

Хмельницький національний університет
Міністерство освіти і науки України

Хмельницький національний університет
Міністерство освіти і науки України

Кваліфікаційна наукова
праця на правах рукопису

РАДЮК ПАВЛО МИХАЙЛОВИЧ

УДК 004.932.2

ДИСЕРТАЦІЯ

**ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ РАНЬОГО ДІАГНОСТУВАННЯ
ПНЕВМОНІЇ ЗА ІНДИВІДУАЛЬНИМ ПІДБОРОМ ПАРАМЕТРІВ
МОДЕЛІ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ ЛЕГЕНЬ**

122 Комп'ютерні науки
(шифр і назва спеціальності)

12 Інформаційні технології
(галузь знань)

Подається на здобуття наукового ступеня доктора філософії

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

_____ П. М. Радюк
(підпис)

Науковий керівник: Бармак Олександр Володимирович, доктор технічних наук,
професор

Хмельницький – 2021

АНОТАЦІЯ

Радюк П. М. Інформаційна технологія раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії з галузі знань 12 Інформаційні технології за спеціальністю 122 – Комп'ютерні науки. – Хмельницький національний університет, Хмельницький, 2021.

Дисертаційна робота присвячена розв'язанню актуальної науково-прикладної задачі автоматизації процесу діагностування вірусного пневмонічного запалення за медичними зображеннями легень через розроблення інформаційної технології раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень. Застосування розробленої інформаційної технології раннього діагностування пневмонії в клінічній практиці дає змогу підвищити точність та надійність ідентифікації пневмонії на ранніх стадіях за медичними зображеннями грудної клітини людини.

На сьогодні клінічне діагностування за допомогою рентгенологічного випромінювання вважаються традиційним та ефективним засобом до виявлення вірусного пневмонічного запалення. У процесі діагностування рентгенологи зіставляють білі плями на медичному зображенні інфільтратам, а білі ділянки – пневмонічній рідині, ідентифікуючи в такий спосіб захворювання легень. Водночас фахівці-рентгенологи мусять мати достатньо навчені очі, щоби розрізнити неоднорідний колірний розподіл повітря в легенях, та мати широкий багаторічний досвід клінічного лікування. Рентгенологам вкрай важливо визначити чи відповідають білі плями на медичному зображенні пневмонічній рідині. Невчасно або неправильно поставлений діагноз може мати фатальні наслідки для пацієнтів із гострим пневмонічним запаленням легень. Отже, з огляду

на значну проблему ідентифікації вірусної пневмонії за медичними зображеннями легень, актуальним видається застосування обчислювальних методів комп'ютерного зору та машинного навчання до діагностування пневмонії.

Об'єктом дослідження є процес діагностування пневмонії за медичними зображеннями грудної клітини людини.

Предметом дослідження є моделі, методи та засоби інформаційної технології для раннього діагностування пневмонії за медичними зображеннями грудної клітини людини.

У дисертаційній роботі визначено актуальність застосування інформаційних технологій у галузі цифрового діагностування захворювань легень за медичними зображеннями грудної клітини. На основі проведено аналізу методів та підходів до виявлення пневмонії встановлено, що нейромережеві моделі є найкращим рішенням для розроблення інформаційної технології раннього діагностування. Досліджено методи для налаштування нейромережевої моделі та підходи до пояснення та інтерпретування результатів ідентифікації захворювання легень. За аналізом сучасних підходів, методів та інформаційних технологій для діагностування захворювання легень на ранніх стадіях за медичними зображеннями грудної клітини обґрунтовано потребу в створенні інформаційної технології раннього діагностування пневмонії.

Уперше розроблено нейромережеву модель медичного зображення легень з ознаками пневмонічного запалення для ідентифікації пневмонії на ранніх стадіях; особливістю запропонованої моделі є використання за навченою згортковою нейронною мережею гіперпараметрів для виділення карт пневмонічних ознак у випадках індивідуальних особливостей легень, які не входили в початкову навчальну вибірку; такий підхід дає змогу використовувати навчену нейронну мережу для прогнозування класів захворювання легень без перенавчання.

Удосконалено метод підбору квазіоптимальних гіперпараметрів нейромережевої моделі для ідентифікації пневмонії на ранніх стадіях за

рентгенівськими зображеннями легень; удосконалення полягає у використанні в генетичному алгоритмові двох генів для формування набору квазіоптимальних гіперпараметрів згорткової нейронної мережі без зміни значень параметрів навчання та застосуванні нового алгоритму формування початкової популяції для створення наборів гіперпараметрів різного розміру; удосконалений метод підбору квазіоптимальних гіперпараметрів нейромережевої моделі за згортковою архітектурою призначений для локалізації та виявлення розсіяних ознак пневмонічного запалення, що відповідають індивідуальним особливостям легень людини; такий підхід дає змогу врахувати індивідуальні особливості легень, й отже, забезпечити високу точність ідентифікації захворювання легень.

Удосконалено метод візуального подання та пояснення результатів медичного діагностування, який, на відміну від відомих підходів, ґрунтується на формуванні карт активації класів на основі середньозважених градієнтів, що дає можливість охопити всю область інтересу на зображенні та забезпечує виражену візуальну локалізацію аномальних зон на медичному зображенні; отримані в такий спосіб теплові карти на попередньо оброблених медичних зображеннях дають змогу ідентифікувати візуальні відмінності в «пневмонічних» зонах зображення, й у такий спосіб, забезпечують зручний інтерфейс для інтерпретування результатів ідентифікації захворювання легень.

Розроблено нову інформаційну технологію раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень, що на основі розробленої моделі згорткової нейронної мережі та методу підбору квазіоптимальних гіперпараметрів нейронних мереж, а також із використанням удосконаленого методу візуального подання результатів цифрового діагностування дає можливість ідентифікувати ранню пневмонію з високим показником точності та низьким рівнем обчислювальної складності.

Виконано експериментальну перевірку інформаційної технології раннього діагностування пневмонії через розроблення та використання інформаційної

системи ідентифікації захворювання легень за рентгенівськими зображеннями. Результати експериментального тестування запропонованої інформаційної технології довели її спроможність розв'язувати поставлені задачі. Так, розроблена інформаційна технологія перевершила аналоги за показником точності класифікації на 0,58 % та 1,95 % за наборами даних CheXpert_small та PadChest_small, відповідно; за показником влучності на 0,02 % за PadChest_small; за показником повноти на 0,69 % та 1,64 % за CheXpert_small та PadChest_small, відповідно; за показником оцінки площі під ROC-кривою на 1,08 % за PadChest_small; за показником ймовірності помилки другого роду на 0,64 % та 1,64 % за CheXpert_small та PadChest_small, відповідно. Високі значення статистичних показників свідчать як про високу точність виявлення пневмонічного запалення, так і значну влучність моделі під час ідентифікації захворювання легень.

У результаті виконаного дослідження розроблено програмне забезпечення інформаційної технології раннього діагностування пневмонії за медичними зображеннями грудної клітини людини. Застосування інформаційної технології раннього діагностування пневмонії дає змогу виконувати ефективну ідентифікацію пневмонічного запалення за рентгенівськими зображеннями легень на малих обчислювальних пристроях; дає можливість враховувати індивідуальні особливості легень кожної людини на медичному зображенні; забезпечує користувача простим та зрозумілим інтерфейсом для виявлення слабо виражених пневмонічних ознак ранньої стадії захворювання. Результати експериментальних тестувань із використанням розробленого програмного забезпечення підтверджують вірність наукових положень запропонованої інформаційної технології, оскільки впровадження інформаційної технології дає змогу підвищити достовірність виявлення ознак пневмонічного запалення за медичними зображеннями на 0,64 %-1,95 % та знизити ймовірність виникнення

помилки під час ідентифікації захворювання легень на 0,64%-1,64% у порівнянні з відомими аналогами.

За результатами виконаних досліджень здобувачем розроблено методичне забезпечення, яке використане в навчальному процесі в Хмельницькому національному університеті на кафедрі комп'ютерних наук та інформаційних технологій у процесі викладання навчальних дисциплін «Моделювання систем», «Дослідження операцій та основи теорії прийняття рішень», «Інтелектуальний аналіз даних» та «Прикладні математичні пакети для аналізу результатів наукових досліджень». Розроблені в дисертації положення знайшли практичне застосування в роботі рентгенологічного відділення КП «Хмельницька міська лікарня», ТОВ «Науково-технічна фірма «Інфосервіс» та в навчальному процесі Хмельницького національного університету.

Ключові слова: інформаційна технологія, раннє діагностування, пневмонія, рентгеновське зображення грудної клітини, нейромережева модель ідентифікації, згортоква нейронна мережа, підбір гіперпараметрів, візуальне подання.

ANNOTATION

Radiuk Pavlo. Information technology for early diagnosis of pneumonia by the individual selection of parameters of the classification model by medical images of the lungs. – Manuscript copyright.

The thesis is on obtaining a scientific degree of Doctor of Philosophy in the field of knowledge 12 Information Technologies by specialty 122 – Computer Science. – Khmelnytskyi National University, Khmelnytskyi, 2021.

The present thesis is devoted to solving the topical scientific and applied problem of automating the process of diagnosing viral pneumonia by medical images of the lungs through the development of information technology for early diagnosis of pneumonia by the individual selection of parameters of the classification model by medical images of the lungs. Applying the developed information technology for the

early diagnosis of pneumonia in clinical practice by medical images of the human chest increases the accuracy and reliability of pneumonia identification in the early stages.

Nowadays, clinical diagnosis by X-ray is considered a traditional and effective means of detecting viral pneumonia. In the diagnosis process, radiologists compare white spots on the medical image to infiltrates and white areas - pneumonic fluid, thus identifying lung disease. Altogether, radiologists must have sufficiently trained eyes to distinguish the heterogeneous color distribution of air in the lungs and have extensive years of clinical treatment experience. Radiologists must determine whether the white spots on the medical image correspond to the pneumonic fluid. An untimely or incorrect diagnosis can be fatal for patients with acute pneumonia. Thus, given the significant problem of identifying viral pneumonia by medical images of the lungs, it is vital to use computational computer vision and machine learning methods to diagnose pneumonia.

The research object is the process of diagnosing pneumonia by medical images of the human chest.

The research subject is models, methods, and means of information technology for the early diagnosis of pneumonia by medical images of the human chest.

It was defined in the dissertation that applying information technologies was highly topical in digital diagnostics of lung diseases on medical images of a thorax. Based on the analysis of methods and approaches to detecting pneumonia, it was established that neural network models are the best solution for the development of information technology for early diagnosis. Methods for setting up a neural network model and approaches to explaining and interpreting the results of lung disease identification have been studied. According to the analysis of modern approaches, methods, and information technologies for diagnosing lung disease in the early stages based on medical images of the chest, the need to create information technology for the early diagnosis of pneumonia is substantiated.

For the first time, a neural network model of a medical image of the lungs with the pneumonic inflammation features was created to identify pneumonia in the early

stages; the peculiarity of the proposed model is the use of hyperparameters on the pretrained convolutional neural network to select maps of pneumonic signs in cases of individual features of the lungs, which were not included in the initial training sample; this approach allows the use of a trained neural network to predict classes of lung disease without retraining.

The method of selection of quasi-optimal hyperparameters of the neural network model for identification of pneumonia in the early stages by X-ray images of the lungs was improved; improvement is the use in the genetic algorithm of two genes to form a set of quasi-optimal hyperparameters of the convolutional neural network without changing the values of learning parameters and the use of a new algorithm for forming the initial population to create sets of hyperparameters of different sizes; the improved method of selection of quasi-optimal hyperparameters of the neural network model according to the convolutional architecture is intended for localization and detection of the scattered signs of pneumonic inflammation corresponding to individual features of lungs of the person; this approach provides considering the individual characteristics of the lungs, and thus ensures high accuracy in identifying lung disease.

The method of visual presentation and explanation of medical diagnosis was improved, which, unlike known approaches, is based on the formation of activation maps of classes based on weighted average gradients; it allows covering the entire region of interest in the image and provides a pronounced visual localization of abnormal areas in the medical image; the heat maps obtained in this way on pre-treated medical images extract visual differences in the “pneumonic” areas of the image, and thus provide a convenient interface for interpreting the results of lung disease identification.

New information technology for early diagnosis of pneumonia by the individual selection of parameters of the classification model by medical images of the lungs was developed, that is based on the proposed model of convolutional neural network and method of selection of quasi-optimal hyperparameters of neural networks, and using an

advanced method of visual presentation ensures the identification of early pneumonia with high accuracy and low computational complexity.

Experimental validation of the information technology of early diagnosis of pneumonia was performed through the development and use of an information system to identify lung disease by X-ray images. The results of experimental testing of the proposed information technology proved its ability to solve the problem. Thus, the developed information technology surpassed the analogs in terms of classification accuracy by 0.58% and 1.95% for the CheXpert_small and PadChest_small datasets, respectively; in precision by 0.02% for PadChest_small; in recall by 0.69% and 1.64% for CheXpert_small and PadChest_small, respectively; in area under the ROC-curve by 1.08% for PadChest_small; in second type error by 0.64% and 1.64% for CheXpert_small and PadChest_small, respectively. High values of statistical indicators indicate both high accuracy of detection of pneumonic inflammation and significant accuracy of the model in the identification of lung disease.

As a result of the performed research, the software of information technology of early diagnosis of pneumonia on medical images of a human thorax was developed. The use of information technology for early diagnosis of pneumonia allows performing effective identification of pneumonic inflammation by X-ray images of the lungs on small computing devices; gives the chance to consider individual features of lungs of each person on the medical image; provides the user with a straightforward interface for detecting mild pneumonia in the early stages of the disease. The results of experimental testing using the developed software confirm the accuracy of the scientific provisions of the proposed information technology, as the introduction of information technology can increase the reliability of detection of signs of pneumonia by medical images by 0.64%-1.95% and reduce the likelihood of error in identifying the lung disease by 0.64%-1.64% compared with known analogs.

Based on research results, the applicant developed methodological support, which was used in the educational process at Khmelnytskyi National University at the

Department of Computer Science and Information Technology in the teaching of disciplines “Systems Modeling,” “Operations Research and Fundamentals of Decision Theory,” “Intelligent Data Analysis” and “Applied mathematical packages for analysis of research results.” The provisions developed in the dissertation have found practical application in the work of the radiology department of KP “Khmelnyskyi City Hospital,” LLC Scientific and Technical Firm “Infoservice” and in the educational process of Khmelnytskyi National University.

Keywords: information technology, early diagnosis, pneumonia, chest X-ray image, neural network model of identification, convolutional neural network, selection of hyperparameters, visual representation.

Список опублікованих праць здобувача за темою дисертації

Публікації в періодичних наукових виданнях, що індексуються в наукометричних базах Scopus, Web of Science:

1. Radiuk P. M. Applying 3D U-Net architecture to the task of multi-organ segmentation in computed tomography. *Applied Computer Systems*. 2020. Vol. 25, No. 1. Pp. 43-50. (*WoS, Latvia*)

2. Радюк П. М., Бармак О. В., Крак Ю. В. Информационная технология ранней диагностики пневмонии с использованием сверточных нейронных сетей. *Международный научно-технический журнал «Проблемы управления и информатики»*. 2021. № 3. С 101-114. (*Scopus*)

3. Radiuk P., Barmak O., Krak Iu. An approach to early diagnosis of pneumonia on individual radiographs based on the CNN information technology. *The Open Bioinformatics Journal*. 2021. Vol. 14, No. 1, Pp. 92-105. (*Scopus, Netherlands*)

Публікації в періодичних наукових виданнях інших держав, які входять до Організації економічного співробітництва та розвитку та/або Європейського Союзу:

4. Radiuk P. M. Impact of training set batch size on the performance of convolutional neural networks for diverse datasets. *Information Technology and Management Science*. 2017. Vol. 20, No. 1. Pp. 20-24.

Статті у фахових наукових виданнях України:

5. Radiuk P. M. Neuroevolution of convolutional neural networks for the classification of lung cancer images. *Herald of Khmelnytskyi National University*. 2018. Vol. 267, No. 6(2). Pp. 188-192.

6. Radiuk P. M. Application of a genetic algorithm to search for the optimal convolutional neural network architecture with weight distribution. *Herald of Khmelnytskyi National University*. 2020. Vol. 281, No. 1. Pp. 7-11.

7. Radiuk P. M. Modular search space for automated design of neural architecture. *Proceedings of the O.S. Popov ONAT*. 2020. Vol. 1, No. 1. Pp. 37-44.

8. Бармак О. В., Радюк П. М. Інформаційна технологія візуального подання рентгенівських зображень для інтерпретації результатів діагностування пневмонії. *Вісник Хмельницького національного університету*. 2021. № 295(2). С. 52-55.

9. Barmak O., Radiuk P. Web-based information technology for classifying and interpreting early pneumonia based on fine-tuned convolutional neural network. *Computer systems and information technologies*. 2021. Vol. 3, No. 1. Pp. 12-18.

Статті в матеріалах конференцій, що індексуються в наукометричних базах

Scopus:

10. Radiuk P. M., Hrypynska N. V. A framework for exploring and modelling neural architecture search methods. *The 4th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2020) : CEUR-WS*. Vol. 2604. (Lviv, 23-24 April 2020). Lviv, 2020. Pp. 1060-1074. (*Scopus, WoS*)

11. Radiuk P. M., Kutucu H. Heuristic architecture search using network morphism for chest X-Ray classification. *The 1st International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2020) :*

CEUR-WS. Vol. 2623. (Khmelnyskyi, 10-12 June 2020). Khmelnyskyi, 2020. Pp. 107-121. (*Scopus, WoS*)

12. Krak Iu., Barmak O., Radiuk P. Information technology for early diagnosis of pneumonia on individual radiographs. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)* : CEUR-WS. Vol. 2753. (Växjö, Sweden, November 19-21, 2020). Växjö, 2020. Pp. 11-21. (*Scopus, WoS*)

13. Krak Iu., Barmak O., Radiuk P. Detection of early pneumonia on individual CT scans with dilated convolutions. *The 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2021)* : CEUR-WS. Vol. 2853. (Khmelnyskyi, 24-26 March 2021). Khmelnyskyi, 2021. Pp. 214-227. (*Scopus*)

Публікації в матеріалах конференцій (тези доповідей):

14. Радюк П. М. Оптимізація розподілу розмірів фільтрів згорткових нейронних мереж у задачах класифікації. *Актуальні наукові дослідження в сучасному світі ISCIENCE.IN.UA* : тези міжнарод. наук. конф. (м. Переяслав, 21-22 груд. 2016). Переяслав, 2016. С. 48-51.

15. Радюк П. М., Праворська Н. І., Грипинська Н. В. Реалізація нейромережевого алгоритму пакета інструментів MatConvNet з використанням графічного процесора. *Science and Education 2017* : proceedings of X international conference of Science and Education (Rome, Italy, 27 April – 4 May, 2017). Khmelnyskyi, Council of Scientific and Engineering Union in Khmelnyskyi Region, 2017. С. 60-62.

16. Радюк П. М. Аналіз застосування методів нейромережевого моделювання для обробки медичних зображень. *«ІНТЕЛЕКТУАЛЬНІ РІШЕННЯ»*. Обчислювальний інтелект (результати, проблеми, перспективи) : матеріали V міжнар. наук.-практ. конф. (м. Ужгород, 15-20 квіт. 2019 р.). Ужгород, 2019. С. 273-274.

17. Радюк П. М. Поиск оптимальной архитектуры сверточной нейронной сети с использованием генетических алгоритмов. *Современные информационные и коммуникационные технологии на транспорте, в промышленности и образовании* : тезисы XIII междунар. науч.-практ. конф. (м. Днепр, 11-12 дек. 2019 г.). Д. : ДПТ, 2019. С. 117-118.

18. Радюк П. М. Аналітичний огляд архітектур згорткових нейронних мереж у задачах аналізу медичних зображень. *Science, Engineering and Technology: Global and Current Trends* : proceedings of inter. and pract. conf. (м. Прага, 27-28 груд. 2019). Прага, 2019. С. 32-25.

19. Радюк П. М. Стратегія пошуку оптимальної архітектури згорткової нейронної мережі. *VIII Всеукраїнська науково-практична конференція студентів, аспірантів та молодих вчених з автоматичного управління присвяченої Дню космонавтики* : матеріали VIII всеукр. наук.-практ. конф. (м. Херсон, 8-10 квіт. 2020 р.). Херсон, 2020. С. 35-36.

20. Радюк П. М., Грипинська Н. В. Простір пошуку для задачі оптимізації архітектури нейронної мережі. *IX Міжнародна науково-практична конференція студентів, аспірантів та молодих вчених: Використання інформаційних та комунікаційних технологій в сучасному цифровому суспільстві* : матеріали IX міжнар. наук.-практ. конф. (м. Херсон, 4-5 черв. 2020 р.) / за заг. ред. Г.О. Райко. Херсон: Видавництво ФОП Вишемирський В.С., 2020. С. 308-311.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ.....	17
ВСТУП	19
РОЗДІЛ 1. АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО ДІАГНОСТУВАННЯ ЛЕГЕНЕВИХ ЗАХВОРЮВАНЬ НА МЕДИЧНИХ ЗОБРАЖЕННЯХ	28
1.1. Актуальність застосування інформаційних технологій у галузі цифрового діагностування легеневиx захворювань.....	28
1.2. Сучасний стан рентгенологічного тестування у галузі медичного діагностування.....	31
1.2.1 Огляд засобів рентгенологічного тестування.....	31
1.2.2 Механізм формування рентгенівського зображення.....	33
1.2.3 Підходи до попереднього оброблення медичних зображень	40
1.3. Сучасний стан ідентифікації легеневиx захворювань на рентгенівських зображеннях.....	42
1.3.1 Аналіз методів та підходів до виявлення пневмонії.....	42
1.3.2 Огляд методів налаштування нейромережових моделей.....	52
1.3.3 Дискримінаційна локалізація для аналізу медичних зображень	52
1.3.4 Програмне забезпечення для навчання та використання нейромережових моделей.....	55
1.3.5 Статистичні критерії оцінювання засобів ідентифікації.....	57
1.4. Постановка задачі	59
1.5. Висновки до розділу 1	60
РОЗДІЛ 2. МОДЕЛІ ТА МЕТОДИ ДЛЯ ВИЯВЛЕННЯ ПНЕВМОНІЧНИХ ОЗНАК НА МЕДИЧНИХ ЗОБРАЖЕННЯХ.....	61
2.1. Модель для виявлення пневмонічних ознак на медичних зображеннях	62
2.2. Опис запропонованої згорткової архітектури нейромережової моделі	66

2.2.1 Ініціалізація ваг фільтрів	66
2.2.2 Глибинна та точкова згорткові операції	69
2.2.3 Архітектура згорткової нейронної мережі	72
2.3. Метод підбору квазіоптимальних гіперпараметрів згорткової нейронної мережі	75
2.3.1 Ініціалізація гіперпараметрів та параметрів навчання	75
2.3.2 Модифікована хромосома генетичного алгоритму	77
2.3.3 Оператор мутації	80
2.4. Метод візуального подання медичних зображень для інтерпретування результатів ідентифікації захворювання легень	83
2.5. Висновки до розділу 2	87
РОЗДІЛ 3. ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ РАННЬОГО ДІАГНОСТУВАННЯ ПНЕВМОНІЇ ЗА МЕДИЧНИМИ ЗОБРАЖЕННЯМИ ГРУДНОЇ КЛІТИНИ	89
3.1. Загальна схема та кроки інформаційної технології.....	90
3.2. Проектування інформаційної технології як інформаційної системи	93
3.2.1 Функціональне подання інформаційної технології	94
3.2.2 Сценарії використання інформаційної технології	99
3.3. Розроблення архітектури інформаційної системи.....	100
3.3.1 Модульна структура інформаційної системи.....	100
3.3.2 Сценарії взаємодії компонент інформаційної системи	103
3.3.3 Вибір засобів програмного розроблення	104
3.4. Підготовлення нейромережевої моделі для використання в інформаційній технології	107
3.4.1 Підготовка вхідних даних медичних зображень.....	107
3.4.2 Навчання нейромережевої моделі	110
3.5. Висновки до розділу 3	113
РОЗДІЛ 4. ЕКСПЕРИМЕНТАЛЬНЕ ТЕСТУВАННЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ РАННЬОГО ДІАГНОСТУВАННЯ ПНЕВМОНІЇ	115

4.1. Опис експериментальної установки	116
4.2. Експериментальне тестування інформаційної технології	120
4.2.1 Опис наборів даних та критеріїв ефективності для тестування інформаційної технології	120
4.2.2 Експериментальне тестування за набором даних CheXpert_small.....	122
4.2.3 Експериментальне тестування за набором даних PadChest_small	126
4.2.4 Дослідження ефективності інформаційної технології	130
4.2.5 Дослідження візуального подання результатів діагностування.....	138
4.3. Висновки до розділу 4	141
ВИСНОВКИ.....	143
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	146
ДОДАТОК А. СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА	163
ДОДАТОК Б. АКТИ ВПРОВАДЖЕННЯ.....	167
ДОДАТОК В. РЕЗУЛЬТАТИ ЕКСПЕРИМЕНТАЛЬНОГО ТЕСТУВАННЯ...	170

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

- ACAM – з англ. average-weighted class activation map, середньозважена карта активації класів
- ACC – з англ. accuracy of classification, точність класифікації
- AGCAM – з англ. average-weighted gradient class activation map, середньозважена градієнтна карта активації класів
- AI – з англ. artificial intelligence, система штучного інтелекту
- AUC – з англ. area under the curve, оцінка площі під ROC-кривою
- COVID-19 – з англ. coronavirus disease 2019, коронавірусна хвороба 2019 року
- CAM – з англ. class activation map, карта активації класів
- CNN – з англ. convolutional neural network, згортова нейронна мережа
- CV – з англ. computer vision, комп'ютерний зір
- GCAM – з англ. gradient class activation map, градієнтна карта активації класів
- DL – з англ. deep learning, глибоке навчання
- GLCM – з англ. gray-level co-occurrence matrix, напівтонна матриця суміжності
- GPU – з англ. graphics processing unit, графічний процесор
- FNR – з англ. false negative rate, хибнонегативний рівень, або ймовірність помилки другого роду
- FPR – з англ. false positive rate, хибнопозитивний рівень, або ймовірність помилки першого роду
- ML – з англ. machine learning, машинне навчання
- RGB – з англ. red, green, blue, червоний, зелений та синій кольори
- ROC – з англ. receiver operating characteristic, операційна характеристика класифікатора
- ROI – з англ. region of interest, область інтересу
- SVM – з англ. support vector machine, метод опорних векторів
- TP – з англ. true positive, істинно позитивні випадки

TN	– з англ. true negative, істинно негативні випадки
FP	– з англ. false positive, хибно позитивні випадки
FN	– з англ. false negative, хибно негативні випадки
ВООЗ	– всесвітня організація охорони здоров'я
ІС	– інформаційна система
ІТ	– інформаційна технологія
КТ	– комп'ютерна томографія
НМ	– нейромережева модель
САД	– система автоматизованого діагностування
РА	– рентгенологічний апарат
РДП	– раннє діагностування пневмонії
ЦРЗ	– цифрове рентгенівське зображення

ВСТУП

Обґрунтування вибору теми дослідження. Процес розпізнавання образів є одним з основних компонентів систем управління та обробки інформації. Завдання, що пов'язані з ідентифікацією та класифікацією об'єктів, явищ і сигналів, виникають в різноманітних сферах людської діяльності, таких як робототехніка, інформаційний пошук, цифрова медична діагностика тощо. Алгоритмічна обробка зображень широко застосовуються в системах безпеки, контролю і управління доступом, в системах відеоспостереження та медичного скринінгу. Тому надзвичайно важливим залишається завдання підвищення продуктивності роботи інформаційних систем що базуються на розпізнаванні образів.

Значний вклад у розпізнавання образів на зображеннях внесли такі українські та іноземні вчені: М. Шлезінгер [1], Ю. Крак [2-5], О. Бармак [2-5], В. Головка [6, 7], Є. Федоров [8-10], Я. Лекун (LeCun) [11-13], Дж. Хінтон (Hinton) [13-15], А. Зісерман (Zisserman) [16-18], К. Хе (He) [19, 20].

За останні десятиліття вірусна пневмонія стала одним із найбільш широко поширених захворювань. Щорічно у світі понад 450 мільйонів людей потерпають від цього легеневого захворювання, а 4 мільйони гинуть не отримавши вчасного лікування. В Україні на пневмонію хворіють щороку від 40 до 50 тис. осіб. Також у країні зросла смертність від цього захворювання: 5-15 % випадків при позалікарняних пневмоніях, до 50 % – при шпитальних. Значна кількісна різниця між показниками інфекціонування та смертності демонструє, наскільки вирішальним є раннє діагностування пневмонії.

На сьогодні клінічне діагностування за допомогою рентгенологічного випромінювання вважаються традиційним та ефективним засобом до виявлення вірусного пневмонічного запалення. У процесі діагностування рентгенологи зіставляють білі плями на медичному зображенні інфільтратам, а білі ділянки – пневмонічній рідині, ідентифікуючи в такий спосіб захворювання легень. Проте

обмежена колірна гамма медичних зображень стоїть на заваді точному діагнозу, оскільки візуальний перехід від легеневої тканини, що заповнений повітрям і відповідає нормальному стану легень, до щільних ділянок легень із пневмонічною рідиною розмивається і стає мало помітним. Тобто легені пацієнта мають бути заповнені значною кількістю рідини, щоби правильно і вірогідно встановити наявність пневмонічного запалення. Очевидно, що такий підхід не сприяє успішному лікуванню.

Іншою проблемою раннього діагностування пневмонії є людський чинник. Фахівці-рентгенологи мусять володіти достатньо навченими очима, щоби розрізнити неоднорідний колірний розподіл повітря в легенях, та мати широкий багаторічний досвід клінічного лікування. Рентгенологу дуже важливо визначити чи відповідають білі плями на медичному зображенні пневмонічній рідині. Невчасно або неправильно поставлений діагноз може мати фатальні наслідки для пацієнтів із гострим пневмонічним запаленням легень. Отже, з огляду на значну проблему ідентифікації вірусної пневмонії за медичними зображеннями легень, актуальним видається застосування обчислювальних методів комп'ютерного зору та машинного навчання до діагностування пневмонії. Дослідженню застосування розпізнавання образів для аналізу та оброблення медичних зображень присвячено ряд робіт українських та іноземних вчених: Ю. Зайченко [21, 22], О. Березький [23-25], Ю. Крак [26-29], Є. Бодянський [30], А. Макхневич (Makhnevich) [31], Є. Федорченко [32, 33], С. Баловсяк [34], Дж. Ірвін (Irvin) [35, 36], А. Джонсон (Johnson) [37], С. Раджараман (Rajaraman) [38, 40], А. Бустос (Bustos) [39].

На сьогодні, попри поширення інформаційних систем у медичному діагностуванні, недостатність чіткої інтерпретації цифрового діагностування не дає змогу вчасно виявляти та лікувати важкі легеневі захворювання. Недостатньо вивчена поведінка моделей комп'ютерного зору обмежує їхнє використання у повсякденній клінічній практиці. Відтак потреба в автоматизації процесу

діагностування вірусного пневмонічного запалення за медичними зображеннями легень, а також брак інформаційної технології раннього діагностування пневмонії створюють актуальну науково-прикладну задачу, одним зі шляхів розв'язання якої є розроблення інформаційної технології раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень.

Мета і завдання дослідження відповідно до предмета та об'єкта дослідження.

Об'єкт дослідження – процес діагностування пневмонії за медичними зображеннями грудної клітини людини.

Предмет дослідження – моделі, методи та засоби інформаційної технології для раннього діагностування пневмонії за медичними зображеннями грудної клітини людини.

Метою дослідження є підвищення точності та надійності ідентифікації пневмонії на ранніх стадіях шляхом розроблення інформаційної технології раннього діагностування пневмонії за медичними зображеннями грудної клітини.

Для досягнення поставленої мети необхідно вирішити такі *задачі*:

- провести аналіз сучасних підходів до діагностування пневмонії за медичними зображеннями грудної клітини людини;

- розробити модель для ідентифікації захворювання легень за рентгенівськими зображеннями легень;

- розробити методи підбору параметрів моделі для виявлення пневмонічних ознак ранньої пневмонії та інтерпретації результатів діагностування;

- спроектувати та реалізувати інформаційну технологію раннього діагностування пневмонії за медичними зображеннями грудної клітини людини;

- виконати практичне впровадження отриманих результатів за еталонними наборами даних медичних зображень грудної клітини.

Гіпотеза дослідження. Сучасний стан розвитку обчислювальних засобів та інформаційних технологій дає змогу пропонувати моделі та методи, налаштовані індивідуально для кожного пацієнта, і, завдяки цьому, отримати більшу вірогідність ідентифікації захворювання, не нижчу за показники професійних фахівців.

Методи дослідження. Для розв'язання поставлених задач використовуються основні положення системного аналізу, методи математичної статистики та теорії ймовірності, методи інтелектуального аналізу даних та машинного навчання, методи чисельної оптимізації, евристичні методи оптимізації, методи верифікації гібридних моделей, імітаційне та комп'ютерного моделювання.

Наукова новизна отриманих результатів полягає в розробленні інформаційної технології раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень, яка забезпечує підвищення точності та надійності ідентифікації пневмонії на ранніх стадіях за медичними зображеннями грудної клітини людини.

У результаті проведеного дослідження здобувачем *одержано такі наукові результати:*

вперше розроблено:

1) нейромережеву модель медичного зображення легень з ознаками пневмонічного запалення для ідентифікації пневмонії на ранніх стадіях; особливістю запропонованої моделі є використання за навченою згортковою нейронною мережею гіперпараметрів для виділення карт пневмонічних ознак у випадках індивідуальних особливостей легень, які не входили в початкову навчальну вибірку; такий підхід дає змогу використовувати навчену нейронну мережу для прогнозування класів захворювання легень без перенавчання;

удосконалено:

2) метод підбору квазіоптимальних гіперпараметрів нейромережевої моделі для ідентифікації пневмонії на ранніх стадіях за рентгенівськими зображеннями легень; удосконалення полягає у використанні в генетичному

алгоритмові двох генів для формування набору квазіоптимальних гіперпараметрів згорткової нейронної мережі без зміни значень параметрів навчання та застосуванні нового алгоритму формування початкової популяції для створення наборів гіперпараметрів різного розміру; удосконалений метод підбору квазіоптимальних гіперпараметрів нейромережевої моделі за згортковою архітектурою призначений для локалізації та виявлення розсіяних ознак пневмонічного запалення, що відповідають індивідуальним особливостям легень людини; такий підхід дає змогу врахувати індивідуальні особливості легень, й отже, забезпечити високу точність ідентифікації захворювання легень;

3) метод візуального подання та пояснення результатів медичного діагностування, який, на відміну від відомих підходів, ґрунтується на формуванні карт активації класів на основі середньозважених градієнтів, що дає можливість охопити всю область інтересу на зображенні та забезпечує виражену візуальну локалізацію аномальних зон на медичному зображенні; отримані в такий спосіб теплові карти на попередньо оброблених медичних зображеннях дають змогу ідентифікувати візуальні відмінності в «пневмонічних» зонах зображення, й у такий спосіб, забезпечують зручний інтерфейс для інтерпретування результатів ідентифікації захворювання легень;

одержала подальшого розвитку:

4) інформаційна технологія раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень, що на основі розробленої моделі згорткової нейронної мережі та методу підбору квазіоптимальних гіперпараметрів нейронних мереж, а також з використанням удосконаленого методу візуального подання результатів цифрового діагностування дає можливість ідентифікувати ранню пневмонію з високим показником точності та низьким рівнем обчислювальної складності.

Особистий внесок здобувача полягає в розробленні моделі, методів, елементів інформаційної технології та інструментальних засобів, що

забезпечують розв'язання поставлених у дисертації задач. Усі основні наукові й прикладні результати дисертаційної роботи отримані здобувачем самостійно. Основні результати дисертації опубліковані у 20 наукових працях ([41-60] та додаток А), поміж яких 3 статті в періодичних виданнях, що індексуються в наукометричних базах Scopus, Web of Science [41-43] (в тому числі: 2 статті, що опубліковані в періодичних наукових виданнях інших держав, які входять до Європейського Союзу [41, 43]), 1 стаття в періодичному науковому виданні іншої держави, яка входить до Європейського Союзу [44], 5 статей у фахових наукових журналах України [45-49], 4 статті в матеріалах конференцій, що індексуються в наукометричних базах Scopus і Web of Science [50-53], 7 публікацій у матеріалах наукових конференцій (тез доповідей) [54-60].

У роботах, що опубліковані в співавторстві, здобувачеві належать: дослідження сучасних засобів та підходів до ідентифікації захворювання легень за рентгенівськими зображеннями грудної клітини та налаштування моделей ідентифікації [45, 50]; нейромережена модель за згортковою архітектурою для виявлення пневмонічних ознак захворювання легень на ранній стадії [43, 46, 53]; метод підбору квазіоптимальних гіперпараметрів нейромережевої моделі [44, 47, 51]; метод візуального подання результатів ідентифікації захворювання легень [41, 42]; проєктування та реалізація інформаційної технології для раннього діагностування пневмонії [48, 49, 52].

Апробація результатів дисертації. Апробацію основних положень, ідей, висновків дисертаційної роботи проведено на міжкафедральному науковому семінарі кафедри комп'ютерних наук та інформаційних технологій та кафедри комп'ютерної інженерії та системного програмування у Хмельницькому національному університеті. Наукові результати роботи доповідалися також на:

– X International Conference of Science and Education (м. Рим, 2017) [55];

- V міжнародній науково-практичній конференції «Інтелектуальні рішення: Обчислювальний інтелект (результати, проблеми, перспективи)» (м. Ужгород, 2019) [56];
- XIII міжнародній науково-практичній конференції «Современные информационные и коммуникационные технологии на транспорте, в промышленности и образовании» (м. Дніпро, 2019) [57];
- International Practical Conference «Science, Engineering and Technology: Global and Current Trends» (м. Прага, 2019) [58];
- VIII Всеукраїнській науково-практичній конференції студентів, аспірантів та молодих вчених з автоматичного управління присвяченої Дню космонавтики (м. Херсон, 2020) [59];
- 4th International Conference on Computational Linguistics and Intelligent Systems COLINS (м. Львів, 2020) [50];
- IX Міжнародній науково-практичній конференції студентів, аспірантів та молодих вчених «Використання інформаційних та комунікаційних технологій в сучасному цифровому суспільстві» (м. Херсон, 2020) [60];
- 1st International Workshop on Intelligent Information Technologies and Systems of Information Security (м. Хмельницький, 2020) [51];
- 3rd International Conference on Informatics & Data-Driven Medicine IDDM (м. Львів, 2020) [52];
- 2nd International Workshop on Intelligent Information Technologies and Systems of Information Security (м. Хмельницький, 2021) [53].

Структура та обсяг дисертації. Дисертаційна робота складається з анотації, змісту, переліку умовних скорочень, вступу, чотирьох розділів, висновку, списку використаних джерел та додатків. Повний обсяг роботи становить 174 сторінки друкованого тексту, з них анотація – на 12 стор., зміст – на 3 стор., перелік умовних скорочень – на 2 стор., основний текст – на 127 стор.,

список зі 143 використаних джерел – на 18 стор., додатки – на 12 стор. Дисертація містить 45 рисунків та 7 таблиць.

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

Дисертаційна робота є складовою частиною досліджень, що виконувались за держбюджетними темами № 2Б-2016 “Розробка теорії та практики автоматичного зрівноваження обертових тіл рідинними і сипкими матеріалами без підведення енергії та керування рухом” (№ держреєстрації 0116U001547) та № 1Б-2021 “Самоорганізована розподілена система виявлення зловмисного програмного забезпечення в комп'ютерних мережах” (№ держреєстрації 0121U109936) у Хмельницькому національному університеті, в яких здобувач був виконавцем окремих розділів.

Практичне значення отриманих результатів. У результаті виконаного дослідження розроблено програмне забезпечення інформаційної технології раннього діагностування пневмонії за медичними зображеннями грудної клітини людини. Застосування інформаційної технології раннього діагностування пневмонії дає змогу виконувати ефективну ідентифікацію пневмонічного запалення за рентгенівськими зображеннями легень на малих обчислювальних пристроях; дає можливість враховувати індивідуальні особливості легень кожної людини на медичному зображенні; забезпечує користувача простим та зрозумілим інтерфейсом для виявлення слабо виражених пневмонічних ознак ранньої стадії захворювання. Результати експериментальних тестувань із використанням розробленого програмного забезпечення підтверджують вірність наукових положень запропонованої інформаційної технології, оскільки впровадження інформаційної технології дає змогу підвищити достовірність виявлення ознак пневмонічного запалення за медичними зображеннями на 0,64 %-1,95 % та знизити ймовірність виникнення помилки під час ідентифікації захворювання легень на 0,64 %-1,64 % порівняно з відомими аналогами.

За результатами виконаних досліджень здобувачем розроблено методичне забезпечення, яке використане в навчальному процесі в Хмельницькому національному університеті на кафедрі комп'ютерних наук та інформаційних технологій при викладанні дисциплін «Моделювання систем», «Дослідження операцій та основи теорії прийняття рішень», «Інтелектуальний аналіз даних» та «Прикладні математичні пакети для аналізу результатів наукових досліджень».

