

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ ІМЕНІ ІГОРЯ СІКОРСЬКОГО»
МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ ІМЕНІ ІГОРЯ СІКОРСЬКОГО»
МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

Кваліфікаційна наукова
праця на правах рукопису

МАТВІЙЧУК ОЛЕКСАНДР ВАДИМОВИЧ

УДК 004.89:616-073.75

ДИСЕРТАЦІЯ
МЕТОДИ КЛАСИФІКАЦІЇ ФОРМ ТУБЕРКУЛЬОЗУ ЛЕГЕНЬ ЗА
ДАНИМИ КОМП'ЮТЕРНОЇ ТОМОГРАФІЇ НА ОСНОВІ АНСАМБЛЕВОЇ
СЕЛЕКЦІЇ ОЗНАК

122- Комп'ютерні науки
12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії.

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

_____ **Олександр МАТВІЙЧУК**

Науковий керівник: Настенко Євген Арнольдович, д. б. н., к. т. н., професор

Київ - 2025

АННОТАЦІЯ

Матвійчук О. В. Методи класифікації форм туберкульозу легень за даними комп'ютерної томографії на основі ансамблевої селекції ознак. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня (доктора філософії) за спеціальністю 122 «Комп'ютерні науки» (12 - Інформаційні технології). – Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», Київ, 2025.

Дисертаційна робота присвячена дослідженню даних комп'ютерної томографії легень у пацієнтів із туберкульозом легень та розробці методів диференціації лікарсько-чутливої та лікарсько-стійкої форми захворювання.

Туберкульоз легень є другою за поширеністю інфекційною хворобою у світі та призвів у 2023 році до 1,3 млн смертей. Ефективна рання діагностика відіграє ключову роль у своєчасному призначенні лікування, особливо у випадках розвитку стійкості до протитуберкульозних препаратів. Для виявлення туберкульозу легень використовуються різні методи діагностики, зокрема мікробіологічний, молекулярно-генетичний, радіологічний, імунологічний та біохімічний. Застосування комп'ютерної томографії як рентгенологічного методу дозволяє швидко отримати зображення легень, оцінити наявність та ступінь уражень. Аналіз даних з зображень томографії дає змогу визначити форму та місце ураження легень туберкульозом, що є важливим етапом для подальшої розробки ефективних алгоритмів діагностики та оптимізації лікування.

Проведено аналітичний огляд сучасних підходів до диференціації лікарсько-чутливої та лікарсько-стійкої туберкульозу із застосуванням методів машинного навчання. Розглянуто основні алгоритмічні підходи, включаючи використання штучних нейронних мереж, методів статистичного та текстурного аналізу, а також технологій сегментації для виділення зон інтересу на зображеннях комп'ютерної томографії.

За результатами проведеного огляду встановлено, що комп'ютерна томографія легень містить ключові візуальні ознаки, які можуть бути використані для автоматизованої диференціації форм туберкульозу. Методи машинного навчання, зокрема згорткові нейронні мережі, демонструють високу точність у розпізнаванні структурних змін та класифікації патологічних процесів, що робить їх перспективним інструментом у діагностичних системах.

Розглянуті сучасні методи мають проблеми з точністю класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу. Тому постає задача вдосконалення даних методів та технологій для збільшення точності діагностики, а також для підбору персоналізованої стратегії лікування.

Для підвищення точності класифікації додано попередню обробку томографічних даних із виділенням легеневого вікна та визначенням площі легень, що дозволяє усунути надлишкову інформативність. В алгоритмі сегментації враховано можливість появи непромаркованих пікселів у середині легень та їх корекцію шляхом приєднання до виділеної області.

Проведено дослідження з застосування методів текстурного аналізу для виділення ключових характеристик, що дозволяють більш точно ідентифікувати закономірності в структурі об'єктів на зображенні. Для отримання текстурних особливостей було застосовано різні типи матриць, зокрема – гістограма, матриця співвідношення рівнів сірого, матриця розміру зони рівнів сірого, матриця граничної довжини рівнів сірого. Перевагою використання матриць текстурних характеристик є збільшення інформативності отриманих даних за рахунок переходу від традиційного геометричного аналізу до оцінки текстури. Виділення настільки великої кількості ознак потребує механізму селекції інформативних ознак, для чого використано метод Minimum Redundancy Maximum Relevance.

Побудована модель та методика моделювання ознак надає можливість впорядкувати ознаки за інформативністю та сформувати ансамбль найбільш релевантних за яким побудовано класифікатор.

На основі сформованого ансамблю проведено дослідження, спрямоване на розробку класифікаційної моделі для визначення приналежності зображень до лікарсько-чутливого або лікарсько-стійкого класу. Для реалізації класифікаційного підходу застосовано метод випадкового лісу (Random Forest), який забезпечує високу стійкість до варіативності вхідних даних та знижує ризик перенавчання. Для підвищення точності класифікації розроблено модифіковану стратегію голосування в рамках ансамблю вирішальних правил. Відмінністю запропонованого підходу є адаптація стандартного алгоритму голосування шляхом введення вагових коефіцієнтів за допомогою методу групового урахування аргументів в комбінації з позиційним голосуванням, що дозволяє враховувати комплексні залежності між ознаками формуючи оптимізований ансамбль голосуючих моделей.

Проведено дослідження, спрямоване на навчання глибокої залишкової нейронної мережі ResNet-50 для вирішення задачі класифікації зображень. Архітектура ResNet-50 обрана через здатність формування ознак на глибоких шарах, та наявності Encoder-Decoder модифікацій, що зменшує проблему зникання градієнта завдяки використанню залишкових зв'язків. Окремо розглянуто підхід гібридизації глибокої залишкової мережі із застосуванням ознак отриманих мережею та класифікатором випадкового лісу. Застосування з модифікованою функцією голосування дозволяє отримати альтернативний набір ознак перед подачею їх на класифікатор випадкового лісу.

Метою роботи було удосконалення методів обчислювального інтелекту для збільшення точності класифікації лікарсько-чутливої та лікарсько-стійкої форм туберкульозу.

В дисертації отримані такі наукові результати:

- 1. Запропоновано** метод селекції ансамблів інформативних ознак, який відрізняється поєднанням одновимірною послідовного відбору за міжкласовою, внутрішньокласовою дисперсією та визначенням оптимального набору ознак за

критеріями інформативності та надмірності, що дозволяє зменшити обчислювальні ресурси та підвищити точність класифікації за даними великої розмірності.

2. Удосконалено метод прийняття рішень у колективах вирішувальних правил за рахунок додаткового впорядкування експертів по характеристиках компетентності на основі МГУА, що дозволяє модифікувати ваги в функції голосування для персоналізації рішень та підвищення точності класифікаторів з ансамблевою структурою

3. Вдосконалено метод визначення патологій на медичних зображеннях, в якому нейронна мережа з Encoder-Decoder архітектурою на основі ResNet50 для визначення зони патології доповнена оптимізованим ансамблевим класифікатором Random Forest, що надає можливість визначення класу патології за виокремленими Encoder частиною ознаками.

Ключові слова: Класифікація, клас-орієнтована селекція ознак, метод групового урахування аргументів, багатопотоковість, методи оптимізації, математична оптимізація, математична модель, математична статистика, нейронні мережі, глибинне навчання, згорткові нейронні мережі, ResNet, системи основані на правилах, інформаційні технології, програмне забезпечення.

ANNOTATION

Matviichuk O. V. Methods for pulmonary tuberculosis forms classification based on computed tomography data using ensemble feature selection. – Qualification of scientific work with the manuscript copyright.

Dissertation for the degree of Doctor of Philosophy in Specialty 122 "Computer Sciences" (12 - Information Technology). – National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", Kyiv, 2025.

The dissertation is dedicated to studying computed tomography lung data of patients with tuberculosis and developing methods for differentiating drug-sensitive and drug-resistant forms.

Pulmonary tuberculosis is the second most prevalent infectious disease worldwide, causing 1.3 million deaths in 2023. Effective early diagnosis plays a key role in timely treatment, particularly in cases of developing resistance to anti-tuberculosis drugs. Various diagnostic methods are used for tuberculosis detection, including microbiological, molecular-genetic, radiological, immunological, and biochemical approaches. The application of computed tomography as a radiological method allows for the rapid acquisition of lung images, assessment of the extent of lesions, and determination of their characteristics. Analysis of tomography image data enables the identification of the form and location of lung lesions, which is a crucial step in developing effective diagnostic algorithms and optimising treatment strategies.

An analytical review of modern approaches to differentiating drug-sensitive and drug-resistant tuberculosis using machine learning methods has been conducted. The study examines algorithmic approaches, including artificial neural networks, statistical and texture analysis methods, and segmentation technologies, for identifying regions of interest in computed tomography images.

Based on the review, CT lung images contain key visual features that can be utilised for automated differentiation of tuberculosis forms. Machine learning methods, particularly convolutional neural networks, demonstrate high efficiency in recognising structural changes and classifying pathological processes, making them a promising tool for diagnostic systems.

However, current methods have limitations in the accuracy of distinguishing drug-sensitive and drug-resistant tuberculosis. Therefore, enhancing these methods and technologies is necessary to improve diagnostic accuracy and develop personalised treatment strategies.

To improve classification accuracy, preprocessing of tomographic data was implemented, including lung window segmentation and lung area extraction, which eliminates redundant information. The segmentation algorithm accounts for the possible appearance of unmarked pixels inside the lungs and corrects them by reassigning them to the segmented region.

A study was conducted using texture analysis methods to extract key features that enable more precise identification of structural patterns in images. Various texture matrices were applied, including the histogram matrix, grey-level co-occurrence matrix (GLCM), grey-level size zone matrix (GLSZM), and grey-level dependence matrix (GLDM). The advantage of using texture-based features lies in enhancing data informativeness by shifting from traditional geometric analysis to texture-based feature extraction. Given the large number of extracted features, a feature selection mechanism was required, for which the Minimum Redundancy Maximum Relevance method was applied.

The developed feature modelling methodology enables the ranking of features by informativeness and the formation of an ensemble of the most relevant features for classifier construction.

A study was conducted to develop a classification model for determining the category of images as drug-sensitive or drug-resistant tuberculosis. The Random Forest method was applied as the classification approach, ensuring high resistance to input data variability and reducing overfitting risks. To improve classification accuracy, a modified voting strategy within the ensemble of decision rules was developed. The proposed approach differs from standard voting methods by incorporating the Group Method of Data Handling (GMDH) in combination with positional voting, allowing for the consideration of complex dependencies between features and forming an optimised ensemble of voting models.

A study was conducted aimed at training a deep residual neural network, ResNet-50, for solving the image classification problem. The ResNet-50 architecture was selected due to its ability to extract features in deep layers and the presence of Encoder-Decoder modifications, which mitigate the vanishing gradient problem through the use of residual connections. A hybrid approach was also considered, combining deep residual networks with feature extraction and classification using a Random Forest classifier. The application of a modified voting function enables the generation of an alternative feature set prior to input into the Random Forest classifier.

The aim of the work was to improve computational intelligence methods to enhance the accuracy of classification between drug-sensitive and drug-resistant forms of tuberculosis.

Scientific novelty of the obtained results:

A method for selecting ensembles of informative features was proposed. This method is distinguished by a combination of univariate sequential selection based on inter-class and intra-class dispersion, as well as the determination of an optimal feature set according to informativeness and redundancy criteria. This enables reduced computational resource usage and improved classification accuracy in high-dimensional data.

The decision-making method in ensembles of decision rules was improved by introducing additional expert ordering based on competence characteristics using MGUA (Modified Group Method of Data Handling). This allows the adjustment of weights in the voting function to personalize decisions and increase the accuracy of ensemble-based classifiers.

The method for detecting pathologies in medical images was improved. In this method, a neural network with an Encoder-Decoder architecture based on ResNet-50 is used to localize pathological regions. It is complemented by an optimized ensemble classifier (Random Forest), enabling the classification of pathology type based on features extracted by the Encoder.

Keywords: Classification, class-oriented feature selection, Group Method of Data Handling, multiprocessor computing, optimisation methods, mathematical optimisation,

mathematical model, mathematical statistics, neural networks, deep learning, convolutional neural networks, ResNet, rule-based systems, information technology, software development.

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Наукові праці, в яких опубліковані основні наукові результати дисертації

1. Nastenکو I, Maksymenko V, Potashev S, et al (2021) Random Forest algorithm construction for the diagnosis of coronary heart disease based on echocardiography video data streams. Innovative Biosystems and Bioengineering 5:61–69. doi: 10.20535/ibb.2021.5.1.225794. (Здобувачем досліджено клас алгоритмів класифікації випадковий ліс, та його застосування до медичних зображень).
2. Voronchuk N, Bovsunovska K, Davydko A, et al (2021) Segmentation of tuberculosis lungs on computer tomography images. Innovative Biosystems and Bioengineering 5:117–124. doi: 10.20535/ibb.2021.5.2.233051. (Здобувачем досліджено застосування нейронної мережі з згортковою архітектурою для диференціації ураження легень туберкульозом).
3. Давидько О, Матвійчук О (2023а) ПРОЦЕС ІДЕНТИФІКАЦІЇ УРАЖЕНЬ ЛЕГЕНІВ НА ЗНІМКАХ КОМП'ЮТЕРНОЇ ТОМОГРАФІЇ ПРИ covid-19. Біомедична інженерія і технологія 63–70. doi: 10.20535/2617-8974.2023.9.277490.(Здобувачем запропоновано програмну реалізацію модуля виділення легень, застосовано методи текстурного аналізу)
4. Матвійчук О, Настенко Є, (2023) Класифікація туберкульозних уражень легень методом позиційного голосування за даними комп'ютерної томографії. Біомедична інженерія і технологія 11. doi: 10.20535/2617-8974.2023.11.287885 (Здобувачем запропоновано програмну реалізацію модуля позиційного голосування, застосовано метод групового урахування аргументів для визначення структури па параметрів функції голосування).

Наукові праці, які засвідчують апробацію матеріалів дисертації

5. Matviichuk O, Nosovets O, Linnik M, et al (2021) Class-oriented features selection technology in medical images classification problem on the example of distinguishing between tuberculosis sensitive and resistant forms. 2021 IEEE 16th International Conference on Computer Sciences and Information Technologies (CSIT). doi: 10.1109/csit52700.2021.9648747.(ISSN: 2766-3639). (Здобувачем досліджено методи селекції ознак та запропоновано математичну модель технології клас-орієнтованої селекції ознак).
6. Babenko V, Nosovets O, Nastenka I, et al (2021) Forming the system with the functionality of clinical pharmacist for personalized treatment strategy searching. Proceedings of Sixth International Congress on Information and Communication Technology 503–512. doi: 10.1007/978-981-16-2377-6_47. (Здобувачем проаналізована розробка методів персоналізованої діагностики).
7. Matviichuk O, Biloshytska O, Horodetska O, et al (2022) Positional approach to the voting function formation of random forest trees as an example of solving the differentiating tuberculosis forms problem. 2022 IEEE 17th International Conference on Computer Sciences and Information Technologies (CSIT) 555–558. doi: 10.1109/csit56902.2022.10000450.(ISSN: 2766-3639) (Здобувачем досліджено методи голосування в класі алгоритмів випадковий ліс та застосовано метод позиційного голосування колективами вирішальних правил до задачі диференціації форми туберкульозного ураження легень).
8. Matviichuk O, Nastenka I, Pavlov V, (2023) Class-oriented selection of informative features in the problem of differential diagnosis of drug-resistant and drug-sensitive tuberculosis forms by CT images. СУЧАСНИЙ СТАН ТА ПЕРСПЕКТИВИ БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ 28-29. (Здобувачем застосовано розроблену технологію клас-орієнтованої селекції в задачі диференціації форми туберкульозу).

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	14
ВСТУП.....	15
РОЗДІЛ 1 ОГЛЯД СУЧАСНИХ ПІДХОДІВ ДО ЗАДАЧІ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ	20
1.1 Можливості радіометрії по виділенню ознак лікарсько-чутливого та лікарсько-стійкого туберкульозу	21
1.2 Методи виділення зони інтересу	23
1.3 Текстурні методи аналізу зображень	26
1.3.1 Виділення матриць текстурних характеристик.....	27
1.3.2 Аналіз матриць текстурних характеристик.....	33
1.4 Статистичні методи класифікації зображень	35
1.5 Нейромережеві методи класифікації зображень.....	39
1.5.1 Згорткові нейронні мережі.....	40
1.5.2 Рекурентні нейронні мережі	45
1.5.3 Нейронні мережі типу Encoder-Decoder	47
1.6 Ансамблеві класифікатори.....	52
Висновки до розділу 1	56
РОЗДІЛ 2 МАТЕРІАЛИ ТА МЕТОДИ ПОШУКУ ОЗНАК РОЗДІЛЬНОСТІ КЛАСІВ ЛІКАРСЬКО-ЧУТЛИВОГО ТА ЛІКАРСЬКО-СТІЙКОГО ТУБЕРКУЛЬОЗУ	57
2.1 Дані томографії легень	57
2.2 Виділення легень на зображеннях томографії	61
2.3 Виділення текстурних характеристик форми туберкульозу.....	63
2.4 Методи класифікації форми туберкульозу за текстурними характеристиками	73
Висновки до розділу 2.....	75
РОЗДІЛ 3 СТАТИСТИЧНА КЛАС-ОРІЄНТОВАНА СЕЛЕКЦІЯ ТЕКСТУРНИХ ОЗНАК.....	76
3.1 Формування вхідного простору ознак	76
3.2 Клас-орієнтована селекція	78
3.3 Підбір ансамблю ознак	85

3.4	Пришвидшення алгоритму фільтрації ознак паралелізацією	92
	Висновки до розділу 3	95
РОЗДІЛ 4 СТРУКТУРНА ОПТИМІЗАЦІЯ КЛАСИФІКАТОРА В КЛАСІ АЛГОРИТМІВ RANDOM FOREST		96
4.1	Вибір ансамблевого класифікатора	96
4.2	Модифікація структури класифікатора методом групового урахування аргументів	97
4.3	Застосування методу позиційного голосування до класифікатора Random Forest 100	
	Висновки до розділу 4	107
РОЗДІЛ 5 ДИФЕРЕНЦІАЦІЯ ЛІКАРСЬКО-ЧУТЛИВОЇ ТА ЛІКАРСЬКО- СТІЙКОЇ ФОРМИ ТУБЕРКУЛЬОЗУ НЕЙРОМЕРЕЖЕВИМИ МЕТОДАМИ ...		108
5.1	Глибока згорткова нейронна мережа ResNet-101	108
5.2	Гібридизовані нейронні мережі	111
5.2.1	Encoder-Decoder мережі	112
5.2.2	Гібридизований класифікатор з архітектурою ResNet-50 Autoencoder ...	114
5.3	Структурне порівняння розроблених інформаційних технологій	117
5.4	Практичне використання класифікатора	118
	Висновки до розділу 5	124
ВИСНОВКИ		125
СПИСОК ЛІТЕРАТУРНИХ ДЖЕРЕЛ		127
ДОДАТОК А СПИСОК ПУБЛІКАЦІЙ ТА ВІДОМОСТІ ПРО АПРОБАЦІЮ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЇ		139
ДОДАТОК Б АКТИ ВПРОВАДЖЕННЯ		141

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

ВООЗ – Всесвітня організація охорони здоров'я

ДУ – Державна установа

КТ – Комп'ютерна томографія

МГУА – Метод групового урахування аргументів (Group Method of Data Handling)

НН – Нейронна мережа

ШІ – Штучний інтелект

DICOM – Digital Imaging and Communications in Medicine

GLCM – Gray Level Co-occurrence Matrix

GLDM – Gray Level Dependence Matrix

GLRLM – Gray Level Run Length Matrix

GLSZM – Gray Level Size Zone Matrix

HU – Hounsfield Units

LSTM – Long Short-Term Memory

NIfTi – Neuroimaging Informatics Technology Initiative

NGTDM – Neighborhood Gray Tone Difference Matrix

RF – Random Forest

SVN – Support Vector Machine

ВСТУП

Актуальність теми дослідження. Туберкульоз легень залишається однією з найбільш поширених інфекційних хвороб у світі, що спричинила понад 1,3 мільйона летальних випадків у 2023 році [1]. Високий рівень захворюваності та смертності обумовлює необхідність ефективної ранньої діагностики та персоналізованого підходу до лікування. Сучасні методи діагностики включають молекулярно-генетичні тести, посіви культур збудника [2], імунологічні методи [3,4], аналіз біомаркерів [5] та радіологічні дослідження [6].

Серед радіологічних методів комп'ютерна томографія (КТ) є одним із найбільш інформативних, оскільки дозволяє отримати швидку, неінвазивну та детальну візуалізацію легневих уражень. Розвиток методів штучного інтелекту відкриває нові можливості для автоматизованої обробки КТ-зображень, що сприяє підвищенню точності діагностики. Використання глибоких згорткових нейронних мереж дозволяє виділяти зони інтересу, автоматизувати аналіз зображень та підвищувати точність класифікації форми туберкульозу [7,8]. Додатково, інтеграція КТ-зображень із клінічними даними пацієнтів покращує діагностичну точність [9]. Запропоновані на сьогодні методи аналізу медичних зображень демонструють точність класифікації до 92% у задачі диференціації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу [10].

У контексті сучасних тенденцій розвитку медичних інформаційних систем та автоматизованої діагностики важливою є розробка ефективних алгоритмів для аналізу КТ-зображень, що сприятиме зменшенню часу діагностики, підвищенню точності визначення форми захворювання та зниженню навантаження на лікарів. Одним із перспективних напрямів є поєднання методів глибокого навчання з текстурним аналізом та ансамблевими моделями, що дозволяє покращити якість класифікації та розширити можливості розпізнавання патологічних змін у легеневій тканині.

Таким чином, актуальність дослідження обумовлена необхідністю удосконалення методів діагностики туберкульозу шляхом автоматизації обробки

КТ-знімків, покращення алгоритмів класифікації та впровадження інтелектуальних систем підтримки прийняття рішень у сфері фтизіатрії. Впровадження сучасних підходів машинного навчання сприятиме створенню автоматизованих діагностичних систем, що можуть бути інтегровані в клінічну практику, забезпечуючи швидшу та точнішу диференціацію форм туберкульозу та підвищуючи ефективність контролю над його поширенням.

Зв'язок роботи з науковими програмами, планами, темами.

Наукову роботу виконано на кафедрі біомедичної кібернетики Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського» у рамках співпраці з ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф. Г. Яновського НАМН України» акт впровадження від 15 листопада 2022 року.

Мета і завдання дослідження. Метою дисертаційної роботи було удосконалення методів обчислювального інтелекту для збільшення точності класифікації лікарсько-чутливої та лікарсько-стійкої форм туберкульозу.

Для досягнення поставленої мети необхідно було вирішити наступні **завдання:**

1. На основі літературних джерел проаналізувати технології отримання та аналізу медичних зображень.
2. Дослідити можливість застосування методів текстурного аналізу до зображень комп'ютерної томографії легень.
3. Дослідити механізм селекціонування інформативних ознак для зменшення розмірності даних.
4. Дослідити алгоритм голосування на основі колективу вирішувальних правил в класифікаторах ансамблевої структури для можливості підвищення точності вирішення задачі класифікації.
5. Дослідити можливість застосування нейромережових та гібридизованих класифікаторів для диференціації форми туберкульозу.

Об'єкт дослідження – процес розв'язання задачі класифікації на прикладі КТ-зображень легень пацієнтів хворих на лікарсько-стійку та лікарсько-чутливу форму туберкульозу.

Предмет дослідження – методи штучного інтелекту для аналізу КТ-зображень представлені текстурним аналізом, випадковим лісом та штучними нейронними мережами та способи їх гібридизації.

Методи дослідження

Дослідження проводилось з застосуванням методів текстурного аналізу зображень, статистичного аналізу даних та нейронних мереж в задачах класифікації.

Наукова новизна отриманих результатів:

- 1. Запропоновано** метод селекції ансамблів інформативних ознак, який відрізняється поєднанням одновимірною послідовного відбору за міжкласовою, внутрішньокласовою дисперсією та визначенням оптимального набору ознак за критеріями інформативності та надмірності, що дозволяє зменшити обчислювальні ресурси та підвищити точність класифікації за даними великої розмірності.
- 2. Удосконалено** метод прийняття рішень у колективах вирішувальних правил за рахунок додаткового впорядкування експертів по характеристиках компетентності на основі МГУА, що дозволяє модифікувати ваги в функції голосування для персоналізації рішень та підвищення точності класифікаторів з ансамблевою структурою
- 3. Вдосконалено** метод визначення патологій на медичних зображеннях, в якому нейронна мережа з Encoder-Decoder архітектурою на основі ResNet50 для визначення зони патології доповнена оптимізованим ансамблевим класифікатором Random Forest, що надає можливість визначення класу патології за виокремленими Encoder частиною ознаками.

Практичне значення одержаних результатів

За результатами проведених досліджень розроблено інформаційну систему класифікації зображень комп'ютерної томографії легень пацієнтів хворих на лікарсько-стійку та лікарсько-чутливу форму туберкульозу. Розроблено клас-орієнтовану технології селекції ознак класів за даними отриманими з текстурного аналізу. Визначено спосіб гібридизації нейронної мережі за допомогою класифікатора з мережевою структурою.

Результати роботи впроваджено в ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф. Г. Яновського НАМН України» акт впровадження від 15 листопада 2022 року.

Особистий внесок здобувача.

Сформульовано мету та постановку завдань дослідження, розроблено методи та способи досягнення поставленої мети. Проведено аналіз сучасного стану застосування методів штучного інтелекту до задачі диференціації форми захворювання на туберкульоз легень. Застосовано статистичний та нейромережевий підходи для успішного вирішення завдання дослідження. Побудовано статистичні моделі та проаналізовано можливості програмної реалізації алгоритмів, проведено експерименти на даних комп'ютерної томографії легень, проаналізовано та узагальнено результати досліджень.

Загальний дизайн дослідження, статистичну та алгоритмічну постановку завдань дослідження, розробку моделей та технічних рішень виконано у співпраці з д.б.н., к.т.н., Настенко Є. А.

Апробація результатів дисертації.

Матеріали дисертаційної роботи доповідались та були обговорені на наступній науково-практичній конференції:

- «СУЧАСНИЙ СТАН ТА ПЕРСПЕКТИВИ БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ(Україна, Київ, 2022р.)».

Включено до міжнародної наукометричної бази Scopus матеріали опубліковані на наступних конференціях:

- 2021 IEEE 16th International Conference on Computer Sciences and Information Technologies (CSIT)(Україна, Львів, 2021р.)
- Proceedings of Sixth International Congress on Information and Communication Technology(Велика Британія, Лондон, 2021р.),
- 2022 IEEE 17th International Conference on Computer Sciences and Information Technologies (CSIT)(Україна, Львів, 2022р.)

Публікації.

Результати дисертаційної роботи опубліковані в 4 наукових працях, з яких 2 статті у наукових фахових виданнях України категорії Б за спеціальністю 122 – комп’ютерні науки, у 2 що включені до міжнародної наукометричної бази даних Scopus.

Структура і обсяг дисертації.

Дисертаційна робота складається зі вступу, 5 розділів, висновків, списку літературних джерел. Загальний обсяг роботи складає 140 сторінок. Обсяг основного тексту становить 112 сторінок. Робота містить 6 таблиць і 78 рисунків. Список літературних джерел складається з 105 найменувань на 12 сторінках.

РОЗДІЛ 1 ОГЛЯД СУЧАСНИХ ПІДХОДІВ ДО ЗАДАЧІ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ

Значне поширення туберкульозу легень та висока смертність від його резистентної форми зумовлюють необхідність пошуку інноваційних підходів до діагностики та класифікації захворювання. Одним із сучасних напрямів розвитку є застосування алгоритмів машинного навчання для аналізу КТ-зображень, що значно підвищує швидкість та точність діагностики. До ключових тенденцій у цій сфері можна віднести використання текстурних методів аналізу зображень, глибоких нейронних мереж у розпізнаванні туберкульозу за рентгенографічними та томографічними зображеннями. Використання таких алгоритмів дозволяє автоматизувати локалізацію уражених зон та підвищити якість класифікації зображень перед передачею їх для лікаря.

Окремої уваги заслуговують біологічні методи виявлення туберкульозу, як включають молекулярно-генетичні тести, посіви культур збудника [2], імунологічні методи [3,4], аналіз біомаркерів. Хоча ці методи є важливими для визначення наявності збудника туберкульозу, вони не дозволяють оцінити ступінь ураження легень, що є критичним для підбору стратегії лікування хвороби.

Саме тому розвиток сучасних методів діагностики туберкульозу базується на інтеграції математичного моделювання, алгоритмів штучного інтелекту та передових біотехнологій, що забезпечує високу чутливість та специфічність. Методи глибокого навчання дають можливість підвищити точність класифікації до 92%, що підтверджує ефективність їх застосування у медичних задачах [10].

Автоматизовані методи діагностики ТБ поступово стають невід'ємною частиною сучасної фтизіатрії, поєднуючи результати фундаментальних досліджень та клінічної практики. Основна увага приділяється розробці оптимальних алгоритмів аналізу КТ-зображень та створенню інтелектуальних систем підтримки прийняття рішень, що дозволить не лише підвищити точність діагностики, але й зробити її доступнішою у регіонах із високим рівнем захворюваності.

Метою цього аналітичного огляду є узагальнення сучасних методів автоматизованого аналізу медичних зображень для діагностики туберкульозу, оцінка їх ефективності та перспективи подальшого розвитку у сфері медичних інформаційних технологій.

1.1 Можливості радіометрії по виділенню ознак лікарсько-чутливого та лікарсько-стійкого туберкульозу

Комп'ютерна томографія дозволяє отримувати детальні зображення внутрішніх структур організму, використовуючи рентгенівське випромінювання. Процес перетворення фізичних частин тіла на цифрові КТ-зображення включає кілька ключових етапів, які забезпечують точність і якість отримання даних. Серед етапів виділяють[12] рентгенівське сканування для отримання вхідних даних, обчислення коефіцієнтів ослаблення та реконструкцію зображень.

Сканування відбувається коли пацієнт розміщується в апараті, де рентгенівська трубка обертається навколо тіла, випромінюючи вузький пучок рентгенівських променів. Промені проходять через тканини організму та частково поглинаються в залежності від їх щільності. Таким чином на зображеннях формуються наступні класи об'єктів:

- Кістки
- М'які тканини
- Повітря

Виділення кісток можливе, оскільки вони є об'єктами високої щільності, тобто вони поглинають більше рентгенівського випромінювання ніж всі інші типи тканин, залишаючи для детектора менше променів. М'які тканини є об'єктами середньої щільності, вони поглинають частину променів, формуючи проміжні рівні сигналу. Об'єктами низької щільності є гази, наприкладі повітря. Такі речовини не поглинають випромінювання завдяки своїй структурі, таким чином на детектор приходить найсильніший сигнал.

Детектори КТ-апарата реєструють рівень залишкового випромінювання після проходження через тіло, створюючи сирі проекційні дані, які в подальшому в процесі математичної обробки перетворюються на дані зображень.

Отримавши сирі дані відбувається обчислення коефіцієнтів та реконструкція зображення[13]. В процесі реконструкції дані ослаблень проходять через алгоритми фільтрацій та згладжування. Після чого відбувається математичне масштабування даних зображення в шкалу Хаунсфілда. Зображення приведені до даної шкали є нормалізованим і може бути використаним для подальшого аналізу лікарем, або автоматичною системою.

Після отримання зображень КТ, їх приводять до вікна досліджуваного органу[14], що в процесі аналізу дозволяє отримати та врахувати ознаки лише певних елементів організму, наприклад лише кістки, або кістки та м'які тканини.

