05	9.479191e-06	0.9975763	0.001610338	0.0006167496	8.642132e-05
train	4	0.88184386	0.82063204	0.8654016	0.44180077	0.34906092	0.26757625	0.15020336	5.9625086e-06	6.4523454e-05	1.703047e-05	0.9999118	8.905297e-09	7.2208337e-07
train	4	0.8657801	0.7618308	0.6761423	0.39241973	0.3289924	0.12136843	0.038559593	2.4875373e-05	0.00010259484	0.000135396	0.99972814	2.0856447e-07	2.7148612e-06
train	4	0.87164587	0.7570207	0.7928378	0.27661285	0.23004025	0.08813635	0.043869756	2.0532249e-05	5.5639717e-05	0.00022494579	0.99969097	1.6897735e-06	8.1824416e-05
train	4	0.81545784	0.77702415	0.7969685	0.5023483	0.5296833	0.27448127	0.06186795	1.7262253e-05	6.0818406e-06	8.907762e-08	0.9999573	4.4461843e-10	6.704146e-08

Рисунок 4.54 – Фрагмент таблиці з векторами ймовірностей

## 4.6.2 Навчання на мета-рівні

Для побудови фінального рівня класифікації використано мета-модель, яка навчається не на сирих зображеннях, а на ймовірностях, отриманих від

попередніх моделей. Після того, як для кожного зразка були сформовані мета-ознаки у вигляді набору прогнозних значень, завантажено їх у таблицю та виокремлено лише числові стовпці, які безпосередньо слугують вхідними даними для мета-класифікації. Цільова змінна бралася з тієї ж таблиці, де збережені справжні класи зображень.

Для навчання було використано логістичну регресію як мета-класифікатор. Ця модель добре підходить для роботи з уже сформованими вхідними ознаками, не вимагає тривалої підготовки та дозволяє коректно поєднувати прогнози базових моделей в один фінальний результат. Щоб оцінити якість такої моделі і переконатися, що вона не «запам'ятовує» дані, а дійсно узагальнює закономірності, застосовано стратифіковану k-fold перевірку.

Сутність цього підходу полягає в тому, що всі дані діляться не один раз, а кілька, причому кожного разу нова частина використовується як валідаційна, а решта – як тренувальна. Стратифікація гарантує, що в кожній частині зберігається та сама пропорція класів, що і в усій вибірці. Простіше кажучи, модель не перевіряла лише на одному відкладеному наборі, а була дана їй можливість по черзі «побачити» всі зразки і в тренувальних, і у валідаційних умовах. Такий метод дозволяє отримати більш об'єктивну оцінку, бо модель не пристосовується під одну єдину частину даних, а показує стабільний результат на різних комбінаціях.

У процесі кожного проходу було навчено логістичну регресію на тренувальних фрагментах, прогнозовано класи для відповідної валідаційної частини та збережено точність. Після завершення всіх ітерацій обчислено середнє значення точності, що дало більш реалістичне уявлення про здатність моделі узагальнювати.

Фінальна мета-модель має точність 83% (див. рис. 4.55). Якість отриманої моделі значно зросла, якщо порівнювати її з окремими розробленими моделями.

```
==== ПІДСУМКИ LogisticRegression (K-Fold) ====  
Fold 1 accuracy: 0.8462  
Fold 2 accuracy: 0.7692  
Fold 3 accuracy: 0.7692  
Fold 4 accuracy: 0.9200  
Fold 5 accuracy: 0.8800  
  
Mean accuracy: 0.8369
```

Рисунок 4.55 – Точність мета-моделі

#### 4.7 Створення програмного застосунку

Для створення програмного застосунку системи класифікації ступенів фіброзу печінки було реалізовано інтерфейс на Qt через PySide6 із власними віджетами, потоками та індикатором прогресу.

Робота програми від моменту запуску така: відкриваємо УЗ-зображення, за бажанням виділяємо фрагмент( з мінімальним розміром 150\*150), після чого зображення проходить нормалізацію та масштабування і подається в послідовний конвеєр інференсу з обмеженням споживання пам'яті; спершу обчислюються ймовірності семи порогових бінарних моделей, далі з вихідного кадру будуються три набори текстурних карт (гістограмні, GLCM і GLRLM) і для кожного набору запускається окрема багатокласова CNN; усі отримані ймовірності об'єднуються в ознаковий вектор, який мета-класифікатор перетворює на фінальні ймовірності класів і прогноз стадії фіброзу.

Інтерфейс у реальному часі показує прогрес, підсумковий клас, таблицю «відсотків» базових моделей і відсортовані фінальні ймовірності, а також дозволяє скинути або змінити ROI та повторити класифікацію.

Початкове вікно програми зображено на рис. 4.56.



Рисунок 4.56 – Початкове вікно програмного застосунку

Вікно програми з завантаженим зображенням для класифікації зображено на рис. 4.57.



Рисунок 4.57 – Вікно з завантаженим зображенням

Вікно програми з можливістю виділення фрагменту зображено на рис. 4.58.

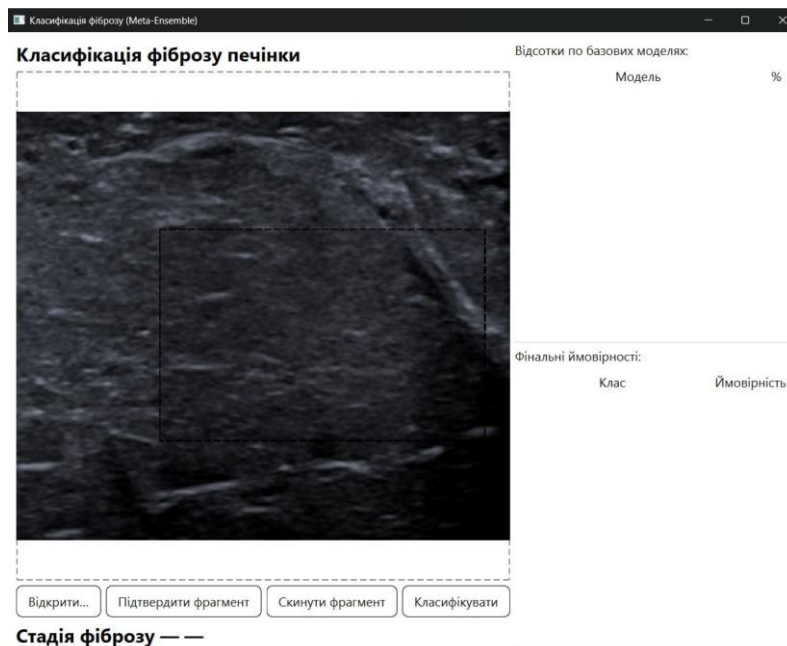


Рисунок 4.58 – Вікно з виділенням фрагменту

Виділення фрагменту обмежено розміром 150\*150, тому при такій спробі виводиться повідомлення про помилку, що зображено на рис. 4.59.