Розроблені у дисертації положення знайшли практичне застосування в роботі рентгенологічного відділення КП «Хмельницька міська лікарня» (довідка про впровадження від 21.04.2021 р.), ТОВ «Науково-технічна фірма «Інфосервіс» (довідка про впровадження від 19.05.2021 р.) та в навчальному процесі Хмельницького національного університету (акт про впровадження від 22.06.2021 р.) (додаток Б).

Подяка. Автор роботи висловлює щиро дякує науковому керівнику, д.т.н., професору, завідувачеві кафедри комп'ютерних наук та інформаційних технологій Хмельницького національного університету Олександровичу Бармаку за корисні поради та зауваження, підтримку і віру під час підготовки даної дисертаційної роботи.

РОЗДІЛ 1.

АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ПІДХОДІВ ДО ДІАГНОСТУВАННЯ ЛЕГЕНЕВИХ ЗАХВОРЮВАНЬ НА МЕДИЧНИХ ЗОБРАЖЕННЯХ

1.1. Актуальність застосування інформаційних технологій у галузі цифрового діагностування легеневиx захворювань

Пневмонія є серйозним захворюванням людей будь-якого віку у всьому світі. За даними Всесвітньої організації охорони здоров'я (ВООЗ), щороку повідомляється про майже 2 мільйонів смертей від пневмонії [61]. Важка пандемія коронавірусу COVID-19 на початку 2020 року ще більше посилила летальний результат легеневиx захворювань. Численні клінічні дослідження підтвердили, що інфекція COVID-19 спричиняє важку форму пневмонії в значній кількості людей [62, 63]. Водночас бактеріальні та вірусні патогени спричиняють різні форми пневмонії, що потребують різних підходів до лікування. Бактеріальна пневмонія негайно лікується антибіотиками, тоді як вірусна пневмонія вимагає допоміжної допомоги, що робить важливим своєчасну та точну діагностику [64].

Профілактичні заходи щодо діагностування легеневиx захворювань – запорука ефективного лікування. Навіть за браком перших зовнішніх ознак пневмонії (кашель, утруднене дихання, висока температура тіла (39°), прискорене дихання) є можливість виявити її зародження на рентгенівських зображеннях [65-70]. Результат діагностування пневмонії з допомогою рентгенограм можливий у трьох основних станах: абсолютно здорові легені без жодних видимих проявів захворювання, однозначно пневмонія з яскравими проявами на зображенні, та проміжний стан, за якого ознаки пневмонії виражені не чітко. Водночас рентгенограма грудної клітини робиться в профілактичних цілях, або ж якщо є підозра на ранні прояви вірусної пневмонії [70, 71]. Тому

індивідуальний підхід цифрової діагностики полягає у виявленні перших проявів пневмонії на рентгенівських зображеннях.

Ознаками вірусної пневмонії вважаються такі візуальні відхилення [72] на рентгенівському зображенні:

- повна втрата прозорості легеневої тканини (повне затемнення легеневого поля);
- затемнення однієї або декількох частин легені (субповне затемнення);
- затемнення, яке перебуває в межах одного сегмента легені (обмежене затемнення).

Патологічні зміни в легенях під час пневмонії відповідають чотирьом етапам [73]: прилив рідини до легень, червоне легенеve ущільнення, сіре поглиблення та розрідження. До ранньої стадії пневмонії відносять прилив та легенеve ущільнення.

Стадія приливу триває 12-72 години й характеризується інтенсивним припливом крові до судинної системи легень, зниженням їхньої функціональної активності та утворенням альвеолярного ексудату. На рентгенівському зображенні можна побачити підвищення інтенсивності та чіткості легеневого зображення, легке затемнення легеневих полів у зоні локалізації патологічних змін і збільшення площі кореня легкого з одночасною втратою його структурності [74]. Рентгенівське зображення грудної клітини на першій стадії хвороби, унаслідок наповнення легень кров'ю, нагадує решітку (стільникове легке).

Стадія червоного ущільнення зазвичай триває від 24 до 72 годин. У цей час спостерігається ущільнення інтерстиціальної тканини, яка за структурою починає нагадувати печінку. В ексудаті з'являється певна маса крові (еритроцитів). Рентгенологічна картина має лише незначні відмінності від першої стадії: легенеve зображення менш виражене, проте збільшене, легеневі контури стають більш затемненими (ефект «матового скла»).

Здебільшого виявити пневмонію на початкових етапах розвитку можна лише порівнюючи знімки, що виконані з інтервалом 1-2 дні [75]. Проте суттєвим недоліком рентгенограм, як засобу ранньої діагностики вірусної пневмонії, є обмежена гамма кольорів, що складена з різних відтінків сірого. Крім того, у зв'язку з високою інтенсивністю довжини білої хвилі на фотоплівці, рідину в легенях на стадії приливу досить складно ідентифікувати, як щільну і тверду тканину [76]. Іншими словами, візуальний перехід від наповненої повітрям тканини (нормальний стан легень), яку добре помітно в темніших відтінках, до виразно ущільненої тканини потребує достатньої кількості рідини, щоби змістити загальну кольорову гамму зображення до світліших відтінків. Як наслідок, профілактичні дії щодо виявлення вірусної пневмонії ускладнюються обмеженою кольоровою гаммою рентгенограм, і, як наслідок, слабким вираженням ознак захворювання легень на зображенні.

Іншою проблемою ранньої діагностики пневмонії є людський чинник. Рентгенологи мусять мати широку експертизу, щоби розрізнити різномірний колірний розподіл повітря в легенях. Подібний розподіл може бути яскраво виражений на рентгенограмі різними відтінками сірого, проте водночас не відповідати пневмонічній рідині. Тому фахівцям критично важливо визначити, чи відповідають білі плями на рентгенівській плівці рідині. Як показує досвід фахівців [77, 78] як хибно позитивний, так і хибно негативний діагнози можуть істотно зашкодити здоров'ю пацієнта. Тому використання обчислювальних методів та впровадження автоматизованих систем діагностики на ранньому етапі протікання захворювання може суттєво збільшити шанси на правильну постановку діагнозу й у результаті підвищити надійність превентивних заходів та подальшого лікування.

З огляду на вище сказане, виникає необхідність у використанні обчислювальних методів для розроблення систем автоматизованого діагностування (САД) на ранній стадії пневмонії. Впровадження САД може

значно збільшити шанси на постановку правильного діагнозу і, як наслідок, поліпшити профілактичні заходи та подальше лікування. Отже, у дисертаційній роботі пропонується інформаційна технологія для виявлення та інтерпретації ознак ранній стадії вірусної пневмонії на рентгенівському зображенні грудної клітини.

1.2. Сучасний стан рентгенологічного тестування у галузі медичного діагностування

1.2.1 Огляд засобів рентгенологічного тестування

Короткохвильове електромагнітне випромінювання, що нині відоме як рентгенівське проміння, було відкрите німецьким інженером В.К. Рентгеном у 1895 р. Відтоді рентгенівські промені широко використовуються для ідентифікації внутрішніх структур, зокрема, для візуалізація внутрішньої частини людського тіла. Процес застосування рентгенівських променів до людського організму має назву рентгенівське випромінювання або рентгенологічне тестування, а результат випромінювання подають на так званих рентгенівських знімках. Рентгенологічне тестування проводять для розпізнавання певних особливостей людського тіла, наприклад, для виявлення цілісності та геометричних розмірностей внутрішніх органів, для оцінювання бажаних (або небажаних) внутрішніх ознак організму. Зокрема, для досягнення ефективного рентгенівського випромінювання розробляються автоматизовані та напівавтоматизовані системи. Такі застосунки забезпечують переваги об'єктивності та відтворюваності для кожного тесту порівняно з ручним рентгенологічним тестуванням. Водночас основними недоліками цих систем є складність їхньої конфігурації, негнучкість до будь-яких змін у процесі

оцінювання та похибки під час аналізу складних образів на рентгенівських зображеннях.

Упродовж останніх двох десятиліть у галузі комп'ютерного діагностування використовувалася методологія рентгенологічного тестування на основі методів комп'ютерного зору [79, 80, 81]. Процес отримання рентгенівських зображень методами комп'ютерного зору проводиться за узагальненою схемою, що наведено на рис. 1.1.




Рис. 1.1 – Загальна схема рентгенологічного тестування на основі системи комп'ютерного зору [79]

З рис. 1.1 бачимо, що рентгенівські зображення тестового об'єкта можуть створюватися в різних положеннях та на різних енергетичних рівнях. Блоки цієї схеми можуть бути використанні (або не використані) з огляду на процес отримання та аналізу рентгенівських знімків [82], що відповідає конфігурації того чи іншого рентгенівського апарату (РА). Наприклад, у проєкційній рентгенографії деякі методи комп'ютерного зору аналізують поодинокі або множинні погляди, використовуючи моноенергетичні або подвійні енергетичні системи [83].

1.2.2 Механізм формування рентгенівського зображення

Рентгенологічне тестування – процес використання рентгенівського зображення для оцінювання можливих змін та просторових зміщень об'єкта тестування від заданого набору специфікацій [79]. У результаті проходження рентгенівського випромінювання через об'єкт детектор захоплює такий званий рентгенівський знімок, текстурні об'єкти на якому відповідають силі випромінювання різних частин об'єкта.

Найбільш широко використовуваними системами рентгенологічного тестування є цифрова рентгенографія (РГ) та комп'ютерна томографія (КТ). У системах рентгенологічного тестування зазвичай використовується плоский аморфний кремнієвий детектор, як датчик зображення. У таких детекторах за допомогою напівпровідника енергія від рентгенівського випромінювання перетворюється безпосередньо в електричний сигнал, що дає змогу оцифрувати рентгенівське зображення [84]. Цифрова рентгенографія використовує електронні датчики (проти традиційної рентгенографічної плівки) для отримання цифрової рентгенівської проєкції об'єкта тестування й забезпечує в такий спосіб швидку пропускну здатність. Натомість система КТ створює зображення поперечного перерізу об'єкта тестування для чіткого розділення всіх його частин.

Проте КТ виконує значну кількість проєкцій для реконструкції точного зображення поперечного перерізу, що займає багато часу.

Відповідно до принципу фотоелектричного поглинання [85], сила випромінення, що передається через об'єкт тестування, визначена за формулою:

$$I = I_0 e^{-\mu z}, \quad (1.1)$$

де I_0 сила випромінення, що потрапляє на об'єкт тестування, z – товщина об'єкта, μ – коефіцієнт поглинання, що пов'язаний з матеріалом об'єкта.

Процедура рентгенологічного тестування об'єкта (1.1) на основі системи комп'ютерного зору (рис. 1.1) проводиться на основі контрольованої методології розпізнавання зразків [86]. Ця процедура відбувається в такий спосіб:

- 1) детектор виконує рентгенівський знімок об'єкта тестування;
- 2) система комп'ютерного зору зберігає створене зображення на фізичному носії обчислювального пристрою;
- 3) цифрове рентгенівське зображення модифікується для висвітлення та підвищення контрастності;
- 4) виділяються зони інтересу на зображенні із шуканими цільовими ознаками;
- 5) методи комп'ютерного зору вилучають найбільш значущі ознаки;
- б) виявлені ознаки аналізуються для того, щоби визначити, чи цільові ознаки на зображенні відповідають заданим наперед класам; водночас виявлення цільових ознак та навчання класифікатора виконується з використанням репрезентативних зображень, які мають бути позначені експертами заздалегідь.

Аналіз рентгенівських зображень відповідно до кроків вище є хорошим засобом для виявлення цільових ознак. Проте подібний підхід може не спрацювати або спрацювати погано для ідентифікації легеневих хвороб на рентгенівських зображеннях грудної клітини. У таких випадках на зображеннях

формується текстурні перекриття різних складових грудної клітини: легені, ребра, серце, цільові ознаки можливої хвороби тощо. Відповідно кожен піксель рентгенівського зображення може відповідати поглинанню різних складових, що значно ускладнює виокремлення цільових ознак легеневого захворювання, і, як наслідок, встановлення правильного діагнозу.

Для формування рентгенівського зображення різнорідного об'єкта використовується багатовидовий аналіз. Для цього розглянемо об'єкт тестування, що складається з n різних матеріалів товщиною $z_i, i = \overline{1, n}$. Якщо через різні частини n об'єкта тестування проходить рентгенівське випромінювання з коефіцієнтами поглинання $\mu_i, i = \overline{1, n}$, то сила випромінення, що передається через цей об'єкт, визначена за формулою:

$$I = I_0 e^{-\sum_i^{\mu_i z_i}}. \quad (1.2)$$

У рентгенологічному тестуванні багатовидовий аналіз зазвичай використовуються для досягнення двох основних цілей: а) аналіз ознак на двовимірних зображеннях кількома поглядами; б) аналіз тривимірних ознак, що отримані в результаті підходу тривимірної реконструкції [82]. В обох випадках виконується спроба здобути відповідну інформацію про об'єкт тестування. Багатовидовий аналіз за формулою (1.2) використовують для оцінювання складних об'єктів, як от грудна клітина людини, коли невизначеність може призвести до неправильної інтерпретації. Для підтвердження та вдосконалення діагностування на основі аналізу лише одного зображення використовують два або більше поглядів на один і той же об'єкт, що зняті з різних точок зору.

Як бачимо на рис. 1.1, вхідними даними аналізу багаторазового перегляду є пов'язані дані, тобто відповідні точки в кількох зображеннях. Дво- та тривимірні ознаки пов'язаних даних виявляють та обирають, а класифікатор

навчають на основі контрольованої методології розпізнавання зразків. Нарешті, залежно від задачі, результатом рентгенологічного тестування може бути вимірювання, клас або інтерпретація результатів [81].

Загалом процес формування зображення об'єкта тестування в результаті рентгенівського випромінювання із силами випромінювання (1.1)-(1.2) проілюстровано на рис. 1.2.

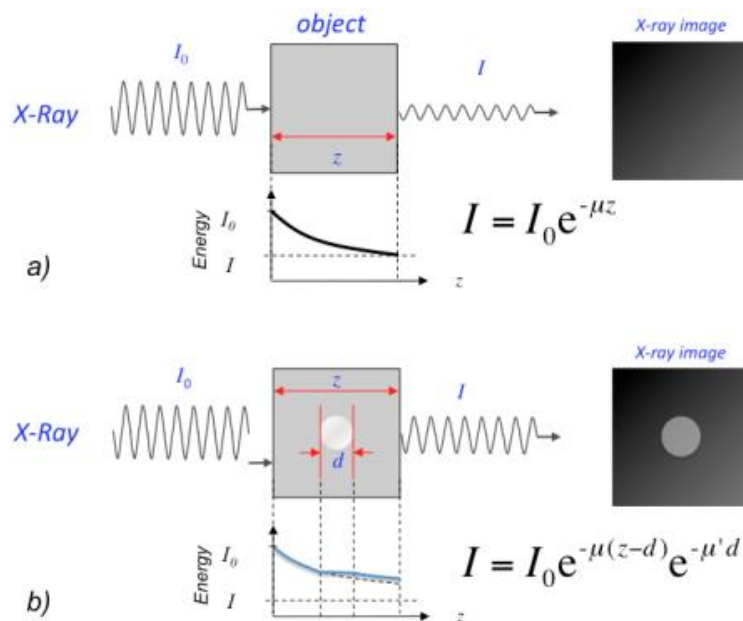


Рис. 1.2 – Схема формування рентгенівського зображення за законом поглинання: а) рентгенівське зображення однорідного об'єкта, б) рентгенівське зображення об'єкта, що складається з двох різних матеріалів [79]

На рис. 1.2а) продемонстровано формування зображення однорідного об'єкта тестування. Водночас на рис. 1.2б), окрім об'єкта, показано формування зображення зони, що присутня всередині об'єкта, а саме яскраво виражений прояв газового пузиря. Зауважимо, що значним недоліком подібного підходу є перекривання об'єктів між собою, що суттєво ускладнює їхнє правильне розрізнення на рентгенівському зображенні.

Геометрична модель рентгенівського зображення. Рентгенівське зображення об'єкта тестування відповідає проєкції в перспективі, де тривимірна точка цього об'єкта розглядається, як піксель на цифровому рентгенівському зображенні, як показано на рис. 1.3.




Рис. 1.3 – Схема геометричної моделі рентгенівського зображення: тривимірна точка (X, Y, Z) проєктується як двовимірна точка (u, v) [79]

Геометрична модель, що зображена на рис. 1.3, використовується для тривимірної реконструкції та для асоціації даних між різними кутами споглядання одного й того ж об'єкта. Тому тривимірні ознаки та двовимірні ознаки, що отримані в результаті багатовидового аналізу, можуть бути використані для поліпшення діагностування, що виконане одним переглядом.

Для побудови геометричної моделі використовуються чотири системи координат [87] (див. рис. 1.3):

- OCS (X, Y, Z) : (з англ. object coordinate system) система координат об'єкта, де тривимірна точка визначається на основі координат, що приєднані до об'єкта тестування;

– WCS (X', Y', Z') : (з англ. world coordinate system) світова система координат, де початок відповідає оптичному центру (джерело рентгенівського випромінювання), а вісь Z' перпендикулярна площині проєкції детектора;

– PCS (x, y) : (з англ. projected coordinate system) проєкційна система координат, де тривимірна точка проєкується на площину $Z' = f$, а початок координат визначений перетином цієї площини з віссю Z' ;

– ICS (u, v) : (з англ. image coordinate system) система координат зображення, де проєктована точка переглядається на зображенні; тут осі (x, y) встановлюються паралельними осям (u, v) .

З огляду на вищесказане, геометрична модель рентгенівського зображення $OCS \rightarrow ICS$ визначається відображенням $P: (X, Y, Z) \rightarrow (u, v)$, що виражається матричним співвідношенням так:

$$\lambda \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = P \begin{bmatrix} X \\ Y \\ Z \\ 1 \end{bmatrix}, \quad (1.3)$$

де λ – коефіцієнт масштабу, P – матриця розмірності 3×4 , що змодельована трьома відображеннями:

– $OCS \rightarrow WCS$, тобто відображення $T_1: (X, Y, Z) \rightarrow (X', Y', Z')$ з використанням тривимірної матриці обертання \mathbf{R} та тривимірного вектора зміщення \mathbf{t} ;

- WCS \rightarrow PCS, тобто відображення $T_2 : (X', Y', Z') \rightarrow (x, y)$ з використанням матриці оптичної проєкції, яка залежить від фокусної відстані f ;
- PCS \rightarrow ICS, тобто відображення $T_3 : (x, y) \rightarrow (u, v)$ з використанням коефіцієнтів масштабування α_x та α_y , та двовимірний вектор зміщення (u_0, v_0) .

Загалом три відображення OCS \rightarrow WCS \rightarrow PCS \rightarrow ICS виражаються так

$$P = \begin{matrix} & T_1 & & T_2 & & T_3 \\ \begin{bmatrix} \alpha_x & 0 & u_0 \\ 0 & \alpha_y & v_0 \\ 0 & 0 & 1 \end{bmatrix} & & \begin{bmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} & & \begin{bmatrix} \mathbf{R} & \mathbf{t} \\ O^T & 1 \end{bmatrix}, \end{matrix} \quad (1.4)$$

Багатовидовий аналіз на основі (1.4) виконується через обертання та зміщення об'єкта. У результаті отримують m проєкцій об'єкта тестування. Для k -ої проєкції, $k = \overline{1, m}$, геометрична модель P_k , що використана в (1.3), обчислюється за (1.4), включно з тривимірною матрицею обертання \mathbf{R}_k та тривимірним вектором зміщення \mathbf{t}_k . Далі матриці P_k оцінюються за допомогою калібрувального об'єкта, що проєкується в m різних положеннях, або за допомогою алгоритму регулювання пучка, де геометрична модель отримується з m рентгенівських зображень об'єкта тестування.

Наразі рентгенологічне тестування грудної клітини є одним із найбільш поширених методів діагностики та диференціації видів пневмонії [31]. На рис. 1.4 зображено приклади рентгенівських зображень зі здоровими та інфікованими пневмонією легень.




Рис. 1.4 – Рентгенівські зображення: (а) прозорі легені без аномального помутніння; (б) бактеріальна пневмонія, що демонструє консолідовану частку рідини в правій верхній частині зображення; (с) вірусна пневмонія, що проявляється дифузними інтерстиціальними рисунками в обох легенях [88]

1.2.3 Підходи до попереднього оброблення медичних зображень

До вхідного рентгенівського зображення застосовується процес попереднього оброблення, щоб зробити його чіткішим та мати змогу виявити ознаки легеневого захворювання. Попереднє оброблення складається з трьох етапів.

На першому кроці рентгенівське зображення освітлюється для збільшення яскравості. Такий підхід застосовувалася з урахуванням того, що навіть професійні рентгенологи досліджують рентгенівське зображення під світлом. Штучне освітлення рентгенограми може бути ефективним засобом до виявлення ознак пневмонії для задачі класифікації. Підвищення яскравості виконується шляхом синтаксичного аналізу кожного окремого пікселя зображення, а далі збільшенням їхніх відповідних значень червоного, зеленого та синього (з англ. Red, Green та Blue або RGB) [89] кольорів на певну константу.

На другому кроці збільшується контраст зображення, що є подібним до зміни яскравості зображення. Підвищення контрастності робить межі на

зображенні більш суцільними, а окремі зони – більш помітними. Подібний прийом може бути використаний з оригінальною кольоровою гамою, що не відображатиме ознак захворювання, проте дасть змогу підкреслити локальні зони на зображенні. Збільшення контрастності зображення можна бути отримане із впровадженням афінної еквівалентності [90].

Третій крок призначений для розширення кольорової гама зображення. На цьому кроці знаходимо середні значення RGB (*avg*) для кожного зображення. Далі усі значення RGB множаться із знайденим середнім значенням *avg* для підвищення загальних значень та отримання кольорової версії зображення. Цей прийом застосовуються для спрощення ознак захворювання у процесі класифікації. Створене у такий спосіб зображення дає змогу виокремити деталі на поверхні, щоб класифікатор зміг краще виявити будь-які особливості та відмінності від зображення із здоровими легенями.

Розмір вхідних зображень змінюється в навчальному наборі даних до 128×128 пікселів, щоби визначити найбільш слушну область інтересу (англ. region of interest або ROI) з ознаками пневмонії на ранній стадії. Для завдання класифікації пневмонії ROI інтерпретується, як бліда маса рідини у пошкодженій пневмонією легені [91]. Ця бліда зона на рентгенограмі може бути виявлена з допомогою розподілу суміжності, також відому як квадратну напівтонну матрицю суміжності (англ. gray-level co-occurrence matrix або GLCM) [92]. GLCM може бути застосовна до зображення, як розподіл значень суміжних пікселів (відтінків сірого або кольорів) із певним зміщенням.

Використання GLCM дає змогу виміряти текстурний відтінок зображень. Крім того, в процесі проведення обчислювальних експериментів створюється кілька GLCM через обертання початкової GLCM під кутами 0° , 45° , 90° , 135° . Одержані матриці розподіляються по всьому зображенню, щоб охопити максимальну кількість його пікселів. У дисертаційній роботі цільові ознаки ранньої пневмонії описуються текстурними ознаками Хараліка і вилучаються

згортковими шарами моделі (1.8)-(1.10) [93]. Зауважимо, що ознаки Хараліка визначають ступінь зв'язку між сусідніми пікселями на зображенні з точки зору впливу їхньої інтенсивності. Така характеристика функцій Хараліка є важливою особливістю для виявлення ранньої пневмонії, оскільки цільові рентгенограми визначаються обмеженим кольоровим спектром.

Відповідно до аналізу джерел [91-93], три текстурних ознаки, а саме дисперсія F_4 , сума середніх значень F_6 та сума дисперсії F_7 показали найбільш значну різницю у значеннях між зображеннями здорової людини і зображеннями з легеневою хворобою. Отже, функції F_4 , F_6 і F_7 , були обрані за основні обчислювальні ознаки ранньої пневмонії і використовувалися в подальшому для візуальної інтерпретації діагностування пневмонії на ранніх стадіях.

1.3. Сучасний стан ідентифікації легеневих захворювань на рентгенівських зображеннях

1.3.1 Аналіз методів та підходів до виявлення пневмонії

Зазвичай САД служать додатковим інструментом під час прийняття клінічних рішень. Вони поєднують системи комп'ютерного зору (CV) та штучного інтелекту (AI) із рентгенівською обробкою зображень для виявлення закономірностей на зображеннях [94, 95]. Сучасні САД зазвичай працюють на основі методів машинного навчання (ML) [81, 96, 97], які виявляють та описують конкретні особливості захворювання на зображенні. Такі методи оптимізовані для конкретних наборів даних і навчені визначати заздалегідь задані зміни в розмірі ROI [91], орієнтації та положенні на рентгенівських променях. Зазначимо, що в останні роки застосовувались методи, що засновані на виявленні ознак з використанням глибокого навчання (DL) [35, 78, 94, 98].

Різні питання CV в медичній обробці зображень, як правило, вирішуються за допомогою згорткових нейронних мереж (CNN). За останні роки різні модифікації згорткової архітектури отримали значне визнання [99-101]. Крім того, на основі нових порівняльних досліджень [102-104] можна стверджувати, що CNN переважно перевершують традиційні методики ML в медичних завданнях візуалізації. Ключовою перевагою CNN є поєднання послідовно розміщених різних шарів обробки для виявлення ієрархічних особливостей об'єктів за вхідними піксельними даними [105]. Початкові шари мережі абстрагують особливості цільового об'єкта за допомогою різноманітних піксельних маніпуляційних методів [106], таких як локалізація сприйнятливих полів, розподіл та розподіл ваги, субдискретизація, об'єднання та нормалізація. Успішна синергія різних механізмів отримання забезпечує цілісне уявлення про об'єкти тестування на зображеннях, що забезпечує високу класифікацію. Враховуючи всі можливі методи медичної обробки зображень, CNN був обраний основним екстрактором характеристик автоматизованого виявлення пневмонії.

Попри те, що методи DL демонструють значні досягнення у вирішенні різних проблем із медичною візуалізацією, відсутність надійної інтерпретації обмежує їхній медичний діагноз. Наприклад, недостатньо вивчена поведінка моделі CNN обмежує її використання у повсякденній клінічній практиці [102, 107]. На сьогоднішній день досі немає чіткого розуміння особливостей пневмонії на рентгені, які вказують на моделі CNN про наявність захворювання. Відповідно, незрозуміло, як розробити та вказати правильну топологію CNN для індивідуальної діагностики пневмонії на ранніх стадіях. Тому дисертаційна робота присвячена розв'язанню актуальної ідентифікації та інтерпретації ранньої пневмонії на рентгенівських зображеннях грудної клітини.

Упродовж останніх років наукове співтовариство запропонувало багато робіт із використання машинної діагностики пневмонії на рентгенограмах органів грудної клітки. Наприклад, в [108] для виявлення всієї зони легень

грудної клітини використовувались активні контурні алгоритми, а потім ця зона була розділена на 40 ROI. В результаті застосування двовимірного вейвлет-перетворення Даубекі та аналізу основних компонентів компоненти кожної області були видалені та порівняні з прогнозованою площею. Таким чином, автори могли сегментувати зображення грудної клітки та подати ROI з можливими ознаками захворювання легень. Дослідження [109] присвячене ідентифікації пневмонії за допомогою модифікованого порогового значення Otsu. Це значення дає змогу відокремити здорову частину легені від проявів матового скла на зображенні, що сигналізує про наявність захворювання. У дослідженнях [110-112] запропоновано САД, яка використовує процедуру рентгенівської диференціації вокселів для послідовного вилучення ознак пневмонії в заздалегідь підготовлених ROIs. Одночасно метод референтних векторів був використаний для тренування та позначення ROI легеневої паренхіми, керуючись характеристиками текстури та форми зображення. Такий підхід дозволив досягти точності класифікації 91%, що перевищувало результати рентгенологів того часу.

Попри хороші результати традиційних методів короткого замикання при цифровій діагностиці пневмонії, вони не виявляють декількох важливих моментів. По-перше, необхідно вказати ROI самостійно, але незрозуміло, скільки їх достатньо для охоплення всіх особливостей пневмонії. Крім того, невідомо, які типи текстур є найбільш значущими для ранньої пневмонії, враховуючи розмитість особливостей рентгенівського зображення. Крім того, для нових форм пневмонії, таких як захворювання, спричинені COVID-19 [70, 73, 113], необхідно покращити рівень сегментації грудної клітки на зображенні, зберігаючи при цьому високий рівень інтерпретації результати. Загалом, традиційні методи CV вимагають значної попередньої обробки зображень та ручного втручання для видалення конкретних візуальних особливостей перед класифікацією. Протягом

останніх кількох років такі проблеми в основному вирішувались методами DL, переважно з використанням CNN.

У роботі [114] запропоновано модифіковану VGG19 [16], що розроблено для локалізації області інтересу на основі градієнта для виявлення та просторової локалізації пневмонії. Крім того, автори цієї роботи опублікували велику колекцію наборів даних фронтальних рентгенівських променів розміром 112 120 зображень. На момент написання статті автори досягли точності виявлення пневмонії у 63,3%. У роботі [35] (CheXNet) метод градієнтного зображення у поєднанні з тепловими картами був застосований до локалізації ROI для виявлення пневмонії (DenseNet [115]). Автори використовували 121-шарову тісно пов'язану нейронну мережу для оцінки ймовірності захворювання та досягли AUC 76,8%. В роботах [38, 40] автори сфокусувалися на візуалізації процесу виявлення пневмонії, застосували градієнтні карти активації класів (з англ. gradient activation class maps, або GCAMs) [116] для інтерпретування результатів автоматизованої системи діагностування. В результаті модифікації VGG19 вони досягли 93,6% точності класифікації, і їх підхід до зображення виявив, які особливості CNN вважає найбільш важливими для клінічного рішення. Іншим підходом до візуалізації та інтерпретації глибокого навчання є повністю пов'язаний CNN, зокрема, архітектура U-Net [117]. Наприклад, у дослідженні [41] запропоновано використовувати U-Net зі згортковими ядрами $3 \times 3 \times 3$ для сегментування органів черевної порожнини на об'ємних знімках комп'ютерної томографії.

За останні кілька років популярним став підхід під назвою трансферне навчання, що полягає у перенесенні значень ваг мережі, що навчені на одному наборі даних, у цільову модель розглядуваної задачі. Наприклад, у дослідженні [88] застосовано метод трансферного навчання до 36-шарової CNN (Inception_v4 [118]) для ефективною класифікації пневмонії на малому наборі даних та використано GCAMs для інтерпретування результатів автоматизованого

діагностування. Ця CNN досягла точності класифікації в 96,4% за малим навчальним набором даних із 5 232 рентгенівських зображень. У нещодавньому дослідженні [119] автори запропонували автоматизовану систему діагностування пневмонії та COVID-19 розвинувши метод трансферного навчання з використанням невеликої кількості рентгенівських зображень COVID-19. Запропонована багат шарова CNN ґрунтується на архітектурі ResNet [120] та використовує поглиблену згортку з різними коефіцієнтами розширення для ефективного вилучення різноманітних характеристик із рентгенограм. Крім того, у роботі інтегрована дискримінаційна локалізація [121] на основі градієнта для відокремлення ROI, що можуть сигналізувати про наявність пневмонії. Наразі підхід із поглибленим згортком ядром [122, 123] видається найбільш перспективним для раннього діагностування пневмонії без значного розширення топології нейронної мережі.

Крім того, дискримінаційна локалізація на основі градієнта інтегрована в окремі області інтересу, які можуть сигналізувати про наявність пневмонії. В даний час підхід глибокої згортки видається найбільш перспективним для ранньої діагностики пневмонії без істотного розширення топології нейронної мережі. У нещодавньому дослідженні [124] запропоновано ансамблевий підхід, що поєднує архітектуру AlexNet [15] як екстрактор функцій, алгоритм рельєфу для ефективного вибору функцій та метод опорних векторів (SVM) як остаточний класифікаційний рівень. Цей підхід [125, 126] продемонстрував помітні результати, досягши точності перевірки 96-97% залежно від різних наборів даних. Тим не менше, незважаючи на успішне впровадження архітектури CNN у виявленні пневмонії, мало досліджень стосуються ранньої діагностики.

Усі вище згадані методи виявлення ґрунтуються на застосуванні багат шарових CNN [127], в основі яких закладено операцію згортки. Ядро згортки CNN є типовим прикладом механізму вилучення ознак. У згортковому шарі, що складається з множини фільтрів, вхід кожного нейрона під'єднаний до

локальної приймаючої ділянки попереднього шару, що дає змогу вилучати локальні особливості на зображенні. Подібний підхід на основі локальних зв'язків був неодноразово успішно застосований до багатьох завдань аналізу текстур [121]. Отже, внаслідок модифікації згорткового шару виникає можливість ефективно вилучати локальні особливості текстур. Проте текстура не завжди у повній мірі відображає основні властивості об'єкта, тому неможливо використовувати лише особливості текстури для отримання більш високого рівня вмісту зображення. Зі збільшенням глибини моделі роздільна здатність карти об'єктів поступово зменшується, і текстура, виділена ядром згортки, може мати значні відхилення.

Нижче деталізуємо найбільш використовувані операції CNN за допомогою загальноприйнятих математичних виразів [105].

Двовимірний згортковий шар (Conv2D) визначається так:

$$a^{[l]} = \left[\begin{array}{l} \text{ReLU}^{[l]} \left(\text{Conv} \left(a^{[l-1]}, K^{(1)} \right) \right), \text{ReLU}^{[l]} \left(\text{Conv} \left(a^{[l-1]}, K^{(2)} \right) \right), \dots \\ \dots, \text{ReLU}^{[l]} \left(\text{Conv} \left(a^{[l-1]}, K^{(n_c^{[l]})} \right) \right) \end{array} \right], \quad (1.5)$$

де

$$\text{Conv} \left(a^{[l-1]}, K^{(n_c^{[l]})} \right)_{x,y} = \sum_{i=1}^{n_H^{[l-1]}} \sum_{j=1}^{n_W^{[l-1]}} \sum_{k=1}^{n_C^{[l-1]}} K_{i,j,k}^{(n_c^{[l]})} a_{x+i-1,y+j-1,k}^{[l-1]} + b_n^{[l]}, \quad (1.6)$$

$$a^{[l]} : n_H^{[l]}, n_W^{[l]}, n_C^{[l]}.$$

Для неліаризації кожного згорткового шару використано функцію активації ReLU, що визначена так:

$$\text{ReLU} = \max\{0, x\}. \quad (1.7)$$

Для виявлення рецептивних полів різного розміру застосовують різні типи згорткових операцій (1.6), як от, розширена, точкова та глибинна згортки. Нижче наведемо математичне формулювання кількох типів згорткової операції.

Математичне формулювання розширеної згорткової операції [128] є таким:

$$\begin{aligned} \text{DilatedConv} \left(a^{[l-1]}, K^{(n_c^{[l]})} \right)_{x,y} &= \sum_{i=1}^{n_w^{[l-1]}} \sum_{j=1}^{n_w^{[l-1]}} \sum_{k=1}^{n_c^{[l-1]}} K_{i,j,k}^{(n_c^{[l]})} a_{x+di-1, y+dj-1, k}^{[l-1]} + b_n^{[l]}, \\ a^{[l]} &: n_H^{[l]}, n_W^{[l]}, n_C^{[l]}. \end{aligned} \quad (1.8)$$

Точкова згорткова операція [129] визначена так:

$$\begin{aligned} \text{PointwiseConv} \left(a^{[l-1]}, K^{(n_c^{[l]})} \right)_{x,y} &= \sum_{k=1}^{n_c^{[l-1]}} K_{i,j,k}^{(n_c^{[l]})} a_k^{[l-1]} + b_n^{[l]}, \\ a^{[l]} &: n_C^{[l]}. \end{aligned} \quad (1.9)$$

Глибинна згорткова операція [130] визначається так:

$$\begin{aligned} \text{DepthwiseConv} \left(a^{[l-1]}, K^{(n_c^{[l]})} \right)_{x,y} &= \sum_{i=1}^{n_w^{[l-1]}} \sum_{j=1}^{n_w^{[l-1]}} K_{i,j}^{(n_c^{[l]})} \circ a_{x+i-1, y+j-1}^{[l-1]} + b_n^{[l]}, \\ a^{[l]} &: n_H^{[l]}, n_W^{[l]}. \end{aligned} \quad (1.10)$$

Після кожного згорткового шару з функцією активації зазвичай додається шар нормалізації, так що вхідне значення функції нелінійного перетворення потрапляє в область, що чутлива до вхідних даних. Це дає змогу уникнути проблеми зникнення градієнтів та пришвидшити навчання мережі. Після

активації згорткового шару розміщується пакетна нормалізація (Batch-norm), що визначена так:

$$z_{i,j,k,c} = \text{BatchNorm}_{\gamma_c \beta_c}(x_{i,j,k,c}) = \gamma_c \hat{x}_{i,j,k,c} + \beta_c, \quad (1.11)$$

$$\hat{x}_{i,j,k,c} = \frac{x_{i,j,k,c} - \mu_{B,c}}{\sqrt{\sigma_{B,c}^2 + \varepsilon}}.$$

Після залишкових шарів у моделі розміщений усереднений підвибірковий шар (Average Pooling 2D), що визначений формулою:

$$a_{x,y,z}^{[l]} = \text{avgpool}(a^{[l-1]})_{x,y,z} = \varphi^{[l]} \left(\left(a_{x+i-1,y+i-1,z}^{[l-1]} \right)_{(i,j) \in [1,2,\dots,f^{[l]}]^2} \right). \quad (1.12)$$

Усереднений підвибірковий шар обчислює середнє значення кожної карти ознак для останнього результуючого згорткового шару. Отримана множина ознак дорівнює кількості карт ознак останнього шару і подається на два повнозв'язних шари.

Перший повнозв'язний шар (Dense(64)+ReLU) має 256 вузлів з функцією активації ReLU:

$$z_j^{[i]} = \sum_{l=1}^{n_{i-1}} w_{j,l}^{[i]} \cdot a_l^{[i-1]} + b_j^{[i]} \quad (1.13)$$

$$\rightarrow a_j^{[i]} = \text{ReLU}^{[i]}(z_j^{[i]}).$$

Другий повнозв'язний шар (Dense(1)+Sigmoid) є останнім шаром класифікації у моделі. Він містить 2 вузла із функцією активації Sigmoid для

стиснення двовимірного виходу у ймовірнісний розподіл класифікації. Останній шар моделі визначений так:

$$a_j^{[i]} = \frac{1}{1 + e^{-a_j^{[i-1]}}} \quad (1.14)$$

Далі сформуємо завдання виявлення пневмонічних ознак на рентгенівських зображеннях. Загалом у задачах оброблення зображень найчастіше використовують такі ознаки зображень: цільовий колір, форма об'єкта, текстура та взаємозв'язок об'єктів у просторі. Основною відмінністю різних типів пневмонії від здорових легень на зображенні є текстурні ознаки легень. Попри інтуїтивно зрозумілий вибір текстурних ознак для ідентифікації захворювання на зображенні, нині немає чіткого стандарту визначених текстур, і обговорення їх визначень є досі актуальною задачею [61]. Крім того, на відміну від таких ознак зображення, як відтінки сірого та колір, текстури є розподіленням відтінків сірого щодо певного пікселя та простору навколо нього. Тому текстура подається, як постійне повторення локального простору на зображенні.

Відповідно до практик клінічного діагностування [31, 64, 71], особливості пневмонії на рентгенівському зображенні можуть бути або сильно ущільненими або дифузно розподіленими на всій площині легень. Тому виникає необхідність розглядати ознаки захворювання різних рівнів спостережень [72]. Наприклад, у роботі [128] пропонується використовувати інший тип згорткового ядра, що зветься розширеною згорткою, для розширення рецептивного поля згортки без збільшення загальної кількості параметрів ядер згортки.

Нижче опишемо процес вилучення ознак за допомогою операції розширеної згортки. Спершу точкова згортка проходить через карту вхідних характеристик для проєктування інформації з багатьох вхідних каналів у ширший простір. Далі зображення проводиться через велику кількість глибинних згорток

із різними просторовими ядрами та різними коефіцієнтами розширення, від 1 до максимального значення коефіцієнта d . Значення d регулюється відповідно до форми вхідної карти ознак, щоби покрити усю необхідну рецептивну площину. Як результат, поглиблені згортки витягують просторові ознаки з різних рецептивних полів, від дуже ущільнених до узагальнених ознак. Далі всі розрізнені ознаки проходять через наступну точкову згортку для об'єднання у звужений простір. Подібна процедура веде до вилучення навіть мало видимих ознак пневмонії на зображенні з використанням усього лиш кількох згорткових шарів, що дає змогу проектувати індивідуальні архітектури CNN. На рис. 1.5 зображено розширену згортку з різними коефіцієнтами розширення.




Рис. 1.5 – Розширена згортка з різними коефіцієнтами розширення з розміром ядра згортки 3×3 охоплює різні рецептивні поля. Зі збільшенням коефіцієнта розширення рецептивне поле також збільшується за незмінного ядра [128]

Завдяки особливості розширення різні ознаки захворювання, що вилучені з різних згортків із різним коефіцієнтом розширення, накопичуватимуть більшу різноманітність. На додаток, традиційну згортку можна розбити на поглиблену та точкову, що слідує одна за одною. Під час виконання глибокої (просторової) згортки кожен вхідний канал індивідуально оброблюється порізненими

фільтрами. Далі виконується точкова (традиційна) згортка з ядрами 1×1 , для інтегрування результатів глибокої згортки в новий простір. Такий підхід робить процес вилучення обчислювально ефективним за невеликої кількості згорток.