Для більш детального аналізу органів виділяють спеціальні вікна. Дані вікна містять налаштування контрастності та яскравості КТ зображень, які дозволяють оптимально візуалізувати певний орган або тканину. Вони ґрунтуються на коригуванні діапазону шкали Хаунсфілда (HU) відповідно до щільності структур. Таким чином для аналізу легневих уражень використовують легеневе вікно[15]. Центр даного вікна в $[-600; -700]$ HU (Hounsfield unit), та ширина в $[1000; 1500]$ HU, що дозволяє переглядати паренхіму легень, бронхи та дрібні дихальні шляхи, кровоносні судини, інфільтрати, фіброзну та рубцеву тканину.

Виділення саме цих елементів забезпечує чітку візуалізацію повітряних структур у легенях, допомагає відрізнити інфільтрати, набряки та фіброз від нормальної паренхіми. Подальший аналіз зображень отриманих з даним вікном дозволяє виділяти ознаки різних хвороб легень, в тому числі туберкульозу та його форм[7, 16-18].

Нормалізація та приведення до вікна відбувається за формулою(1.1) [19].

$$I_{windowed} = \max\left(\min\left(\frac{I_{HU} - C}{W} + 0.5, 1\right), 0\right) \quad (1.1)$$

Де $I_{windowed}$ – нормалізоване значення інтенсивності в діапазоні $[0, 1]$, W – ширина вікна, C – Центр вікна, I_{HU} – вихідне значення у шкалі Хаунсфілда, \min – функція вибору мінімального значення, \max – функція вибору максимального значення.

1.2 Методи виділення зони інтересу

Відбір легеневого вікна для дослідження дозволяє відкинути з дослідження дані тканин та кісток, які не мають впливу на легеневі процеси. Однак через те що форма легень досить специфічна віконна фільтрація дозволяє захопити нелегеневі структури в зону дослідження, що в подальшому може призвести до вибору зовнішніх ознак, наприклад наявність медичних засобів на тілі, замість легневих ознак[20].

Для виділення зони інтересу на ображенні можна застосувати наступні методи:

- Ручне виділення (виділення експертом)
- Порогова сегментація
- Метод активних контурів
- Регіональне зростання
- Застосування нейронних мереж.

Застосування ручного виділення, де фахівець вручну обирає зону інтересу на зображенні можливе в дослідженнях, де більшість аналізу залишається за самим експертом. Даний метод в застосуванні до розпізнаванню туберкульозу має високу точність, однак потребує дуже великих затрат експерта (лікаря) для проведення такого виділення.

Порогова сегментація як метод дозволяє зробити виділення зони інтересу за рівнем інтенсивності пікселів, виходячи з певного порогу. Даний метод

застосовується для аналізу зображень та відіграє в них важливу роль. Розрізняють методи Bi-level порогу[21] та Multi-level[22] порогу для виділення області. Результат застосування даних методів зображено на рис. 1.1.



Рис. 1.1. Приклад застосування методів порогової сегментації: А – оригінальне зображення, Б – застосування бінарного порогу (Bi-Level), В – застосування багаторівневого порогу (Multi-level)

Метод активних контурів застосовується для визначення меж об'єктів на зображеннях[23-26]. Особливістю даного методу є здатність зберігати топологію області інтересу, що робить його придатним для різних сфер, особливо для сегментації та візуалізації медичних зображень. Для вирішення даної задачі метод може використовувати підхід з побудови контурів, що базуються на краях(Edge-Based models)[27], або ж взяти за основу область та коригувати контур під неї[28].




Рис. 1.2. Застосування методу активних контурів виділення зони інтересу в суглобі[26]

Метод регіонального зростання (Region Growing)[29] є одним із підходів до сегментації зображень, який базується на поступовому розширенні області, починаючи з початкової точки (seed point). Алгоритм додає до зони інтересу сусідні пікселі, якщо вони задовольняють певний критерій подібності, мають схожу інтенсивність або текстуру. Однією з переваг цього підходу є його здатність точно виділяти об'єкти з чіткими межами, але він може бути чутливим до шуму. Приклад застосування методу регіонального зростання зображено на рис. 1.3.




Рис. 1.3. Приклад застосування методу регіонального зростання. А – оригінальне зображення, Б – виділений контур

Оскільки виділення зони інтересу на зображенні є задачею сегментації, для її вирішення можна застосувати нейромереві підходи. Таким чином нейронна мережа навчається виділяти зону певного об'єкта. На базі таких мереж можливе подальше навчання мережі як класифікатора за допомогою використання додаткових шарів в структурі мережі. Також дані мережі можуть інтегрувати механізми уваги для фокусування на найбільш значущих ділянках зображення. Для виділення легень існують розроблені нейронні мережі на архітектурі U-net, які з точністю в 96%[30] вирішують задачу сегментації зображення легень. Приклад класифікації нормалізованого зображення КТ-легень нейронною мережею за архітектурою U-net(R321) зображено на рис. 1.4.[30].




Рис. 1.4. Приклад застосування нейронної мережі[14] для сегментації легень

1.3 Текстурні методи аналізу зображень

Текстурний аналіз є важливою технікою в обробці зображень, що дозволяє кількісно оцінювати варіації інтенсивності та патерни в зображеннях. Він має широке застосування в галузі медичної візуалізації, допомагаючи автоматизувати процеси розпізнавання та класифікації текстурних особливостей[31]. Текстурний аналіз може відбуватись за рахунок статистичних, перетворювальних, моделювальних або ж нейромережових методів.

Статистичні методи текстурного аналізу аналізують взаємозв'язки між пікселями та використовують метрики оцінки текстури. Прикладом статистичних методів можуть бути матриця співвідношень рівнів сірого[32], яка може виділяти такі ключові особливості як: контрастність, гомогенність.

Перетворювальні методи в процесі аналізу розкладають зображення на частотні компоненти, що дозволяє оцінити локальні та глобальні тенденції в текстурі. Прикладом таких методів може бути застосування вейвлет перетворень в процесі аналізу[31].

Моделювальні методи створюють математичні моделі для представлення текстур. Даний тип методів зазвичай використовується в комбінації з статистичними методами в задачах генеративного моделювання текстур.

Нейромережіві методи аналізу текстур базуються на основі глибоких нейронних мереж, таких як AlexNet, або ж GoogleNet. Дані мережі на початкових шарах своєї архітектури досить ефективно виділяють характеристики текстур, та можуть застосовуватись для їх класифікації[33].

1.3.1 Виділення матриць текстурних характеристик

Обрахунок текстури з зображення дозволяє збільшити його інформативність за рахунок переходу від геометричних характеристик з положенням пікселя, до структурних характеристик. Таким чином текстурний аналіз зображень відіграє ключову роль у визначенні особливостей зображення шляхом кількісної оцінки просторового розподілу інтенсивності пікселів, або значення їх кольорів.

Для аналізу та виділення текстури можна застосовувати одновимірні аналітичні методи, зокрема гістограмний аналіз зображення [34]. Цей підхід забезпечує графічне представлення розподілу інтенсивності пікселів зображень на рис. 1.5., що є важливим для оцінки яскравості та контрасту зображення. На основі гістограмми можливе використання еквалізації, яка сприяє покращенню контрастності шляхом більш рівномірного розподілу інтенсивностей та підвищує деталізацію зображення. Алгоритм еквалізації подібний до процесу виділення легеневого вікна, оскільки обидва методи зменшують діапазон значень, у межах якого нормалізується зображення, що сприяє кращій візуалізації важливих структур.




Рис. 1.5. Приклад гістограми зображення

Двовимірними методами аналізу текстури є застосування матриць текстурних характеристик, таких як:

- **GLCM** – Gray Level Co-occurrence Matrix [32]
- **GLRLM** – Gray Level Run Length Matrix [35]
- **GLSZM** – Gray Level Size Zone Matrix [36]
- **NGTDM** – Neighborhood Gray Tone Difference Matrix [36]
- **GLDM** – Gray level dependence Matrix [37]

Матриця співвідношень рівнів сірого (GLCM) використовується для визначення ймовірності появи певних пар рівнів сірого на певній відстані та напрямку в зображенні. Даний метод дозволяє оцінити імовірність появи певної комбінації яскравостей у сусідніх пікселях. В якості параметрів алгоритму побудови даної матриці є відстань на якій оцінюється сусідство пікселів та кут нахилу. Застосування різного кута нахилу дозволяє будувати текстурну матрицю з горизонтальних, вертикальних та проміжних комбінацій яскравості. Приклад розрахунку горизонтальної(0°) та під кутом 45° матриці GLCM зображено на рис. 1.6.




Рис. 1.6. Приклад розрахунку матриці GLCM для кута повороту 0° та 45°

Матриця довжин послідовностей рівня сірого (GLRLM) використовується для текстурного аналізу та виділяє закономірності на основі наявності послідовності пікселів однакової яскравості. Також дана матриця може бути побудована з певним кутом, через що розширення зони послідовності пікселів буде відбуватись у вказаному напрямку. Приклад побудови горизонтальної матриці GLRLM зображено на рис. 1.7. Як відображено на рисунку група пікселів однакової яскравості (3) об'єдналась в матричне значення 1, записане в комірку значення – 3, та комірку довжини 3. Значення пари (1,1), яке зустрічається 2 рази записано в комірку з значенням 1 та комірку довжини 2. Побудована матриця текстурних характеристик дозволяє проаналізувати наявність зон однакової інтенсивності, що є важливим при пошуку контурів та зон з однаковими показниками яскравості пікселів.

4	1	4	2	2
3	3	3	2	2
4	2	4	1	1
4	1	3	3	4
1	1	4	4	2

		Length			
		1	2	3	4
Voxel value	1	2	2	0	0
	2	2	2	0	0
	3	0	2	1	0
	4	6	1	0	0

GLRLM (horizontal)

Рис. 1.7. Приклад розрахунку матриці GLRLM

Окрім аналізу наявних послідовностей існує можливість аналізу зон з однаковою яскравістю на зображенні. Для такого роду аналізу застосовують матрицю розмірів зон сірого (GLSZM). Даний метод дозволяє аналізувати зображення шляхом оцінки розподілу зон однакової яскравості, та сформувати дані про зв'язність та розмір зон. Об'єднання зон однакової яскравості при побудові даної матриці можливе по горизонталі, вертикалі та діагоналі. Такий спосіб виділення зони дозволяє оцінити розміри об'єктів однакової яскравості. Приклад побудови GLSZM матриці відображено на рис. 1.8. Як відображено на рисунку зеленим кольором виділено зону з чотирьох 2, які об'єднались в один об'єкт і записані у відповідну комірку з значенням 1, де Voxel Value – 2 та Zone Size 4.



Рис. 1.8. Приклад побудови матриці GLSZM

Матриця відмінності рівнів сірого в локальному оточенні (NGTDM) використовується для оцінки на скільки інтенсивність кожного пікселя відрізняється від середнього значення його сусідів. Даний метод дозволяє визначити гладкість, контрастність та зернистість структури зображення. Приклад розрахунку даної матриці відображений на рис. 1.9. Дані на рисунку розмальовані для розгляду вікна в 1 сусідній піксель. Розрахунки для кожного з окремих пікселів виконані власними кольорами.

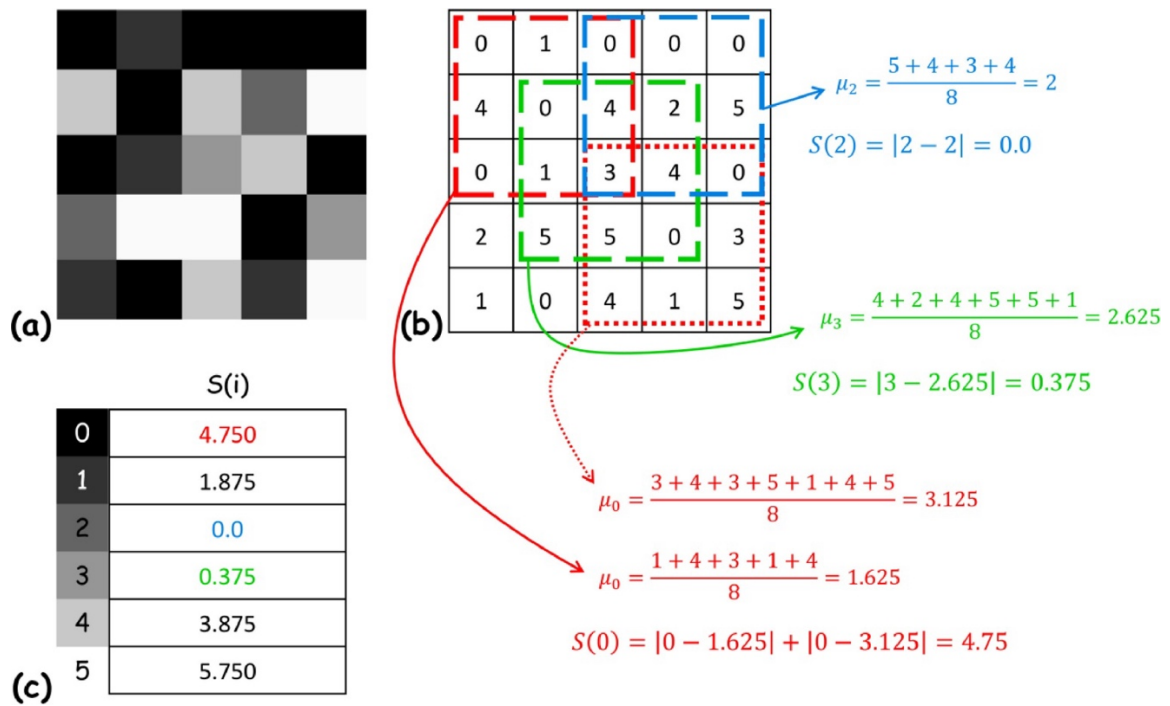


Рис. 1.9. Приклад розрахунку матриці NGTDM: А - Оригінальне зображення, В - розрахунки значень для пікселів, С - заповнення результуючої матриці розрахунками з кроку В

Матриця залежності рівнів сірого (GLDM) використовується для оцінки залежності між рівнями сірого, що дозволяє оцінити неоднорідності структури. Даний алгоритм оцінює залежності враховуючи кількість сусідів з аналогічним рівнем інтенсивності. Візуалізація на рис. 1.10 демонструє процес формування матриці залежностей.




Рис. 1.10. Приклад розрахунку матриці GLDM: А - Оригінальне зображення, В – результуюча матриця [38]

1.3.2 Аналіз матриць текстурних характеристик

Матриці текстурних характеристик забезпечують глибший, точніший та більш структурований аналіз зображень, ніж традиційний аналіз піксельних значень. Вони ґрунтуються на статистичних моделях розподілу інтенсивностей пікселів у певному локальному або глобальному контексті. Одними з найефективніших реалізацій цього підходу є побудова та аналіз матриць текстурних характеристик[23], які забезпечують глибоку, багатовимірну інтерпретацію структурної організації зображення, переважаючи традиційні піксель-орієнтовані методи як за точністю, так і за узагальненістю результатів.

До найбільш поширених типів таких матриць належать:

- GLCM
- GLRLM
- GLSZM
- NGTDM
- GLDM

Зазначені матриці формують основу для обчислення широкого спектра дескрипторів, що характеризують властивості текстури, зокрема її однорідність, контрастність, направленість, ступінь ентропії. Застосування текстурних матриць має наступні переваги в контексті застосування у завданнях класифікації, сегментації та розпізнавання образів.

- Висока дискримінаційна здатність
- Інваріантність до геометричних трансформацій
- Підтримка тривимірного аналізу
- Адаптивність і зменшення розмірності
- Покращення ефективності класифікаційних алгоритмів

Висока дискримінаційна здатність матриць текстурних характеристик дозволяє формувати вектор ознак із високою роздільною здатністю щодо

міжкласових відмінностей. Застосовуючи ознаки типу контрасту, ентропії, енергії, кореляції, інерційності, а також мір гомогенності метод дає змогу чітко ідентифікувати локальні текстурні неоднорідності, що є ключовим чинником у задачі класифікації. Дослідження[23] підтверджують, що ці дескриптори демонструють високу чутливість до навіть незначних варіацій у структурі об'єктів, що має особливу практичну цінність у медичній діагностиці та аналізі тканин[23].

Інваріантність до геометричних трансформацій є однією з важливих властивостей текстурного підходу. Забезпечуючи його стійкість до геометричних варіацій, таких як поворот, масштабування або зміщення об'єктів на зображенні. Завдяки агрегації статистичних залежностей між пікселями на визначеній відстані під різними напрямками (наприклад, 0° , 45° , 90° , 135°) формується узагальнений опис текстури, незалежний від абсолютної просторової прив'язки. Застосування методів нормалізації та обчислення інваріантних ознак (зокрема, на основі спектрального аналізу або сингулярного розкладу матриць) дозволяє досягати високої стійкості до трансформацій, що особливо актуально у випадках зміну кута перспективи.

Підтримка тривимірного аналізу матрицями текстурних характеристик дозволяє обробляти дані томографії, оскільки набір зображень пацієнта також є тривимірним. 3D-GLCM, 3D-GLRLM та інші аналогічні структури забезпечують формування просторових дескрипторів, що враховують кореляції у трьох вимірах (X, Y, Z). Це дозволяє враховувати просторову глибину об'єктів і їхню внутрішню морфологію.

Адаптивність і зменшення розмірності даних оптимізує застосування обчислювальних ресурсів та є важливим фактором дозволяючи контрольовано зменшити розмірності текстурного простору без втрати інформативності. Це досягається шляхом попереднього квантування рівнів сірого, застосування адаптивних вікон до регіонів інтересу (ROI), а також використання методів відбору ознак (наприклад, PCA, LDA, wrapper-фільтраційних методів). Завдяки цьому

суттєво зменшується обсяг обчислень і підвищується ефективність подальших алгоритмів машинного навчання, зберігаючи при цьому релевантність ознак.

Покращення ефективності класифікаційних алгоритмів стає можливим завдяки застосуванню ансамблю текстурних ознак, сформованого на основі зазначень матриць. Ансамбль ознак є джерелом вхідної інформації для широкого спектра алгоритмів класифікації: Random Forest, SVM, KNN, логістична регресія, а також глибокі нейронні мережі. У випадку обмеженої кількості навчальних даних або наявності шуму в зображеннях, використання текстурних дескрипторів підвищує узагальнюючі здатності моделей, забезпечує зменшення ризику перенавчання та підвищує показники точності, чутливості та специфічності[23].

Таким чином, використання матриць текстурних характеристик як інструменту формалізованого опису структури зображення дозволяє суттєво покращити якість виявлення та розпізнавання об'єктів. Їхня висока дискримінаційна здатність, інваріантність до трансформацій, можливість тривимірного моделювання, адаптивність та ефективна інтеграція з алгоритмами машинного навчання роблять цей підхід незамінним у широкому спектрі прикладних задач, зокрема медичній діагностиці.

1.4 Статистичні методи класифікації зображень

Статистичні методи класифікації є ключовими інструментами в аналізі зображень, оскільки дозволяють автоматично розпізнавати, сегментувати та класифікувати об'єкти на основі їхніх статистичних характеристик. Вони базуються на ймовірнісних підходах, розподілах ознак та математичних моделях, що дозволяють знаходити зв'язки між вхідними даними (піксельні або текстурні ознаки) та відповідними класами зображень. На сьогодні можна виділити наступні групи статистичних методів класифікації:

- Байєсівські класифікатори
- Нечіткі класифікатори
- Ансамблеві класифікатори

- Статистичні класифікатори

Байєсівські класифікатори застосовують для класифікації зображень завдяки ймовірнісному підходу та ефективності в роботі з великими наборами даних. Вони базуються на теоремі Байєса, що дозволяє приймати рішення на основі оцінки апостеріорної ймовірності для кожного класу. До даної групи відносяться наступні реалізації класифікаторів:

- Наївний Байєсів класифікатор (Naive Bayes Classifier) – класифікує використовуючи апостеріорні ймовірності, завдяки чому відзначається швидким навчанням та конкурентною точністю в порівнянні з іншими класифікаторами[40].
- Квантові байєсівські класифікатори – вдосконалена версія класифікатора, що застосовує принципи квантових обчислень та вирішує завдання шляхом виділення локальних особливостей зображень[41].
- Мережеві байєсівські класифікатори – модифікація базового класифікатора орієнтована на аналіз взаємної інформації про об'єкти та визначення залежностей між атрибутами. Прикладами алгоритмів даної групи є деревоподібно розширений класифікатор TANC та лісоподібно розширений класифікатор FANC[42].
- Байєсівський класифікатор на основі локальних парних спостережень. Даний варіант класифікатора зосереджується на ключових регіонах та особливих точках в зображенні. При роботі методу формується гістограма Bag Of Features для опису дискримінативних парних локальних спостережень, які потім застосовуються для навчання моделей класів об'єктів[43].

Нечіткі класифікатори базуються на нечіткій логіці, яка дозволяє моделювати невизначеність та неповну інформацію у класифікаційних задачах. На відміну від традиційних методів, що використовують чіткі границі між класами, нечіткі класифікатори дозволяють елементам належати до кількох класів одночасно з певним ступенем належності. Це особливо корисно для класифікації зображень із розмитими або перекриваючими класами, таких як біомедичні зображення або природні сцени. Основні методи включають Fuzzy K-Nearest

Neighbour[44], нечіткі дерева рішень[45], нечіткі байєсівські моделі та нейромережі з нечіткими правилами.

Ансамблеві класифікатори базуються на використанні кількох навчених алгоритмів з метою покращення передбачуваної ефективності. Такі класифікатори складаються з скінченної множини альтернативних моделей, що дозволяє досягти більшої гнучкості моделі та збільшити точність класифікації.

Прикладом Ансамблевого класифікатора є Random Forest(RF). Даний класифікатор широко застосовується для класифікації зображень завдяки стійкості до шуму та здатності працювати з великими наборами даних. Метод заснований на побудові множини дерев рішень, кожне з яких проводить незалежну класифікацію, а остаточний клас визначається шляхом голосування між деревами. Схематична робота класифікатора зображена на рис. 1.11.




Рис. 1.11. Структурна схема класифікатора Random Forest[46]

Завдяки побудові множини дерев рішень за зменшеним набором ознак в кожному з них та голосуванню деревами, RF мінімізує ризик перенавчання, що є важливою перевагою порівняно з окремими деревами рішень. Метод добре працює з зображеннями високої роздільної здатності, забезпечуючи ефективний аналіз

навіть за наявності незначущих або корельованих ознак. Такий результат досягається завдяки використанню випадкового відбору підмножини ознак при побудові дерев. RF підтримує мультикласову класифікацію та демонструє низьку чутливість до вибору гіперпараметрів, що спрощує його навчання та використання. Застосування регуляризації в випадковому лісі дозволяє запобігти перенавчанню моделі. Основні методи регуляризації включають в себе обмеження глибини дерев, мінімальну кількість зразків для формування точки поділу (вузла) в дереві. Дані параметри зменшують кількість даних про які знає кожне з дерев, зменшуючи варіативність моделі та підвищуючи її узагальнюючу здатність.

Статистичні класифікатори, зокрема регресійні, широко застосовуються в класифікації зображень завдяки здатності моделювати залежності між ознаками та класами. Вони можуть бути реалізовані з високою паралелізацією обчислень, а також підтримують процес регуляризації для уникання перенавчання та роботи з високорозмірними даними.

Логістична регресія є одним із найпоширеніших прикладів статистичного класифікатора, що застосовує ймовірнісну модель для визначення належності об'єкта до певного класу. Вона підтримує бінарну та мультикласову класифікацію, а також регуляризацію (L_1 , L_2). Результат логістичної регресії може бути покращений відбором релевантних ознак та застосуванням регуляризації. Даний класифікатор може аналізувати структурну інформацію в даних за допомогою тензорних модифікацій[47]. Приклад формування лінійного та логістичного регресора зображено на рис. 1.12.




Рис. 1.12. Приклад застосування регресійної функції: А – Лінійної, Б – логістичної[48]

Регресія є гнучким інструментом для класифікації текстур зображень, здатним вирішувати такі завдання, як інваріантність до обертання та масштабування. Дозволяючи працювати у високорозмірних просторах ознак і забезпечуючи надійне статистичне моделювання. Завдяки використанню різноманітних характеристик та методів перетворення зображень, логістична регресія може бути оптимізована для досягнення високої точності класифікації у широкому діапазоні застосувань аналізу текстур.

1.5 Нейромережеві методи класифікації зображень

Нейронні мережі є потужним інструментом аналізу даних, який не обмежується класифікацією зображень, однак в розрізі задачі аналізу зображень вони демонструють конкурентні результати в порівнянні з іншими класифікаторами. В порівнянні з статистичними класифікаторами нейромережеві вміють автоматично визначати, аналізувати та узагальнювати ознаки.

Автоматичне визначення ознак у нейронних мережах працює без необхідності ручного налаштування, що дозволяє моделі самостійно виділяти важливі характеристики під час навчання. Це забезпечує високу точність

класифікації зображень, а також стійкість до шуму, розмиття та змін яскравості завдяки згортковим шарам і механізму нормалізації. Крім того, нейромережі можуть розпізнавати об'єкти незалежно від їхнього положення, обертання чи масштабу, що робить їх більш ефективними, ніж традиційні методи обробки зображень.

Глибокі нейронні мережі здатні обробляти великі обсяги даних, що є особливо важливим для медичної діагностики. Проте вони мають і певні недоліки. Велика кількість параметрів (від мільйонів до мільярдів) вимагає значних обчислювальних ресурсів. Також для ефективного функціонування нейромережі потребують великих, збалансованих і якісних наборів даних, а їхній дефіцит може призводити до перенавчання (overfitting), тоді модель добре працюватиме на навчальних даних, але не узагальнюватиме нові зразки.

Ще однією проблемою є низька інтерпретованість рішень, оскільки нейронні мережі діють як "чорна скринька", що ускладнює пояснення їхньої логіки. Це особливо критично для медичних досліджень, де необхідна прозорість у прийнятті рішень. Для пояснення рішення існують методи по типу Grad-Cam, але їх застосування ускладнює роботу мережі та збільшує необхідну кількість ресурсів необхідних для роботи мережі. Також нейромережі можуть бути вразливими до атак на основі змінених зображень, коли штучно внесені незначні зміни вводять систему в оману, змушуючи її класифікувати об'єкти неправильно.

1.5.1 Згорткові нейронні мережі

Згорткові нейронні мережі активно використовуються в медичній діагностиці, оскільки дозволяють із високою точністю виявляти патології на рентгенівських, КТ та МРТ-знімках. Вони навчаються отримувати ключові ознаки, такі як аномальні тканини, пухлини, крововиливи та інші патологічні зміни, що дає змогу покращити раннє виявлення захворювань. Однією з основних переваг є висока точність і швидкість аналізу, що допомагає лікарям приймати обґрунтовані клінічні рішення. Приклад структури згорткової мережі зображено на рис. 1.13.

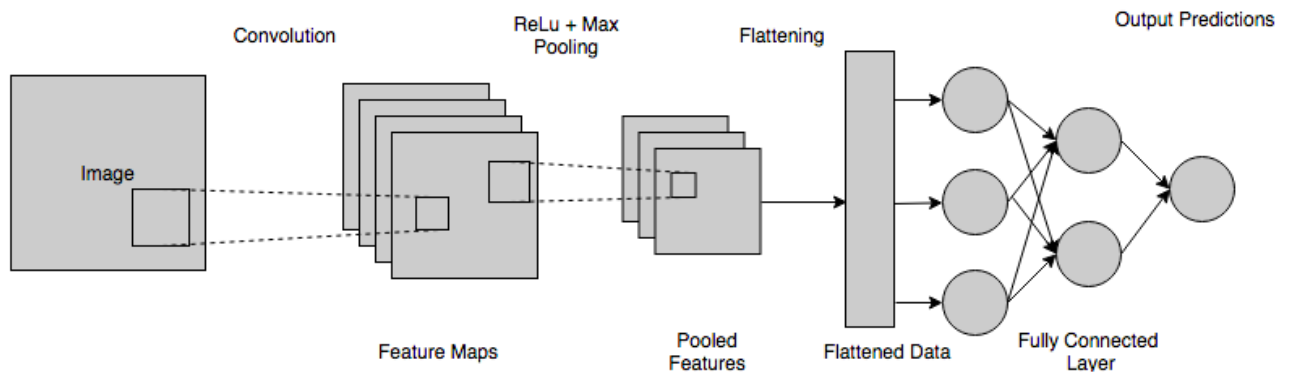


Рис. 1.13. Приклад архітектури згорткової мережі[49]

Згорткові мережі складаються з наступних компонентів:

- Згорткові шари (Convolutional layers)
- Функції активації (Activation functions)
- Рівень об'єднання (Pooling Layers)
- Повнозв'язний шар (Fully Connected Layers)

Згорткові шари є основними компонентами даного типу нейронних мереж і відповідають за автоматичне виділення ознак з вхідних зображень. Вони працюють шляхом застосування фільтрів, що ковзають по зображенню та виявляють локальні патерни, як зображено на рис. 1.14.

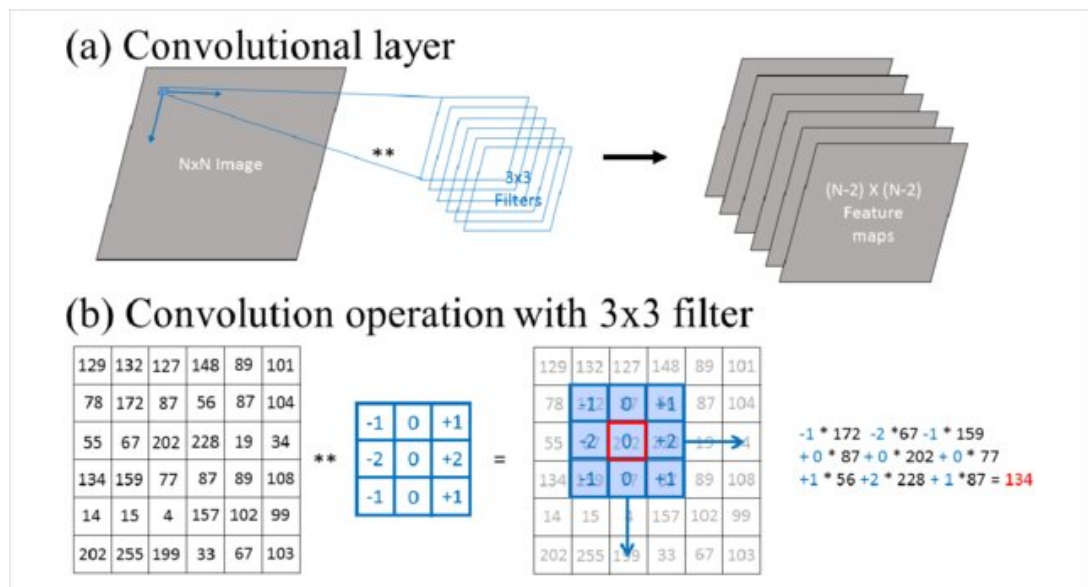


Рис. 1.14. А - Опис згорткового шару нейронної мережі, б - операція згортки[50]

Застосування таких шарів на ранніх етапах обробки зображення в мережі дозволяє виділяти такі структури як контури, структури та градієнти яскравості. На більш пізніх етапах карта ознак може вміщувати більш складні ознаки об'єкта. Комбінування елементарних ознак дозволяє отримати та аналізувати більш складні патерни, як форми, частини об'єктів на пізніших шарах. Основні параметри згорткових шарів включають:

- розмір ядра (наприклад, 3×3 або 5×5);
- крок(stride), який визначає, з яким зміщенням рухається фільтр по зображенню;
- заповнення (padding), яке додає пікселі навколо меж зображення та впливає на розмір вихідного зображення[51];

Функції активації — це математичні перетворення, що застосовується до вихідного значення нейрона[52]. Вони відіграють критичну роль у здатності мережі моделювати складні функціональні залежності між вхідними та вихідними даними. Без цієї нелінійності мережа діяла б як звичайна лінійна регресія, незалежно від кількості її шарів.