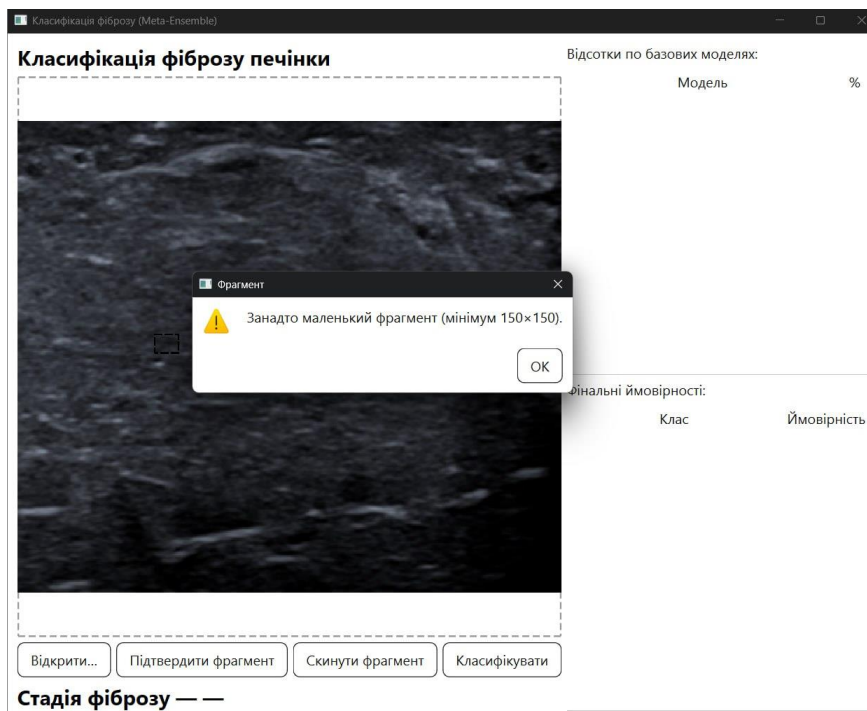


Рисунок 4.59 – Вікно з помилкою виділення фрагменту

Результат класифікації зображення подано на рис. 4.60.



Рисунок 4.60 – Вікно з результатом роботи програмного застосунку

## Висновок з розділу 4

У цьому розділі було послідовно реалізовано повний цикл побудови системи класифікації ступеня фіброзу печінки за ультразвуковими зображеннями – від підготовки даних до створення прикладного програмного інтерфейсу [5]. Спочатку виконано аналіз вихідної вибірки УЗ-зображень паренхіми печінки, проведено їх попередню обробку: усунення дефектів, нормалізацію розмірів, нормалізацію яскравості та розподіл на тренувальні й тестові підмножини. Далі були розроблені та реалізовані функції виділення текстурних характеристик на основі гістограм відтінків сірого, матриці суміжності відтінків сірого (GLCM) та матриці довжин відтінків сірого (GLRLM). Для кожного підходу сформовано багатоканальні карти ознак фіксованого розміру, які використовувалися як вхідні дані для окремих згорткових нейронних мереж у багатокласових задачах класифікації. Паралельно побудовано групові бінарні класифікатори, що розділяють сусідні

та проміжні стадії фіброзу, що дозволило оцінити здатність моделей відрізняти різні рівні ураження.

Окремо була досліджена стратегія навчання моделей на фрагментованих областях інтересу. Показано, що для повнозображень паренхіми поділ на дрібні фрагменти призводить до втрати глобального контексту та погіршення якості класифікації, тому моделі на основі ROI не були включені до фінальної системи. Водночас найкращі результати продемонструвала мета-модель, яка поєднує ймовірнісні виходи семи бінарних та трьох багатокласових CNN, досягаючи точності близько 83 % і суттєво перевершуючи окремі базові моделі.

Завершальним етапом стало створення програмного застосунку з графічним інтерфейсом користувача, який реалізує повний конвеєр інференсу: завантаження зображення, за потреби виділення фрагмента, автоматичну нормалізацію, послідовний запуск усіх моделей, об'єднання їхніх результатів мета-класифікатором та візуалізацію прогнозованої стадії фіброзу. Таким чином, у розділі представлено не лише окремі алгоритмічні компоненти, а й їх інтеграцію в цілісну, практично орієнтовану систему підтримки діагностики фіброзу печінки..

## РОЗДІЛ 5

### УЗАГАЛЬНЕННЯ РЕЗУЛЬТАТІВ РОБОТИ

У цьому розділі представлено детальний аналіз та інтерпретацію результатів обчислювальних експериментів, проведених у межах дослідження автоматизованої класифікації ступенів фіброзу печінки за УЗ-зображеннями. Розглянуто якість роботи розроблених моделей – як окремих бінарних класифікаторів і багатокласових нейронних мереж, так і мета-моделі, що поєднує їх результати. Показано, яким чином застосовані методи обробки зображень та текстурного аналізу впливають на точність розпізнавання різних стадій фіброзу.

Окрему увагу приділено порівнянню запропонованого підходу з існуючими аналогами в сучасній науковій літературі, що використовують глибокі згорткові мережі, RF-сигнали та еластографічні методи. Таке зіставлення дозволяє продемонструвати сильні сторони запропонованої системи, зокрема її здатність працювати зі стандартними ультразвуковими зображеннями, розширену деталізацію класифікації та переваги побудованого ансамблю моделей.

#### 5.1 Аналіз та інтерпретація отриманих результатів

Вхідні дані для дослідження становили 128 УЗ-зображень паренхіми печінки від 120 пацієнтів, розподілені на 8 класів, що відповідають основним та проміжним стадіям фіброзу (F0, F1, F1–2, F2, F2–3, F3, F3–4, F4) [5]. Такий обсяг і структура вибірки є типовими для реальних клінічних даних, але водночас створюють низку викликів: невелика кількість прикладів, нерівномірний розподіл між класами та часткова візуальна схожість сусідніх стадій.

У процесі підготовки даних було виконано: ручне видалення частин інтерфейсу апарату, нормалізацію розмірів зображень до узгодженого формату, нормалізацію яскравості (rescale до діапазону  $[0, 1]$ ), поділ на тренувальну та

тестову вибірки у співвідношенні 70/30 для кожного класу.

Ці кроки дозволили мінімізувати вплив технічних відмінностей апаратури та покращити умови для навчання нейронних мереж.

