

КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ІМЕНІ ТАРАСА ШЕВЧЕНКА
Факультет інформаційних технологій
Кафедра інтелектуальних технологій

КВАЛІФІКАЦІЙНА РОБОТА
на здобуття освітнього ступеня «магістр»
НА ТЕМУ:

**КЛАСИФІКАТОР ЗАХВОРЮВАНЬ ЗА УЛЬТРАЗВУКОВИМ
ЗОБРАЖЕННЯМ ПЕЧІНКИ ІЗ ЗАСТОСУВАННЯМ
НЕЙРОННИХ МЕРЕЖ ТА РАДІОМІКИ**

Галузь знань: 12 «Інформаційні технології»
Спеціальність: 122 «Комп'ютерні науки»
Освітньо-наукова програма «Технології штучного інтелекту»

Виконав:
студент 2 курсу магістратури, групи ТШ-21

Науковий керівник:

Янковий Ілля Олексійович
(ПІБ)

Красовська Ганна Валеріївна
(ПІБ)

кандидат технічних наук,
доцент кафедри інтелектуальних технологій
(науковий ступінь, вчене звання)

Засвідчую, що в цій кваліфікаційній роботі
немає запозичень з праць інших авторів без
відповідних посилань

Студент

_____ підпис

Кваліфікаційна робота допущена до захисту
рішенням кафедри *інтелектуальних технологій*

Протокол № _____ від «_____» травня 2021 р.

Зав. кафедри _____ доц. Іларіонов О.Є.
підпис

Київ 2021

ЗМІСТ

ВСТУП	3
РОЗДІЛ 1	7
КЛАСИФІКАЦІЯ ЗАХВОРЮВАНЬ ПЕЧІНКИ ЛЮДИНИ УЛЬТРАЗВУКОВИМ ЗОБРАЖЕННЯМ ПЕЧІНКИ	3А 7
1.1 Предметна область. Дифузні захворювання печінки	7
1.2 Недоліки традиційних методів класифікації захворювань	8
1.3 Розробки штучного інтелекту для аналізу медичних зображень	9
1.4 Радіоміка і текстурний аналіз	11
1.5 Класифікатор стану пацієнта за текстурними статистиками	17
Висновки до розділу 1	23
РОЗДІЛ 2	25
ПРОЕКТУВАННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЛАСИФІКАЦІЇ ЗАХВОРЮВАНЬ ПЕЧІНКИ	25 25
2.1 Постановка задачі моделювання	25
2.2 Проектування класифікатора захворювань печінки	25
2.2.1. Стандартизація даних	26
2.2.2. Зменшення розмірності	27
2.2.3. Оцінка точності моделі	29
2.3. Проектування архітектури штучної нейронної мережі	31
РОЗДІЛ 3	40
РОЗРОБКА ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЛАСИФІКАЦІЇ ЗАХВОРЮВАНЬ ПЕЧІНКИ	40 40
3.1 Функціональний аналіз програми класифікатора захворювань	40
3.2 Графічний інтерфейс користувача	44
3.2.1 Реалізація функції «Вибір та автоматична обробка медичного зображення»	45
3.2.2 Реалізація функції «Прогнозування захворювання печінки»	49
3.2.3 Використання головного меню програми	50
3.3 Підготовка набору даних	54
3.4 Аналіз результатів роботи класифікатора захворювань печінки	58
ВИСНОВКИ	61

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

ВСТУП

Понад 1.3 мільйони людей померли від вірусного гепатиту печінки у 2015 році за даними Всесвітньої організації охорони здоров'я [1]. Ці цифри на рівні смертності туберкульозу (понад 1.3 мільйони), вірус імунодефіциту людини (понад 1 мільйон) чи малярія (понад 0,4 мільйони). Важливість вчасної і ефективної діагностики захворювань печінки полягає в тому, що це може запобігти таким смертельно небезпечним ускладненням як цироз чи рак печінки.

Діагностування стану пацієнта вимагає від лікаря оперативного прийняття клінічного рішення за відомою вихідною інформацією. У медицині це зазвичай зовнішні прояви хвороби та результати аналізів. Швидкість і точність прийняття рішення залежить як від компетенції лікаря, його клінічного досвіду, так і від здатності аналізувати великі масиви даних щодо особливостей прояву захворювання у конкретного хворого. Одним з джерел таких даних є медичні візуалізації тіла людини за допомогою спеціальних пристроїв та подальша діагностика лікарем. Однак, у такого підходу є суттєві недоліки, пов'язані з людським фактором і тому у останні десятиліття виник напрямок науки, що займається кількісним аналізом медичних зображень за допомогою інтелектуальних систем.

За напрямком діагностики зображень існує важлива, проте невирішена досі задача класифікації захворювань, пов'язаних з печінкою за зображенням ультразвукової діагностики печінки. Неправильна діагностика може викликати затримку лікування і тим самим збільшити ймовірність летальних результатів для пацієнта. Актуальність даної теми полягає в необхідності безпечної (без хірургічного втручання), точної та швидкої діагностики ультразвукових медичних зображень печінки за допомогою наявних технологій штучного інтелекту та прикладної статистики.

Метою даної роботи є дослідження, проектування та розробка програмного додатку, здатного проводити обчислювальний аналіз медичних

ультразвукових зображень печінки людини на основі засобів машинного навчання й методів радіоміки та надавати якісно нову інформацію для подальшої діагностики пацієнта медичними спеціалістами.

Завдання. Для досягнення поставленої мети, потрібно виконати завдання:

1. Провести літературний огляд предметної області та описати існуючі системи та методи, що використовуються для класифікації захворювань на основі медичних зображень.
2. Спроекувати модель класифікатора захворювань печінки людини на основі ансамблю методів радіоміки, класичних статистичних алгоритмів та згорткових глибинних штучних нейронних мереж застосованих до зображення ультразвукової діагностики печінки. Порівняти метрики точності нової моделі з минулими результатами.
3. Розробити програму, що надає можливість вилучати та зберігати атрибути текстурних статистик з бази зображень ультразвукової діагностики печінки пацієнтів та виконувати класифікацію захворювань печінки на нових даних.

Об'єкт дослідження – це процес класифікації захворювання в рамках діагностики ультразвукового зображення печінки людини з використанням технологій штучного інтелекту.

Предмет дослідження полягає у застосуванні методів глибинного навчання та радіоміки для класифікації захворювання людини за ультразвуковим зображенням печінки.

Наукова новизна роботи полягає в реалізації нового виду архітектури системи класифікації захворювань печінки, де глибинне навчання посередництвом згорткової нейромережі поєднується з класичними текстурними ознаками зображень.

Практичним **результатом роботи** є розробка системи класифікації дифузних захворювань печінки за допомогою комплексної архітектури, що включає згорткову нейронну мережу і модуль обчислення текстурних статистик.

РОЗДІЛ 1

КЛАСИФІКАЦІЯ ЗАХВОРЮВАНЬ ПЕЧІНКИ ЛЮДИНИ ЗА УЛЬТРАЗВУКОВИМ ЗОБРАЖЕННЯМ ПЕЧІНКИ

Печінка – багатофункціональний та життєво необхідний орган людини. Будь-які пошкодження цього органу становлять небезпеку життю людини і повинні бути діагностовані якомога раніше, щоб вчасно почати лікування і уникнути важких ускладнень. В наступних підрозділах 1.3–1.4 описані методи інтелектуального аналізу і технічні деталі того, як цю діагностику можна виконувати за допомогою систем штучного інтелекту, а підрозділи 1.1–1.2 зосереджено на основних деталях предметної області, що є важливим для роботи над даною задачею.

1.1 Предметна область. Дифузні захворювання печінки

Дифузні захворювання печінки – небезпечна група захворювань, при відсутності лікування яких може розвиток цирозу та рак печінки (гепатоцелюлярна карцинома) [2]. Головна риса цієї групи захворювань печінки полягає в тому, що вони запускають процес щоденного розпаду клітин печінки – хронічне запалення, або ж розвиток фіброзу [3].

Фіброз характеризується виникненням більш щільної сполучної тканини, яку можна спостерігати протягом ультразвукового дослідження печінки. Організм людини формує рубці намагаючись ізолювати запалення. Відсутність лікування на цьому етапі загрожує розвитком значно небезпечніших патологій [2]. Кінцевим етапом фіброзу є розвиток цирозу печінки, при якому незворотно пошкоджується структура поверхні печінки внаслідок масового рубцювання і порушуються всі основні функції цього органу. Цироз значно збільшує ризик розвитку раку печінки та ймовірність летальних наслідків [4, 5].

1.2 Недоліки традиційних методів класифікації захворювань

Отже, дифузні захворювання печінки без належного та своєчасного лікування можуть бути дуже небезпечними для людини, а для вибору стратегії лікування спочатку потрібно провести діагностику.

Так званим «золотим стандартом» або ж основною процедурою діагностики печінки до початку 2000-их років була біопсія. Це інвазивна (хірургічна) процедура, протягом якої отримують фрагмент тканини печінки і проводять його аналіз. Прямим недоліком цієї операція є небезпека ймовірної шкоди пацієнту, адже існує ймовірність різноманітних ускладнень, таких як виникнення гематоми печінки, чи в крайньому випадку може статися масивна внутрішня кровотеча, що загрожує життю і здоров'ю людини.

Альтернативою є застосування медичної візуалізації ультразвукового дослідження (сонографії) печінки людини. Медична візуалізація – це наукова дисципліна, що вивчає наукоємкі процеси отримання візуальних зображень внутрішніх органів та частин тіла людини, що використовуються для клінічного аналізу та прийняття рішень щодо подальших медичних втручань. Технологія медичної візуалізації направлена на розкриття інформації про структури, приховані шкірою та кістками з метою ефективною діагностики та лікування людей. Медична візуалізація відбувається неінвазивно – тобто без введення жодних інструментів в тіло людини [6].

Отримані зображення дають медичним працівникам унікальну інформацію про стан різних структур тіла, будь то кістки, органи, м'язи, сухожилля, нерви, хрящі, кровоносні судини та інші. На основі цих зображень медики проводять експертний аналіз, який можна розглядати як вирішення зворотних математичних задач. У такому випадку причину (властивості живої тканини) отримують з ефекту (сигнал, що спостерігається, або ж медичне зображення).

Підхід ультразвукового дослідження внутрішніх органів є неінвазивним, тобто не потребує хірургічного втручання в тіло людини. Сонографією називають метод медичного обстеження при використанні звукових хвиль високої частоти, або ж, ультразвуку. Ця медична візуалізація потрібна для безпечної діагностики внутрішніх органів людини. Технічна сторона процесу полягає у записуванні ультразвукових хвиль, що відбилися від поверхонь внутрішніх органів [7]. Отримані зображення медичні спеціалісти вивчають вручну та ставлять діагноз на основі своїх експертних знань.

Однак, безпосередньому аналізу зображень сонографії властивий ряд недоліків, пов'язаних з людським фактором, а саме: низька точність, на рівні 80% в порівнянні з біопсією та низька швидкість прийняття клінічних рішень. Щоб встановити діагноз за цим методом вимагається погодження кількох медичних спеціалістів, для чого потрібен додатковий час. Наявний метааналіз точності діагностичного тесту на основі 43 публікацій для методу сонографії проти більш точної біопсії демонструє специфічність між 70-85% та чутливість в діапазоні 73-90% [8].

1.3 Розробки штучного інтелекту для аналізу медичних зображень

Протягом декади 2010-их років значного поширення в науці набули методи штучного інтелекту, а саме технології deep learning (з англ. «глибинного навчання»). Не стала виключенням і сфера медичних досліджень, особливо у області обробки зображень медичного походження і точної медицини [9]. Областю найбільшого зацікавлення у методах ШІ виявилась радіологія, кількість статей з використанням ШІ у якій зросло із 100-150 у 2007-2008 до понад 700-800 у 2016-2017 роках [10]. Медичну галузь зацікавила можливість проводити діагностику та класифікацію медичних зображень за допомогою інтелектуальних алгоритмів з точністю, на рівні чи вищою ніж у середнього лікаря. При цьому, система не замінює людину, а грає роль виключно

консультативного інструменту, адже відповідальність за прийняття клінічних рішень залишалось за медичним спеціалістом.

Ця технологія почала використовувати і в області дослідження печінки людини. Виник ряд наукових публікацій (Таблиця 1.1) на тему використання згорткових нейронних мереж застосованих на різних модальностях (видах медичних візуалізацій). В якості метрики в цих дослідження часто застосовується гістологічна (та, що стосується тканини) експертна оцінка вираженості фіброзу печінки за системою METAVIR за 5-рівневою шкалою (F0-F4), де F0 – відсутність фіброзу, F4 – цироз печінки.

Таблиця 1.1

№	Тип технології	AUC, площа під ROC-кривою	Джерело
1	ГН на основі даних МРТ (магнітно-резонансної томографії)	F4: 0.84; ≥ F3: 0.84; ≥ F2: 0.85	[11]
2	ГН на основі даних КТ (комп'ютерної томографії)	F4: 0.73; ≥ F3: 0.76; ≥ F2: 0.74	[12]
3	ГН на основі shear-wave elastography (з англ. «еластографії зсувної хвилі»), що використовує ультразвук для отримання карти жорсткості поверхні печінки	F4: 0.97; ≥ F3: 0.98; ≥ F2: 0.85	[13]

Серед інших медичних візуалізацій, методи ШІ почали часто застосовуватися і до зображень ультразвукового дослідження печінки людини [14]. За останні кілька років було опубліковано дослідження про використання МН, ГН і, перш за все, згорткових нейронних мереж для задач, що стосуються діагностики печінки та пов'язаних з нею систем тіла людини на основі зображень ультразвукового дослідження печінки людини (Таблиця 1.2).

Таблиця 1.2

№	Назва завдання	Точність	Чутливість	Специфічність	Джерело
1	виявлення наявності жирової хвороби печінки	100%	100%	100%	[15]
2	виявлення та класифікації різних видів фокального ураження печінки	97.2%	98%	95.7%	[16]
3	оцінка стеатозу печінки за допомогою методів transfer learning (англ. «передавальне навчання»)	96.3%	100%	88.2%	[17]
4	оцінка хронічних захворювань печінки	87.3%	93.5%	81.2%	[18]

1.4 Радіоміка і текстурний аналіз

Класичною альтернативою для аналізу медичних зображень є методи, що включають використання певних hand-engineered (англ. «розроблених вручну», тобто, описаних експліцитно, виражених через конкретну формулу) ознак даних, які можна ефективно використовувати для конкретних видів задач.

Радіоміка – статистичний метод медичного дослідження, що витягує кількісні ознаки, використовуючи алгоритми характеристики даних і пристосований для медичних радіографічних зображень [19]. Одним з видів таких зображень є зрізи текстури поверхні печінки, що отримують в результаті сонографії (ультразвукового дослідження).

Текстура – це зображення, здатне передавати ознаки поверхні певного об'єкту. В цьому зображенні знаходиться інформація, придатна для використання у задачах по класифікації та розпізнаванню об'єктів. Для того, щоб скористатися цією інформацією, спочатку потрібно її звідти отримати. Одним з найбільш широко досліджених способів є текстурний аналіз (ТА). ТА є розділом науки, що вивчає зображення та досліджує опис властивостей зображень за

допомогою текстурних ознак [20]. Для обчислення текстурних ознак розглядають різні види просторових відносин сусідніх пікселів чи вокселів (точок у тривимірних зображеннях), на основі чого формують спеціальні таблиці, з яких за існуючими формулами отримують значення.

Існує два види текстурних статистик за їхніми властивостями щодо зображень. Для обчислення текстурних атрибутів першого порядку застосовують гістограми зображень на основі їх рівня інтенсивності. Для обчислення текстурних атрибутів другого і вищих порядків застосовують спеціальні матриці, що демонструють відносини між сусідніми пікселями зображення за врахування їх рівня інтенсивності [21].

Текстурні статистики 1-го порядку:

1. Центральні моменти відтінків сірого
2. Форми (розміри) зображення
3. Мінімальне, максимальне, мода, квантили

Текстурні статистики вищих порядку – це спеціальні методи для аналізу зображення в сірій шкалі [21]:

- 1) матриця суміжності GLCM (англ. Grey-Level Co-Occurrence Matrix) [22, 23] ;
- 2) матриця довжини пробігу GLRLM (англ. Grey-Level Long Run Matrix) [24] ;
- 3) матриця розміру зони GLSZM (англ. Grey-Level Size Zone Matrix) [25] ;
- 4) матриця залежності GLDM (англ. Grey-Level Dependence Matrix) ;
- 5) матриця різниці за сусідством NGLDM (англ. Neighborhood Grey-Level Difference Matrix) [26] ;

Просторові відносини, які мають певну направленість (наприклад, матриця суміжності та довжини пробігу) задаються через кут відносно напрямку на піксель справа від центрального пікселя та напрямком на обраний піксель.

Щоб провести підрахунок матриці GLCM спочатку потрібно отримати вхідне зображення (яке відображається у формі матриці пікселів), а також кут між пікселями ("0", "45", "90" або "135", Рисунок 1.1), також вказується дистанція між пікселями, що розглядаються. Система координат GLCM задається як всі доступні відтінки сірого кольору (якщо зображення 8-бітне, то отримаємо таблицю з довжиною сторони 256).

Протягом підрахунку матриці кожному комірці зображення обирають в якості опорного пікселя, відносно якого порівнюються сусідні пікселі на вказаній дистанції (у цілих числах) за вказаним кутом відносно напрямку направо (де "0" градусів є пікселем справа, "90" є пікселем зверху) від опорного пікселя, якого ще називають сусіднім пікселем. Кожного разу, коли знайдено пару опорне значення – значення сусіда, відповідний рядок і стовпець GLCM збільшується на 1 [27–29].




Рисунок 1.1. Кут між напрямком на піксель справа від центрального та

обраним пікселем

GLCM – це матриця, яка виражає, як комбінації дискретизованих інтенсивностей сусідніх пікселів розподіляються за одним з напрямків зображення (Рисунок 1.2).