Активаційна функція визначає, чи слід активувати нейрон, обчислюючи зважену суму вхідних значень і додаючи зміщення. Це дозволяє моделі робити складніші прогнози та ухвалювати більш точні рішення, забезпечуючи нелінійність вихідних сигналів нейронів. Для активації зазвичай застосовують функції графік яких представлено на рис. 1.15. Кожна з функцій має свої переваги та недоліки в залежності від задачі в якій відбувається її застосування.

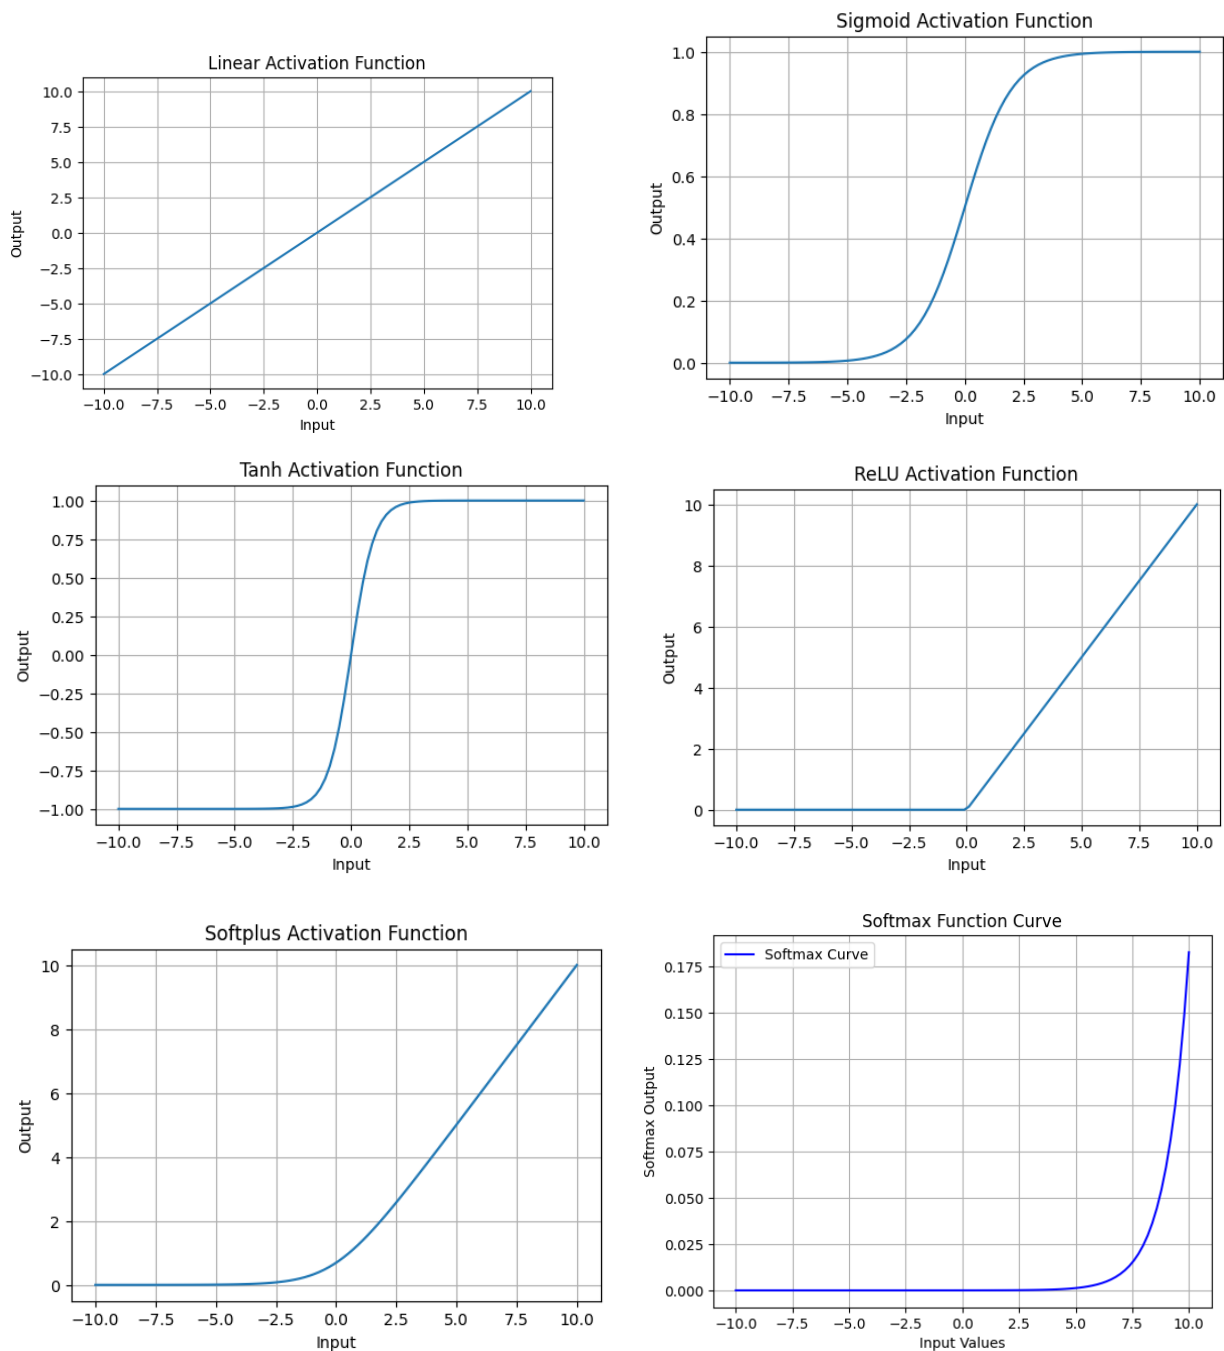


Рис. 1.15. Графічне представлення функцій активації: Linear, Sigmoid, Tanh, Relu, Softplus, Softmax[53]

Функція лінійної активації передає вихід у тому ж вигляді, в якому він був отриманий, без будь-яких змін. Вона використовується в завданнях регресії, де вихід може приймати будь-яке значення. Однак у глибоких нейронних мережах лінійна функція неефективна, оскільки не вводить нелінійності, що унеможливорює навчання складних залежностей[54].

Сигмоїдна функція активації стискає вхідні значення до діапазону $(0,1)$. Вона добре підходить для задач, де потрібно передбачити ймовірність. Однак має проблему зникнення градієнта, що ускладнює навчання глибоких мереж. Тому при високих або низьких значеннях аргументу градієнт стає дуже малим, що сповільнює оновлення ваг. Через ці обмеження вона поступово замінюється іншими функціями активації[54].

Гіперболічний тангенс схожий на сигмоїд, але має перевагу у вигляді центрованого нуля, що робить його більш ефективним у рекурентних нейронних мережах. Дана функція активації також страждає від проблеми зникнення градієнта. Через це вона використовується переважно в специфічних задачах[55].

ReLU залишає позитивні значення незмінними, а для негативних повертає 0. Вона є однією з найпоширеніших функцій активації в глибоких нейронних мережах завдяки своїй простоті та ефективності у прискоренні навчання. Однак ReLU має проблему «мертвих нейронів», коли градієнт стає нульовим для негативних значень, що зупиняє навчання деяких нейронів. Незважаючи на цей недолік, вона залишається основним вибором для багатьох моделей[52].

Softplus є згладженим варіантом ReLU. На відміну від ReLU, Softplus забезпечує ненульовий градієнт навіть для негативних значень, що дозволяє уникнути проблеми «мертвих нейронів». Проте обчислення Softplus є складнішим у порівнянні з ReLU, що може впливати на швидкість навчання. Завдяки своїм властивостям вона іноді використовується у спеціалізованих архітектурах[54].

Softmax — це узагальнення сигмоїдної функції для багатокласової класифікації. Вона перетворює вхідний вектор на набір ймовірностей, сума яких дорівнює 1, що робить її ідеальною для класифікаційних задач. Softmax підкреслює найбільші значення у вхідному векторі, роблячи впевненість моделі більш вираженою. Однак вона чутлива до великих значень у входах, що може призводити до нестабільності навчання, тому часто використовується разом із нормалізацією вхідних даних[52].

В задачі класифікації зображень легень згорткові нейронні мережі є потужним інструментом досягаючи точності класифікації 98%[56, 57].

1.5.2 Рекурентні нейронні мережі

Рекурентні нейронні мережі є важливим інструментом глибинного навчання для аналізу даних, що мають послідовну або структуровану природу. Завдяки своїй здатності запам'ятовувати попередні вхідні стани через зворотні зв'язки, ці мережі дозволяють моделювати контекст, що є особливо важливим у задачах, де ізольовані фрагменти даних недостатні для повноцінної інтерпретації. У випадку комп'ютерного аналізу рентгенографічних та томографічних зображень легень, особливо при діагностиці туберкульозу, RNN дозволяють виявляти просторово-послідовні патерни, які можуть не бути очевидними при традиційному підході на основі згорткових нейронних мереж.

Комп'ютерні томограми легень демонструють складні структури, що включають альвеолярні зміни, фіброзні ділянки, каверни та інші прояви туберкульозного ураження. У таких випадках поєднання CNN та RNN стає особливо актуальним, оскільки згорткова мережа добре виділяє локальні ознаки, такі як границі об'єктів, текстура, структура тканин. Рекурентна мережа у свою чергу, обробляє послідовність ознак із кількох зрізів або з різних регіонів зображення, що дозволяє виявляти глобальні патерни поширення патології.

Одним з прикладів сучасної реалізації такого підходу є Multi-path x-D Recurrent Neural Network[58], яка використовує кілька паралельних рекурентних блоків для аналізу внутрішньокласової варіації патологічних проявів. Це дозволяє моделі фокусуватися як на локальних, так і на дифузних змінах легень, характерних для різних стадій туберкульозу. Дана мережа дозволяє визначати зону первинного ураження, посттуберкульозні зміни та зону вторинного ураження.

Особливе місце серед RNN займає архітектура LSTM (Long Short-Term Memory), що була розроблена для подолання проблеми затухаючих градієнтів в довгих послідовностях. LSTM використовує спеціальні комірки пам'яті та

механізми керування для вибіркового збереження або відкидання інформації з попередніх кроків. Це робить її надзвичайно ефективною у медичних задачах, де необхідно враховувати не лише локальну інформацію, а й контекстуальні зв'язки між різними ділянками зображення або зрізами КТ.

У задачах виявлення туберкульозу, LSTM дозволяє моделювати поширення ураження в динаміці по зрізах при розгляді серії зображень, або по площі зображення при аналізі виділених регіонів на зображенні, що надає моделі глибшого розуміння розподілу патологічних змін.

Перевагами застосування LSTM в задачі виділення туберкульозних уражень[59]:

- Збереження клінічно значущого контексту між ділянками легеневої тканини.
- Гнучкість у роботі з нерегулярними структурами, що характерні для фіброзно-кавернозного туберкульозу.
- Підвищена стабільність і узагальнення моделей при обробці гетерогенних даних пацієнтів із різною формою та стадією хвороби.

У реальних сценаріях застосування, LSTM-мережі демонструють[60] здатність до точного виявлення туберкульозних уражень навіть у тих випадках, коли вони частково маскуються фоновими змінами (старими рубцями, кальцифікатами). Це забезпечує вищу діагностичну чутливість у порівнянні з класичними згортковими архітектурами.

Структурні відмінності між згортковими та рекурентними архітектурами представлені на рис. 1.16. У структурі RNN кожен вузол має зворотний зв'язок, який дозволяє йому впливати на обчислення наступного стану, зберігаючи внутрішню пам'ять. У CNN, навпаки, зв'язки є лише однонаправленими, що обмежує модель в урахуванні послідовних залежностей.

Ця архітектурна різниця є ключовою в контексті аналізу медичних зображень, де взаємозв'язки між ділянками легень можуть мати не лише морфологічну, але й просторову та функціональну послідовність.




Рис. 1.16. Відмінність структури рекурентної мережі (а) від мережі з прямою передачею сигналу (б)

У сфері медичної візуалізації рекурентні нейронні мережі використовуються для покращення класифікаційних завдань за рахунок виявлення прихованих особливостей та взаємозв'язків між патологічними станами. Застосування даних мереж задачі класифікації шкірних уражень або ж легневих вузлів допомагають аналізувати послідовні та структуровані залежності між зображеннями без необхідності ручної сегментації. Це дозволяє уникнути трудомісткого попереднього аналізу та підвищує загальну точність діагностики та допомагає автоматизувати діагностичні процеси.

1.5.3 Нейронні мережі типу Encoder-Decoder

Мережі Encoder-Decoder набули популярності у задачах класифікації зображень завдяки їхній здатності працювати із зображеннями довільних розмірів

та виконувати класифікацію всього зображення без необхідності обробки окремих фрагментів. Такі мережі дозволяють ефективно кодувати вхідну інформацію у стислий контекстуальний вектор та використовувати його для генерування або аналізу вихідних даних. Даний принцип виявився надзвичайно корисним для автоматизованого аналізу медичних зображень, зокрема в задачах, де важлива глобальна узагальнена інтерпретація з локальною деталізацією — наприклад, при розпізнаванні легневих патологій.

У традиційному варіанті архітектура складається з двох компонентів:

- Енкодер, що кодує вхідні дані у стислий прихований стан;
- Декодер, який реконструює вихід на основі отриманого прихованого стану.

Такий підхід дозволяє реалізовувати сегментацію, генерацію або класифікацію зображень без потреби ручної сегментації або обробки фрагментів. У медичних застосуваннях ця властивість є критично важливою, оскільки дозволяє автоматично охопити зображення цілком, водночас фокусуючись на патологічних ділянках.

Зокрема, у класифікації рентгенограм легень, мережі типу Encoder–Decoder застосовуються для виявлення морфологічних змін, характерних для туберкульозу, таких як фіброзні тяжі, каверни, ділянки інфільтрації або кальциновані вузли. Стиснене представлення дозволяє зберігати інваріантність до розміру та локалізації аномалій, а механізм уваги — ідентифікувати релевантні зони з високою точністю[61]. Також в мережі зберігається інформація про глобальний контекст з детальними просторовими характеристиками за допомогою використання механізму уваги. Структурна схема Encoder-Decoder архітектури зображена на рис. 1.17.




Рис. 1.17. Архітектура Encoder-Decoder мережі[61]

З появою моделі Transformer[62] відбулося концептуальне переосмислення архітектури Encoder–Decoder. На відміну від рекурентних або згорткових мереж, трансформери використовують лише механізм багатоголової уваги (Multi-Head Self-Attention) для моделювання залежностей у даних. Це дозволяє досягати повної паралелізації обчислень, покращувати масштабованість та зберігати довготривалі залежності у вхідних даних.

Структурно трансформер також поділяється на енкодер і декодер, проте в ньому:

- кожен шар енкодера містить блок багатоголової самоуваги та позиційно-нормовану трансформацію;
- декодер додатково отримує інформацію від енкодера через механізм крос-уваги, що дозволяє узгоджувати вхідну та вихідну послідовності.

У порівнянні з класичними моделями, трансформери виявляють такі переваги:

1. Глобальна самоувага — кожен піксель (або патч) потенційно взаємодіє з усіма іншими, що дозволяє виявляти віддалені кореляції між аномаліями.

2. Відсутність локальних обмежень — на відміну від CNN, трансформер не обмежений розміром фільтра, що дозволяє краще моделювати великі патологічні області.

3. Гнучкість щодо форми вхідних даних — можлива робота з зображеннями різних розмірів та форматів без перекроювання даних.

4. Контекстуальна сегментація та класифікація — трансформер одночасно фокусує увагу як на дрібних, так і на глобальних структурах.

Vision Transformer є розвитком трансформерів, він перетворює зображення на послідовність векторів, кожен з яких відповідає окремому патчу зображення (наприклад, 16×16 пікселів). Кожен патч подається в Encoder трансформера з доданим позиційним вектором, який зберігає інформацію про просторову локалізацію. Така зміна в задачі аналізу зображень дає можливість:

- виділяти структурні патерни ураження незалежно від місця їх локалізації;
- використовувати попередньо навчені моделі для покращення класифікації навіть при обмеженій кількості медичних даних;
- уникати втрати просторових характеристик, як це іноді відбувається у CNN при великій глибині.

Ключовою відмінністю трансформерів від Encoder-Decoder є багатоголовий механізм уваги (Multi-Head Attention), який паралельно обчислює кілька незалежних “уважних” представлень і потім об’єднує їх. Такий обрахунок дозволяє мережі більш детально:

- виявляти різні типи патернів на одному і тому самому зображенні;
- моделювати як локальні, так і глобальні залежності;
- підвищити стійкість до шуму або неповноти даних, що часто трапляється в медичних наборах.

У Vision transformer архітектурах механізм уваги дозволяє одночасно враховувати:

- текстурні особливості фіброзних ділянок.
- геометричні контури каверн.
- симетричність легеневих полів.
- відмінності між активними й посттуберкульозними змінами.

Структурна схема Vision transformer з механізмом уваги зображено на рис. 1.18.

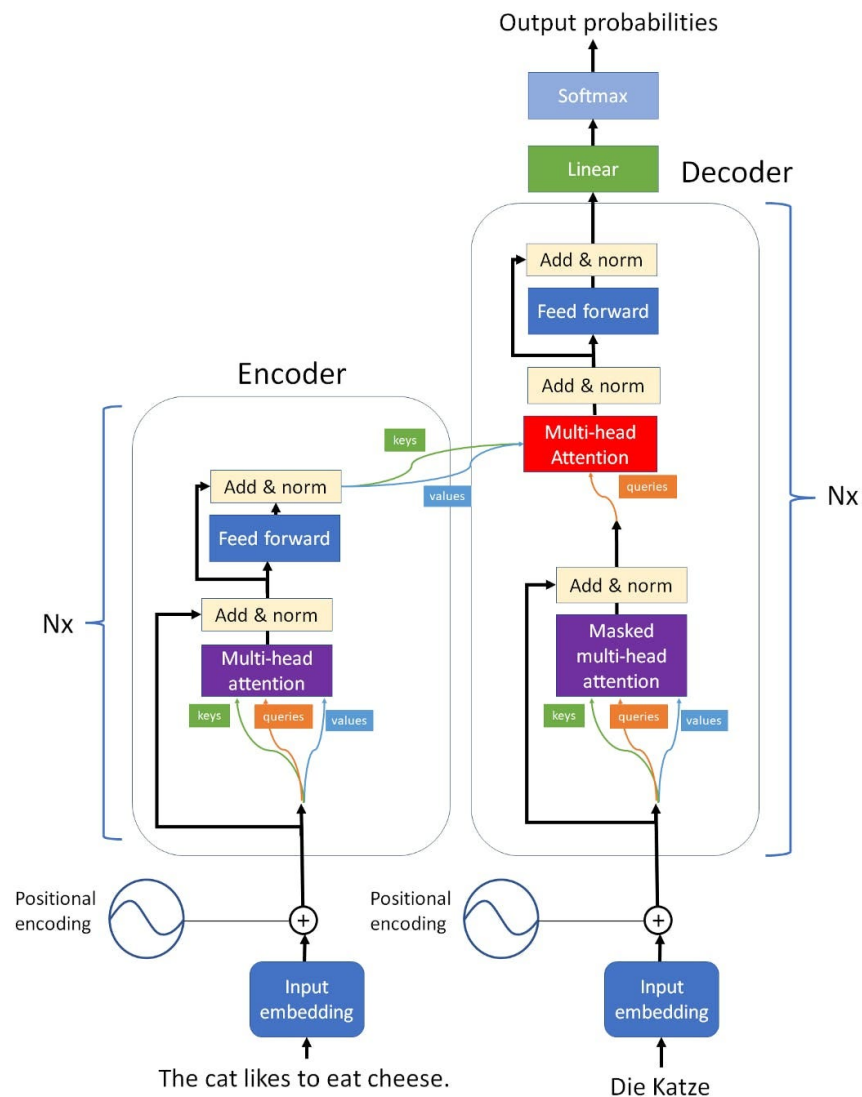


Рис. 1.18. Структура мережі Vision transformer з застосуванням механізму уваги[63]

Еволюція архітектури Encoder–Decoder до трансформерних моделей, зокрема Vision Transformer та його модифікацій, суттєво розширила можливості класифікації медичних зображень.

1.6 Ансамблеві класифікатори

Ансамблеві класифікатори знаходять широке застосування в задачах класифікації, оскільки базуються на ідеї поєднання декількох класифікаторів з метою покращення узагальнюючої здатності моделі, підвищення точності та стійкості до шумових спотворень у даних. Завдяки використанню різнорідних моделей або незалежних підмножин даних, ансамблеві класифікатори здатні компенсувати слабкі сторони окремих моделей, що суттєво підвищує ефективність у задачах розпізнавання складних патернів, зокрема на медичних зображеннях.

Ансамблева система класифікації зазвичай включає три основні етапи: формування підмножин даних, побудову окремих моделей та інтеграцію їх результатів. Загальна схема ансамблевого класифікатора наведена на рис. 1.19.




Рис. 1.19. Схема ансамблевого класифікатора[64].

На першому етапі (етап відбору) здійснюється розподіл вихідного набору даних на кілька підмножин, які можуть формуватися:

- випадковим чином (метод bagging).
- із зваженою послідовністю прикладів (метод boosting).
- шляхом крос-валідації.

Такий розподіл забезпечує варіативність вхідних даних, що критично важливо для уникнення перенавчання та підвищення стійкості моделі.

На другому етапі (етап побудови) для кожної підмножини застосовується окремий класифікатор. Ці моделі можуть бути як однотипними (гомогенними), так і різнорідними (гетерогенними). До гомогенних належать ансамблі на основі одного алгоритму, наприклад, дерев рішень (Random Forest), а до гетерогенних — комбінації різних моделей: нейронних мереж, методів опорних векторів (SVM), логістичної регресії.

Завершальним етапом (етап інтеграції) є об'єднання результатів класифікаторів у єдину відповідь. Найчастіше для побудови відповіді застосовуються такі стратегії:

- метод голосування більшості (majority voting), де клас з найбільшою кількістю "голосів" класифікаторів вважається фінальним результатом.
- зважене голосування, де кожен класифікатор має певну вагу залежно від точності або довіри.
- стекінг (stacking) — навчання метамоделі на виходах базових класифікаторів для остаточного прийняття рішення.

Як продемонстровано на рис. 1.19 схема обробки даних ускладнюється наявністю додаткових методів класифікації та етапу голосування. Класифікатори в такому підході можуть застосовуватись як статистичні так і нейромережеві. Збільшення їх кількості вимагає додаткових ресурсів для розрахунку, однак

наявність декількох класифікаторів дозволяє на етапі голосування комбінувати їх голоси та точніше визначати результуючий клас.

Ансамблеві моделі вирізняються низкою переваг, зокрема:

- Підвищенням класифікаційної точності, зниження помилок другого та першого роду;
- Зменшенням варіативності результатів при повторному навчанні або використанні нових даних.
- Стійкістю до перенавчання, особливо у випадках з невеликим обсягом даних.
- Гнучкістю у виборі моделей, що дозволяє поєднувати алгоритми різної природи.

У задачах автоматизованого аналізу рентгенологічних зображень легень, зокрема для виявлення туберкульозних змін, ансамблеві класифікатори застосовуються для підвищення чутливості та специфічності моделей. Наприклад, окремі CNN-моделі, натреновані на різних проекціях або зображеннях різної якості, можуть бути поєднані в ансамбль, де мета-класифікатор приймає остаточне рішення з урахуванням результатів усіх базових моделей. Застосування такого підходу дозволяє виявляти слабко виражені фіброзні чи посттуберкульозні зміни, враховувати симетричність або асиметрію уражень, мінімізувати вплив шуму, артефактів або помилок маркування у навчальній вибірці.

Попри перелічені переваги, ансамблеві моделі мають і низку обмежень, а саме:

- Високу обчислювальну складність: навчання кількох класифікаторів потребує більше ресурсів CPU/GPU, пам'яті та часу.

- Потребу в оптимізації: кожен компонент ансамблю потребує налаштування гіперпараметрів, балансування вибірки, узгодження форматів вихідних прогнозів.
- Ускладнення інтерпретації: чим складніша модель, тим важче обґрунтувати її рішення.

Тим не менш, при належному проектуванні та валідації ансамблеві класифікатори дозволяють досягати вищих показників точності, ніж будь-який окремий класифікатор. Вони є важливим напрямом розвитку інтелектуальних систем аналізу зображень. Завдяки можливості інтегрувати прогнози кількох класифікаторів, вони забезпечують вищу надійність та стабільність рішень, особливо в умовах обмежених або зашумлених даних. Їх застосування в задачах діагностики туберкульозу легень дозволяє створювати високоточні автоматизовані системи, які можуть ефективно доповнювати клінічну експертизу та пришвидшувати процес прийняття рішень.

Висновки до розділу 1

На основі проведеного аналізу визначено, що перспективним є застосування методів текстурного аналізу КТ зображень для визначення лікарсько-чутливої та лікарсько-стійкої форми туберкульозу легень. Для подібних досліджень все частіше застосовуються нейронні мережі, які автоматизують процес відбору ознак і в подальшому застосовуються для навчання класифікаторів.

Також активно розробляються методи аналізу зображень томографії, які можуть класифікувати ступінь ураження легень та локалізувати його місцезнаходження.

Застосування статистичних методів для аналізу дозволяє визначити та переглянути набір критеріїв, за якими відбулось прийняття рішення. Нейронні мережі для даних задач без додаткових технік аналізу власні рішення не обґрунтовують.

Розробка технологій статистичного та нейромережевого аналізу зображень в системах прийняття медичних рішень потребують подальшого аналізу.

Формування простору вхідних ознак за матрицями текстурних характеристик в класифікаційних системах сприяє збільшенню точності роботи систем.

РОЗДІЛ 2 МАТЕРІАЛИ ТА МЕТОДИ ПОШУКУ ОЗНАК РОЗДІЛЬНОСТІ КЛАСІВ ЛІКАРСЬКО-ЧУТЛИВОГО ТА ЛІКАРСЬКО-СТІЙКОГО ТУБЕРКУЛЬОЗУ

Даний розділ описує походження та розподіл даних між навчальною, валідаційною та тестовою вибіркою, на якій проведено дослідження. В рамках розділу розглядається проведення попередньої обробки даних КТ легень, що включає виділення легеневого вікна, нормалізацію вікна до 256 градацій рівня сірого та сегментацію легень для виділення зони інтересу. За виділеними зонами інтересу проведено текстурний аналіз, що дозволяє переглянути різницю текстур лікарсько-чутливої та лікарсько-стійкої форми туберкульозу. Це створює важливе підґрунтя для застосування методів аналізу текстур на зображеннях та навчання класифікаційних моделей, що розглядатиметься в наступних розділах.

2.1 Дані томографії легень

Дані для проведення дослідження були представленими анонімізованими серіями знімків пацієнтів Національного наукового центру фтизіатрії, пульмонології та алергології ім. Ф. Г. Яновського НАМН України. Кожна серія знімків містить дані зрізів КТ-томографії пацієнта з характеристиками щільності тканин з розподілом на класи представленим в табл. 2.1.

Таблиця 2.1

Розподіл зображень пацієнтів між класами

Клас	Кількість зображень з виділеною зоною ураження	Кількість пацієнтів
Лікарсько-чутливий	433	9
Лікарсько-стійкий	420	6

Графічне представлення даних по кожному з знімків відображено на Рис. 2.1




Рис. 2.1. Оригінальне КТ зображення хворого на туберкульоз: А – лікарсько-чутлива форма, Б – лікарсько-стійка форма.

Для проведення оцінки класифікації зображень застосовано метод перехресного затвердження (Cross Validation), схема його роботи представлена на рис. 2.2[65].




Рис 2.2. Схема k-кратного перехресного затвердження

За даною схемою дані пацієнтів були розподілені в відношенні 70% - навчальна вибірка(training set), 20% валідаційна вибірка(validation set) та 10% тестова вибірка (test set). Коефіцієнт кратності застосування – 10, таким чином кожне з зображень 1 раз було в екзаменаційній вибірці.

Додатково варто зазначити спосіб наповнення вибірок, він складався з визначення даних пацієнтів таким чином, щоб дані одного пацієнта не належали одночасно до навчальної та тестової вибірки.

Для проведення класифікації кожне зображення оригінальної серії додатково містило розмічену область інтересу, в рамках якої знаходилась зона ураження захворюванням. Приклад зображення з відміченою зоною зображено на рис. 2.3. та рис. 2.4.




Рис. 2.3. Приклад зображення з визначеною зоною ураження лікарсько-чутливою формою туберкульозу.




Рис. 2.4. Приклад зображення з визначеною зоною ураження лікарсько-стійкою формою туберкульозу.

Для проведення аналізу кожне з оригінальних вхідних зображень розмірністю 512x512 було нормалізовано та відфільтровано до легеневого вікна з центром в -600HU та шириною 1600 HU[15]. Основною метою такої операції слугувала оптимізація діапазону даних, оскільки для візуалізації та подальшого аналізу відбувається зміна діапазону нормалізацією. Одним з ключових аспектів застосування легеневого вікна – є локалізація патологій. Дане вікно дозволяє більш чітко сфокусуватись на змінах в рамках легень, через зміни по налаштуванню контрастності та щільності, через які зображення розширює діапазон значень для щільності тканин, що знаходяться в легеневій частині тіла. Також приведення до легеневого вікна дозволяє прибрати деякі апаратні шуми, оскільки при такому приведенні змінюється діапазон щільності тканин, які в подальшому потраплять в дослідження.

Таким чином для отримання легеневого вікна по зображенням було виконано фільтрацію діапазону характеристик щільності від [-2000; 1000] до [-1400; 200], після чого для відображення та подальшого аналізу відбулась нормалізація даного діапазону в [0; 255] за формулою 1.1. Нормалізовані зображення виділені

легеневих вікон отриманих з оригінальних КТ-зображень кожної з форм туберкульозу відображено на рис. 2.5.




Рис. 2.5. Нормалізоване зображення з легеневим вікном: А - для лікарсько-чутливої форми туберкульозу; Б - для лікарсько-стійкої форми туберкульозу.

Виділення легеневого вікна на оригінальних даних та його нормалізація в градації сірого дозволила застосувати методи дослідження орієнтовані на дані з зображень.

2.2 Виділення легень на зображеннях томографії

Виділення легеневого вікна дозволяє зробити на зображеннях фільтрацію за типами відображуваних тканин та нормалізувати яскравість зображення в діапазон градацій сірого за формулою 1.1. Дане приведення дозволяє розглядати зображення томографії, як звичайне з рівнями сірого, та застосовувати до нього методи обробки зображень. Одним з таких методів є неймережевий підхід, що базується на мережевій архітектурі Unet[30], який сегментує зображення виділяючи легені. Таке виділення формує маску, що може бути застосована для виділення зони інтересу.

Приклад застосування сегментації за мережею[30] до зображень з рис. 2.5. стали маски легень зображені на рис. 2.6.




Рис. 2.6. Маски відсегментованих легень: А – лікарсько-чутлива форма туберкульозу легень, Б – лікарсько-стійка форма туберкульозу легень

Отримана маска на рис. 2.6 виділяє зону легень з оригінального зображення, відкинувши тканини що знаходяться поза легенями. Така зона є областю інтересу для проведення подальшого аналізу зображень. З результату сегментації також можна помітити, що виділена маска є монолітною та не містить в середині себе виключних ореолів, які могли б виключити частини легень, що можуть містити важливі для аналізу дані з регіону аналізу. Накладання даної маски на нормалізоване зображення легеневого вікна(рис. 2.5.) зображено на рис. 2.7.