Загалом, щоб зберегти необхідну інформацію щодо текстурних ознак пневмонії і водночас не ускладнити модель великою кількістю згорткових шарів, у кваліфікаційній роботі пропонується CNN із трьома згортковими шарами на основі розширеної згортки.

1.3.2 Огляд методів налаштування нейромережових моделей

1.3.3 Дискримінаційна локалізація для аналізу медичних зображень

Інтерпретування роботи CNN є актуальною задачею в галузі аналізу медичних зображень. Проте на сьогодні CNN все ще сприймаються, як чорні скриньки; як у рентгенологів, так і у фахівців КЗ немає довіри до сформованих нейронними мережами прогнозів [35, 107]. Водночас розуміння принципів виявлення ознак може допомогти в налаштуванні та оптимізації гіперпараметрів мережі, виявити та зрозуміти причину відмов моделі та пояснити результати кінцевому користувачеві-неспеціалісту в процесі розв'язання практичних завдань. Методи візуалізації CNN переважно класифікують на [110] попередні методи, які допомагають візуалізувати загальну структуру моделі, та методи на основі градієнта, що дають змогу маніпулювати градієнтами від прямого та заднього ходу під час навчання.

Навчена модель фокусується на дискримінаційних частинах зображення на останньому етапі класифікації. З огляду джерел літератури з'ясовано, що GCAMs [116] можуть допомогти у візуалізації та налагодженні передбачень моделі, особливо у випадку помилки передбачення. Результуючі дані з підвибіркового

шару надходять до лінеаризованого шару для ідентифікації дискримінаційного ROI, що виділений спеціально для класифікації входів до відповідних класів.

Позначимо через V^m вектор карт ознак на останньому підвибірковому шарі, який просторово усереднює m -у карту ознак з останнього згорткового шару, а через w_m^c ваги, що з'єднують m -у карту ознак з результуючим нейроном, що відповідає очікуваному класу c . Оцінка прогнозування y^c на результуючому шарі класифікації виражається, як зважена сума усіх нейронів на підвибірковому шарі:

$$y^c = \sum_{m=1}^M w_m^c \sum_{i=1}^I \sum_{j=1}^I v_{i,j,m} = \sum_{m=1}^M \sum_{i=1}^I \sum_{j=1}^I w_m^c v_{i,j,m}, \quad (1.15)$$

де $v_{i,j,m}$ позначає m -у карту ознак на площині зображення (i, j) , I – розмір зображення, M – загальна кількість карт ознак.

Позначимо через $CAM_{i,j}^c$ зважену суму активацій з усіх карт об'єктів щодо очікуваного класу c на площині зображення (i, j) :

$$CAM_{i,j}^c = \sum_{m=1}^M w_m^c v_{i,j,m}. \quad (1.16)$$

Кarti активації класі надають інформацію щодо важливості активацій на кожній просторовій сітці (i, j) для класифікації вхідного зображення до очікуваного класу c . Кarti масштабуються до розміру вхідного зображення для пошуку дискримінаційного ROI, що використовується для класифікації зображення за очікуваним класом. Такий підхід може пояснити процес прогнозування моделі та локалізувати ROI, що є характерним для її класу.

У роботі [123] запропоновано використовувати середньозважені карти активації класів (з англ. average-weighted class activation maps або ACAMs).

Запропонована модифікація ACAM виділяє ROI на рівні класу, що вважається найбільш значущим для правильного прогнозування для всіх входів, що належать до даного класу. ACAM для класу c обчислюється шляхом усереднення усіх виходів CAM:

$$\text{ACAM}_{i,j}^c = \sum_{k=1}^K \text{CAM}_{i,j,k}^c, \quad (1.17)$$

де $\text{CAM}_{i,j,k}^c$ відповідає значенню CAM на площині зображення (i, j) для k -го зображення в очікуваному класі c , K – загальна кількість зображень на виході підвибіркового шару.

Підхід (1.17) дає змогу визначати ROI, що характерний для передбачуваного класу, та пояснювати передбачення моделі. Проте, як метод CAM, так і його прямі модифікації, мають спільний недолік, а саме застосування CAMs лише до нейронних мереж із підвибірковим шаром. Водночас далеко не усі CNN із малою кількістю шарів можуть містити підвибіркові шари. Тому що усунути потенційний недолік, у роботі [116] запропоновано використати строге узагальнення карт активації класів, під назвою градієнтно-зважена карта активація класів (з англ. gradient-weighted class activation map або GCAM).

Метод GCAM дає змогу застосовувати карти активації класів до CNN з будь-якими типами шарів. GCAM використовує інформацію щодо градієнта очікуваного класу, що повертається назад у найглибший згортковий шар для генерування пояснень. GCAM формує зважену суму всіх карт об'єктів у найглибшому згортковому шарі для очікуваного класу c :

$$\text{GCAM}_{i,j}^c = \text{ReLU} \left(\sum_{m=1}^M g_m^c v_{i,j,m} \right). \quad (1.18)$$

Значення градієнтних ваг g_m^c отримаємо через обчислення градієнта оцінки прогнозування y^c відносно m -ої карти ознак

$$g_m^c = \sum_{i=1}^l \sum_{j=1}^l \frac{\partial y^c}{\partial v_{i,j,m}}. \quad (1.19)$$

Нелінійність ReLU застосовується у формулі (1.18), щоб уникнути впливу негативних ваг на клас c ; припускається, що пікселі з від'ємними вагами належать до інших класів. Відповідно до формул (1.15) та (1.18), значення g_m^c рівноцінне значенню w_m^c для мереж із архітектурою, що сумісна з САМ. Різниця полягає у застосуванні нелінійності ReLU для виключення впливу негативних ваг, які, ймовірно, належать до інших класів.

1.3.4 Програмне забезпечення для навчання та використання нейромережових моделей

З аналізу джерел вище з'ясовано, що за останнє десятиліття нейромережеве моделювання набуло значного поширення. Крім того, методи DL широко використовуються в галузі оброблення медичних зображень, зокрема, рентгенівських зображень у задачах ідентифікації легеневих захворювань. Така популярність зумовлена методологічними розробками (наприклад, архітектури CNN AlexNet [15], U-Net [117] та ResNet [120]), оптимізацією графічних процесорів (GPU), збільшенням даних навчання та розробленням інформаційних систем DL з відкритим кодом (відокремлені програмні середовища, бібліотеки, програмовані модулі тощо).

Сучасні платформи з відкритим кодом у галузі систем штучного інтелекту мають істотний вплив на результативність та ефективність впровадження методів

DL для розв'язання задач КЗ. Проте зазвичай ці засоби спрямовані на розв'язання задач із різних галузей [97]. Наприклад, програмні середовища MatConvNet [55], TensorFlow [131], PyTorch [132], ONNX [133] широко розповсюдженні для створення, розгортання та впровадження складних моделей D. Проте вони не забезпечують функціональності оброблення медичних зображень та мають обмежене підтримання клінічних випробувань. Інші цільові програмовані інструменти, як от NiftyNet [134], MONAI [135] та TorchIO[136], розроблені на основі TensorFlow й PyTorch та дають змогу здійснювати комплексний аналіз медичних зображень із побудовою, навчанням та оптимізацією моделей DL. Проте їм не вистачає зрозумілого та зручного графічного інтерфейсу, що стримує медичних фахівців від використання сучасних інформаційних систем та застосунків, оскільки ці інструменти зазвичай орієнтовані на інженерів програмного забезпечення.

Водночас за останні кілька років було розроблено кілька успішних рішень саме для аналізу медичних зображень. У вільному доступі наявні різні програмні засоби для розв'язання вузькоспеціалізованих практичних завдань у цифровому медичному діагностуванні: класифікація (наприклад, Tensor networks [137]), сегментація (наприклад, MIScn [138]) та візуалізація (наприклад, mrivis [139]) медичних зображень. Однак, усі вище згадані інструменти орієнтовані на використання фахівцями комп'ютерних наук, але не медичними дослідниками, включно з рентгенологами. Вони не забезпечують зручного користувальницького інтерфейсу, який дав би змогу за короткий час опанувати інструмент. Крім того, усі проекти з відкритим кодом покладаються на одну з платформ широкого вжитку, TensorFlow або PyTorch, що робить їх потенційно негнучкими для швидкого переходу на іншу платформу.

Перспективним рішенням для побудови та гнучкої реалізації моделей DL зі зручним користувальницьким інтерфейсом є платформа Keras [140] на основі

TensorFlow. Нижче розглянемо переваги, які має платформа Keras порівняно з іншими засобами розпізнавання об'єктів.

1. На відміну від стандартних фотографій із трьома каналами RGB, рентгенівські зображення мають різний спектр відтінків сірого, створюючи в такий спосіб велику кількість каналів обробки сигналів. Keras дає змогу користувачам обробляти необмежену кількість каналів, що спрощує обрахунки на апаратному рівні.

2. Архітектура системи Keras розроблена із метою швидкого завантаження навчальних даних; модульна структура Keras забезпечує гнучкість та ефективну взаємодію науковою платформою Python.

3. Keras є портативним інструментом на різних настільних платформах (Windows, Mac, Linux) та мобільних пристроях.

4. Keras дає змогу будувати та навчати DL моделі із написанням кількох рядків коду. Водночас він забезпечує створення абстрактних рішень зі зрозумілим та легко налаштовуваним кодом.

5. Keras тісно інтегрований з іншими засоби наукових обчислень, як от, NumPy, SciPy, Scikit-learn та інші.

6. Keras виконує ефективне автоматичне диференціювання (символьне) та забезпечує автоматичну оптимізацію коду для підвищення швидкості та стабільності виконуваного коду.

З допомогою Keras сучасні засоби виявлення об'єктів на зображеннях можуть бути реалізовані за кілька десятків рядків коду. Keras є відмінним засобом як для проведення експериментів із конструюванням архітектур DL, так і для оптимізації вже наявних моделей. Цей інструмент дає змогу збільшувати продуктивність унаслідок модульної структури та низького порогу входження.

1.3.5 Статистичні критерії оцінювання засобів ідентифікації

Насамкінець, наведемо статичні показники [141], що використовуються в дисертаційній роботі для оцінювання моделей виявлення пневмонічних ознак. Для цього позначимо через P кількість дійсних позитивних випадків виявлення пневмонії, а через N – дійсних негативних. Тоді результати класифікації можемо поділити на як істинно позитивні (TP), істинно негативні (TN), хибно позитивні (FP) та хибно негативні (FN) випадки. Нижче опишемо використані статистичні критерії через відомі математичні співвідношення.

Точність (ACC) класифікації визначається так

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}. \quad (1.20)$$

Влучність (Precision) позначається так

$$Precision = \frac{TP}{TP + FP}. \quad (1.21)$$

Повноту (Recall) подано у такий спосіб

$$Recall = \frac{TP}{TP + FN}. \quad (1.22)$$

Хибнопозитивний рівень (FPR), або ймовірність помилки першого роду, виражається так

$$FPR = \frac{FP}{FP + TN}. \quad (1.23)$$

Хибнонегативний рівень (FNR), або ймовірність помилки другого роду, визначається так

$$\text{FNR} = \frac{\text{FN}}{\text{TP} + \text{FN}}. \quad (1.24)$$

Для обрахування відмінності між зразками із виявленою пневмонією та без пневмонії застосовано оцінку площі під ROC-кривою (AUC) для двох класів, що визначена у такий спосіб

$$\text{AUC} = \frac{1}{2} \left(\frac{\text{FP}_n}{\text{FP}_n - \text{TN}_n} - \frac{\text{FP}_p}{\text{FP}_p - \text{TN}_p} \right) \cdot \left(\frac{\text{TP}_n}{\text{TP}_n - \text{FN}_n} - \frac{\text{TP}_p}{\text{TP}_p - \text{FN}_p} \right). \quad (1.25)$$

де TP_n – істинно позитивні, TN_n – істинно негативні, FP_n – хибно позитивні та FN_n – хибно негативні випадки для класу без пневмонії; TP_p – істинно позитивні, TN_p – істинно негативні, FP_p – хибно позитивні та FN_p – хибно негативні випадки для класу із пневмонією.

Крім критеріїв (1.20-1.25), нейромережева модель виявлення ознак також оцінюється за часом навчання нейронної мережі, що виражений в годинах роботи обчислювального процесора.

1.4. Постановка задачі

Дисертаційна робота присвячена розробленню інформаційної технології для реалізації індивідуального підходу діагностування пневмонії на ранній стадії. Основна ідея технології полягає в наступному: створення моделі класифікації, яка зможе виявляти слабо виражені ознаки ранньої пневмонії на

рентгенівському зображенні; реалізація методу візуального подання для інтерпретації результатів класифікації. Для досягнення мети роботи потрібно виконати наступні завдання:

- 1) створити модель класифікації на основі CNN для визначення ознак ранньої пневмонії;
- 2) обґрунтувати та розробити метод візуального подання для інтерпретації результатів класифікації;
- 3) оцінити запропоновану інформаційну технологію за кількісними та якісними показниками;
- 4) порівняти отримані результати з існуючими підходами для верифікації та валідації технології.

1.5. Висновки до розділу 1

У розділі визначено актуальність застосування інформаційних технологій у галузі цифрового діагностування захворювань легень за медичними зображеннями грудної клітини. На основі проведено аналізу методів та підходів до виявлення пневмонії встановлено, що нейромережеві моделі є найкращим рішенням для розроблення інформаційної технології раннього діагностування. Досліджено методи для налаштування нейромережевої моделі та підходи до пояснення та інтерпретування результатів ідентифікації захворювання легень.

Отже, за аналізом сучасних підходів, методів та інформаційних технологій для діагностування захворювання легень на ранніх стадіях за медичними зображеннями грудної клітини обґрунтовано потребу в створенні інформаційної технології раннього діагностування пневмонії зроблено постановку задачі.

РОЗДІЛ 2.

МОДЕЛІ ТА МЕТОДИ ДЛЯ ВИЯВЛЕННЯ ПНЕВМОНІЧНИХ ОЗНАК НА
МЕДИЧНИХ ЗОБРАЖЕННЯХ

У розділі розглянуто теоретичні засади, а саме модель та методи, за допомогою яких стане можливим реалізувати ІТ для виявлення пневмонічних ознак захворювання легень на ранніх стадіях за рентгенівськими зображеннями.

Для досягнення мети виявлення та ідентифікації захворювання легень на ранніх стадіях пропонується модель, в основу якої покладено нейромережеву модель за згортковою архітектурою (CNN). Особливістю запропонованої моделі є використання за навченою CNN гіперпараметрів та параметрів РА для виявлення пневмонічних ознак у випадках індивідуальних особливостей легень, які не входили в початкову навчальну вибірку. Такий підхід дасть змогу використовувати навчену CNN для прогнозування класів захворювання без перенавчання.

Запропонована модель складається безпосередньо з нейромережевої моделі за архітектурою CNN та вектору квазіоптимальних параметрів РА. Запропонована архітектура містить глибинні та точкові згорткові операції з різними коефіцієнтами розширення. У різних розширених згорткових шарах запропоновано використовувати спадні (від 5×5 до 1×1) та зростаючі (від 1×1 до 3×3) розміри ядер, що дасть змогу охопити більше рецептивне поле на зображенні. Також запропоновано ініціалізувати ваги ядра на першому згортковому шарі новими запропонованими автором роботи значеннями модифікованого оператора Собеля для чіткішого виділення границь розсіяних пневмонічних ущільнень на зображенні. Подібна модифікація дозволяє виявляти як щільно локалізовані, так і сильно розсіяні пневмонічні ознаки на значній площині рентгенівського зображення.

Визначення вектору квазіоптимальних гіперпараметрів CNN здійснюється за генетичним алгоритмом із динамічною зміною хромосом. Попереднє

налаштування гіперпараметрів CNN забезпечує впровадження індивідуального підходу до раннього діагностування пневмонії.

Також у розділі наведено систему візуалізації рентгенівського зображення для підкреслення (локалізації) виявлених ознак захворювання за механізмом теплових карт, що дає змогу інтерпретувати результати прогнозування класів легеневого захворювання.

2.1. Модель для виявлення пневмонічних ознак на медичних зображеннях

Подамо модель у вигляді лінійного відображення:

$$f : I \rightarrow \langle \mathbf{V}, \mathbf{R} \rangle, \quad (2.1)$$

де I – матриця пікселів вхідного рентгенівського зображення із областю легень у навчальному наборі даних (процедуру отримання рентгенівського зображення описано в п. 1.2.2), $I \in \mathbf{I}^n$, \mathbf{V} – згорткова нейромережева модель, що виконує виявлення пневмонічних ознак та складається із різних згорткових операцій, як от, точкова, глибинна та розширена згортки, \mathbf{R} – вектор параметрів рентгенологічного апарату.

За наведеною моделлю (2.1) для ідентифікації використаємо пороговий класифікатор із двома виходами:

$$y = \varphi(f(I_k)) = \begin{cases} 1, & \text{якщо } \mathbf{V}_k > \theta; \\ 0, & \text{якщо } \mathbf{V}_k \leq \theta. \end{cases} \quad (2.2)$$

де I_k – матриця пікселів k -го зображення легень у тестовому наборі даних $I_k \in \mathbf{I}^m$, θ – порогове значення функції класифікації φ .

У (2.1) згорткова нейромережева модель (V) має наступні особливості:

1) архітектура нейромережевої моделі складається з різних типів функціональних операцій, як от, згорткова операція, нелінійна активація, пакетна нормалізація, усереднений глобальний підвибірковий шар, повнозв'язний шар та сигмоїдальна функція класифікації; поєднання цих операцій має на меті забезпечити навчання та оптимізацію CNN для виявлення пневмонічних ознак за мінімально можливою обчислювальною складністю;

2) запропоновано два залишкових згорткових блоки, кожний із яких містить поєднання точкової та глибинної згортки, що дає можливість закріпити карти ознак i , у такий спосіб, оптимізувати глибоку CNN без надмірного перенавчання;

3) у різних згорткових шарах запропоновано використовувати спадні (від 5×5 до 1×1) та висхідні (від 1×1 до 3×3) розміри ядер для охоплення більшого рецептивного поля на зображенні; водночас більше рецептивне поле дозволяє локалізувати розсіяні пневмонічні ознаки на значній площині зображення та відповідно підвищити точність класифікації нейромережевої моделі для ідентифікації легеневого захворювання;

4) кожна згорткова операція містить розширене ядро з різними коефіцієнтами розширення, що призначені для вилучення просторової інформації на зображенні щодо ущільнення легеневої тканини, що є характерним для захворювання легень на ранній стадії;

5) ваги ядра на першому згортковому шарі ініціалізовано новими запропонованими автором роботи значеннями модифікованого оператора Собеля для чіткішого виділення границь розсіяних пневмонічних ущільнень на зображенні; така модифікація має на меті налаштувати CNN під виділення пневмонічних ознак, що є характерними ранній стадії легеневого захворювання.

З аналізу джерел у п. 1.1 стало відомо, що пневмонічні ознаки вірусного легеневого захворювання на ранніх стадіях діагностування мають певний ступінь подібності з ознаками вірусної та бактеріальної пневмонії на більш пізніх стадіях

як із клінічної, так і з фізіологічної точок зору. Зважаючи на результати аналізу, припускаємо, що метод передавального навчання може дати можливість вилучити інформацію щодо пневмонічних ознак на ранній стадії з великої кількості рентгенівських зображень грудної клітини, що зібрані у хворих на пневмонію на пізніх стадіях захворювання.

Узагальнена схема запропонованого підходу навчання та використання нейромережевої моделі наведено на рис 2.1.

Спершу нейромережева модель навчається на великому наборі рентгенівських зображень за двома класами: пневмонія та нормальний стан здоров'я. Далі до попередньо навченої мережі застосовується метод підбору квазіоптимальних гіперпараметрів для налаштування мережі саме для виявлення ознак вірусного легеневого захворювання на ранніх стадіях. Оскільки згорткові шари оптимізовані для вилучення просторових пневмонічних ознак із рентгенівських зображень, ваги цих шарів передаються для фінального навчання на малому наборі даних. Попередньо навчена CNN з індивідуально підібраними гіперпараметрами та оптимізованими згортковими шарами вилучає пневмонічні ознаки захворювання легень на ранніх стадіях. Насамкінець, вектор вилучених пневмонічних ознак передається до моделі класифікації на етапі використання для встановлення класу тестового рентгенівського зображення.

Далі детально розглянемо архітектуру згорткової нейромережевої моделі та вектор параметрів рентгенологічного апарату. Також нижче наведемо опис особливостей запропонованого підходу для реалізації ІТ для раннього діагностування пневмонії, що не потребує перенавчання CNN.

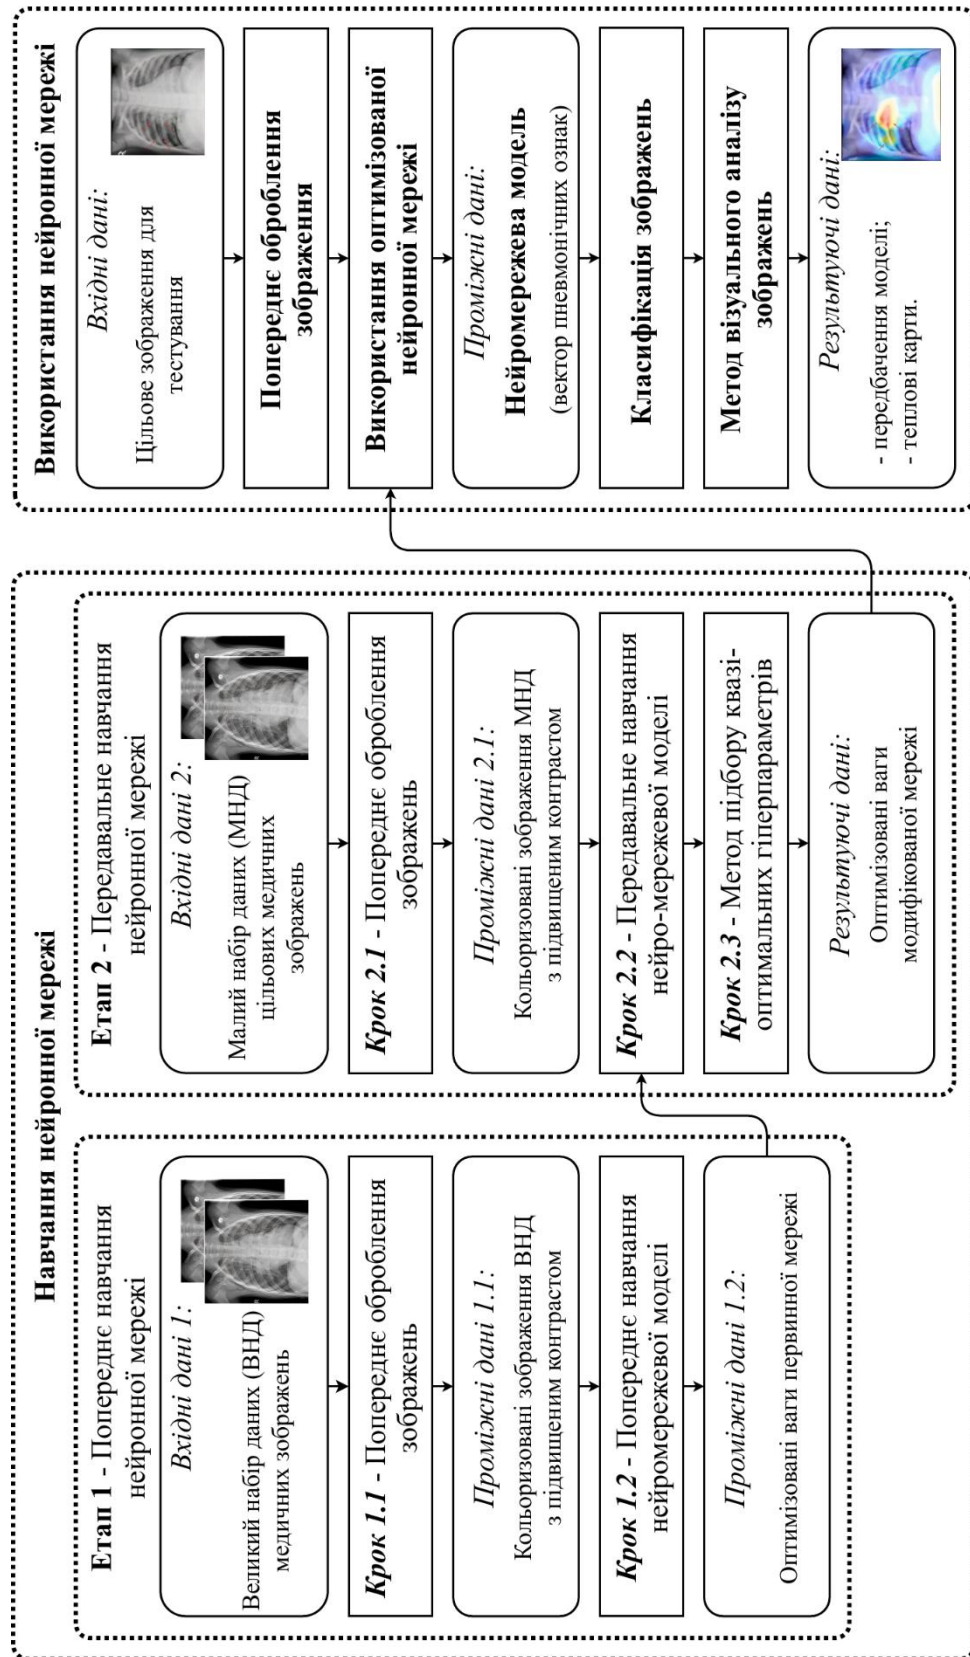


Рис. 2.1 – Узагальнена схема запропонованого підходу до навчання та використання нейромережевої моделі

2.2. Опис запропонованої згорткової архітектури нейромережевої моделі

У п. 1.1 встановлено, що пневмонічні ознаки захворювання легень на ранніх стадіях можуть бути або ледь помітно локалізованими (ущільненими) або розсіяними на значній площині рентгенівського зображення. Тому пропонується виявляти такі ознаки на різних рівнях спостережень. Також у п. 1.3.1 визначено, що операція розширеної згортки (див. рис. 1.5) виконує розширення рецептивного поля згорткового шару без збільшення розміру його ядра лише зі збільшенням коефіцієнта розширення. Тому висуваємо припущення, що застосування операції розширеної згортки на різних згорткових шарах із різними значеннями коефіцієнта розширення забезпечуватиме більшу різноманітність під час вилучення пневмонічних ознак на рентгенівському зображенні.

2.2.1 Ініціалізація ваг фільтрів

Перш за все, наведемо ініціалізацію ваг згорткового ядра на першому згортковому шарі. Значення ваг ініціалізовано вручну у зв'язку із налаштуванням CNN під виявлення специфічних пневмонічних ознак. В якості початкового розподілення ваг ядра використано оператор (фільтр) Собеля. Фільтр Собеля характеризується трьома перевагами (див. п. 1.3) порівняно з іншими фільтрами:

- 1) низька обчислювальна складність;
- 2) висока якість виділення границь об'єктів на зображенні;
- 3) висока стійкість до цифрового шуму зображення.

Традиційний оператор Собеля використовує два окремих ядра з розміром 3×3 для вилучення горизонтальних (G_x) та вертикальних (G_y) границь на зображенні. Проте для охоплення більшого рецептивного поля розмір ядра на першому згортковому шарі підвищено до 5×5 . Також пропонуються нові

значення ядра для виділення безпосередньо горизонтальних (P_x) та вертикальних (P_y) границь розсіяних ущільнень на рентгенівському зображенні, що є характерними для ранньої стадії легеневого захворювання. Запропоновану модифікацію до оператора Собеля зображено на рис. 2.2.

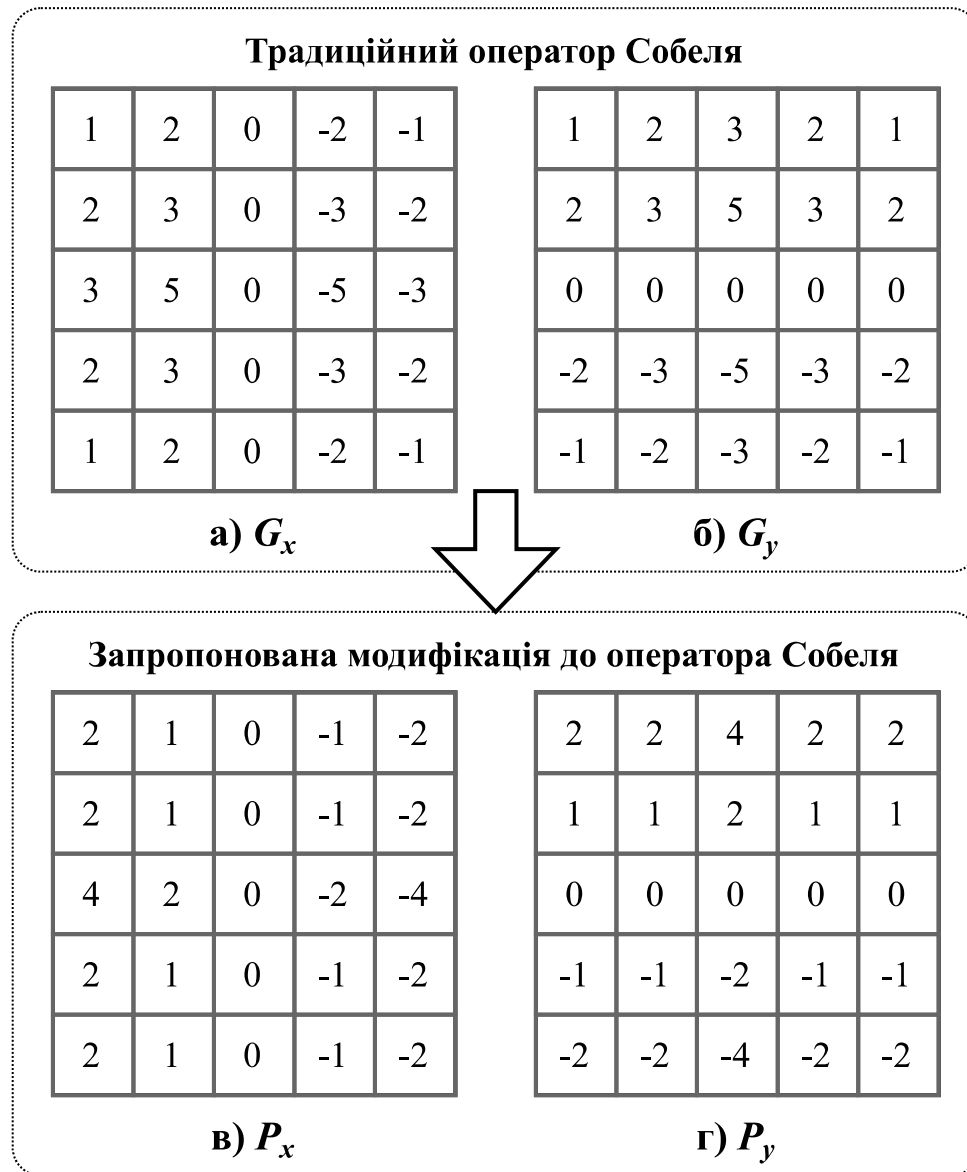


Рис. 2.2 – Значення ядер оператора Собеля 5×5 :

а)-б) традиційні; в)-г) запропоновані у роботі

Використання лише одного з горизонтальних (P_x) або вертикальних (P_y) фільтрів іноді призводить до виникнення значного цифрового шуму зображення. Тому для уникнення шуму обидва ядра P_x та P_y використовуються по чергово. Приклад застосування модифікованого оператора Собеля наведено на рис. 2.3.




Рис. 2.3 – Порівняння застосування фільтрів у першому згортковому шарі:
а) вхідні зображення; б) традиційний оператор Собеля; в) запропонована
модифікація

Як бачимо із рис. 2.3, запропонована модифікація (рис. 2.3в) дає змогу більш чіткіше виявити границі всіх ущільнень в легенях порівняно з традиційним оператором Собеля (рис. 2.3б). Крім того, рівень цифрового шуму на зображенні в результаті впровадження запропонованої модифікації є прийнятним для подальшого застосування згорткових шарів.

2.2.2 Глибинна та точкова згорткові операції

В архітектурі CNN використано поділ традиційної операції згортки на глибинну та точкову згортки. Тут глибинна згортка виконує роль просторової операції, де кожний вхідний канал відособлено обробляється різними фільтрами. Після цього виконується точкова згортка з розміром ядер згортки 1×1 для проєктування міжканальних ознак у новий простір ознак. Загалом такий підхід має забезпечити обчислювально ефективне навчання CNN.

За результатами проведеного аналізу джерел у п. 1.3.1, CNN із залишковими з'єднаннями [120] демонструє найкращі результати в задачах ідентифікації легеневих захворювань на рентгенівських зображеннях. Тому в дисертаційній роботі за основу нейромережевої моделі взято архітектуру залишкової CNN з додатковими згортковими блоками. Два згорткових блоки схематично зображено на рис. 2.4-2.5.

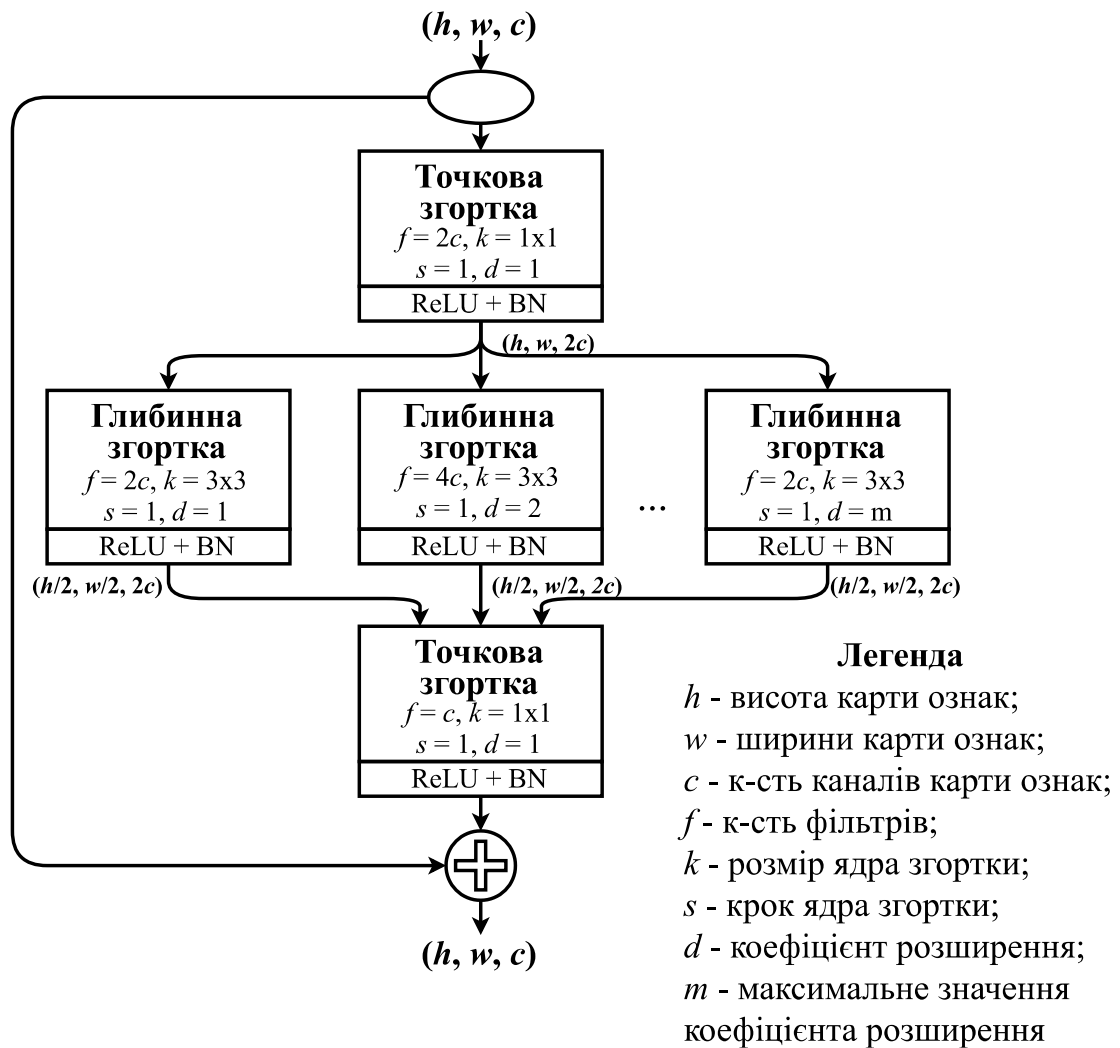


Рис. 2.4 – Схема залишкового згорткового блоку

Обидва згорткові блоки (див. рис. 2.4-2.5) містять у своїй структурі точкову (1.9) та глибинну (1.10) розширені згортки. Вхідна карта ознак піддається точковій згортковій операції, у результаті чого міжканальна інформація проєктується в ширший простір ознак. Далі виконуються глибинні розширені згорткові операції з різними коефіцієнтами розширення d , $d = \overline{1, m}$, де m регулюється відповідно до форми вхідної карти ознак для покриття необхідного рецептивного поля. Глибинні розширені згортки вилучають просторові ознаки з різних рецептивних полів, від дуже ущільнених до дуже розсіяних ознак на всій

площині зображення. В урешті-решт, усі ці різноманітні ознаки об'єднуються в один простір ознак на точковому згортковому шарі.

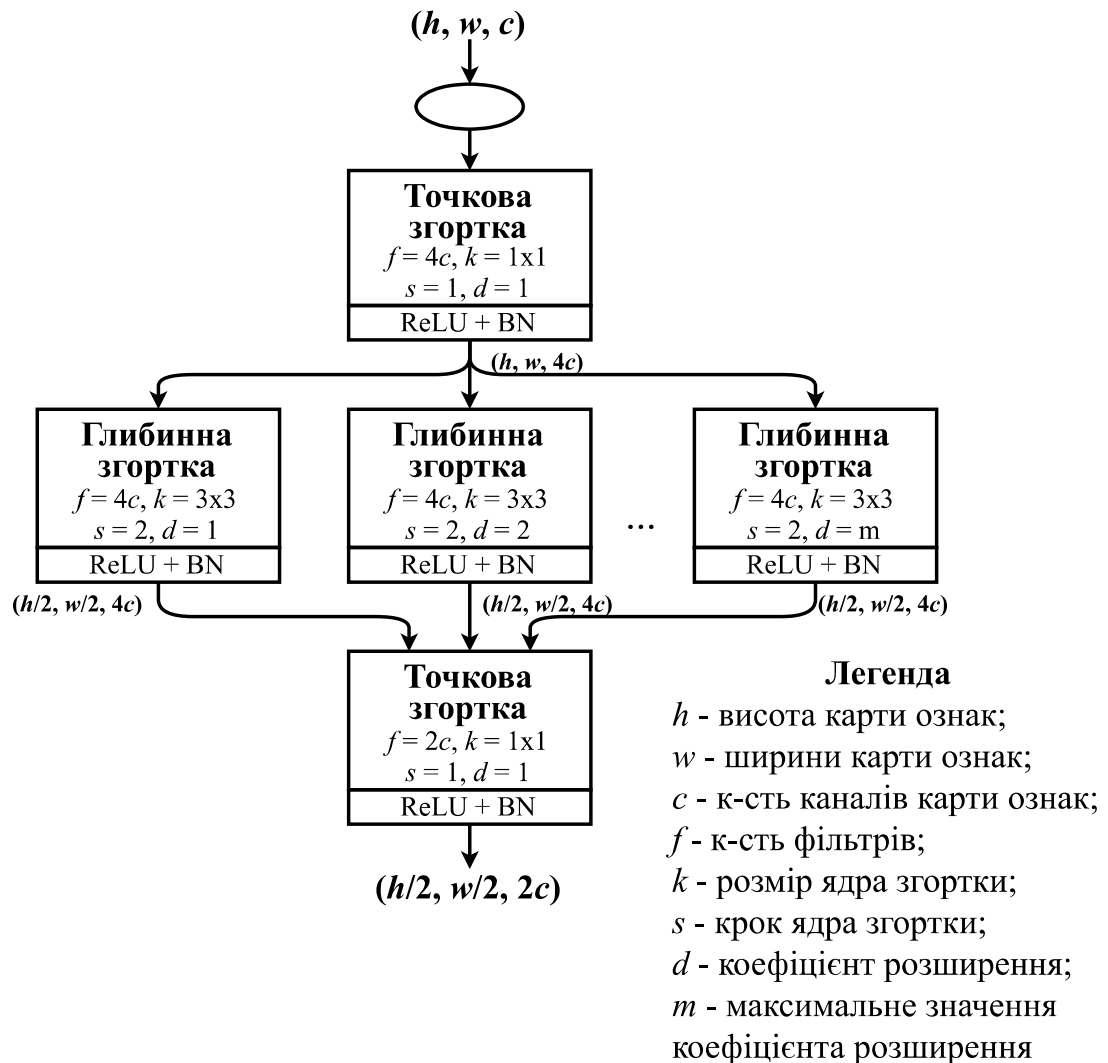


Рис. 2.5 – Схема залишкового згорткового блоку із перемиканням

У залишковому згортковому блоці запропоновані глибинно-точкові згорткові операції відповідають залишковому відображенню (див. рис. 2.4), що описане в оригінальній роботі залишкової мережі [114]. Це відображення фіксує карти ознак, що дає можливість створити глибоку CNN без надмірного перенавчання. У залишковому згортковому блоці з перемиканням вхідна карта ознак зазнає розмірних перетворень (див. рис. 2.5). По-перше, глибина вхідної

карти ознак збільшується вчетверо, щоби забезпечити більшу кількість просторових скорочень. Далі просторові розмірності вдвічі зменшуються через крок глибинних згорток. Таке просторове скорочення розширює рецептивне поле для подальшого узагальнення цільових ознак. Насамкінець, глибина результуючої карти ознак підвищується вдвічі в останній точковій згортці для збільшення кількості операцій фільтрації на останніх шарах НМ.