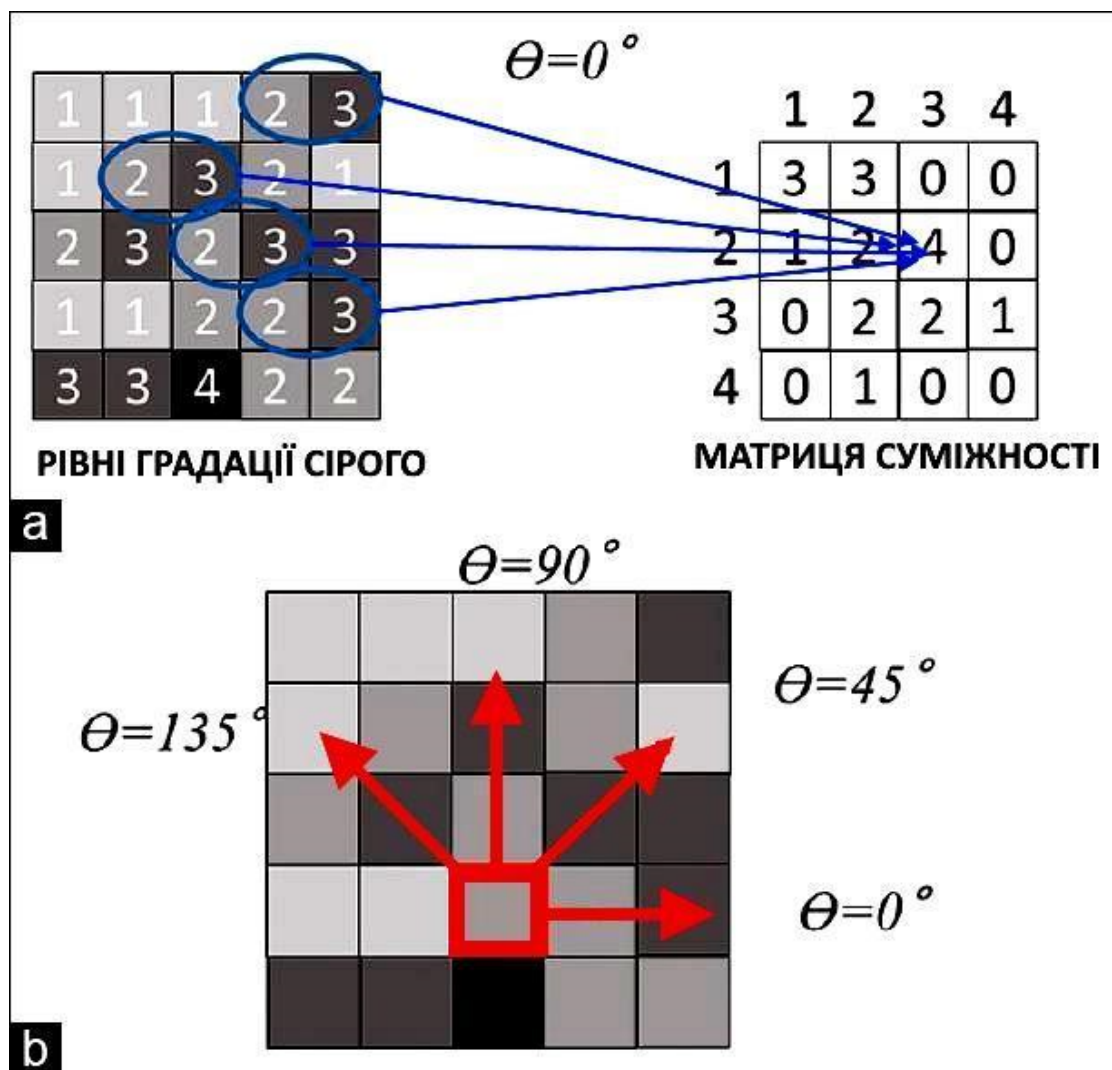


Рисунок 1.2. Матриця суміжності сірих рівнів

GLRLM – це матриця, що оцінює кількість рядків пікселів певної довжини в одному напрямку одного рівня інтенсивності на зображенні. Довжиною пробігу називають кількість пікселів одного відтинку сірого кольору за обраним напрямом відносно опорного пікселя (Рисунок 1.3). У матриці GLRLM

записується кількість пробігів з довжиною j для відтінку сірого кольору i [30].

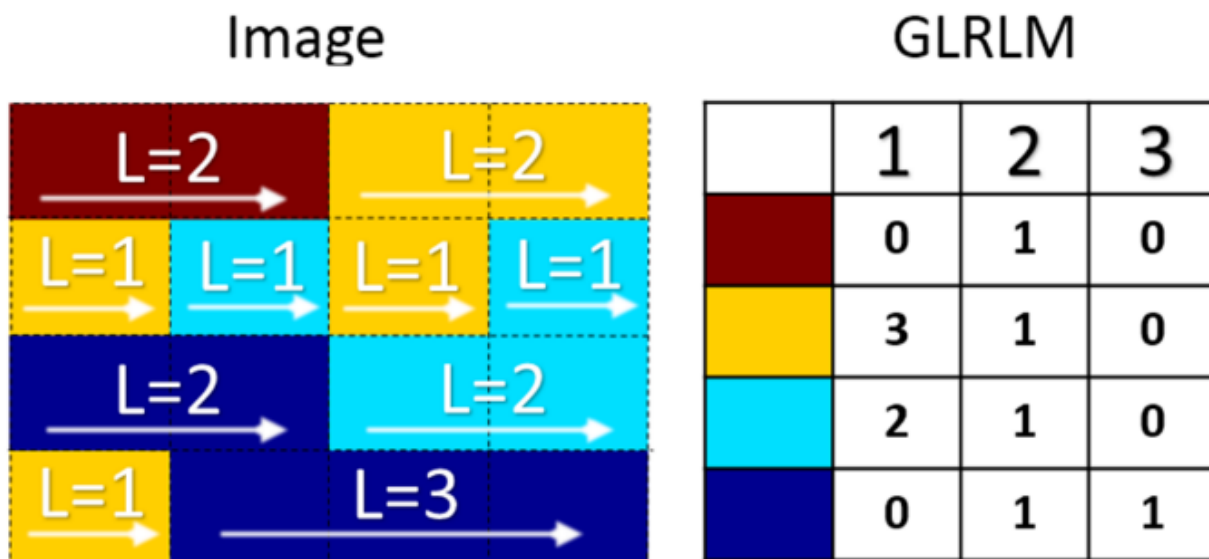


Рисунок 1.3. Матриця довжини пробігу сірих рівнів [30]

GLSZM – це матриця, що оцінює кількість областей певного розміру, де у сусідніх пікселів однаковий відтінок сірого кольору (Рисунок 1.4).

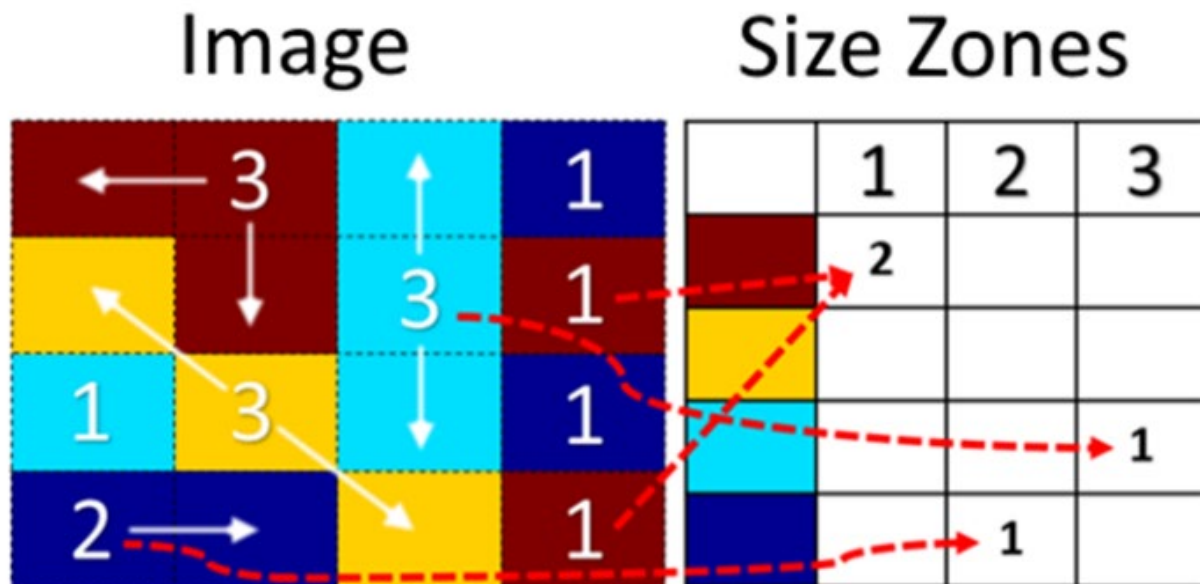


Рисунок 1.4. Матриця розміру зони сірих рівнів [30]

GLDM – це матриця, яка виконує оцінку загальної грубості текстури, а також перевіряє її незмінність при обертанні (Рисунок 1.5).

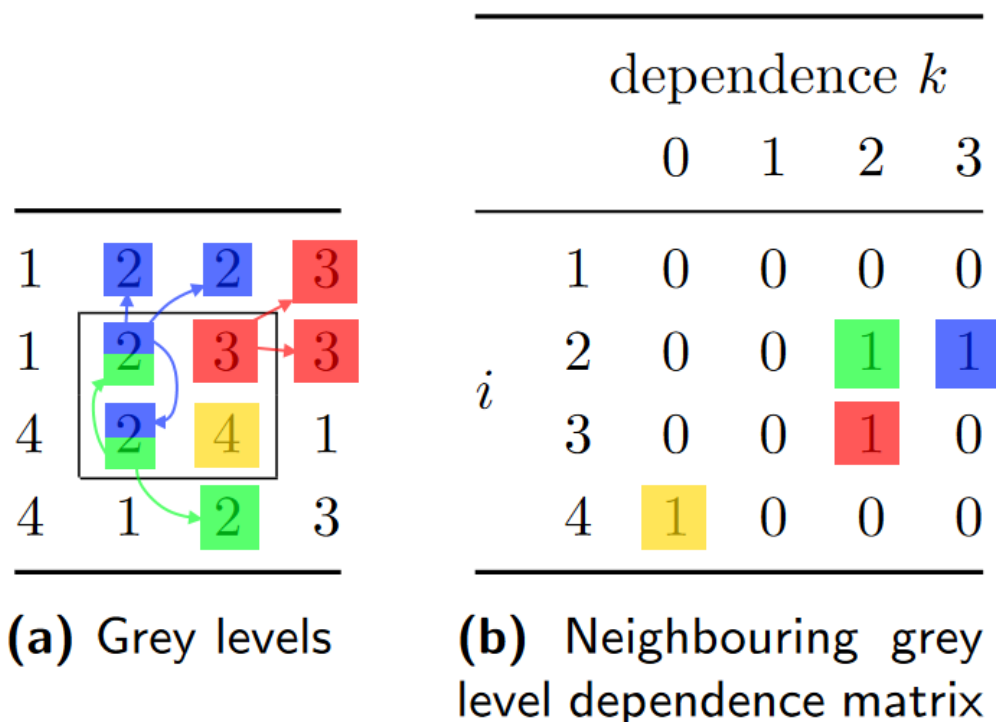


Рисунок 1.5. Матриця залежності сірих рівнів [30]

NGLDM – це матриця, у якій зберігається сума різниці інтенсивності відтінку сірого кольору та середнього рівня інтенсивного сірого сусідніх пікселів (Рисунок 1.6).

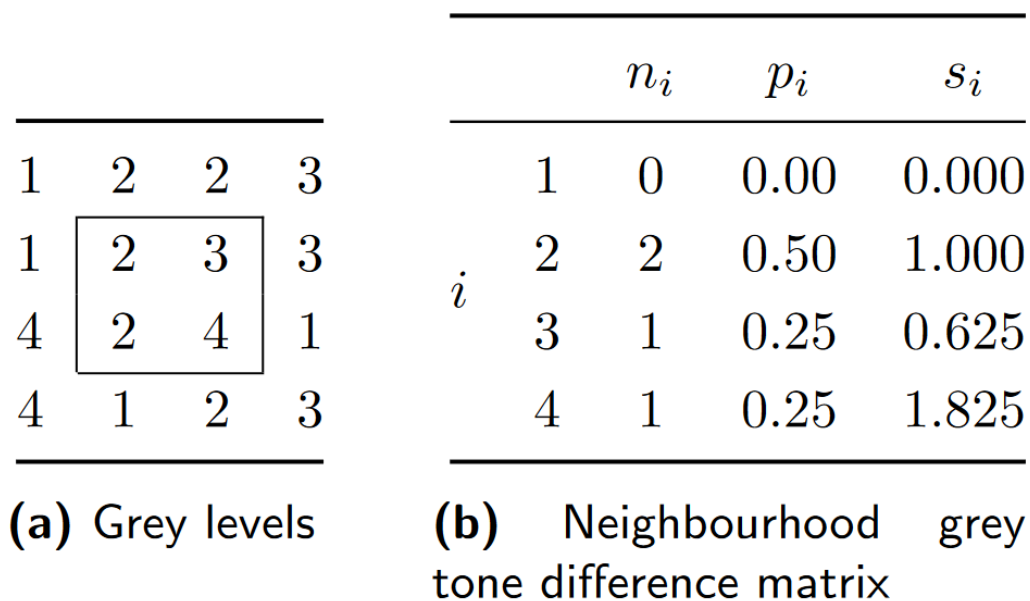


Рисунок 1.6. Матриця різниці сірих рівнів за сусідством [30]

де s_i абсолютна різниця між інтенсивністю пікселя чи вокселя і середньою сумою інтенсивностей сусідів.

$$s_2 = |2 - 19/8| + |2 - 21/8| = 1$$

$$s_3 = |3 - 19/8| = 0.625$$

$$s_2 = |4 - 17/8| = 1.825$$

До кожної з описаних вище матриць у дослідженнях [22–30] були запропоновані розроблені вручні атрибути, що передають ті чи інші властивостей текстури зображень. Стандартизувати ці атрибути матриць сірих тонів намагаються автори дослідження [31], що пропонує детальне описання всіх відомих текстурних статик.

1.5 Класифікатор стану пацієнта за текстурними статистиками

Детальному вивченню нейронних мереж і можливостей їх застосування у задачах класифікації зображень передувало інше дослідження [21] автора даної роботи, в якому задача розпізнавання стану пацієнта на основі зображення УЗД печінки вирішується за допомогою виключно методів текстурного аналізу і класичного машинного навчання без використання глибокого навчання та згорткових нейромереж (Рисунок 1.7).




Рисунок 1.7 Архітектура системи класифікатора з попереднього дослідження [21]

Текстурні статистики загалом можна поділити на два види (Рисунок 1.8): 1-го роду та 2-го і вищих. Статистики 1-го роду описують переважно властивості, які можна отримати з інформації про інтенсивність зображення. ТС 2-го роду описують різні матриці відносин між двома чи більше пікселями зображення,.

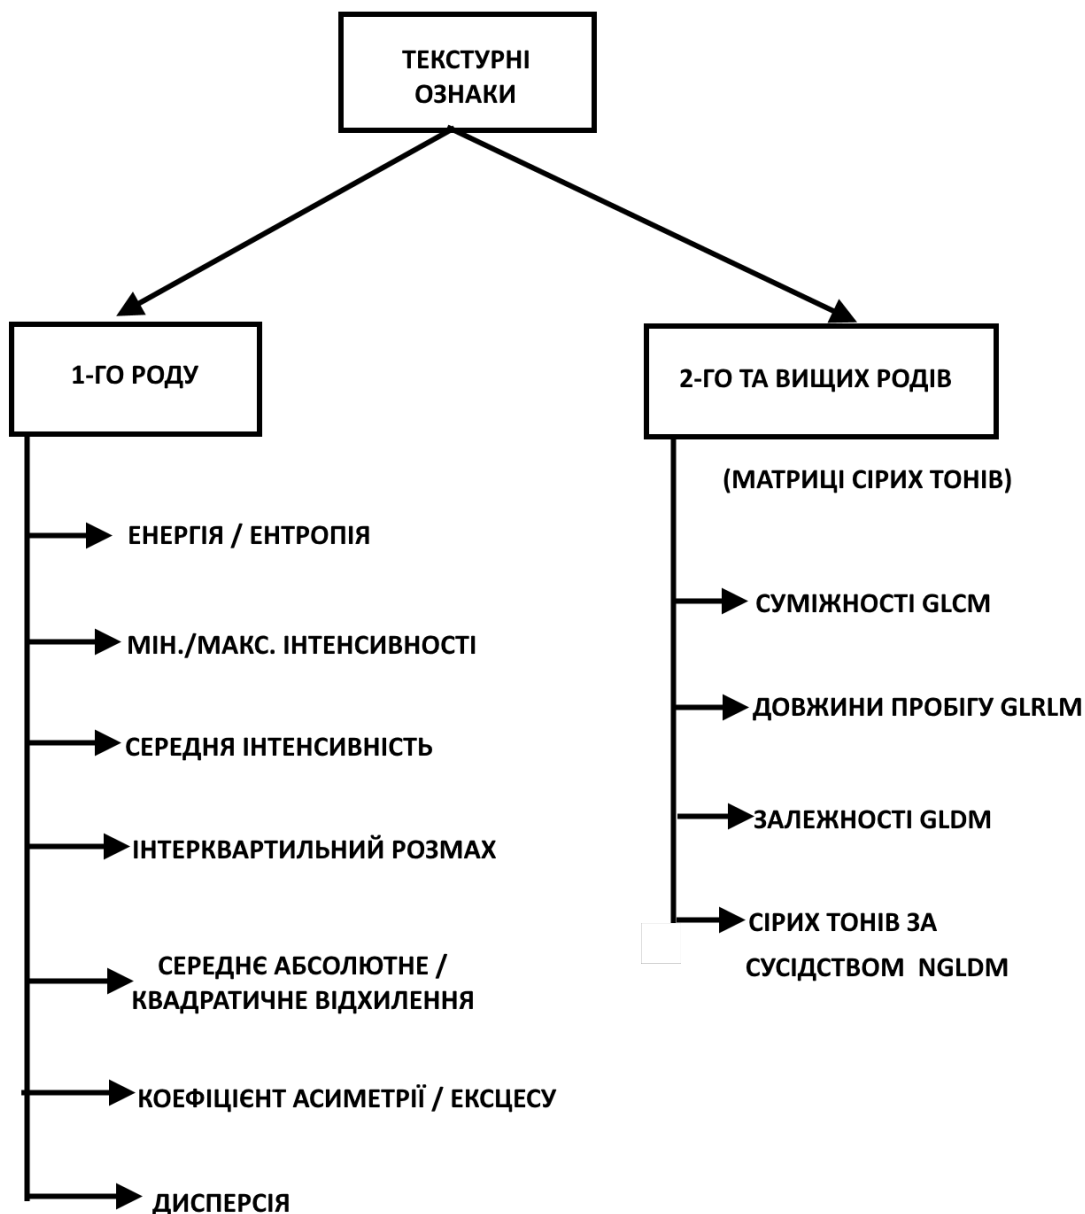


Рисунок 1.8 Класифікація текстурних ознак, використаних у дослідженні [21]

В контексті завдання та обраної архітектури необхідним було отримання ознак, що є властивими для класів дифузних захворювань печінки. Дослідника зацікавила можливість застосування радіоміки для отримання вказаних текстурних ознак [32] медичних зображень.