Рис. 2.7. Результат накладання маски на нормалізоване зображення легеневого вікна: А – лікарсько-чутлива форма туберкульозу легень, Б – лікарсько-стійка форма туберкульозу легень

2.3 Виділення текстурних характеристик форми туберкульозу

Текстурний аналіз є сукупністю методів обробки зображень, що дозволяють виділити патерни та структурні характеристики об'єкта. Даний підхід дозволяє ідентифікувати текстурні зміни в легневих тканинах уражених туберкульозом для підвищення точності виявлення хвороби[67, 68]. Окрім визначення наявності туберкульозу легень текстурні ознаки дозволяють диференціювати чутливість хвороби до лікування[69]. Дослідження [69] виділяє локальні дескриптори ознак для отримання патерну та локалізації зони формування текстурних характеристик. Однак застосування статистичних матриць текстурного аналізу дозволяє побудувати інформативний набір характеристик з даних зображень для проведення подальшого аналізу.

Застосування текстурного аналізу до нормалізованих зображень легеневого вікна дозволяє виділити наступний набір текстурних характеристик:

- Histogram

- **GLCM** [32]
- **GLRLM** [35]
- **GLSZM** [36]
- **NGTDM** [36]
- **GLDM** [37]

Побудована гістограма для зображення лікарсько-чутливої та лікарсько-стійкої форми зображена на рис. 2.8.

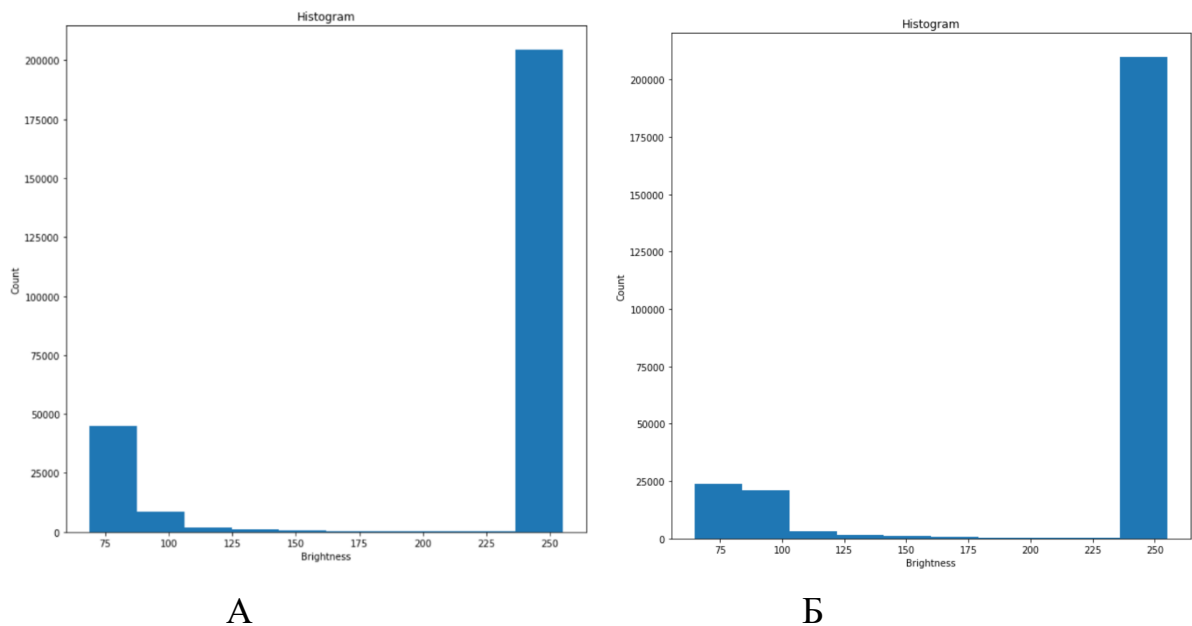


Рис. 2.8. Гістограма нормалізованого зображення легень з: А – лікарсько-чутливою формою туберкульозу, Б – лікарсько-стійкою формою туберкульозу

Візуально порівнявши можна виділити що гістограми мають схожий розподіл яскравостей з двома основними піками, один в діапазоні низьких значень яскравості (~ 75) та один у високих значеннях (~ 250). З розбіжностей у гістограмі рис. 2.8(А) пік у низькому діапазоні яскравостей є вищим ніж у гістограмі на рис. 2.8(Б), що означає наявність більшої кількості темних регіонів на зображенні.

Така відмінність дозволяє проводити подальший аналіз ознак виділених гістограмою та розробити правило диференціації форми туберкульозу.

Побудована візуалізація матриці GLCM для зображень лікарсько-чутливої та лікарсько-резистентної форми з коефіцієнтом суміжності $= 1$ та кутом повороту

0°(сусідні горизонтальні пікселі зображення) зображена на рис. 2.9. На даному зображенні червоним квадратом виділено фокусування в області ознак з найвищими значеннями. Додатково на рис. 2.10 зображено числові значення виділених ознак.




Рис. 2.9. Візуалізація матриці GLCM побудованих на зображенні: А – лікарсько-стійкої форми, Б – лікарсько-резистентної форми туберкульозу

	3	74	75	76	77	78	79	80	81	82	83		79	80	81	82	83	84	85	86	87	88
78	3	3	0	2	1	0	0	0	0	0	0	83	3	38	14	12	5	4	1	1	4	0
79	7	7	4	7	1	1	1	1	0	0	0	84	29	135	48	30	20	11	7	1	2	1
80	22	24	29	11	3	6	1	1	0	0	0	85	73	277	97	63	37	8	25	8	7	6
81	74	118	113	46	25	16	7	7	2	0	0	86	76	647	252	132	94	33	16	19	12	3
82	118	260	402	182	113	43	27	9	1	5	0	87	174	1128	561	306	155	83	49	36	18	16
83	113	402	1318	1050	547	237	102	30	17	14	0	88	128	1932	1140	749	478	218	133	77	61	26
84	46	182	1050	1892	1566	752	376	139	49	36	0	89	31	1140	1324	1074	750	350	181	124	87	37
85	25	113	547	1566	2986	2052	1039	371	166	94	0	90	36	749	1074	1316	1080	619	337	203	149	70
86	16	43	237	752	2052	2800	2279	896	418	227	0	91	35	478	750	1080	1734	1075	657	404	300	143
87	7	27	102	376	1039	2279	4064	2210	1099	625	0	92	3	218	350	619	1075	938	706	502	345	212
88	7	9	30	139	371	896	2210	2620	1726	1089	0	93	3	133	181	337	657	706	818	644	454	264
89	2	1	17	49	166	418	1099	1726	1970	1580	0	94	3	77	124	203	404	502	644	610	554	358
90	0	5	14	36	94	227	625	1089	1580	2116	0	95	3	61	87	149	300	345	454	554	778	417
91	0	1	3	13	49	88	251	396	726	1213	0	96	3	26	37	70	143	212	264	358	417	366
92	1	0	4	6	22	43	136	238	398	754	0	97	2	28	39	48	96	117	193	220	280	303
93	0	2	2	7	13	25	53	132	218	413	0	98	2	15	19	33	74	81	107	163	221	230
94	0	1	0	1	8	21	51	86	155	309	0	99	2	17	15	30	47	69	86	113	202	201
95	0	0	0	1	3	8	31	55	70	148	0	100	2	10	16	22	37	44	54	74	114	111
96	0	0	1	3	7	7	17	32	58	102	0	101	2	7	14	15	23	37	40	62	92	81
97	0	0	1	3	7	7	17	32	58	102	0	102	2	8	7	9	31	36	41	48	67	77
98	0	0	1	3	7	7	17	32	58	102	0	103	2	4	3	11	17	13	32	32	63	52
99	0	0	1	1	3	4	11	24	25	87	0	104	2	4	4	7	18	14	22	26	43	41

А

Б

Рис. 2.10. Візуалізація числових значень матриці GLCM побудованих на зображенні: А – лікарсько-чутливої форми, Б – лікарсько-резистентної форми туберкульозу

Візуально порівнявши дані матриці можна помітити на кожній з них одну виділену зону високої яскравості в лівому квадранті, що свідчить про наявність ознак з великою кількістю повторень яскравості. Зона повторюваних ознак має витягнуту діагонально орієнтовану форму. У рис. 2.9(А) зона розташована трохи нижче та правіше в порівнянні з рис. 2.9(Б), також зона А є ширшою, що свідчить про більший ступінь розсіювання отриманих ознак, в свою чергу зона Б – більш сконцентрована та містить більш чіткий градієнт інтенсивності. Таким чином зображення містять схожі області текстурних характеристик, однак абсолютні значення, градієнт їхньої зміни та розсіювання відрізняються між собою. Така відмінність дозволяє проводити подальший аналіз ознак виділених матрицею GLCM та розробити правило диференціації форми туберкульозу.

Побудована візуалізація матриці GLRLM для зображень лікарсько-чутливої та лікарсько-стійкої форми туберкульозу з кутом повороту 0° (горизонтальне розширення) зображено на рис. 2.11. Порівняння числових значень матриць зображено на рис. 2.12.




Рис. 2.11. Візуалізація матриці GLRLM для зображень: А – лікарсько-чутливої форми туберкульозу, Б – лікарсько-стійкої форми туберкульозу

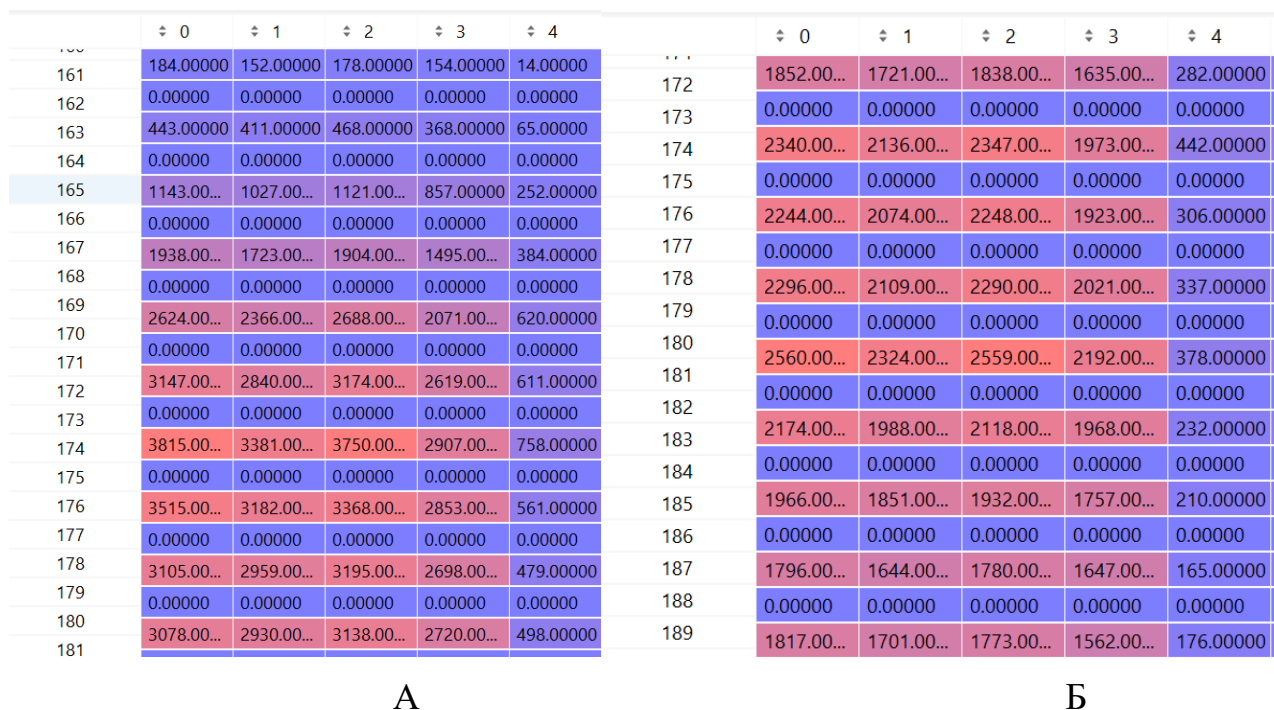


Рис. 2.12. Візуалізація числових значень GLRLM матриці для зображень: А – лікарсько-чутливої форми туберкульозу, Б – лікарсько-стійкої форми туберкульозу

Візуально порівнявши матриці побудовані на рис. 2.11 можна відзначити розташування в лівій частині матриці зон високої яскравості, що свідчить про наявність значної кількості регіонів з короткими пробігами рівня сірого. У рис. 2.11(А) яскравий регіон є більш сконцентрованим у верхній частині, що свідчить про меншу варіативність довжин, натомість рис. 2.11(Б) більш витягнута вертикально та горизонтально, що свідчить про наявність більш довгих пробігів та ширший розподіл рівнів сірого.

Проаналізувавши однорідність текстури, можна відзначити на рис. 2.12(А) більш чітке зосередження точок високої інтенсивності, що свідчить про вищу локальну однорідність. В то же час на рис. 2.12(Б) розтягнута структура точок високої інтенсивності та менше абсолютне значення ознак вказує на наявність більш однорідних ділянок в текстурі зображення.

Побудована візуалізація матриці GLSZM (з кутом 0° – горизонтальне розширення) для зображень лікарсько-чутливої (рис. 2.13) та лікарсько-стійкої

форми туберкульозу (рис. 2.14). Порівняння числових значень матриць зображено на рис. 2.15.




Рис. 2.13. Візуалізація матриці GLSZM для лікарсько-чутливої форми туберкульозу. А – Побудована матриця, Б – виділена червоним зона інтересу з зображення (А)




Рис. 2.14. Візуалізація матриці GLSZM для лікарсько-стійкої форми туберкульозу. А – Побудована матриця, Б – виділена червоним зона інтересу з зображення (А)

Візуально порівнявши матриці побудовані на рис. 2.13 та рис. 2.14 можна відзначити розташування в лівій частині матриці зон високої яскравості, що свідчить про наявність значної кількості регіонів з невеликими площами рівня сірого. У рис. 2.13 яскравий регіон містить більші значення площ рівнів сірого, однак на відміну від рис. 2.14, площі рівнів сірого більш інтенсифіковані. Також варто відмітити наявність двох піків концентрації ознак на зображеннях лікарсько-чутливої форми туберкульозу, в той час як зображення лікарсько-стійкої форми містять один пік та є більш варіативними (розтягнутими) на візуалізації.

	÷ 0	÷ 1	÷ 2	÷ 3	÷ 4	÷ 5		÷ 0	÷ 1	÷ 2	÷ 3	÷ 4
80	154	24	5	1	0	0	104	316	13	1	0	0
81	368	81	14	5	0	0	105	283	16	0	0	1
82	857	283	83	28	15	12	106	299	17	0	0	0
83	1495	431	128	46	12	8	107	247	7	0	0	0
84	2071	639	222	74	20	18	108	235	1	0	0	0
85	2619	656	191	69	17	5	109	188	10	0	0	0
86	2907	793	288	116	40	20	110	189	6	1	1	0
87	2853	617	191	64	17	5	111	166	4	0	0	0
88	2698	513	134	42	14	2	112	161	5	0	0	0
89	2720	512	145	46	13	9	113	182	5	0	0	0
90	2100	294	63	15	10	1	114	124	5	0	0	0
91	1736	265	43	18	4	1	115					
92	1456	177	24	4	3	0						
93	1366	204	29	7	1	0						
94	1021	89	7	4	1	0						
95												
96												

А

Б

Рис. 2.15. Візуалізація числових значень GLSZM матриці для зображень: А – лікарсько-чутливої форми туберкульозу, Б – лікарсько-стійкої форми туберкульозу

Порівняння числових значень матриці GLSZM на рис. 2.15(А) свідчить про наявність більших абсолютних значень для лікарсько-чутливої форми та до більшої їх розбіжності. Також в рис. 2.15(Б) можна виділити більш рівномірний розподіл значень та значно менші абсолютні значення.

Побудована візуалізація матриці NGTDM для зображень лікарсько-чутливої (рис. 2.16) та лікарсько-стійкої форми туберкульозу (рис. 2.17) з відстанню = 1. Порівняння числових значень матриць зображено на рис. 2.18.

Візуально порівнявши матриці побудовані на рис. 2.16 та рис. 2.17 можна відзначити, що обидва зображення мають велику темну область, що свідчить про

зону низької інтенсивності виділених ознак. Основна інформація зосереджена у вузькому вертикальному регіоні, що відображає варіативність значень текстури.

Локалізація відмінностей свідчить, що текстура лікарсько-чутливого зображення містить більш низьку інтенсивність значень з рис. 2.18(А), більш згладжену та менш виражену неоднорідність текстури. Лікарсько-стійка форма туберкульозу хоч і розташована в основному в тому самому місці містить значення з більшими значеннями інтенсивності ознак з рис. 2.18(Б). Також рис. 2.17 демонструє більшу варіативність сусідніх значень рівнів сірого.




Рис. 2.16. Візуалізація матриці NGTDM для лікарсько-чутливої форми туберкульозу. А – Побудована матриця, Б – виділена червоним зона інтересу з зображення (А)




Рис. 2.17. Візуалізація матриці NGTDM для лікарсько-стійкої форми туберкульозу. А – Побудована матриця, Б – виділена червоним зона інтересу з зображення (А)

	÷ 0	÷ 1	÷ 2	÷ 3		÷ 0	÷ 1	÷ 2	÷ 3
78	16.00000	83.00000	72.00000	0.00000	79	281.00000	521.00000	73.00000	0.00000
79	59.00000	188.00000	73.00000	0.00000	80	539.00000	882.00000	74.00000	0.00000
80	221.00000	528.00000	74.00000	0.00000	81	825.00000	1192.00...	75.00000	0.00000
81	599.00000	1034.00...	75.00000	0.00000	82	1517.00...	2025.00...	76.00000	0.00000
82	1938.00...	2543.00...	76.00000	0.00000	83	1833.00...	2326.00...	77.00000	0.00000
83	3071.00...	3348.00...	77.00000	0.00000	84	2389.00...	2844.00...	78.00000	0.00000
84	4540.00...	4264.00...	78.00000	0.00000	85	2648.00...	3196.00...	79.00000	0.00000
85	4967.00...	4261.00...	79.00000	0.00000	86	3595.00...	4655.00...	80.00000	0.00000
86	6204.00...	5602.00...	80.00000	0.00000	87	3100.00...	3962.00...	81.00000	0.00000
87	5061.00...	5036.00...	81.00000	0.00000	88	3179.00...	3957.00...	82.00000	0.00000
88	4390.00...	4634.00...	82.00000	0.00000	89	3667.00...	4964.00...	83.00000	0.00000
89	4506.00...	5247.00...	83.00000	0.00000	90	2795.00...	4050.00...	84.00000	0.00000
90	2993.00...	4217.00...	84.00000	0.00000	91	2482.00...	3919.00...	85.00000	0.00000
91	2493.00...	4214.00...	85.00000	0.00000	92	2202.00...	3908.00...	86.00000	0.00000
92	1913.00...	3483.00...	86.00000	0.00000	93	2236.00...	4637.00...	87.00000	0.00000
93	1901.00...	4113.00...	87.00000	0.00000	94	1613.00...	3209.00...	88.00000	0.00000
94	1241.00...	3178.00...	88.00000	0.00000	95	1371.00...	3577.00...	89.00000	0.00000
95	1036.00...	3332.00...	89.00000	0.00000					
96	821.00000	2946.00...	90.00000	0.00000					
97	827.00000	3480.00...	91.00000	0.00000					
98	527.00000	2205.00...	92.00000	0.00000					
99	529.00000	2781.00...	93.00000	0.00000					
100	495.00000	2754.00...	94.00000	0.00000					

Рис. 2.18. Візуалізація числових значень NGTDM матриці для зображень: А – лікарсько-чутливої форми туберкульозу, Б – лікарсько-стійкої форми туберкульозу

Побудована візуалізація матриці GLDM для зображень лікарсько-чутливої та лікарсько-стійкої форми туберкульозу з відстанню = 1, зображено на рис. 2.19. Порівняння числових значень матриць зображено на рис. 2.20.

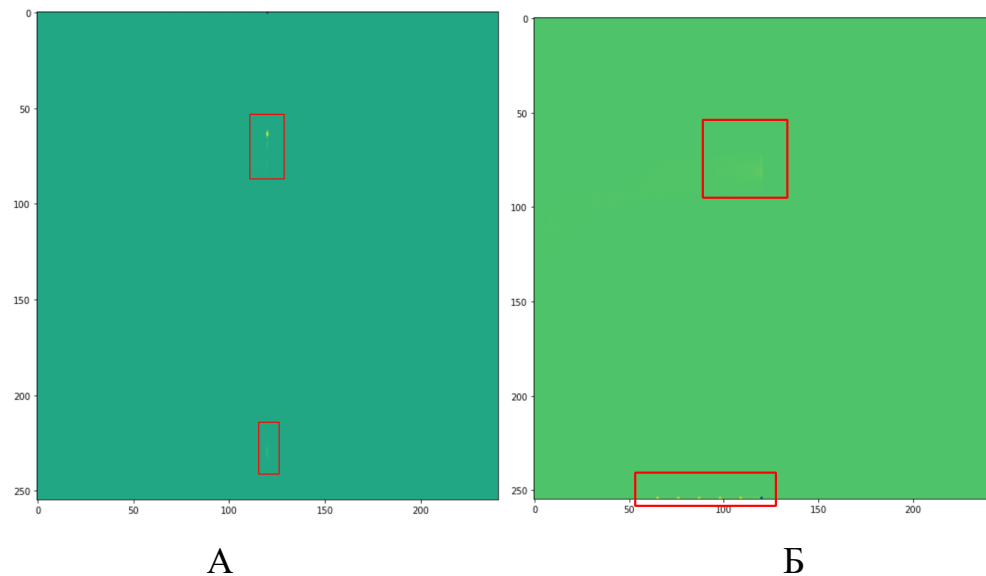


Рис. 2.19. Візуалізація матриці GLDM для зображень: А – лікарсько-чутливої форми туберкульозу, Б – лікарсько-стійкої форми туберкульозу

	÷ 8	÷ 9	÷ 10	÷ 11	÷ 12	÷ 13		÷ 8	÷ 9	÷ 10	÷ 11	÷ 12	÷ 13
104	22	13	21	14	20	23	104	8	5	18	10	18	14
105	10	22	18	14	18	28	105	10	15	9	15	12	12
106	22	25	20	23	24	13	106	15	12	15	16	12	12
107	17	16	11	13	16	10	107	6	7	13	13	12	12
108	11	15	11	14	20	14	108	8	12	13	9	7	7
109	21	19	9	6	13	9	109	19	10	13	7	8	4
110	14	17	16	13	13	7	110	6	4	8	9	8	11
111	15	12	19	9	7	8	111	6	7	10	6	2	3
112	25	13	16	16	8	5	112	4	5	6	3	5	5
113	17	15	9	15	6	2	113	8	5	5	8	7	5
114	10	13	8	6	6	6	114	7	3	2	5	4	4
115	11	17	4	9	7	3	115	5	2	4	3	0	7
116	9	10	7	7	12	9	116	5	6	9	3	2	2
117	9	8	6	7	6	10	117	2	10	7	4	4	0
118	11	4	5	7	7	1	118	7	2	1	2	3	4
119	11	6	7	1	3	4	119	3	0	5	1	3	7
120	9	13	6	5	2	1	120	1	2	1	3	1	0
121	12	9	8	4	5	2	121	0	2	2	2	3	2
122	14	5	6	7	6	2	122	1	1	2	0	0	0
123	6	6	4	5	7	6	123	4	3	0	1	0	0
124							124						
125							125						
126							126						

Рис. 2.20. Візуалізація числових значень GLDM матриці для зображень: А – лікарсько-чутливої форми туберкульозу, Б – лікарсько-стійкої форми туберкульозу

Візуально порівнявши матриці побудовані на рис. 2.19 можна відзначити, що обидва зображення мають велику темну область, що свідчить про зону низької

інтенсивності виділених ознак. Основна інформація зосереджена у вузькому вертикальному регіоні в центральній області.

Додатково до ознак центральної зони є додатковий пік в діапазоні [210; 240] для лікарсько-чутливої форми та [250;255] для лікарсько-стійкої форми. Темні зони зображення представляють з себе не нульові значення залежностей ознак, що відображено на рис. 2.20.

2.4 Методи класифікації форми туберкульозу за текстурними характеристиками

Для класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу легень застосовувались ансамблеві[70] та нейромережеві методи[71]. Кожне з зображень, що передавалось на вхід ансамблевому та нейромережевому методі було нормалізовано за легеневим вікном та виділено за допомогою маски з згорткової нейронної мережі. Класифікація ансамблевим методом виконувалась на наборі ознак сформованим нейронною мережею (рис. 2.21) та текстурним аналізом з подальшою клас орієнтованою селекцією (рис. 2.22). Нейромережевий відбір ознак відбувався за допомогою використання Autoencoder модифікації архітектури ResNet[72]. Навчання оригінальної мережі відбувалось з учителем в задачі класифікації форми туберкульозу. Після завершення процесу навчання архітектура мережі була спрощена лише до Encoder частини, що дозволило отримати ознаки прихованого шару та застосувати їх для входу ансамблевого класифікатора.

Відбір текстурних ознак базувався на побудові матриць текстурних характеристик з подальшим відбором розробленою технологією клас-орієнтованої селекції ознак. Алгоритм селекції сформував оптимальний ансамбль ознак для навчання класифікатора за допомогою генетичного відбору за критерієм Minimum redundancy maximum relevance [73].

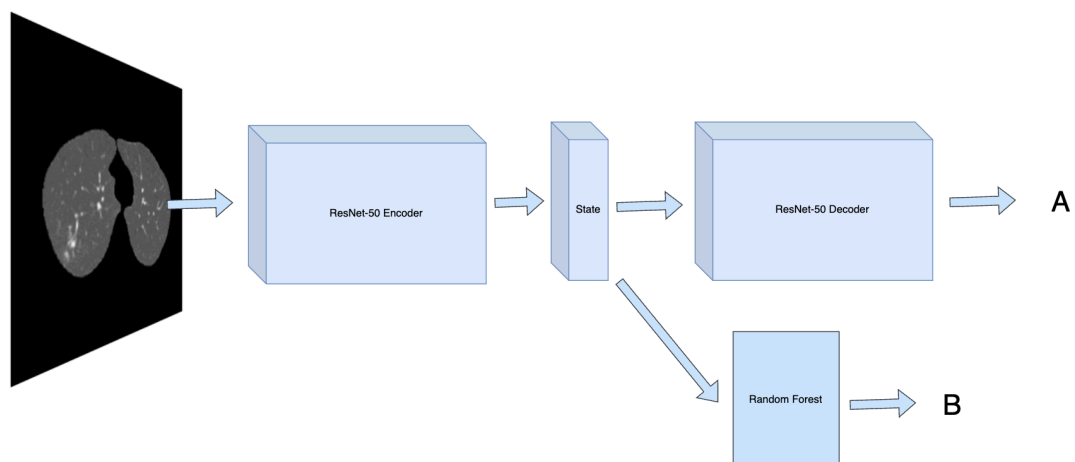


Рис. 2.21. Схема неймережевої технології класифікації на основі autoencoder ResNet. А –вихід мережі в процесі навчання. Б – Результат роботи класифікатора

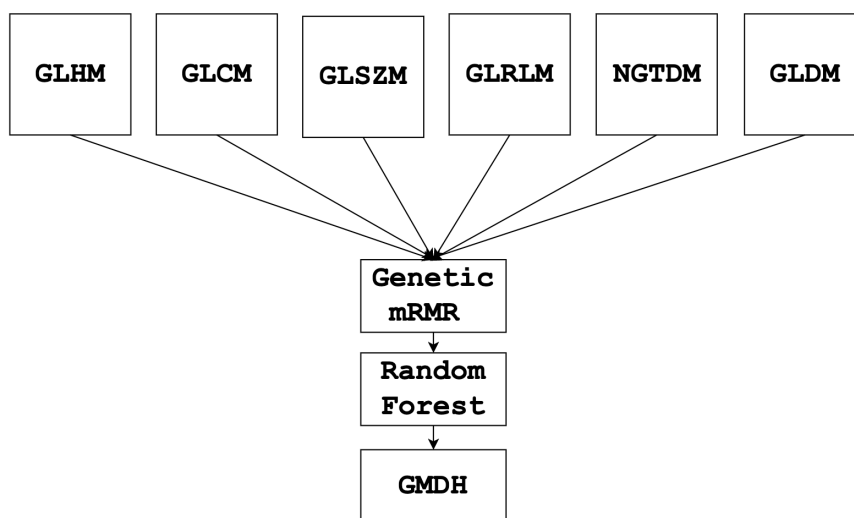


Рис. 2.22. Схема ансамблевої технології на основі клас-орієнтованої селекції текстурних ознак

Задача диференціації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу легень проводилась лише неймережевими методами за схемою зображеною на рис. 2.23, з використанням архітектури ResNet-101.




Рис. 2.23. Схема технології з застосуванням архітектури ResNet-101

Висновки до розділу 2

В результаті попередньої обробки даних зображень комп'ютерної томографії вдалось зменшити надлишковість та збільшити інформативність оригінальних даних за рахунок застосування методів статистичного та текстурного аналізу медичних зображень.

Застосування легеневого вікна зменшує надлишковість даних та дозволяє підготувати їх для подальшого аналізу в якості зображення, однак в результаті даного перетворення все ще залишається інформація про зону за легеньми.

Формування області інтересу, що складається лише з зони легень можливе з застосуванням нейромережевого сегментатора. На основі сегментованого зображення легень можна виділити маску, що представлятиме зону аналізу ураження легень, як статистичними так і нейромережевими методами.

Застосування нейронних мереж вимагає великих обсягів даних для навчання, тоді як статистичні методи не мають таких обмежень.

РОЗДІЛ 3 СТАТИСТИЧНА КЛАС-ОРІЄНТОВАНА СЕЛЕКЦІЯ ТЕКСТУРНИХ ОЗНАК

Даний розділ розглядає застосування методу клас-орієнтованої селекції ознак до підбору оптимального ансамблю для вирішення задачі класифікації на прикладі диференціації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу легень. Розглянутий метод складається з декількох послідовних етапів відбору ознак та їх результуючого об'єднання в єдиний ансамбль. Такий підхід забезпечує можливість зменшення надлишковості даних, що будуть передані до класифікатора. Також в рамках розділу розглядаються оптимізації методу для використання в багатопоточному середовищі, що дозволяє оптимізувати час виконання за рахунок паралелізації обчислень.

3.1 Формування вхідного простору ознак

Формування вхідного простору ознак є важливим етапом у машинному навчанні. Від якості обраних ознак залежить точність та швидкість класифікаційних алгоритмів. Якщо набір ознак містить багато нерелевантних або зайвих даних - це ускладнює роботу моделі. Наявність великої кількості параметрів збільшує час навчання, підвищує вимоги до обчислювальних ресурсів та може спричинити перенавчання. Тому правильний вибір ознак допомагає зменшити розмірність, виключити з моделі надлишкові ознаки та покращити здатність моделі до узагальнення[74-76].

Дані великої розмірності містять багато інформації, але не вся вона корисна. Деякі ознаки можуть бути дубльованими або слабко пов'язаними з кінцевим результатом. Тому використання правильних методів відбору ознак дає змогу сфокусувати увагу моделі лише на найважливіших з них. Це підвищує точність, та зменшує час необхідний для роботи моделі.

Окрім неінформативних ознак на точність класифікації негативним чином впливає шум, який з'являється через похибки вимірювань та може призводити до

некоректності даних. Якщо модель навчатиметься на зашумлених даних, вона може розпізнавати випадкові закономірності замість реальних патернів. Деякі класифікатори, такі як нейронні мережі, частково здатні адаптуватись до шуму[77]. Однак більшість методів вимагають попередньої обробки даних для усунення некоректності даних.

Для попередньої обробки та відбору ознак виділяють три основні групи методів:

- Фільтраційні методи(Filter Methods)
- Обгорткові методи (Wrapper methods)
- Гібридні методи (Hybrid Methods)

Методи фільтрації працюють незалежно від алгоритму класифікації та оцінюють значущість кожної ознаки на основі статистичних показників. Обгорткові методи тестують різні комбінації ознак в поєднанні з класифікатором та дозволяють підібрати найкращий набір параметрів, однак вимагають великої кількості ресурсів. Гібридні методи поєднують переваги двох попередніх підходів, дозволяючи балансувати між перевагами кожного з них[78].