### **5.1.1 Результати групових бінарних класифікаторів**

Було розроблено сім бінарних класифікаторів, кожен з яких розділяє простір класів за певним порогом (F0 проти усіх, «F0-2» проти «F2-4» і т.д.). Для всіх класифікаторів використовувалася однакова компактна CNN-архітектура з двома згортковими шарами, підвибіркою, одним повнозв'язним шаром та Dropout-регуляризацією.

Отримані результати показали:

- для «грубих» порогів (наприклад, F0 vs  $\geq$ F1) та виділення пізніх стадій (класифікатори №1, №2, №3, №7) точність досягала 0,82–0,87;
- найгірші результати спостерігалися в зонах переходу між сусідніми стадіями (класифікатори №4, №5, №6), де точність опускалася до 0,63–0,76.

Характерною проблемою виявилось суттєве «просідання» якості класифікації для класів, які відповідають раннім та проміжним стадіям (F0, F1, F1–2). Матриці помилок показали, що моделі схильні відносити більшість випадків до «більш фіброзних» класів. Це пояснюється як візуальною схожістю початкових стадій фіброзу, так і дисбалансом вибірки (менша кількість прикладів F0–F1-2 порівняно з більш просунутими стадіями).

Водночас висока чутливість до «грубих» порогів (наприклад, відсутність фіброзу/наявність, відсутність цирозу/F4) є клінічно важливою, оскільки саме такі сценарії часто використовуються у діагностичних алгоритмах.

### **5.1.2 Результати багатокласових моделей на основі текстурних характеристик**

Для більш глибокого аналізу структури паренхіми печінки було сформовано три набори текстурних карт:

- на основі гістограми відтінків сірого (Mean, Std, Variance, Skewness, Kurtosis, Energy, Entropy);

- на основі GLCM (контраст, несхожість, однорідність, енергія, кореляція);
- на основі GLRLM (SRE, LRE, GLN, RLN, RP, LGRE, HGRE).

Усі карти були приведені до розміру 64×64.

Були побудовані три окремі багатокласові CNN для кожного типу текстурних ознак. Основні результати:

- модель на основі гістограм відтінків сірого – точність близько 42 %;
- модель на основі GLCM – близько 45 %;
- модель на основі GLRLM – близько 50 %.

Незважаючи на відносно невисокі абсолютні показники, слід враховувати: задача є складною, адже 8 класів з високим ступенем перетину візуальних ознак, випадковий вгадування для 8 класів дає лише 12,5 %, отже, всі три моделі суттєво перевищують випадковий рівень, а також матриці помилок демонструють, що моделі краще розрізняють «грубі» стадії (F0/F4) та гірше – проміжні, що цілком відповідає клінічній практиці.

Найкращим виявився підхід на основі GLRLM, що свідчить про важливість опису протяжності однорідних сегментів сірого для диференціації ступенів фіброзу.

### **5.1.3 Оцінка моделей з розбиттям на області інтересу**

Додатково було протестовано підхід з фрагментацією зображення на 12 перекривних фрагментів (ROI) з перекриттям 70 %. Цей метод добре зарекомендував себе в попередніх дослідженнях для судин печінки, однак для повної паренхіми показав гірші результати:

- точність багатокласових моделей на текстурних картах фрагментів виявилася суттєво нижчою, ніж для цільних зображень;
- спостерігалось «зашумлення» ознак та втрата глобального контексту (розподіл ехогенності по всій паренхімі, характерні глобальні патерни).

Причиною є те, що фрагменти втрачають анатомічну прив'язку та глобальну структуру, а локальні текстурні характеристики стають статистично нестабільними. Унаслідок цього моделі починають плутати класи, особливо у проміжних станах. З огляду на це, ROI-орієнтовані текстурні моделі не були включені до фінальної системи.

#### **5.1.4 Ефективність мета-класифікатора**

Ключовим результатом роботи є побудова мета-класифікатора, який поєднує 7 бінарних моделей та 3 багатокласові CNN на текстурних картах.

На вході мета-модель (логістична регресія) отримує вектор ймовірностей від базових моделей і виконує кінцеву 8-класову класифікацію. За результатами стратифікованої k-fold перевірки мета-класифікатор досяг точності 83 %, що істотно перевищує якість будь-якої окремої моделі.

#### **5.2 Порівняння з існуючими підходами та обговорення актуальності**

У розділі 1 було проаналізовано низку сучасних робіт, спрямованих на автоматизовану оцінку фіброзу печінки.

У роботі Ш. Хірати використано класичну VGG-16 із додатковими каналами, що базуються на статистичних моментах ехосигналу (skewness, kurtosis). Система працює з 4 класами (F1–F4) та демонструє покращення точності при інтеграції статистичних ознак. У запропонованій роботі:

- використано ширший набір текстурних дескрипторів (гістограма, GLCM, GLRLM замість двох моментів);
- реалізовано 8-класову класифікацію, включно з проміжними стадіями;
- запроваджено мета-рівень, який узагальнює результати різних моделей.

Таким чином, робота розширює підхід Хірати не лише за кількістю ознак, але й за деталізацією класифікації та архітектурою ансамблю.

У дослідженні К. Вана використовується 2D shear wave elastography (SWE) та глибинні мережі для радіоміки жорсткості тканини. Хоча такі методи показують високу діагностичну точність, їх застосування обмежене доступністю SWE-модулів та вартістю обладнання. На відміну від цього, у даній роботі:

- система працює на стандартних B-mode знімках, які доступні у значно більшій кількості клінік;
- не вимагає доступу до спеціалізованих еластографічних або RF-модулів.

Роботи Х. Ай та Й. Хуана базуються на аналізі RF-сигналів, що справді є більш інформативними щодо мікроструктури тканини. Проте доступ до RF-даних у рутинній практиці, як правило, обмежений можливостями виробника апарату та специфічним програмним забезпеченням. Запропонована система:

- орієнтована на найбільш поширені умови реальної клінічної практики;
- працює з даними, які лікар уже має у стандартному форматі;
- дозволяє отримати додаткову діагностичну інформацію без зміни обладнання.

Окремо слід відзначити еволюцію від попередніх бакалаврських напрацювань: від аналізу судин печінки з бінарною класифікацією до комплексної системи, що:

- працює з паренхімою печінки;
- поєднує декілька CNN та текстурні підходи в єдиній мета-моделі;
- має повноцінний програмний застосунок із графічним інтерфейсом.

Практична значущість роботи полягає в тому, що розроблена система: може використовуватися як допоміжний інструмент для лікаря, який надає другий, автоматизований «погляд» на УЗ-зображення; дозволяє

стандартизувати оцінку ступеня фіброзу, зменшуючи суб'єктивний фактор; потенційно придатна до інтеграції в клінічні робочі процеси.