З метою підрахунку властивостей текстурних статистик зображення було застосовано фреймворк Radiomics (Рисунок 1.9). Цю програмну бібліотеку

розробили вчені лабораторії обчислювальної обробки зображень та біоінформатики Гарвардської Медичної Школи [33] для масового використання вченими області точної медицини та діагностики у задачах із застосуванням технологій штучного інтелекту. Фреймворк Radiomics використовується на етапах вилучення ознак (англ. feature extraction), а також обрання ознак (англ. feature selection) для підготовки атрибутів, які на наступних кроках використовуватимуться при навчанні, та тестуванні алгоритмів класифікації.

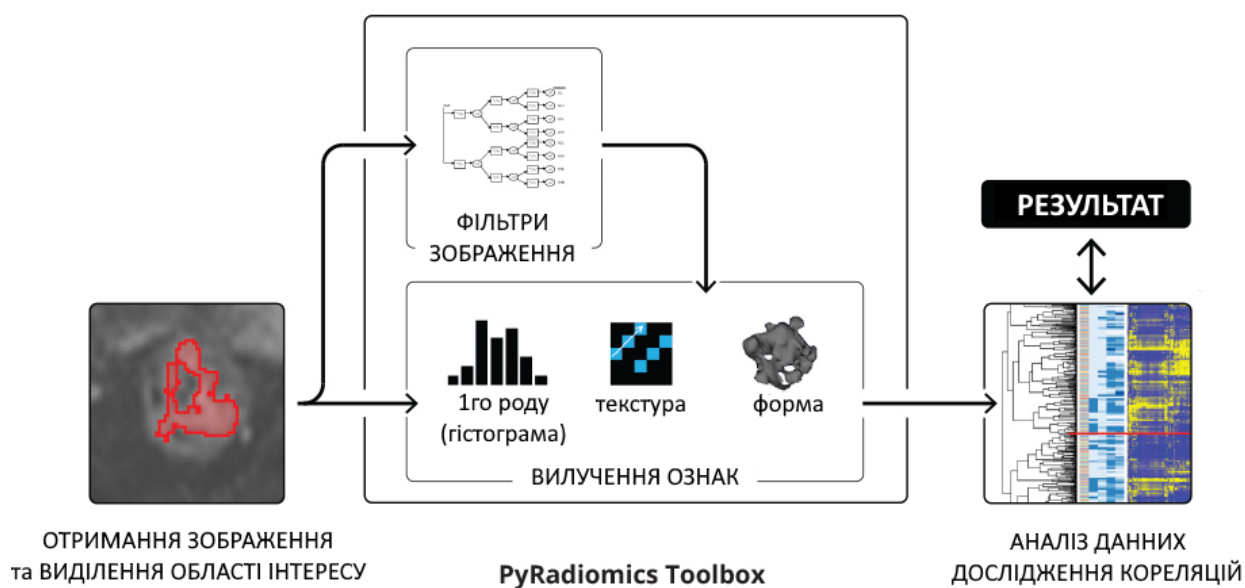


Рисунок 1.9 Підхід до використання бібліотеки Radiomics [31]

У згаданій вище роботі [21] за даною темою розглядалися можливі варіанти використання таких класичних методів класифікації як логістична регресія, дерева рішень та випадковий ліс застосовані до текстурних статистик медичного зображення. Також випробовувались методи зменшення розмірності (англ. dimension reduction) набору атрибутів, такі як метод головних компонент та ядровий метод головних компонент з різними варіантами ядра (було розглянуто поліноміальне ядро, радіальну базисну функцію, а також сигмоїда, найкращі результати продемонструвала радіальна базисна функція) та різною кількістю компонент (Рисунок 1.10).

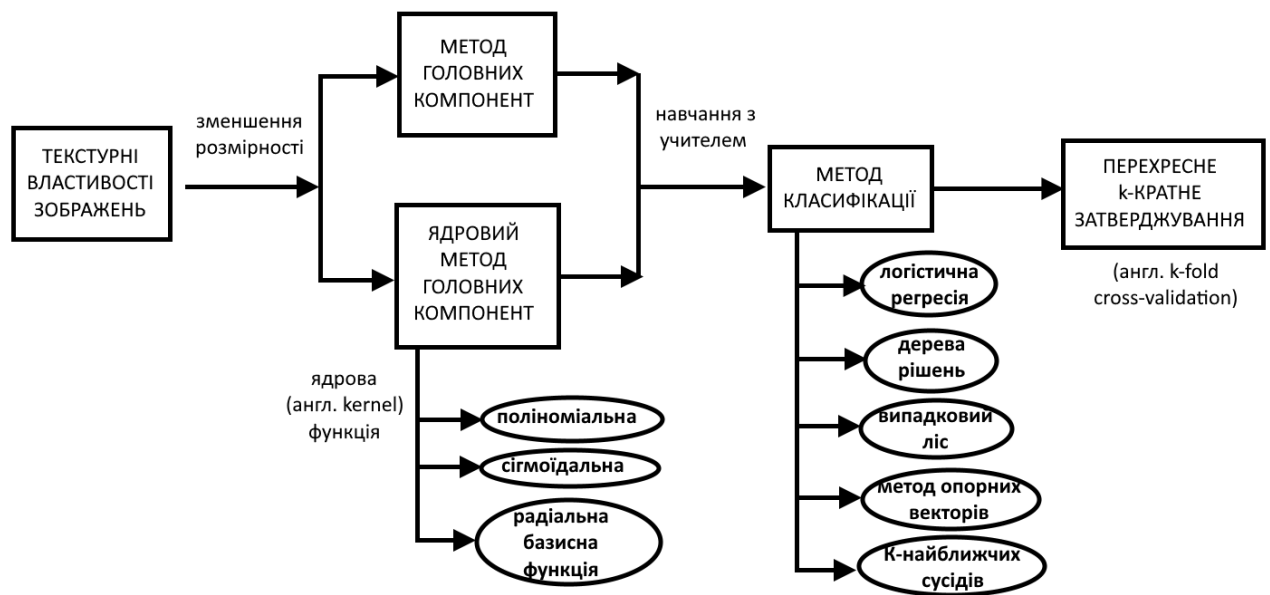


Рисунок 1.10 Порядок застосування методів машинного навчання у системі.

Ця система здатна надавати прогноз захворювання із точністю 77% серед усіх патологій, або 85% при класифікації норма-патологія (один против всіх, де обираємо клас норми против всіх захворювань разом).

Перевагами описаної системи можна назвати:

1. Точність класифікації захворювань печінки на рівні середнього медичного спеціаліста в області ультразвукової діагностики печінки.
2. Швидкість результатів, які користувач системи отримує миттєво.

До недоліків цієї системи можна внести:

1. Незбалансований набір даних в основі класифікатора – такий набір даних, де один клас переважає над іншими. В даному випадку до найбільшої асиметричної групи входить норма (дані здорових пацієнтів), тоді як дані певних класів захворювань обсягом в 2-3 рази менше. Цю проблему можна вирішити зібравши більшу базу даних.
2. Концентрація на текстурних ознаках розроблених виключно вручну (текстурних статистик). Ці ознаки були розроблені спеціально для роботи з текстурою зображень і вважаються ефективним класичним методом, однак

сучасні методи глибинного навчання дають можливість отримати значно більше унікальних властивостей зображення, що є недоступними для ока звичайної людини і які важко описати формально (на відміну від текстурних ознак, до кожної з яких є конкретна формула).

Ці недоліки викликали потребу в розробці вдосконаленої системи, що могла би поєднати сильні сторони як глибоких згорткових нейромереж, так і традиційних методів текстурного аналізу і радіоміки. Метою створення вдосконаленої системи є досягнення більшої точності роботи системи.

Висновки до розділу 1

Перший розділ кваліфікаційної роботи присвячений основним питанням предметної області обраної проблеми, що є важливими для розуміння перед розробкою системи штучного інтелекту. До цих питань відносяться: загальне описання захворювань, які має діагностувати система, наслідки їх ускладнень в разі відсутності діагностики і своєчасного лікування, коротке описання традиційних методів діагностики та їх недоліків, що мають бути вирішені системою.

Протягом розвитку дифузних хвороб печінки відбувається ущільнення поверхні печінки (фіброз), що порушує її функції і з часом призводить до незворотних пошкоджень органу (цироз) і у деяких випадках викликає рак печінки, що є летальним ускладненням для пацієнта. Популярний метод діагностики печінки з хірургічним втручанням – біопсія несе певну небезпеку для пацієнта, тому розглядається безпечний нехірургічний метод ультразвукового дослідження.

Відомим і ефективним класичним підходом до вирішення задач такого класу є методи радіоміки або текстурний аналіз. Основна ідея полягає в підрахунку спеціальних матриць, що відображають відносини між сусідніми пікселями одного чи різних відтінків сірого кольору. На основі кожної з отриманих матриць обчислюються текстурні статистики. Іншим підходом до роботи із зображеннями є глибинне навчання, а саме згорткові штучні нейронні мережі, що самостійно формують ознаки із зображень, виділяючи елементи, недоступні людині. Архітектура системи, що поєднує ці дві концепції розглядатиметься в наступному Розділі 2.

Також було розглянуто попередні дослідження класифікації зображень з використанням текстурних статистик і класичного машинного навчання без штучних нейронних мереж. Основними недоліками цієї системи є те, що вона

базується на розроблених вручну властивостях текстури зображень та ігнорує нові ознаки, які в процесі роботи формує глибинна нейромережа. Це мотивувало почати розробку системи, яка вирішує вказані обмеження. Метою подальшого дослідження стала розробка системи, що демонструє кращі результати, долаючи недоліки попередніх досліджень.

РОЗДІЛ 2

ПРОЕКТУВАННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЛАСИФІКАЦІЇ ЗАХВОРЮВАНЬ ПЕЧІНКИ

2.1 Постановка задачі моделювання

Людський фактор накладає значні обмеження на ручну діагностику медичних зображень: точність та швидкість клінічних рішень. І ці параметри є вирішальними у діагностиці захворювань печінки тому що лише своєчасний точний діагноз може зберегти життя людини, тоді як помилки ведуть до запізненого лікування, що може завершитись більш важкими наслідками для пацієнта. З цією задачею допомагають впоратися сучасні технології глибинного навчання. Але перед початком роботи потрібно задати дану задачу формально.

Наявно M класів зображень (областей інтересу на обраних зображеннях). Класи представлені як певні скінченні чи нескінченні множини багатовимірних об'єктів O_i^* , $i=1, \dots, M$. Допускається, що $O_i^* \cap O_j^* = \emptyset$. Класи задано навчальними підмножинами областей інтересу o_{ij} , $j = 1, \dots, n_i$, де n_i – потужність підмножини. Кожна точка даних є зображенням ультразвукової діагностики печінки людини. Задача полягає у підборі найкращого алгоритму класифікації o_{ij} з O_i^* , $i = 1, \dots, M$ з урахуванням початкових наборів даних O_i^* , $i = 1, \dots, M$.

2.2 Проектування класифікатора захворювань печінки

Для того, щоб спроектувати ефективну модель класифікації, потрібно пройти ряд обов'язкових кроків:

- 1) Нормалізація і стандартизація вхідного набору даних

- 2) Попередня обробка даних
- 3) Скорочення розмірності через вибірку ознак чи проєкцію ознак
- 4) Вимірювання точності роботи моделі

Різні текстурні атрибути застосовують дуже несхожі формули, а тому їх значення у результаті досягають різниці у кілька порядків (наприклад, -0.2 і 15000) і це негативно впливає на роботу класифікатора, а для деяких алгоритмів стандартизація є обов'язковим підготовчим етапом для коректної роботи.

Крім того, бібліотека `radiomics` обчислює набір з 96 атрибутів текстури зображення, однак деякі з них не потрібні для процесу класифікації. Саме тому потрібно обрати ті атрибути, що несуть більше всього змістовної інформації і зробити це можна за допомогою методів скорочення розмірності (англ. «dimension reduction»). В разі успішного дотримання попередніх етапів можна підібрати сам алгоритм класифікатора та обрати метрики для об'єктивної оцінки його точності.

2.2.1. Стандартизація даних

Обов'язковим етапом багатьох алгоритмів як класичного машинного навчання (логістична регресія чи метод опорних векторів), так і глибоких нейронних мереж є попередня стандартизація вхідного набору даних [34]. Якщо атрибути вхідних даних не є нормально розподіленими і стандартизованими, це викличе помилки в роботі зазначених вище алгоритмів і тому в багатьох програмних бібліотек ці алгоритми вимагають це перед застосуванням. Для вирішення цієї проблеми дані приводять до нормального розподілу, що задається густиною або щільністю ймовірності:

$$f(x; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

де x – базовий вектор ознак,

μ – перший момент, математичне очікування випадкової величини,

σ^2 – другий момент, дисперсія випадкової величини.

Розподіл називається *стандартним нормальним* якщо $\mu = 0$, $\sigma^2 = 1$.

2.2.2. Зменшення розмірності

Як вже було сказано в Розділі 1, для обчислення тестурних статистик пропонується використовувати систему дослідників Гарвардської Медичної Школи у сфері медичних візуалізацій і точної медицини за назвою Radiomics [33], а точніше саме її реалізацію у мові Python в бібліотеці PyRadiomics. В результаті роботи цієї системи отримуємо 96 атрибутів, серед яких 75 текстурних ознак несуть змістовну для даної задачі інформацію.

Відбувається збільшення кількості атрибутів, що отримує на вхід система машинного навчання і сам процес навчання відбувається у багатовимірному просторі. Внаслідок цього може проявитися шкідливе явище «прокляття розмірності» (англ. curse of dimensionality). Цей комплекс феноменів сповільнює процес оптимізації та погіршує роботу значної кількості обчислювальних методів. За цієї причини потрібно зменшити кількість атрибутів системи, тобто провести скорочення розмірності – трансформація набору вхідних атрибутів, в результаті якої скорочується їхня кількість завдяки підбору мінімального числа змінних для ефективного описання даних.

Одним із підходів до скорочення розмірності є проекція ознак (англ. feature projection) трансформує набір атрибутів з простору високої розмірності у простір з низькою розмірністю. Найбільш відомим методом проекції ознак є метод головних компонент. МГК – це статистичний процес обчислення головних компонент і їх використання для зміни базису даних, іноді з використанням

тільки декількох перших головних компонент та ігнорування всіх інших. Процедура підрахунку головних компонент зводять до сингулярного розкладу матриці даних, що можна сформулювати як підрахунок власних векторів і власних чисел коваріаційної матриці вхідного набору атрибутів [35] (Рисунок 2.1).




Рисунок 2.1. Метод головних компонент [36]. На отриманій проекції даних, перша головна компонента демонструє максимальну вибіркову дисперсію.

Важливо взяти до уваги те, що на ефективність МГК впливає дисперсія між вхідними даними. Якщо один атрибут демонструє значення значно більші, ніж інший, то їх вплив на процедуру буде нерівноцінним і в такому разі потрібно масштабувати всі атрибути за їхніми стандартними відхиленнями, в результаті чого отримуємо безрозмірні елементи з одиничною дисперсією.

Значним недоліком традиційного МГК є те, що цей метод розпізнає кореляції між функціями виключно лінійного характеру. Вихід із цієї ситуації пропонує удосконалена версія алгоритму - ядровий метод головних компонент. Ця модифікація входить до групи ядрових методів (англ. kernel methods) і дає можливість обійти обмеження лінійності. Ядрові методи застосовують спеціальні ядрові функції, завдяки яким переходять до неявного простору ознак, в якому не потрібно обчислювати координати даних, а просто підраховувати скалярний добуток між парами точок даних цього простору. Цей математичний метод називають ядровим трюком [37] (Рисунок 2.2).

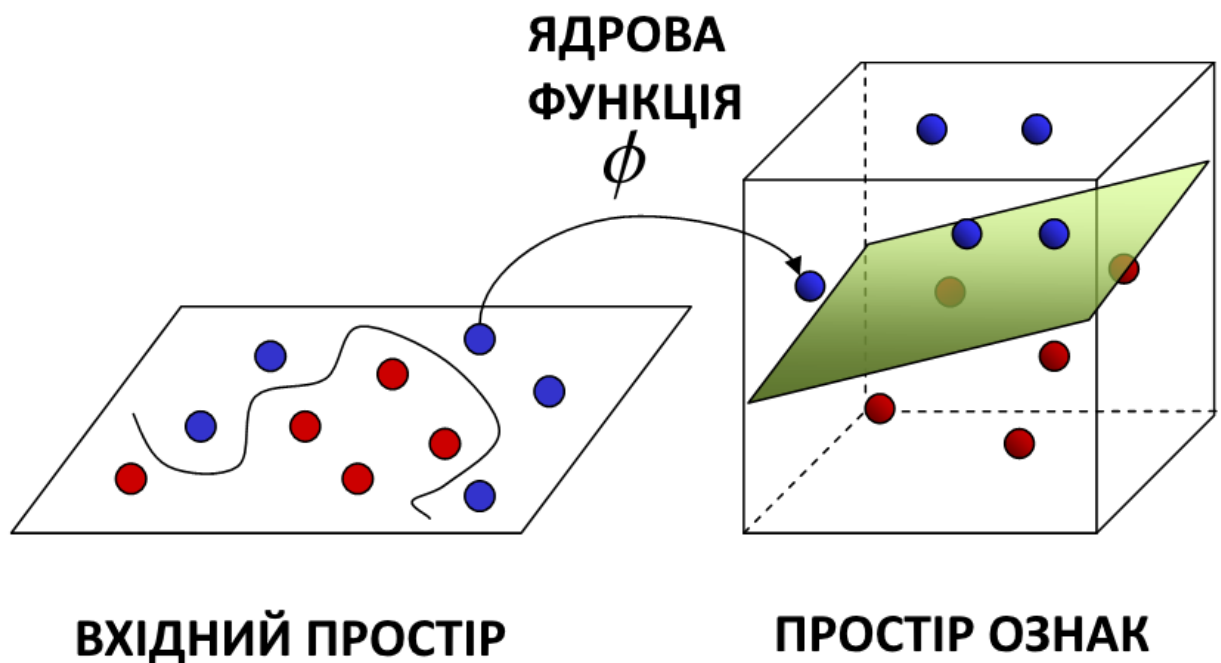


Рисунок 2.2 Ядровий трюк допомагає розділити кластери.