Вибір правильних ознак є одним з найважливіших етапів у побудові класифікаційних моделей. Зменшення кількості та збільшення інформативності дозволяє підвищити точність класифікації та зменшити час на навчання моделі.

Для вирішення задачі класифікації за матрицею текстурних характеристик потрібно зменшити кількість ознак які прийматимуть участь в навчанні класифікатора[79]. Для цієї цілі можна скористатись методами лінійного програмування, або ж скористатись попередньо визначеними фільтраційними методами.

Попередньо проаналізувавши матриці текстурних характеристик отримані в розділі 2 можна сказати що частина з ознак отриманих таким чином не містить інформативних даних, оскільки такі комбінації градацій сірого не зустрічаються ні

для одного з класів. Тому первинним фільтром є відбір ознак значення яких не дорівнює 0 для будь якого з класів. Подальший процес відбору інформативних ознак виконується в рамках клас-орієнтованої технології селекції ознак.

3.2 Клас-орієнтована селекція

Клас-орієнтована технологія селекції ознак пропонує трьох етапний гібридний метод класифікації:

- Етап 1 – обробка окремих ознак (кроки 1-3)
- Етап 2 – аналіз ознак та формування ансамблю (крок 4)
- Етап 3 – навчання класифікатора на сформованому ансамблі (крок 5)

Етап 1 обробляє окремі ознаки зображень, що дозволяє виділити по кожній з матриць текстурних характеристик окремий вхідний канал, та провести поканальну паралелізацію обчислень. На етапі 2 виконується об'єднання поканально відібраних ознак в загальну колекцію з подальшим відбором з застосуванням генетичного алгоритму. Етап 3 передбачає побудову класифікатора на ансамблі ознак отриманих на етапі 2.

Етап 1 складається з трьох кроків, серед яких:

1. Відбір ознак за найгіршою міжкласовою різницею
2. Об'єднання сусідніх ознак
3. Відбір шляхом мінімізації внутрішньокласової відстані та максимізації міжкласової відстані

Крок відбору за найгіршою міжкласовою різницею орієнтується на наближеність значень ознак двох класів, що дозволяє припустити що дана ознака не збільшує інформативність потенційного ансамблю ознак. Відкидання ознак на першому кроці відбувається відповідно до формули 3.1

$$\left| \frac{1}{n} \sum_{i=1}^n a_{ir} - \frac{1}{m} \sum_{j=1}^m b_{jr} \right| > T \quad (3.1)$$

Де a_{ir} та b_{jr} є значеннями ознаки r на зображеннях першого та другого класу, n , m – кількість об'єктів першого та другого класу, $r=1\dots N$, T – поріг зменшення простору ознак.

Значення порогу T визначається на основі абсолютних значень ознак в кожному з каналів відповідно до формули 3.2.

$$T = \beta \cdot \max_{r_1, \dots, r_i} \left| \frac{1}{n} \sum_{i=1}^n a_{ir} - \frac{1}{m} \sum_{j=1}^m b_{jr} \right| \quad (3.2)$$

Де a_{ir} та b_{jr} є значеннями ознаки r на зображеннях першого та другого класу, n , m – кількість об'єктів першого та другого класу, $r=1\dots N$, T – поріг зменшення простору ознак, β коефіцієнт відбору в діапазоні $[0,1]$.

Параметр β визначає поріг чутливості при відборі. Подальші обрахунки розраховані для значення $\beta = 0,1$. Додатково варто зауважити, що якщо попередньо маскою не визначено та не відфільтровано ознаки, що сформовані за ознаками які не зустрічались – то вони будуть відкинуті на даному кроці, оскільки їх значення не перевищуватиме поріг T .

Крок 2 передбачає відбір ознак з кроку 1 за критерієм вибору з підмножин, сформованих із заданим кроком за незалежним аргументом s . Рациональність кроку обґрунтовується очікуваною близькою ефективністю суміжних (за незалежним аргументом s) ознак при їх застосуванні в класифікаційному ансамблі. Рис. 3.1 відображає гістограму різниці частот зустрічальності відтінків сірого на зображеннях класів.




Рис. 3.1. Кроковий відбір ознак

Кожна частота h відповідного відтинку s може виступати як ознака в задачі класифікації. Сусідні ознаки (відтинки сірого) матимуть близький вплив на точність в ансамблі ознак. Тому має сенс вибирати лише 1 ознаку з обраного діапазону δ . В складних випадках можливе застосування відбору з змінним кроком $\delta = \delta(s)$. Окремо варто зауважити обробку ознак сусіди яких були відфільтровані на попередньому кроці, дані ознаки потраплятимуть на наступний крок відбору, оскільки в крок δ потраплятиме лише одна ознака.

Застосування даного відбору є схожим до застосування шару max pooling в мережах з згортковою структурою (рис. 3.2).




Рис. 3.2. приклад застосування операції max pooling в згортковій нейронній мережі[80].

Крок 3 реалізує відбір ознак шляхом мінімізації внутрішньокласової та максимізації міжкласової відстані, відповідно до формули 3.3.

$$\frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (a_{ir} - \mu_a)^2} + \sqrt{\frac{1}{m} \sum_{j=1}^m (b_{jr} - \mu_b)^2}}{\left| \frac{1}{n} \sum_{i=1}^n a_{ir} - \frac{1}{m} \sum_{j=1}^m b_{jr} \right|} > T \quad (3.3)$$

Де $\mu_a = \frac{1}{n} \sum_{i=1}^n (a_{ir})$, $\mu_b = \frac{1}{m} \sum_{j=1}^m (b_{jr})$, T – поріг відбору ознак.

Значення порогу T визначається на основі абсолютних значень ознак в кожному з каналів відповідно до формули 3.4.

$$T = \beta \cdot \max_{r_1, \dots, r_i} \left| \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (a_{ir} - \mu_a)^2} + \sqrt{\frac{1}{m} \sum_{j=1}^m (b_{jr} - \mu_b)^2}}{\left| \frac{1}{n} \sum_{i=1}^n a_{ir} - \frac{1}{m} \sum_{j=1}^m b_{jr} \right|} \right| \quad (3.4)$$

Де $\mu_a = \frac{1}{n} \sum_{i=1}^n (a_{ir})$, $\mu_b = \frac{1}{m} \sum_{j=1}^m (b_{jr})$, T – поріг відбору ознак, β коефіцієнт відбору в діапазоні $[0,1]$.

Крок 4 реалізується в рамках етапу 2. В рамках кроку виконується відбір набору ознак для формування ансамблю в рамках одного вхідного каналу. Для виконання відбору застосовується алгоритм генетичного відбору з функцією пристосованості вираженою формулою 3.5, вагові коефіцієнти відбору обраховуються формулою 3.6. Кількість ознак k , що описують розмір результуючого інформаційного ансамблю є гіперпараметром алгоритму.

$$\max_{i_1, \dots, i_k} \frac{\frac{1}{k} \sum_{p=1}^k \left| S_{y, x_{i_p}} \right|}{1 + \frac{1}{C_k^2 - k} \sum_{p=1}^k \sum_{q=1}^p \left| S_{x_{i_p}, x_{i_q}} \right|_{i_p \neq i_q}} \quad (3.5)$$

Де S є кореляцією Спірмена[78], k – кількість ознак в ансамблі.

$$\max_{i_1, \dots, i_k} \frac{\alpha}{2k} \sum_{p=1}^k \left| S_{y, x_{i_p}} \right| + \frac{1 - \alpha}{2 + \frac{1}{C_k^2 - k} \sum_{p=1}^k \sum_{q=1}^p \left| S_{x_{i_p}, x_{i_q}} \right|_{i_p \neq i_q}} \quad (3.6)$$

Де S є кореляцією Спірмена, k – кількість ознак в ансамблі.

Критерій забезпечує відбір ансамблю попарно незалежних ознак за кореляцією з класом. Для пошуку оптимальних ансамблів ознак застосовується алгоритм генетичного відбору ознак. Дане рішення використано через високу обчислювальну вартість повного перебору всіх комбінацій ознак в ансамблі. Також замість генетичного алгоритму на кроці 4 можна застосувати нейронну мережу з критерієм mRMR[73], яка також дозволяє зробити ранжування ансамблю ознак. Застосування алгоритму описаного в кроці 4 дозволяє ранжувати ознаки за ступенем інформативності та вибрати ансамбль сталої розмірності, або ж сформулювати його відібравши ознаки за пороговим значенням інформативності.

Етап 3 та крок 5 об'єднує поканально визначені ознаки в єдиний ансамбль, для побудови класифікатора. Реалізація такого об'єднання може бути виконана двома способами, зображеними на рис. 3.3. Схема на рис. 3.3(А) орієнтована на застосування генетичного відбору результуючого ансамблю ознак більшого розміру поєднуючи ознаки отримані на кожному з вхідних каналів.

Схема зображена на рис. 3.3.(Б) Орієнтована на навчання класифікатора на ознаках текстурних характеристик та формуванні ансамблевої функції голосування, що враховуватиме результат голосування кожного з каналів. Оскільки на кожен канал прийде різна матриця текстурних характеристик, то така схема визначатиме результуючий клас за комбінуванням голосів по кожній з матриць.

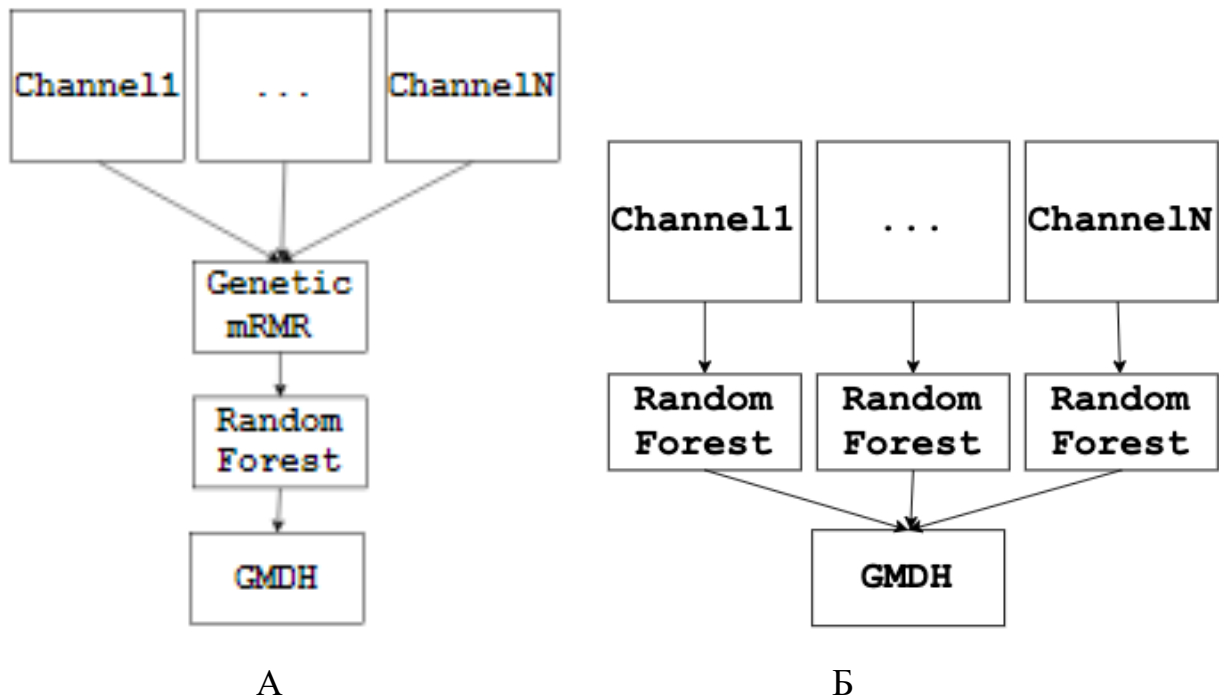


Рис. 3.3. Схема реалізації об'єднання ознак для навчання класифікатора. А – відбір генетичним алгоритмом, Б – відбір з ансамблюванням класифікаторів випадкового лісу.

Застосувавши дану технологію до задачі класифікації матриць текстурних характеристик ми отримаємо наступні варіації результуючих схем для навчання класифікатора, що зображено на рис. 3.4. та рис 3.5. Схема на рис. 3.4. орієнтується на застосування генетичного алгоритму для відбору результуючого ансамблю. Схема на рис. 3.5. орієнтується на навчання окремого класифікатора для кожного з вхідних каналів та формування єдиної функції голосування над класифікаторами кожного з каналів ознак.

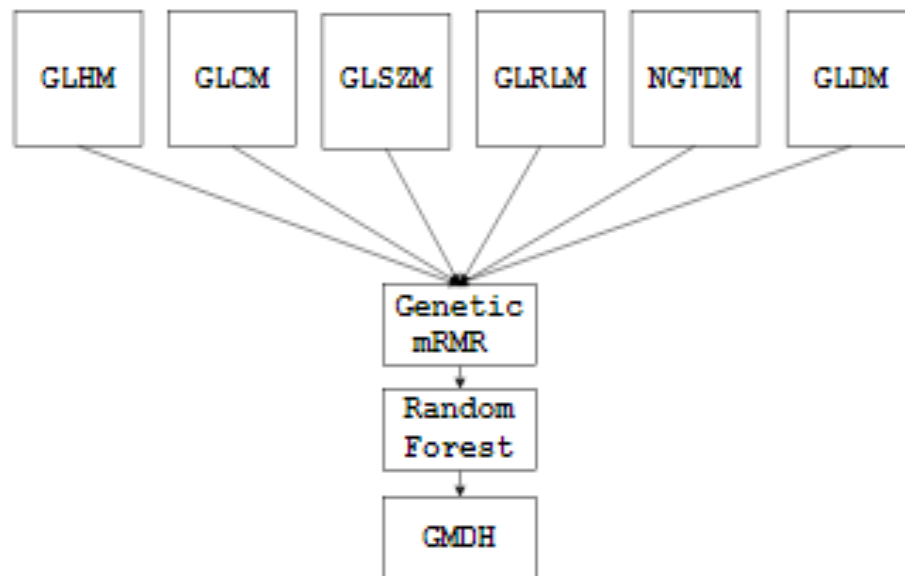


Рис. 3.4. Результуюча схема технології голосування з застосуванням генетичного алгоритму для об'єднання ознак кожного з каналів.

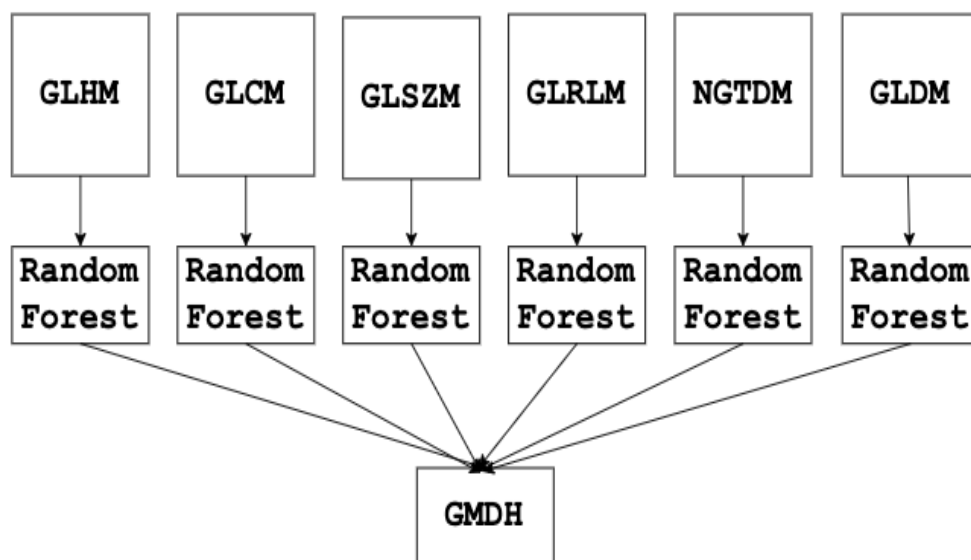


Рис 3.5. Результуюча схема технології голосування з застосуванням технології ансамблювання дерев.

Додатково варто відзначити можливість покращення результатів голосування в схемі на рис. 3.5. за допомогою методу групового урахування аргументів[83]. Дане покращення можливе за рахунок введення додаткових ваг для дерев що приймають участь в класифікації, та визначення ваг дерев поліноміальним методом.

У випадку схеми технології голосування з застосуванням технології ансамблювання дерев – метод групового урахування аргументів дозволяє

визначити ваги кожного з класифікаторів для побудови єдиної функції голосування.

3.3 Підбір ансамблю ознак

Відбір інформативного ансамблю для класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу застосовується для даних текстурних характеристик, отриманих з зображень комп'ютерної томографії. Селекція інформативного ансамблю за матрицею суміжностей рівнів сірого зображено на рис. 3.6. Де рис. 3.6(А, Б) описують оригінальні зображення лікарсько-чутливої(А) та лікарсько-стійкої форми туберкульозу(Б). Побудовані матриці GLCM за даними зображеннями легень відображені на рис 3.6(В) для лікарсько-чутливої та рис. 3.6(Г) для лікарсько-стійкої форми.




Рис. 3.6. А – виділена область інтересу для лікарсько-чутливої форми туберкульозу, Б – виділена область інтересу для лікарсько-стійкої форми туберкульозу, В - Візуалізація матриці GLCM побудованої на зображенні А, Г - Візуалізація матриці GLCM побудованої на зображенні Б

Як можна замітити зображення GLCM містять зони високої інтенсивності, виділені в червоному квадраті, однак ознаки для аналізу текстури містяться не

лише там. На рис. 3.7. відображено матрицю ознак, що містять відмінності для матриці GLCM з рис. 3.6(В та Г).




Рис. 3.7. Матриця різниці для GLCM ознак лікарсько-чутливої та лікарсько-стійкої форми туберкульозу.

Візуалізація матриці на рис. 3.7 демонструє, що не лише зони високої інтенсивності містять ознаки що відрізняються для обох форм туберкульозу. Також за даним графіком розсіювання можна визначити дзеркальність відносно діагоналі, оскільки це одна з особливостей матриці GLCM. Також дані різниці яскравостей мають значний розкид точок, що свідчить про наявність великої кількості комбінацій яскравостей. Дані яскравості є як і інформативними так і надлишковими.

Для відбору найбільш інформативних з них скористаємось технологією клас орієнтованої селекції ознак. Перший крок містить відбір за найгіршою міжкласовою різницею, що визначається в рамках розкиду значень характеристики на усіх зображеннях серії, та свідчить про слабку ступінь роздільності класів за даною ознакою. Застосувавши крок 1 клас-орієнтованої технології отримаємо наступну візуалізацію матриці інформативних ознак, зображену на рис. 3.8.




Рис. 3.8. Візуалізація інформативних ознак матриці GLCM після застосування першого кроку клас-орієнтованої технології селекції ознак

Відповідно до рис. 3.8. кількість ознак з матриці суттєво зменшилась та сконцентрувалась в зоні високої інтенсивності оригінальної матриці текстурних характеристик.

Другий крок технології містить об'єднання сусідніх ознак. Застосувавши його з кроком об'єднання $\delta = 2$.




Рис. 3.9. Візуалізація інформативних ознак матриці GLCM після застосування другого кроку клас-орієнтованої технології селекції ознак

Як зображено на рис. 3.9. кількість ознак зменшилась в 2 рази по горизонтальній осі. Однак кроковий алгоритм може бути застосований для зменшення кількості ознак як по горизонтальній так і по вертикальній осі. А застосування його до горизонтальної та вертикальної осі одночасно приведе до згортки max Pooling сформованої за ознаками з матриці текстурних характеристик.

На третьому кроці технології відбувається відбір за критерієм мінімізації внутрішньокласової відстані та максимізації міжкласової відстані, що формує набір ознак візуалізований на рис 3.10.




Рис. 3.10. Візуалізація інформативних ознак матриці GLCM після застосування третього кроку клас-орієнтованої технології селекції ознак

З візуалізації третього кроку можна замітити що кількість ознак суттєво зменшилась та прийняла форму контуру оригінальної фігури. Середина даного контуру заповнена інформативними ознаками, однак їх кількість зменшилась.

Застосування генетичного алгоритму на четвертому кроці дозволяє отримати зменшений інформативний ансамбль ознак, зображений на рис. 3.11.




Рис. 3.11. Візуалізація інформативних ознак матриці GLCM після застосування четвертого кроку клас-орієнтованої технології селекції ознак

На п'ятому кроці технології відбувається об'єднання матриць текстурних характеристик. До об'єданого простору ознак застосовується алгоритм селекції найбільш інформативних ознак, що визначає конкретні ознаки для виділення найбільш інформативних пікселів.

Оскільки застосування матриць текстурних характеристик є оборотним перетворенням, то за виділенням на кроці 5 інформативним ансамблем можна провести виділення пікселів, ознаки яких входять в інформативний ансамбль.

Таким чином на рис. 3.12. відображено оригінальне зображення та зображення з виділеними інформативними пікселями, що характеризують ознаки відібрані в процесі клас орієнтованої технології селекції.




Рис. 3.12. А – Візуалізація пікселів представлених ознаками відібраними в процесі клас-орієнтованої селекції, Б – оригінальне зображення легень після виділення зони інтересу.

Візуалізація пікселів за ознаками з інформативного ансамблю містять розріджені пікселі по всій структурі легень, а також концентрацію пікселів в зоні ураження легень, що дозволить класифікатору визначити приналежність даного зображення до лікарсько-чутливого або лікарсько-стійкого класу.

Провівши навчання класифікатора на вирізаних зонах інтересу з зображень вдалось отримати результати класифікації представлені в таблиці 3.1. Найбільша точність класифікації у 85% в методу клас-орієнтованої селекції з об'єднанням за mRMR та класифікатором Random Forest з МГУА.

Варто зазначити що даний метод застосовує генетичний відбір як до поканальних ознак так і до загального інформативного ансамблю. Це дозволяє в збільшувати порогові значення кількості ознак отриманих в каналному алгоритмі генетичної селекції. Збільшення кількості ознак на кроці чотири призводить до збільшення обрахунків на кроці п'ять, однак це потенційно розширює можливості по аналізу залежностей ознак одночасно в різних матрицях текстурних характеристик.

Таблиця 3.1

Точність класифікації на виділених областях інтересу

Метод	Клас		Загальна точність
	Лікарсько-чутливий	Лікарсько-стійкий	
Клас-орієнтована селекція з об'єднанням за mRMR та класифікатором Random Forest	84,2%	83,3%	83,8%
Клас-орієнтована селекція з об'єднанням за mRMR та класифікатором Random Forest з МГУА	86,3%	83,7%	85%
Клас-орієнтована селекція з каналною класифікацією Random Forest та голосуванням більшістю	83,2%	82,5%	82,9%
Клас-орієнтована селекція з каналною класифікацією Random Forest та голосуванням з МГУА	84,2%	83%	83,6%

Таблиця 3.2

Кількість ознак в по кожній матриці характеристик після відбору

Тип матриці	Початкова кількість	Крок 1	Крок 2	Крок 3	Крок 4
GLHM	256	82	41	37	10
GLCM	65536	1533	767	690	20
GLSZM	131072	530	265	238	30
GLRLM	131072	768	384	346	30
NGTDM	256	103	52	47	10
GLDM	65536	1432	716	645	20

Таблиця 3.2. містить інформацію про розміри інформативних ансамблів та процес відбору на кроках 1-4. Крок 5 містить дві альтернативні схеми завершення технології, враховуючи дану характеристику, кількість ознак яка задіяна в процесі класифікації буде варіюватись від схеми по якій застосована технологія.

3.4 Пришвидження алгоритму фільтрації ознак паралелізацією

Паралелізація обчислень – ключовий підхід до підвищення продуктивності та скорочення часу виконання в сучасних інформаційних системах. Великий обсяг даних, що приймає участь в методі селекціонування вимагає ефективного використання ресурсів. Зменшення часу виконання в системі можливе за рахунок паралелізації обчислень в багатопотоковому середовищі виконання.

Для проведення паралелізації алгоритму було виконано декомпозицію задачі, розподіл обчислень, синхронізацію розрахунків та балансування навантаження.

В рамках декомпозиції визначено дві основні фази які дозволяють застосувати паралелізацію за даними. Перша фаза стосується поканальних алгоритмів фільтрації. Друга фаза паралелізації можлива при використанні генетичного алгоритму.

В рамках фази 1 кожен канал представляє з себе окремий конвеєр в який передається зображення для побудови матриці текстурних характеристик та виконання подальшої фільтрації методом клас-орієнтованої селекції на кроках 1-4. Дані кроки не вимагають синхронізації обчислень між матрицями, тому можуть виконуватись паралельно один від одного.

Якщо середовище виконання дозволяє застосування більш широкої паралелізації обчислень, тоді потрібно перейти від дата-орієнтованого[83] підходу, до завдання-орієнтованого, де в рамках кожного з вхідних зображень буде відбуватись обрахунок всіх матриць текстурних характеристик. Схема з дата-орієнтованим підходом (рис. 3.13) та завдання-орієнтованим (рис. 1.14) дозволяє оптимізувати необхідний час для виконання обчислень.

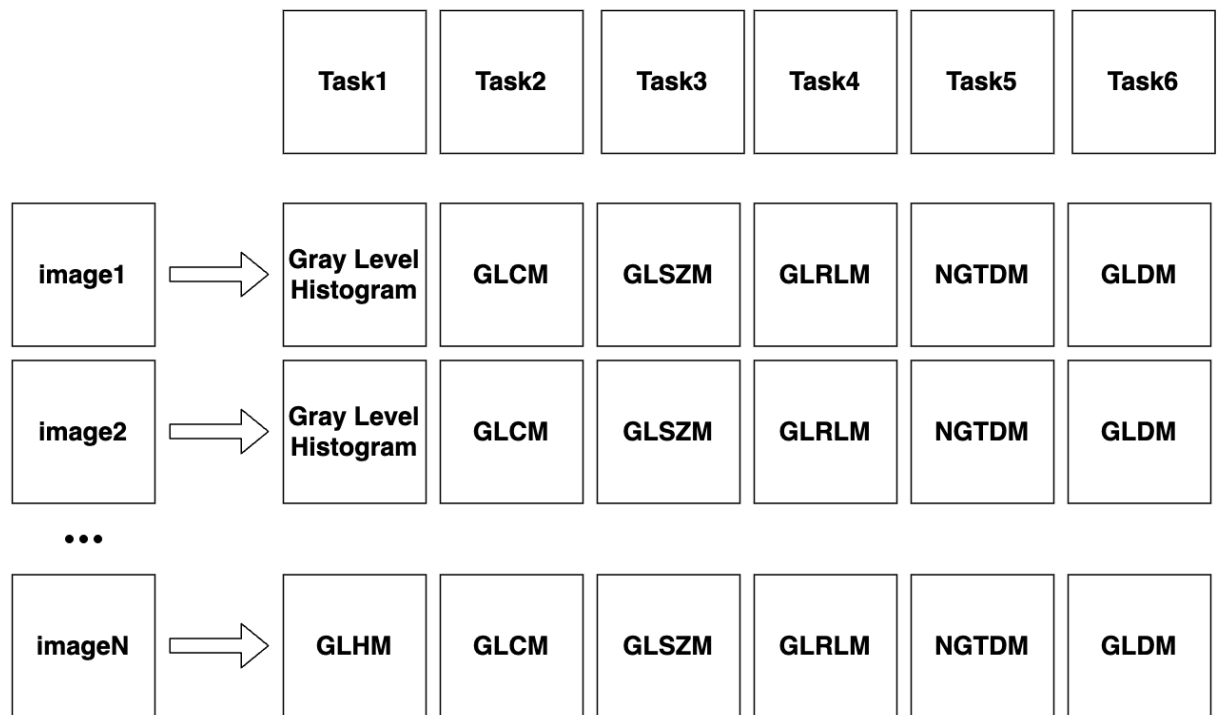


Рис. 3.13.Схема паралелізації за дата-орієнтованим підходом



Рис. 3.14.Схема паралелізації за завдання-орієнтованим підходом

Схема з дата-орієнтованим (рис. 3.13) підходом дозволяє отримати дані кожної з матриць текстурних характеристик для всіх зображень серії в рамках одного завдання, що дозволить в рамках механізму навчання клас-орієнтованій селекції приступити до фільтрації даних на кроках 1-4 без додаткової синхронізації по даним.

Завдання-орієнтована паралелізація (рис. 3.14) дозволяє не виконувати копіювання кожного з зображень в пам'ять кожного з виконавців задач для обрахунку, що зменшує вимогу по її кількості. Однак такий механізм паралелізації створює додаткову точку синхронізації, оскільки для проведення розрахунку по клас-орієнтованій технології для кроку 1 потрібне визначення значень матриці для кожного з зображень.

Після завершення відбору та визначення інформативних ознак на кожній з матриць більш ефективним підходом паралелізації є подійно-орієнтований. Цей підхід дозволяє в рамках однієї задачі виконати розрахунок всіх вхідних каналів з ознаками для зображення та виконати для нього класифікацію.

Застосування другої фази паралелізації можливе в рамках кроку 5 клас-орієнтованої селекції ознак в обох схемах.

Паралелізація в схемі з застосуванням генетичного алгоритму можлива за рахунок паралелізації обрахунку fitness функції для кожного індивіда вибірки[84,85], або ж в рамках паралельного обрахунку мутацій[86]. Додатково окрім паралелізації обрахунку функції пристосованості можливе застосування алгоритмів кешування даних для пришвидшення роботи даного алгоритму за рахунок використання попередньо обрахованих даних.

Для застосування такого кешування особливо важливо вибрати правильну структуру для зберігання даних по результатам обрахунків функцій пристосованості. Найкращим варіантом буде використання асоціативної хеш мапи, оскільки дана структура має часову складність вставки в $O(1)$ та часову складність пошуку $O(1)$. Також за рахунок використання асоціативного ключа дана колекція дозволяє побудувати пряме перетворення параметрів функції пристосованості в хеш ключ для збереження даних по обрахунку.

Висновки до розділу 3

Запропонована клас-орієнтована технологія селекції ознак дозволяє сформувати інформативний ансамбль ознак базуючись на послідовному алгоритмі відбору за критеріями міжкласової та внутрішньокласової дисперсії та об'єднаного відбору ознак з застосуванням генетичного відбору, або класифікатора ансамблевої структури.

Залежно від структури та потужності набору первинних ознак, технологія може бути реорганізована, для оптимізації часу виконання та кращого розподілу використання ресурсів з подальшим об'єднанням селекціонованих ознак в єдиний ансамбль.

Визначивши технологією клас-орієнтованої селекції ансамбль інформативних ознак, найоптимальнішою стратегією паралелізації обчислень стане подійно-орієнтована.

Застосування класифікатора Random Forest з оптимізацією функції голосування дозволяє отримати точність 85% на зображеннях отриманих за виділеною зоною інтересу.

Застосування матриць текстурних характеристик таких як GLHM, GLCM, GLSZM, GLDM, NGDTM дозволяє сформувати набір ознак, достатній для класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу.

РОЗДІЛ 4 СТРУКТУРНА ОПТИМІЗАЦІЯ КЛАСИФІКАТОРА В КЛАСІ АЛГОРИТМІВ RANDOM FOREST

У цьому розділі розглядається можливість зміни функції голосування методу випадкового лісу з застосуванням методу позиційного голосування. Даний метод дозволяє за рахунок зміни структури голосуючої функції розв'язати задачу підвищення точності голосування на основі колективу вирішувальних правил в класифікаторі ансамблевої структури на прикладі методу випадкового лісу.

Реалізація даного методу дає змогу оцінити вплив даної технології на точність голосування методу випадкового лісу в експериментальній задачі класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу легень.