### **5.3 Обмеження дослідження та напрями подальшого розвитку**

Попри досягнуті результати, робота має обмеження: обмежений обсяг вибірки (128 зображень) і дисбаланс між класами, що впливає на стабільність і узагальнюваність моделей та відсутність незалежної зовнішньої валідації на даних з інших клінік чи інших типів ультразвукових апаратів.

Можливі напрями подальших досліджень:

- розширення бази даних за рахунок багатопрофільних центрів і різних типів апаратів;
- застосування методів transfer learning на більш глибоких архітектурах та в комбінації з уже навченими медичними моделями;
- оптимізація архітектури мета-рівня (включно з калібруванням ймовірностей для клінічного використання);
- інтеграція системи в клінічні інформаційні системи та проведення проспективних клінічних досліджень для оцінки впливу на діагностичний процес.

### **Висновки з розділу 5**

У даному розділі було узагальнено результати магістерської роботи та показано що:

- розроблена система класифікації фіброзу печінки на основі УЗ-зображень реалізує комплексний підхід, який поєднує текстурні характеристики (гістограмні, GLCM, GLRLM), групові бінарні CNN та багатокласові моделі на мета-рівні;
- задачі технічного завдання повністю виконано: сформовано датасет, реалізовано функції виділення ознак, побудовано та оцінено моделі,

створено програмний застосунок;

- досягнута точність мета-класифікатора на рівні близько 83 % свідчить про доцільність ансамблевого підходу та його потенційну клінічну придатність;

- у порівнянні з відомими аналогами, що використовують RF-сигнали або SWE, запропоноване рішення має важливу перевагу – працює зі звичайними B-mode знімками, які є найбільш доступними в рутинній практиці.

## **РОЗДІЛ 6**

### **СТАРТАП-ПРОЄКТ ЗА ТЕМОЮ МАГІСТЕРСЬКОГО ДОСЛІДЖЕННЯ**

У розділі подано узагальнену характеристику проєкту як медичного AI-рішення, описано його призначення, цінність для користувачів, основні підходи до реалізації та організації роботи стартапу [51]. Наведено ключові аспекти бізнес-моделі, ресурси, необхідні для впровадження системи, а також орієнтовні фінансові та ринкові показники, що дають уявлення про економічну доцільність та потенціал розвитку проєкту [51].

#### **6.1 Назва проєкту**

Визначення ступеню фіброзу печінки на основі аналізу характеристик УЗ зображень паренхіми засобами нейронних мереж.

#### **6.2 Короткий опис проєкту**

Проєкт передбачає створення високоточного програмного рішення – системи, яка автоматично визначає ступінь фіброзу печінки (F0–F4) за ультразвуковими зображеннями паренхіми органу [5, 51]. Система використовує згорткові нейронні мережі (CNN) у поєднанні з текстурним аналізом тканини печінки, що дозволяє врахувати як візуальні, так і глибинні структурні зміни. Програмний інструмент орієнтований на впровадження в практику лікарів УЗД, гастроентерологів та телемедицини для заміни інвазивної, дороговартісної біопсії.

Особливості системи:

- побудована на сучасних архітектурах нейромереж з можливістю донавчання;
- адаптована під стандартні УЗ-знімки.

## **6.3 Бізнес модель**

### **6.3.1 Цінність продукту**

Цінними якостями продукту відмінними від існуючих є (фактори створення цінності) [51, 52]:

- забезпечує неінвазивну, безпечну діагностику фіброзу без необхідності біопсії;
- мінімізує людський фактор в інтерпретації УЗ-знімків – дає об'єктивний висновок;
- вирішує проблему низької точності візуальної оцінки стадій фіброзу;
- економить час лікаря - аналіз триває до 1 хвилини.

### **6.3.2 Виконання вимог користувачів**

- «Надії» споживача (пацієнта або клініки) - на можливість отримати точну, швидку та безпечну діагностику, уникнувши біопсії, яка викликає стрес, тривогу та потребує післяопераційного догляду;
- «Бажання» лікаря - мати у своєму розпорядженні інструмент, що допоможе позбавити пацієнта непотрібної інвазивної процедури, зберігши при цьому діагностичну точність;
- «Хоче бути»: клініка - сучасною, цифровізованою, з високими стандартами обслуговування; лікар - професійно підкованим, технологічно оснащеним, швидким у прийнятті рішень; пацієнт - здоровим, спокійним і впевненим, що його стан контролюється об'єктивно.

### **6.3.3 Сегмент споживачів**

Цільовими споживачами є: приватні та державні клініки, що мають відділення ультразвукової діагностики, лікарі-гастроентерологи, гепатологи, УЗ-спеціалісти, телеклініки та телемедичні сервіси, які працюють із дистанційною діагностикою, навчальні заклади та дослідницькі інститути - для навчання й аналізу УЗ-даних.

Потреби клієнтів: доступ до швидкої та точної діагностики, підвищення стандартів якості обслуговування пацієнтів, зменшення витрат на дорогі аналізи, інструмент для прийняття рішень при великому потоці пацієнтів.

Як вони звикли купувати?

- Придбання ліцензії програмного забезпечення;
- Підписка із щомісячною оплатою;
- Пакети з аналізу знімків (оплата за кількість досліджень) [51].

### **6.3.4 Канали збуту**

Головними каналами збуту продукту можуть бути [51]:

- Прямі продажі в лікарні через презентації, демонстрації;
- Співпраця з дистриб'юторами УЗ-обладнання;
- Онлайн-інтеграція з телемедичними платформами;
- Участь у тендерах на цифрові медичні рішення.

Післяпродажна підтримка:

- Навчальні відео та інструкції;
- Можливість спілкування на форумі професіоналів;
- Консультації з технічних та клінічних питань [51].

### **6.3.5 Взаємодія з користувачами**

Залучення користувачів: демонстраційний доступ до системи з обмеженим функціоналом, який дозволяє ознайомитися з основними можливостями без потреби у встановленні; пробний період тривалістю 7–14 днів, під час якого клінік може протестувати повний функціонал на власних даних; презентації та навчальні зустрічі у медичних закладах, включно з короткими семінарами щодо застосування системи в клінічній практиці [51].

Підтримка користувачів: телефонна лінія технічної підтримки у робочі години для швидкого вирішення критичних питань; база знань, що містить відеоінструкції [51].

### **6.3.6 Дохід проєкту**

Дохід буде отримуватись шляхом прямих та посередницьких продажів готових до експлуатації продукту, а також відповідно до зазначених вище каналів збуту [51, 53].

### **6.3.7 Ключові види діяльності**

Ключовим видом діяльності стартапу є здійснення розробки і навчання нейромережі, інтеграція в медичні робочі процеси, клінічна валідація результатів та розробка інтерфейсу [51, 53].