2.2.3. Оцінка точності моделі

В основі методів машинного навчання стоїть процес навчання на випробувальній виборці з вхідного набору даних, однак не менш важливим етапом є правильна оцінка точності отримано моделі. На початку роботи системи обчислювального інтелекту, набір даних розділяється тестові та навчальні. У

певних випадках дуже складно правильно розділити дані, зберігаючи потрібний баланс між кількістю представників різних класів і це може негативно вплинути на оцінку якості роботи системи. Для того щоб вирішити цю проблему використовують групу методів перехресного затвердження (англ. cross-validation). Головною ідеєю методики є розділення вхідного набору даних на k частин одного розміру, після чого дані $k-1$ частин використовуються для навчання, а останній фрагмент застосовують в якості тестових даних (Рисунок 2.3).

Під час навчання модель отримує відомі дані, що слугують в якості навчальної вибірки та невідомі дані як випробувальну вибірку, за допомогою якої оцінюють якість класифікатора. В ході перехресного затвердження перевіряють модель на можливість працювати на нових даних, що не були застосовані протягом навчання. Це потрібно для виявлення таких можливих проблем як перенавчання класифікатора і це дає уявлення про узагальнення моделі на нових даних. Ця методика сумує показники придатності щоб більш точно продемонструвати рівень точності роботи моделі.




Рисунок 2.3. Діаграма k -кратної перехресної перевірки [38]

2.3. Проектування архітектури штучної нейронної мережі

Для якісного проектування потрібної архітектури штучної нейронної мережі потрібно пригадати і чітко визначити, що це таке і чому це потрібно для вирішення даної задачі.

Машинним навчанням називають розділ штучного інтелекту, що вивчає системи, здатні до автоматичного вдосконалення власної структури. Це відбувається завдяки прописаному для них процесу навчання на тренувальних даних. Отримана система надає рішення чи прогнози вирішення певної задачі, не будучи явним чином запрограмованою на її вирішення, а виключно спираючись на висновки з даних [39].

Підвидом таких інтелектуальних систем, що імітують здатність нервової системи навчатися є штучні нейронні мережі (ШНМ) – це обчислювальні системи, віддалено схожі на біологічні нейронні мережі живих організмів. ШНМ складаються з шарів поєднаних вузлів. Ці вузли називають штучними нейронами і вони здатні отримувати інформацію, обробляти зважену суму входів за допомогою передавальної нелінійної функції (або ж функції активації) та направляти результат до наступного шару. Зв'язки між штучними нейронами концептуально нагадують синапси біологічних нейронів, що приймають сигнал з інших нейронів, та передають далі.

Інакше кажучи, штучна нейронна мережа – це обчислювальна нелінійна модель, що здатна навчатися вирішувати завдання класифікації, прогнозування, прийняття рішень, візуалізації і деяких інших тільки завдяки розгляду навчальних прикладів.

Будь-яка архітектура ШНМ складається з штучних нейронів (Рисунок 2.4) - елементів обробки, мають структуру 3 видів пов'язаних один з одним шарів: вхідним, що складається з одного або кількох шарів прихованим і вихідним.

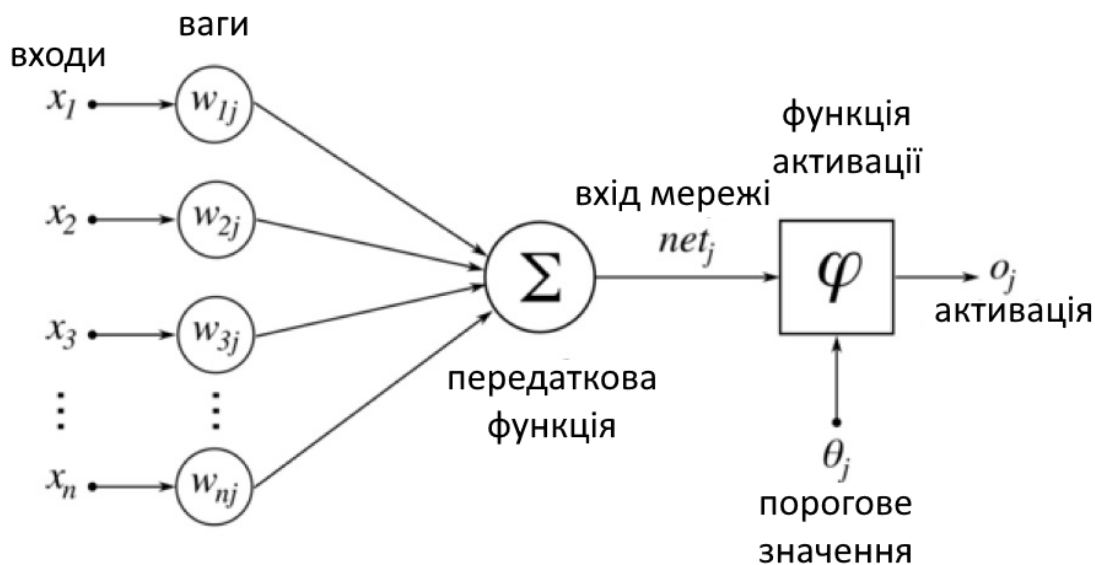


Рисунок 2.4 Штучний нейрон.

Найпростішою архітектурою ШНМ є перцептрон. Перцептроном називають алгоритм класифікації, який робить свої прогнози на основі функції лінійного предиктора (лінійний класифікатор), що комбінує набір ваг та вектор ознак. Дослідник Ф. Розенблат вперше описав цю архітектуру ШНМ (Рисунок 2.5) у 1947 році, трактуючи це як спрощену кібернетичну модель сприйняття інформації мозком [40]. Вхідний шар перцептрона складається з вхідних нейронів, які передають інформацію в прихований шар, а прихований шар в свою чергу передає інформацію в вихідний. Кожен нейрон має входи з вагами – синапсами, функцією активації, що задає вихідну інформацію при вказаній вхідній, та один вихід системи. Синапси – це параметри, які можна регулювати, що перетворюють нейронну мережу в параметризовану систему. Багато завдань розробки ШНМ зводяться до задачі підбору цих параметрів для забезпечення найкращого рівня роботи системи (наприклад, найвищої точності класифікації чи інших метрик, таких як чутливість, специфічність чи F-міра, що є середнім гармонійним між точністю та повнотою системи).




Рисунок 2.5. Приклад простої архітектури штучної нейронної мережі [41]

Більш складні види архітектури застосовують більшу кількість прихованих шарів, що дає можливість ускладнити функцію та більш влучно прогнозувати значення моделі. Найближчим прикладом до зазначеного вище є – багатозаровий перцептрон (рисунок 2.6), або ж модифікація звичайного штучного перцептрона з додатковими прихованими шарами.




Рисунок 2.6 Приклад архітектури багатозарового перцептрону

В літературі часто зустрічаються «глибинні» нейронні мережі (англ. deep neural networks) – це клас ШНМ, що містять кілька внутрішніх шарів (Рисунок 2.7).

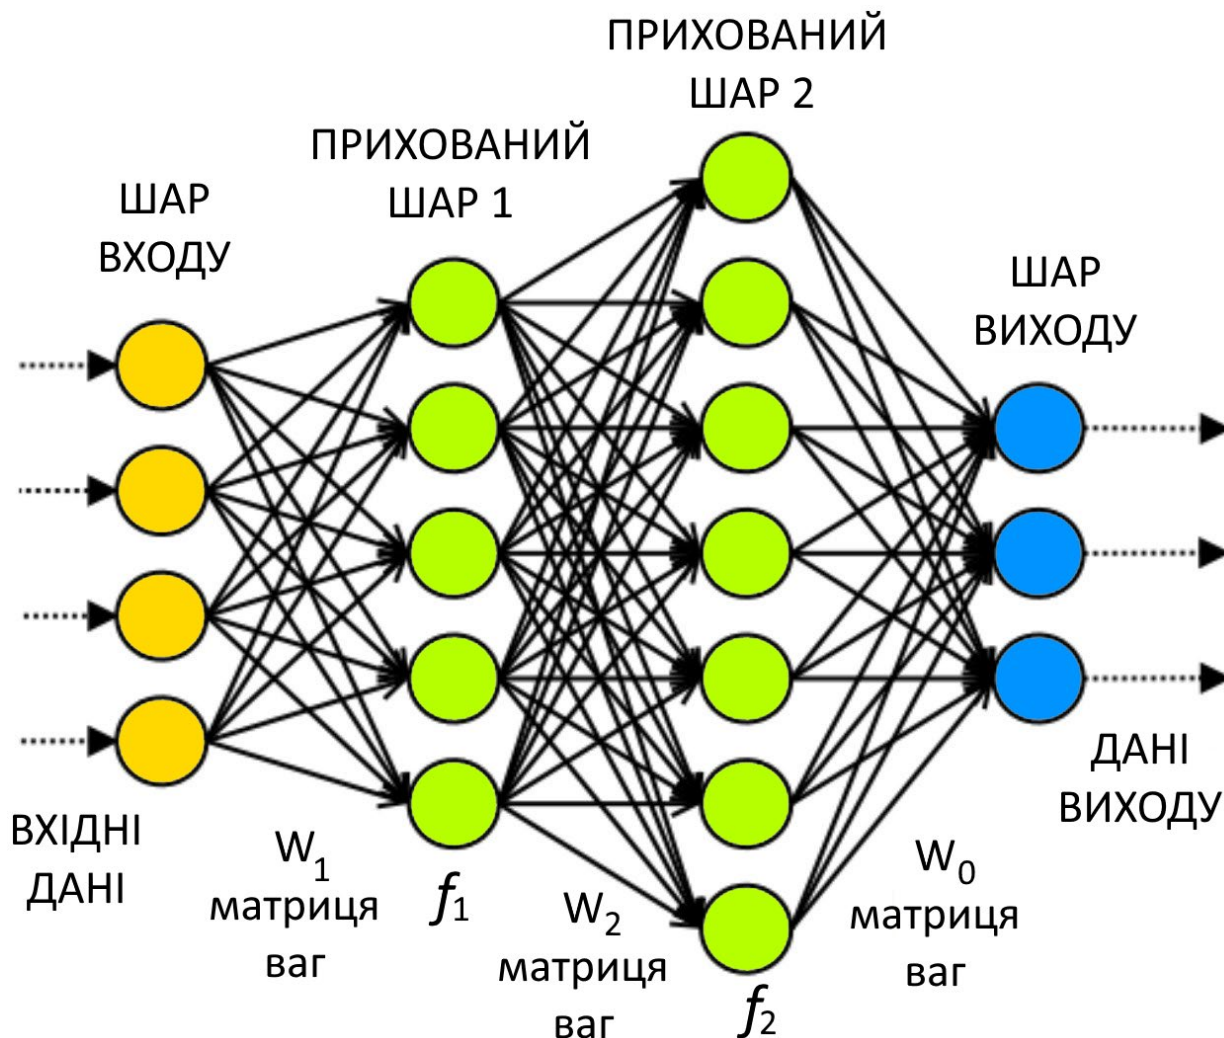


Рисунок 2.7 Архітектура глибинної штучної нейронної мережі

Особливий вид глибинних ШНМ – це згорткові нейромережі. Згорткові нейронні мережі (ЗНМ) – клас глибинних нейромереж, спеціалізований на ефективному розпізнаванні зорових образів та текстурних патернів. ЗНМ використовуються у задачах класифікації, розпізнавання об'єктів та обробки зображень завдяки можливості досягати в цих задачах продуктивності, яку можна порівнювати з людською [42]. Цей вид інтелектуальних систем не потребує значної попередньої обробки даних та застосовує власний метод

вилучення та конструювання ознак із даних на основі використання згорток (Рисунок 2.8), що відрізняє його від багатьох інших видів МН. Вперше цю архітектуру описав дослідником штучного інтелекту Я. ЛеКуном в 1988 році [43].

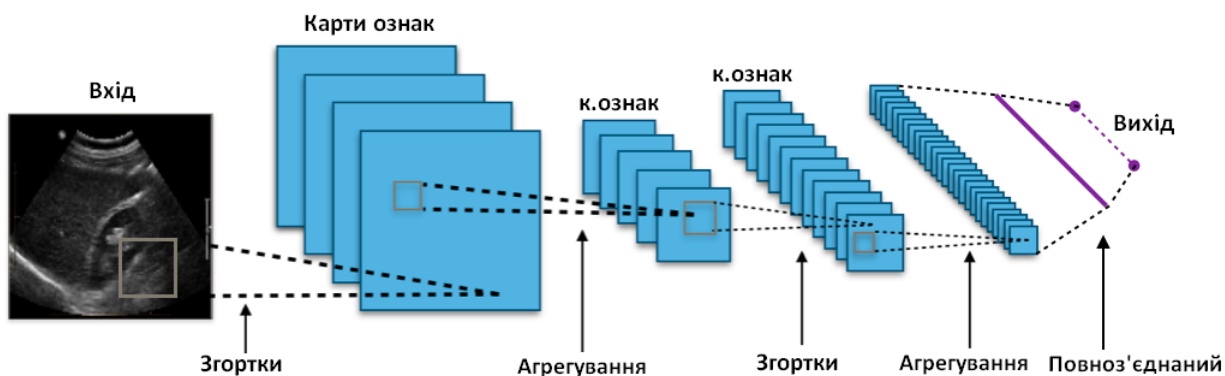


Рисунок 2.8 Архітектура згорткової штучної нейронної мережі [44] – адаптовано з [45]

Архітектура згорткових ШНМ зосереджена довкола математичної операції згортки (1), що дає можливість навчатись на окремих частинах зображення і підвищує точність системи.

$$S(t) = (x \cdot k)(t) = \int_{-\infty}^{+\infty} x(\tau)k(t - \tau)d\tau \quad (1),$$

де $x(t)$ – деяка функція на $t \in R$,

$S(t)$ – згортка функції $x(t)$ з ядром $k(t)$

Згорткові ШНМ – це клас обчислювальних систем, що здатний автоматично виділяти важливі недоступні людині ознаки зображень, що відрізняють ці зображення одне від одного.

Останні публікації [46] за напрямком обробки медичних зображень демонструють найбільшу ефективність використання саме згорткових нейронних мереж в якості класифікатора в порівнянні з іншими класичними

методами виділення ознак (англ. «feature extraction»). Оглядом дослідження [47] демонструють, що згорткові ШНМ є найбільш популярним і ефективним методом роботи як із зображеннями загального виду, так і конкретно медичними зображеннями області радіології.

З врахуванням попередніх спостережень та інтересу у порівнянні нового підходу з існуючим було прийнято рішення розробити архітектуру класифікатора на основі згорткової штучної нейронної мережі у поєднанні з модулем, що виконує попередню обробку даних та обчислює текстурні ознаки вхідних медичних зображень (Рисунок 2.9).

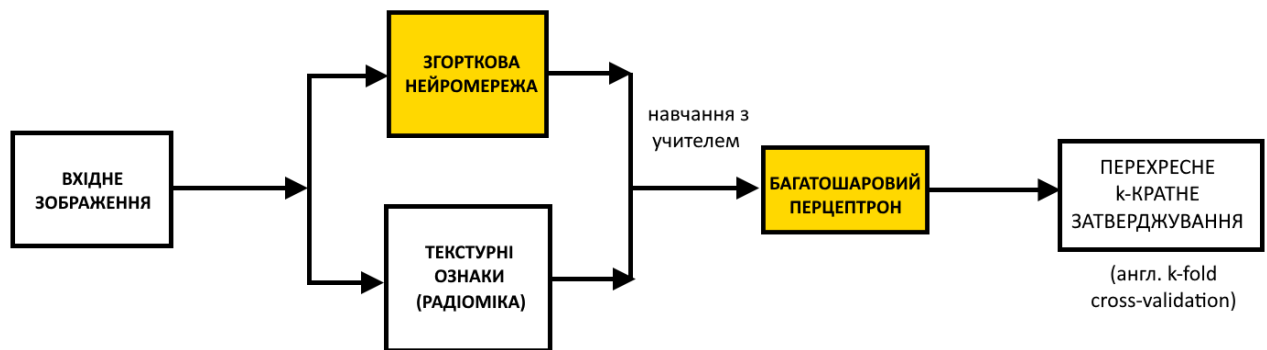


Рисунок 2.9 Порядок застосування методів машинного навчання у системі.

Помаранчевим кольором виділено нові методи, запропоноване розширення в порівнянні з попереднім дослідженням [21].

Основна ідея нового підходу полягає в тому, що вивід останнього шару агрегування згорткової нейронної мережі та текстурні ознаки передаються разом на вхід до повнозв'язного шару багатошарового перцептрона (Рисунок 2.10).

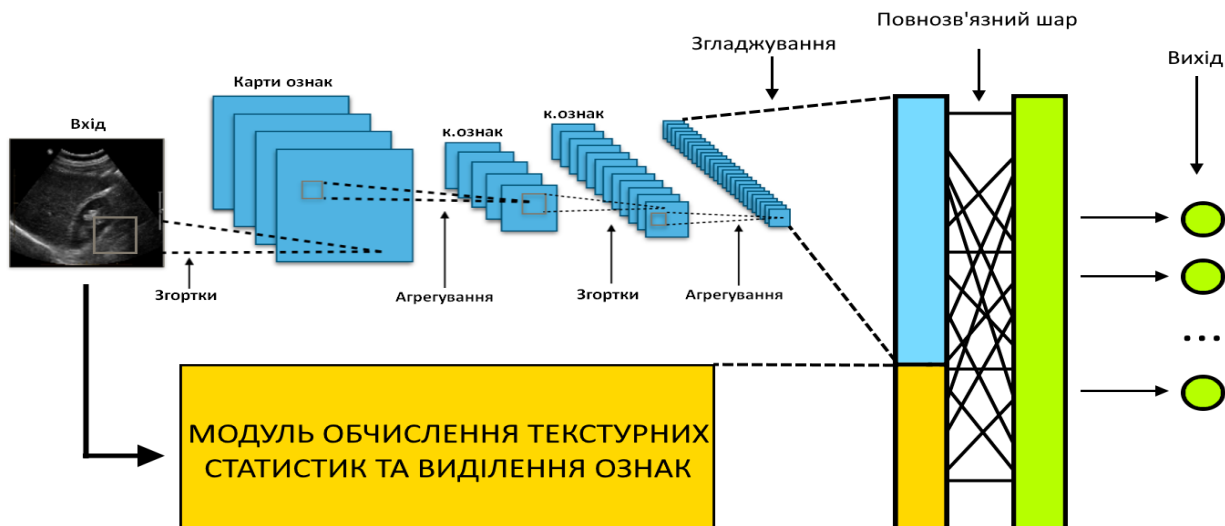


Рисунок 2.10. Прототип архітектури системи класифікатора

Остаточні властивості архітектури мережі (Рисунок 2.11) було обрано за урахуванням наявної літератури рекомендацій експертів області нейронних мереж [48].