4.1 Вибір ансамблевого класифікатора

Ансамблеві методи класифікації є потужним методом до підвищення точності моделей, оскільки вони об'єднують результати кількох базових алгоритмів для зменшення помилок та підвищення узагальнюючої точності. Використання ансамблів особливо ефективно в умовах високої варіативності вхідних даних. Одним з найефективніших методів є Random Forest. Він використовує поєднання кількох дерев прийняття рішень для отримання точних та надійних прогнозів[87-89].

Процес побудови дерев в даному алгоритмі відбувається за допомогою Bagging[90] механізму, що комбінує випадкові підмножини даних разом з випадковим вибором ознак. Таке навчання дозволяє урізноманітнити множину сформованих класифікаційних моделей та робить алгоритм більш стійким до локальних змін вхідних даних.

Завдяки випадковому вибору підмножини даних кожне дерево навчається на випадковій підвибірці даних, що запобігає надмірній залежності від вхідних даних. Щоб більше зменшити залежність від даних, на кожному вузлі дерева вибирається лише випадкова частина з усіх доступних ознак для поділу. Даний спосіб підбору

утворює менш корельовані дерева та покращує загальну продуктивність ансамблю[91].

Навчений ліс містить багато дерев, кожне з яких при вирішенні задачі класифікації дає результуючий клас. Результуючі класи різних дерев можуть відрізнятись між собою, тому в даного алгоритму є функція голосування, яка визначає клас відносно голосування всього лісу.

Стандартна реалізація алгоритму для задачі класифікації визначає рішення шляхом підрахунку більшості голосів. В задачі регресії – усередненням передбачених значень.

Даний підхід до голосування дає більш точний результат ніж єдине дерево, оскільки ліс здатен компенсувати випадкові помилки окремих дерев. Дана особливість найбільше проявляється на задачі класифікації високорозмірних даних, оскільки в лісі створюються прості дерева, що орієнтують на невеликий набір ознак. Єдина складна класифікаційна модель враховуватиме багато ознак, за рахунок чого страждатиме її пристосовуваність до змін.

4.2 Модифікація структури класифікатора методом групового урахування аргументів

Структурна схема класифікатора випадкового лісу представлена на рис. 4.1. За даною схемою кожне дерево голосує за певний клас і остаточний прогноз визначається як клас, за який проголосувало найбільше дерев. Такий підхід зменшує вплив слабких або перенавчених дерев на результат. Також дана схема голосування підвищує стійкість та точність моделі, оскільки помилки окремих дерев можуть компенсуватись рішеннями інших. За схемою з рис. 4.1. за мажоритарним голосуванням n дерев обирається клас 2 для вхідного об'єкту X .

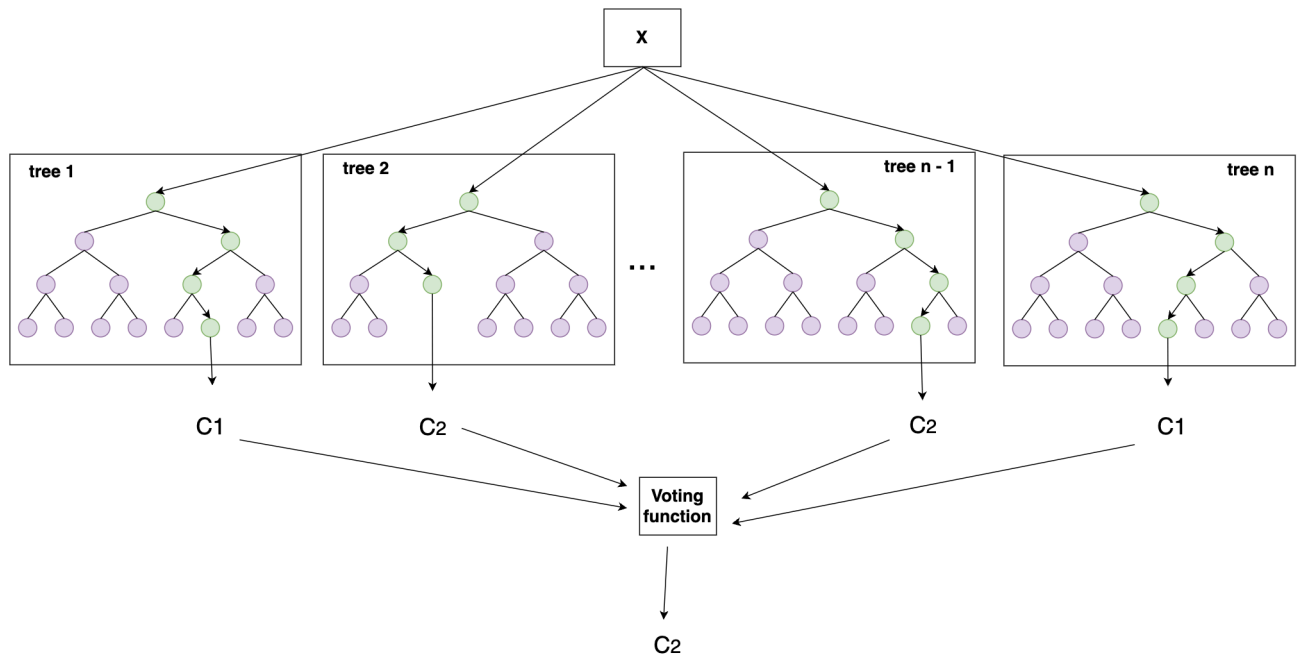


Рис. 4.1. Структурна схема класифікатора випадкового лісу. X – вхідний об’єкт, $C1$, $C2$ – результуючі класи.

Для покращення функції голосування та збільшення точності алгоритму класифікації застосовуються можливе застосування структурних оптимізацій. Вони можуть базуватись повноцінній зміні механізму голосування[92], що призводить до виключання дерев з результуючого лісу, або ж до надання деревам вагових коефіцієнтів[93, 94]. Структурна схема оптимізації з наданням вагових коефіцієнтів для дерев представлена на рис. 4.2. В даній схемі голос кожного з дерев зважується ваговим коефіцієнтом w , який застосовується до всіх голосувань даного дерева. Дана схема дозволяє не виключати в процесі навчання дерева з малою вагою, та застосовувати результати їх голосування. Розвитком даної схеми є застосування в [95] вагових коефіцієнтів до кожного з голосуючих маршрутів по дереву, ввівши таким чином k вагових коефіцієнтів для дерева, де k = кількості можливих маршрутів голосування в дереві.

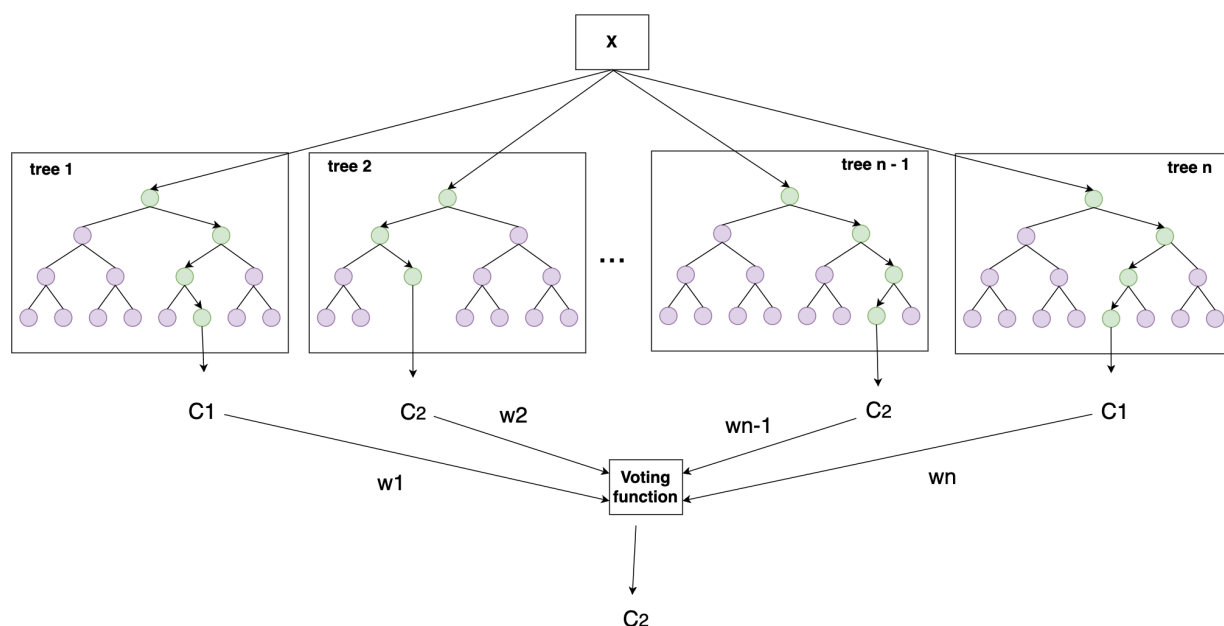


Рис. 4.2. Структурна схема оптимізованого класифікатора випадкового лісу з введенням вагових коефіцієнтів для дерев, X – вхідний об'єкт, $C1$, $C2$ – результуючі класи.

Оптимізаційні структурні техніки призводять до виключення дерев з лісу та приведення класифікатора до схеми зображеної на рис. 4.3.




Рис. 4.3. Структурна схема класифікатора випадкового лісу з виключенням дерев в процесі оптимізації.

Застосування методу групового урахування аргументів в комбінації з випадковим лісом можливе в задачі відбору ознак з найбільшою кореляцією та подальшим навчанням класифікатора на оптимальній підмножині ознак з оригінального набору.

Альтернативним застосуванням МГУА є підбір вагових коефіцієнтів дерев, для приведення структури класифікатора до зображеної на рис. 4.2. За рахунок вагових коефіцієнтів структура класифікатора зміниться, також дерева з нульовою вагою можуть бути виключені з лісу для оптимізації обчислень.

Застосування даної оптимізації в комбінації з класифікатором випадкового лісу та клас-орієнтованою технологією селекції ознак дозволило отримати точність класифікації представлену в таблиці 3.1. Підрахунок точності класифікації (Accuracy) здійснювався за формулою 4.1.

$$acc = \frac{1}{2} \left(\frac{N_1^+}{N_1} + \frac{N_2^+}{N_2} \right) \quad (4.1)$$

де, acc – точність класифікації, N_1, N_2 кількість областей інтересу в класі 1 та 2, N_1^+, N_2^+ – кількість правильно класифікованих областей інтересу в класі 1 та 2.

4.3 Застосування методу позиційного голосування до класифікатора Random Forest

Функція голосування методу випадкового лісу за замовчуванням є мажоритарною, де результуючий клас об'єкта визначається найбільшим числом голосів дерев. Мажоритарне голосування передбачає однаковий ступінь довіри до кожного з дерев в лісі. Однак кожне з дерев в класифікаторі помиляється з різною імовірністю. Розвиток цієї ідеї, а також можливість застосування функції голосування з власними ваговими коефіцієнтами до дерев в [95], сформував гіпотезу про компетентнісний принцип формування голосуючих суб'єктів та

застосування методу позиційного голосування при підборі вагових коефіцієнтів[95].

Голосуючим суб'єктом ансамблевого класифікатора випадкового лісу в загальній реалізації є дерево (рис. 4.4).




Рис. 4.4. Схема голосування дерева в класифікаторі випадкового лісу.

Кожне з дерев містить свій набір вузлових точок, які визначають маршрут голосування по дереву (виділений зеленим) базуючись на значеннях ознак. Розглянувши більш детально кожен з маршрутів – ми помітимо що всі вони закінчуються в листах дерева, які визначають приналежність об'єкта до певного класу. Для кожного з дерев отриманих в процесі навчання формується свій набір вузлових точок які залежать від власного набору ознак. Таким чином маршрут побудований по дереву дозволяє отримати результуючий клас в останньому листовому елементі. Кожен такий маршрут продукує власний результат

голосування, який є єдиним для одного дерева в процесі голосування за один об'єкт.

Розглянувши кожен окремий маршрут по дереву, як окремо сформований суб'єкт голосування (рис. 4.5.) можна виконати процедуру верифікації точності голосування за конкретним маршрутом та розрахувати компетентність такого маршруту окремо від дерева.




Рис. 4.5. Схема голосування в дереві з визначенням кожного листа як окремого голосуючого суб'єкта.

Заміна голосуючого суб'єкта дозволяє застосувати декілька варіацій голосування на деревах, а саме єдиний найбільш компетентний голос, зважене голосування з урахування компетентностей кожної з сутностей, та голосування фіксованою кількістю сутностей з найбільшою компетентністю. Визначивши в такій схемі голосуючу сутність як експерта отримаємо схему голосування зображену на рис 4.6.

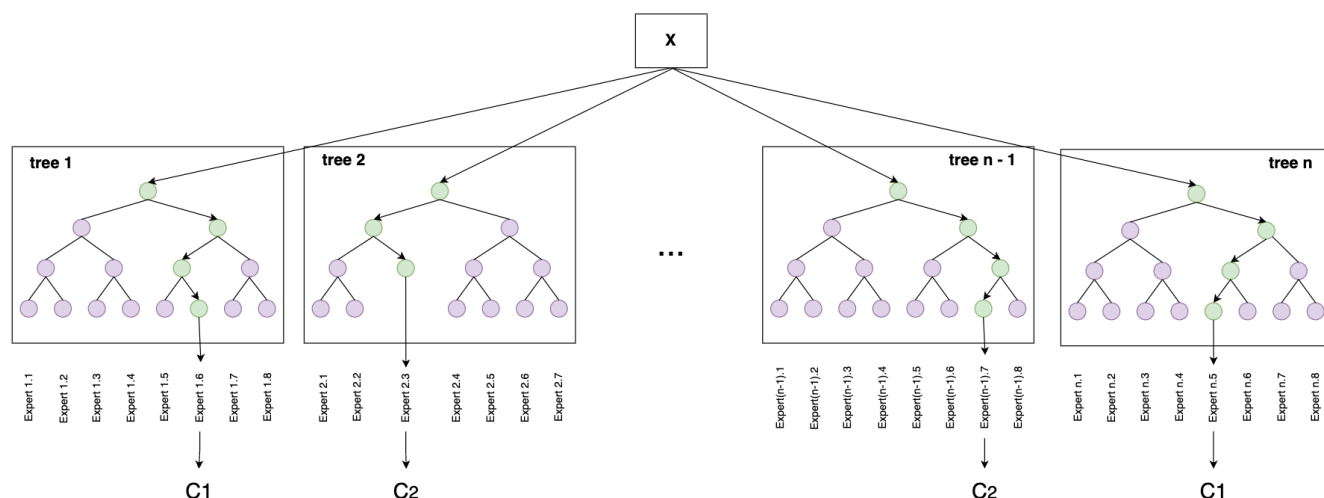


Рис. 4.6. Схема голосування класифікатора випадкового лісу з визначеними експертами.

Вагові коефіцієнти кожного з експертів можуть бути визначені не лише показником його компетентності, а й за допомогою інших способів. Одним з таких способів є застосування МГУА до впорядкованого набору експертів[93]. Даний підхід визначає вагу кожного з експертів в залежності від позиції його компетентності в процесі голосування. Таким чином функція голосування спочатку визначає експертів, які голосують за клас для конкретного вхідного об'єкту. Після чого експерти, які приймають участь в голосуванні впорядковуються за показником власної компетентності при голосування за свій клас. Впорядковані експерти отримують вагові коефіцієнти визначені в за МГУА в процесі навчання для кожної з позицій функції в голосування, за схемою зображеною на рис. 4.7. Оскільки вхідні об'єкти (Source 1, Source 2, ... Source n) будуть передаватись на однаковий набір дерев, то розмірність кількості маршрутів в них буде однакою, відповідно однаковою буде кількість позицій в впорядкованій функції голосування.

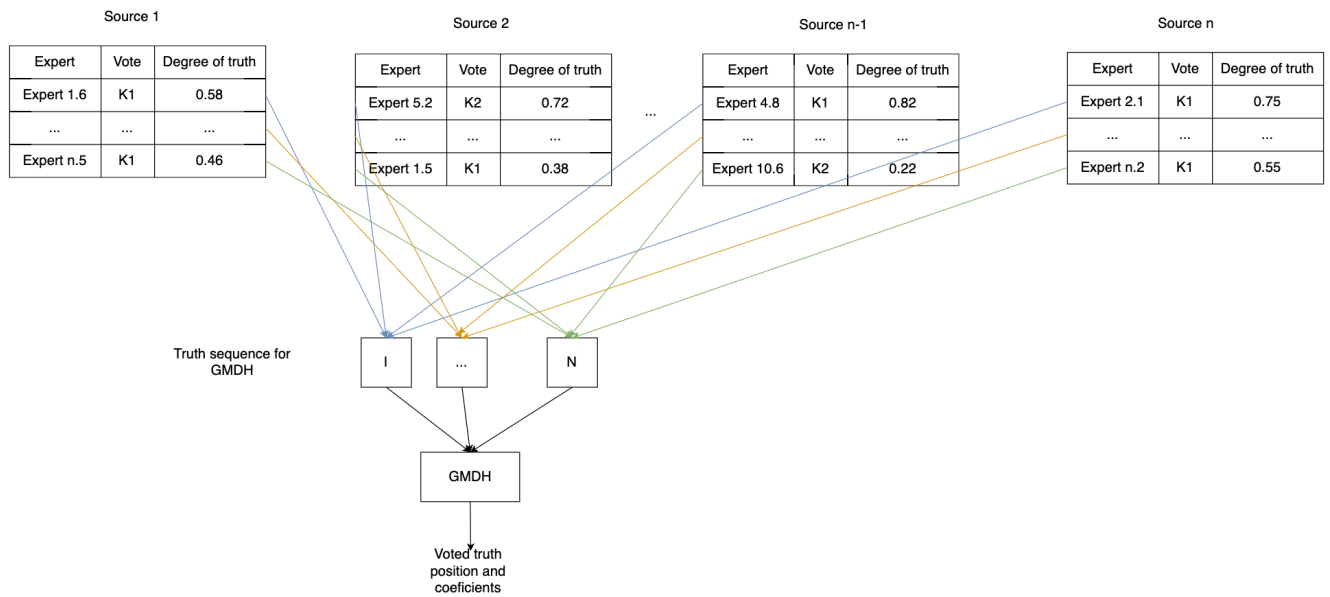


Рис. 4.7. Схема формування вагових коефіцієнтів для впорядкованих за компетентністю експертів.

Розрахунок вагових коефіцієнтів позицій за МГУА відбувається під час розрахунку структури та параметрів функції на об'єктах навчальної вибірки. Та тестується на об'єктах верифікаційної вибірки. Приклад збору статистичних даних за об'єктами навчальної вибірки та їх подальша передача для підбору вагових коефіцієнтів позицій зображена на рис. 4.8.

В даному випадку джерелом на зображенні виступає ансамбль ознак отриманих в рамках технології клас-орієнтованої селекції та їх абсолютні значення.

Обрахувавши їх для кожного з об'єктів навчальної вибірки та впорядкувавши послідовність голосувань експертів в єдину матрицю стає можливим застосування методу групового урахування аргументів для відбору ваг інформативності позицій в фінальній функції голосування. Також в МГУА передається вихідний вектор Y , що містить дані про клас вхідного зображення, на основі якого було виділено інформативний ансамбль ознак.

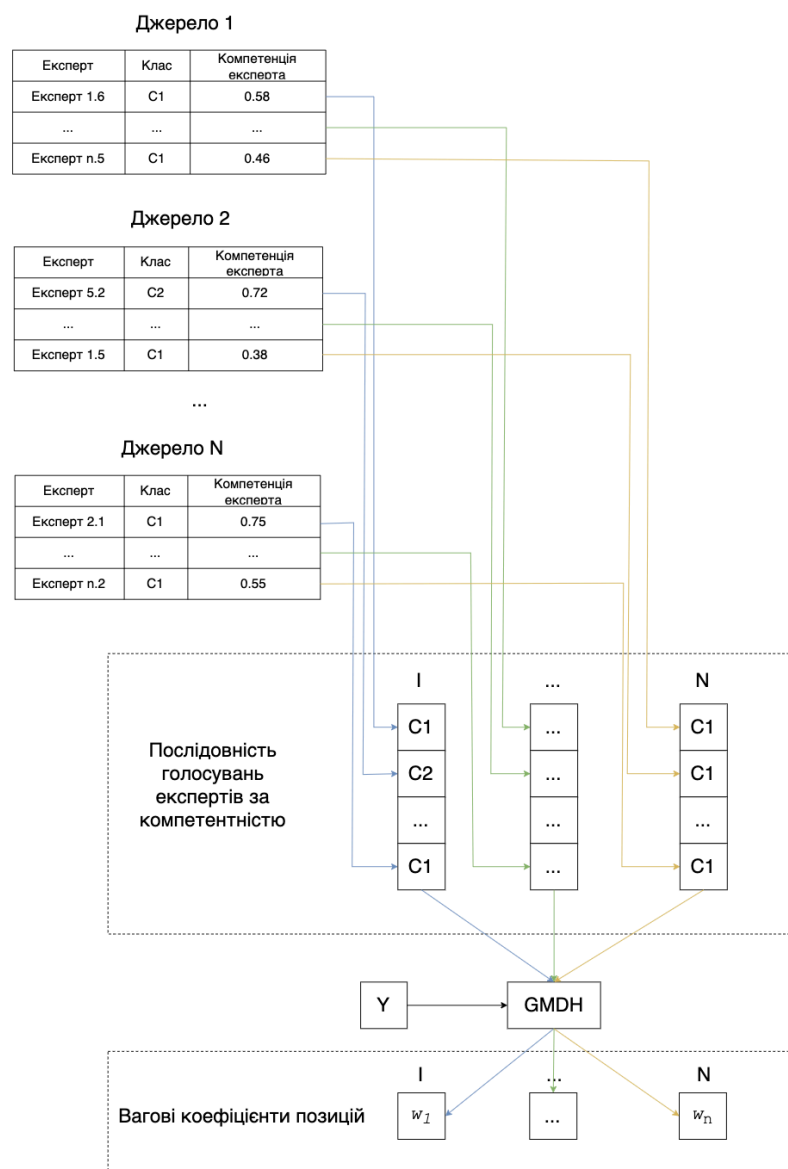


Рис. 4.8. Схема технології позиційного відбору ознак з зображень для передачі методу групового урахування аргументів

Після визначення вагових коефіцієнтів позицій при класифікації нового об'єкту буде сформована власна унікальна комбінація експертів, впорядкована за компетенціями. Після впорядкування до кожної з позицій буде застосована вага позиції, що визначатиме вклад експерту в фінальну функцію голосування.

Схема голосування для кожного нового об'єкту що передається в функцію класифікації зображено на рис. 4.9.

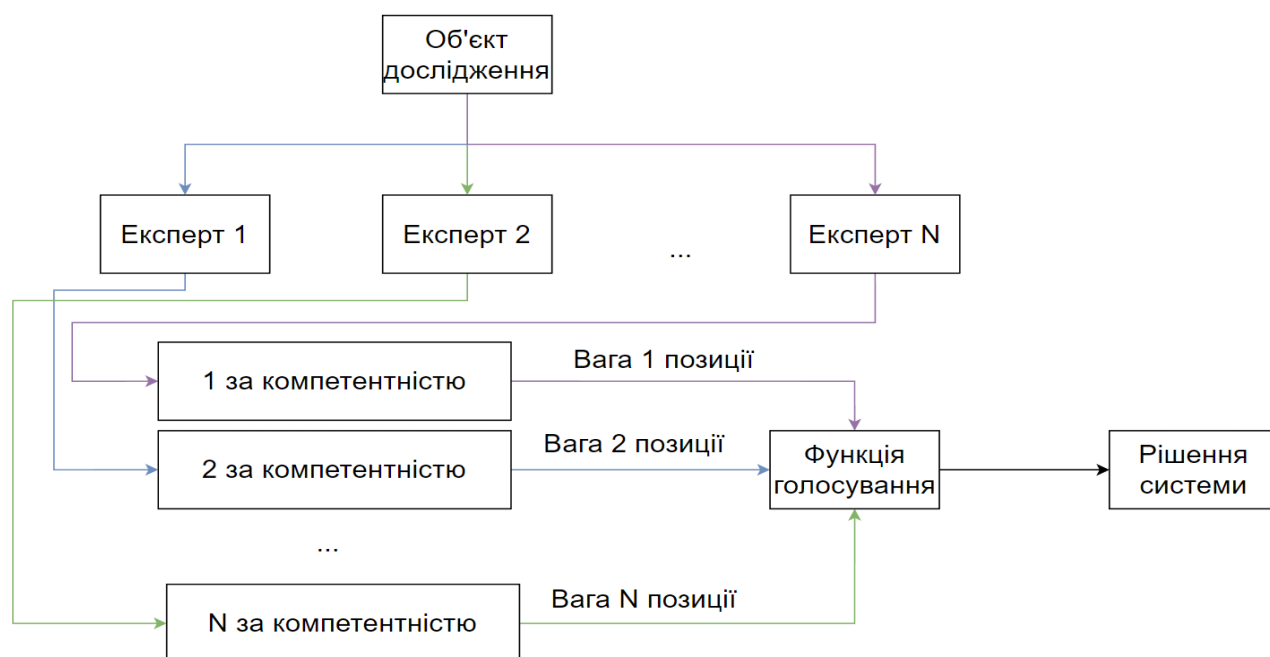


Рис. 4.9. Схема застосування алгоритму класифікації після завершення навчання.

Після завершення навчання та побудови структури класифікатора з визначеними ваговими коефіцієнтами позицій можлива класифікація нових об'єктів. Для кожного нового вхідного об'єкту буде сформований власний персоналізований набір експертів для голосування. Сформований набір експертів за схемою буде впорядкований за компетентністю, після чого до них буде застосовано ваговий коефіцієнт позиції обрахований за допомогою МГУА.

Оскільки експерти обираються індивідуально для кожного вхідного об'єкта, результат голосування є персоналізованим, тобто найкращим, який можна отримати саме для цього об'єкта з голосування членів колективу вирішальних правил[95].

Висновки до розділу 4

Застосування альтернативних функцій голосування до алгоритму випадкового лісу дозволяє збільшити точність класифікації. Вагові коефіцієнти в функції голосування дозволяють частково обмежити вагу окремих дерев, або виключити їх з фінального набору експертів.

Структура дерева класифікації дозволяє визначити віртуальних експертів, що представлятимуть маршрут по дереву, таким чином визначивши точність класифікації дерева при проходженні кожного з навчених маршрутів.

Розроблено оптимізацію функції голосування, що базується на введенні віртуальних експертів та їх персоналізованому впорядкуванні за рівнем компетентності. Застосування методу групового урахування аргументів дозволяє отримати ваги позицій голосуючих експертів, що дозволило збільшити точність класифікації з 85% до 88.2% за виділеною зоною інтересу.

Завдяки формуванню коефіцієнта довіри до експерта при голосуванні та їх впорядкуванню вдалось досягти створення їх персоналізованого набору. Позиціонування та введення ваги позиції зменшило вплив на функцію голосування експертів, що голосують в суперечливих ситуаціях за неправильний клас.

РОЗДІЛ 5 ДИФЕРЕНЦІАЦІЯ ЛІКАРСЬКО-ЧУТЛИВОЇ ТА ЛІКАРСЬКО-СТІЙКОЇ ФОРМИ ТУБЕРКУЛЬОЗУ НЕЙРОМЕРЕЖЕВИМИ МЕТОДАМИ

У даному розділі розглянуто застосування нейромережевих технологій до задачі диференціації лікарсько-стійкої та лікарсько-резистентної форми туберкульозу. Вирішення задачі класифікації розглянуто за допомогою застосування нейромережевого підходу з мережею ResNet-101.

Також розглянуто підхід з гібридизацією нейронної мережі з архітектурою Encoder-Decoder ResNet50 з додаванням ансамблевого класифікатора, що використовує на вході ознаки прихованого шару мережі.

Реалізація даних підходів дала змогу вирішити задачу диференціації з високою точністю, та спроектувати інформаційну систему з відображенням області ураження на зображенні томографії.

5.1 Глибока згорткова нейронна мережа ResNet-101

Згорткові нейронні мережі є одним основних методів класифікації зображень. З моменту свого набуття популярності вони широко застосовуються в задачах різних областей обробки даних, включаючи задачі медичної візуалізації та класифікації зображень.

Методи еволюціонували від перших застосувань до провідної технології класифікації зображень у 2012 році. Це стало можливим завдяки збільшенню обчислювальних ресурсів комп'ютерів та появі великих розмічених наборів даних. Архітектура таких мереж складається з шарів згортки, пулінгу та повнозв'язних. Така структура дозволяє мережі аналізувати та визначати патерни притаманні зображенню та робить мережу надзвичайно ефективною в класифікації.

З розвитком технології для задачі класифікації лікарсько-стійкої та лікарсько-чутливої форми туберкульозу застосовувались різні варіації згорткових нейронних мереж. Одним з перших прикладів є застосування архітектури VGG-

16[96] до задачі класифікації форм туберкульозу. Точність даної мережі становила 62.5%. Подальший розвиток архітектури та збільшення розміру навчальної вибірки дозволило покращити результат мережі з даною архітектурою до 92%[97].

Паралельно з розвитком даної архітектури до задачі диференціації форми туберкульозу легень застосовано згорткову мережу GoogLeNet[97], точність класифікації якої становить 90,6%. Окрім розглянутих вище архітектур мереж застосовувались спеціалізовані, призначені для роботи з медичними зображеннями на прикладі U-net[98]. Точність отримана на даній архітектурі становить 82%[99].

Розвиток нейромережевих технологій створює оновлені архітектури глибоких нейронних мереж. Застосування таких мереж до задачі класифікації може покращити результат попередніх досліджень, що дозволить покращити спосіб діагностування лікарсько-стійкої та лікарсько-чутливої форми туберкульозу.

Новою для даної задачі є архітектура мережі ResNet-101[99]. Дана мережа має 101 шар та використовує механізм skip connections для ефективного тренування моделі. Схематичне представлення архітектури даної мережі представлено на рис. 5.1[100].

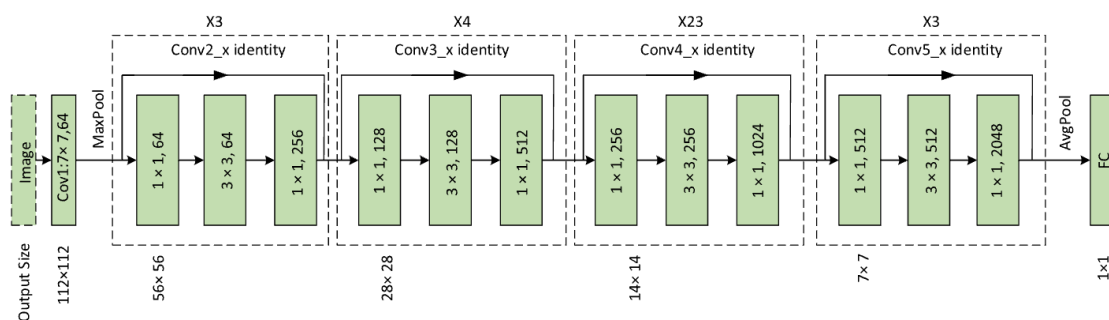


Рис. 5.1. Візуалізація архітектури ResNet-101

Застосування архітектури ResNet-101 для задачі класифікації лікарсько-стійкої та лікарсько-чутливої форми туберкульозу на оригінальних зображеннях дозволило отримати загальну точність класифікації в 96.36%. Більш детальні характеристики застосування даної мережі до задачі класифікації представлені в таблиці 5.1.

Таблиця 5.1

Показники застосування мережі з архітектурою ResNet-101

Назва показника	Значення
Загальна точність	96.36%
Точність для лікарсько-стійкого класу	96.7%
Точність для лікарсько-чутливого класу	96%
Recall	0,967
F1 score	0,967
Коефіцієнт Matthews	0,927
Кількість епох навчання	8

Схема застосування мережі до оригінальних зображень томографії представлена на рис. 5.2.