## **6.4 Ключові ресурси**

### **6.4.1 Матеріальні ресурси**

Для функціонування програмного рішення будуть використані наступні матеріальні ресурси [51]:

- Орендована технічна інфраструктура - розгортання серверів для навчання нейронних мереж здійснюватиметься на хмарних платформах (Google Cloud, AWS, Azure) з GPU-підтримкою;
- Робочі станції для локальної розробки - ноутбуки/ПК з потужними відеокартами (NVIDIA RTX/Quadro), які будуть використовуватись на етапі дослідження та тестування;
- Закупівля та оренда хмарних обчислювальних потужностей - для масштабування, зберігання зображень та розгортання сервісу;
- Ліцензійне програмне забезпечення - Python IDE, інструменти медичного аналізу зображень, бібліотеки комп'ютерного зору (OpenCV, PyTorch, TensorFlow) з комерційними ліцензіями [51].

### **6.4.2 Інтелектуальні ресурси**

1. Власноруч розроблений алгоритм комбінованої нейронної мережі, що включає згорткову CNN-модель і модулі текстурного аналізу;
2. Авторське право на архітектуру системи розпізнавання ступеня фіброзу печінки;

3. Створена база анонімованих УЗ-зображень з відповідною медичною розміткою для навчання моделі;
4. Методика клінічної валідації продукту – експертне порівняння результатів із медичними висновками;
5. Документація проєкту: технічне завдання, інструкції для користувача, архітектурні схеми, опис API, сертифікаційна документація.

### **6.4.3 Людські ресурси**

1. Керівник проєкту - директор-організатор, менеджер проєктів зі знанням принципів цифрової трансформації в медицині, відповідальний за стратегію розвитку, пошук інвесторів, юридичне оформлення;
2. Технічний директор (СТО) - експерт зі штучного інтелекту, нейромереж і медичної візуалізації, володіє досвідом розробки та впровадження алгоритмів у сфері медичних зображень не менше 3 років;
3. Медичний консультант - лікар УЗД, який має досвід клінічного аналізу ступеню фіброзу, супроводжує валідацію моделі, створення медичних сценаріїв використання;
4. AI-інженер - фахівець із комп'ютерного зору та deep learning, відповідальний за побудову архітектури CNN, тренування моделі та її оптимізацію;
5. UI/UX-дизайнер - створює інтерфейс користувача для вебплатформи, орієнтуючись на зручність роботи для лікарів;
6. Backend-розробник - програміст, що відповідає за реалізацію логіки обробки зображень, API, взаємодію front-back частини;
7. Маркетолог та PR-менеджер - фахівець із просування стартапу в медичному середовищі, підготовки презентацій, участі у конференціях, формування іміджу проєкту;
8. Бухгалтер - спеціаліст з обліку витрат проєкту, контрактів, грантового супроводу, ведення звітності;

9. Асистент з документації - відповідальний за оформлення технічної та нормативної документації, супровід сертифікації [51].

#### **6.4.4 Фінансові ресурси**

- Гранти від державних та інноваційних фондів (наприклад, Український фонд стартапів) – очікуваний розмір гранту до 2000000 грн;
- Інвестиції від хакатонів, приватних фондів - на стадії pre-seed/seed – від 1500000 до 3000000 грн;
- Партнерське фінансування (клініки, університети) – у вигляді ресурсів, доступу до даних або оплати послуг – до 500000 грн;
- Резервний фонд та непередбачені витрати – близько 200000 грн [51].

#### **6.4.5 Ключові партнери**

- Клініки для пілотного тестування.
- Медичні університети (спільні дослідження, збір даних).
- Технічні платформи для хостингу та розгортання.

#### **6.4.6 Витрати**

- Витрати на розробку програмного забезпечення та моделей [51]:

До цієї групи належать витрати на оренду хмарних обчислювальних потужностей для тренування нейронних мереж (Google Cloud, AWS, Azure), закупівлю або оновлення робочих станцій із потужними GPU, придбання ліцензійного програмного забезпечення, а також оплату хостингу для розгортання сервісу [51]. Орієнтовний річний обсяг витрат становить 640000 – 990000 грн [51].

- Витрати на оплату праці команди: команда включає керівника проекту, технічного директора, медичного консультанта, AI-інженера, UI/UX-дизайнера, backend-розробника, маркетолога, бухгалтера та асистента з

документації [51]. З урахуванням середніх ринкових ставок загальні річні витрати на персонал становлять 2700000 – 4000000 грн [51].

- Юридичні витрати, сертифікація та клінічна валідація: включають підготовку юридичних документів, супровід договорів з медичними установами, проведення етапів експертної клінічної валідації та підготовку сертифікаційної документації [51]. Орієнтовні витрати складають 420000 – 760000 грн [51].

- Маркетинг та реалізація продукту: до цієї категорії належать створення промоматеріалів, розробка сайту, участь у медичних конференціях, презентаціях, а також витрати на пілотні інтеграції в клініках [51]. Загальна річна сума витрат становить 240000 – 470000 грн [51].

- Операційні витрати: включають адміністративні витрати, оплати комунікаційних сервісів, бухгалтерського обслуговування та резервний фонд для покриття непередбачених витрат [51]. Орієнтовна сума – 230000 – 390000 грн [51].

Підсумок річних витрат: загальні витрати на реалізацію проекту протягом року оцінюються в межах 3970000 – 6610000 грн, що відповідає середньому діапазону бюджетів для стартапів у сфері медичних AI-технологій [51].

#### **6.4.7 Споживчі властивості товару**

Програмний продукт для покупця має такі ключові переваги: дає змогу швидко і точно визначити ступінь фіброзу, зменшує потребу у проведенні інвазивних процедур (біопсія), працює з будь-якими стандартними УЗ-знімками, не залежить від конкретного апарату.

#### **6.5 Дослідження ринку**

На світовому ринку систем для діагностування стадій фіброзу засобами нейронних мереж немає, але існують системи які мають наближені властивості і можуть розвиватися (див. табл. 6.1) [51].

Таблиця 6.1 – Системи наближені до розроблюваної

№ з/п	Назва підприємства конкурента	Короткий опис діяльності	Короткий опис продукту/послуги	Схожість зі стартапом
1	FibroScan® (Echosens, Франція)	Розробка медичного обладнання для оцінки стану печінки	Апарати для неінвазивного визначення фіброзу методом віброеластографії	Висока: спільна мета - діагностика фіброзу без біопсії
2	Qure.ai	Розробка AI-рішень для медичних зображень	AI-аналітика для рентген-знімків, КТ, МРТ; рішення для діагностики туберкульозу, інсульту	Середня: використовують AI для медичних зображень, але інші діагнози
3	Lunit INSIGHT	AI-аналітика для радіології (Корея)	Автоматичний аналіз медичних зображень (рентген, КТ, МРТ) з AI	Середня: використовують AI для візуальної діагностики, але не для печінки
4	PathAI	AI-аналітика для гістопатології	Інструменти на основі ШІ для аналізу біопсійних зразків	Низька: інша технологія, але теж оцінка фіброзу

## 6.6 Елементи фінансового плану

### 6.6.1 Опис бізнес-проєкту

Організація розробки, впровадження та реалізації програмного комплексу продукту – інноваційної системи, яка автоматично визначає ступінь фіброзу печінки на основі УЗ-зображень, з використанням технологій згорткових нейронних мереж та текстурного аналізу, у формі IT-стартапу в галузі цифрової медицини, з орієнтацією на ринок України та подальший вихід на закордонні ринки [51].