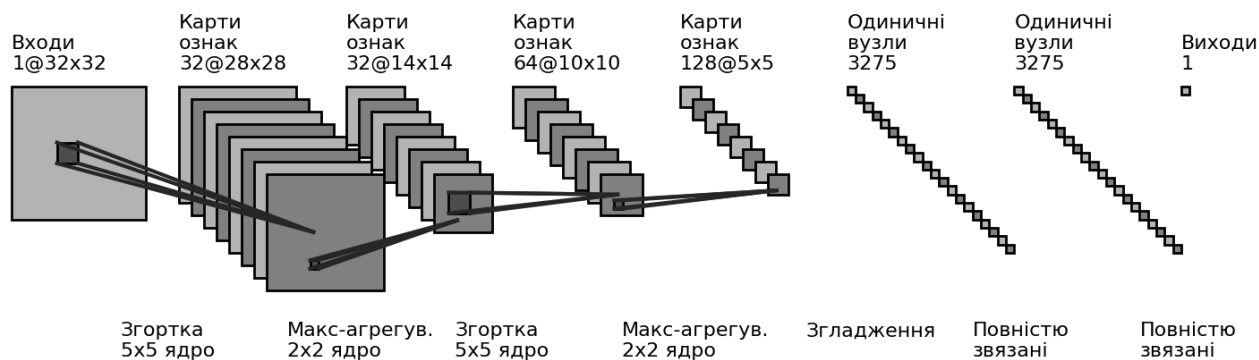


Рисунок 2.11 Кінцева версія архітектури класифікатора

Структуру мережі можна описати наступним чином:

- 1) На вході система отримує зображення розміром в 32x32 пікселя.
- 2) Після цього на 4 шарах згорткової мережі по черзі відбувається операція максимізаційного агрегування (з англ. max pooling) та згортки.

3) Після цього відбувається згладжування (з англ. flattening) і трансформація даних у одиничний вектор. Протягом роботи нейронної мережі формується 3200 властивостей, а також 75 властивостей утворюються за допомогою модуля, що займається обчисленням текстурних статистик.

4) За цим слідує 2 шари звичайної мережі прямого поширення (англ. feedforward neural network). На виході система отримує 1 значення найбільш ймовірного класу, до якого належить вхідне зображення.

Висновки до розділу 2

У другому розділі дипломної роботи розглянуто формально постановку завдання інтелектуальної системи класифікатора та вказано основні методи аналізу та побудови класифікаторів. В ході роботи було розглянуто побудову математичної моделі класифікатора шляхом стандартизації даних, зменшення простору ознак та перехресного перевірки точності.

Окремо досліджено новий елемент архітектури системи – згорткову нейронну мережу. Робота детально описує запропоновану архітектуру класифікатора, що враховує зауваження до минулих досліджень автора на цю тему та пропонує новий підхід до вирішення задачі.

РОЗДІЛ 3

РОЗРОБКА ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЛАСИФІКАЦІЇ ЗАХВОРЮВАНЬ ПЕЧІНКИ

3.1 Функціональний аналіз програми класифікатора захворювань

Як було визначено, головною задачею системи є класифікація захворювання печінки на основі УЗД пацієнта з використанням різних математичних методів і стандартів.

Кінцевими користувачами системи є медичні спеціалісти УЗД. Для користування системою робоче місце має бути облаштоване робочого комп'ютера.

Під час запуску, система отримує медичне зображення ультразвукової діагностики печінки, а на виході користувач отримує текстове повідомлення на рахунок можливого діагнозу (наявного захворювання печінки або ж норми) та розраховану точність цього діагнозу (рисунок 3.1).



Рисунок 3.1 Контекстна діаграма проекту

Представлена система в своїй роботі буде використовувати математичний апарат методів:

- радіоміки (текстурний аналіз);
- Стандарт NRRD;
- Методи класифікації (згорткові нейронні мережі);
- Методи оцінки точності моделі (кратне перехресне затвердження).

На рисунку 3.2 відображено узагальнений процес класифікації захворювання печінки на основі УЗД пацієнта. Основний процес роботи системи було розділено на 4 окремих етапи:

- 1) Обрання та автоматична обробка зображення;
- 2) Виділення властивостей;
- 3) Прогнозування захворювання печінки;
- 4) Оцінка точності прогнозу.

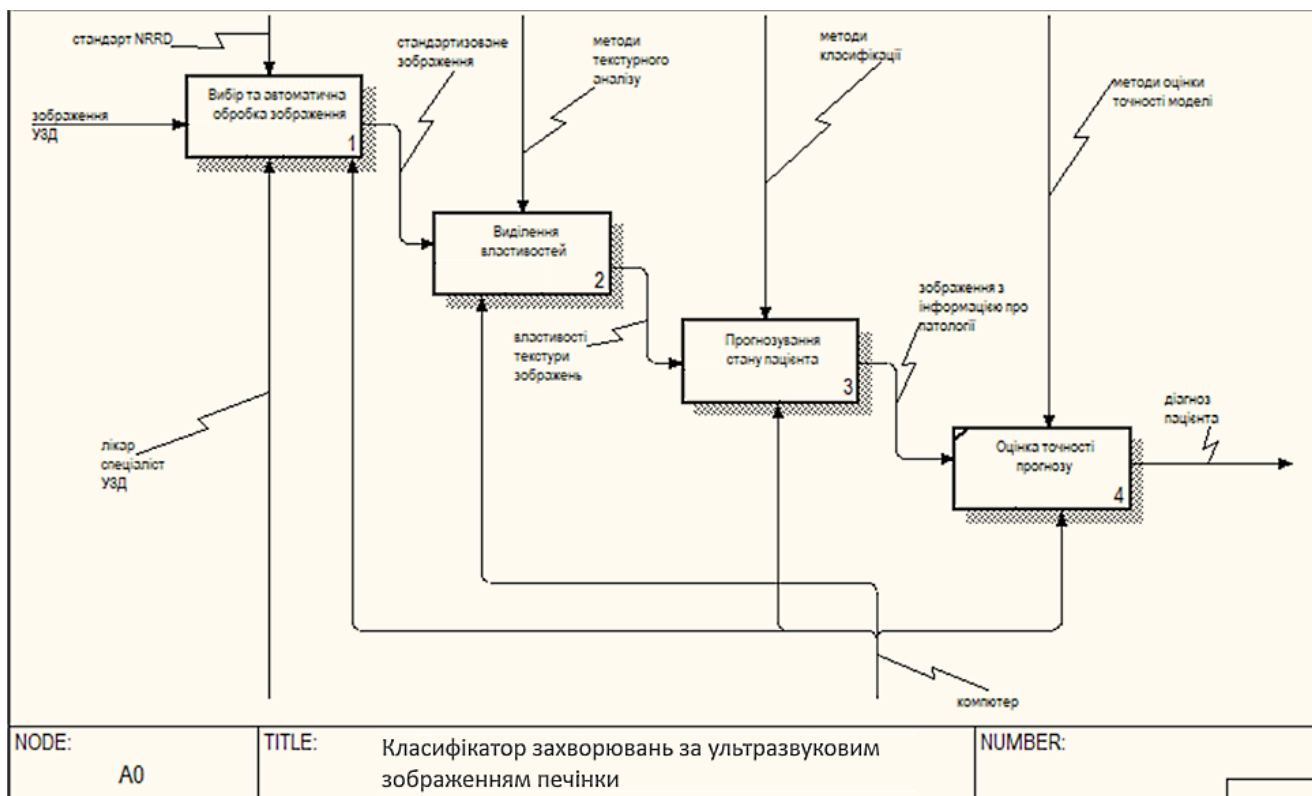


Рисунок 3.2 Діаграма декомпозиції 1-го рівня

Було проведено функціональний аналіз системи класифікації захворювання печінки на основі УЗД пацієнта. До основних функцій системи (рис. 3.3) можна віднести:

1. Вибір та автоматична обробка зображення;
 - 1.1. завантажити зображення до бази даних інформаційної системи;
 - 1.2. перевірка формату та узгодження можливих змін з користувачем;
 - 1.3. приведення вхідних даних до стандарту NRRD;
2. Виділення властивостей;
 - 2.1. обчислення текстурних матриць;
 - 2.2. обчислення специфічних ознак текстурних матриць;
3. Прогнозування класу захворювання печінки;
 - 3.1. завантаження текстурних ознак;
 - 3.2. набір прогнозів “один против всіх” для кожної патології;
 - 3.3. прогноз стану пацієнта серед усіх можливих класів;
 - 3.4. збереження висновків прогнозуючих алгоритмів;

4. Оцінка точності прогнозу
 - 4.1. налаштування К-фолду
 - 4.2. запуск крос-валідації (перехресного затвердження)
 - 4.3. збереження прогнозів з отриманими точностями алгоритмів

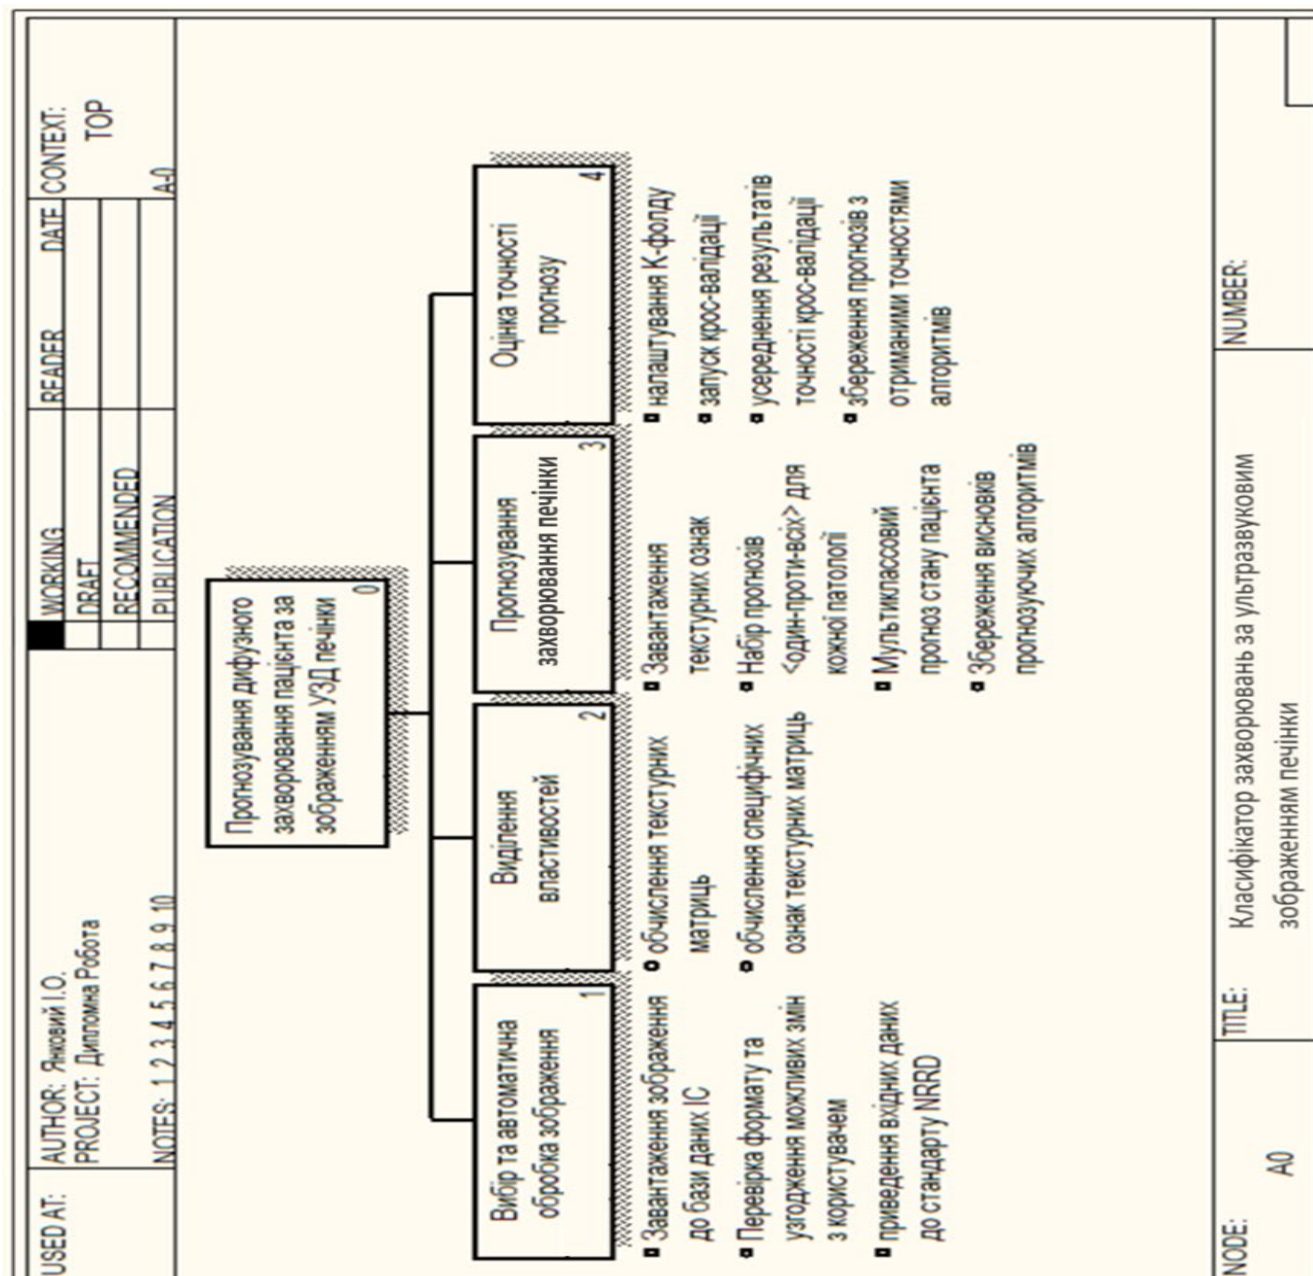


Рисунок 3.3 Функціональний аналіз класифікатора захворювання печінки на основі УЗД пацієнта

3.2 Графічний інтерфейс користувача

Дана програма класифікації захворювань печінки розроблялась для користування медичними спеціалістами УЗД. Це значить, що програмі потрібен зручний та простий для розуміння графічний інтерфейс.

За архітектурою класифікатора, що була розроблена на етапі проектування, користувач має обирати медичне зображення на своєму комп'ютері, після чого програма запускає спроектовану автором систему обчислювального інтелекту та видає текстовий результат.

На початку користувач запускає програму і перед ним відкривається нове вікно, в якому відображено графічний інтерфейс роботи з програмою. До структури інтерфейсу входить ряд простих елементів, які можна використовувати для роботи з програмою:

- Основне меню програми
- Вертикальне меню, що випадає, «Файл» містить доступ до основних можливостей програми
- Вертикальне меню, що випадає, «Допомога» містить інформацію про програму, її можливості та автора.
- Простір з описанням основних можливостей додатку
- Простір відображення останнього зображення
- Кнопка «Обрати Зображення»
- Кнопка «Аналізувати»
- Простір для демонстрації результатів класифікації захворювань



Рисунок 3.4 Графічний інтерфейс користувача при запуску програми

На зображенні (рисунок 3.4) видно графічний інтерфейс користувача з меню, що містить пункти «Файл» та «Допомога». Трохи нижче вказано основну функцію програми – це класифікатор дифузних захворювань печінки. Після цього можна побачити дві кнопки, за допомогою яких можна управляти класифікатором – «обрати зображення» та «аналізувати». В нижній частині зображення зліва у спеціальному віджеті демонструється останнє завантажене зображення, що було передано системі класифікатора. Там же справа розташовано простір для відображення текстових результатів класифікатора на основі поточного зображення.

3.2.1 Реалізація функції «Вибір та автоматична обробка медичного зображення»

Спочатку користувач системи повинен завантажити зображення, з яким хоче працювати.