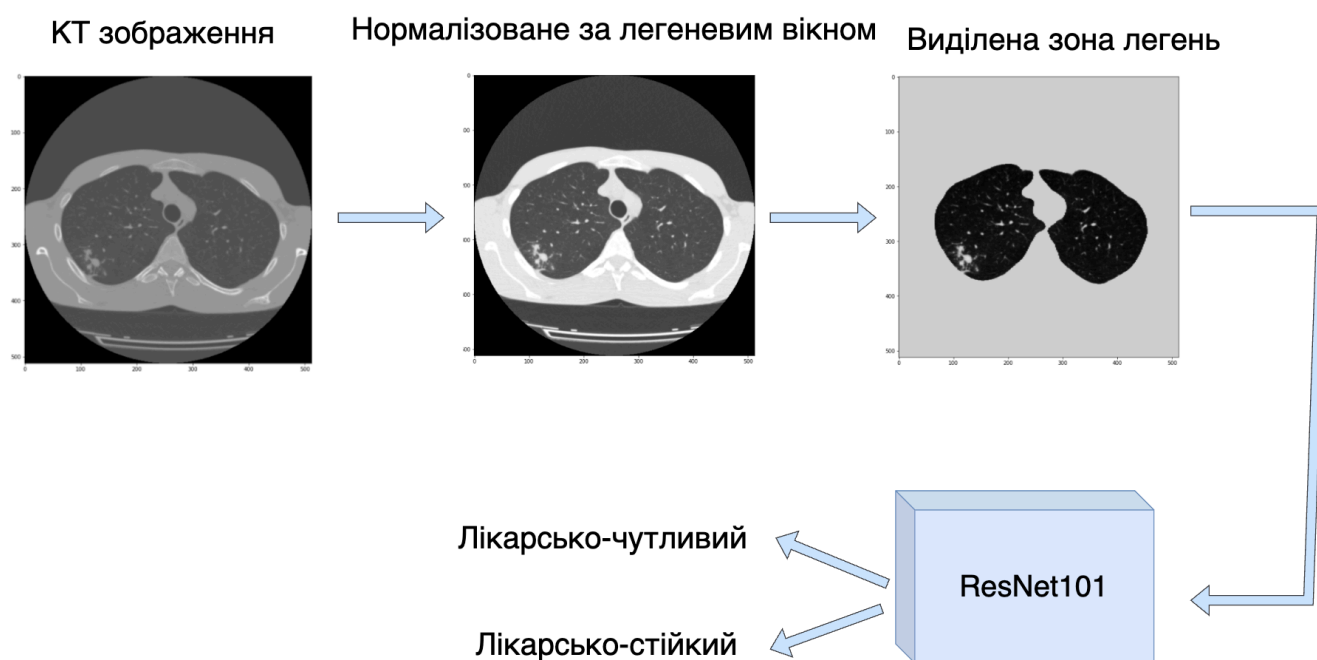


Рис. 5.2. Схема застосування мережі ResNet-101.

Дана архітектура мережі самостійно визначає набір інформативних ознак необхідних для класифікації зображень на лікарсько-чутливий та лікарсько-стійкий. Вхідним зображенням для мережі є нормалізоване до легеневого вікна

зображення КТ томографії з проведеною сегментацією та виділенням регіону легень.

Перед застосуванням нейронної мережі відбувається блок попередньої обробки даних зображення, що включає в себе приведення оригінального КТ зображення (512 x 512 пікселів) до нормалізованого в 256 градацій сірого зображення, з застосуванням фільтрації легеневим вікном (центр -600HU, ширина 1600HU). Такий блок попередньої обробки виділяє лише структури що містяться в легеневій області. Після формування нормалізованого в 256 градацій сірого зображення відбувається виділення області інтересу для мережі за допомогою попередньої сегментації зони легень за допомогою згорткової мережі. Застосувавши маску отриману в процесі сегментації до нормалізованого в 256 градацій сірого зображення формується вхідне зображення для мережі ResNet-101. Навчена мережа формує на виході результуючий клас – лікарсько-чутливий або лікарсько-стійкий туберкульоз.

5.2 Гібридизовані нейронні мережі

Гібридизація нейронних мереж можлива з застосуванням методів комбінування різних архітектур та з інтеграцією мережі до інших обчислювальних методів. Даний підхід дозволяє використати переваги кожного з компонентів гібриду та підвищити характеристики точності, узагальнення та ефективності обробки даних в процесі вирішення конкретної задачі.

Гібридизація нейронної мережі може відбуватись з об'єднанням архітектур. В морфологічно-лінійній мережі[101] в результаті гібридизації формується дві комбінації застосування та розподілу відповідальностей. Перша, де морфологічні нейрони використовуються для виділення ознак, а перцептрони – для формування вихідних рішень. Схема два навпаки застосовує перцептрони для виділення ознак, а морфологічні нейрони для класифікації. Об'єднання мереж дозволяє отримати кращу здатність до виділення ознак в наслідок чого вони потребують менше параметрів для навчання, в порівнянні з традиційними методами.

Гібридизація структури мережі може стосуватись не лише конвеєру обробки даних, а й самої структури. В мережах такого типу відбувається вдосконалення структури за рахунок застосування додаткового регуляторного механізму після процесу навчання. Комбінування мереж з самоорганізованими картами в випадку системи [102] дозволило за рахунок самоорганізованих карт відфільтрувати нетипові та нерелевантні дані та передати на мережу лише залишкові дані для прогнозування.

Зміни структури можуть застосовуватись не лише до окремих нейронів в складі мережі а й до рівнів. Гібридний пулінг є прикладом такої гібридизації[103]. В даній системі шар пулінгу випадково перемикається між стратегією max pooling та average pooling. Застосування такого підходу покращує узагальнюючу точність алгоритму, оскільки зміна пулінг стратегії призведе до зміни сигналу в подальших шарах мережі. Ще однією перевагою даного методу є хороше поєднання з техніками Dropout. Оскільки вони обидві дозволяють вплинути на регуляризацію мережі та запобігають перенавчанню мережі.

5.2.1 Encoder-Decoder мережі

Мережі Encoder-Decoder застосовуються для класифікації та сегментації медичних зображень, отримуючи високі показники точності. Структура таких мереж складається з двох основних модулів, що дозволяє використовувати переваги мереж інших типів та комбінувати їх, значно покращуючи процес аналізу зображення.

Перший модуль – Encoder. Він приймає вхідні дані та поступово зменшує їх розмірність через послідовність шарів, визначаючи при цьому ключові характеристики даних та створюючи приховане контекстне представлення.

Другий модуль – Decoder. Даний модуль отримує контекстне представлення та поступово відновлює вихідні дані. Даний модуль може працювати в регресивному режимі, прогнозуючи значення крок за кроком, використовуючи раніше згенеровані вихідні елементи.

Додатково в Decoder модулі може застосовуватись механізм уваги (Attention), який дозволяє модулі фокусуватись на найбільш релевантних частинах вхідних даних під час декодування.

Тип мережі який буде застосований в модулі Encoder визначається за форматом вхідних даних, та може бути рекурентною мережею для задач машинного перекладу, та згортковим в задачах обробки зображень. Структурна схема Encoder-Decoder мережі зображена на рис. 5.3.




Рис. 5.3. Структурна схема Encoder-Decoder мережі

Архітектура даної мережі містить прихований State шар в якому міститься набір найбільш інформативних ознак. Навчання такого класифікатора в задачі класифікації зони ураження на лікарсько-чутливий та лікарсько-стійкий туберкульоз формує в стейті набір ознак, що описують найінформативніші ділянки зображення.

Використання механізмів гібридизації до даної мережі дозволяє відділити від неї Decoder частину та навчити класифікатор за набором інформативних ознак з State шару.

5.2.2 Гібридизований класифікатор з архітектурою ResNet-50 Autoencoder

Гібридизація класифікатора виконується на ResNet-50 з застосуванням Autoencoder модифікації[104]. Детальна архітектура оригінальної мережі представлена на рис. 5.4.




Рис. 5.4. оригінальна схема мережі ResNet-50 виділенням Encoder-Decoder частини[104].

Для гібридизації даної мережі відбувається передача ознак з шару прихованого стану на класифікатор випадкового лісу з позиційною функцією голосування. Така передача відбувається з модифікацією зображеною на рис. 5.5.

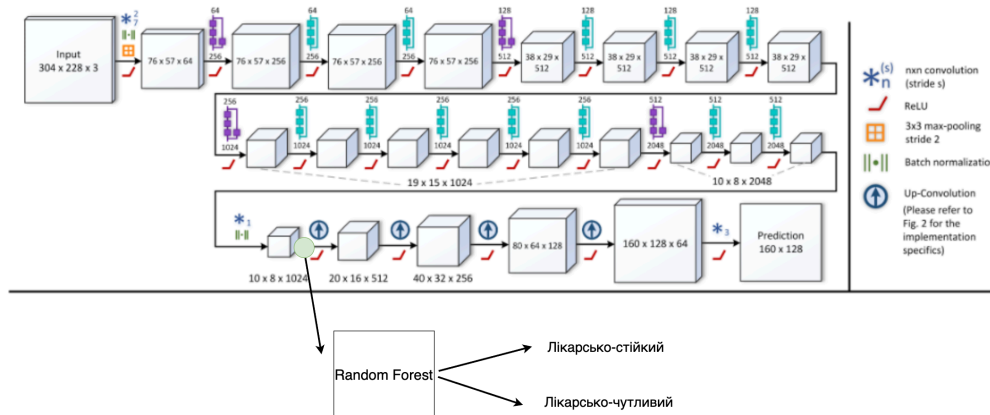


Рис. 5.5. Схема гібридизації мережі ResNet-50 за допомогою алгоритму випадкового лісу з позиційною функцією голосування.

Приведення архітектури під Encoder-Decoder тип дозволяє визначити набір ознак на певній глибині нейронної мережі. Виконавши навчання даної мережі в задачі сегментації області інтересу, в відповідності до наступної структурної схеми (рис. 5.5) вдалось отримати точність сегментації зображення в 91.36%, що є достатнім для визнання прихованого state шару даної мережі інформативним. Характеристики навчання даної мережі в задачі сегментації представлені в таблиці 5.2.

Таблиця 5.2

Показники точності сегментації мережі ResNet-50 з виділенням Encoder-Decoder

Назва показника	Значення
Загальна точність	91.56%
Recall	0,997
F1 score	0,677
Коефіцієнт Matthews	0,831
Кількість епох навчання	4

Проаналізувавши показники сегментації з таблиці 5.2 можна визначити що мережа повністю виділила зображення очікуваної зони інтересу (показник Recall = 0,997). Тому застосування прихованого шару як інформативного ансамблю для класифікатора є можливим. Також варто зазначити що за рештою показників результат сегментації є точним, однак виділена маска містить надлишкові пікселі, які до неї не мають відноситись. Це свідчить про дещо знижену специфічність моделі, що може бути обумовлено схожістю фонових елементів із зоною ураження.

Окремо слід підкреслити загальну точність моделі, яка становить 91,56%, що свідчить про високий рівень узгодження між сегментованими і референтними пікселями на рівні всього зображення. Проте слід враховувати, що цей показник може бути зміщений через домінування негативного класу.

Навчивши алгоритм класифікації на наборі інформативних ознак з застосуванням методу позиційного голосування вдалось отримати результати представлені в таблиці 5.3.

Таблиця 5.3

Показники точності класифікації гібридною системою

Назва показника	Значення
Загальна точність	94.54%
Точність для лікарсько-стійкого класу	95.1%
Точність для лікарсько-чутливого класу	94%
Recall	0,951
F1 score	0,951
Коефіцієнт Matthews	0,891

Загальна схема технології з застосуванням гібридизованого класифікатора зображено на рис. 5.6.

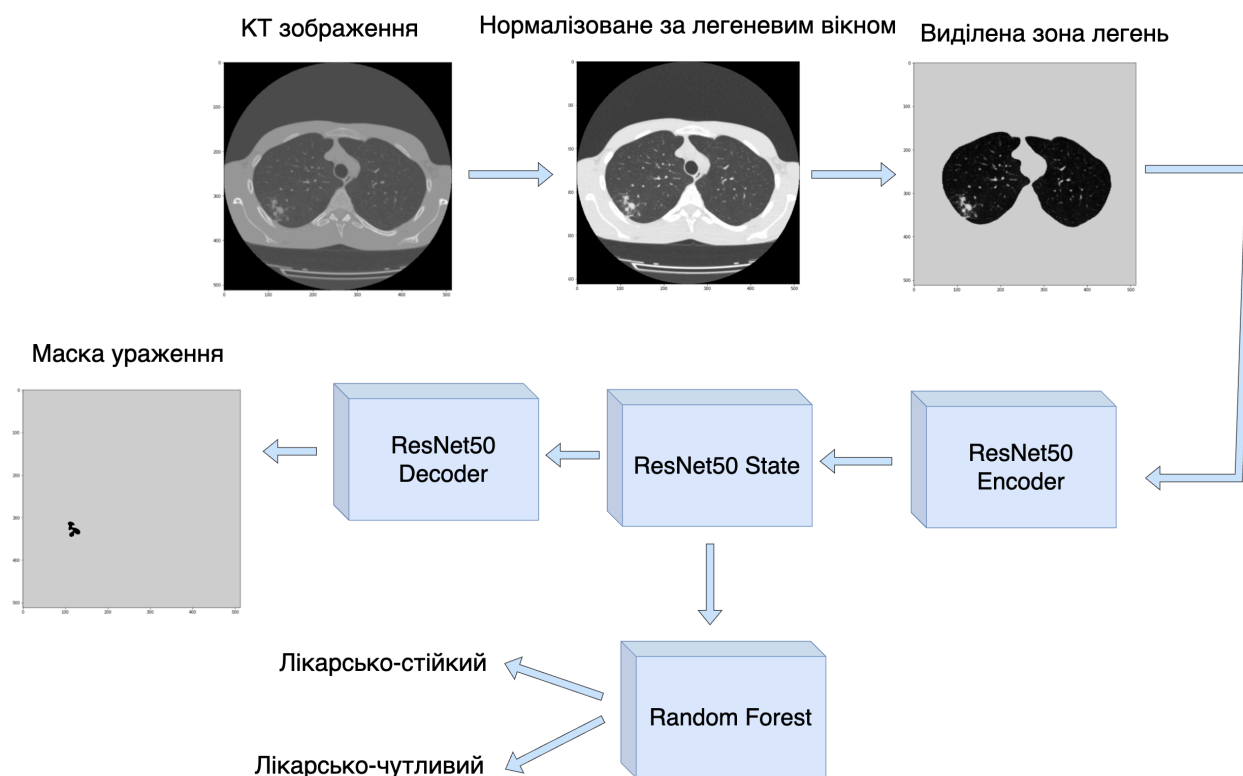


Рис. 5.6. Схема технології з застосуванням гібридизованого класифікатора.

Даний класифікатор працює з оригінальним зображенням КТ легень (512 x 512 пікселів). На першому етапі відбувається виділення легеневого вікна з центром в -600HU та шириною в 1600 HU. Виділивши структури в легеновому вікні відбувається нормалізація зображення за формулою 1.1. до 256 градацій сірого. Після приведення зображення до 256 градацій сірого воно передається на згорткову нейронну мережу[30] для виділення області легень. Результат сегментації легень накладається на оригінальне зображення виділяючи область інтересу гібридизованої модифікації ResNet50 з Encoder-Decoder архітектурою. Нейронна мережа працює як сегментатор та дає на виході зображення з виділеними областями ураження легень. Класифікатор навчений на прихованому стані мережі з функцією позиційного голосування дає результуючий клас ураження, у відповідності до схеми зображеної на рис. 5.6.

5.3 Структурне порівняння розроблених інформаційних технологій

Розроблені інформаційні технології демонструють високу точність класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу. Дані результати досягаються застосуванням попередньої обробки даних для виділення області легень.

Попередня обробка включає нормалізацію зображення за виділеним легеним вікном та сегментацію легень. Виділення легень як зони інтересу дозволяє алгоритмам фокусуватись лише на ознаках, що знаходяться в легеневій зоні.

Найбільшу точність класифікації на зображенні з зоною інтересу продемонструвала глибока згорткова мережа ResNet-101. Її структура дозволила ефективно виділити інформативні ознаки на навчитись класифікувати зображення в приналежності до класу. Однак ознаки на які опирається мережа в процесі своєї роботи не можуть бути накладені на зображення, тому дана система дозволяє поставити кінцевий діагноз без можливості виділення інформативних зон для лікаря.

Зміна системи від повністю нейромережевої (рис. 5.2) до гібридної (рис.5.5) дозволяє залишити формування набору інформативних ознак на згортковій частині нейронної мережі та навчити ансамблевий класифікатор Random Forest. Навчений класифікатор з високою точністю класифікує зображення на лікарсько-чутливий та лікарсько-стійкий клас. Використання додаткового виходу мережі (рис. 5.6) дозволяє з точністю в 91.56% виділити зону ураження легень для демонстрації її лікарю, та прийняття ним рішення по стратегії лікування пацієнта.

Застосування текстурних методів аналізу зображень, та клас-орієнтованої селекції дозволяє прослідкувати повний шлях прийняття рішення про виділення зони на зображенні та класифікації приналежності пацієнта до певного класу.

Статистична селекція текстурних ознак дозволяє побудувати інформативний ансамбль з текстурних ознак, а оборотність побудови матриці текстурних характеристик дозволяє однозначно відобразити на оригінальному зображенні набір пікселів, що приймали участь в класифікації та мають на неї прямий вплив. Дане виділення дозволяє продемонструвати лікарю додаткові зони підвищеної уваги, для більш точної діагностики пацієнта.

5.4 Практичне використання класифікатора

В результаті даної роботи побудовано та навчено три класифікаційні моделі, які дозволяють за набором вхідних даних пацієнта визначити його приналежність до класу лікарсько-чутливого та лікарсько-стійкого туберкульозу.

Для застосування даної технології потрібно отримати дані комп'ютерної томографії пацієнта та імпортувати їх в робоче середовище. Для вибору даних томографії передбачено елементи управління з вибором директорії, або файлу з даними томографії пацієнта. Приклади вибору директорії та файлів відображено на рис. 5.7. та рис. 5.8. Дані томографії зберігаються в форматах NIfTI та Dicom.

Формати NIfTI та Dicom є основними форматами зберігання даних про медичні зображення, тому розроблена система працює з кожним з них. NIfTI

дозволяє зберігати дані зображення як 3D або 4D об'єкт, що робить його зручним для роботи з даними одного пацієнта. Також даний формат дозволяє зберігати деякі метадані, за рахунок чого зберігаються просторові дані зображення.

Dicom в свою чергу є міжнародним стандартом для зберігання та обміну медичними даними. Однак кожне з зображень зберігається у вигляді 2D даних зрізу, що вимагає контролю над всіма даними послідовності, для коректної роботи з даними.

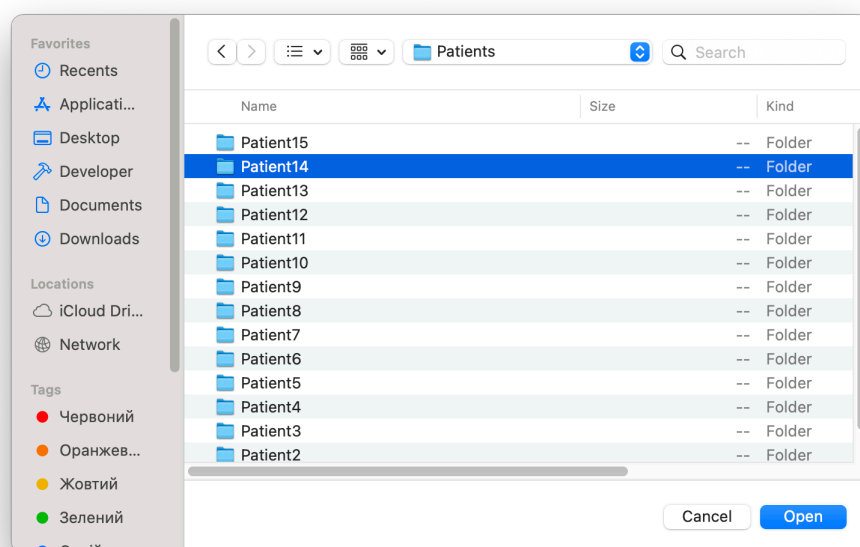


Рис 5.7. Приклад вибору директорії з даними КТ томографії легень

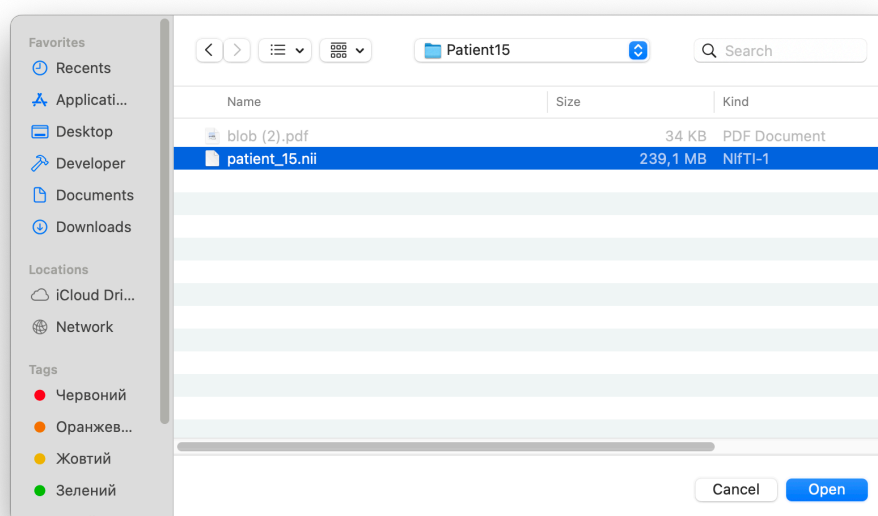


Рис. 5.8. Приклад завантаження даних пацієнта в форматі NifTI

Завантаживши дані пацієнта в систему можна переглянути кожен з зрізів даних томографії пацієнта, як зображено на рис. 5.9.



Рис. 5.9. Відображення оригінальних даних КТ пацієнта.

Переглянувши оригінальні дані зображень можна застосувати кожен з систем для аналізу даних пацієнта. Система виділить дані легень та відобразить область інтересу в якій буде проводитись дослідження, як відображено на рис 5.10. Для побудови області інтересу застосовується нейронна мережа Unet[30], також результат виділення можна переглянути для кожного з зображень в серії. Виділення легень відбувається з проведенням попередньої обробки кожного з зображень серії. На етапі попередньої обробки кожне вхідне зображення розмірністю 512 x 512 пікселів та з діапазоном характеристик щільності від $[-2000; 1000]$ приводиться до легеневого вікна, зберігаючи при цьому розмірність оригінального зображення. Після виділення легеневого вікна відбувається приведення в 256 градацій сірого, за формулою 1.1. Зображення в градаціях сірого

передається на нейронну мережу [30] для проведення сегментації. Перетворення над даними зображення в процесі попередньої обробки відображено на рис. 5.11.




Рис. 5.10. Відображення сегментованої області інтересу на оригінальному зображенні.



Рис 5.11. Перетворення над даними в процесі попередньої обробки

Провівши аналіз вхідних даних система відобразить результат про приналежність даних пацієнта до лікарсько-чутливого або лікарсько-резистентного класу (рис. 5.12).

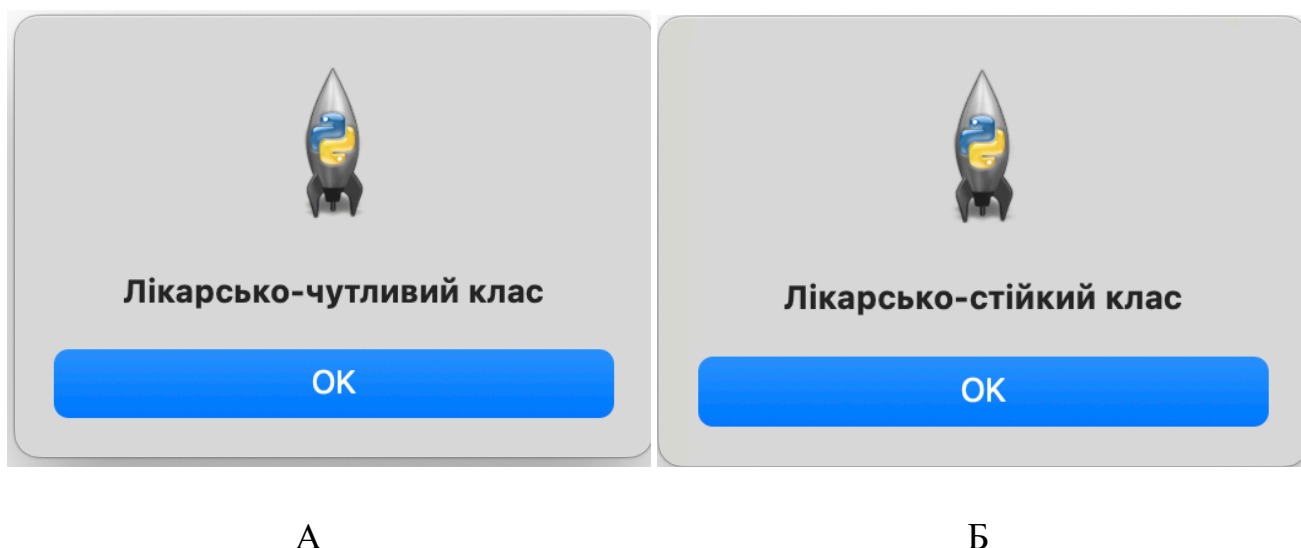




Рис. 5.12. Приклад результату: А – лікарсько-чутливий клас, Б – лікарсько-стійкий клас

Застосування методу клас-орієнтованої селекції з класифікатором випадкового лісу та оптимізацією методом позиційного голосування дозволяє виділити на зображенні пікселі, що приймають участь в процесі класифікації, та містять зону потенційного захворювання.

Застосування гібридизованої архітектури ResNet50 дозволяє окрім результуючого класу отримати маску з сегментацією області ураження. Маска формується з Decoder виходу алгоритму та дозволяє переглянути виділену зону, виділення якої можливе з прихованого стану Encoder-Decoder архітектури. Результат застосування відображено на рис. 5.12. Приклад відображення сегментованої ResNet50 маски на оригінальному зображенні відображено на рис. 5.13. Інформаційна система дозволяє змінювати прозорість такої маски, для можливості перегляду оригінальних яскравостей пікселів при мінімальному рівні яскравості маски, та заміщуючи пікселі виділеною маскою, для більш зручного перегляду результату сегментації.



А



Б

Рис. 5.13. Виділена зона ураження: А – з маскою прозорістю 70%, Б – з маскою прозорістю 10%.

В якості подальшого розвитку системи перед можливе впровадження системи визначення наявності туберкульозного ураження на зображенні томографії перед передачею такого зображення в дану систему класифікації, однак точність такого класифікатора потрібно досліджувати додатково.

Висновки до розділу 5

Застосування глибоких нейронних мереж дозволяє отримати високу точність класифікації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу. Однак рішення отримане мережею складно інтерпретувати на оригінальне зображення.

Рішення статистичних методів класифікації є більш інтерпретованим, та дозволяє лікарю звернути увагу на пікселі, що приймали участь в голосуванні за приналежність об'єкту до певного класу.

Гібридизація нейронної мережі з застосуванням ансамблевого класифікатора дозволяє отримати високу точність класифікації, та відобразити схему прийняття рішення. Система такого типу продемонструвала точність класифікації у 94.54%, однак вона не дозволяє відобразити пікселі, які потребують додаткової уваги на оригінальному зображенні.

Застосування нейромережевого підходу з архітектурою ResNet-101 дозволяє досягти найвищої точності класифікації у 96.36%. Однак дане рішення не інтерпретується на оригінальне зображення легень, та не дозволяє виділити пікселі, на які варто звернути увагу лікареві при прийнятті медичних рішень щодо діагнозу.

ВИСНОВКИ

У дисертації теоретично узагальнено та наведено нові способи розв'язку науково-технічної проблеми збільшення точності диференціації лікарсько-чутливої та лікарсько-стійкої форми туберкульозу на основі комбінування методів штучного інтелекту.

1. Виконано аналіз методів статистичної та нейромережевої обробки даних медичних зображень, визначено обмеження та запропоновано перспективні напрямки дослідження з побудови ансамблевих класифікаторів, нейронних мереж та застосування текстурного аналізу для виділення ознак з зображення.
2. Застосування методів текстурного аналізу до зображень комп'ютерної томографії легень дозволяє зменшити надлишковість та збільшити інформативність ознак отриманих з зображення.
3. Вдосконалено механізм селекціонування інформативних ознак для зменшення розмірності даних. Клас-орієнтована селекція ознак з відбором за міжкласовою та внутрішньокласовою дисперсією та застосування генетичного алгоритму за критерієм максимізації інформативності та мінімізації надмірності дозволяє отримати ансамбль з оптимального набору ознак.
4. Вдосконалено алгоритм голосування на основі колективу вирішувальних правил в класифікатора ансамблевої структури - Random Forest. Шляхом застосування методу групового урахування аргументів до позицій голосуючих елементів для збільшення персоналізації результату класифікації та підвищення точності з 85% до 88.2%.
5. Застосовано нейромережевий класифікатор ResNet для диференціації форми туберкульозу. Даний класифікатор завдяки наявності рекурентних зв'язків ефективно визначає ознаки та демонструє точність 96%.
6. Створено гібридизовану модель на базі глибокої нейронної мережі ResNet та класифікатора ансамблевого типу Random Forest. Вдосконалена функція позиційного голосування ефективно використала виділені мережею ознаки та дозволила досягти точності 95%.

7. Розроблено та впроваджено до використання у ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф. Г. Яновського НАМН України» рекомендаційну систему, що дозволяє збільшити інформативність даних для лікаря визначаючи наявність лікарсько-чутливої або лікарсько-стійкої форми туберкульозу за даними КТ зображень легень. Досягнута точність інформаційної системи становить 96%.

СПИСОК ЛІТЕРАТУРНИХ ДЖЕРЕЛ

1. Всесвітня організація охорони здоров'я. (2023). Звіти з туберкульозу. ВООЗ. <https://www.who.int/teams/global-tuberculosis-programme/tb-reports>
2. Solanki, P., Elton, L., Honeyborne, I., Park, M., Satta, G., McHugh, T. (2024). Improving the diagnosis of tuberculosis: old and new laboratory tools. Expert review of molecular diagnostics. <https://doi.org/10.1080/14737159.2024.2362165>.
3. Hamada, Y., Cirillo, D., Matteelli, A., Penn-Nicholson, A., Rangaka, M., Ruhwald, M. (2021). Tests for tuberculosis infection: landscape analysis. *European Respiratory Journal*, 58. <https://doi.org/10.1183/13993003.00167-2021>.
4. Nyendak, M., Lewinsohn, D., Lewinsohn, D. (2009). New diagnostic methods for tuberculosis. *Current Opinion in Infectious Diseases*, 22, 174–182. <https://doi.org/10.1097/QCO.0b013e3283262fe9>.
5. MacLean, E., Broger, T., Yerlikaya, S., Fernández-Carballo, B., Pai, M., Denking, C. (2019). A systematic review of biomarkers to detect active tuberculosis. *Nature Microbiology*, 4, 748 - 758. <https://doi.org/10.1038/s41564-019-0380-2>.
6. Skoura, E., Zumla, A., Bomanji, J. (2015). Imaging in tuberculosis. *International journal of infectious diseases: IJID: official publication of the International Society for Infectious Diseases*, 32, 87-93. <https://doi.org/10.1016/j.ijid.2014.12.007>.
7. Huy, V., Lin, C. (2023). An Improved Densenet Deep Neural Network Model for Tuberculosis Detection Using Chest X-Ray Images. *IEEE Access*, 11, 42839-42849. <https://doi.org/10.1109/ACCESS.2023.3270774>.
8. Abideen, Z., Ghafoor, M., Munir, K., Saqib, M., Ullah, A., Zia, T., Tariq, S., Ahmed, G., Zahra, A. (2020). Uncertainty Assisted Robust Tuberculosis Identification With Bayesian Convolutional Neural Networks. *IEEE Access*, 8, 22812-22825. <https://doi.org/10.1109/ACCESS.2020.2970023>.
9. Li, Z., Wu, F., Hong, F., Gai, X., Cao, W., Zhang, Z., Yang, T., Wang, J., Gao, S., Peng, C. (2022). Computer-Aided Diagnosis of Spinal Tuberculosis From CT Images Based on Deep Learning With Multimodal Feature Fusion. *Frontiers in Microbiology*, 13. <https://doi.org/10.3389/fmicb.2022.823324>.