2.2.3 Архітектура згорткової нейронної мережі

Отже, у роботі пропонується нейромережева модель за архітектурою залишкової CNN, що зображена на рис. 2.6.

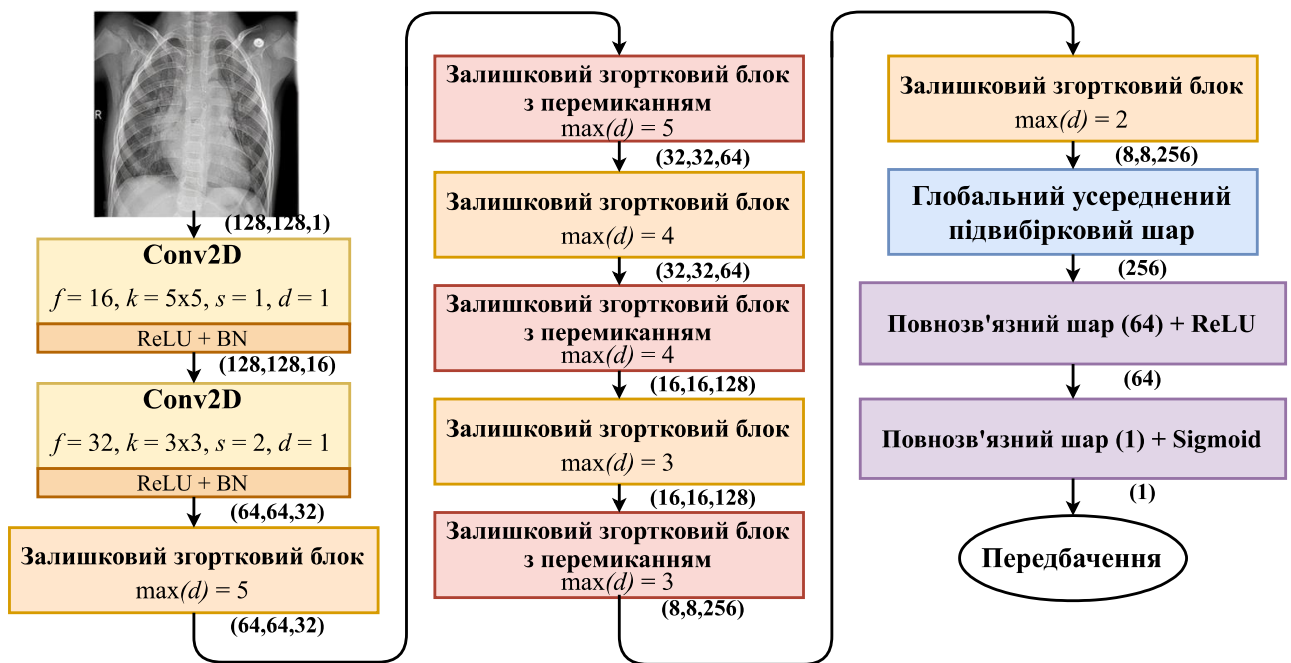


Рис. 2.6 – Схема архітектури запропонованої залишкової CNN

Відповідно до рис. 2.6, вхідне зображення піддається двом розширеним згортковим операціям із ядрами згортки 5×5 та 3×3 для оброблення інформації з більшим рецептивним полем. Після кожної операції згортки розташовуються

функція активації ReLU (1.7) для приведення результуючого сигналу до нелінійного стану та пакетна нормалізація BN (1.11) для прискорення навчання НМ. Далі, отримана карта ознак, проходить через кілька залишкових згорткових блоків. Залишкові блоки з перемиканням розташовані між залишковими блоками для введення розмірної трансформації, щоби надалі об'єднати ознаки в один простір. Зазначимо, що максимальні значення коефіцієнта розширення (m) на кожному залишковому блоці встановлені заздалегідь на основі розмірів вхідної карти ознак. Для оброблення більш розсіяних ознак значення m встановлюється вищим, щоби розширити рецептивне поле залишкового блоку i , відповідно, охопити більше варіацій вилучених ознак. Нарешті, оброблена карта ознак проходить через глобальний усереднений підвибірковий шар GAP (1.12), за яким розташовано повнозв'язний шар із ReLU (1.13) повнозв'язний шар із Sigmoid (1.14) для остаточного прогнозування класу захворювання.

Типове навчання CNN полягає в оптимізації великої кількості ваг на картах ознак, що є зазвичай є обчислювально складною задачею для будь-якого набору даних. Тому в роботі пропонується використати механізм передавального навчання, що полягає у попередньому навчанні CNN (оптимізації ваг мережі) на великому наборі даних та передачі цих ваг до фінального навчання на малому наборі даних. Водночас пропонується внести модифікацію до архітектури CNN на етапі передавального навчання для забезпечення обчислювальної ефективності. Схему архітектури CNN на етапі передавального навчання зображено на рис. 2.7.




Рис. 2.7 – Архітектура згорткової нейронної мережі на етапі передавального навчання

Спершу ваги усіх згорткових шарів включно із залишковими згортковими блоками оптимізуються на великому наборі даних навчання з пневмонією. Далі ці ваги передаються до CNN з підібраними квазіоптимальними гіперпараметрами для фінального навчання на наборі валідування. Два оптимізованих згорткових шара додаються до оптимізованої CNN. Після згортки до мережі додаються усереднений глобальний підвбірковий шар та два повнозв'язних шара.

Отже, архітектура CNN (див. рис. 2.6) та модифікація до неї (див. рис. 2.7) забезпечує як сталі розширення мережі, так і мінімальні втрати розширення простору зображень. Крім того, ядро розширеної згортки дає змогу підтримувати збільшення рецептивного поля без збільшення кількості параметрів ядра й дає змогу уникнути надмірних втрат розширення карт ознак.

2.3. Метод підбору квазіоптимальних гіперпараметрів згорткової нейронної мережі

Поряд зі зростанням впливу методів DL у різних галузях людської діяльності розвиваються також підходи до підвищення продуктивності цих методів. Ключовим підходом до покращення роботи нейронних мереж, зокрема CNN, є розроблення автоматизованого налаштування оптимальних або квазіоптимальних гіперпараметрів мережі. У цьому підрозділі наводиться опис нейро-генетичного алгоритму для налаштування гіперпараметрів архітектури CNN, що була запропонована у п. 2.2. Основна мета застосування нейро-генетичного алгоритму – досягти квазіоптимальних значень гіперпараметрів мережі за скінченний час на малих обчислювальних пристроях, наприклад, на одному GPU.

У дисертаційній роботі за основу методу пошуку множини квазіоптимальних параметрів взято традиційний генетичний алгоритм (ГА). До ГА пропонується модифікація, що полягає в збільшенні або зменшенні складності хромосом алгоритм залежно від кількості закодованих генів.

2.3.1 Ініціалізація гіперпараметрів та параметрів навчання

Початкові значення гіперпараметрів НМ для подальшого пошуку наведено в таблиці 2.1.

Простір пошуку цільових гіперпараметрів було обмежено, відповідно до обмежених ресурсів малих обчислювальних пристроїв. Вибір неправильних операцій також заборонено.

Таблиця 2.1

Ініціалізація гіперпараметрів згорткової нейронної мережі

Гіперпараметр	Значення
Кількість фільтрів в кожному згортковому шарі	1
Розмір згорткового ядра	1×1
Крок згорткового ядра	1
Коефіцієнт розширеної згортки	1
Функція активації	ReLU
Розмір підвибіркового ядра	2×2
Крок підвибіркового ядра	1
Коефіцієнт виключення, dropout	0.8
Кількість одиниць повнозв'язного шару	256

Таблиця 2.2

Ініціалізація параметрів навчання ГА та CNN

Параметр	Значення
Генетичний алгоритм	
Коефіцієнт кросинговера	0.7
Коефіцієнт мутації	0.3
Кількість поколінь	10
Розмір початкової популяції	100
Розмір турнірної мутації	7
Згорткова нейронна мережа	
Кількість епох	починаємо з 3, далі збільшується на 1 для кожного покоління
Розмір партії (batch size)	256
Алгоритм навчання мережі	Adam

Початкові значення параметрів навчання ГА і CNN, що використовувалися для навчання НМ, подано у таблиці 2.2. Попередні дослідження проводилися через пошук діапазону значень гіперпараметрів, щоби врешті-решт дістати їхні кінцеві значення. Параметри із таблиці 2.2 були єдиними значеннями, які вводяться в запропонований метод.

Модифікований алгоритм пошуку на основі модифікованого ГА схематично подано на рис 2.8.

Алгоритм із рис. 2.8 дає змогу ефективно обробляти складні комбінації дискретних (наприклад, функція активації) та неперервних (наприклад, швидкість навчання) просторів пошуку гіперпараметрів.

2.3.2 Модифікована хромосома генетичного алгоритму

Кожна хромосома модифікованого ГА складена з двох генів, кожна з яких формує необхідні компоненти для налаштування гіперпараметрів CNN на певному наборі даних. Один ген відповідає за швидкість навчання, що застосовується під час навчання CNN, інший – за решту гіперпараметрів архітектури, що визначають функціональні залежності на кожному шарі архітектури CNN. ГА має доступ до налаштування таких шарів CNN: точкова та глибинна згорткові розширені операції, усереднений підвибірковий та повнозв'язний шари.




Рис. 2.8 – Удосконалений метод підбору квазіоптимальних гіперпараметрів згорткової нейронної мережі

Запропонований у роботі алгоритм початкового формування популяції ґрунтується на методі половинчастого згладжування [142], який дає змогу

створювати кандидатів різних розмірів. На рис. 2.9 наведено схему удосконаленого методу початкового формування популяції.




Рис. 2.9 – Запропонований алгоритм початкового формування популяції згорткової архітектури різного розміру

Запропонований алгоритм також застосовано до архітектур CNN різного розміру, щоби підвищити різноманітність складових у початковій сукупності.

2.3.3 Оператор мутації

Для кожного виконання оператора мутації за допомогою турнірного відбору здобуваємо самотнього батька. Спершу оператор мутації застосовується до батька для створення першого потомства, далі – до першого потомства, у результаті чого формується друге потомство. Порівнюється допасованість (fitness) першого потомства, другого потомства та початкової батьківської хромосоми. Хромосома з найнижчою допасованістю (запропонований метод сформульований, як задача мінімізації) повертається та поміщається в нову популяцію. Зауважимо, що оператор мутації повторюється, щоб сформувати дві варіації потомства й у такий спосіб охопити весь простір пошуку.

Для поточної хромосоми оператор мутації випадковим чином змінює або швидкість навчання хромосоми, або шари CNN. Якщо вибрано швидкість навчання, тоді випадковим чином генерується нове значення. Якщо вибрані шари CNN, тоді оператор або додає новий шар, видаляє шар, або замінює його. На рис. 2.10 проілюстровано оператори мутації заміни, видалення та додавання.

Вибір робиться на основі розміру архітектури CNN. Якщо розмір архітектури хромосоми досяг максимального розміру, то шар можна або видалити, або замінити. Однак, якщо розмір менше максимально дозволеного, шар можна або додати, видалити, або замінити. Заздалегідь визначено обмеження, щоб оператор мутації не міг видалити перший або останній шари, оскільки це призведе до недійсної мережі. Оператор видалення здійснює випадковий вибір будь-якого шару (за винятком першого або останнього шарів) і вилучає його з архітектури мережі в хромосомі. Оператор заміни випадковим чином обирає шар в архітектурі та вилучає його. Повністю новий шар формується і вставляється в тому ж місці, де був видалений шар. Оператор додавання формує новий шар і додає його у випадковому місці в архітектурі.




Рис. 2.10 – Ілюстрація операторів мутації: а) заміни, б) видалення та в) додавання

Варте уваги те, що випадковість всередині мутації може призвести до недійсних архітектур нейронних мереж. Тому після кожного застосування оператора мутації виконується перевірка для оцінювання валідності отриманої архітектури. Якщо мутація формує недійсну архітектуру, то оператор мутації застосовується знову, доки не буде створено дійсну. Насамкінець, кількість параметрів нейронної мережі обчислюється для кожного потомства.

Для оцінювання хромосом у роботі використано функцію допасованості, що використовує помилку в наборі валідування (набір даних попередньо розділений на підмножини навчання, валідування та тестування) та кількість гіперпараметрів. Нижче подано формулу функції допасованості:

$$fitness(CNN) = val_{error}(CNN) + \alpha \left(1 - \frac{1}{N(CNN)} \right), \quad (2.3)$$

де CNN – оцінювана архітектура згорткової нейронної мережі, val_{error} – помилка на наборі даних валідування, α – параметр складності (за замовчування, $\alpha = 1$), N – кількість гіперпараметрів оцінюваної CNN.

Відносна важливість помилки та кількості гіперпараметрів визначена параметром складності α . Функція допасованості (2.3) винагороджує менш складні та точні моделі проти більш складних та менш точних. Параметр складності задано $\alpha = 1$, щоби забезпечити однакове зважування між похибкою мережі та її складністю. Водночас значення α можна змінювати залежно від продуктивності та розміру мережі.

Як тільки оператор мутації породжує потомство, архітектура та гіперпараметри, що закодовані в хромосомі, використовуються для фінального налаштування нейронної мережі. Після закінчення навчання мережі на даних навчання, отримана архітектура CNN оцінюється функцією допасованості (2.3) на наборі даних валідування. Насамкінець, значення функції (2.3) зберігається, як допасованість хромосоми.

Отримані результати класифікації демонструють, що удосконалений метод підбору квазіоптимальних параметрів дає змогу досягти конкурентних показів порівняно з аналогами з використанням менших обчислювальних ресурсів.

2.4. Метод візуального подання медичних зображень для інтерпретування результатів ідентифікації захворювання легень

У розділу 1 з'ясовано, що задача інтерпретування результатів ідентифікації легеневого захворювання на зображеннях є надзвичайно актуальною у медичному діагностуванні. Виникає необхідність у розробленні додаткових механізмів, які дали б змогу медичним фахівцям зрозуміти чому нейромережева модель віднесла зображення до того чи іншого класу захворювання. У зв'язку з цим, нижче наведено опис методу візуального подання рентгенівського зображення для підкреслення (локалізації) виявлених ознак захворювання за механізмом теплових карт, що дає змогу інтерпретувати результати прогнозування класів легеневого захворювання.

За основу методу візуального подання взято градієнтний алгоритм відображення активації класів, що інтегрується до запропонованою CNN. Метод призначений для формування відображення активацій класу, що візуально локалізує ROI на зображенні. Загальну схему методу зображено на рис. .

Вхідними даними методу є:

- цифрове рентгенівське зображення (\mathbf{I}) подане у вигляді матриці чисел, кожний елемент якої визначає інтенсивність відповідного пікселя у зображенні;
- вектор пневмонічних ознак (\mathbf{V}^m , $m = \overline{1, M}$), що одержаний за допомогою CNN; де M – загальна кількість карт ознак, що одержані за допомогою CNN;
- вектор очікуваного класу ($\mathbf{C} \in \{0,1\}$), що одержаний в результаті застосування функції класифікації (1.14).

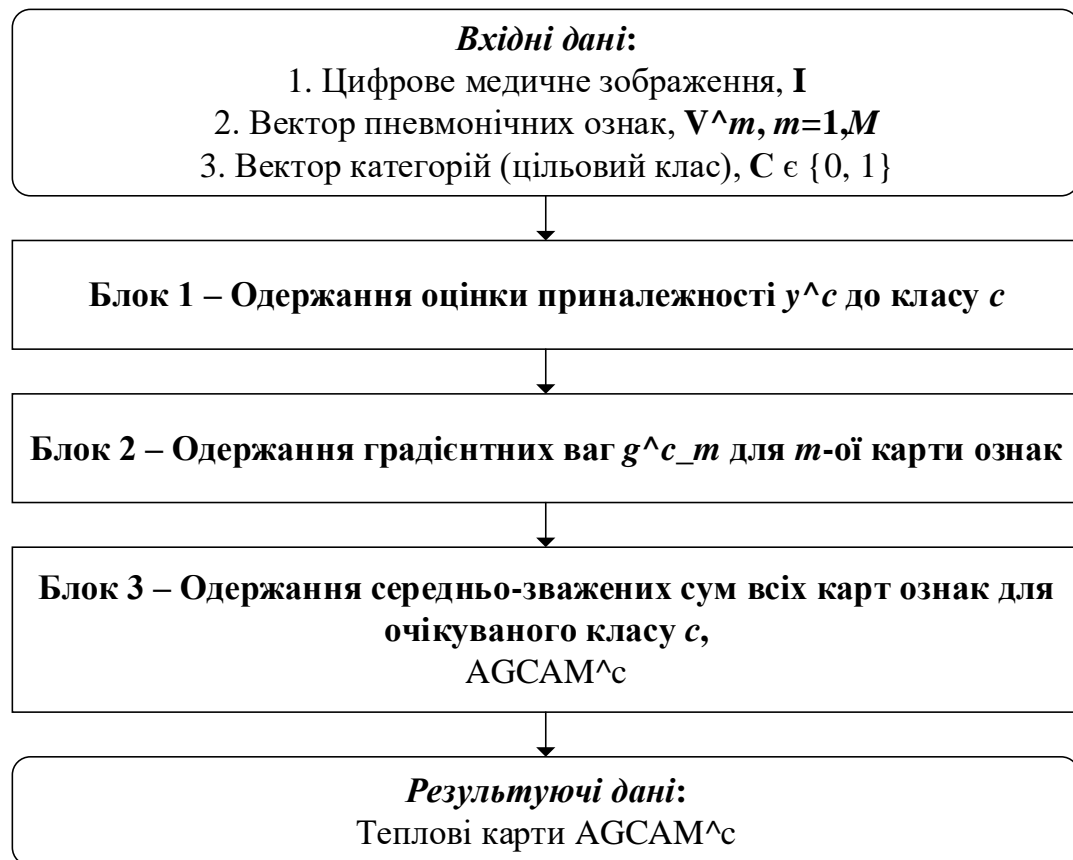


Рис. 2.11 – Загальна схема методу візуального подання медичних зображень для інтерпретування результатів ідентифікації легеневого захворювання

У блоці 1 обраховується оцінка y^c за формулою (1.15). Ця оцінка є ступенем приналежності вхідного зображення I до очікуваного класу c на результуючому шарі класифікації (1.14).

У блоці 2 обраховуються значення градієнтних ваг g_m^c за формулою (1.19). Операція обрахування ваг (1.19) відображає зворотну часткову лінеризацію CNN від результуючого шару до першої карти ознак V^1 , а самі ваги g_m^c відображають важливість карти ознак m для очікуваного класу c . Відповідно до формул (1.15) та (1.18), значення g_m^c рівноцінне значенню ваг w_m^c для мереж із архітектурою, що сумісна з SAM (див. 1.16). Різниця полягає у подальшому застосуванні

функції неліаризації (1.7) для виключення впливу негативних ваг, які, ймовірно, належать іншим класам.

У блоці 3 обраховуються середньозважені карти активації класів. Для цього у роботі запропоновано модифікацію обрахування GCAM (див. 1.18):

$$AGCAM_{i,j}^c = \text{ReLU} \left(\sum_{k=1}^K \left(\sum_{m=1}^M g_m^c v_{i,j,m} \right)_k \right), \quad (2.4)$$

де $\sum_{k=1}^K \left(\sum_{m=1}^M g_m^c v_{i,j,m} \right)_k$ – це значення градієнтних карт активації класів на площині зображення (i, j) для k -го зображення в очікуваному класі c , K – загальна кількість зображень на виході підвибіркового шару.

Теплові карти (2.4) формуються у вигляді двовимірних оціночних сіток, що розраховуються для кожного розташування точок вхідного зображення. Запропонована модифікація AGCAM відображає ROI на рівні класу, що вважається найбільш значущим для правильного прогнозування для всіх входів, що належать до даного класу. Також метод AGCAM дає змогу застосовувати карти активації класів до CNN з будь-якими типами шарів.

Результуючими даними методу є теплові карти $AGCAM_{i,j}^c$ на площині зображення (i, j) для очікуваного класу c . Ці карти візуально накладаються на початкове зображення та підкреслюють (локалізують) ті частини зображення, які призвели до вибору того чи іншого класу легеневого захворювання. Далі ці локалізації аналізуються, щоб інтерпретувати роботу CNN з клінічної точки зору.

Накладені теплові карти, як приклад застосування методу візуального подання, зображено на рис. 2.12.

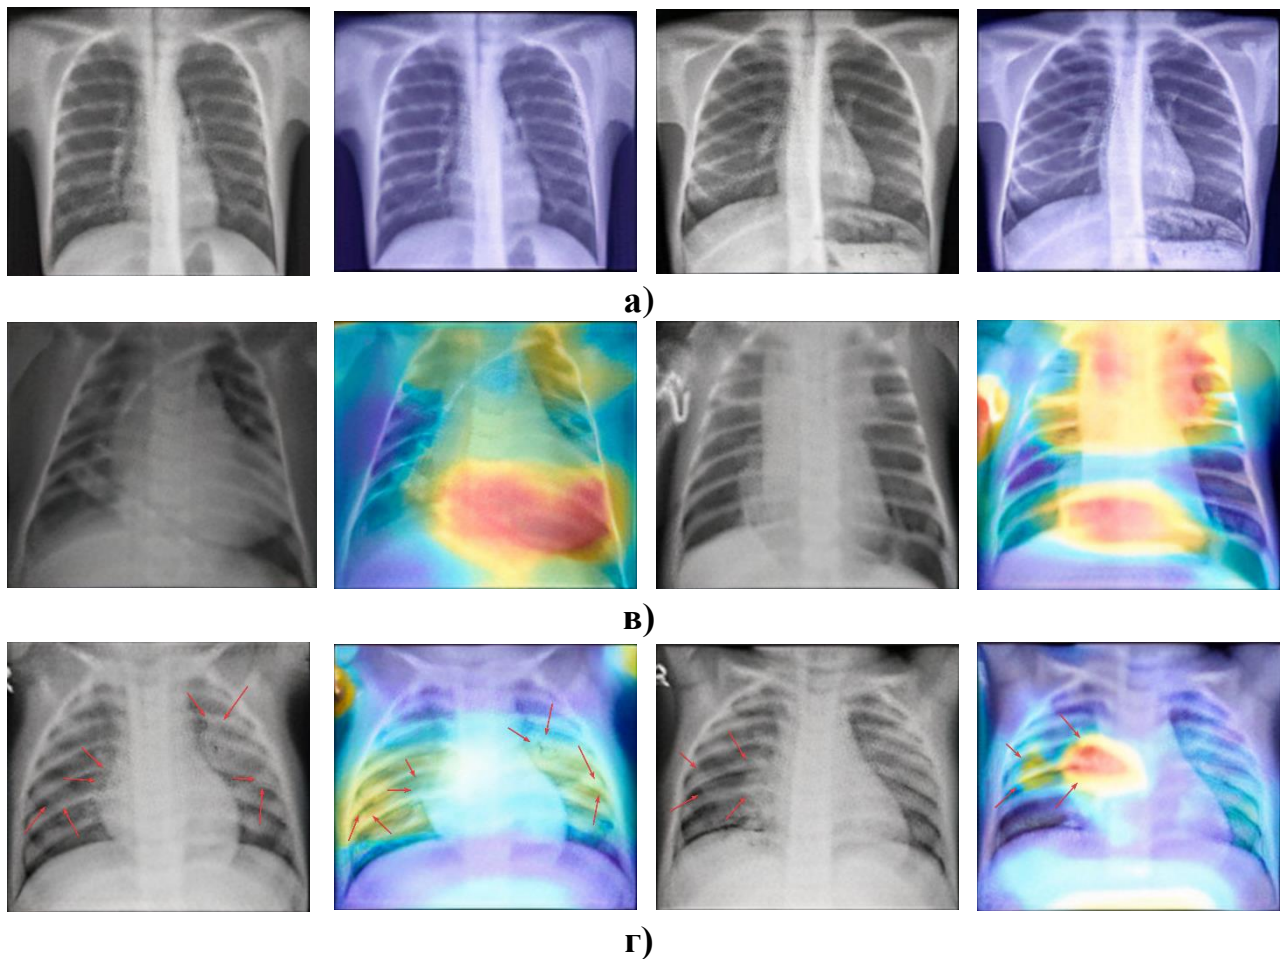


Рис. 2.12 – Візуальна інтерпретація роботи CNN через метод візуального подання через градієнтну локалізацію: а) нормальний стан легень; б) зображення легень із вірусною пневмонією на пізніх стадіях; в) зображення легень із вірусною пневмонією на ранній стадії;

На рентгенівських зображеннях із нормальним станом легень відсутні які-небудь візуальні непрозорі помутніння. На зображеннях на рис. 2.12а) немає яскраво-вираженого червоного забарвлення, що свідчить про відсутність легеневого захворювання.

З аналізу теплових карт на рис. 2.12б) бачимо, що за допомогою методу локалізовано значні області з двосторонніми мультифокальними помутніннями із матового скла разом з нерівними ущільненнями в деяких випадках. Крім того, деякі локалізовані регіони містять розсіяне матове скло та багаточисельні

інфільтрації. Подібні локалізовані ознаки також є загально визнаними рентгенологічними ознаками традиційної вірусної пневмонії на пізніх стадіях.

Відповідно до аналізу джерел у п. 1.1 встановлено, що пневмонічні ознаки захворювання легень на ранній та пізніх стадіях хоча і мають певні відмінності, але загалом мають вигляд двостороннього матового скла разом з деякими неоднорідними ущільненнями. Деякими більш імовірними ознаками ранньої пневмонії є легко виражене периферичне та розсіяне затемнення легеневої тканини. На рис. 2.12 бачимо, що яскраво-червоне забарвлення відповідає розсіяному розподілу таких помутнінь.

Отже, в результаті аналізу рис. 2.12 отримали, що пневмонічні ознаки, які вилучені запропонованою CNN та локалізовані методом візуального подання CovXNet, надають істотну інформацію щодо можливої наявності легеневого захворювання. Подібний підхід із локалізацією ROI може допомогти медичним фахівцям інтерпретувати результати роботи запропонованої CNN, і, як наслідок, асистувати у діагностуванні легеневого захворювання на ранніх стадіях.

2.5. Висновки до розділу 2

Отримано теоретичні засади, а саме модель та методи, за допомогою яких стане можливим реалізувати ІТ для виявлення пневмонічних ознак захворювання легень на ранніх стадіях на рентгенівських зображеннях.

1. Вперше розроблено нейромережеву модель за згортковою архітектурою для досягнення мети виявлення та ідентифікації захворювання легень на ранніх стадіях. Особливістю запропонованої моделі є використання за навченою CNN гіперпараметрів для виявлення пневмонічних ознак у випадках індивідуальних особливостей легень, які не входили в початкову навчальну вибірку. Такий підхід дасть змогу використовувати навчену CNN для прогнозування класів захворювання без перенавчання.

2. Запропонована нейромережева модель складається безпосередньо з нейромережевої моделі за архітектурою CNN та вектору параметрів PA. Запропонована архітектура містить глибинні та точкові згорткові операції з різними коефіцієнтами розширення. У різних розширених згорткових шарах запропоновано використовувати спадні (від 5×5 до 1×1) та зростаючі (від 1×1 до 3×3) розміри ядер, що дасть змогу охопити більше рецептивне поле на зображенні. Подібна модифікація дозволяє виявляти як щільно локалізовані, так і сильно розсіяні пневмонічні ознаки на значній площині рентгенівського зображення.

3. Удосконалено метод підбору векторів квазіоптимальних гіперпараметрів на основі генетичного алгоритму із динамічною зміною хромосом. Це дає нагоду впроваджувати індивідуальний підхід до раннього діагностування пневмонії.

4. Удосконалено метод візуального подання рентгенівського зображення для підкреслення (локалізації) виявлених ознак захворювання за механізмом теплових карт, що дає змогу інтерпретувати результати прогнозування класів легеневого захворювання.

РОЗДІЛ 3.

ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ РАНЬОГО ДІАГНОСТУВАННЯ ПНЕВМОНІЇ ЗА МЕДИЧНИМИ ЗОБРАЖЕННЯМИ ГРУДНОЇ КЛІТИНИ

У розділі пропонується інформаційна технологія (ІТ) раннього діагностування пневмонії (РДП) за індивідуальним підбором квазіоптимальних гіперпараметрів моделі для ідентифікації захворювання легень за рентгенівськими зображеннями легень.

Розроблена ІТ призначена для допомоги медичним фахівцям у прийнятті рішень щодо наявності в пацієнта захворювання легень на ранній стадії за його медичним зображенням. Застосування ІТ полягає в автоматизованому перетворенні вхідної інформації, що подана як цифрове зображення рентгенівського випромінювання грудної клітини людини, у результуючу інформацію як діагноз захворювання людини з візуалізацією ділянок легень з патогенними змінами. Цифрове рентгенівське зображення подається як матриця чисел, кожний елемент якої визначає інтенсивність відповідного пікселя в зображенні. Діагноз у такому випадку визначений оцінкою стану захворювання легень людини, рентгенівське зображення якої аналізується з допомогою ІТ.

Запропонована ІТ ґрунтується на використанні моделі для ідентифікації пневмонії, яка містить пневмонічні ознаки захворювання легень. Для наповнення елементів моделі пропонується застосувати механізм виявлення ознак захворювання легень за допомогою НМ та метод підбору квазіоптимальних гіперпараметрів НМ на основі генетичного алгоритму. Однією з основних особливостей ІТ є візуальне подання результатів ідентифікації захворювання легень, що дасть змогу медичним фахівцям інтерпретувати виявлення ознак захворювання на медичному зображенні.

У розділі подається загальна схема та кроки ІТ, а також наводиться опис проєктування запропонованої ІТ як інформаційної системи (ІС). Визначено схему

розподілу функцій за компонентами системи та класифіковано функції користувача ІС. На основі розглянутих вимог та сценаріїв використання ІТ розроблено архітектуру ІС, яка ґрунтується на класичній трирівневій архітектурі програмних застосунків.

3.1. Загальна схема та кроки інформаційної технології

ІТ раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень використовує запропоновану у п. 2.1 модель для ідентифікації захворювання легень та метод візуального подання результатів ідентифікації захворювання легень (див. п. 2.4).

Схематично застосування моделі та методу у ІТ подано на рис. 3.1.



Рис. 3.1 – Схема застосування неймережевої моделі та методу візуального подання в інформаційній технології

З рис. 3.1 бачимо, що зображення легень, подане у вигляді моделі (2.1)-(2.2), з подальшим застосуванням удосконаленого методу візуального подання визначає мету запропонованої ІТ. Узагальнену схему застосування ІТ РДП подано на рис 3.2.

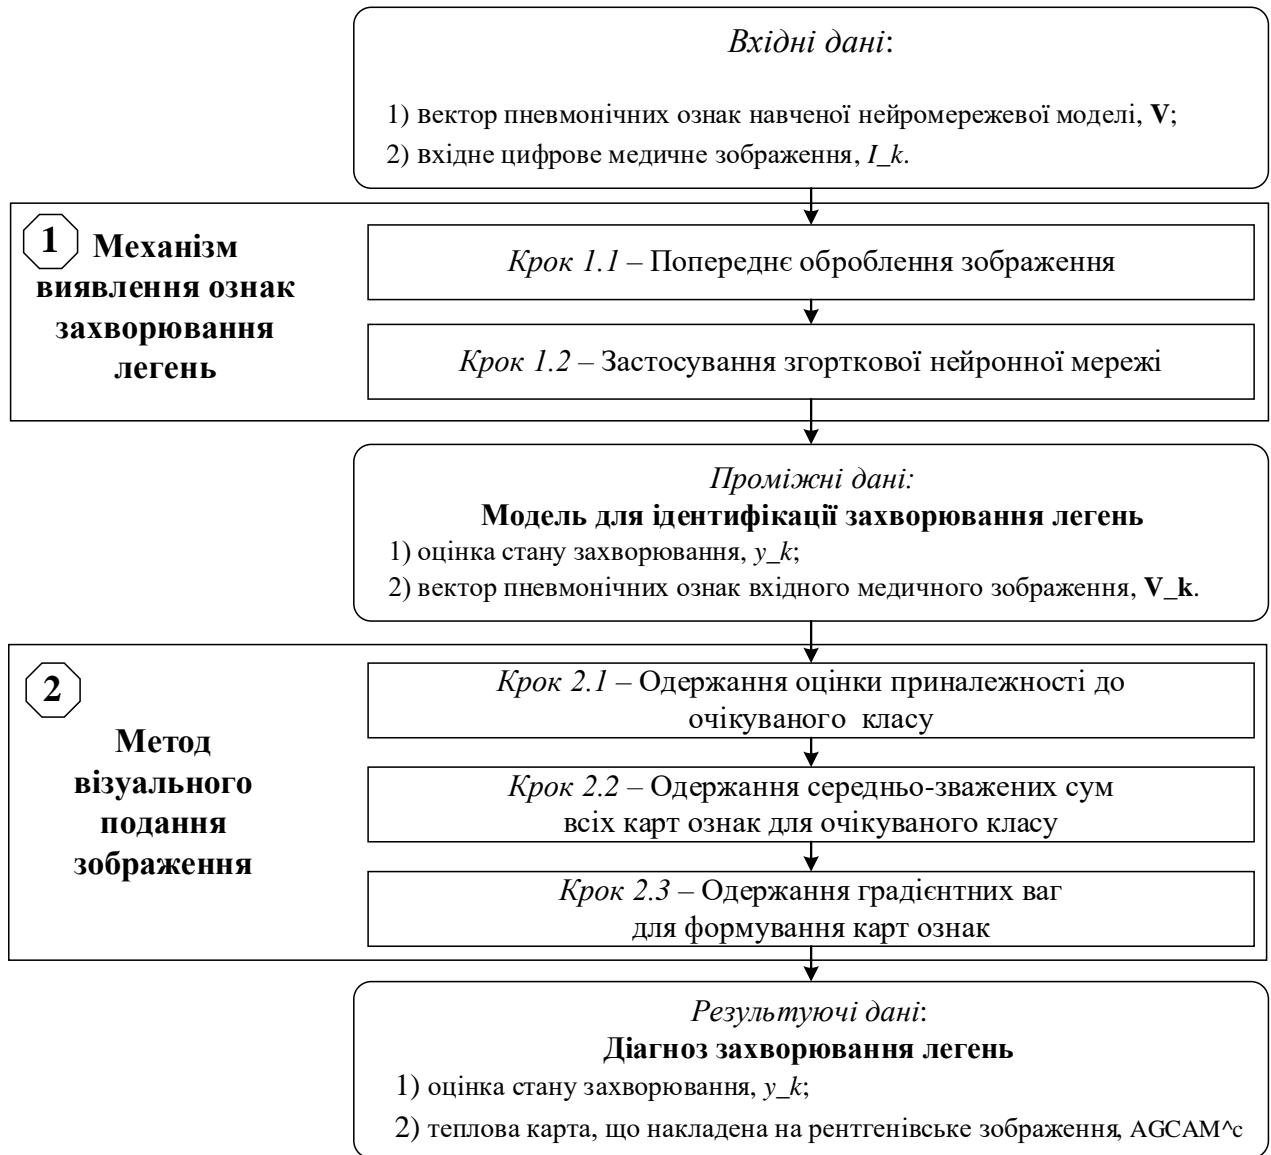


Рис. 3.2 – Узагальнена схема використання інформаційної технології

Вхідними даними ІТ є два елементи:

1) вхідне цифрове рентгеновське зображення (ЦРЗ) у форматі DICOM, JPEG або PNG подане у вигляді матриці чисел, кожний елемент якої визначає інтенсивність відповідного пікселя в зображенні (див. п. 3.4.1);

2) вагові коефіцієнти повнозв'язного шару НМ із квазіоптимальними гіперпараметрами (\mathbf{V}) за запропонованою згортковою архітектурою, навченою за еталонним набором даних медичних зображень (див. п. 2.2-2.3).

Вхідні дані потрапляють до блоку 1 (*механізм виявлення ознак захворювання легень*), що є першим етапом роботи ІТ. У процесі виконання блоку 1 ІТ відбувається виявлення ознак захворювання легень із ЦРЗ з допомогою заздалегідь навченої НМ з квазіоптимальними гіперпараметрами.

На *кроці 1.1* до ЦРЗ застосовується попереднє оброблення зображення, що полягає в освітленні зображення для збільшення яскравості, підвищенні контрастності та розширенні кольорової гами (див. п. 3.4.1). Після цього на *кроці 1.2* до ЦРЗ застосовується оптимізована НМ для видалення слабо виражених ознак захворювання легень на ранній стадії (див. п. 3.4).

У результаті виконання блоку 1 одержуємо *проміжні дані*, що сформовані виявленими пневмонічними ознаками ЦРЗ \mathbf{V}_k та подані моделлю для ідентифікації захворювання легень як відображення (2.1)-(2.2). Результат цього відображення визначає оцінку стану захворювання легень y_k за ЦРЗ. Оцінка y_k та вектор \mathbf{V}_k слугують вхідними даними для блоку 2.

Блок 2 (*метод візуального подання зображення*) є другим етапом виконання ІТ. Результатом цього блоку є автоматично сформовані теплові карти у вигляді двовимірних оцінювальних сіток із вираженими локалізованими зонами потенційних ознак захворювання легень на ранній стадії (див. п. 2.4). На *кроці 2.1* обраховується оцінка ступеня приналежності ЦРЗ y_k^c до очікуваного класу c на результуючому шарі класифікації. На *кроці 2.2* обраховуються значення градієнтних ваг, що відображають важливість карти ознак t для

очікуваного класу c . На кроці 2.3 одержуються середньозважені карти активації класів $AGCAM_{i,j}^c$ на площині зображення (i, j) для очікуваного класу c , що накладаються на пікселі ЦРЗ. Ті пікселі на зображенні, яким відповідає високе прогнозне значення для очікуваного класу захворювання, мають яскраво-червоне забарвлення з чіткими переходами кольору різних діапазонів.

Результуючими даними ІТ є оцінка стану захворювання людини, ЦРЗ якої аналізується з допомогою ІТ, та теплова карта, що накладена на ЦРЗ, та є результатом виконання методу візуального подання. Разом оцінка стану захворювання за підбором квазіоптимальних гіперпараметрів НМ та накладена теплова карта можуть бути використані медичними фахівцями для раннього діагностування пневмонії за рентгенівським зображенням легень.

Отже, використання моделі для ідентифікації захворювання легень в запропонованій ІТ дає змогу за вхідними даними у вигляді ЦРЗ отримувати результуючі дані у вигляді оцінки стану захворювання легень із візуальною інтерпретацією цієї оцінки.

Для прикладної реалізації ІТ нижче визначимо вимоги до вхідних даних, наведемо функціональне подання та опишемо сценарії використання ІТ.

3.2. Проєктування інформаційної технології як інформаційної системи

У підрозділі визначено кінцевого користувача ІТ раннього діагностування пневмонії та наведено основні ролі використання інформаційної системи (ІС). Відповідно до процедур рентгенологічного тестування (див. п. 1.2), медичними фахівцями, що займаються діагностуванням захворювань легень за медичними зображеннями є рентгенологи-технологи та рентгенологи-асистенти. Для спрощення термінології, далі в дисертаційній роботі кінцевий користувач ІС матиме назву «рентгенолог».

Перша вимога до архітектури ІС – надання послуг діагностування у вигляді хмарного сервісу, тим самим мінімізуючи витрати кінцевого споживача. Подібна бізнес-модель має назву «програмне забезпечення як послуга» (Software as a Service, SaaS). Для кінцевого користувача ІС за типом SaaS подається у вигляді вебсайту, доступного з будь-якого браузера (в тому числі з браузерів мобільних пристроїв). На сьогодні поширення інтернету практично позбавило будь-яких апаратно-технічних складнощів у використанні таких продуктів, що також робить SaaS простими й кращими у використанні.

Медичні зображення захворювання легень та результати діагностування є приватною інформацією пацієнтів, тому такі дані мають бути захищеними. Крім того, ІС призначена для надання послуг з аналізу даних різним користувачам з різними потребами та приватними даними. Кожний окремо взятий рентгенолог мусить мати власні налаштування системи. Відповідно визначено другу вимогу до ІС – потреба у забезпеченні автентифікації різних користувачів, для кожного з яких необхідно зберігати потрібні дані й надавати доступ до них. Водночас дані одного користувача мають бути недоступними для інших. Тому в ІС має бути передбачена процедура входу («логін»), яка вимагає введення секретного пароля («пароль»), що відомий лише єдиному користувачу.