Алгоритм роботи:

1. Натиснути кнопку «Обрати Зображення»
2. У вікні, що випало треба знайти зображення
3. Натиснути «Відкрити»

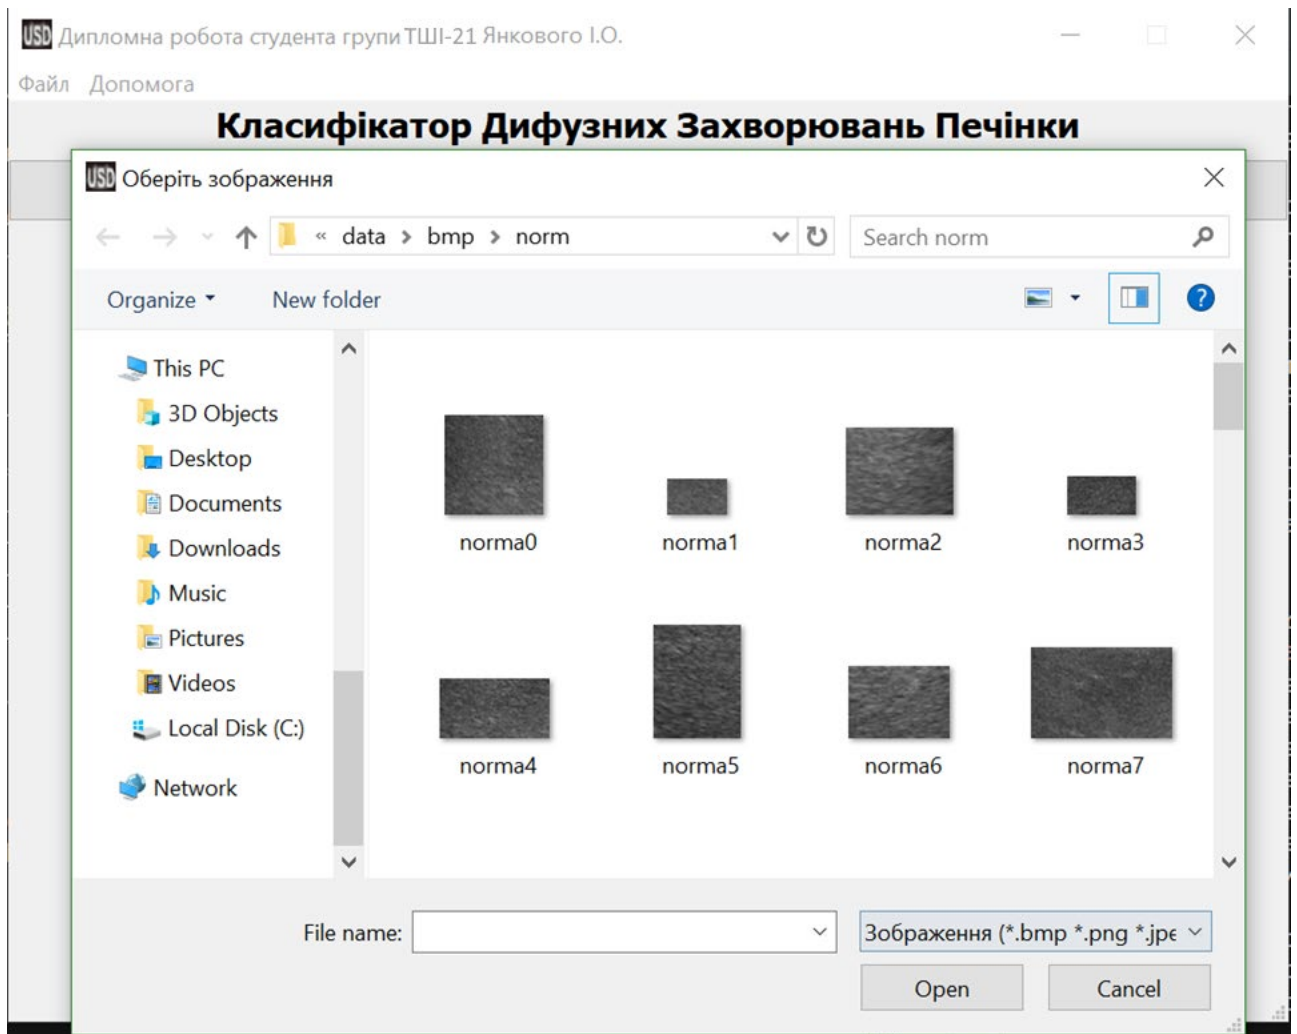


Рисунок 3.5 Вікно вибору медичного зображення для обробки

У новому вікні (Рисунок 3.5) можна обрати папку на компютері користувача та обрати об'єкт файлової системи допустимого формату: BMP, JPEG чи PNG .

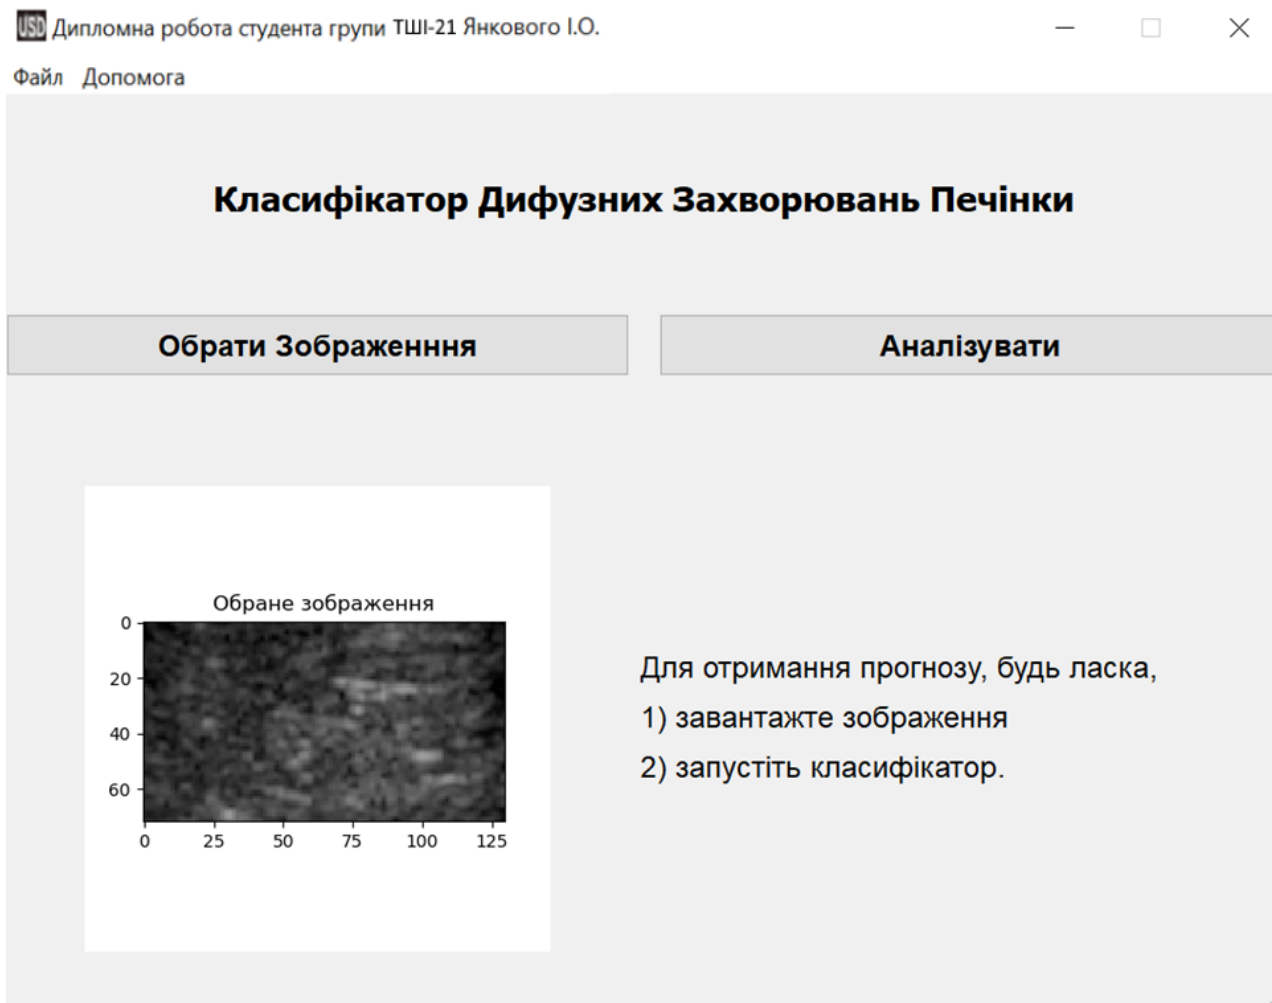


Рисунок 3.6 Графічний інтерфейс після вибору зображення

Система враховує можливість допущення користувачем помилки, коли він пропускає етап вибору зображення (без чого неможливо проводити аналіз). Описана послідовність дій порушує логіку роботи системи. По цій причині було встановлено обмеження до наступного виконання, поки користувач не завантажить потрібне зображення. Обмеженням організоване як логічний прапорець коректного завантаження вхідних даних.

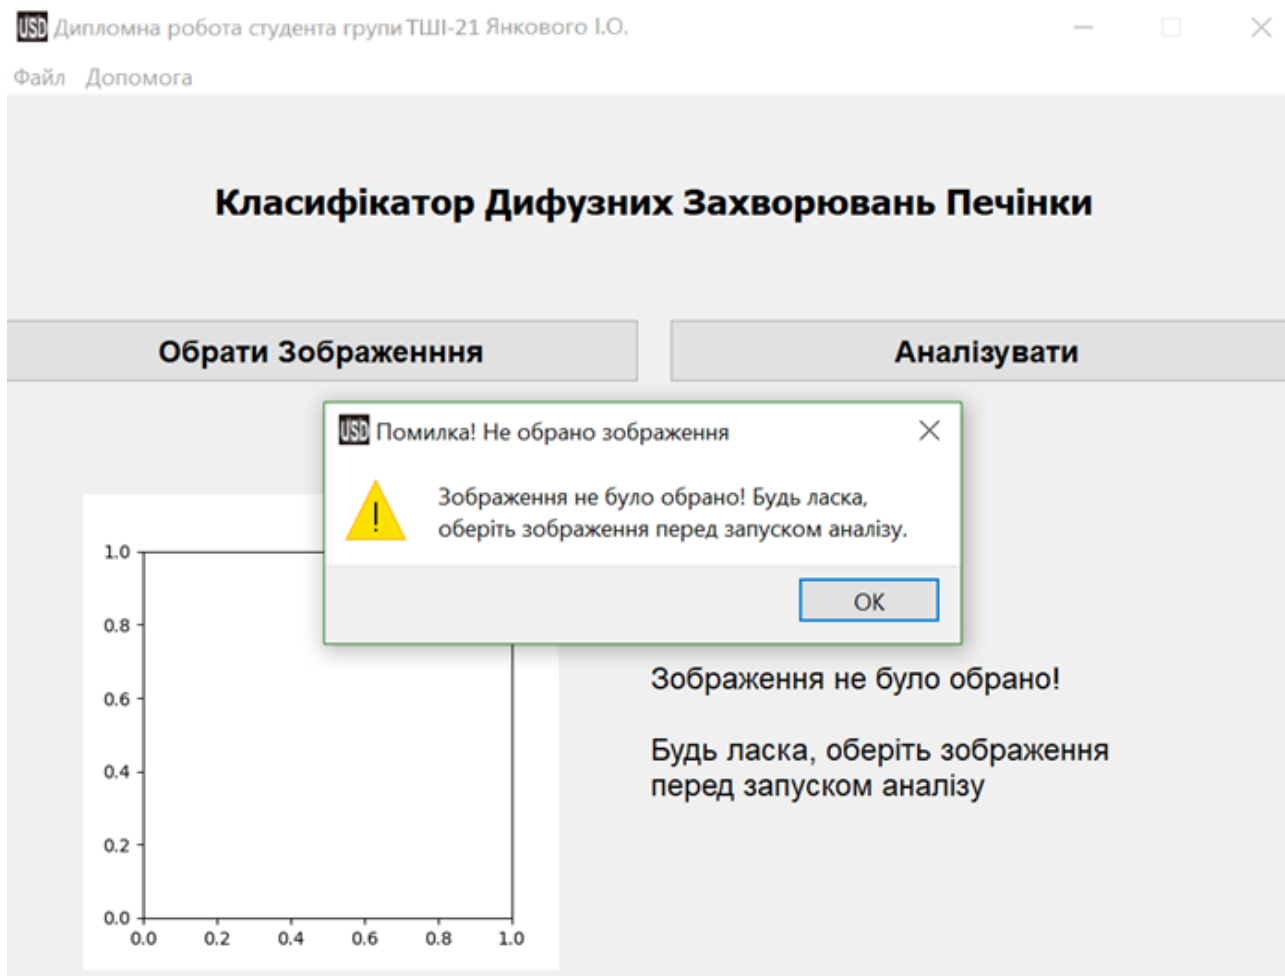


Рисунок 3.7 Вікно помилки в разі пропуску завантаження зображення

При пропущенні користувачем завантаження зображення, програма створить додаткове тимчасове вікно з описанням помилки і ця ж інформація виникне у просторі для результатів (Рисунок 3.7).

Користуваче має зачинити закрити тимчасове вікно з помилкою та обрати коректне зображення щоб мати можливість запуснути аналіз системи.

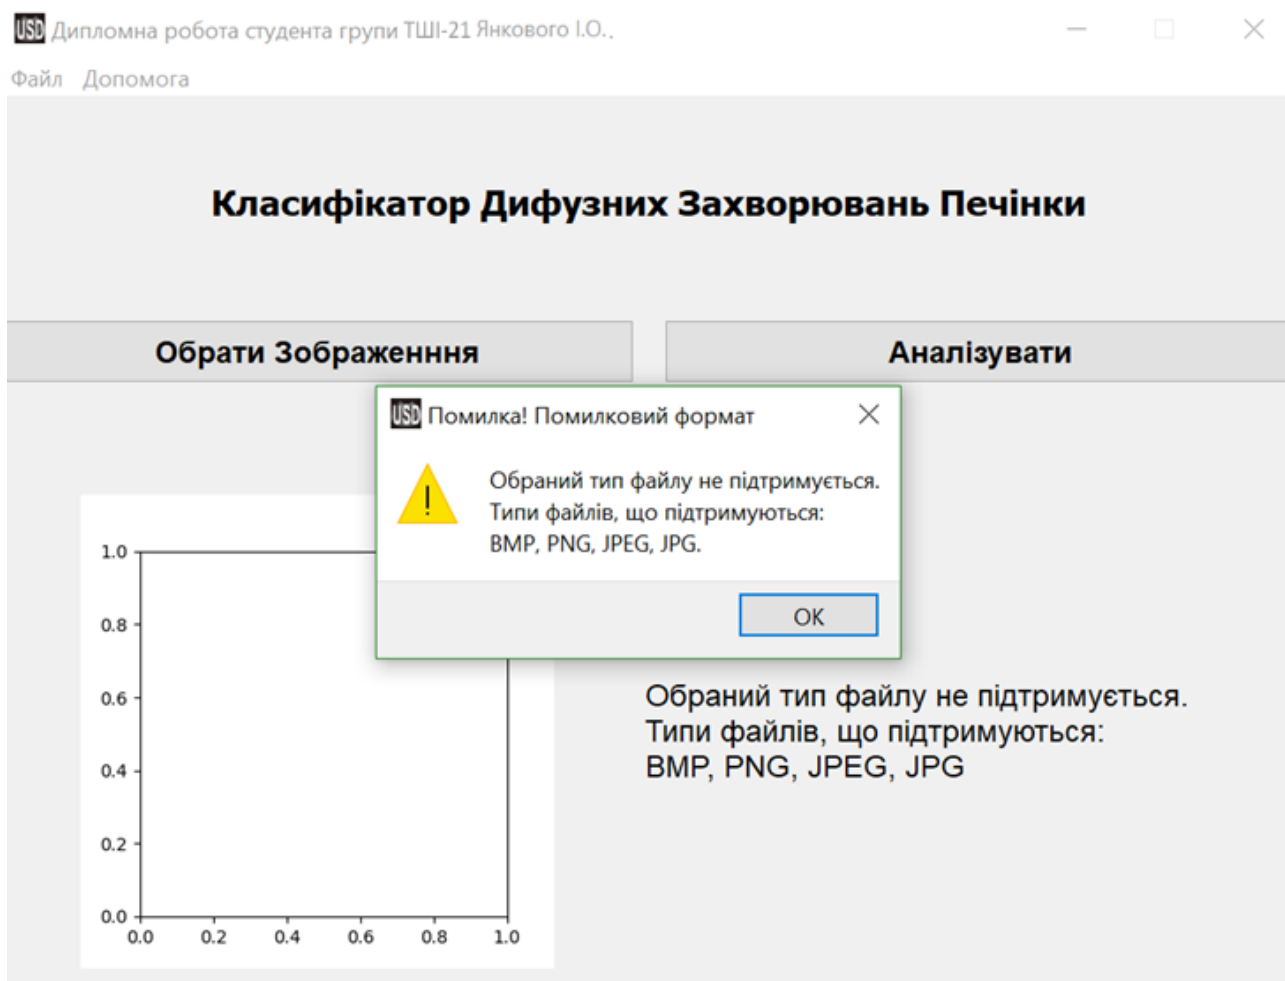


Рисунок 3.8 Вікно помилки при виборі помилкового формату

Також в програмі враховано можливість вибору некоректного формату даних. В такому сценарії користувач отримує повідомлення з описанням про помилку (Рисунок 3.8).

3.2.2 Реалізація функції «Прогнозування захворювання печінки»

Наступним кроком роботи з програмою є запуск самого класифікатора. Щоб це зробити потрібно:

1. Переглянути графічний віджет, чи обрано те зображення, що треба
2. Натиснути кнопку «Обрати Зображення»



Рисунок 3.9 Демонстрація результатів класифікації зображення

У просторі для демонстрації результатів відображаються текстові висновки за розробленою архітектурою системи класифікатора (Рисунок 3.9).

3.2.3 Використання основного меню програми

Під час роботи з графічним інтерфейсом програми, користувач може використати основне меню, що містить наступні розділи:

1. Файл
2. Допомога



Рисунок 3.10 Результат вибору розділу основного меню «Файл»

У сценарії вибору розділу основного меню «Файл» випадає список, в якому користувач може обрати необхідний варіант використання: завантажити зображення, проаналізувати за допомогою класифікатора, або вийти з програми (Рисунок 3.15).