### 6.6.2 Опис товару/послуги/технології

Програмний продукт призначений для медичних закладів, що здійснюють УЗ-діагностику печінки [51]. Система автоматично класифікує ступінь фіброзу (від F0 до F4) за УЗ-зображеннями паренхіми печінки. Призначення продукту - підвищення точності, швидкості та об'єктивності діагностики, зниження залежності від суб'єктивного досвіду лікаря.

### **6.6.3 Маркетинг та продаж**

Дослідження ринку рішень для неінвазивної діагностики фіброзу показує:

- У світі ринок інструментів для оцінки фіброзу активно зростає (використовується FibroScan, еластографія, але цифрових AI-рішень бракує);
- В Європі, США, Канаді такі рішення є частиною телемедицини, особливо після пандемії COVID-19;
- В Україні аналогічні рішення не представлені. Біопсія досі лишається основним методом визначення ступеня фіброзу, а кількість випадків захворювань печінки зростає щороку.

Маркетингова стратегія включає участь у медичних виставках (MEDICA, Public Health), запуск рекламних кампаній у соцмережах, пряма B2B-презентація в медзакладах, відеодемонстрації, публікації в професійних виданнях.

### **6.6.4 Фінансовий план**

Витрати на організацію стартапу на період 12 місяців:

- Розробка ПЗ та AI-моделі – 640000 – 990000 грн;
- Заробітна плата команди – 2700000 – 4000000 грн;
- Юридичні витрати та сертифікація – 420000 – 760000 грн;
- Маркетинг і збут – 240000 – 470000 грн;
- Операційні витрати – 230000 – 390000 грн [51].

Загальна річна сума витрат: 3970000 – 6610000 грн [51].

### **Висновок з розділу 6**

Проведений аналіз засвідчує, що запропонований стартап має чітко визначену цінність, сформований ринок потенційних споживачів і реалістичну модель монетизації [51]. Оцінені ресурси та витрати підтверджують можливість практичної реалізації проекту, а конкурентний аналіз демонструє наявність

вільної ніші у сфері AI-рішень для діагностики фіброзу печінки [51]. У поєднанні з технологічною новизною та актуальністю продукту це створює передумови для успішного впровадження системи на ринку медичних цифрових технологій [51].

## ЗАГАЛЬНІ ВИСНОВКИ

У магістерській роботі розроблено підхід до автоматизованого визначення ступенів фіброзу печінки за ультразвуковими зображеннями, що поєднує сучасні методи цифрової обробки медичних зображень та інструменти глибокого машинного навчання. Було сформовано єдину технологічну структуру, яка охоплює всі ключові етапи – від підготовки та аналізу даних до побудови модульної системи класифікації та її інтеграції у програмний застосунок з інтерфейсом користувача.

Всі поставлені в магістерській роботі задачі було повністю виконано. Зокрема, було реалізовано такі етапи: проведено аналіз методів діагностики фіброзу печінки та текстурних характеристик за даними вітчизняних та зарубіжних джерел, що дозволило сформувавши теоретичне підґрунтя для подальших досліджень; виконано огляд існуючих підходів та програмно-алгоритмічних рішень для класифікації ступеня фіброзу печінки, із виокремленням їх сильних сторін та обмежень; розроблено та реалізовано канали текстурних характеристик зображень, а також побудовано архітектури згорткових нейронних мереж для розв'язання задачі класифікації; проведено тренування окремих моделей, їх об'єднання у мета-класифікатор та створено програмний інтерфейс користувача, який забезпечує практичне застосування розробленої системи в задачах підтримки діагностики фіброзу печінки.

У межах роботи реалізовано декілька підходів до аналізу ультразвукових даних, зокрема аналіз текстурних характеристик та нейронних мереж різної складності, що забезпечило можливість багаторівневого розпізнавання структурних змін у тканині печінки. Побудовано ансамбль моделей, у якому проміжні класифікатори доповнюються мета-рівнем, що об'єднує їх прогностичні оцінки. Така архітектура дозволила узагальнити інформацію з різних джерел ознак та підвищити надійність автоматизованого визначення стадій фіброзу.

Наукова значущість роботи полягає у демонстрації ефективності комплексного ансамблевого підходу для аналізу стандартних ультразвукових

зображень, які традиційно вважаються складними для автоматизованої інтерпретації. Запропонована система орієнтована на реальні клінічні умови, не потребує спеціального обладнання чи доступу до високоспеціалізованих сигналів, а отже, є потенційно придатною для широкого застосування у медичних закладах.

Практична цінність роботи визначається можливістю використання створеної системи як інструмента підтримки прийняття рішень. Вона може підвищити об'єктивність та відтворюваність оцінки ступеня фіброзу, доповнюючи суб'єктивні спостереження лікаря кількісним, стандартизованим аналізом ультразвукових зображень. Такі системи здатні сприяти ранній діагностиці та підвищенню ефективності клінічного моніторингу.

..

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Convolutional neural network classification of ultrasound images by liver fibrosis stages based on echo-envelope statistics / S. Hirata et al. *Frontiers in Physics*. 2023. Vol. 11. URL: <https://doi.org/10.3389/fphy.2023.1164622> (date of access: 10.09.2025).
2. Deep learning Radiomics of shear wave elastography significantly improved diagnostic performance for assessing liver fibrosis in chronic hepatitis B: a prospective multicentre study / K. Wang et al. *Gut*. 2018. Vol. 68, no. 4. P. 729–741. URL: <https://doi.org/10.1136/gutjnl-2018-316204> (date of access: 10.09.2025).
3. Ultrasonic assessment of liver fibrosis using one-dimensional convolutional neural networks based on frequency spectra of radiofrequency signals with deep learning segmentation of liver regions in b-mode Images: A Feasibility Study / H. Ai et al. *Sensors*. 2024. Vol. 24, no. 17. P. 5513. URL: <https://doi.org/10.3390/s24175513> (date of access: 11.09.2025).
4. Evaluation of hepatic fibrosis using ultrasound backscattered radiofrequency signals and one-dimensional convolutional neural networks / Y. Huang et al. *Diagnostics*. 2022. Vol. 12, no. 11. P. 2833. URL: <https://doi.org/10.3390/diagnostics12112833> (date of access: 17.09.2025).
5. Буднік Ю. С. Групова класифікація деталізованих ступенів фіброзу за ультразвуковими зображеннями судин печінки при аутоімунному гепатиті : дипломна робота . бакалавра : 122 Комп'ютерні науки / Буднік Юлія Сергіївна. – Київ, 2024. – 73 с. URL: <https://ela.kpi.ua/handle/123456789/69714> (дата звернення: 15.10.2025).
6. EASL clinical practice guidelines: Autoimmune hepatitis. *Journal of Hepatology*. 2015. Vol. 63, no. 4. P. 971–1004. URL: <https://doi.org/10.1016/j.jhep.2015.06.030> (date of access: 20.09.2025).
7. A closer look into autoimmune liver diseases / B. Filipovic et al. *International journal of molecular sciences*. 2025. Vol. 26, no. 5. P. 1863. URL: <https://doi.org/10.3390/ijms26051863> (date of access: 20.09.2025).