З огляду на описаний вище процес використання запропонованої ІТ, визначимо її функціональні можливості та основні сценарії застосування.

3.2.1 Функціональне подання інформаційної технології

Узагальнюючи процес використання ІТ, виділимо такі ролі її користувачів та їхні операції:

- 1) рентгенолог:
 - реєстрація в системі;
 - автентифікація (вхід в систему);

- завантаження зображення;
- виконання ідентифікації захворювання легень;
- виконання візуального подання результатів ідентифікації;
- перегляд результатів ідентифікації;
- перегляд результатів візуального подання;

2) пацієнт:

- реєстрація в системі;
- автентифікація (вхід в систему);
- перегляд результатів ідентифікації;
- перегляд результатів візуального подання.

Вказані вище ролі користувачів та їхні операції щодо роботи з системою відображені у вигляді діаграми варіантів використання на рис. 3.3.

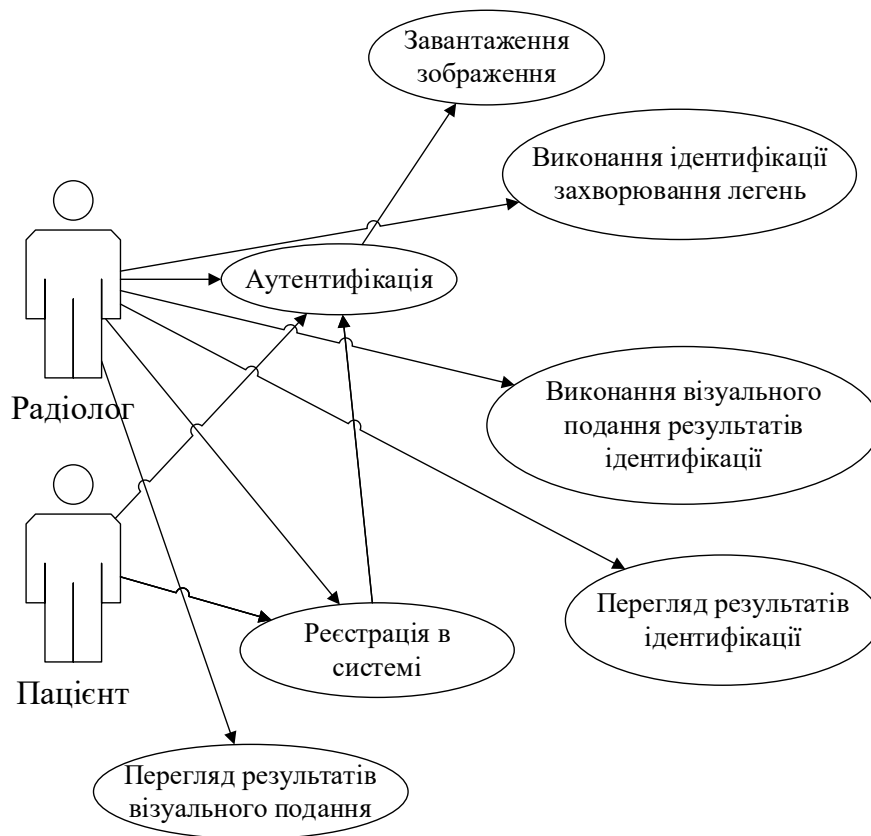


Рис. 3.3 – Діаграма варіантів використання ІС

З діаграми на рис. 3.3 бачимо, що перелік дій користувача «пацієнт» входить в множину дій користувача «рентгенолог».

У відповідь на дії користувачів із рис. 3.3 визначено функції запропонованої ІТ. Функціональне подання запропонованих в ІТ методів застосування CNN подано у вигляді IDEF0-діаграми на рис. 3.4.

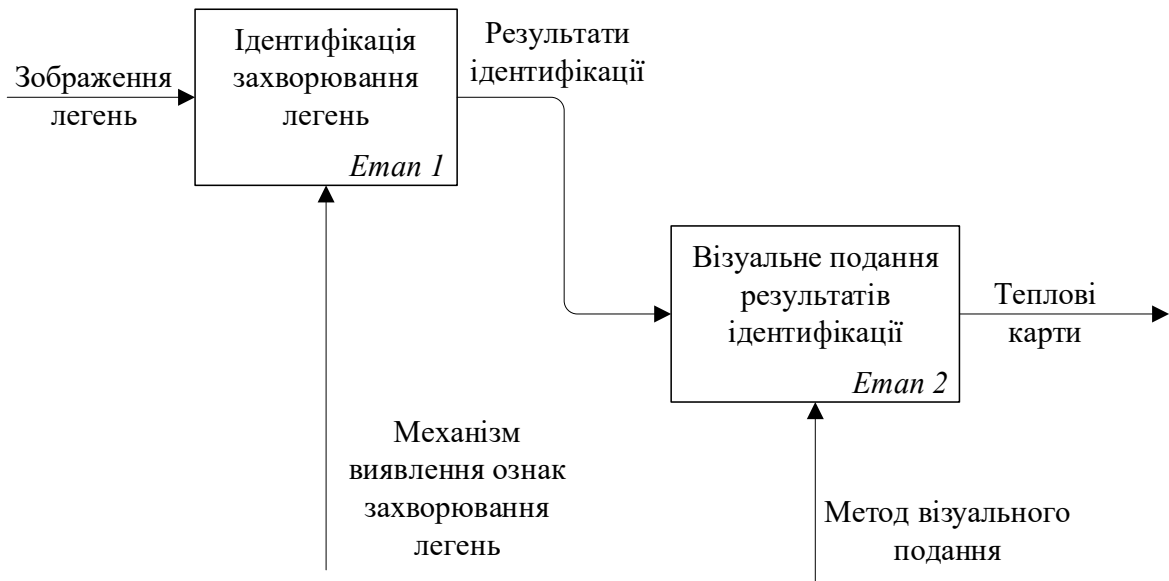


Рис. 3.4 – Діаграма етапів розв’язання задачі ідентифікації захворювання легень

На основі поданих етапів розв’язання задачі ідентифікації захворювання легень виділимо функціональні вимоги до ІС. Кожному етапу розв’язання розглядуваної задачі (рис. 3.4) відповідають кроки перетворення даних з узагальненої схеми ІТ (див. рис. 3.2). Водночас ці етапи відображають відокремлені компоненти ІС, що братимуть участь в обробленні даних. Схему розподілу функцій за компонентами системи зображено на рис. 3.5.



Рис. 3.5 – Схема розподілу функцій за компонентами системи

На основі схеми розподілу функцій за компонентами системи із рис. 3.5 виділено дві підсистеми майбутньої ІС:

- 1) підсистема ідентифікації захворювання легень;
- 2) підсистема візуального подання результатів ідентифікації захворювання.

Цей розподіл функцій (рис. 3.5) за двома підсистемами визначає обсяг можливих дій користувача, які згруповано та подано у вигляді діаграми функцій на рис. 3.6.

Функції користувача згруповано у три категорії:

1) обов'язкові активні функції користувача, без яких робота системи є неможливою:

- реєстрування в системі;
- автентифікація (вхід в систему);
- завантаження зображення;
- запуск процесу ідентифікації;

2) необов'язкові активні функції користувача, які мають безпосередній вплив на фінальний результат роботи ІС:

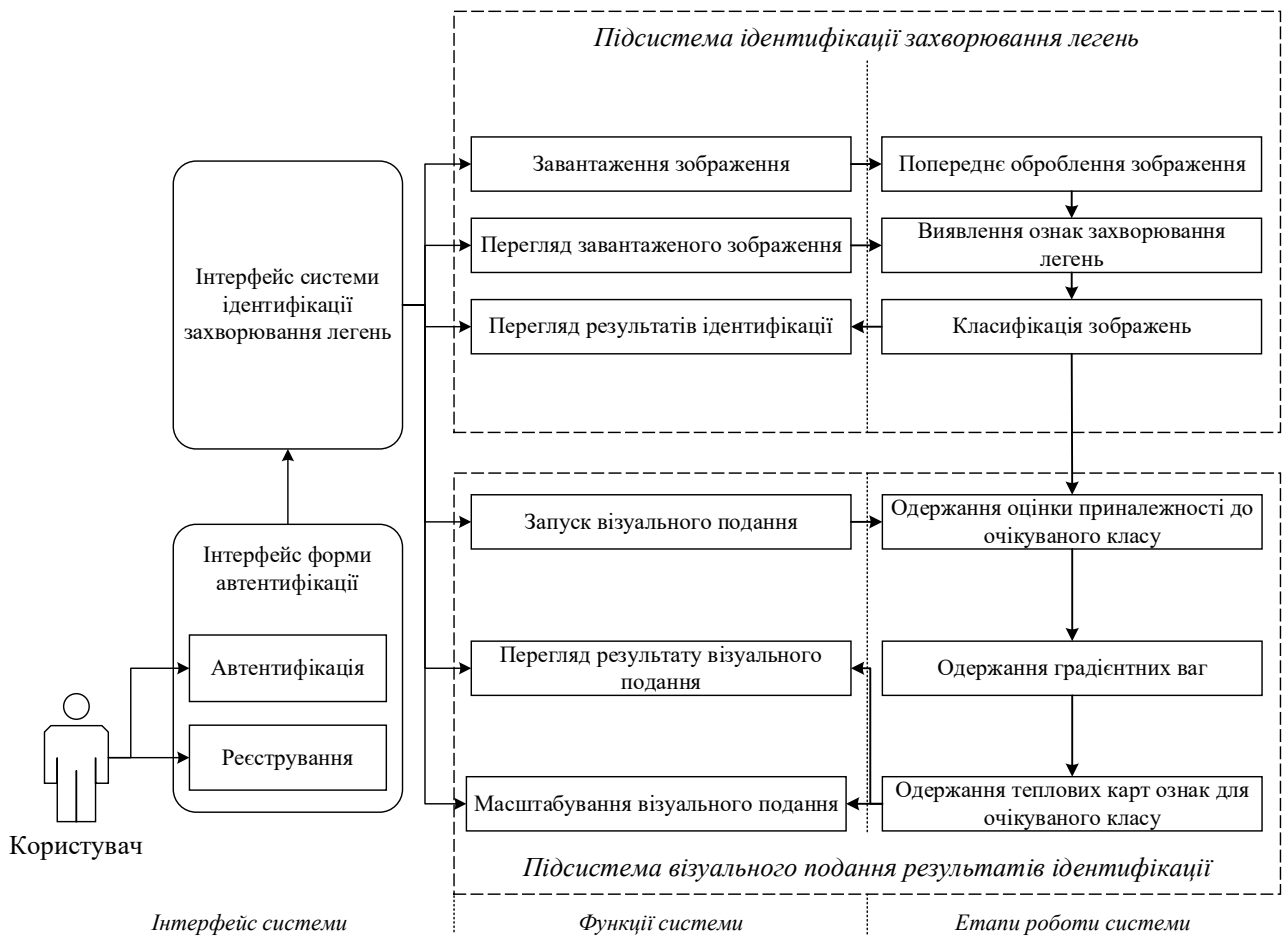


Рис. 3.6 – Діаграма функцій користувача інформаційної системи

- запуск візуального подання;
- масштабування візуального подання;

3) необов'язкові спостережні функції користувача, які не впливають на кінцевий результат роботи системи та призначені для огляду проміжних даних роботи системи, і до яких належать:

- перегляд результатів ідентифікації;
- перегляд результатів візуального подання.

Отже, обов'язковими функціями користувача ІС раннього діагностування пневмонії є реєстрація, автентифікація, завантаження зображення легень для його оброблення та запуск процесу ідентифікації. Наступні кроки, що призводять до оцінки стану захворювання легень за ЦРЗ, система здатна виконувати самостійно.

Решта функцій користувача є необов'язковими (для покращення результату роботи системи) або спостережними (для відображення результуючих даних).

Далі наведемо основні сценарії використання ІТ з огляду на визначені користувацькі функції.

3.2.2 Сценарії використання інформаційної технології

На основі функцій користувача ІТ (див. рис. 3.2), виокремлено основні сценарії використання ІС за ІТ.

Сценарій 1-2 – Взаємодія користувача із інтерфейсом ІС (рис. 3.7).

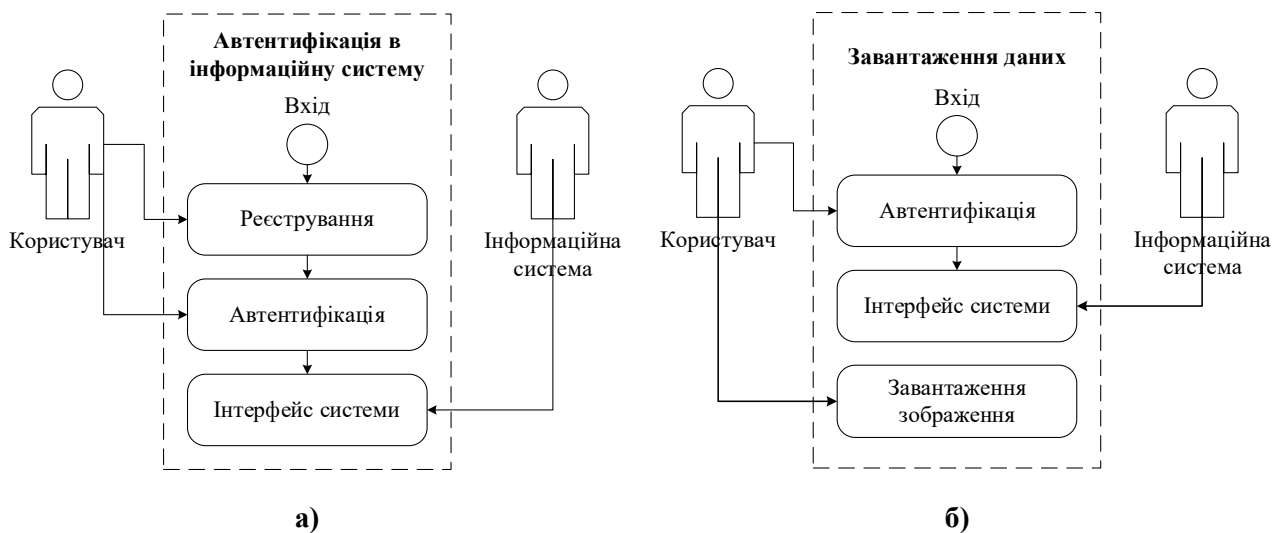


Рис. 3.7 – Діаграми сценаріїв користувача: а) «Автентифікація в інформаційну систему»; б) «Завантаження даних»

Сценарій 3-4 – Застосування моделі для ідентифікації захворювання легень та методу візуального подання результатів ідентифікації (рис. 3.8).

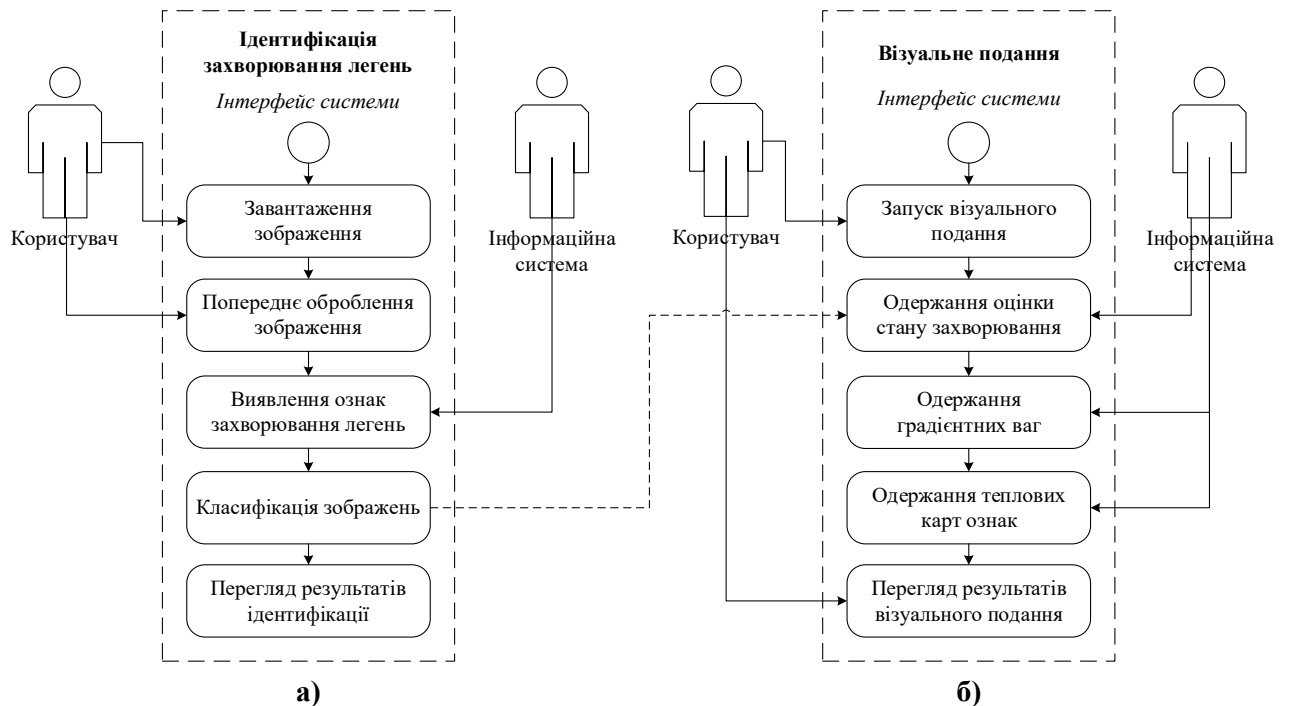


Рис. 3.8 – Діаграми сценаріїв користувача: а) «Ідентифікація захворювання легень»; б) «Візуальне подання результатів ідентифікації»

Відповідно до сценаріїв використання ІС за ІТ, визначимо вимоги до реалізації ІТ та розроблення архітектури ІС за ІТ.

3.3. Розроблення архітектури інформаційної системи

На основі визначених функціональних вимог та описаних сценаріїв використання ІТ розробимо архітектуру ІС з огляду на її застосування та подальше масштабування. Далі, для запропонованої ІС розглянемо структуру модулів, сценарії взаємодії компонент та опишемо засоби для її розроблення.

3.3.1 Модульна структура інформаційної системи

Розроблення архітектури ІС виконано на основі шаблону тривірневої архітектури (рис. 3.9):




Рис. 3.9 – Трирівнева архітектура ІС

Відповідно до схеми трирівневої архітектури (рис. 3.9), ІС розділяється на три впорядковані рівні, де кожен рівень взаємодіє лише з нижчим рівнем через використання інтерфейсів рівнів. Тобто лише один спеціально призначений компонент має дозвіл на взаємодію з компонентом нижчого рівня.

Розроблена ІТ використовується в ІС з типовою структурою «Користувач» → «Робоча станція» → «Мережа» → «ОС/Сервер БД» → «БД» (рис. 3.10)

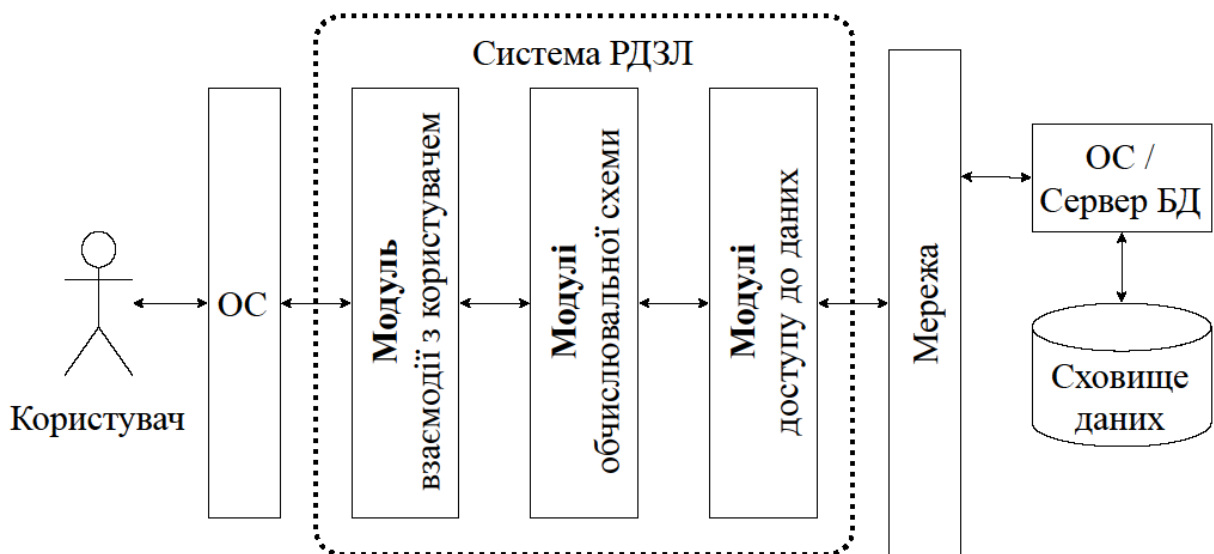


Рис. 3.10 – Інтеграція інформаційної технології РДП в інформаційній системі

ІС РДП складається із таких модулів:

1) *модуль завантаження даних*: призначений для завантаження та відкриття ЦРЗ із зовнішніх джерел у форматі DICOM, JPEG або PNG;

2) *модуль ідентифікації захворювання легень*: відповідає за реалізацію розроблених моделі та методів ідентифікації захворювання легень;

3) *модуль візуального подання*: приймає на вхід вектор ознак захворювання легень та виконує візуальну локалізацію ознак на зображенні;

4) *модуль взаємодії з користувачем*: реагує на дії користувача та координує роботу інших модулів відповідно до цих дій;

5) *модуль збереження даних*: відповідальний за перетворення даних з внутрішнього формату до обраного зовнішнього формату та зберігання результатуючих даних на зовнішньому сховищі.

На рис. 3.11 наведено схему взаємодії користувача та усіх модулів ІС між собою.

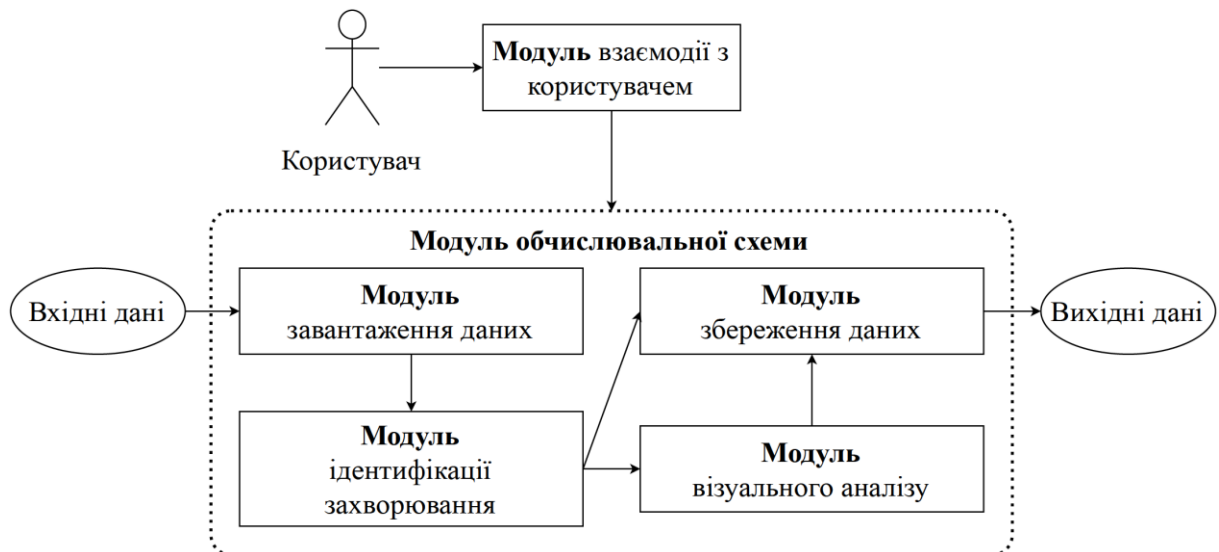


Рис. 3.11 – Схема взаємодії користувача із модулями обчислювальної схеми інформаційної системи РДП

Модуль ідентифікації захворювання складається з багатьох етапів і є достатньо складним для безпосередньої взаємодії з користувачем. Оскільки *модуль ідентифікації* повинен підтримувати можливість побудови складних і різноманітних обчислювальних схем, то взаємодію з користувачем реалізовано в

окремому модулі взаємодії з користувачем за шаблоном «керівник-виконавці». Модуль взаємодії з користувачем організовує взаємодію між усіма іншими модулями та налаштовує зв'язки між ними у відповідь на дії користувача. Після запуску користувачем отриманої схеми, модуль взаємодії з користувачем керує процесом виконання всіх модулів через отримання та відправлення повідомлень від/до модулів обчислювальної схеми.

3.3.2 Сценарії взаємодії компонент інформаційної системи

Для реалізації ІС із погляду способу взаємодії з користувачем виділимо такі типи програмної реалізації:

- застосунки командного рядка – взаємодія з користувачем відбувається через вбудований в операційну систему термінал;

- застосунки з графічним інтерфейсом – взаємодія відбувається через засоби відображення графічного інтерфейсу, що надаються операційною системою;

- вебзастосунки – взаємодія відбувається через графічний інтерфейс, що надається веббраузером, який зазвичай іде в комплекті з операційною системою, але не є частиною самої системи;

- прикладний програмний інтерфейс (API) – взаємодія із кінцевим користувачем відбувається через зовнішні засоби поєднання компонентів ІС.

Для програмної реалізації ІТ РДП було обрано тип взаємодії «вебзастосунок» через такі переваги:

- зручність використання для недосвідченого користувача;
- можливість використання складних візуалізацій.

З погляду розподіленого режиму роботи на кількох обчислювальних пристроях (ОП) виділяють такі класи програмних систем (ПС):

- повністю локальні ПС, що виконуються на єдиному ОП та не підтримують роботу на кількох ОП;
- слабо-розподілені ПС, які використовують невелику кількість ОП, що поєднані мережею; наприклад, пристрої, що належать до єдиної локальної мережі підприємства або установи;
- сильно-розподілені ПС, які підтримують або потребують режим роботи на великій кількості ОП, що поєднані мережею; наприклад, пристрої з багатьох різних локальних мереж, поєднаних у мережі «Інтернет».

Слабо/сильно-розподілені ПС використовуються за нестачі обчислювальних можливостей єдиного ОП, щоби виконувати поставлені завдання у визначений проміжок часу. У випадку завдань, що ставляться перед розроблюваною ІТ, значної потреби в розподіленій роботі не виникає, тому було обрано саме повністю локальний варіант реалізації.

Далі опишемо основні сценарії взаємодії компонент ІС РДП та розглянемо відповідні діаграми послідовностей.

Діаграма взаємодії користувача та компонент протягом життєвого циклу наведено на рис. 3.12.

3.3.3 Вибір засобів програмного розроблення

Наведемо опис найбільш ефективних інструментів (системи управління базами даних, мови програмування, бібліотеки програмних компонентів тощо) для реалізації ІС.

Основними компонентами ІС є бази даних, оскільки саме вони займаються зберіганням інформації, оброблення якої складає основну будь-якого застосунку. Реалізація ІТ діагностування ранньої пневмонії містить у собі дві незалежні бази даних – нереляційна СКБД для зберігання наперед навченої НМ та реляційна для

зберігання приватних даних користувачів, як от, особисті зображення легень пацієнтів, результати ідентифікації та їхнє візуальне подання.

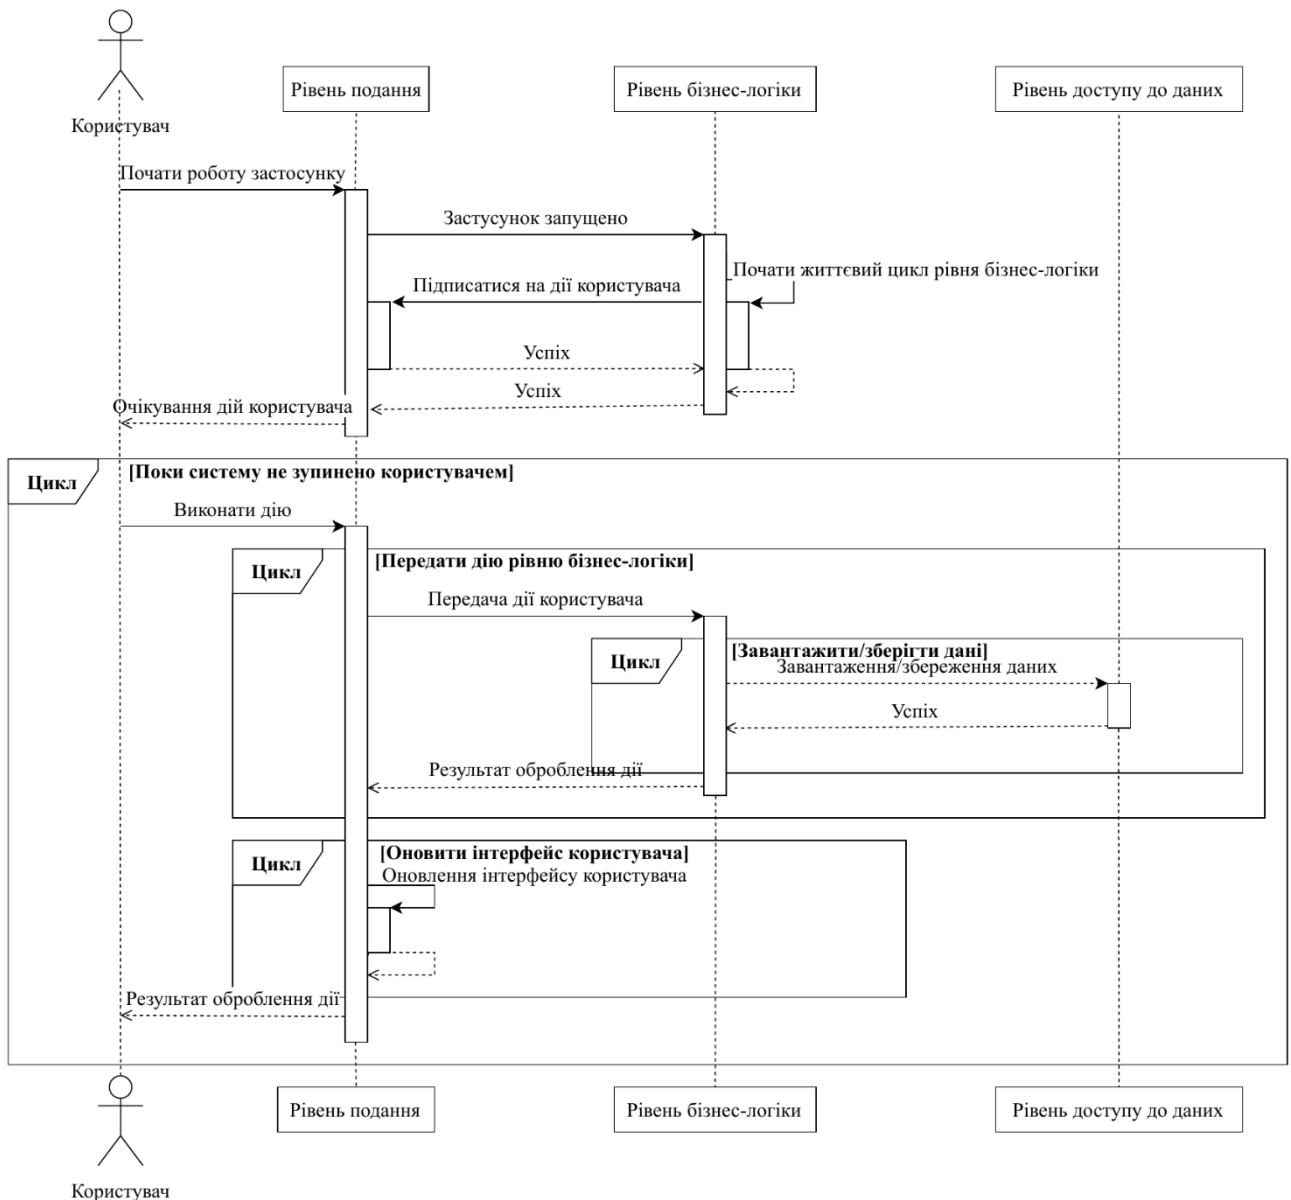


Рис. 3.12 – Діаграма послідовності взаємодії користувача та компонент системи протягом життєвого циклу ІС

Виділимо основні критерії вибору засобів для розроблення ІС:

– безоплатне використання, що є критично важливим для зниження витрат;

- розповсюдження та наявність документації для забезпечення простоти впровадження;
- ефективність у вирішенні поставлених завдань, до якої можна віднести як обчислювальна швидкість, так і простота написання програмного коду.

Станом на весну 2021 року лідером поміж безоплатних реляційних СКБД є MySQL, тому її було обрано для реалізації ІС.

Істотну роль в ІС виконує модуль ідентифікації захворювання легень. Тому необхідно організувати ефективне впровадження НМ у кінцевий застосунок. З цією метою для попереднього навчання НМ та її розгортання обрано програмне середовище TensorFlow та платформу з користувальницьким інтерфейсом Keras, що працює поверх TensorFlow. Це програмне середовище дає змогу використовувати лаконічну та багатофункціональну мову програмування Python, забезпечує гнучкість у конструюванні архітектур НМ та надає прості інструменти для розгортання НМ у користувальницьких застосунках.

За основну мову програмування обрано Python, оскільки в її середовищі реалізовано низку бібліотек, що забезпечують легкі та ефективні API, зокрема, з допомогою бібліотеки Flask. Python дає змогу створити серверний процес із вбудованим інтерфейсом програмного забезпечення для навчених НМ, що є істотним для модуля ідентифікації. Отже, мова програмування Python, разом з інструментами TensorFlow та Flask, складає основу для модулів ІС.

Модуль взаємодії з користувачем підтримує логіку клієнтських взаємодій із сервером ІС. Ключова особливість цього модуля – це взаємодія з внутрішніми компонента ІС – реляційна й нереляційна СКБД та модуль ідентифікації. Важливим для цього модуля є ефективність операції вводу-виводу, що може бути забезпечена асинхронністю платформи Node.js – серверної реалізації мови програмування JavaScript. Асинхронний ввід-вивід Node.js дасть змогу значно підвищити ефективність оброблення користувальницьких запитів. Тому за

розроблення серверної частини застосунку обрано програмне середовище Express.js на основі платформи Node.js.

Клієнтська частина застосунку реалізована мовою програмування JavaScript з використанням програмного середовища Angular.js. Також для розроблення користувальницького інтерфейсу використовується бібліотека програмно-візуальних компонентів Bootstrap.

Усі вище описані засоби розроблення є безоплатним програмним забезпеченням, більшість якого розповсюджується з відкритим кодом. За операційну систему використано Windows 10.

3.4. Підготовлення нейромережевої моделі для використання в інформаційній технології

3.4.1 Підготовка вхідних даних медичних зображень

До вхідного рентгенівського зображення застосовується процес попереднього оброблення, щоб зробити його чіткішим та мати змогу виявити ознаки легеневого захворювання. Попереднє оброблення складається з трьох етапів:

- 1) підвищення яскравості зображення;
- 2) підвищення контрасту;
- 3) розширення кольорової гами.

На *першому кроці* ЦРЗ освітлюється для збільшення яскравості. Такий підхід застосовувалася з урахуванням того, що навіть професійні рентгенологи досліджують рентгенівське зображення під світлом. Штучне освітлення зображення може бути ефективним засобом до виявлення ознак пневмонії для задачі класифікації. Підвищення яскравості виконується шляхом синтаксичного аналізу кожного окремого пікселя зображення, а далі збільшенням їхніх відповідних значень RGB кольорів на певну константу.

На *другому кроці* збільшується контраст ЦРЗ, що є подібним до зміни яскравості зображення. Підвищення контрастності робить межі на зображенні більш суцільними, а окремі зони – більш помітними. Подібний прийом може бути використаний з оригінальною кольоровою гамою, що не відобразатиме ознак захворювання, проте дасть змогу підкреслити локальні зони на зображенні. Збільшення контрастності зображення можна бути отримане із впровадженням афінної еквівалентності (див. п. 1.2.3).

На *третьому кроці* проводиться розширення кольорової гама ЦРЗ. На цьому кроці знаходимо середні значення RGB (*avg*) для кожного зображення. Далі усі значення RGB множаться із знайденим середнім значенням *avg* для підвищення загальних значень та отримання кольорової версії зображення. Цей прийом застосовуються для спрощення ознак захворювання у процесі класифікації. Створене у такий спосіб зображення дає змогу виокремити деталі на поверхні, щоб класифікатор зміг краще виявити будь-які особливості та відмінності від зображення із здоровими легенями.

Розмір вхідних зображень змінюється в навчальному наборі даних до 128×128 пікселів, щоби визначити найбільш слушну ROI з ознаками пневмонії на ранній стадії. Для завдання класифікації пневмонії ROI інтерпретується, як бліда маса рідини у пошкодженій пневмонією легені. Подібна бліда область на рентгенівському зображенні може бути виявлена за допомогою матриці суміжності GLCM (див. п. 1.2.3). Використання GLCM дає змогу виміряти текстурний відтінок зображень. Під час проведення обчислювальних експериментів було створено кілька GLCM шляхом обертання початкової GLCM під кутами 0° , 45° , 90° , 135° . Одержані матриці розподіляються по всьому зображенню, щоб охопити максимальну кількість його пікселів. Результат застосування запропонованого попереднього оброблення рентгенівських зображень проілюстровано на рис. 3.13.




Рис. 3.13 – Зразок рентгенівського зображення на різних етапах попереднього оброблення: а) оригінальне зображення; б) зі зміненою яскравістю; в) із підвищеним контрастом; г) остаточна версія кольорового рентгенівського зображення

Відповідно до рис. 3.13, застосовані модифікації до рентгенівського зображення дають змогу окреслити деталі на поверхні зображення. Завдяки такому обробленню розроблена НМ за згортковою архітектурою (див. п. 2.2) зможе краще виявляти пневмонічні ознаки та будь-які інші текстурні відмінності від зображення зі здоровими легеньми.

3.4.2 Навчання нейромережевої моделі

Для навчання мережі використано еталонний великий набір рентгенівських зображень під назвою MIMIC-CXR [37]. Цей набір даних містить 371 920 рентгенівських зображень легень грудної клітини людини розміром 320×320 пікселів, що отримані від 64 588 пацієнтів. Весь набір розбитий на дві категорії: зображення здорових легень та легень з пневмонією. Набір даних також розділений на навчальну та валідаційну підвибірки, які містять 70% і 30% всіх зображень відповідно.

Для виконання обчислювальних експериментів використано CPU AMD Ryzen 2700 з 8 фізичними ядрами з тактовою частотою 3,40 ГГц та 12 МБ кеш-пам'яті та з 16 ГБ оперативної пам'яті. Для апаратного прискорення використано одну GPU NVIDIA GTX 1080 з 2560 ядрами CUDA на частоті 1670 МГц з пам'яттю GDDR5X на 8 ГБ. Всі експерименти виконано на операційній системі Windows 10 на основі стеку програмного забезпечення TensorFlow v.1.15 та Keras (див. п. 1.3.4).

Для оцінювання ефективності навчання запропонованої CNN використано такі статистичні критерії (див. п. 1.3.5):

- 1) точність (ACC) класифікації за формулою (1.20);
- 2) влучність (Precision) за формулою (1.21);
- 3) повнота (Recall) за формулою (1.22);
- 4) хибнопозитивний рівень (FPR), або ймовірність помилки першого роду, за формулою (1.23);
- 5) хибнонегативний рівень (FNR), або ймовірність помилки другого роду, за формулою (1.24);
- 6) оцінка площі під ROC-кривою (AUC) за формулою (1.25).

Мережа навчається алгоритмом зворотного поширення помилки з регуляризацією L_2 для мінімізації функції втрат перехресної ентропії \mathcal{L} . Ваги

згорткових шарах оптимізуються алгоритмом Adam. Функція сигмоїд (1.14) використовується для прогнозування належності поточного зображення до одного із двох класів: пневмонія або нормальний стан.

Проведено обчислювальні експерименти для оцінювання та порівняння запропонованої CNN із п'ятьма сучасними архітектурами: CheXNet [35], VGG19 [16], InceptionV4 [118], ResNet-50 [120] та MobileNetV3 [123].