У цих дій є комбінації «гарячих клавіш» які можна використати для швидкого вибору цих функцій на клавіатурі:

- Завантажити = Ctrl + D (з англ «Download»)
- Аналіз = Ctrl + A (з англ «Analysis»)
- Вихід = Ctrl + Q (з англ «Quit»)

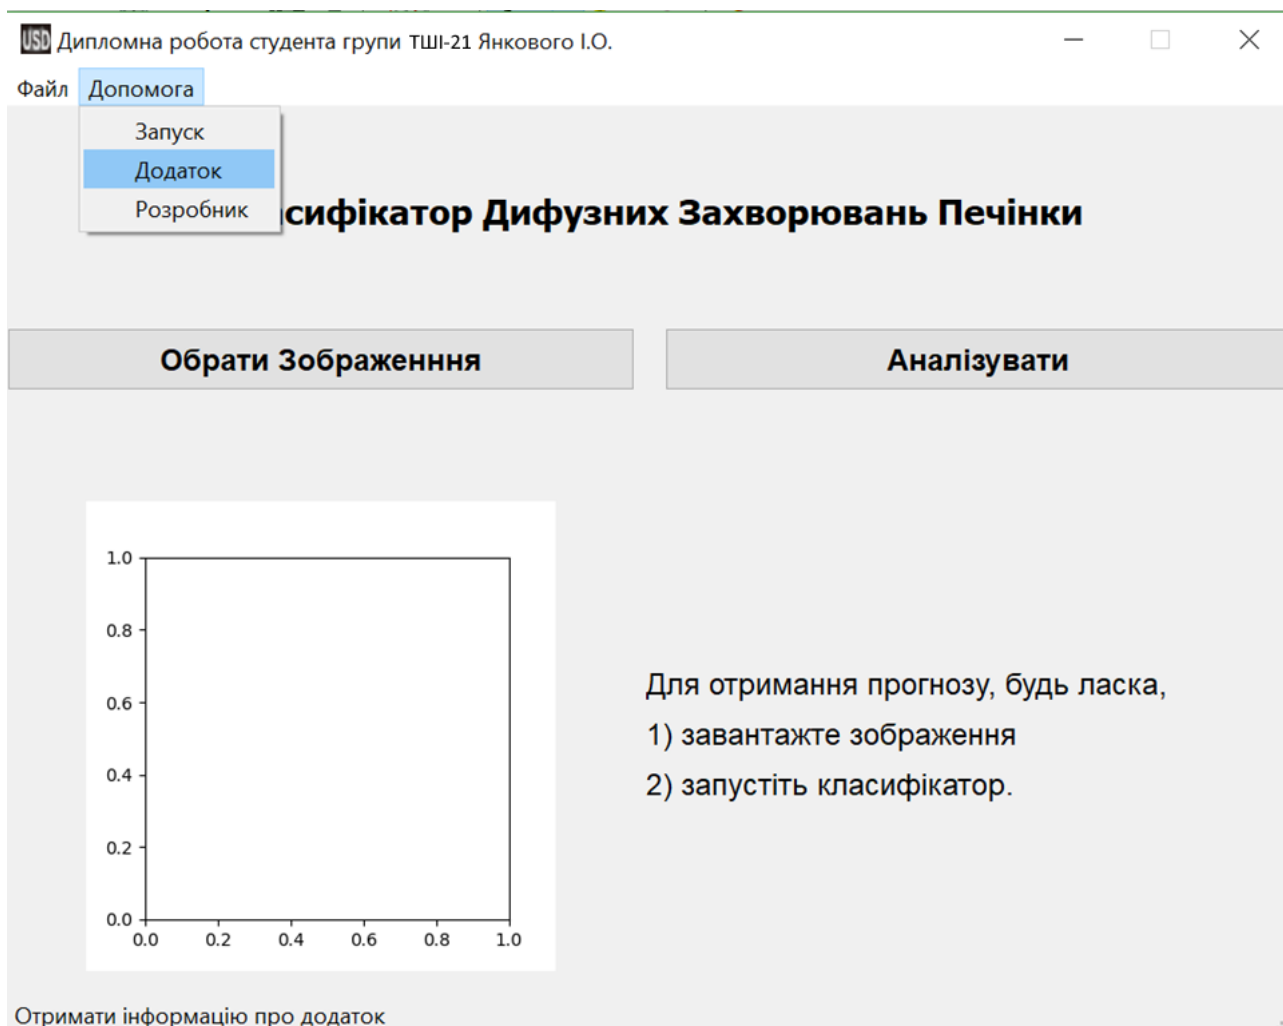


Рисунок 3.10 Результат вибору розділу головного меню «Допомога»

При виборі розділу головного меню «Допомога» випадає список (Рисунок 3.10), в якому користувач може отримати додаткову інформацію про:

- Алгоритм запуску класифікатора
- Основну задачу роботи додатку
- Подобиці про розробника додатку

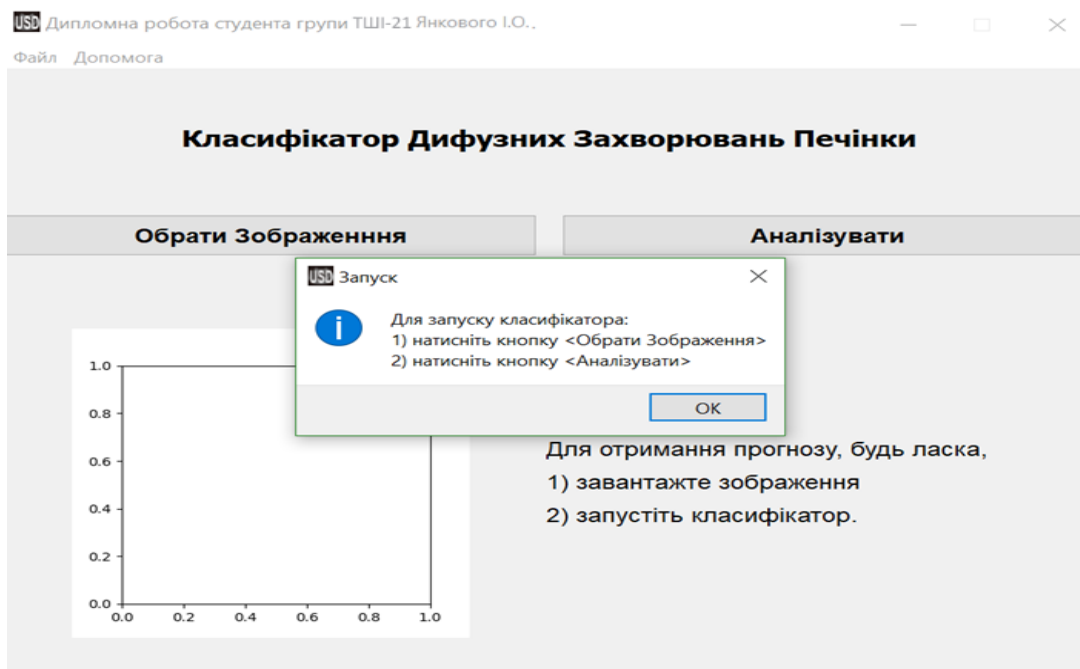


Рисунок 3.11 Результат вибору підрозділа «Запуск» у меню , що випадає «Допомога»

При виборі пункту «Запуск», програма генерує повідомлення з інформацією, з якої можна дізнатись основну інструкцію про роботу з програмою (Рисунок 3.11).

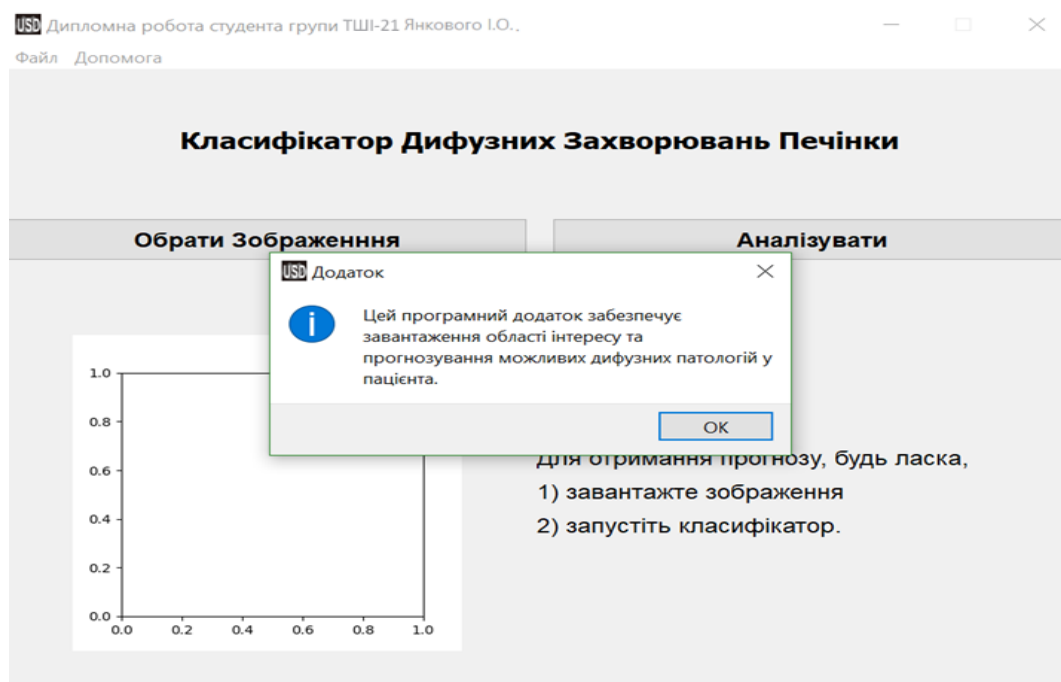


Рисунок 3.12 Результат вибору підрозділу «Додаток» у меню , що випадає «Допомога»

При виборі підрозділу «Допомога» програма створює інформаційне повідомлення, у якому можна дізнатися основне призначення програмного додатку. (Рисунок 3.12).

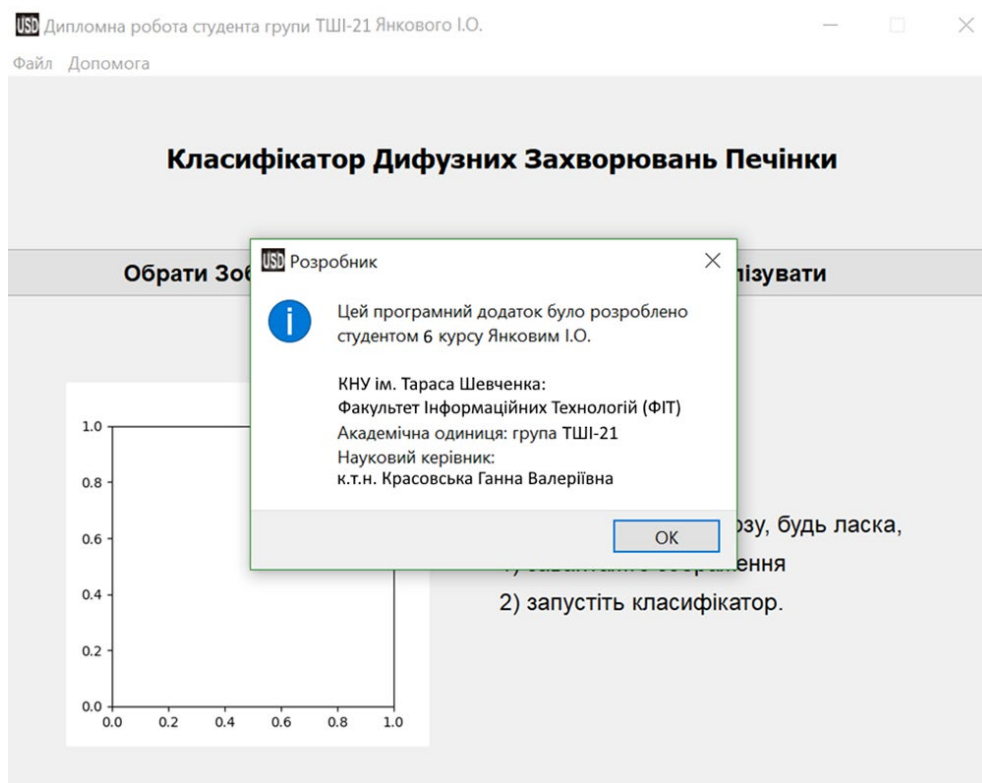


Рисунок 3.13 Результат вибору підрозділу «Розробник» у меню , що випадає «Допомога»

Коли користувач вибирає підрозділ «Розробник», програма генерує повідомлення з інформацією, з якої можна дізнатись більше про розробника програми. (Рисунок 3.13).

3.3 Підготовка набору даних

Вхідними даними для задачі класифікації стану печінки пацієнта стали

зображення ультразвукового дослідження (Рисунок 3.14).




Рисунок 3.14 Медичне зображення УЗД печінки людини

Клінічна база дослідження складається з 247 зображень областей інтересу (текстури паренхіми печінки, її функціональної тканини), заздалегідь розмічених медичними спеціалістами на зображеннях УЗД в b-режимі роботі пристрою (Рисунок 3.15). Ці зображення були отримані, записані та анонімізовані в результаті обстеження 15 пацієнтів дитячого віку у державній установі «Інститут ядерної медицини та променевої діагностики Національної Академії Медичних Наук України».

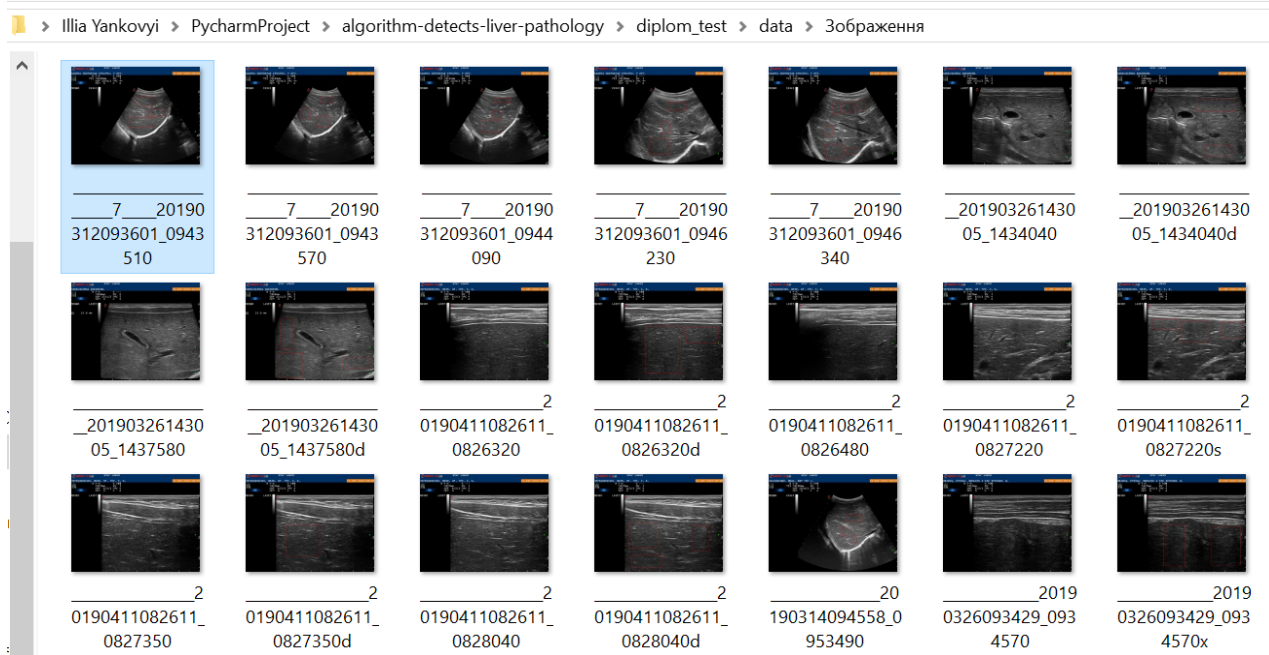


Рисунок 3.15 Знімок екрану з директорії комп'ютера, що містить оригінальний набір медичних зображень УЗД

У будь-якому алгоритмі машинного навчання для того щоб досягнути задовільних результатів потрібно якісно провести етап попередньої обробки даних. У даній роботі в ході підготовки вхідних зображень, експертом предметної області (медичним спеціалістом) було обрано області інтересу. Отримані зображення розташовуються в спеціальних директоріях, назва кожної з яких відповідає класу захворювань печінки, що класифікуються системою (Рисунок 3.16).

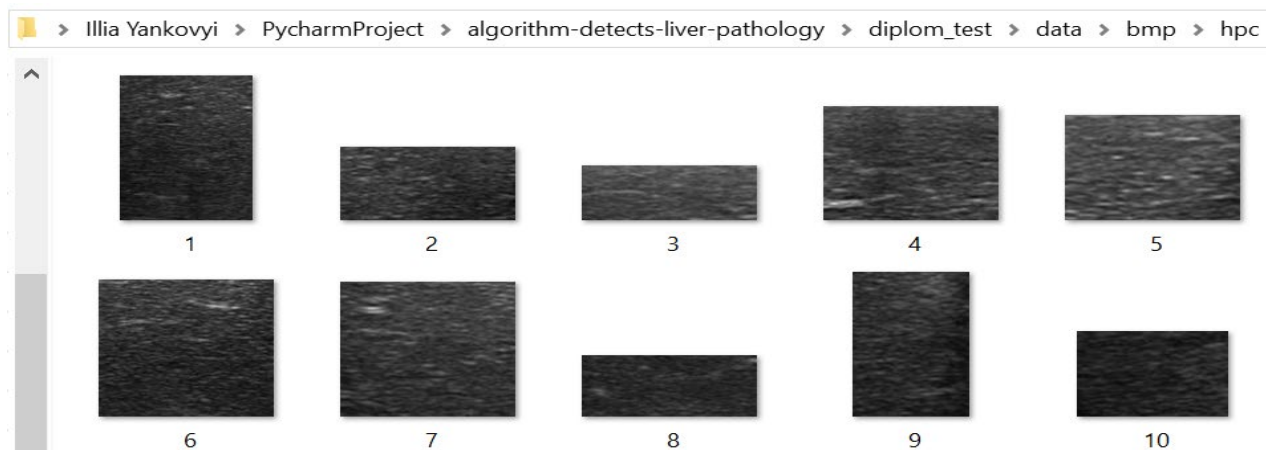


Рисунок 3.16. Знімок екрану з директорії комп'ютера з результатами попередньої обробки зображень для захворювання «гепатит С»

Після цього всі зображення завантажуються та дискретизуються як матриці відтінків сірого кольору (Рисунок 3.4).

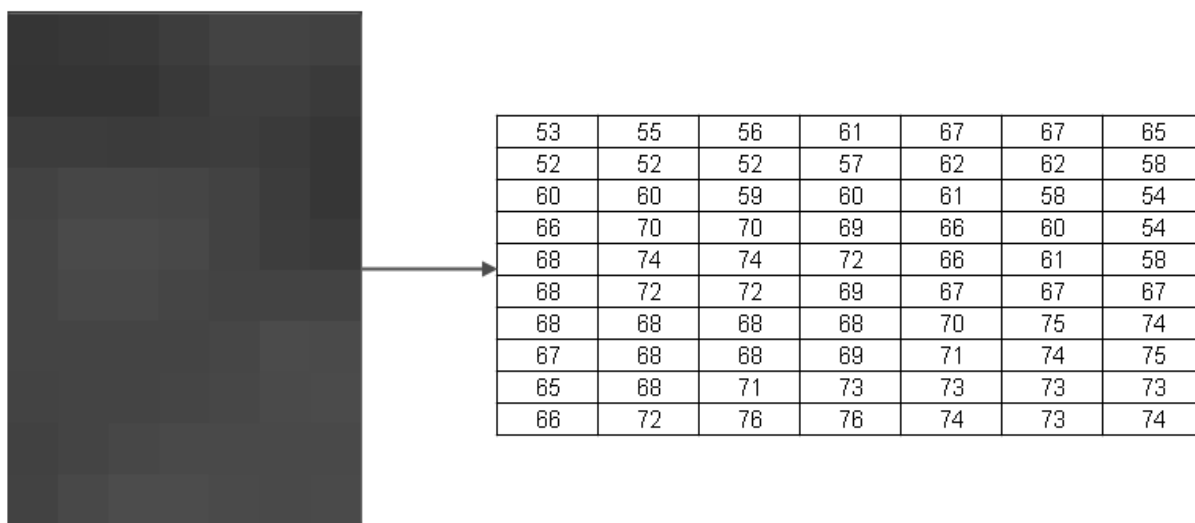


Рисунок 3.17. Створення матриці відтінків сірого

На наступному кроці відбувається основна робота по опрацюванню медичних зображень, структурованих на минулому етапі за директоріями. В ході цієї роботи застосовується модуль радіоміки, що спочатку формує всі доступні матриці сірих відтінків, після чого витягує спеціальні текстурні статистики і зберігає їх в окрему таблицю.