8. Autoimmune hepatitis - Symptoms and causes. Mayo Clinic. URL: <https://www.mayoclinic.org/diseases-conditions/autoimmune-hepatitis/symptoms-causes/syc-20352153> (date of access: 21.09.2025).
9. Lohse A. W., Mieli-Vergani G. Autoimmune hepatitis. *Journal of Hepatology*. 2011. Vol. 55, no. 1. P. 171–182. URL: <https://doi.org/10.1016/j.jhep.2010.12.012> (date of access: 25.09.2025).
10. Bedossa P., Poynard T. An algorithm for the grading of activity in chronic hepatitis C. *Hepatology*. 1996. Vol. 24, no. 2. P. 289–293. URL: <https://doi.org/10.1002/hep.510240201> (date of access: 25.09.2025).
11. Bedossa P. Presentation of a grid for computer analysis for compilation of histopathologic lesions in chronic viral hepatitis C. Cooperative study of the METAVIR group. *Annales de pathologie*. 1993. Vol. 13, no. 4. P. 260-265. URL: <https://doi.org/10.3390/ijms26051863> (date of access: 25.09.2025).
12. Batts K. P., Ludwig J. An update on terminology and reporting. *The american journal of surgical pathology*. 1995. Vol. 19, no. 12. P. 1409–1417. URL: <https://doi.org/10.1097/00000478-199512000-00007> (date of access: 27.09.2025).
13. Цироз печінки. StudFiles. URL: <https://studfile.net/preview/2783784/> (дата звернення: 15.10.2025).
14. Фіброз печінки: причини, симптоми, діагностика та лікування. Немо Медика. URL: <https://hemomedika.com.ua/new/fibroz-pechinki-prichini-simptomi-diagnostika-ta-likuvannya> (дата звернення: 30.09.2025).
15. EASL-ALEH Clinical Practice Guidelines: Non-invasive tests for evaluation of liver disease severity and prognosis. *Journal of Hepatology*. 2015. Vol. 63, no. 1. P. 237–264. URL: <https://doi.org/10.1016/j.jhep.2015.04.006> (date of access: 27.09.2025).
16. Sampling error and intraobserver variation in liver biopsy in patients with chronic HCV infection / A. Regev et al. *The American Journal of Gastroenterology*. 2002. Vol. 97, no. 10. P. 2614–2618. URL: <https://doi.org/10.1111/j.1572-0241.2002.06038.x> (date of access: 27.09.2025).

17. Sampling variability of liver biopsy in nonalcoholic fatty liver disease / V. Ratziu et al. *Gastroenterology*. 2005. Vol. 128, no. 7. P. 1898–1906. URL: <https://doi.org/10.1053/j.gastro.2005.03.084> (date of access: 29.09.2025).
18. Transient elastography: a new noninvasive method for assessment of hepatic fibrosis / L. Sandrin et al. *Ultrasound in Medicine & Biology*. 2003. Vol. 29, no. 12. P. 1705–1713. URL: <https://doi.org/10.1016/j.ultrasmedbio.2003.07.001> (date of access: 29.09.2025).
19. Performance of transient elastography for the staging of liver fibrosis: A Meta-Analysis / M. Friedrich–Rust et al. *Gastroenterology*. 2008. Vol. 134, no. 4. P. 960–974.e8. URL: <https://doi.org/10.1053/j.gastro.2008.01.034> (date of access: 29.09.2025).
20. WFUMB guidelines and recommendations for clinical use of ultrasound elastography: Part 3: Liver / G. Ferraioli et al. *Ultrasound in Medicine & Biology*. 2015. Vol. 41, no. 5. P. 1161–1179. URL: <https://doi.org/10.1016/j.ultrasmedbio.2015.03.007> (date of access: 30.09.2025).
21. Heel pad stiffness in plantar heel pain by shear wave elastography / C.-Y. Lin et al. *Ultrasound in Medicine & Biology*. 2015. Vol. 41, no. 11. P. 2890–2898. URL: <https://doi.org/10.1016/j.ultrasmedbio.2015.07.004> (date of access: 30.09.2025).
22. Haralick R. M., Shanmugam K., Dinstein I. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*. 1973. SMC-3, no. 6. P. 610–621. URL: <https://doi.org/10.1109/tsmc.1973.4309314> (date of access: 30.09.2025).
23. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60, no. 6. P. 84–90. URL: <https://doi.org/10.1145/3065386> (date of access: 05.10.2025).
24. Згорткова нейронна мережа – Вікіпедія. Вікіпедія. URL: [https://uk.wikipedia.org/wiki/Згорткова\\_нейронна\\_мережа](https://uk.wikipedia.org/wiki/Згорткова_нейронна_мережа) (дата звернення: 05.10.2025).