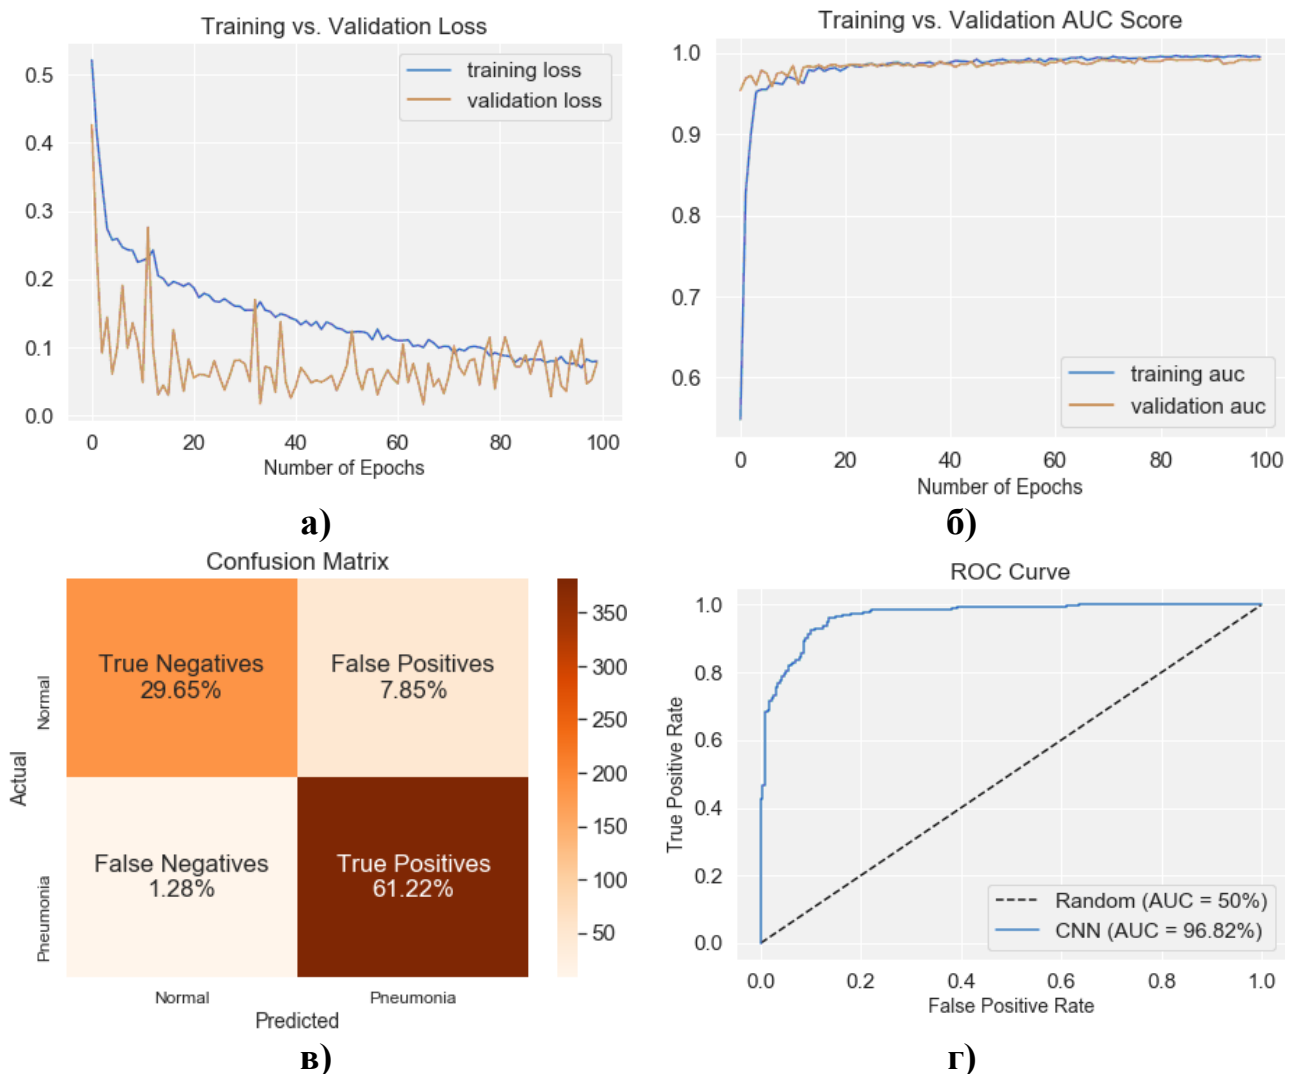


Рис. 3.14 – Результати чисельних експериментів запропонованої CNN: а) криві навчання та валідування функції втрат; б) криві навчання та валідування AUC; в) матриця невідповідностей; г) крива ROC

За попередніми експериментами всі оцінювані НМ збігалися за 100 епох й починали перенавчатися при > 100 епох. Тому фінальне навчання здійснено рівно за 100 епох для кожної моделі. Результати навчання та валідування запропонованої CNN зображено на рис. 3.14.

На рис. 3.14а), зі збільшенням кількості епох, криві втрат навчання та валідування збігаються, вказуючи на відсутність у CNN надмірного недонавчання або перенавчання. На рис. 3.14б) криві навчання та валідування AUC збігаються до практично однієї точки. Розподілення матриці невідповідностей вказує на коефіцієнт хибно позитивних випадків у 7,85% та коефіцієнт хибно негативних випадків у 1,28% (рис. 3.14в). На рис. 3.14г) крива ROC ілюструє істинні (ордината) та хибні (абсциса) позитивні показники. Запропонована CNN досягає оцінки AUC у 96,82% на наборі даних валідування, що вказує на задовільні результати класифікації на етапі валідування.

У таблиці 3.1 подано зведені результати навчання запропонованої CNN та сучасних архітектур для аналізу медичних зображень за набором даних валідування. Найкращі оцінки для кожного критерію виділено жирним шрифтом.

Таблиця 3.1

Статистичне порівняння розробленої CNN порівняно з аналогами за набором даних валідування MIMIC-CXR

Підхід	ACC	Precision	Recall	AUC	FPR	FNR
CheXNet	0,9505	0,9570	0,9434	0,9632	0,0424	0,0566
VGG19	0,9568	0,9463	0,9684	0,9719	0,0549	0,0316
Inception_v4	0,9557	0,9591	0,9520	0,9693	0,0406	0,0480
ResNet-50	0,9574	0,9498	0,9658	0,9680	0,0510	0,0342
MobileNetV3	0,9635	0,9569	0,9706	0,9731	0,0437	0,0294
IT	0,9652	0,9536	0,9780	0,9682	0,0476	0,0220

Відповідно до таблиці 3.1, розроблена CNN перевершує аналоги за показниками точності класифікації (ACC, 90,87%), повноти (Recall, 97,80%) та хибнонегативного рівня (FNR, 2,20%). Модель InceptionV4 показала кращі результати за показником влучності (Precision, 95,91%) та хибнопозитивного рівня (AUC, 4,06%). Насамкінець, модель MobileNetV3 продемонструвала найвищий показник оцінки площі під ROC-кривою (AUC, 97,31%).

З огляду на розподілення матриці невідповідностей (рис. 3.4в) припускаємо, що високі значення критерії класифікації досягнуто запропонованою CNN через розширене ROI, внаслідок застосування глибокої та точкової розширених згорткових операцій у залишкових згорткових блоках. Отже, відповідно до результатів навчання бачимо, що запропонований підхід до виявлення пневмонічних ознак демонструє високу ефективність і може бути використаний в ІТ для ідентифікації захворювання легень на ранніх стадіях.

3.5. Висновки до розділу 3

У розділі запропоновано ІТ раннього діагностування пневмонії за індивідуальним підбором параметрів моделі для ідентифікації захворювання легень за рентгенівськими зображеннями легень.

1. Запропонована ІТ призначена для перетворення вхідної інформації поданої у вигляді цифрового рентгенівського зображення в діагноз, що подається як оцінка стану захворювання людини. Важливою рисою ІТ є візуальне подання результатів діагностування, що дає змогу медичним фахівцям інтерпретувати виявлення ознак захворювання на медичному зображенні.

2. На основі розглянутих вимог та сценаріїв використання розроблено архітектуру ІС для раннього діагностування пневмонії, що складається з двох підсистем. Визначено схему розподілу функцій за компонентами системи. Визначено та класифіковано функції користувача ІС. На основі розглянутих

вимог та сценаріїв використання розроблено архітектуру інформаційної системи нової інформаційної. Архітектура ІС ґрунтується на класичній трирівневій архітектурі програмних застосунків: «Рівень подання» → «Рівень бізнес-логіки» → «Рівень доступу до даних», що забезпечує просту реалізацію кінцевого застосунку та забезпечує вимоги надійності та гнучкості.

3. В рамках розробленої ІТ до вхідного рентгенівського зображення запропоновано застосовувати попереднє оброблення для виділення контурів текстурних ознак на зображенні. Процес попереднього оброблення полягає у застосуванні трьох фільтрів: підвищення яскравості зображення, підвищення контрасту та розширення кольорової гами. В результаті виконання цього три етапного процесу розроблена ІТ може краще відрізнити текстурні ознаки пневмонічного запалення на зображенні від інших текстурних відмінностей на зображенні зі здоровими легенями.

4. Для реалізації модуля ідентифікації захворювання легень виконання навчання запропонованої НМ за згортковою архітектурою. Навчена CNN досягла показників точності класифікації (ACC, 90,87%), влучності (Precision, 95,36%), повноти (Recall, 97,80%), хибнопозитивного рівня (FPR, 4,06%) та хибнонегативного рівня (FNR, 2,20%) за набором даних валідування. За показниками точності, повноти та хибнонегативного рівня запропонована модель перевершила аналогічні НМ. З огляду на отримані результати навчання та валідування робимо висновок, що запропонований підхід до виявлення пневмонічних ознак на основі розробленої НМ за згортковою архітектурою демонструє високу ефективність і може бути використаний в ІТ для ідентифікації захворювання легень на ранніх стадіях.

РОЗДІЛ 4.

ЕКСПЕРИМЕНТАЛЬНЕ ТЕСТУВАННЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ
РАНЬОГО ДІАГНОСТУВАННЯ ПНЕВМОНІЇ

У розділі викладено експериментальне тестування запропонованої ІТ раннього діагностування пневмонії. Для експериментального тестування ІТ розроблено відповідну прикладну ІС, що має вигляд вебзастосунку із користувацьким інтерфейсом. За результатами роботи ІС щодо ідентифікації захворювання легень за медичними зображеннями грудної клітини визначено ефективність розробленої ІТ.

Експериментальне тестування ІТ виконано за двома великими еталонними наборами даних. Для забезпечення чистоти експерименту з еталонних наборів даних виділено малі збалансовані набори. Оцінювання ефективності ІТ проведено за статистичними показниками точності, влучності, повноти, оцінки площі під ROC-кривою, ймовірності помилок першого та другого роду. Високі значення статистичних показників, що здобуті запропонованою ІТ, свідчать про її ефективність порівняно з аналогами. Результати експериментального тестування ІТ довели її спроможність розв'язувати поставлені задачі.

Проведено дослідження ІТ щодо її здатності до надійної інтерпретації результатів ідентифікації захворювання легень. Відповідно до результатів дослідження, візуальна локалізація удосконаленим методом забезпечує виокремлення ознак, що сильно корелюють із класом пневмонії, та з високою точністю виявляє ті області інтересу, що цілком покривають ознаки пневмонічного запалення.

Отримані результати досліджень ілюструють такі можливості ІТ: дає змогу виконувати ефективну класифікацію рентгенівських зображень на малих обчислювальних пристроях та додавати елементи до архітектури; враховує індивідуальні особливості легень кожної людини на медичному зображенні, і, у

такий спосіб, забезпечує високий рівень ідентифікації захворювання проти аналогів; надає простий та зрозумілий користувацький інтерфейс для виявлення слабо виражених ознак пневмонічного запалення на ранній стадії захворювання.

4.1. Опис експериментальної установки

Для валідації та верифікації запропонованої ІТ розроблено експериментальну ІС у вигляді вебзастосунку на основі Flask, що складається з окремих модулів для забезпечення гнучкості та масштабованості (див. п. 3.3). Модульний підхід дає змогу впроваджувати прості модифікації до системи в майбутньому. Реалізована ІС використовує програмне середовище TensorFlow (див. п. 1.3.4) для розгортання та передачі НМ до користувацького інтерфейсу (веббраузера). Модель попередньо навчена та підготовлена за допомогою бібліотеки Keras. ІС також використовує надбудову до програмного середовища TensorFlow.js, яка призначена для відображення результатів ідентифікації, що отримані НМ у браузері.

Ядро програмного середовища TensorFlow передає підготовлені значення розробленої моделі, як окремі файли для її розгортання в браузері. Далі відповідний скрипт запускає ці файли в браузері користувача, щоби виконати застосування моделі для ідентифікації і водночас забезпечити конфіденційність користувацьких даних. Скрипт обробляє зображення у форматі DICOM, JPEG або PNG (див. п. 3.4.1), виконує обчислення та наводить чисельні результати у відсотках. Користувач має змогу виконати локалізацію цільових ROIs для інтерпретації роботи моделі у новому вікні браузера.

На рис. 4.1 подано користувацький інтерфейс вебзастосунку для роботи із рентгенівськими зображеннями.

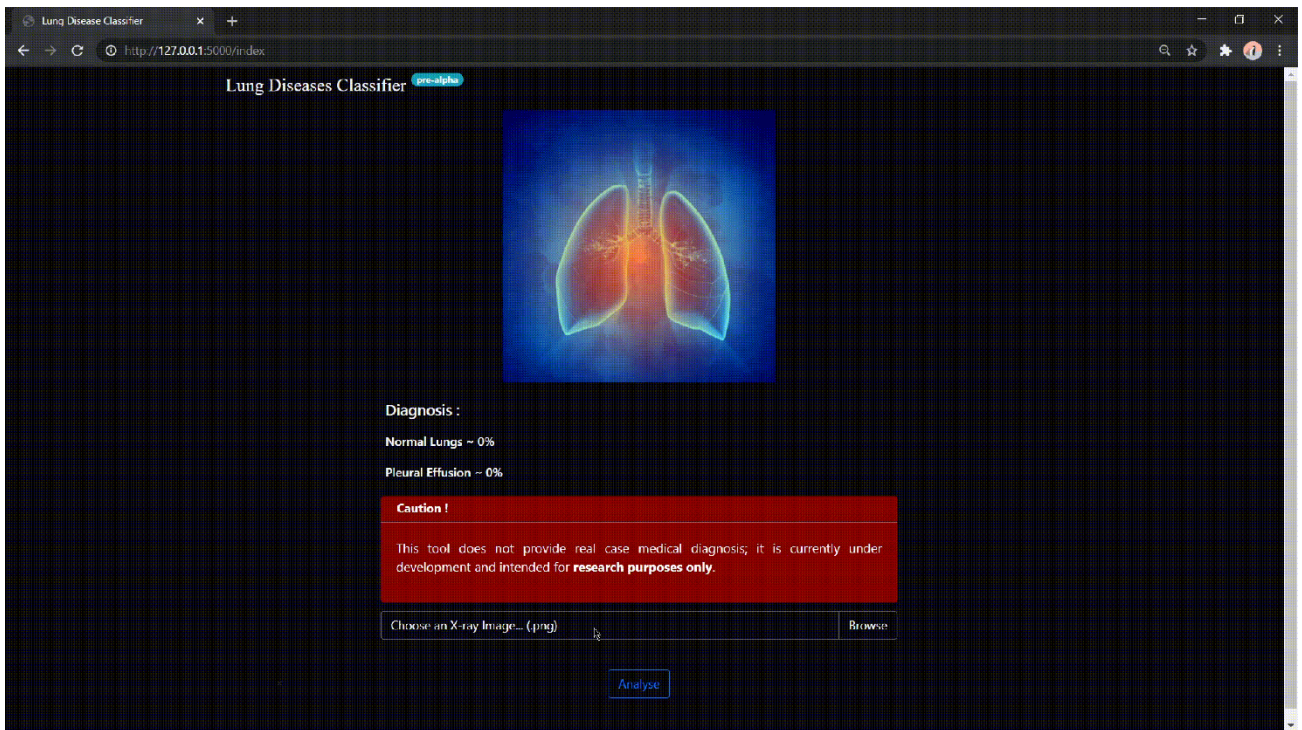


Рис. 4.1 – Головне меню експериментальної ІС

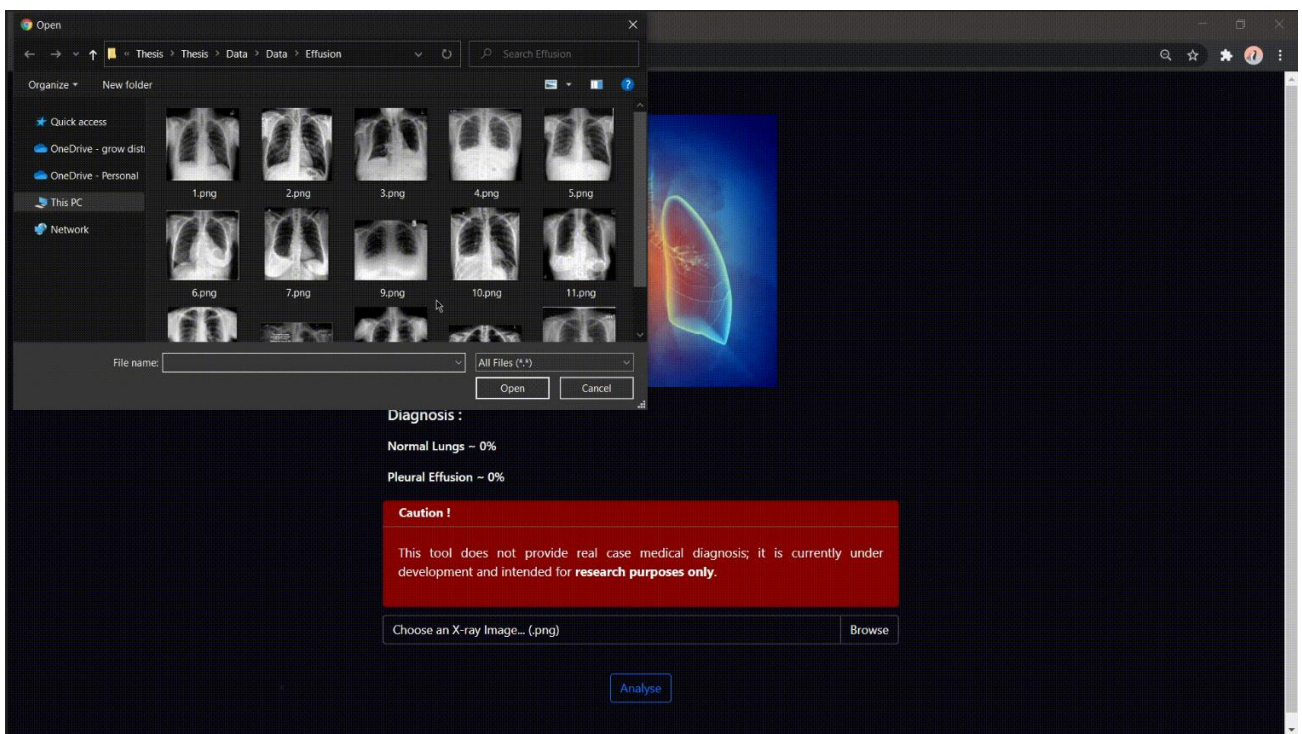


Рис. 4.2 – Інтерфейс завантаження зображення до ІС

Експериментальну ІС реалізовано з простим та зрозумілим більшості користувачів інтерфейсом. ІС може бути доступна з використанням таких браузерів, як Google Chrome, Mozilla Firefox та Microsoft Edge.

Для роботи із ІС необхідно завантажити цільове зображення, натиснувши на «Browse» (рис. 4.2). ІС відобразить цільове зображення в браузері та очікуватиме подальших дій користувача (рис. 4.3).

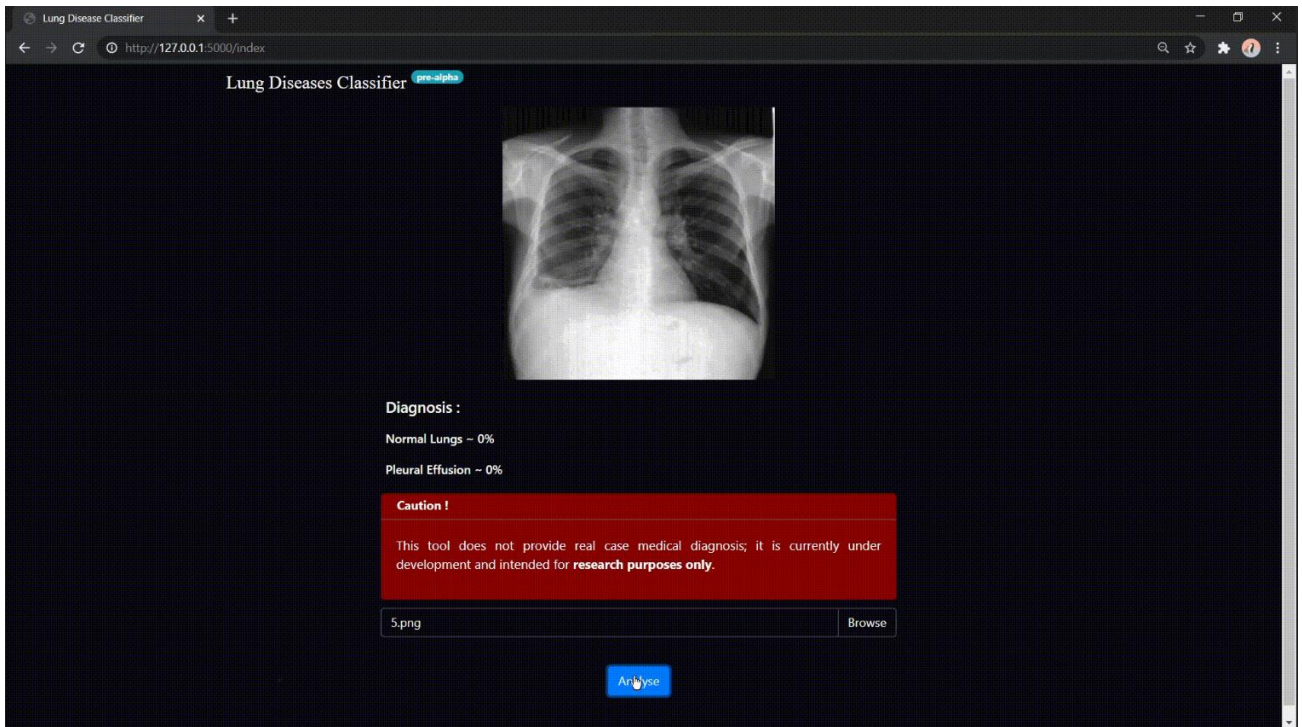


Рис. 4.3 – Інтерфейс завантаженого зображення та очікування на запуск процедури ідентифікації

Для запуску процедури ідентифікації необхідно натиснути на «Analyse» та зачекати допоки модель в браузері виконає обрахунки. Результат роботи моделі щодо наявності пневмонічного запалення у рентгенівському зображенні відображається як числова характеристика (рис. 4.4). Результат модуля інтерпретації результатів ідентифікації подано на рис. 4.5.




Рис. 4.4 – Інтерфейс вебзастосунку, що демонструє результат ідентифікації моделі щодо наявності пневмонічного запалення у рентгенівському зображенні




Рис. 4.5 – Інтерфейс застосунку, що демонструє результати візуальної локалізації

Для запуску модуля інтерпретації потрібно натиснути на числовий результат ідентифікації моделі. У новому вікні в браузері відобразиться завантажене рентгенівське зображення із накладеними тепловими картами.

4.2. Експериментальне тестування інформаційної технології

Для тестування ІТ використано два великих еталонних набори даних медичних зображень CheXpert [36] та PadChest [39]. Далі наведемо опис основних характеристик цих наборів та критеріїв ефективності для їх тестування.

4.2.1 Опис наборів даних та критеріїв ефективності для тестування інформаційної технології

Перший набір даних CheXpert – це великий загальнодоступний набір даних рентгенівських зображень грудної клітини людини. Набір містить 224 366 рентгенограми грудної клітини, що зібрані із 65 240 пацієнтів. Зображення зібрані при науково-дослідному центрі Стенфордської лікарні (США) протягом жовтня 2002 року та липня 2017 року. Зразки набору даних подано у вигляді 8-бітних зображень у відтінках сірого з оригінальною роздільною здатністю. Переважна більшість зразків набору даних була автоматично анотована за допомогою методу рентгенологічних звітів та поділена на 14 категорій, як от, кардіомедіастinum, кардіомегалія, помутніння легень, ураження легень, набряки, ущільнення, пневмонія, ателектаз, пневмоторакс, плевральний випіт, інші плевральні апарати, переломи та допоміжні пристрої. Водночас кожна категорія визначена, як наявна (1), відсутня (0) або невизначена (-1).

Для забезпечення чистоти експерименту із великого набору даних CheXpert відібрано малий збалансований набір CheXpert_small із 3 458 зображеннями у форматі JPEG: 1 729 зразків із міткою «Пневмонія» (клас “1”), 1 729 із міткою

«Нормальний» (клас “0”). Усі зображення *CheXpert_small* відносяться тих, що були попередньо анотовані двома незалежними рентгенологами. У наборі використано лише фронтальні рентгенівські зображення.

Другий набір даних PadChest – це також великий загальнодоступний набір даних, який складається з 160 868 рентгенівських зображень, що зібрані із 109 931 досліджень, що проводилися над 67 000 пацієнтами упродовж 2009-2017 років. Зображення зібрано науковим центром при лікарні Сан-Хуан (Іспанія) у 2017 році. Зразки набору даних подано у вигляді 16-бітних зображень у відтінках сірого з повною роздільною здатністю. Набір *PadChest* розподілено на 19 категорій; водночас 27 593 зображень набору анотовані рентгенологами, решта – за допомогою рекурентної НМ.

Для збереження чистоти експерименту із великого набору даних *PadChest* вилучено малий збалансований набір *PadChest_small*, що містив 4 626 зображень у форматі JPEG. Усі зразки набору *PadChest_small* були анотовані рентгенологами. 2 313 зображень відносяться до класу «Пневмонія» (клас “1”), 2 313 зображень – до класу «Нормальний» (клас “0”). У наборі використано лише фронтальні рентгенівські зображення.

Для встановлення ефективності запропонованої ІТ проведено її порівняння з аналогами за обчислювальними експериментами. Відповідно до аналізу джерел (див. п. 1.3.1), для порівняння взято такі сучасні підходи на основі методів ML та DL: *PCA* [111], *Wavelet* [112], *CheXNet* [35], *VGG* [16], *Inception* [118], *ResNet* [120], *MobileNetV3* [123], *NSGANetV1* [125], *MUXNet-m* [126], запропонована ІТ (див. п. 3.1).

Критеріями ефективності оцінюваних підходів слугують оцінки статистичних показників (див. п. 1.3.5):

- 1) точність (ACC) класифікації за формулою (1.20);
- 2) влучність (Precision) за формулою (1.21);
- 3) повнота (Recall) за формулою (1.22);

4) хибнопозитивний рівень (FPR), або ймовірність помилки першого роду, за формулою (1.23);


5) хибнонегативний рівень (FNR), або ймовірність помилки другого роду, за формулою (1.24);

6) оцінка площі під ROC-кривою (AUC) за формулою (1.25).


4.2.2 Експериментальне тестування за набором даних CheXpert_small

Перше тестування проведено за збалансованим набором даних медичних зображень грудної клітини CheXpert_small.

Результати обчислювальних експериментів за набором даних тестування CheXpert_small наведено в додатку В у вигляді матриць невідповідностей, що зображено на рис. В.1-В2. Натомість на рис. 4.6 подано розподілення істинно позитивних й негативних та хибно позитивних й негативних випадків, що визначені оцінюваними підходами за набором даних CheXpert_small.



a)



b)




Рис. 4.6 – Розподілення показників, що визначені оцінюваними підходами, за набором даних CheXpert_small: а) істинно позитивні випадки (TP); б) істинно негативні випадки (TN); в) хибно позитивні випадки (FP); г) хибно негативні випадки (FN)

З рис. 4.6а) бачимо, що запропонована IT та підходи MobileNetV3 й ResNet виявилися лідерами у правильній ідентифікації пневмонії, визначивши 1672, 1660 та 1657 випадків відповідно за набором даних CheXpert_small. Водночас із рис. 4.6б) впливає, що підходи MUXNet-m, NSGANetV1 та IT правильно віднесли тестові зразки до класу «Нормальний» найбільшу кількість разів проти аналогів, визначивши 1670, 1654 та 1645 істинно негативних випадків відповідно. Найгірші результати показали підходи VGG19, Wavelet та PCA із такими показами: 1615, 1538 та 1501 істинно позитивних випадків, а також 1472, 1410 та 1343 істинно негативних випадків відповідно.

На рис. 4.6в)-г) подано розподілення хибно позитивних та хибно негативних випадків, які були виконані оцінюваними підходами. Так, найбільшу кількість помилок під час ідентифікації пневмонії допустили підходи PCA, Wavelet та VGG19 – 386, 319 та 257 хибно позитивних позначень відповідно.

PCA, Wavelet та VGG19 неправильно віднесли 228, 191 та 114 зразків відповідно до класу «Нормальний».

Отже, за наведеними на рис. 4.6а)-г) показами бачимо, що підходи MobileNetV3, ResNet, MUXNet-m, NSGANetV1 та запропонована ІТ найкраще у порівнянні з аналогами виконали ідентифікацію захворювання легень на ранній стадії за набором даних CheXpert_small. Натомість підходи PCA, Wavelet та VGG19 за цим набором даних показали незадовільні результати.

Для порівняння пристосованості оцінюваних підходів до нових зразків набору даних CheXpert_small розглянуто криві АСС. Тестування підходів проведено на 100 епохах. Криві АСС підходів зображено на рис. 4.7.




Рис. 4.7 – Криві точності за набором даних CheXpert_small

Відповідно до рис. 4.7, криві АСС підходів Inception, ResNet, MobileNetV3, NSGANetV1, MUXNet-m та запропонованої ІТ зростали до певної точки стабільності (12-15 епохи), після чого рівномірно прямували до кінцевої епохи. Натомість, PCA, Wavelet, CheXNet та VGG19 демонстрували значні коливання

ACC, досягнувши точки рівномірного росту на приблизно 35-40 епохах. Такі результати свідчать про високу пристосованість підходів Inception, ResNet, MobileNetV3, NSGANetV1, MUXNet-m та запропонованої ІТ до неоднорідних зразків тестування. Іншими словами, ці підходи здатні покривати цільові ROIs із текстурними ознаками, що нерівномірно розподілені на зображенні, і є властивими пневмонії на ранній стадії. Водночас підходи PCA, Wavelet, CheXNet та VGG19 демонструють погану здатність до виявлення цільових ROIs.

У таблиці 4.1 подано зведені результати обчислювальних експериментів, що виражені в оцінках статистичних показників (1.20)-(1.25), за збалансованим набором даних CheXpert_small.

Таблиця 4.1

Оцінки статистичних показників за набором даних CheXpert_small

Підхід	ACC	Precision	Recall	AUC	FPR	FNR
PCA	0,8224	0,7954	0,8681	0,8457	0,2233	0,1319
Wavelet	0,8525	0,8282	0,8895	0,8874	0,1845	0,1105
CheXNet	0,9344	0,9158	0,9566	0,9513	0,0879	0,0434
VGG19	0,8927	0,8627	0,9341	0,9082	0,1486	0,0659
Inception_v4	0,9291	0,9178	0,9427	0,9315	0,0844	0,0573
ResNet-50	0,9401	0,9247	0,9584	0,9512	0,0781	0,0416
MobileNetV3	0,9517	0,9443	0,9601	0,9609	0,0567	0,0399
NSGANetV1	0,9465	0,9557	0,9364	0,9488	0,0434	0,0636
MUXNet-m	0,9534	0,9650	0,9410	0,9513	0,0341	0,0590
ІТ	0,9592	0,9522	0,9670	0,9589	0,0486	0,0330

Відповідно до таблиці 4.1, запропонована ІТ показала кращі результати у порівнянні з аналогами за трьома статистичними показниками: ACC (95,92%), Recall (96,7%) та FNR (3,3%). Підхід MUXNet-m досяг найвищих показів за

критеріями Precision (96,5%) та FPR (3,41%). Водночас підхід MobileNetV3 досягнув найвищого значення AUC (96,09%).

Високий показник ACC (95,92%) демонструє високу точність виявлення пневмонічних ознак розробленою НМ. Водночас низький показник FNR (3,3%) свідчить про те, що модель допускає малу кількість помилок під час ідентифікації пневмонії. Відзначимо, що низьке значення FNR є критичним у цифровому діагностуванні, оскільки правильний діагноз з використанням САД залежить від того, наскільки часто система помиляється під час виявлення захворювання. Отже, одержані результати свідчать про те, що запропонована ІТ забезпечує високу ефективність та надійність ідентифікації захворювання легень на ранній стадії.

4.2.3 Експериментальне тестування за набором даних PadChest_small

Друге тестування проведено за збалансованим набором даних медичних зображень грудної клітини PadChest_small.

Результати обчислювальних експериментів за набором даних тестування PadChest_small наведено в додатку В у вигляді матриць невідповідностей, що зображено на рис. В.3-В4. Водночас на рис. 4.8 подано розподілення істинно позитивних й негативних та хибно позитивних й негативних випадків, що визначені оцінюваними підходами за набором даних PadChest_small.

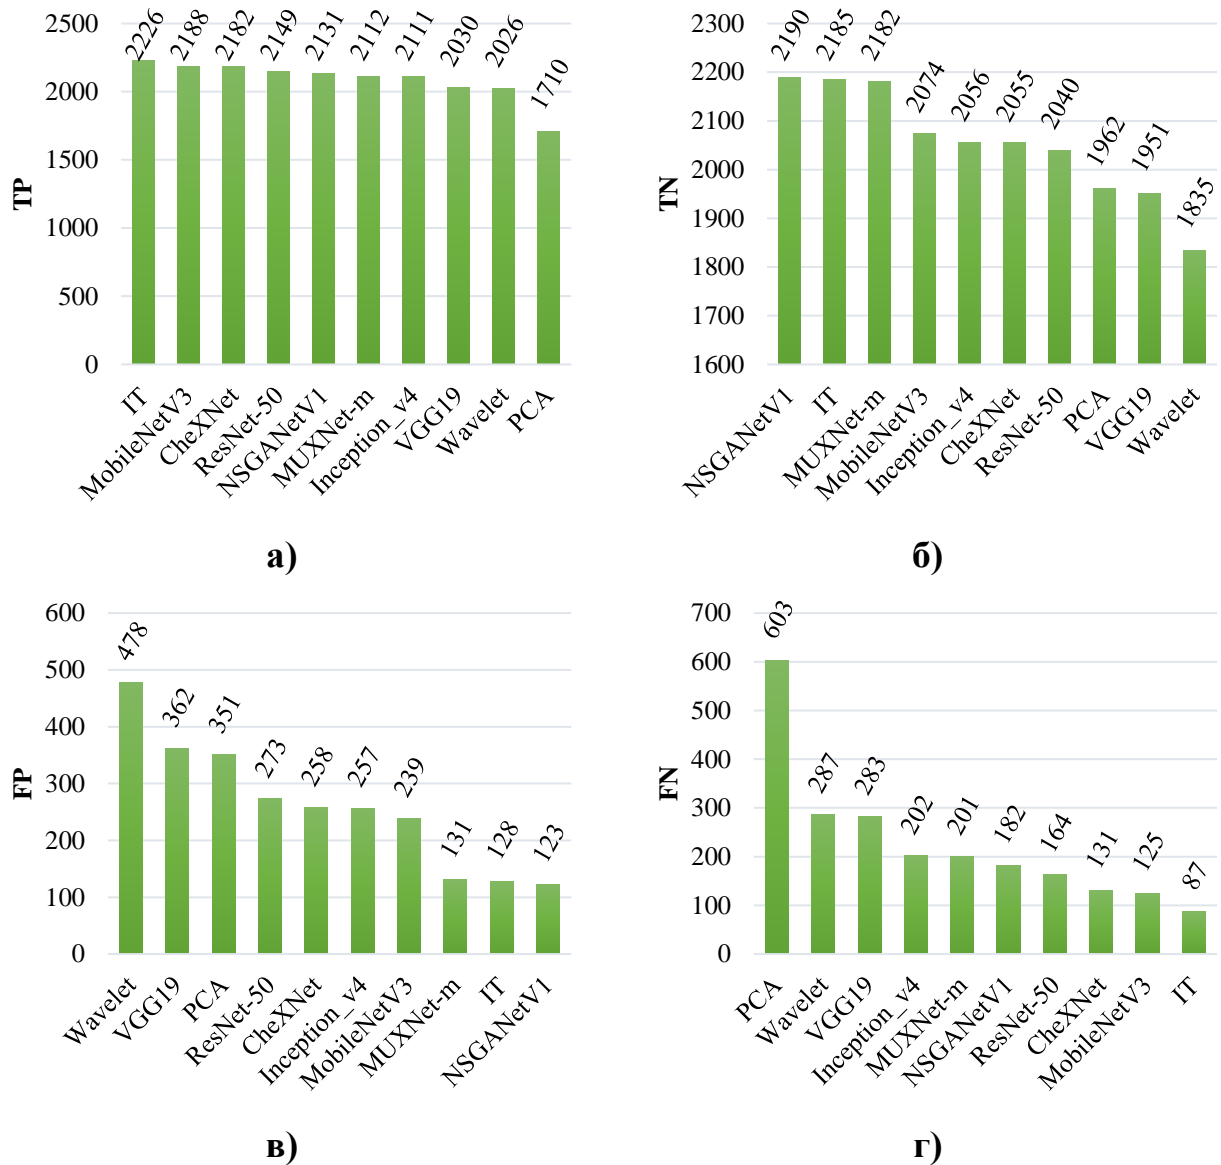


Рис. 4.8 – Розподілення показників, здобутих моделями, за набором даних PadChest_small: а) істинно позитивні випадки (TP); б) істинно негативні випадки (TN); в) хибно позитивні випадки (FP); г) хибно негативні випадки (FN)

З рис. 4.8а) бачимо, що запропонована IT та підходи MobileNetV3 й CheXNet здійснили найбільше правильних визначень пневмонії на зображеннях, визначивши 2226, 2188 та 2182 випадки відповідно за набором даних PadChest_small. Відповідно до рис. 4.8б), підходи NSGANetV1, IT та MUXNet-m найкраще справилися із завдання віднесення тестових зразків до класу «Нормальний», визначивши 2190, 2185 та 2182 істинно негативних випадки

відповідно. Натомість підходи VGG19, Wavelet та PCA продемонстрували найгірші результати як для класу «Пневмонія» (2030, 2026, 1710, відповідно), так і для класу «Нормальний» (1951, 1835, 1962, відповідно). допустили найбільшу кількість помилок під час опрацювання зображень, що позначені як «Пневмонія», позначивши 478, 362 та 351 зразків 1615, 1538 та 1501 істинно позитивних випадків, а також 1472, 1410 та 1343 істинно негативних випадків відповідно.

На рис. 4.8в)-г) подано розподілення помилок, які допустили усі підходи під час тестування за набором даних PadChest_small. Так, підходи Wavelet, VGG19 та PCA неправильно віднесли до класу «Пневмонія» 478, 362 та 351 зразків, і неправильно позначили класом «Нормальний» 287, 283 та 603 зразки відповідно, що є найгіршим результатом поміж аналогів.

Отже, із рис. 4.8а)-г) випливає, що запропонована IT та підходи NSGANetV1, MUXNet-m, MobileNetV3 та CheXNet здатні ефективно виконувати ідентифікацію пневмонічного запалення на ранній стадії за набором даних PadChest_small. Натомість підходи PCA, Wavelet та VGG19 за цим набором досягли найменших показників поміж аналогів, що свідчить про їхню низьку ефективність для задачі ідентифікації захворювання легень.

Розглянуто криві ACC, щоби оцінити пристосованість оцінюваних підходів до нових зразків набору даних PadChest_small. Тестування підходів проведено на 100 епохах. Криві ACC підходів наведено на рис. 4.9.

Відповідно до рис. 4.9, криві тестування ACC усіх підходів відображені з певними збуреннями. Проте з епох 25-30 криві досягають певної стабільності та починають рівномірно прямувати до кінцевої епохи. Також на рис. 4.9 спостерігаються значні коливання кривих протягом усіх епох тестування. Такі результати свідчать про низьку пристосованість оцінюваних підходів до різних зразків тестування набору даних PadChest_small. Проте відзначимо відносну пологість кривих IT, MUXNet-m та NSGANetV1, що може свідчити про низький рівень перенавчання моделей, і, відповідно, високий рівень їхньої

пристосованості до опрацювання рентгенівських зображень із неоднорідним розподіленням текстурних ознак на площині.




Рис. 4.9 – Криві точності за набором даних PadChest_small

Далі подано зведені результати обчислювальних експериментів, що виражені в оцінках статистичних показників (1.20)-(1.25), за збалансованим набором даних PadChest_small (табл. 4.2).

Із таблиці 4.2 випливає, що запропонована ІТ досягла кращих результатів порівняно з аналогами за п'ятьма статистичними показниками: ACC (95,35%), Precision (94,56%), Recall (96,24%), FNR (3,76%) та AUC (96,01%). Водночас підхід NSGANetV1 показав найнижче значення FPR (5,32%).

Високі значення статистичних показників, що отримані запропонованою ІТ, демонструють як високу точність виявлення пневмонічного запалення, так і значну влучність ІТ під час ідентифікації захворювання легень. Крім того, низьке значення FNR (3,76%) свідчить про те, що модель допускає малу кількість помилок в процесі ідентифікації.