10. Meraj, S. S., et al. (2019). Detection of pulmonary tuberculosis manifestation in chest X-rays using different convolutional neural network (CNN) models. *International Journal of Engineering and Advanced Technology*, 9(1), 2270–2275. <https://doi.org/10.35940/ijeat.a2632.109119>.
11. Vajda, S., Karagyris, A., Jäger, S., Santosh, K., Candemir, S., Xue, Z., Antani, S., Thoma, G. (2018). Feature Selection for Automatic Tuberculosis Screening in Frontal Chest Radiographs. *Journal of Medical Systems*, 42, 1-11. <https://doi.org/10.1007/s10916-018-0991-9>.
12. Li, Y., Li, K., Zhang, C., Montoya, J., Chen, G. (2019). Learning to Reconstruct Computed Tomography Images Directly From Sinogram Data Under A Variety of Data Acquisition Conditions. *IEEE Transactions on Medical Imaging*, 38, 2469-2481. <https://doi.org/10.1109/TMI.2019.2910760>.
13. Shi, L., Liu, B., Yu, H., Wei, C., Wei, L., Zeng, L., Wang, G. (2020). Review of CT image reconstruction open source toolkits. *Journal of X-ray science and technology*. <https://doi.org/10.3233/XST-200666>.
14. Mayo-Smith, W., Gupta, H., Ridlen, M., Brody, J., Clements, N., Cronan, J. (1999). Detecting hepatic lesions: the added utility of CT liver window settings. *Radiology*, 210 3, 601-4 . <https://doi.org/10.1148/RADIOLOGY.210.3.R99MR07601>.
15. Cui, X., Fan, S., Heuvelmans, M., Han, D., Zhao, Y., Groen, H., Dorrius, M., Oudkerk, M., De Bock, G., Vliegenthart, R., Ye, Z. (2020). Optimization of CT windowing for diagnosing invasiveness of adenocarcinoma presenting as sub-solid nodules. *European journal of radiology*, 128, 108981. <https://doi.org/10.1016/j.ejrad.2020.108981>.
16. Pelletier-Galarneau, M., Martineau, P., Zuckier, L., Pham, X., Lambert, R., Turpin, S. (2017). 18F-FDG-PET/CT Imaging of Thoracic and Extrathoracic Tuberculosis in Children. *Seminars in nuclear medicine*, 47 3, 304-318. <https://doi.org/10.1053/j.semnuclmed.2016.12.003>.
17. Haq, I., Mazhar, T., Nasir, Q., Razzaq, S., Mohsan, S., Alsharif, M., Alkahtani, H., Aljarbouh, A., Mostafa, S. (2022). Machine Vision Approach for Diagnosing

- Tuberculosis (TB) Based on Computerized Tomography (CT) Scan Images. *Symmetry*, 14, 1997. <https://doi.org/10.3390/sym14101997>.
18. Li, Z., Wang, B., Du, B., Sun, Q., Wang, D., Wei, R., Li, C., Zhu, C., Jia, H., Xing, A., Zhang, Z., Pan, L., Hou, D. (2024). The incremental value of Mycobacterium tuberculosis trace nucleic acid detection in CT-guided percutaneous biopsy needle rinse solutions for the diagnosis of tuberculosis. *Frontiers in Microbiology*, 15. <https://doi.org/10.3389/fmicb.2024.1335526>.
 19. Zeb, I., Li, D., Nasir, K., Katz, R., Larijani, V. N., Budoff, M. J. (2012). Computed tomography scans in the evaluation of fatty liver disease in a population based study: the multi-ethnic study of atherosclerosis. *Academic radiology*, 19(7), 811–818. <https://doi.org/10.1016/j.acra.2012.02.022>.
 20. Duc, T., Huong, N. (2023). Improvement of Vehicle detection and classification performance with Region of Interest. *ITEJ (Information Technology Engineering Journals)*. <https://doi.org/10.24235/itej.v8i1.116>.
 21. Khairuzzaman, A., Chaudhury, S. (2019). Masi entropy based multilevel thresholding for image segmentation. *Multimedia Tools and Applications*, 78, 33573 - 33591. <https://doi.org/10.1007/s11042-019-08117-8>.
 22. Mousavirad, S., Ebrahimpour-Komleh, H. (2020). Human mental search-based multilevel thresholding for image segmentation. *Appl. Soft Comput.*, 97, 105427. <https://doi.org/10.1016/J.ASOC.2019.04.002>.
 23. Pierre, F., Amendola, M., Bigeard, C., Ruel, T., Villard, P. (2021). Segmentation with Active Contours. *Image Process. Line*, 11, 120-141. <https://doi.org/10.5201/ipol.2021.298>.
 24. Yushkevich, P., Piven, J., Hazlett, H., Smith, R., Ho, S., Gee, J., Gerig, G. (2006). User-guided 3D active contour segmentation of anatomical structures: Significantly improved efficiency and reliability. *NeuroImage*, 31, 1116-1128. <https://doi.org/10.1016/j.neuroimage.2006.01.015>.
 25. Guo, X., Schwartz, L., Zhao, B. (2019). Automatic Liver Segmentation by Integrating Fully Convolutional Networks into Active Contour Models. *Medical physics*. <https://doi.org/10.1002/mp.13735>.

26. Moccia, S., De Momi, E., Mattos, L. S. (2014). A combined approach to 3D medical image segmentation using marker-based watersheds and active contours: the active watershed method. *International Journal of Computer Assisted Radiology and Surgery*, 9(5), 785–797.
27. Wang, L., Chen, G., Shi, D., Chang, Y., Chan, S., Pu, J., Yang, X. (2018). Active contours driven by edge entropy fitting energy for image segmentation. *Signal processing*, 149, 27-35. <https://doi.org/10.1016/J.SIGPRO.2018.02.025>.
28. Wang, L., Chang, Y., Wang, H., Wu, Z., Pu, J., Yang, X. (2017). An active contour model based on local fitted images for image segmentation. *Information sciences*, 418-419, 61-73. <https://doi.org/10.1016/j.ins.2017.06.042>.
29. Mancas, M., Gosselin, B., Macq, B. (2005). Segmentation using a region-growing thresholding., 5672. <https://doi.org/10.1117/12.587995>.
30. Hofmanninger, J., Prayer, F., Pan, J., Langs, G. (2020). Automatic lung segmentation in routine imaging is primarily a data diversity problem, not a methodology problem. *European Radiology Experimental*, 4(50). <https://doi.org/10.1186/s41747-020-00173-2>.
31. Bharati, M., Liu, J., MacGregor, J. (2004). Image texture analysis: methods and comparisons. *Chemometrics and Intelligent Laboratory Systems*, 72, 57-71. <https://doi.org/10.1016/J.CHEMOLAB.2004.02.005>.
32. Oberholzer, M., Östreicher, M., Christen, H., Brühlmann, M. (1996). Methods in quantitative image analysis. *Histochemistry and Cell Biology*, 105, 333-355. <https://doi.org/10.1007/BF01463655>.
33. Zheng, G., Li, X., Zhou, L., Yang, J., Ren, L., Chen, P., Zhang, H., Lou, X. (2018). Development of a Gray-Level Co-Occurrence Matrix-Based Texture Orientation Estimation Method and Its Application in Sea Surface Wind Direction Retrieval From SAR Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 56, 5244-5260. <https://doi.org/10.1109/TGRS.2018.2812778>.
34. Park, B., Jang, W., Yoo, S. (2016). Texture Analysis of Supraspinatus Ultrasound Image for Computer Aided Diagnostic System. *Healthcare Informatics Research*, 22, 299 - 304. <https://doi.org/10.4258/hir.2016.22.4.299>.

35. Liu, X., Aldrich, C. (2022). Deep Learning Approaches to Image Texture Analysis in Material Processing. *Metals*. <https://doi.org/10.3390/met12020355>.
36. Singh, A., Regenauer-Lieb, K., Walsh, S., Armstrong, R., Griethuysen, J., Mostaghimi, P. (2020). On Representative Elementary Volumes of Grayscale Micro-CT Images of Porous Media. *Geophysical Research Letters*, 47. <https://doi.org/10.1029/2020GL088594>.
37. Sathish, D., Kamath, S., Prasad, K., Kadavigere, R. (2018). Texture analysis of breast thermograms using neighbourhood grey tone difference matrix. *Int. J. Bioinform. Res. Appl.* <https://doi.org/10.1504/IJBRA.2018.10009348>.
38. Delahaies, A., Landré, J., Morain-Nicolier, F. (2024). Texture Classification Using Local Dissimilarity Maps of Gray-Level Co-Occurrence Matrices. 2024 32nd European Signal Processing Conference (EUSIPCO), 1947-1951.
39. Tatsunidas. GLCM (Texture analysis using GLCM). Qiita. Retrieved February 11, 2025, from <https://qiita.com/tatsunidas/items/fd49ef6ac7c3deb141e0>.
40. Tang, X. (1998). Texture information in run-length matrices. *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*, 7 11, 1602-9. <https://doi.org/10.1109/83.725367>.
41. Hsu, S., Chen, I., Huang, C., 2015. Image classification using pairwise local observations based Naive Bayes classifier. 2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA), pp. 444-452. <https://doi.org/10.1109/APSIPA.2015.7415311>.
42. Wang, M., Zhang, X. (2024). Quantum Bayes classifiers and their application in image classification. *Physical Review A*. <https://doi.org/10.1103/physreva.110.012433>.
43. Kheddam, R., Boudissa, Y., Belhadj-Aissa, A., 2017. Supervised classification of remotely sensed images using Bayesian network models and Kruskal algorithm., 10427. <https://doi.org/10.1117/12.2278122>.
44. Hsu, S., Chen, I., Huang, C., 2017. Image Classification Using Naive Bayes Classifier With Pairwise Local Observations. *J. Inf. Sci. Eng.*, 33, pp. 1177-1193.

45. Keller, J., Gray, M., Givens, J. (1985). A fuzzy K-nearest neighbor algorithm. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15, 580-585. <https://doi.org/10.1109/TSMC.1985.6313426>.
46. Moustakidis, S., Mallinis, G., Koutsias, N., Theocharis, I., Petridis, V. (2012). SVM-Based Fuzzy Decision Trees for Classification of High Spatial Resolution Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 50, 149-169. <https://doi.org/10.1109/TGRS.2011.2159726>.
47. IBM. What is random forest? IBM. Retrieved February 4, 2025, from <https://www.ibm.com/think/topics/random-forest>.
48. Tan, X., Zhang, Y., Tang, S., Shao, J., Wu, F., Zhuang, Y. (2012). Logistic Tensor Regression for Classification. , 573-581. https://doi.org/10.1007/978-3-642-36669-7_70.
49. Maheshwari, V. (2018, December 21). Logistic regression. *DataDrivenInvestor*. Retrieved February 4, 2025, from <https://medium.datadriveninvestor.com/logistic-regression-18afd48779ce>.
50. Chauhan, N. S. (2020, June 3). Introduction to convolutional neural networks. *KDnuggets*. <https://www.kdnuggets.com/2020/06/introduction-convolutional-neural-networks.html>.
51. Azuri, I., Goldian, I., Regev-Rudzki, N., Fantner, G., Cohen, S. R. (2021). The role of convolutional neural networks in scanning probe microscopy: A review. *Beilstein Journal of Nanotechnology*, 12(1), 878–901. <https://doi.org/10.3762/bjnano.12.66>
52. Li, Z., Liu, F., Yang, W., Peng, S., Zhou, J. (2020). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33, 6999-7019. <https://doi.org/10.1109/TNNLS.2021.3084827>.
53. Obla, S., Gong, X., Aloufi, A., Hu, P., Takabi, D. (2020). Effective Activation Functions for Homomorphic Evaluation of Deep Neural Networks. *IEEE Access*, 8, 153098-153112. <https://doi.org/10.1109/ACCESS.2020.3017436>.
54. GeeksforGeeks. Activation functions in neural networks. Retrieved February 5, 2025, from <https://www.geeksforgeeks.org/activation-functions-neural-networks>.

55. Wang, Y., Li, Y., Song, Y., Rong, X. (2020). The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition. *Applied Sciences*. <https://doi.org/10.3390/app10051897>.
56. Khadim, E., Shah, S., Wagan, R. (2021). Evaluation of Activation Functions in CNN Model for Detection of Malaria Parasite using Blood Smear Images. 2021 International Conference on Innovative Computing (ICIC), 1-6. <https://doi.org/10.1109/icic53490.2021.9693056>.
57. Rahman, T., Khandakar, A., Kadir, M., Islam, K., Islam, K., Mazhar, R., Hamid, T., Islam, M., Mahbub, Z., Ayari, M., Chowdhury, M. (2020). Reliable Tuberculosis Detection Using Chest X-Ray With Deep Learning, Segmentation and Visualization. *IEEE Access*, 8, 191586-191601. <https://doi.org/10.1109/ACCESS.2020.3031384>.
58. Kim, T., Krichen, M., Ojo, S., Alamro, M., Sampedro, G. (2024). TSSG-CNN: A Tuberculosis Semantic Segmentation-Guided Model for Detecting and Diagnosis Using the Adaptive Convolutional Neural Network. *Diagnostics*, 14. <https://doi.org/10.3390/diagnostics14111174>.
59. Gao, R., Huo, Y., Bao, S., Tang, Y., Antic, S., Epstein, E., Deppen, S., Paulson, A., Sandler, K., Massion, P., Landman, B. (2020). Multi-path x-D recurrent neural networks for collaborative image classification. *Neurocomputing*, 397, 48-59. <https://doi.org/10.1016/j.neucom.2020.02.033>.
60. GeeksforGeeks. Introduction to recurrent neural network (RNN). Retrieved February 5, 2025, from <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>.
61. Gujrathi, G., & Yadav, M. (2024). Enhanced Tuberculosis Detection in Chest X-Rays Using Optimal Feature Selection with Hybrid Binary Particle Swarm Optimization (HBPSO) and a Dual Classifier Framework Combining LSTM and Spiking Neural Networks. *South Eastern European Journal of Public Health*. <https://doi.org/10.70135/seejph.vi.2080>.
62. Duong, L., Le, N., Tran, T., Ngo, V., & Nguyen, P. (2021). Detection of tuberculosis from chest X-ray images: Boosting the performance with vision transformer

- and transfer learning. *Expert Syst. Appl.*, 184, 115519. <https://doi.org/10.1016/J.ESWA.2021.115519>.
63. Gao, F., Wu, T., Chu, X., Yoon, H., Xu, Y., Patel, B. (2020). Deep Residual Inception Encoder–Decoder Network for Medical Imaging Synthesis. *IEEE Journal of Biomedical and Health Informatics*, 24, 39-49. <https://doi.org/10.1109/JBHI.2019.2912659>.
 64. Kumar, A. (2024, January 12). Demystifying encoder decoder architecture neural network. *Analytics Yogi*. Retrieved from <https://vitalflux.com/encoder-decoder-architecture-neural-network/>.
 65. MLNotes. (2025, February 6). Data science interview challenge 21C. Substack. Retrieved from <https://mlnotes.substack.com/p/data-science-interview-challenge-21c>.
 66. Tsai, J. (2019). New feature selection and voting scheme to improve classification accuracy. *Soft Computing*, 23. <https://doi.org/10.1007/s00500-019-03757-2>.
 67. Bates, S., Hastie, T., Tibshirani, R. (2021). Cross-Validation: What Does It Estimate and How Well Does It Do It?. *Journal of the American Statistical Association*, 119, 1434 - 1445. <https://doi.org/10.1080/01621459.2023.2197686>.
 68. Hakim, B. (2019). Tuberculosis detection analysis using texture features on CXRs images. , 2092, 040001. <https://doi.org/10.1063/1.5096734>.
 69. Hu, Y., Liang, Z., Song, B., Han, H., Pickhardt, P., Zhu, W., Duan, C., Zhang, H., Barish, M., Lascarides, C. (2016). Texture Feature Extraction and Analysis for Polyp Differentiation via Computed Tomography Colonography. *IEEE Transactions on Medical Imaging*, 35, 1522-1531. <https://doi.org/10.1109/TMI.2016.2518958>.
 70. Govindarajan, S., Manuskandan, S., Swaminathan, R. (2023). Diagnostics of Multi Drug Resistant Tuberculosis in Chest Radiographs using Local Textures Extreme Gradient Boosting. *Current Directions in Biomedical Engineering*, 9, 721 - 724. <https://doi.org/10.1515/cdbme-2023-1181>.
 71. Matviichuk, O., Nosovets, O., Davydko, O. (2021). Class-oriented features selection technology in medical images classification problem on the example of tuberculosis diagnostics. 2021 IEEE 16th International Conference on Computer Sciences

- and Information Technologies (CSIT), 22–25.
<https://doi.org/10.1109/CSIT52700.2021.9648747>.
72. Матвійчук О, Настенко Є, (2023) Класифікація туберкульозних уражень легень методом позиційного голосування за даними комп'ютерної томографії. Біомедична інженерія і технологія 11. doi: 10.20535/2617-8974.2023.11.287885.
 73. Wickramasinghe, C. S., Marino, D. L., Manic, M. (2021). ResNet autoencoders for unsupervised feature learning from high-dimensional data: Deep models resistant to performance degradation. IEEE Access, 9, 40511–40520.
<https://doi.org/10.1109/ACCESS.2021.3064819>.
 74. Peng, H., Long, F., Ding, C. (2005). Minimum redundancy feature selection from microarray gene expression data. Journal of Bioinformatics and Computational Biology, 3(2), 185–205. <https://doi.org/10.1142/S0219720005001004>.
 75. Jiménez, F., Sánchez, G., Palma, J., Miralles-Pechuan, L., Botía, J. (2022). Multivariate feature ranking with high-dimensional data for classification tasks. IEEE Access, PP, 1-1. <https://doi.org/10.1109/ACCESS.2022.3180773>.
 76. Kiang, M. (2003). A comparative assessment of classification methods. Decis. Support Syst., 35, 441-454. [https://doi.org/10.1016/S0167-9236\(02\)00110-0](https://doi.org/10.1016/S0167-9236(02)00110-0).
 77. Hasan, R., Chu, C. (2022). Noise in Datasets: What Are the Impacts on Classification Performance?. , 163-170. <https://doi.org/10.5220/0010782200003122>.
 78. Pourkamali-Anaraki, F., Bennette, W. (2021). Adaptive Data Compression for Classification Problems. IEEE Access, PP, 1-1.
<https://doi.org/10.1109/ACCESS.2021.3130551>.
 79. Carneiro, M., Zhao, L. (2018). Organizational Data Classification Based on the Importance Concept of Complex Networks. IEEE Transactions on Neural Networks and Learning Systems, 29, 3361-3373. <https://doi.org/10.1109/TNNLS.2017.2726082>.
 80. Garg, M., Dhiman, G. (2020). A novel content-based image retrieval approach for classification using GLCM features and texture fused LBP variants. Neural Computing and Applications, 33, 1311 - 1328. <https://doi.org/10.1007/s00521-020-05017-z>.
 81. Yani, M., Irawan, B., Setiningsih, C. (2019). Application of transfer learning using convolutional neural network method for early detection of Terry's nail. Journal of

- Physics: Conference Series, 1201(1), 012052. <https://doi.org/10.1088/1742-6596/1201/1/012052>.
82. (2018). Spearman's rank correlation coefficient. *British Medical Journal*, 362. <https://doi.org/10.1136/bmj.k4131>.
 83. Ivakhnenko, A. G., Stepashko, V. S. (1985). Noise-immunity modeling. *Naukova Dumka*.
 84. Xue, G., Feng, H. (2018). A new parallel algorithm for solving parabolic equations. *Advances in Difference Equations*, 2018. <https://doi.org/10.1186/s13662-018-1617-8>.
 85. Reeves, C. (1995). A genetic algorithm for flowshop sequencing. *Comput. Oper. Res.*, 22, 5-13. [https://doi.org/10.1016/0305-0548\(93\)E0014-K](https://doi.org/10.1016/0305-0548(93)E0014-K).
 86. Goldberg, D., Kuo, C. (1987). Genetic Algorithms in Pipeline Optimization. *Journal of Computing in Civil Engineering*, 1, 128-141. [https://doi.org/10.1061/\(ASCE\)0887-3801\(1987\)1:2\(128\)](https://doi.org/10.1061/(ASCE)0887-3801(1987)1:2(128)).
 87. Dockhorn, A., Lucas, S. (2022). Choosing Representation, Mutation, and Crossover in Genetic Algorithms. *IEEE Computational Intelligence Magazine*, 17, 52-53. <https://doi.org/10.1109/MCI.2022.3199626>.
 88. Parmar, A., Katariya, R., Patel, V. (2018). A Review on Random Forest: An Ensemble Classifier. *International Conference on Intelligent Data Communication Technologies and Internet of Things (ICICI) 2018*. https://doi.org/10.1007/978-3-030-03146-6_86.
 89. Zhang, L., Suganthan, P. (2017). Benchmarking Ensemble Classifiers with Novel Co-Trained Kernel Ridge Regression and Random Vector Functional Link Ensembles [Research Frontier]. *IEEE Computational Intelligence Magazine*, 12, 61-72. <https://doi.org/10.1109/MCI.2017.2742867>.
 90. Wyner, A., Olson, M., Bleich, J., Mease, D. (2015). Explaining the Success of AdaBoost and Random Forests as Interpolating Classifiers. *ArXiv*, abs/1504.07676.
 91. Gislason, P., Benediktsson, J., Sveinsson, J. (2006). Random Forests for land cover classification. *Pattern Recognit. Lett.*, 27, 294-300. <https://doi.org/10.1016/J.PATREC.2005.08.011>.

92. Hanika, T., Hirth, J. (2023). Conceptual Views on Tree Ensemble Classifiers. *Int. J. Approx. Reason.*, 159, 108930. <https://doi.org/10.1016/j.ijar.2023.108930>.
93. Lindner, C., Bromiley, P., Ionita, M., Cootes, T. (2015). Robust and Accurate Shape Model Matching Using Random Forest Regression-Voting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37, 1862-1874. <https://doi.org/10.1109/TPAMI.2014.2382106>.
94. Yu, Y., Wang, L., Huang, H., Yang, W. (2020). An Improved Random Forest Algorithm. *Journal of Physics: Conference Series*, 1646. <https://doi.org/10.1088/1742-6596/1646/1/012070>.
95. Matviichuk, O., Biloshytska, O., Horodetska, O., et al (2022). Positional approach to the voting function formation of random forest trees as an example of solving the differentiating tuberculosis forms problem. In *Proceedings of the 2022 IEEE 17th International Conference on Computer Sciences and Information Technologies (CSIT)* (pp. 555–558). IEEE. <https://doi.org/10.1109/csit56902.2022.10000450>.
96. Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., Miao, Y. (2021). Review of Image Classification Algorithms Based on Convolutional Neural Networks. *Remote. Sens.*, 13, 4712. <https://doi.org/10.3390/rs13224712>.
97. Jaeger, S., et al. (2018). Detecting drug-resistant tuberculosis in chest radiographs. *International Journal of Computer Assisted Radiology and Surgery*, 13(12), 1915–1925. <https://doi.org/10.1007/s11548-018-1857-9>.
98. Meraj, S.S. et al. (2019). Detection of pulmonary tuberculosis manifestation in chest X-rays using different convolutional neural network (CNN) models. *International Journal of Engineering and Advanced Technology*, 9(1), 2270–2275. <https://doi.org/10.35940/ijeat.a2632.109119>.
99. Mosquera-Berrazueta, L., Pérez, N., Benítez, D., Grijalva, F., Camacho, O., Herrera, M., Marrero-Ponce, Y. (2023). Red-Unet: An Enhanced U-Net Architecture to Segment Tuberculosis Lesions on X-Ray Images. *2023 IEEE 13th International Conference on Pattern Recognition Systems (ICPRS)*, 1-7. <https://doi.org/10.1109/ICPRS58416.2023.10178991>.

100. He, K., Zhang, X., Ren, S., Sun, J. (2015). Deep residual learning for image recognition. arXiv. <https://doi.org/10.48550/arXiv.1512.03385>.
101. Kalshetty, R., Parveen, A. (2023). Abnormal event detection model using an improved ResNet101 in context aware surveillance system. *Cognitive Computation and Systems*, 5(2). <https://doi.org/10.1049/ccs2.12084>.
102. Hernández, G., Zamora, E., Azuela, J., Téllez, G., Colón, F. (2020). Hybrid neural networks for big data classification. *Neurocomputing*, 390, 327-340. <https://doi.org/10.1016/j.neucom.2019.08.095>.
103. Tsai, C., Lu, Y. (2009). Customer churn prediction by hybrid neural networks. *Expert Syst. Appl.*, 36, 12547-12553. <https://doi.org/10.1016/j.eswa.2009.05.032>.
104. Tong, Z., Tanaka, G. (2019). Hybrid pooling for enhancement of generalization ability in deep convolutional neural networks. *Neurocomputing*, 333, 76-85. <https://doi.org/10.1016/j.neucom.2018.12.036>.
105. Laina, I., Rupprecht, C., Belagiannis, V., Tombari, F., Navab, N. (2016). Deeper depth prediction with fully convolutional residual networks. arXiv. <https://doi.org/10.48550/arXiv.1606.00373>.
106. Babenko V, Nosovets O, Nastenko I, et al (2021) Forming the system with the functionality of clinical pharmacist for personalized treatment strategy searching. *Proceedings of Sixth International Congress on Information and Communication Technology* 503–512. https://doi.org/10.1007/978-981-16-2377-6_47.

ДОДАТОК А

СПИСОК ПУБЛІКАЦІЙ ТА ВІДОМОСТІ ПРО АПРОБАЦІЮ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЇ

- Перелік публікацій:

1. Nastenکو I, Maksymenko V, Potashev S, et al (2021) Random Forest algorithm construction for the diagnosis of coronary heart disease based on echocardiography video data streams. Innovative Biosystems and Bioengineering 5:61–69. doi: 10.20535/ibb.2021.5.1.225794.
2. Voronchuk N, Bovsunovska K, Davydko A, et al (2021) Segmentation of tuberculosis lungs on computer tomography images. Innovative Biosystems and Bioengineering 5:117–124. doi: 10.20535/ibb.2021.5.2.233051.
3. Давидько О, Матвійчук О (2023а) ПРОЦЕС ІДЕНТИФІКАЦІЇ УРАЖЕНЬ ЛЕГЕНІВ НА ЗНІМКАХ КОМП'ЮТЕРНОЇ ТОМОГРАФІЇ ПРИ covid-19. Біомедична інженерія і технологія 63–70. doi: 10.20535/2617-8974.2023.9.277490.
4. Матвійчук О, Настенко Є, (2023) Класифікація туберкульозних уражень легень методом позиційного голосування за даними комп'ютерної томографії. Біомедична інженерія і технологія 11. doi: 10.20535/2617-8974.2023.11.287885.

- Апробація матеріалів дисертації:

1. 16 міжнародна конференція з комп'ютерних наук, Львів, Україна, 22-25 вересня 2021. Заочна форма участі з публікацією тез в Scopus[70].
2. IV міжнародна науково-практична конференція «Інформаційні системи та технології в медицині» (ІСМ-2021), м. Харків, 25–26 листопада 2021 року, заочна форма участі з публікацією тез [105].
3. 17 міжнародна конференція з комп'ютерних наук, Львів, Україна, 10-12 листопада 2021. Заочна форма участі з публікацією тез в Scopus[94].
4. Міжнародна науково-практична конференція «Сучасний стан та перспективи біомедичної інженерії», присвячена 20-річному ювілею Факультету біомедичної

інженерії КПІ ім. Ігоря Сікорського, м. Київ, 15–16 грудня 2022 року, онлайн участь з доповіддю.

ДОДАТОК Б

АКТИ ВПРОВАДЖЕННЯ

«ЗАТВЕРДЖУЮ»

головний лікар ДУ «Національний інститут
фтизіатрії і пульмонології ім. Ф.Г.
Яновського НАМН України» Микола Опанасенко

«15» листопада 2022 р.

Акт
впровадження в практичну охорону здоров'я
матеріалів наукових досліджень

Найменування пропозиції для впровадження:

1. Система класифікації для визначення типів уражень (матове скло, бруківка, консолідація) легень по КТ-зображенням при захворюванні на Covid-19
2. Система класифікації для диференціювання по КТ-зображенням легень хіміорезистентної та хіміочутливої форми туберкульозу.

Ким запропоновано: НТУУ «Київський політехнічний інститут імені Ігоря Сікорського», Факультет біомедичної інженерії, кафедра біомедичної кібернетики, Настенко С.А., Павлов В.А., Давидько О.Б., Матвійчук О.В., Гладкий Я. В., Семчук О. О., Маслянчук С. М. Бутко В.Д.

Джерело інформації:

1. Матвійчук О.В. Сегментація туберкульозних уражень легень на зображеннях комп'ютерної томографії / О.В. Матвійчук, С.Н. Ворончук, К.С.Бовсєуновська, О.Б/ Давидько, М.І. Линник, А.В. Павлов, С.А. Настенко // Innovative Biosystems and Bioengineering, (2021), 5(2) <https://doi.org/10.20535/ibb.2021.5.2.233051>
2. Давидько О.Б., Класифікація уражень легень при covid-19 на основі текстурних ознак та з горткової нейронної мережі. / О.Б. Давидько, А.О. Ладік, В.Б. Максименко, М. І. Линник, О.В. Павлов, С.А. Настенко // Біомедицина інженерія і технологія (2021), №6 <https://doi.org/10.20535/2617-8974.2021.6.231887>
3. Davydko O., Hladkyi Y., Linnik M., Nosovets O., Pavlov V., Nastenka Ie. / Hybrid Classifiers Based on CNN, LSOF, GMDH in COVID-19 Pneumonic Lesions Types Classification Task // Proceedings of the XVI IEEE International Conference CSIT-21& International Workshop on Inductive Modeling, Lviv, UKRAINE, 23-26 September, 2021 P. 380-384. DOI: 10.1109/CSIT52700.2021.9648752
4. Matviichuk O., Nosovets O., Linnik M., Davydko O., Pavlov V., Nastenka Ie. / Class-Oriented Features Selection Technology in Medical Images Classification Problem on the Example of Distinguishing Between Tuberculosis Sensitive and Resistant Forms// Proceedings of the XVI IEEE International Conference CSIT-21& International Workshop on Inductive Modeling, Lviv, UKRAINE, 23-26 September, 2021 P. 385-389, DOI: 10.1109/CSIT52700.2021.9648747

Впроваджено

1. Система класифікації для визначення типів уражень (матове скло, бруківка, консолідація) легень по КТ-зображенням при захворюванні на Covid-19
2. Система класифікації для диференціювання по КТ-зображенням легень хіміорезистентної та хіміочутливої форми туберкульозу

Строки впровадження: листопад 2022р.

Завідуючий відділом
епідеміологічних та організаційних проблем
фтизіопульмонології ДУ «Національний інститут
фтизіатрії і пульмонології ім. Ф.Г. Яновського
НАМН України», д.мед.н

Микола Линник

Рисунок Б.3. – Акт впровадження в ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф.Г. Яновського»