25. Goodfellow I., Bengio Y., Courville A. Deep learning. Cambridge : MIT Press, 2016. 800 p. URL: <https://www.deeplearningbook.org/> (date of access: 05.10.2025).
26. Understanding convolutional neural networks: a simplified guide - 18 november 2025. AI Coach. URL: <https://aicoach.co.za/convolutional-neural-networks/> (date of access: 08.10.2025).
27. A visual introduction to convolutional neural networks. Medium. URL: <https://sayemuzzamansiam.medium.com/a-visual-introduction-to-convolutional-neural-networks-123d6621b891> (date of access: 18.10.2025).
28. Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images / M. Byra et al. International journal of computer assisted radiology and surgery. 2018. Vol. 13, no. 12. P. 1895–1903. URL: <https://doi.org/10.1007/s11548-018-1843-2> (date of access: 07.10.2025).
29. Materka A., Michal M. Texture analysis methods – A review. Lodz : Technical University of Lodz, 1998. 33 p. URL: <https://scispace.com/pdf/texture-analysis-methods-a-review-3pph5x6k81.pdf> (date of access: 12.10.2025).
30. Texture analysis of medical images / G. Castellano et al. Clinical radiology. 2004. Vol. 59, no. 12. P. 1061–1069. URL: <https://doi.org/10.1016/j.crad.2004.07.008> (date of access: 12.10.2025).
31. Improving the distinction between benign and malignant breast lesions: the value of sonographic texture analysis / B. S. Garra et al. Ultrasonic imaging. 1993. Vol. 15, no. 4. P. 267–285. URL: <https://doi.org/10.1177/016173469301500401> (date of access: 12.10.2025).
32. Tuceryan M., Jain A.K. Texture analysis. Handbook of Pattern Recognition and Computer Vision. World Scientific, 1993. P. 235-276. URL: [https://www.worldscientific.com/doi/epdf/10.1142/9789814343138\\_0010](https://www.worldscientific.com/doi/epdf/10.1142/9789814343138_0010) (date of access: 12.10.2025).
33. A histogram analysis of the pixel grayscale (luminous intensity) of b-mode ultrasound images of the subcutaneous layer predicts the grade of leg edema in pregnant women / E. Ikuta et al. Healthcare. 2023. Vol. 11, no. 9. P. 1328. URL:

<https://doi.org/10.3390/healthcare11091328> (date of access: 14.10.2025).

34. Texture features and analysis. URL: [https://www.uomustansiriyah.edu.iq/media/lectures/5/5\\_2024\\_11\\_20!08\\_06\\_26\\_P M.pdf](https://www.uomustansiriyah.edu.iq/media/lectures/5/5_2024_11_20!08_06_26_P M.pdf) (date of access: 15.10.2025)

35. GLCM Texture: A Tutorial v. 3.0 March 2017. URL: [https://www.researchgate.net/publication/315776784\\_GLCM\\_Texture\\_A\\_Tutorial\\_v\\_30\\_March\\_2017](https://www.researchgate.net/publication/315776784_GLCM_Texture_A_Tutorial_v_30_March_2017) (date of access: 15.10.2025)

36. Haralick R. M., Shanmugam K., Dinstein I. Textural features for image classification. IEEE transactions on systems, man, and cybernetics. 1973. SMC-3, no. 6. P. 610–621. URL: <https://doi.org/10.1109/tsmc.1973.4309314> (date of access: 15.10.2025).

37. Xiaoou Tang. Texture information in run-length matrices. IEEE transactions on image processing. 1998. Vol. 7, no. 11. P. 1602–1609. URL: <https://doi.org/10.1109/83.725367> (date of access: 15.10.2025).

38. Бардак І.О. Розробка апаратно-програмного комплексу автономного польового робота для видалення бур'янів / І.О. Бардак – Запоріжжя: НУ «Запорізька політехніка», 2023. – 76 с. URL: <https://eir.zp.edu.ua/handle/123456789/16939> (дата звернення: 15.10.2025).

39. Technology | 2024 stack overflow developer survey. Stack Overflow Insights - Developer Hiring, Marketing, and User Research. URL: <https://survey.stackoverflow.co/2024/technology> (date of access: 18.10.2025).

40. McKinney W. Python for data analysis. O'Reilly Media, Incorporated, 2022.

41. OpenCV. URL: <https://opencv.org/about/#:~:text=The%20library%20has%20more%20than%202500%20optimized,state-of-the-art%20computer%20vision%20and%20machine%20learning%20algorithms> (дата звернення: 30.10.2025).

42. Array programming with NumPy / C. R. Harris et al. *Nature*. 2020. Vol. 585, no. 7825. P. 357–362. URL: <https://doi.org/10.1038/s41586-020-2649-2> (date of access: 30.10.2025).
43. SciPy 1.0: fundamental algorithms for scientific computing in Python / P. Virtanen et al. *Nature methods*. 2020. Vol. 17, no. 3. P. 261–272. URL: <https://doi.org/10.1038/s41592-019-0686-2> (date of access: 10.11.2025).
44. TensorFlow core. TensorFlow. URL: <https://www.tensorflow.org/guide/gpu?hl=ru> (date of access: 10.11.2025).
45. ImageNet: VGGNet, ResNet, Inception, and Xception with Keras - PyImageSearch. PyImageSearch. URL: <https://pyimagesearch.com/2017/03/20/imagenet-vggnet-resnet-inception-xception-keras/> (date of access: 10.11.2025).
46. Matplotlib – visualization with python. Matplotlib – Visualization with Python. URL: <https://matplotlib.org/> (date of access: 11.10.2025).
47. PySide6. PyPI. URL: <https://pypi.org/project/PySide6/> (date of access: 12.11.2025).
48. Qt licensing. choose the right license for your development needs. Tools for Each Stage of Software Development Lifecycle. URL: <https://www.qt.io/development/qt-framework/qt-licensing> (date of access: 12.11.2025).
49. Stability of FDG-PET Radiomics features: An integrated analysis of test-retest and inter-observer variability / R. T. H. Leijenaar et al. *Acta Oncologica*. 2013. Vol. 52, no. 7. P. 1391–1397. URL: <https://doi.org/10.3109/0284186x.2013.812798> (date of access: 10.10.2025).
50. Keras Conv2D and Convolutional Layers - PyImageSearch. PyImageSearch. URL: <https://pyimagesearch.com/2018/12/31/keras-conv2d-and-convolutional-layers/> (date of access: 10.10.2025).
51. Розробка стартап-проектів: практикум [Електронний ресурс]: навч. посіб. для студ. спеціальностей 151 – «Автоматизація та комп'ютерноінтегровані технології» та 152 – «Метрологія та

інформаційновимірювальна техніка» / О. А. Гавриш, К. О. Бояринова, К. О. Копішинська; КПІ ім. Ігоря Сікорського. Київ: КПІ ім. Ігоря Сікорського, 2019. 116 с. [URL:https://ela.kpi.ua/handle/123456789/29450](https://ela.kpi.ua/handle/123456789/29450) (дата звернення 10.12.2025)

52. Циганов, А. Л. Автоматизація обробки інформації в надвисокочастотних радіометричних системах : магістерська дис. : 152 Метрологія та інформаційно-вимірювальна техніка / Циганов Артем Леонідович. – Київ, 2018. – 79 с. URL: <https://ela.kpi.ua/handle/123456789/22987> (дата звернення: 15.10.2025).

53. Борисова, Г. В. Програмний додаток для визначення функціонального стану системи кровообігу : магістерська дис. : 122 Комп'ютерні науки / Борисова Галина Вікторівна. – Київ, 2019. – 140 с. URL: <https://ela.kpi.ua/handle/123456789/29102> (дата звернення: 15.10.2025).