Таблиця 4.2

Оцінки статистичних показників за набором даних PadChest_small

Підхід	ACC	Precision	Recall	AUC	FPR	FNR
PCA	0,7938	0,8297	0,7393	0,8231	0,1518	0,2607
Wavelet	0,8346	0,8091	0,8759	0,8450	0,2067	0,1241
CheXNet	0,9159	0,8943	0,9434	0,9343	0,1115	0,0566
VGG19	0,8606	0,8487	0,8776	0,8952	0,1565	0,1224
Inception_v4	0,9008	0,8915	0,9127	0,9048	0,1111	0,0873
ResNet-50	0,9055	0,8873	0,9291	0,9112	0,1180	0,0709
MobileNetV3	0,9213	0,9015	0,9460	0,9432	0,1033	0,0540
NSGANetV1	0,9341	0,9454	0,9213	0,9470	0,0532	0,0787
MUXNet-m	0,9282	0,9416	0,9131	0,9493	0,0566	0,0869
IT	0,9535	0,9456	0,9624	0,9601	0,0553	0,0376

Відзначимо, що низьке значення FNR є ключовим у цифровому діагностуванні, оскільки правильний діагноз з використанням САД залежить від того, наскільки часто система помиляється. Отже, з одержаних результатів робимо висновок, що запропонована IT забезпечує високу ефективність ідентифікації пневмонії на ранній стадії.

4.2.4 Дослідження ефективності інформаційної технології

Для дослідження ефективності IT проведено аналіз статистичних показників за збалансованими наборами даних тестування CheXpert_small та PadChest_small. Виконано візуальне порівняння оцінюваних підходів за обома наборами даних, що зображено на рис. 4.10-4.12. Зазначимо, що гістограми на рис. 4.10-4.12 відсортовано за спаданням за показниками набору даних тестування PadChest_small.





Рис. 4.10 – Візуальне порівняння оцінюваних підходів у розрізі наборів даних CheXpert_small та PadChest_small за показниками: а) ACC; б) Precision

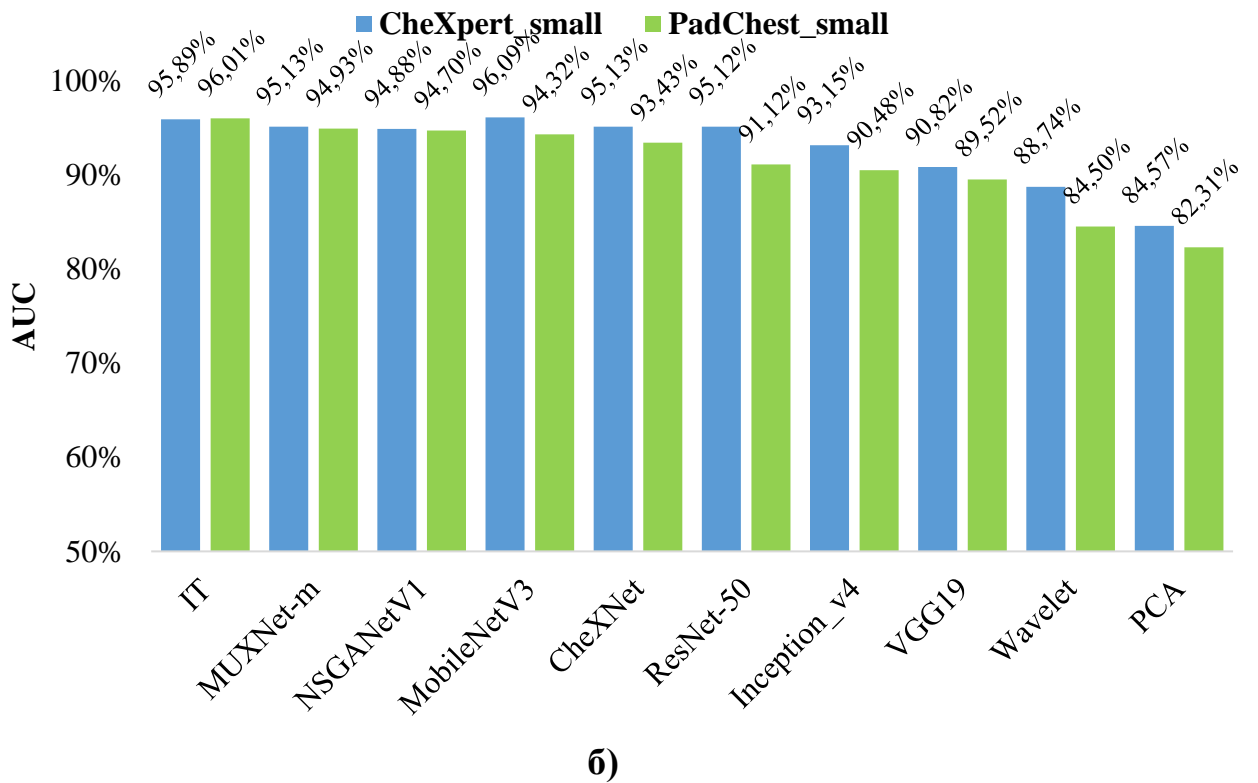



Рис. 4.11 – Візуальне порівняння оцінюваних підходів у розрізі наборів даних CheXpert_small та PadChest_small за показниками: а) Recall; б) AUC


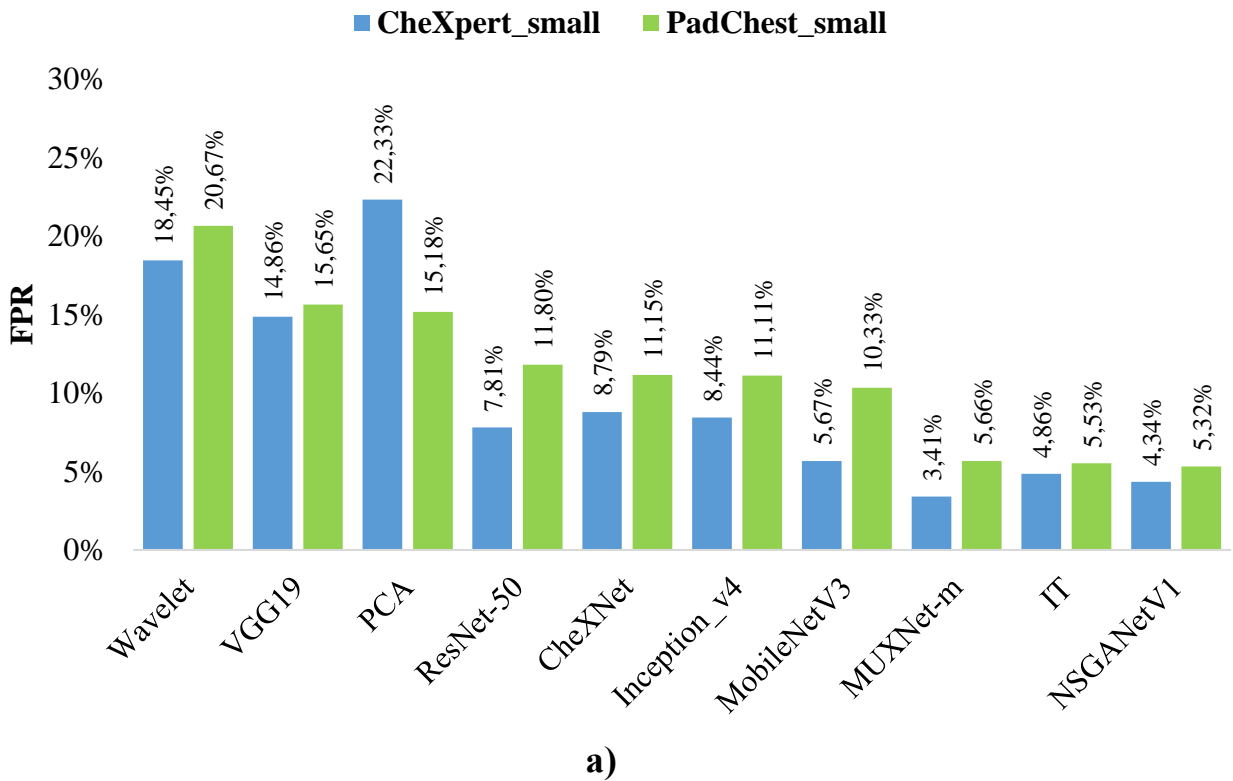


Рис. 4.12 – Візуальне порівняння оцінюваних підходів у розрізі наборів даних тестування CheXpert_small та PadChest_small за показниками: а) FPR; б) FNR

З аналізу рис. 4.10-4.12 бачимо, що переважно для усіх підходів значення таких показників, як точність класифікації (ACC), влучність (Precision), повнота (Recall) та оцінка площі під ROC-кривою (AUC) нижчі, а показників хибнопозитивний рівень (FPR) та хибнонегативний рівень (FNR) вищі за набором даних PadChest_small, ніж показники за набором даних CheXpert_small. Це пояснюється тим, що батьківський набір даних PadChest містить рентгенівські зображення, які отримано від людей із широко розподіленими характеристиками, як от, вік людини (від дітей до людей пенсійного віку) та стадія захворювання (від невеликого приливу рідини у легенях, що характерно ранній стадії, до яскраво вираженого пневмонічного розрідження, що властиво пізній стадії захворювання).

Набір CheXpert_small, за яким проведено експериментальне тестування, містить зображення, що анотовані за допомогою методу рентгенологічних звітів; натомість набір PadChest_small складається із зображень, що анотовані двома незалежними рентгенологами. Анотування професійними медиками є точнішим підходом до формування наборів даних за рентгенологічних звітів, оскільки дає змогу врахувати досвід та експертний погляд людини. З огляду на вище сказане припускаємо, що результати за набором даних PadChest_small є більш репрезентативними для задачі раннього діагностування захворювання легень.

Відповідно до рис. 4.10-4.11, запропонована ІТ досягла найвищих значень за показниками точності класифікації (ACC), влучності (Precision), повноти (Recall) та оцінки площі під ROC-кривою (AUC) за хоча би одним набором даних. Водночас з рис. 4.8 бачимо, що ІТ досягла найнижчих значень ймовірності помилки другого роду (FNR) та порівняно низьких значень ймовірності помилки першого роду (FPR) за обома наборами даних.

З рис. 4.12 бачимо, що запропонована ІТ досягла найнижчих значень ймовірності помилки другого роду (FNR) та порівняно низьких значень ймовірності помилки першого роду (FPR) за обома наборами даних. Низькі значення показників FNR та FPR є критично важливим у медичному

діагностуванні, оскільки правильний діагноз з використанням САД залежить від того, наскільки часто система помиляється. Зокрема, низькі значення FNR та FPR вказують на надійність результатів запропонованої ІТ у задачі ідентифікації захворювання легень.

Зазначимо також, що близькими до найвищих є показники підходів NSGANetV1, MUXNet-m та MobileNetV3. Ці системи містять у своїх структурах CNN, що ґрунтуються на пошуку оптимальної архітектури та розподілення гіперпараметрів для кожного окремо взятого набору даних. Хоча подібні підходи є універсальними засобами для широкого класу задач, вони не здатні забезпечити високої надійності результатів ідентифікації через можливі втрати під час виявлення текстурних ознак на рентгенівському зображенні.

Для оцінювання ефективності запропонованої ІТ порівняно з аналогами виконано попарне порівняння ІТ з підходами, що досягли високих показників за обома наборами даних (табл. 4.3-4.4).

З аналізу табл. 4.3-4.4 зрозуміло, що запропонована ІТ перевершує аналоги за такими показниками:

- точність класифікації (ACC) – на 0,58% та 1,95% (тут і надалі перше значення відповідає набору даних CheXpert_small, друге – набору PadChest_small);

- влучність (Precision) – на 0,02% за набором даних PadChest_small;

- повнота (Recall) – на 0,69% та 1,64%;

- оцінка площі під ROC-кривою (AUC) – на 1,08% за набором даних PadChest_small;

- ймовірність помилки другого роду (FNR) – на 0,64% та 1,64%.

Таблиця 4.3

Оцінювання ефективності інформаційної технології
порівняно з аналогами за зростаючою шкалою

Набір даних	Рейтинг підходів	ACC	Precision	Recall	AUC
CheXpert_small	I місце	<i>IT</i> (95,92%)	<i>MUXNet-m</i> (96,50%)	<i>IT</i> (96,70%)	<i>MobileNetV3</i> (96,09%)
	II / III місце	<i>MUXNet-m</i> (95,34%)	<i>IT</i> (95,22%)	<i>MobileNetV3</i> (96,01%)	<i>IT</i> (95,89%)
	Різниця	↑ 0,58%	↓ 1,28%	↑ 0,69%	↓ 0,20%
PadChest_small	I місце	<i>IT</i> (95,35%)	<i>IT</i> (94,56%)	<i>IT</i> (96,24%)	<i>IT</i> (96,01%)
	II / III місце	<i>NSGANetV1</i> (93,41%)	<i>NSGANetV1</i> (94,54%)	<i>MobileNetV3</i> (94,60%)	<i>MUXNet-m</i> (94,93%)
	Різниця	↑ 1,95%	↑ 0,02%	↑ 1,64%	↑ 1,08%

Таблиця 4.4

Оцінювання ефективності інформаційної технології
порівняно з аналогами за спадною шкалою

Набір даних	Рейтинг підходів	FPR	FNR
CheXpert_small	I місце	<i>MUXNet-m</i> (3,41%)	<i>IT</i> (3,30%)
	II / III місце	<i>IT</i> (4,86%)	<i>MobileNetV3</i> (3,99%)
	Різниця	↓ -1,45%	↑ -0,69%
PadChest_small	I місце	<i>NSGANetV1</i> (5,32%)	<i>IT</i> (3,76%)
	II / III місце	<i>IT</i> (5,53%)	<i>MobileNetV3</i> (5,40%)
	Різниця	↓ -0,22%	↑ -1,64%

Отримані запропонованою ІТ значення статистичних показників можуть бути пояснені застосуванням різноманітних модифікацій до архітектури НМ. Так, до високого значення точності (ACC) могло призвести використання залишкових згорткових блоків в архітектурі CNN. Залишкові блоки призначені для закріплення карт ознак на різних згорткових шарах, що сприяє виявленню цільових ознак пневмонічного запалення. Високі значення влучності (Precision) та повноти (Recall) могли бути отримані через використання різних розмірів згорткових ядер з різними коефіцієнтами розширення в архітектурі CNN. Така модифікація дає змогу охоплювати більші ROIs на зображенні без додаткових втрат у рецептивних полях. Зокрема, ініціалізація ваг ядра на першому згорткового шару новими значеннями модифікованого оператора Собеля призначена для чіткого виділення границь розсіяних пневмонічних ущільнень на зображенні. Подібне удосконалення сприяє кращому виявленню цільових пневмонічних ознак на зображенні, що може виражатися у більшій кількості правильних ідентифікацій захворювання легень. Як результат, ІТ показала найнижчі ймовірності помилки другого роду (FNR) поміж аналогів.

Варте уваги те, що запропонована ІТ демонструє гірші результати за показниками повноти (Precision, на 1,28%) та оцінки площі під ROC-кривою (AUC, на 0,20%) за набором даних CheXpert_small, а також показує високі ймовірності помилки першого роду (FPR, на 1,45% та 0,22%) порівняно з аналогами. Такі покази можуть бути пояснені недосконалістю НМ під час опрацювання зображень із специфічними та мало фіксованими легенями.

Отже, в результаті проведеного аналізу робимо висновок, що запропонована ІТ на основі розробленої НМ за згортковою архітектурою та удосконаленого методу підбору квазіоптимальних гіперпараметрів є ефективним засобом для ідентифікації пневмонічного запалення на ранній стадії за рентгенівськими зображеннями.

4.2.5 Дослідження візуального подання результатів діагностування

Для дослідження методу візуального подання були використані тестовий програмний застосунок, що описаний у п. 4.1, та набір даних рентгенівських зображень *RadChest_small*, що описаний у п. 4.2.1.

Оскільки запропонована архітектура CNN (див. п. 2.2.3) містить у своїй структурі глобальний усереднений підвибірковий шар (див. рис. 2.6), то така CNN є сумісною із картами активації класів. Відповідно вдосконалений метод візуального подання (див. п. 2.4), що ґрунтується на градієнтній активації класів, може бути використаний для візуалізації результатів передбачення моделі CNN. Це, своєю чергою, дасть змогу здійснювати інтерпретування результатів раннього діагностування пневмонії з допомогою ІТ.

У роботі проведено порівняння методу візуального подання із класичним методом дискримінаційної локалізації АСАМ (1.15)-(1.17). На рис. 4.13 зображено результати застосування методу АСАМ до рентгенівських зображень зі слабо вираженими ознаками ранньої пневмонії.

На рис. 4.13а), 4.13г), 4.13є) подано рентгенівські зображення, що отримані від різних пацієнтів; рис. 4.13б), 4.13д), 4.13ж) демонструють обмежувальні рамки із ROIs, що локалізують передбачувані ознаки пневмонії; на рис. 4.13в), 4.13є), 4.13з) зображено теплові карти, що накладені на рентгенівські зображення методом АСАМ. На рис. 4.13 бачимо, що метод АСАМ позначає яскраво-червоним кольором найбільш ймовірне розташування ознак пневмонічного запалення на рентгенівському зображенні та дає змогу пояснювати результати ідентифікації захворювання легень.

Метод САМ добре позначає ROIs у центрі зображення, але іноді ігнорує можливі ущільнення по периметру легень. Для усунення цього недоліку пропонується використовувати вдосконалений метод візуального подання.

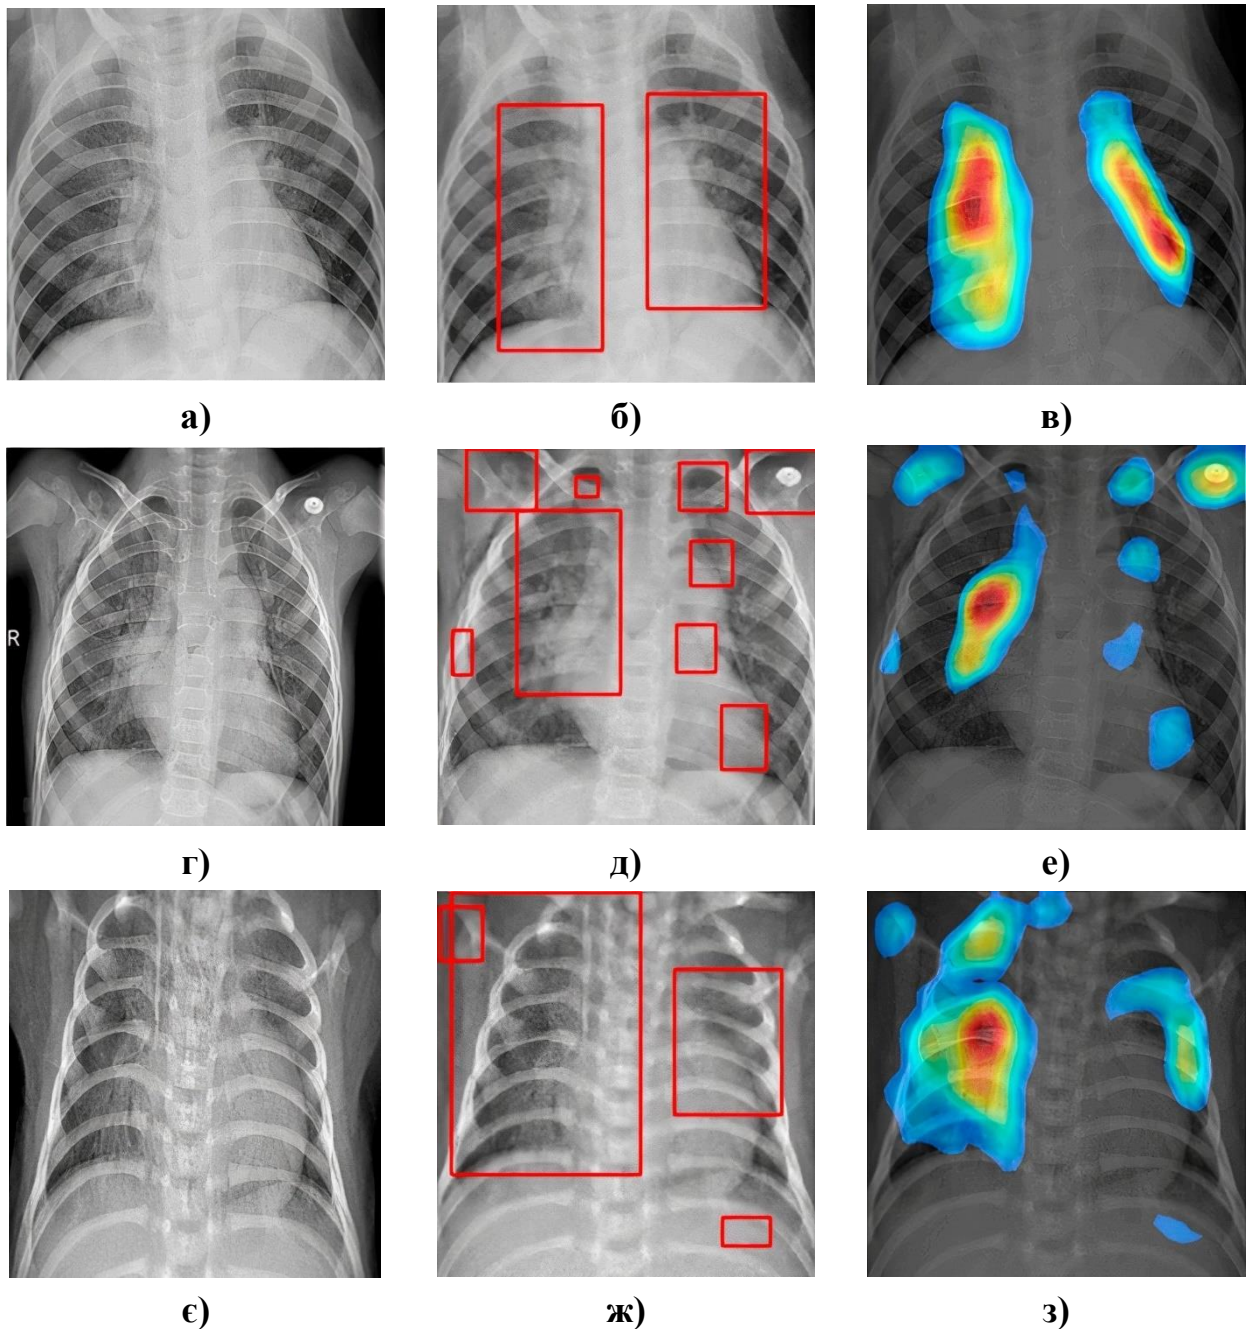


Рис.4.13 – Візуальне інтерпретування роботи CNN з допомогою методу ACAM:
 а), г), є) вхідні рентгенівські зображення; б), д), ж) обмежувальні рамки, що локалізують ROIs; в), е), з) теплові карти, що накладені на вхідні зображення методом ACAM

На рис. 4.14 подано візуальне порівняння різних етапів діагностування пневмонії з використанням удосконаленого методу AGCAM (2.4).

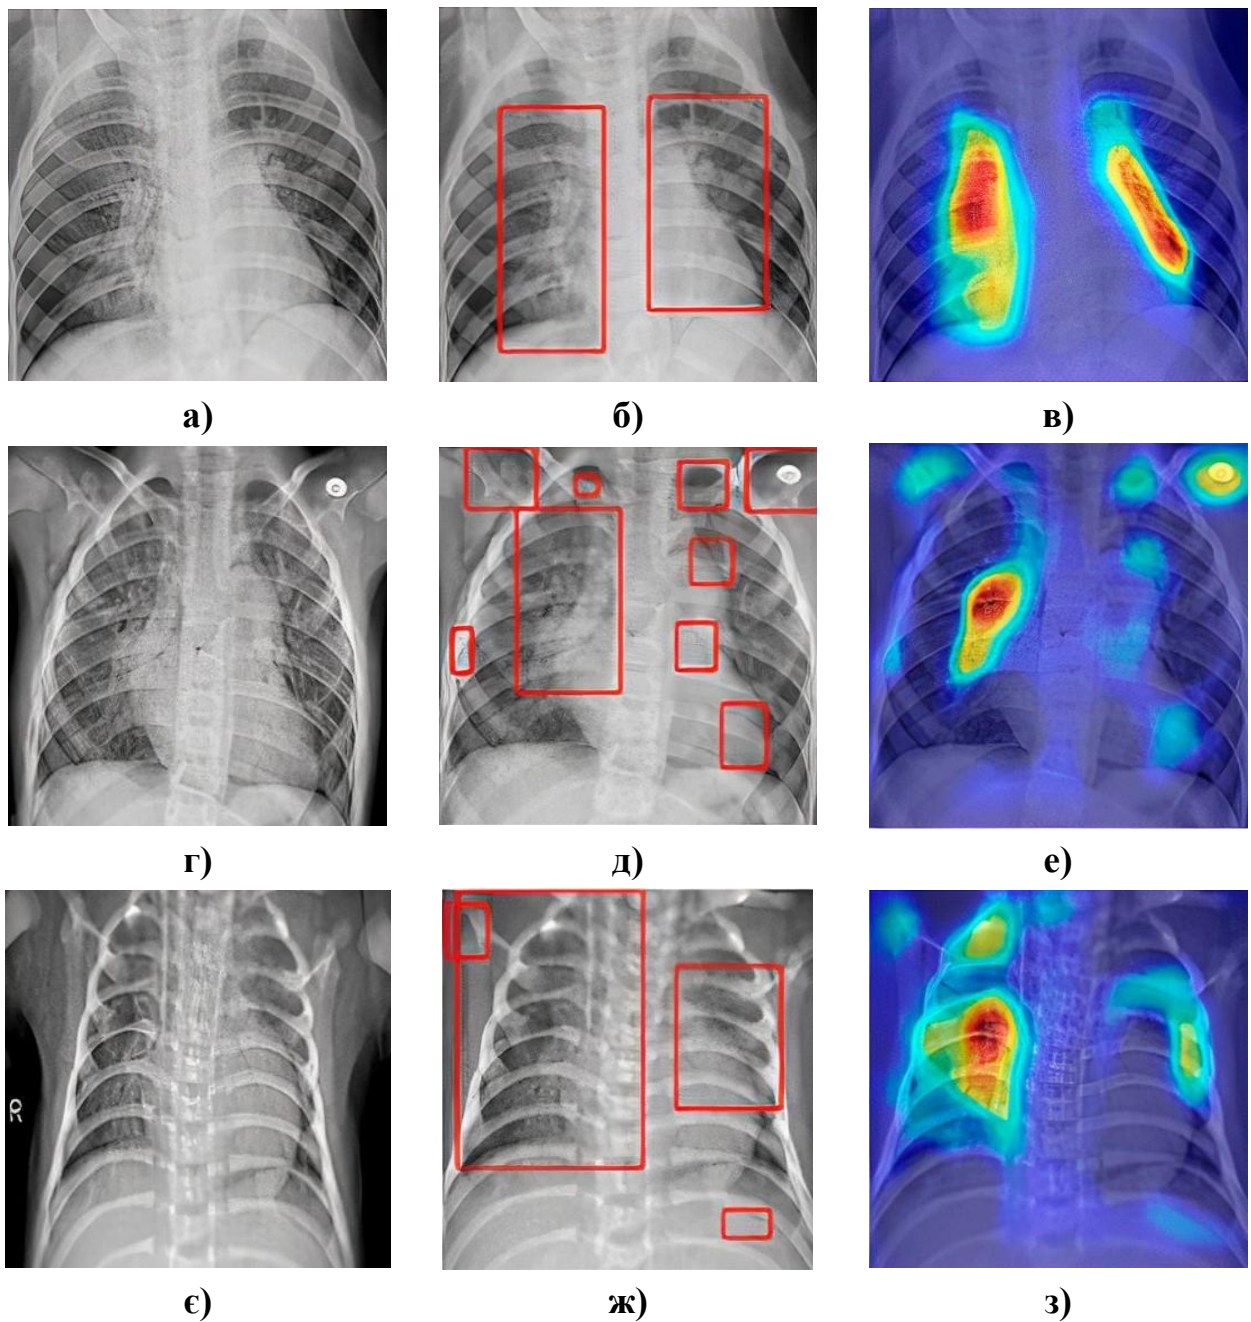


Рис.4.14 – Візуальне інтерпретування роботи CNN з допомогою методу AGCAM: а), г), є) вхідні рентгенівські зображення; б), д), ж) обмежувальні рамки, що локалізують ROIs; в), е), з) теплові карти, що накладені на вхідні зображення методом AGCAM

Результати застосування методу AGCAM (рис. 4.13) є схожими до результатів методу ACAM (рис. 4.14). Проте з огляду на візуальне порівняння

бачимо, що метод візуалізації AGCAM сформував більш виражені теплові карти порівняно з методом ACAM. Візуальна локалізація на рис. 4.14 демонструє те, що запропонована архітектура CNN визначає ознаки, що сильно корелюють із класом пневмонії, і з високою точністю виявляє ті ROIs, що відповідають ознакам пневмонічного запалення. Відповідно отримані теплові карти на попередньо оброблених зображеннях дають нагоду ідентифікувати візуальні відмінності в «пневмонічних» зонах зображення, і отже, забезпечують виявлення слабо виражених ознак ранньої пневмонії.

4.3. Висновки до розділу 4

1. Для експериментального тестування ІТ раннього діагностування пневмонії було розроблено веборієнтований програмний застосунок. Застосунок для діагностування пневмонії за рентгенівськими зображеннями відповідний розроблений ІТ й складається з двох підсистем – підсистеми ідентифікації пневмонії за рентгенівським зображенням та підсистеми візуального подання результатів ідентифікації. Тестування ІТ виконано за двома великими еталонними наборами даних CheXpert та PadChest. Для забезпечення чистоти експерименту із еталонних наборів даних CheXpert та PadChest виділено малі збалансовані набори CheXpert_small та PadChest_small.

2. Дослідження ІТ за статистичними показниками довели її ефективність для ідентифікації захворювання легень. Так, розроблена ІТ перевершила аналоги за показником точності класифікації (ACC) на 0,58% та 1,95% за наборами даних CheXpert_small та PadChest_small, відповідно; за показником влучності (Precision) на 0,02% за PadChest_small; за показником повноти (Recall) на 0,69% та 1,64% за CheXpert_small та PadChest_small, відповідно; за показником оцінки площі під ROC-кривою (AUC) на 1,08% за PadChest_small; за показником ймовірності помилки другого роду (FNR) на 0,64% та 1,64% за CheXpert_small та

PadChest_small, відповідно. Високі значення статистичних показників, що отримані запропонованою ІТ, свідчать як про високу точність виявлення пневмонічного запалення, так і значну влучність ІТ під час ідентифікації захворювання легень.

3. Дослідження ІТ за методом візуального подання підтвердили її здатність до надійної інтерпретації результатів ідентифікації захворювання легень. Удосконалений метод візуального подання AGSAM дає змогу формувати більш виражені теплові карти порівняно з аналогами. Візуальна локалізація методом AGSAM виокремлює ознаки, що сильно корелюють із класом пневмонії, і з високою точністю виявляє ті ROIs, що відповідають ознакам пневмонічного запалення. Відповідно отримані теплові карти на попередньо оброблених зображеннях дають змогу візуально відмічати та ідентифікувати будь-які відмінності в «пневмонічних» зонах зображення, і отже, забезпечують роз'яснення для користувача як ІТ ідентифікувала захворювання легень.

З огляду на отримані результати, робимо висновок, що запропонована ІТ здатна виконувати виявлення пневмонічного запалення на рентгенівських зображеннях із високою точністю та надійністю.

ВИСНОВКИ

У результаті виконання дисертаційної роботи було розв'язано актуальну науково-прикладну задачу раннього діагностування пневмонії за медичними зображенням грудної клітини людини.

У роботі отримано такі наукові та практичні результати:

1. За аналізом сучасних підходів, методів та інформаційних технологій для діагностування захворювання легень на ранніх стадіях за медичними зображеннями грудної клітини обґрунтовано потребу в створенні інформаційної технології раннього діагностування пневмонії.

2. Розроблено нейромережеву модель за згортковою архітектурою для досягнення мети виявлення пневмонічного запалення за рентгенівськими зображеннями та ідентифікації захворювання легень на ранніх стадіях. Особливістю запропонованої моделі є використання за навченою CNN гіперпараметрів для виявлення пневмонічних ознак у випадках індивідуальних особливостей легень, які не входили в початкову навчальну вибірку. Такий підхід дає змогу використовувати навчену CNN для прогнозування класів захворювання без перенавчання.

3. Удосконалено метод підбору квазіоптимальних гіперпараметрів CNN для ідентифікації пневмонії на ранніх стадіях за рентгенівськими зображеннями, що полягає у виділенні критеріїв оптимальності архітектури нейронної мережі для вхідного набору зображень, ініціалізації модульного простору пошуку елементів архітектури та її гіперпараметрів, а також у підборі параметрів архітектури та навчання моделі класифікації у вигляді згорткової нейронної мережі. Подібний підхід дає змогу врахувати індивідуальні особливості медичного зображення, і, у такий спосіб, забезпечити високий рівень ідентифікації захворювання.

4. Удосконалено метод візуального подання медичних зображень для інтерпретації результатів ідентифікації захворювання легень, що полягає в

застосуванні градієнтно-зваженого підходу до карт активацій класів. Візуальна локалізація удосконаленим методом забезпечує виокремлення ознак, що сильно корелюють із класом пневмонії, та з високою точністю виявляє ті області інтересу, що цілком покривають ознаки пневмонічного запалення. Отримані в такий спосіб теплові карти на попередньо оброблених медичних зображеннях дають змогу ідентифікувати візуальні відмінності в «пневмонічних» зонах зображення, і отже, забезпечують зручний інтерфейс для інтерпретування результатів ідентифікації захворювання легень.

5. Розроблено нову інформаційну технологію раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень, яка дає змогу за вхідними даними у вигляді цифрового зображення рентгенівського випромінювання грудної клітини людини одержувати діагноз захворювання людини з візуалізацією ділянок легень із патогенними змінами.

Виконано експериментальну перевірку інформаційної технології раннього діагностування пневмонії через розроблення та використання інформаційної системи ідентифікації захворювання легень за рентгенівськими зображеннями. Результати експериментального тестування запропонованої інформаційної технології довели її спроможність розв'язувати поставлені задачі. Так, розроблена інформаційна технологія перевершила аналоги за показником точності класифікації на 0,58% та 1,95% за наборами даних CheXpert_small та PadChest_small, відповідно; за показником влучності на 0,02% за PadChest_small; за показником повноти на 0,69% та 1,64% за CheXpert_small та PadChest_small, відповідно; за показником оцінки площі під ROC-кривою на 1,08% за PadChest_small; за показником ймовірності помилки другого роду на 0,64% та 1,64% за CheXpert_small та PadChest_small, відповідно. Високі значення статистичних показників свідчать як про високу точність виявлення

пневмонічного запалення, так і значну влучність моделі під час ідентифікації захворювання легень.

6. Практичне значення отриманих результатів полягає в розробленні інформаційної технології діагностування пневмонії на медичних зображеннях, що на основі розробленої моделі згорткової нейронної мережі та методу конфігурації нейронних мереж, а також із використанням удосконаленого методу інтерпретації результатів цифрового діагностування дає змогу ідентифікувати ранню пневмонію з високим рівнем точності та водночас з використанням пристроїв обмеженої обчислювальної складності.

7. Отримані результати досліджень покладено в основу експериментальних програмних застосувань, що ілюструють такі можливості інформаційної технології раннього діагностування пневмонії: дає змогу виконувати ефективну класифікацію рентгенівських зображень на малих обчислювальних пристроях та додавати елементи до архітектури, забезпечуючи її простоту із розширенням нозологій; враховує індивідуальні особливості легень кожної людини на медичному зображенні, і, у такий спосіб, забезпечує високий рівень ідентифікації захворювання проти аналогів; надає простий та зрозумілий користувацький інтерфейс для виявлення слабо виражених ознак пневмонічного запалення на ранній стадії захворювання.

Розроблені положення знайшли практичне застосування в роботі рентгенологічного відділення КП «Хмельницька міська лікарня» (довідка про впровадження), ТОВ «Науково-технічна фірма «Інфосервіс» (довідка про впровадження) та в навчальному процесі Хмельницького національного університету (акт про впровадження).

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Шлезингер М. И. Распознавание образов как реализация определенного подкласса процессов мышления. *Управляющие системы и машины*. 2017. № 2 (268). С. 20-37.
2. Barmak A. V., Krak Y. V., Manziuk E. A., Kasianiuk V. S. Information technology of separating hyperplanes synthesis for linear classifiers. *Journal of Automation and Information Sciences*. 2019. Vol. 51, No. 5. Pp. 54-64.
3. Krak Iu., Barmak O., Manziuk E. Using visual analytics to develop human and machine-centric models: A review of approaches and proposed information technology. *Computational intelligence*. 2020. Pp. 1-26.
4. Бармак О. В., Калита О. Д., Манзюк Е. А. Аналіз моделей для розпізнавання мімічних проявів емоцій. *Вимірювальна та обчислювальна техніка в технологічних процесах*. 2020. № 1. С. 77-83.
5. Krak I. V., Barmak O. V., Manziuk E. Visual analytics to build a machine learning model. *Research Advancements in Smart Technology, Optimization, and Renewable Energy* : eBook. Hershey, 2021. Pp. 313-329.
6. Deep neural network for image recognition based on the Caffe framework / M. Komar et al. *2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP-2018)* : Proceedings, Lviv, Ukraine, 21-25 August 2018. 2018. Pp. 102-106.
7. Deep convolutional neural network for detection of solar panels / V. Golovko et al. *Data-Centric Business and Applications*. Cham, 2020. Pp. 371-389.
8. The method of intelligent image processing based on a three-channel purely convolutional neural network / Eu. Fedorov et al. *The 1st International Workshop on Informatics & Data-Driven Medicine (IDDM 2018)* : Proceedings. CEUR-WS. Vol. 2255. (Lviv, Ukraine, November 28-30, 2018). Lviv, 2018. Pp. 336-351.

9. Fedorov Eu., Utkina T., Nechyporenko O., Korpan Y. Development of technique for face detection in image based on binarization, scaling and segmentation methods. *Eastern-European Journal of Enterprise Technologies*. 2020. Vol. 1, Issue 9 (103). Pp. 23-31.
10. Processing methods and ECG signal recognition model / Eu. Fedorov et al. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)* : Proceedings. CEUR-WS. Vol. 2753. (Växjö, Sweden, November 19-21, 2020). Växjö, 2020. Pp. 82-93.
11. Luc P., Couprie C., LeCun Y., Verbeek J. Predicting future instance segmentation by forecasting convolutional features. *Computer Vision – ECCV 2018* : Proceedings. Cham, 2018. Pp. 593-608.
12. LeCun Y. Deep learning hardware: Past, present, and future. *2019 IEEE International Solid- State Circuits Conference (ISSCC-2019)* : Proceedings, San Francisco, CA, USA, 17-21 February 2019. 2019. Pp. 1-8.
13. Bengio Y., LeCun Y., Hinton G. Deep learning for AI. *Communications of the ACM*. 2021. Vol. 64, No. 7. Pp. 58-65.
14. Chen T., Kornblith S., Norouzi M., Hinton G. A simple framework for contrastive learning of visual representations. *37th International Conference on Machine Learning (PMLR-2020)* : Proceedings, Virtual, 13-18 July 2020. 2020. Pp. 1597-1607.
15. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60, No. 6. Pp. 84-90.
16. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations (ICLR-2015)* : Proceedings, San Diego, CA, USA, 7-9 May 2015. 2015. Pp. 1-14.

17. Feichtenhofer C., Pinz A., Wildes R. P., Zisserman A. Deep insights into convolutional networks for video recognition. *International Journal of Computer Vision*. 2019. Vol. 128, No. 2. Pp. 420-437.

18. Automatically discovering and learning new visual categories with ranking statistics / K. Han et al. *8th International Conference on Learning Representations (ICLR-2020)* : Proceedings, Addis Ababa, Ethiopia, 30 April 2020. 2020. Pp. 1-13.

19. He K., Girshick R., Dollár P. Rethinking ImageNet pre-training. *2019 IEEE/CVF International Conference on Computer Vision (ICCV-2019)* : Proceedings, Seoul, Korea (South), 27 October - 2 November 2019. 2019. Pp. 4917-4926.

20. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2020. Vol. 42, No. 2. Pp. 386-397.

21. Zaychenko Y., Agh Ghamish Ovi Nafas A. Medical images classification and diagnostics using fuzzy neural networks. *American Journal of Neural Networks and Applications*. 2019. Vol. 5, No. 2. Pp. 45-50.

22. Zaychenko Y., Hamidov G. Hybrid fuzzy CNN network in the problem of medical images classification and diagnostics. *Advances in Natural Computation, Fuzzy Systems and Knowledge Discovery*. Cham, Springer International Publishing, 2019. Pp. 883-891.

23. Синтез біомедичних зображень на підставі генеративно-змагальних мереж / О. М. Березький та ін. *Український журнал інформаційних технологій*. 2019. Т. 1, № 1. С. 35-40.