Наступним етапом стала програмна обробка отриманих директорій із збереженими областями інтересу медичних зображень застосовуючи методи радіоміки. В результаті цього була створена таблиця, у якій зберігаються результати застосування радіоміки (властивості матриць текстурних статистик, описаних раніше) всіх зображень вхідного набору даних та відмітки, які захворювання має пацієнт чи знаходиться в нормі на даному зображенні.

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	id	cs_Image-origir	Image-origina	Image-original	firstorder_10P	firstorder_90P	Pal_firstorder_Eal	firstorder_Ertorder	Interqual	firstorder_Ku	firstorder_Mrder	MeanAbsnal	firstorder_1a
2	0	81.85743671	40	136	67	97	43283303	1.236322544	16	3.27169625	136	9.640616838	81.85743671
3	1	87.76867816	61	122	78	98	10806856	0.53112871	11	3.125712915	122	6.286144553	87.76867816
4	2	82.24942396	43	129	64.5	100	12081449	1.36446868	19	2.851232879	129	11.25689253	82.24942396
5	3	71.49694989	35	124	58	86	24021149	1.105577053	15	3.452698244	124	8.74432749	71.49694989
6	4	63.93075802	31	103	53	76	11459458	0.874362154	12	3.594616858	103	7.239050587	63.93075802
7	5	87.05117271	50	130	72	102	21708904	1.137791614	16	3.09356725	130	9.289790766	87.05117271
8	6	88.59473967	41	147	68	110	45313926	1.55599443	23	2.735938325	147	13.12851475	88.59473967
9	7	57.05833662	31	82	47	67	8410431	0.737283903	10	2.823563869	82	6.219797218	57.05833662
10	8	74.59445746	34	204	63	86	14520009	1.107634577	13	23.32783255	204	7.524728802	74.59445746
11	9	72.47098214	39	103	62	84	11941181	1.011119355	12	2.949062264	103	7.120360332	72.47098214
12	10	85.52425028	56	126	73	98	20016079	0.886418585	12	3.829867735	126	7.587444748	85.52425028
13	11	90.1221524	60	136	80	101	20856289	0.676281947	10	4.47424563	136	6.421848668	90.1221524
14	12	90.37508306	40	144	71	110	50547620	1.467978506	21	2.765262868	144	12.24921193	90.37508306

Рисунок 3.18 Фрагменту таблиці з результатами застосування радіоміки

3.4 Аналіз результатів роботи класифікатора захворювань печінки

Обрану архітектуру класифікатора було випробувано на наборі клінічних даних з використанням k-кратного перехресного затвердження. Новий підхід демонструє кращі результати в ході порівняння з попереднім дослідженням [21], у якому не використовувались методи нейронних мереж (Таблиця 3.1).

Підхід до розробки системи	Класифікація серед всіх захворювань	Класифікація норма/ захворювання
Класичний текстурний аналіз, машинне навчання (попередні розробки) [21]	77%	85%
Класичний текстурний аналіз + глибинне навчання (поточна робота)	87%	92%

Висновки до розділу 3

В результаті розробки програмного забезпечення класифікатора захворювань за ультразвуковими зображеннями печінки із застосуванням нейронних мереж та радіоміки було проведено функціональну декомпозицію системи, запропоновано узагальнену технологію реалізації функцій системи, а також розвинено базовий прототи системи класифікації захворювань печінки на основі методів радіоміки, що було описано в першому розділі даної роботи.

Розроблене програмне забезпечення дозволяє спеціалісту в області УЗД-діагностики завантажити медичне зображення у одному з допустимих форматів, після чого запустили процес аналізу цього зображення. Програмне забезпечення реалізоване мовою Python 3.7.

Запропонований ансамбль методів, що базується на застосуванні згорткової штучної нейронної мережі, структура якої було описано в розділі 2 даної роботи, у поєднанні з класичними методами текстурного аналізу демонструє свою ефективність в якості класифікатора завдяки покращенню показників точності класифікації в порівнянні з системою на основі методів радіоміки, що не використовує глибинне навчання як в класифікації серед усіх класів захворювань (зростання з 77% до 87%), так і в класифікації в підході «один проти всіх» або норма/захворювання (зростання з 85% до 92%).

ВИСНОВКИ

В ході виконання випускної кваліфікаційної роботи на здобуття освітнього ступеня “магістр” за спеціальність 122 “Комп’ютерні науки” розроблено програмну систему - класифікатор захворювань за ультразвуковими зображеннями печінки із застосуванням нейронних мереж та радіоміки. Класифікатор розроблено як програмний додаток з графічним інтерфейсом користувача і може у подальшому застосовуватися медичними працівниками для діагностики захворювань печінки. В ході роботи було досліджено можливість дистанційної діагностики захворювань печінки з використанням методів штучного інтелекту та радіоміки, що дозволяють на ранніх стадіях хвороби діагностувати та вчасно проводити лікування для уникнення розвитку таких важких форм хвороб печінки як цироз чи рак.

В процесі виконання роботи було реалізовано такі завдання:

1. Проведено літературний огляд предметної області та описано існуючі системи та методи, що використовуються для класифікації захворювань на основі медичних зображень.

2. Спроектовано модель класифікатора захворювань печінки людини на основі ансамблю методів радіоміки, класичних статистичних алгоритмів та згорткових глибинних штучних нейронних мереж застосованих до зображення ультразвукової діагностики печінки. Було продемонстровано вищий рівень точності класифікації в порівнянні з минулими результатами.

3. Розроблено програму реалізацію класифікатора захворювань за ультразвуковими зображеннями печінки із застосуванням нейронних мереж та радіоміки, що надає можливість вилучати атрибути текстурних статистик з бази зображень ультразвукової діагностики печінки пацієнтів, зберігати їх у формі таблиці та виконувати класифікацію захворювань печінки на нових даних. Аналіз результатів роботи розробленого програмного забезпечення на основі

запропонованого ансамблю методів показує, що результати класифікації серед усіх патологій співпадає з точним діагнозом у 87% (проти попередніх значень 77%), результат класифікації норма-патологія дає точність 92% (проти попередніх значень 85%).

ВИСНОВКИ

В ході виконання випускної кваліфікаційної роботи на здобуття освітнього ступеня “магістр” за спеціальність 122 “Комп’ютерні науки” розроблено програмну систему - класифікатор захворювань за ультразвуковими зображеннями печінки із застосуванням нейронних мереж та радіоміки. Класифікатор розроблено як програмний додаток з графічним інтерфейсом користувача і може у подальшому застосовуватися медичними працівниками для діагностики захворювань печінки. В ході роботи було досліджено можливість дистанційної діагностики захворювань печінки з використанням методів штучного інтелекту, що дозволяють на ранніх стадіях хвороби діагностувати та вчасно проводити лікування для уникнення розвитку таких важких форм хвороб печінки як цироз чи рак.

В процесі виконання роботи було реалізовано такі завдання:

1. Проведено літературний огляд предметної області та описано існуючі системи та методи, що використовуються для класифікації захворювань на основі медичних зображень.

2. Спроектовано модель класифікатора захворювань печінки людини на основі ансамблю методів радіоміки, класичних статистичних алгоритмів та згорткових глибинних штучних нейронних мереж застосованих до зображення ультразвукової діагностики печінки. Було продемонстровано вищий рівень точності класифікації в порівнянні з минулими результатами.

3. Розроблено програму реалізацію класифікатора захворювань за ультразвуковими зображеннями печінки із застосуванням нейронних мереж та радіоміки, що надає можливість вилучати атрибути текстурних статистик з бази зображень ультразвукової діагностики печінки пацієнтів, зберігати їх у формі таблиці та виконувати класифікацію захворювань печінки на нових даних. Аналіз результатів роботи розробленого програмного забезпечення на основі

запропонованого ансамблю методів показує, що результати класифікації серед усіх патологій співпадає з точним діагнозом у 87% (проти попередніх значень 77%), результат класифікації норма-патологія дає точність 92% (проти попередніх значень 85%).

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. World Health Organization. Global Hepatitis Report, 2017 / 2017.
2. Bataller, R., Brenner, D. a. Science in medicine - liver fibrosis. *Journal of Clinical Investigation*. 2005. Vol. 115, No. 2. С. 209–218.
3. Tchelepi, H., Ralls, P. W., Radin, R., та ін. Sonography of Diffuse. *Ultrasound*. 2002. Vol. 21, No. 9. С. 1023–1032.
4. Curley, S. A., Izzo, F., Ellis, L. M., та ін. Radiofrequency ablation of hepatocellular cancer in 110 patients with cirrhosis. *Annals of Surgery*. 2000. Vol. 232, No. 3. С. 381–391.
5. Materne, R., Smith, A. M., Peeters, F., та ін. Assessment of hepatic perfusion parameters with dynamic MRI. *Magnetic Resonance in Medicine*. 2002. Vol. 47, No. 1. С. 135–142.
6. Bushberg, J. T., Seibert, A., Leidholdt Jr., E. M., та ін. The Essential Physics of Medical Imaging , 2nd ed.: *American Journal of Roentgenology*. 2003. 596–596с.
7. Алешкевич, А. И., Рожковская, В. В., Сергеева, И. И., та ін. Основы и принципы лучевой диагностики.: Мінськ: Білоруський державний медичний університет, 2014. 86с.
8. Bohte, A. E., Werven, J. R. Van, Bipat, S., та ін. The diagnostic accuracy of US, CT, MRI and 1H-MRS for the evaluation of hepatic steatosis compared with liver biopsy: A meta-analysis. *European Radiology*. 2011. Vol. 21, No. 1. С. 87–97.
9. Lee, J., Jun, S., Cho, Y., та ін. Deep learning in medical imaging: general overview. *Korean Journal of Radiology*. 2017. Vol. 18, No. 4. С. 570–584.
10. Pesapane, F., Codari, M., Sardanelli, F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental*. 2018. Vol. 2, No. 1.
11. Yasaka, K., Akai, H., Kunimatsu, A., та ін. Liver fibrosis: Deep convolutional neural network for staging by using gadoxetic acid-enhanced hepatobiliary phase MR Images. *Radiology*. 2018. Vol. 287, No. 1. С. 146–155.
12. Yasaka, K., Akai, H., Kunimatsu, A., та ін. Deep learning for staging liver fibrosis on CT: a pilot study. *European Radiology*. 2018. Vol. 28, No. 11. С. 4578–4585.
13. Wang, K., Lu, X., Zhou, H., та ін. Deep learning radiomics of shear wave elastography significantly improved diagnostic performance for assessing liver fibrosis in chronic hepatitis B: A prospective multicentre study. *Gut*. 2019. Vol. 68, No. 4. С. 729–741.
14. Zhou, L. Q., Wang, J. Y., Yu, S. Y., та ін. Artificial intelligence in medical imaging

- of the liver. *World Journal of Gastroenterology*. 2019. Vol. 25, No. 6. C. 672–682.
15. Biswas, M., Kuppili, V., Edla, D. R., та ін. Syntosis: A liver ultrasound tissue characterization and risk stratification in optimized deep learning paradigm. *Computer Methods and Programs in Biomedicine*. 2018. Vol. 155. C. 165–177.
 16. Hassan, T. M., Elmogy, M., Sallam, E. S. Diagnosis of Focal Liver Diseases Based on Deep Learning Technique for Ultrasound Images. *Arabian Journal for Science and Engineering*. 2017. Vol. 42, No. 8. C. 3127–3140.
 17. Byra, M., Styczynski, G., Szmigielski, C., та ін. Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images. *International Journal of Computer Assisted Radiology and Surgery*. 2018. Vol. 13, No. 12. C. 1895–1903.
 18. Gatos, I., Tsantis, S., Spiliopoulos, S., та ін. A Machine-Learning Algorithm Toward Color Analysis for Chronic Liver Disease Classification, Employing Ultrasound Shear Wave Elastography. *Ultrasound in Medicine and Biology*. 2017. Vol. 43, No. 9. C. 1797–1810.
 19. Parekh, V., Jacobs, M. A. Radiomics: a new application from established techniques. *Expert Review of Precision Medicine and Drug Development*. 2016. Vol. 1, No. 2. C. 207–226.
 20. Nailon, W. H. Texture Analysis Methods for Medical Image Characterisation. *Intech*. 2016. Vol. i, No. tourism. C. 13.
 21. Yankovyi, I., Nastenکو, I. Classifier of the state of the liver in children with pathologies of the hepatobiliary system with textural statistics of ultrasound. *Biomedical Engineering and Technology*. 2019. No. 2. C. 15–23.
 22. Haralick, R. M., Shanmugam, K. S., Dinstein, I. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. 1973. C. 610–621.
 23. Haralick, R. M. Statistical and structural approaches to texture. *Proceedings of the IEEE*. 1979. Vol. 67, No. 5. C. 786–804.
 24. Galloway, M. M. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*. 1974. Vol. 4, No. 2. C. 172–179.
 25. Thibault, G., Fertil, B., Navarro, C., та ін. Texture Indexes and Gray Level Size Zone Matrix Application to Cell Nuclei Classification. *Pattern Recognition and Information Processing*. 2009. No. November. C. 140–145.
 26. Amadasun, M., King, R. Textural Features Corresponding to Textural Properties. *IEEE Transactions on Systems, Man and Cybernetics*. 1989. Vol. 19, No. 5. C. 1264–1274.
 27. Хвостиков, А. В., Крылов, А. С., Камалов, Ю. Р. Текстуриный анализ

- ультразвуковых изображений для диагностирования фиброза печени. ПРОГРАММИРОВАНИЕ. 2015. No. 5. С. 39–46.
28. Park, B. E., Jang, W. S., Yoo, S. K. Texture analysis of supraspinatus ultrasound image for computer aided diagnostic system. Healthcare Informatics Research. 2016. Vol. 22, No. 4. С. 299–304.
 29. Abd, H. S., Yassen, W., Alsaif, I. Feature Extraction of Images Texture Based on Co-occurrence Matrix. 2019.
 30. Carlson, J. Radiomics package: URL: https://github.com/joelcarlson/joelcarlson.github.io/blob/master/_posts/2015-7-10-radiomics-package.md(дата звернення: 01.04.21).
 31. Lambin, P. Radiomics Digital Phantom. Cancer Data. 2016.
 32. Kolossváry, M., Kellermayer, M., Merkely, B., та ін. Cardiac Computed Tomography Radiomics. Journal of Thoracic Imaging. 2018. Vol. 33, No. 1. С. 26–34.
 33. VanGriethuysen, J. J. M., Fedorov, A., Parmar, C., та ін. Computational Radiomics System to Decode the Radiographic Phenotype. Cancer Research. 2017. Vol. 77, No. 21. С. 104–107.
 34. Grus, J. Data Science from Scratch (2nd Edition). 2019. С. 409.
 35. Gorban, A. N., Zinovyev, A. Principal Manifolds and Graphs in Practice: From Molecular Biology To Dynamical Systems. International Journal of Neural Systems. 2010. Vol. 20, No. 03. С. 219–232.
 36. Wikipedia Agor153. Перша головна компонента максимізує вибірккову дисперсію проєкції даних: URL: https://ru.wikipedia.org/wiki/Метод_главных_компонент#/media/Файл:FirstPrincipalComponent.jpg.
 37. Rafiee, J., Rafiee, M. A., Prause, N., та ін. Wavelet basis functions in biomedical signal processing. Expert Systems with Applications. 2011. Vol. 38, No. 5. С. 6190–6201.
 38. Riznyk, O., Wikipedia Gufosowa. Схема k-кратного перехресного затвердження: .
 39. Samuel, A. L. Some Studies in Machine Learning Using the Game of Checkers. IBM Journal of Research and Development. 1959. Vol. 3, No. 3. С. 210–229.
 40. Rosenblatt, F. Principles of neurodynamics. Perceptrons and the theory of brain mechanisms.: Spartan Books, 1962.
 41. Riznyk, O. Artificial neural network with layer coloring (in Ukrainian): URL: https://commons.wikimedia.org/wiki/File:Colored_neural_network_uk.svgWikipedia.

42. Ciregan, D., Meier, U., Schmidhuber, J. Multi-column deep neural networks for image classification. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2012. С. 3642–3649.
43. LeCun, Y., Boser, B., Denker, J. S., та ін. Backpropagation Applied to Handwritten Zip Code Recognition. Neural Computation. 1989. Vol. 1, No. 4. С. 541–551.
44. Синеглазов, В., Чумаченко, О. Структурно-Параметричний Синтез Згорткових Нейронних Мереж: *ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ ТА КОМП'ЮТЕРНЕ МОДЕЛЮВАННЯ*, 18. С. 227–230.
45. Apx34. Typical CNN architecture: URL: https://en.wikipedia.org/wiki/Convolutional_neural_network#/media/File:Typical_cnn.pngWikipedia.
46. Li, Q., Cai, W., Wang, X., та ін. Medical image classification with convolutional neural network. 2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014. 2014. Vol. 2014, No. December. С. 844–848.
47. Yamashita, R., Nishio, M., Do, R. K. G., та ін. Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition. Smart Innovation, Systems and Technologies. 2018. Vol. 195. С. 21–30.
48. Brownlee, J. How To Improve Deep Learning Performance: URL: <https://machinelearningmastery.com/improve-deep-learning-performance/Deep-Learning-Performance>.
49. Арлоу, Д., Нейштадт, А. UML 2 и унифицированный процесс. Практический и объектно-ориентированный анализ и проектирование: 2007. 617с.
50. Вендров, А. М. CASE-технологии. Современные методы и средства проектирования информационных систем: 1998.