24. Adaptive immunohistochemical image pre-processing method / O. Berezsky et al. *2020 10th International Conference on Advanced Computer Information Technologies (ACIT)* : Proceedings, Deggendorf, Germany, September 16-18, 2020. Deggendorf, 2020. Pp. 820-823.

25. Specified diagnosis of breast cancer on the basis of immunogistochemical images analysis / O. Berezsky et al. *The 3rd International Conference on Informatics*

& *Data-Driven Medicine (IDDM 2020)* : Proceedings. CEUR-WS. Vol. 2753. (Växjö, Sweden, November 19-21, 2020). Växjö, 2020. Pp. 129-135.

26. Selection parameters in the ECG signals for analysis of QRS complexes / Iu. Krak et al. *1st International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellISIS-2020)* : CEUR-WS. Vol. 2623. (Khmelnyskyi, 10-12 June 2020). Khmelnyskyi, 2020. Pp. 1-13.

27. Electrocardiogram classification using wavelet transformations / Iu. Krak et al. *2020 IEEE 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)* : Proceedings, Lviv-Slavske, Ukraine, 25-29 February 2020. 2020. Pp. 930-933.

28. Pashko A., Krak Iu., Stelia O., Wojcik W. Baseline wander correction of the electrocardiogram signals for effective preprocessing. *Lecture Notes in Computational Intelligence and Decision Making*, Cham, Springer International Publishing, 2022. Pp. 507-518.

29. An expert system prototype for the early diagnosis of pneumonia / M. Voronenko et al. *Lecture Notes in Computational Intelligence and Decision Making* : Proceedings, Zalizniy Port, Ukraine, 24-28 May 2021. Cham, 2021. Pp. 714-728.

30. Perova I., Brazhnykova Y., Bodyanskiy Y., Mulesa P. Neural network for online principal component analysis in medical data mining tasks. *2018 IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)* : Proceedings, Kyiv, Ukraine, 8-12 October 2018. 2018. Pp. 1-9.

31. The clinical utility of chest radiography for identifying pneumonia: Accounting for diagnostic uncertainty in radiology reports / A. Makhnevich et al. *American Journal of Roentgenology*. 2019. Vol. 213, No. 6. Pp. 1207-1212.

32. Stepanenko A., Oliinyk A. O., Fedorchenko I. Application of the fuzzy clustering technique for processing and analysis of medical images. *3rd International Workshop on Computer Modeling and Intelligent Systems (CMIS 2020)* : CEUR-WS. Zaporizhzhia, Ukraine, April 27 - May 1, 2020. Pp. 1079-1093.

33. Development of a genetic method for image recognition in the form of radiographs / A. Fedorchenko et al. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)* : CEUR-WS. Vol. 2753. (Växjö, Sweden, November 19-21, 2020). Växjö, 2020. Pp. 94-107.

34. Automatic processing of digital X-Ray medical images by bilateral filtration method / S. Balovsyak et al. *2nd International Workshop on Intelligent Information Technologies & Systems of Information Security (IntelITSIS-2021)* : CEUR-WS. Vol. 2853. (Khmelnyskyi, 24-26 March 2021). Khmelnyskyi, 2021. Pp. 280-294.

35. Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists / Pp. Rajpurkar et al. *PLOS Medicine*. 2018. Vol. 15, No. 11. Pp. e1002686.

36. CheXpert: A large chest radiograph dataset with uncertainty labels and expert comparison / J. Irvin et al. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019. Vol. 33. Pp. 590-597.

37. MIMIC-CXR, a de-identified publicly available database of chest radiographs with free-text reports / A. E. W. Johnson et al. *Scientific Data*. 2019. Vol. 6, No. 1. Pp. 1-8.

38. Rajaraman S., Thoma G., Antani S., Candemir S. Visualizing and explaining deep learning predictions for pneumonia detection in pediatric chest radiographs. *Medical Imaging 2019: Computer-Aided Diagnosis* : Proceedings, San Diego, CA, USA, 16-21 February 2019 / ed. by H. K. Hahn, K. Mori. 2019. Pp. 1-13.

39. Bustos A., Pertusa A., Salinas J.-M., de la Iglesia-Vayá M. PadChest: A large chest x-ray image dataset with multi-label annotated reports. *Medical Image Analysis*. 2020. Vol. 66. Pp. e101797.

40. Chest X-Ray bone suppression for improving classification of tuberculosis-consistent findings / S. Rajaraman. *Diagnostics*. 2021. Vol. 11, No. 5. Pp. 840.

41. Radiuk P. M. Applying 3D U-Net architecture to the task of multi-organ segmentation in computed tomography. *Applied Computer Systems*. 2020. Vol. 25, No. 1. Pp. 43-50.

42. Радюк П. М., Бармак О. В., Крак Ю. В. Інформаційна технологія ранньої діагностики пневмонії з використанням сверточних нейронних мереж. *Міжнародний науково-технічний журнал «Проблеми управління і інформатики»*. 2021. № 3. С. 101-114.

43. Radiuk P., Barmak O., Krak Ju. An approach to early diagnosis of pneumonia on individual radiographs based on the CNN information technology. *The Open Bioinformatics Journal*. 2021. Vol. 14, No. 1, Pp. 92-105.

44. Radiuk P. M. Impact of training set batch size on the performance of convolutional neural networks for diverse datasets. *Information Technology and Management Science*. 2017. Vol. 20, No. 1. Pp. 20-24.

45. Radiuk P. M. Neuroevolution of convolutional neural networks for the classification of lung cancer images. *Herald of Khmelnytskyi National University*. 2018. Vol. 267, No. 6 (2). Pp. 188-192.

46. Radiuk P. M. Application of a genetic algorithm to search for the optimal convolutional neural network architecture with weight distribution. *Herald of Khmelnytskyi National University*. 2020. Vol. 281, No. 1. Pp. 7-11.

47. Radiuk P. M. Modular search space for automated design of neural architecture. *Proceedings of the O.S. Popov ONAT*. 2020. Vol. 1, No. 1. Pp. 37-44.

48. Бармак О. В., Радюк П. М. Інформаційна технологія візуального подання рентгенівських зображень для інтерпретації результатів діагностування пневмонії. *Вісник Хмельницького національного університету*. 2021. № 295(2). С. 52-55.

49. Barmak O., Radiuk P. Web-based information technology for classifying and interpreting early pneumonia based on fine-tuned convolutional neural network. *Computer systems and information technologies*. 2021. Vol. 3, No. 1. Pp. 12-18.

50. Radiuk P. M., Hrypynska N. V. A framework for exploring and modelling neural architecture search methods. *The 4th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2020)* : CEUR-WS. Vol. 2604. (Lviv, 23-24 April 2020). Lviv, 2020. Pp. 1060-1074.

51. Radiuk P. M., Kutucu H. Heuristic architecture search using network morphism for chest X-Ray classification. *The 1st International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2020)* : CEUR-WS. Vol. 2623. (Khmelnyskyi, 10-12 June 2020). Khmelnyskyi, 2020. Pp. 107-121.

52. Krak Iu., Barmak O., Radiuk P. Information technology for early diagnosis of pneumonia on individual radiographs. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)* : CEUR-WS. Vol. 2753. (Växjö, Sweden, November 19-21, 2020). Växjö, 2020. Pp. 11-21.

53. Krak Iu., Barmak O., Radiuk P. Detection of early pneumonia on individual CT scans with dilated convolutions. *The 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2021)* : CEUR-WS. Vol. 2853. (Khmelnyskyi, 24-26 March 2021). Khmelnyskyi, 2021. Pp. 214-227.

54. Радюк П. М. Оптимізація розподілу розмірів фільтрів згорткових нейронних мереж у задачах класифікації. *Актуальные научные исследования в современном мире ISCIENCE.IN.UA* : тезисы междунар. науч. конф. (м. Переяслав, 21-22 груд. 2016). Переяслав, 2016. С. 48-51.

55. Радюк П. М., Праворська Н. І., Грипинська Н. В. Реалізація нейромережевого алгоритму пакета інструментів MatConvNet з використанням графічного процесора. *Science and Education 2017* : proceedings of X international conference of Science and Education (Rome, Italy, 27 April - 4 May, 2017). Khmelnyskyi, Council of Scientific and Engineering Union in Khmelnyskyi Region, 2017. С. 60-62.

56. Радюк П. М. Аналіз застосування методів нейромережевого моделювання для обробки медичних зображень. «ІНТЕЛЕКТУАЛЬНІ РІШЕННЯ». *Обчислювальний інтелект (результати, проблеми, перспективи)* : матеріали V міжнар. наук.-практ. конф. (м. Ужгород, 15-20 квіт. 2019 р.). Ужгород, 2019. С. 273-274.

57. Радюк П. М. Поиск оптимальной архитектуры сверточной нейронной сети с использованием генетических алгоритмов. *Современные информационные и коммуникационные технологии на транспорте, в промышленности и образовании* : тезисы XIII междунар. науч.-практ. конф. (м. Днепр, 11-12 дек. 2019 г.). Д. : ДПТ, 2019. С. 117-118.

58. Радюк П. М. Аналітичний огляд архітектур згорткових нейронних мереж у задачах аналізу медичних зображень. *Science, Engineering and Technology: Global and Current Trends* : proceedings of inter. and pract. conf. (м. Прага, 27-28 груд. 2019). Прага, 2019. С. 32-25.

59. Радюк П. М. Стратегія пошуку оптимальної архітектури згорткової нейронної мережі. *VIII Всеукраїнська науково-практична конференція студентів, аспірантів та молодих вчених з автоматичного управління присвяченої Дню космонавтики* : матеріали VIII всеукр. наук.-практ. конф. (м. Херсон, 8-10 квіт. 2020 р.). Херсон, 2020. С. 35-36.

60. Радюк П. М., Грипинська Н. В. Простір пошуку для задачі оптимізації архітектури нейронної мережі. *IX Міжнародна науково-практична конференція студентів, аспірантів та молодих вчених: Використання інформаційних та комунікаційних технологій в сучасному цифровому суспільстві* : матеріали IX міжнар. наук.-практ. конф. (м. Херсон, 4-5 черв. 2020 р.) / за заг. ред. Г.О. Райко. Херсон: Видавництво ФОП Вишемирський В.С., 2020. С. 308-311.

61. Global, regional, and national age-sex-specific mortality for 282 causes of death in 195 countries and territories, 1980-2017: A systematic analysis for the Global

Burden of Disease Study 2017 / G. A. Roth et al. *The Lancet*. 2018. Vol. 392, No. 10159. Pp. 1736-1788.

62. Raghu G., Wilson K. C. COVID-19 interstitial pneumonia: Monitoring the clinical course in survivors. *The Lancet Respiratory Medicine*. 2020. Vol. 8, No. 9. Pp. 839-842.

63. Clinical features, diagnostics, and outcomes of patients presenting with acute respiratory illness: A retrospective cohort study of patients with and without COVID-19 / S. J. Shah et al. *EClinicalMedicine*. 2020. Vol. 27. Pp. e100518.

64. Tansarli G. S., Mylonakis E. Systematic review and meta-analysis of the efficacy of short-course antibiotic treatments for community-acquired pneumonia in adults. *Antimicrobial Agents and Chemotherapy*. 2018. Vol. 62, No. 9. Pp. 00635-18.

65. Early identification of patients at risk for acute respiratory distress syndrome among severe pneumonia: A retrospective cohort study / J. Luo. *Journal of Thoracic Disease*. 2017. Vol. 9, No. 10. Pp. 3979-3995.

66. Importance of early diagnosis and treatment in idiopathic pulmonary fibrosis / M. Molina-Molina et al. *Expert Review of Respiratory Medicine*. 2018. Vol. 12, No. 7. Pp. 537-539.

67. El-Helbawy R., Aghaa M., Habeab R., Ibrahim R. Utility of chest echography and pulmonary infection score in early diagnosis of ventilator associated pneumonia. *European Respiratory Journal*. 2018. Vol. 52, Issue 62. PA. 856.

68. Early readmission and mortality in acute exacerbation of chronic obstructive pulmonary disease with community-acquired pneumonia / B. Shin et al. *Chronic Respiratory Disease*. 2018. Vol. 16. Pp. 1-12.

69. Prevention of early ventilator-associated pneumonia after cardiac arrest / B. François et al. *New England Journal of Medicine*. 2019. Vol. 381, No. 19. Pp. 1831-1842.

70. Early prediction of disease progression in COVID-19 pneumonia patients with chest CT and clinical characteristics / Z. Feng et al. *Nature Communications*. 2020. Vol. 11, No. 1. Pp. e4968.
71. Modi A. R., Kovacs C. S. Hospital-acquired and ventilator-associated pneumonia: Diagnosis, management, and prevention. *Cleveland Clinic Journal of Medicine*. 2020. Vol. 87, No. 10. Pp. 633-639.
72. Radiographic and CT features of viral pneumonia / H. J. Koo et al. *RadioGraphics*. 2018. Vol. 38, No. 3. Pp. 719-739.
73. Pulmonary pathology of early-phase 2019 novel coronavirus (COVID-19) pneumonia in two patients with lung cancer / S. Tian et al. *Journal of Thoracic Oncology*. 2020. Vol. 15, No. 5. Pp. 700-704.
74. Meta-analysis of the radiological and clinical features of usual interstitial pneumonia (UIP) and nonspecific interstitial pneumonia (NSIP) / L. Ebner et al. *PLOS ONE*. 2020. Vol. 15, No. 1. Pp. e0226084.
75. Comparative analysis of early-stage clinical features between COVID-19 and influenza A H1N1 virus pneumonia / C. Shen et al. *Frontiers in Public Health*. 2020. Vol. 8, No. 1. Pp. e206.
76. Morris A. C. Management of pneumonia in intensive care. *Journal of Emergency and Critical Care Medicine*. 2018. Vol. 2, No. 1. Pp. e101.
77. Analysis of perceptual expertise in radiology - current knowledge and a new perspective / S. Waite et al. *Frontiers in Human Neuroscience*. 2019. Vol. 13. Pp. e213.
78. Deep learning for diagnosis and segmentation of pneumothorax: The results on the Kaggle competition and validation against radiologists / A. Tolkachev et al. *IEEE Journal of Biomedical and Health Informatics*. 2020. Vol. 25, No. 5. Pp. 1660-1672.
79. Mery D., Pieringer C. X-Ray testing. *Computer vision for X-Ray testing* : eBook. 2nd ed. Cham, 2020. Pp. 1-41.
80. Seeram E. Digital radiography : eBook. 2nd ed. Singapore : Springer Singapore, 2019. 227 p.

81. Artificial intelligence in radiology / D. Jin et al. *Artificial Intelligence in Medicine* : eBook. San Diego, 2021. Pp. 265-289.
82. Mery D., Pieringer C. Images for X-Ray testing. *Computer vision for X-Ray testing* : eBook. 2nd ed. Cham, 2020. Pp. 43-63.
83. Seeram E. Computed radiography: Physics and technology. *Digital radiography* : eBook. Singapore, 2019. Pp. 41-63.
84. Toda H. X-Ray CT scanners and application examples. *X-Ray CT: Hardware and Software Techniques* : eBook. Singapore, 2021. Pp. 333-380.
85. Impact of photoelectric effect on X-Ray density logging and its correction / H. Yu et al. *Applied Radiation and Isotopes*. 2020. Vol. 156, No. 1. Pp. e108785.
86. Yin X.-X., Hadjiloucas S., Zhang Y. Pattern classification of medical images: Computer aided diagnosis. Cham : Springer International Publishing, 2017. 218 p.
87. Mery D., Pieringer C. Geometry in X-Ray testing. *Computer vision for X-Ray testing* : eBook. 2nd ed. Cham, 2020. Pp. 65-123.
88. A novel transfer learning-based approach for pneumonia detection in chest X-Ray images / V. Chouhan et al. *Applied Sciences*. 2020. Vol. 10, No. 2. Pp. e559.
89. Understanding color / O. Yélamos et al. *Photography in clinical medicine* : eBook. Cham, 2020. Pp. 99-111.
90. The decomposition of deformation: New metrics to enhance shape analysis in medical imaging. / V. Varano et al. *Medical Image Analysis*. 2018. Vol. 46. Pp. 35-56.
91. Chandra T. B., Verma K. Pneumonia detection on chest X-Ray using machine learning paradigm. *Proceedings of 3rd International Conference on Computer Vision and Image Processing* : Proceedings. Singapore, 2019. Pp. 21-33.
92. Gray-level invariant Haralick texture features / T. Löfstedt et al. *PLOS ONE*. 2019. Vol. 14, No. 2. Pp. e0212110.
93. Vamsha Deepa N., Krishna N., Hemanth Kumar G. Feature extraction and classification of x-ray lung images using Haralick texture features. *Communications in Computer and Information Science* : Proceedings. Singapore, 2018. Pp. 899-907.

94. Accuracy of deep learning for automated detection of pneumonia using chest X-Ray images: A systematic review and meta-analysis / Y. Li et al. *Computers in Biology and Medicine*. 2020. Vol. 123, No. 1. Pp. e103898.
95. Khan W., Zaki N., Ali L. Intelligent pneumonia identification from chest X-Rays: A systematic literature review. *IEEE Access*. 2021. Vol. 9. Pp. 51747-51771.
96. Heinrichs B., Eickhoff S. B. Your evidence? Machine learning algorithms for medical diagnosis and prediction. *Human Brain Mapping*. 2020. Vol. 41, No. 6. Pp. 1435-1444.
97. Puttagunta M., Ravi S. Medical image analysis based on deep learning approach. *Multimedia Tools and Applications*. 2021. Vol. 80, No. 16. Pp. 24365-24398.
98. Deep learning workflow in radiology: A primer / E. Montagnon et al. *Insights into Imaging*. 2020. Vol. 11, No. 1. Pp. 22.
99. Chen Y.-Ch., Hong D. J.-K., Wu Ch.-W., Mupparapu M. The use of deep convolutional neural networks in biomedical imaging: A review. *Journal of Orofacial Sciences*. 2019. Vol. 9, No. 1. Pp. 3-10.
100. Yamashita R., Nishio M., Do R. K. G., Togashi K. Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*. 2018. Vol. 9, No. 4. Pp. 611-629.
101. Sarvamangala D. R., Kulkarni R. V. Convolutional neural networks in medical image understanding: A survey. *Evolutionary Intelligence*. 2021. Pp. e12065.
102. Detection of unexpected findings in radiology reports: A comparative study of machine learning approaches / Pp. López-Úbeda et al. *Expert Systems with Applications*. 2020. Vol. 160, No. 1. Pp. e113647.
103. Al Mamlook R. E., Chen S., Bzizi H. F. Investigation of the performance of machine learning classifiers for pneumonia detection in chest X-Ray images. 2020 *IEEE International Conference on Electro Information Technology (EIT)*: Proceedings, Chicago, IL, USA, 31 July - 1 August 2020. 2020. Pp. 98-104.

104. Yasar H., Ceylan M. A novel comparative study for detection of COVID-19 on CT lung images using texture analysis, machine learning, and deep learning methods. *Multimedia Tools and Applications*. 2020. Vol. 80, No. 1. Pp. 5423-5447.

105. Wiatowski T., Bolcskei H. A mathematical theory of deep convolutional neural networks for feature extraction. *IEEE Transactions on Information Theory*. 2018. Vol. 64, No. 3. Pp. 1845-1866.

106. Khan A., Sohail A., Zahoor U., Qureshi A. S. A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*. 2020. Vol. 53, No. 8. Pp. 5455-5516.

107. Automated deep learning design for medical image classification by health-care professionals with no coding experience: A feasibility study / L. Faes et al. *The Lancet Digital Health*. 2019. Vol. 1, No. 5. Pp. e232-e242.

108. Plankis T., Juozapavičius A., Stašienė E., Usonis V. Computer-aided detection of interstitial lung diseases: A texture approach. *Nonlinear Analysis: Modelling and Control*. 2017. Vol. 22, No. 3. Pp. 404-411.

109. Sharma A., Raju D., Ranjan S. Detection of pneumonia clouds in chest X-Ray using image processing approach. *2017 Nirma University International Conference on Engineering (NUiCONE): Proceedings, Ahmedabad, India, 23-25 November 2017*. 2017. Pp. e8325607.

110. Development of a computer-aided differential diagnosis system to distinguish between usual interstitial pneumonia and non-specific interstitial pneumonia using texture- and shape-based hierarchical classifiers on HRCT images / S. Jun et al. *Journal of Digital Imaging*. 2017. Vol. 31, No. 2. Pp. 235-244.

111. Conventional machine learning based on feature engineering for detecting pneumonia from chest X-Rays / J. Ebiele et al. *SAICSIT '20: Conference of the South African Institute of Computer Scientists and Information Technologists 2020: Proceedings, Cape Town, South Africa, 14-16 September 2020*. New York, NY, USA, 2020. Pp. 149-155.

112. Early recognition of necrotizing pneumonia in children based on non-contrast-enhanced computed tomography radiomics signatures / X. Chen et al. *Translational Pediatrics*. 2021. Vol. 10, No. 6. Pp. 1542-1551.

113. Keles A., Keles M. B., Keles A. COV19-CNNet and COV19-resnet: Diagnostic inference engines for early detection of COVID-19. *Cognitive Computation*. 2021. Pp. e12559.

114. ChestX-Ray8: Hospital-scale chest X-Ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases / X. Wang et al. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Honolulu, HI, USA, 21-26 July 2017. 2017. Pp. 3462-3471.

115. Huang G., Liu Z., van der Maaten L., Weinberger K. Q. Densely connected convolutional networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Honolulu, HI, USA, 21-26 July 2017. 2017. Pp. 2261-2269.

116. Grad-CAM: Visual explanations from deep networks via gradient-based localization / R. R. Selvaraju et al. *International Journal of Computer Vision*. 2019. Vol. 128, No. 2. Pp. 336-359.

117. Recurrent residual U-Net for medical image segmentation / M. Z. Alom et al. *Journal of Medical Imaging*. 2019. Vol. 6, No. 1. Pp. e014006.

118. Szegedy C., Ioffe S., Vanhoucke V., Alemi A. Inception-v4, Inception-ResNet and the impact of residual connections on learning. *31st AAAI Conference on Artificial Intelligence (AAAI-2017)* : Proceedings, San Francisco, California, USA, 4-10 February 2017. Pp. 4278-4284.

119. Mahmud T., Rahman M. A., Fattah S. A. CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-Ray images with transferable multi-receptive feature optimization. *Computers in Biology and Medicine*. 2020. Vol. 122. Pp. e103869.

120. Aggregated residual transformations for deep neural networks / S. Xie et al. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Honolulu, HI, USA, 21-26 July 2017. 2017. Pp. 5987-5995.

121. Feng X., Yang J., Laine A. F., Angelini E. D. Discriminative localization in CNNs for weakly-supervised segmentation of pulmonary nodules. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2017* : Proceedings. Cham, 2017. Pp. 568-576.

122. MobileNetV2: Inverted residuals and linear bottlenecks / M. Sandler et al. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Salt Lake City, UT, USA, 18-23 June 2018. 2018. Pp. 4510-4520.

123. Searching for MobileNetV3 / A. Howard et al. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)* : Proceedings, Seoul, Korea (South), 27 October - 2 November 2019. 2019. Pp. 1314-1324.

124. Turkoglu M. COVIDetectionNet: COVID-19 diagnosis system based on X-Ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence*. 2020. Vol. 51, No. 3. Pp. 1213-1226.

125. Multi-objective evolutionary design of deep convolutional neural networks for image classification / Z. Lu et al. *IEEE Transactions on Evolutionary Computation*. 2020. Vol. 25, No. 2. Pp. 277-291.

126. Lu Z., Deb K., Naresh Boddeti V. MUXConv: Information multiplexing in convolutional neural networks. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR-2020)* : Proceedings, Seattle, WA, USA, 13-19 June 2020. 2020. Pp. 12041-12050.

127. Comparing different deep learning architectures for classification of chest radiographs / K. K. Bressen et al. *Scientific Reports*. 2020. Vol. 10, No. 1. Pp. e13590.

128. Yu F., Koltun V., Funkhouser T. Dilated residual networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Honolulu, HI, USA, 21-26 July 2017. 2017. Pp. 636-644.

129. Hua B.-S., Tran M.-K., Yeung S.-K. Pointwise convolutional neural networks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Salt Lake City, UT, USA, 18-23 June 2018. 2018. Pp. 984-993.
130. Chollet F. Xception: Deep learning with depthwise separable convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* : Proceedings, Honolulu, HI, USA, 21-26 July 2017. 2017. Pp. 1800-1807.
131. TensorFlow.js: Machine learning for the web and beyond / D. Smilkov et al. *2nd Conference on Machine Learning and Systems (SysML-2019)* : Proceedings (Palo Alto, CA, USA, 31 March - 01 April 2019), 2019. Pp. 1-13.
132. PyTorch: An imperative style, high-performance deep learning library / A. Paszke et al. *33rd Conference on Neural Information Processing Systems (NeurIPS-2019)* : Proceedings. Curran Associates, Inc. Vol. 32 (Vancouver, BC, Canada, 8-14 December 2019). Vancouver, 2019. Pp. 8024-8035.
133. Bai J., Lu F., Zhang K. ONNX: Open neural network exchange. *GitHub, Inc.* 2019. URL: <https://github.com/onnx> (last accessed: 28.03.2021).
134. NiftyNet: A deep-learning platform for medical imaging / E. Gibson et al. *Computer Methods and Programs in Biomedicine*. 2018. Vol. 158. Pp. 113-122.
135. Project MONAI / N. Ma et al. *Zenodo*. CERN. 2021. URL: <http://doi.org/10.5281/zenodo.4679866> (last accessed: 02.04.2021).
136. Pérez-García, F., Sparks, R., Ourselin, S. TorchIO: A Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning. *Computer Methods and Programs in Biomedicine*. 2021. Pp. e106236.
137. Selvan R., Dam E. B. Tensor networks for medical image classification. *3rd Conference on Medical Imaging with Deep Learning (PMLR-2020)* : PMLR.org. Vol. 121 (Montreal, QC, Canada, 6-8 July 2020). Montreal, 2020. Pp. 721-732.

138. Müller D., Kramer F. MIScnn: A framework for medical image segmentation with convolutional neural networks and deep learning. *BMC Medical Imaging*. 2021. Vol. 21, No. 12. Pp. 1-11.
139. Reddy Raamana Pp., C. Strother S. mrivis: Medical image visualization library for neuroscience in python. *Journal of Open Source Software*. 2018. Vol. 3, No. 30. Pp. 897-898.
140. Chollet F. Keras: The python deep learning. *GitHub, Inc.* 2021. URL: <https://github.com/keras-team/keras> (last accessed: 12.04.2021).
141. Tharwat A. Classification assessment methods. *Applied Computing and Informatics*. 2020. Vol. 17, No. 1. Pp. 168-192.
142. A recent survey on the applications of genetic programming in image processing / A. Khan et al. *Computational Intelligence*. 2021. Pp. 1-34.
143. Powell W. B. A unified framework for stochastic optimization. *European Journal of Operational Research*. 2019. Vol. 275, No. 3. Pp. 795-821.

ДОДАТОК А.
СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Публікації в періодичних наукових виданнях, що індексуються в наукометричних базах Scopus, Web of Science:

1. Radiuk P. M. Applying 3D U-Net architecture to the task of multi-organ segmentation in computed tomography. *Applied Computer Systems*. 2020. Vol. 25, No. 1. Pp. 43-50. (WoS, Latvia)

2. Радюк П. М., Бармак О. В., Крак Ю. В. Информационная технология ранней диагностики пневмонии с использованием сверточных нейронных сетей. *Международный научно-технический журнал «Проблемы управления и информатики»*. 2021. № 3. С 101-114. (Scopus)

3. Radiuk P., Barmak O., Krak Iu. An approach to early diagnosis of pneumonia on individual radiographs based on the CNN information technology. *The Open Bioinformatics Journal*. 2021. Vol. 14, No. 1, Pp. 92-105. (Scopus, Netherlands)

Публікації в періодичних наукових виданнях інших держав, які входять до Організації економічного співробітництва та розвитку та/або Європейського Союзу:

4. Radiuk P. M. Impact of training set batch size on the performance of convolutional neural networks for diverse datasets. *Information Technology and Management Science*. 2017. Vol. 20, No. 1. Pp. 20-24.

Статті у фахових наукових виданнях України:

5. Radiuk P. M. Neuroevolution of convolutional neural networks for the classification of lung cancer images. *Herald of Khmelnytskyi National University*. 2018. Vol. 267, No. 6 (2). Pp. 188-192.

6. Radiuk P. M. Application of a genetic algorithm to search for the optimal convolutional neural network architecture with weight distribution. *Herald of Khmelnytskyi National University*. 2020. Vol. 281, No. 1. Pp. 7-11.

7. Radiuk P. M. Modular search space for automated design of neural architecture. *Proceedings of the O.S. Popov ONAT*. 2020. Vol. 1, No. 1. Pp. 37-44.

8. Бармак О. В., Радюк П. М. Інформаційна технологія візуального подання рентгенівських зображень для інтерпретації результатів діагностування пневмонії. *Вісник Хмельницького національного університету*. 2021. № 295(2). С. 52-55.

9. Barmak O., Radiuk P. Web-based information technology for classifying and interpreting early pneumonia based on fine-tuned convolutional neural network. *Computer systems and information technologies*. 2021. Vol. 3, No. 1. Pp. 12-18.

Статті в матеріалах конференцій, що індексуються в наукометричних базах Scopus:

10. Radiuk P. M., Hrypynska N. V. A framework for exploring and modelling neural architecture search methods. *The 4th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2020)* : CEUR-WS. Vol. 2604. (Lviv, 23-24 April 2020). Lviv, 2020. Pp. 1060-1074. (*Scopus, WoS*)

11. Radiuk P. M., Kutucu H. Heuristic architecture search using network morphism for chest X-Ray classification. *The 1st International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2020)* : CEUR-WS. Vol. 2623. (Khmelnyskyi, 10-12 June 2020). Khmelnyskyi, 2020. Pp. 107-121. (*Scopus, WoS*)

12. Krak Iu., Barmak O., Radiuk P. Information technology for early diagnosis of pneumonia on individual radiographs. *The 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020)* : CEUR-WS. Vol. 2753. (Växjö, Sweden, November 19-21, 2020). Växjö, 2020. Pp. 11-21. (*Scopus, WoS*)

13. Krak Iu., Barmak O., Radiuk P. Detection of early pneumonia on individual CT scans with dilated convolutions. *The 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2021)* :

CEUR-WS. Vol. 2853. (Khmelnyskyi, 24-26 March 2021). Khmelnyskyi, 2021. Pp. 214-227. (*Scopus*)

Публікації в матеріалах конференцій (тези доповідей):

14. Радюк П. М. Оптимізація розподілу розмірів фільтрів згорткових нейронних мереж у задачах класифікації. *Актуальные научные исследования в современном мире ISCIENCE.IN.UA* : тезисы междунар. науч. конф. (м. Переяслав, 21-22 груд. 2016). Переяслав, 2016. С. 48-51.

15. Радюк П. М., Праворська Н. І., Грипинська Н. В. Реалізація нейромережевого алгоритму пакета інструментів MatConvNet з використанням графічного процесора. *Science and Education 2017* : proceedings of X international conference of Science and Education (Rome, Italy, 27 April - 4 May, 2017). Khmelnyskyi, Council of Scientific and Engineering Union in Khmelnyskyi Region, 2017. С. 60-62.

16. Радюк П. М. Аналіз застосування методів нейромережевого моделювання для обробки медичних зображень. «ІНТЕЛЕКТУАЛЬНІ РІШЕННЯ». *Обчислювальний інтелект (результати, проблеми, перспективи)* : матеріали V міжнар. наук.-практ. конф. (м. Ужгород, 15-20 квіт. 2019 р.). Ужгород, 2019. С. 273-274.

17. Радюк П. М. Поиск оптимальной архитектуры сверточной нейронной сети с использованием генетических алгоритмов. *Современные информационные и коммуникационные технологии на транспорте, в промышленности и образовании* : тезисы XIII междунар. науч.-практ. конф. (м. Днепр, 11-12 дек. 2019 г.). Д. : ДПТ, 2019. С. 117-118.

18. Радюк П. М. Аналітичний огляд архітектур згорткових нейронних мереж у задачах аналізу медичних зображень. *Science, Engineering and Technology: Global and Current Trends* : proceedings of inter. and pract. conf. (м. Прага, 27-28 груд. 2019). Прага, 2019. С. 32-25.

19. Радюк П. М. Стратегія пошуку оптимальної архітектури згорткової нейронної мережі. *VIII Всеукраїнська науково-практична конференція студентів, аспірантів та молодих вчених з автоматичного управління присвяченої Дню космонавтики* : матеріали VIII всеукр. наук.-практ. конф. (м. Херсон, 8-10 квіт. 2020 р.). Херсон, 2020. С. 35-36.

20. Радюк П. М., Грипинська Н.В. Простір пошуку для задачі оптимізації архітектури нейронної мережі. *IX Міжнародна науково-практична конференція студентів, аспірантів та молодих вчених: Використання інформаційних та комунікаційних технологій в сучасному цифровому суспільстві* : матеріали IX міжнар. наук.-практ. конф. (м. Херсон, 4-5 черв. 2020 р.) / за заг. ред. Г.О. Райко. Херсон: Видавництво ФОП Вишемирський В.С., 2020. С. 308-311.

ДОДАТОК Б.
АКТИ ВПРОВАДЖЕННЯ



УКРАЇНА

Хмельницька міська рада

**КОМУНАЛЬНЕ ПІДПРИЄМСТВО
«ХМЕЛЬНИЦЬКА МІСЬКА ЛІКАРНЯ»
ХМЕЛЬНИЦЬКОЇ МІСЬКОЇ РАДИ**
пров. Проскурівський, 1, м. Хмельницький, 29000
E-mail: mlikxm@gmail.com Код ЄДРПОУ 02774384

від 21.04.2021 р. № 747/1

ДОВІДКА

**про впровадження результатів наукових досліджень
за темою дисертаційної роботи
Радюка Павла Михайловича**

Результати дисертаційної роботи Радюка Павла Михайловича за темою «Інформаційна технологія раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень», а саме інформаційна технологія виявлення та ідентифікації ознак ранньої вірусної пневмонії на медичних зображеннях легень використовується в роботі рентгенологічного відділення КП «Хмельницька міська лікарня» для цифрового діагностування ранньої пневмонії на рентгенівських зображеннях з допомогою засобів комп'ютерної діагностики. Впровадження здійснено у вигляді веб-орієнтованої інформаційної системи.

Заступник медичного директора
КП «Хмельницька міська лікарня»



А.С. Моргун

19.05.2021 № _____ 1

ДОВІДКА

про впровадження результатів дисертаційної роботи
 Радюка Павла Михайловича «Інформаційна технологія раннього діагностування
 пневмонії за індивідуальним підбором параметрів моделі класифікації медичних
 зображень легень»

У процесі виробничої діяльності ТОВ "Науково-технічна фірма «Інфосервіс»" знайшли застосування такі результати дисертаційної роботи Радюка Павла Михайловича «Інформаційна технологія раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень»:

- модель за згортковою архітектурою для виявлення ознак запалення захворювання легень за рентгенівськими зображеннями грудної клітини людини;
- метод підбору квазіоптимальних гіперпараметрів нейромережевої моделі для ідентифікації захворювання легень на ранніх стадіях за рентгенівськими зображеннями грудної клітини;
- метод візуального подання та пояснення результатів цифрового діагностування, який забезпечує зручний інтерфейс для інтерпретування результатів ідентифікації захворювання легень на ранніх стадіях за рентгенівськими зображеннями грудної клітини;
- інформаційна технологія раннього діагностування пневмонії за індивідуальним підбором параметрів моделі класифікації медичних зображень легень, яка дає змогу за вхідними даними у вигляді цифрового зображення рентгенівського випромінювання грудної клітини людини одержувати діагноз захворювання людини з візуалізацією ділянок легень із патогенними змінами.

У ТОВ "Науково-технічна фірма «Інфосервіс»" зазначені результати використовуються в процесі розроблення промислового програмного забезпечення для створення інформаційних технологій у модулях для класифікації медичних зображень на малих обчислювальних пристроях та для додавання елементів до архітектури інформаційної системи, забезпечуючи її простоту із розширенням нозологій.

Директор



Павлишин В.В.

ДОДАТОК В.

РЕЗУЛЬТАТИ ЕКСПЕРИМЕНТАЛЬНОГО ТЕСТУВАННЯ

		Прогнозований	
		Нормальний	Пневмонія
Реальний	Нормальний	1343	386
	Пневмонія	228	1501

а)

		Прогнозований	
		Нормальний	Пневмонія
Реальний	Нормальний	1410	319
	Пневмонія	191	1538

б)

		Прогнозований	
		Нормальний	Пневмонія
Реальний	Нормальний	1577	152
	Пневмонія	75	1654

в)

		Прогнозований	
		Нормальний	Пневмонія
Реальний	Нормальний	1472	257
	Пневмонія	114	1615

г)

		Прогнозований	
		Нормальний	Пневмонія
Реальний	Нормальний	1583	146
	Пневмонія	99	1630

д)

		Прогнозований	
		Нормальний	Пневмонія
Реальний	Нормальний	1594	135
	Пневмонія	72	1657

е)

Рис. В.1 – Матриці невідповідностей за набором даних тестування
CheXpert_small: а) PCA; б) Wavelet; в) CheXNet; г) VGG; д) Inception; е) ResNet

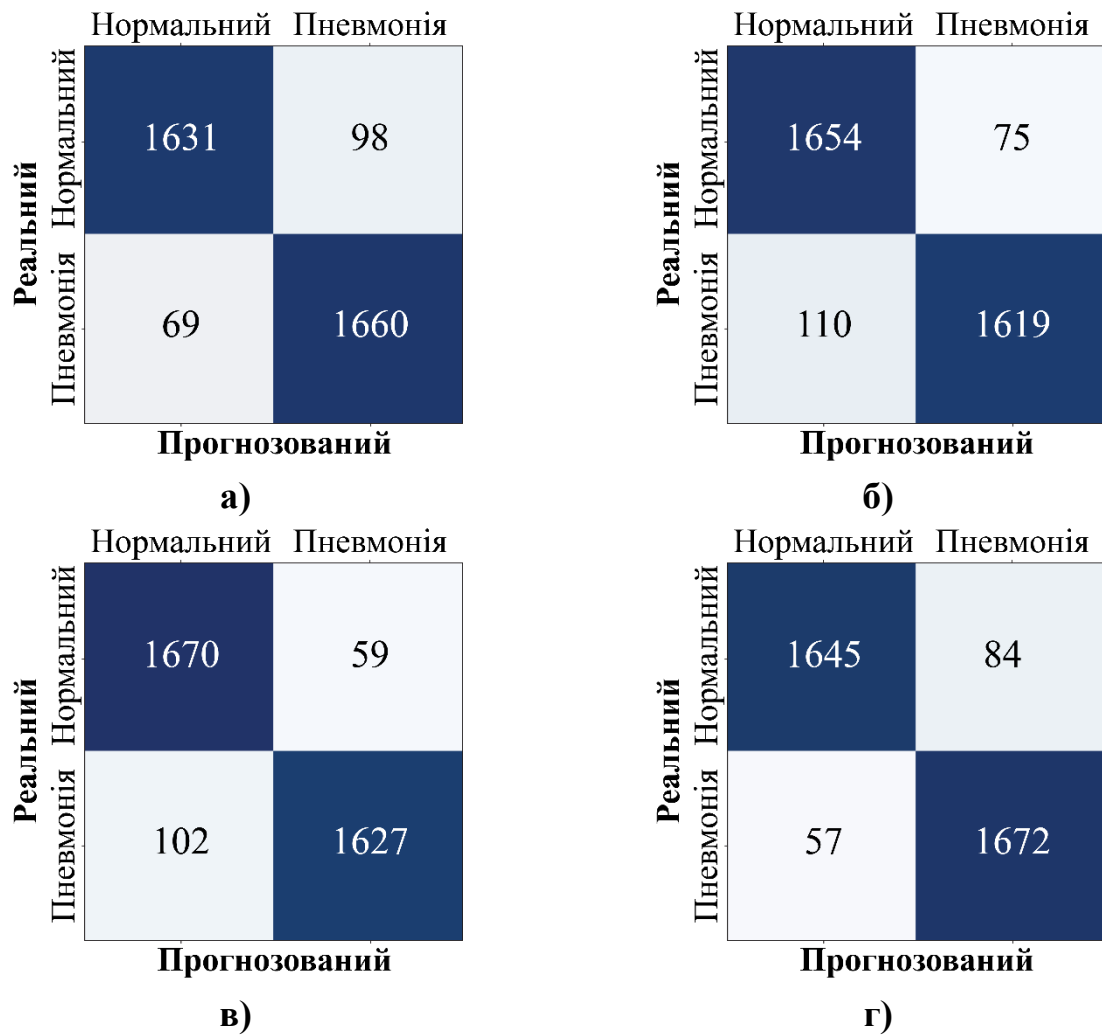


Рис. В.2 – Матриці невідповідностей за набором даних тестування CheXpert_small: а) MobileNet; б) NSGANetV1; в) MUXNet-m; г) Запропонована архітектура




Рис. В.3 – Матриці невідповідностей за набором даних тестування PadChest_small: а) PCA; б) Wavelet; в) CheXNet; г) VGG; д) Inception; е) ResNet

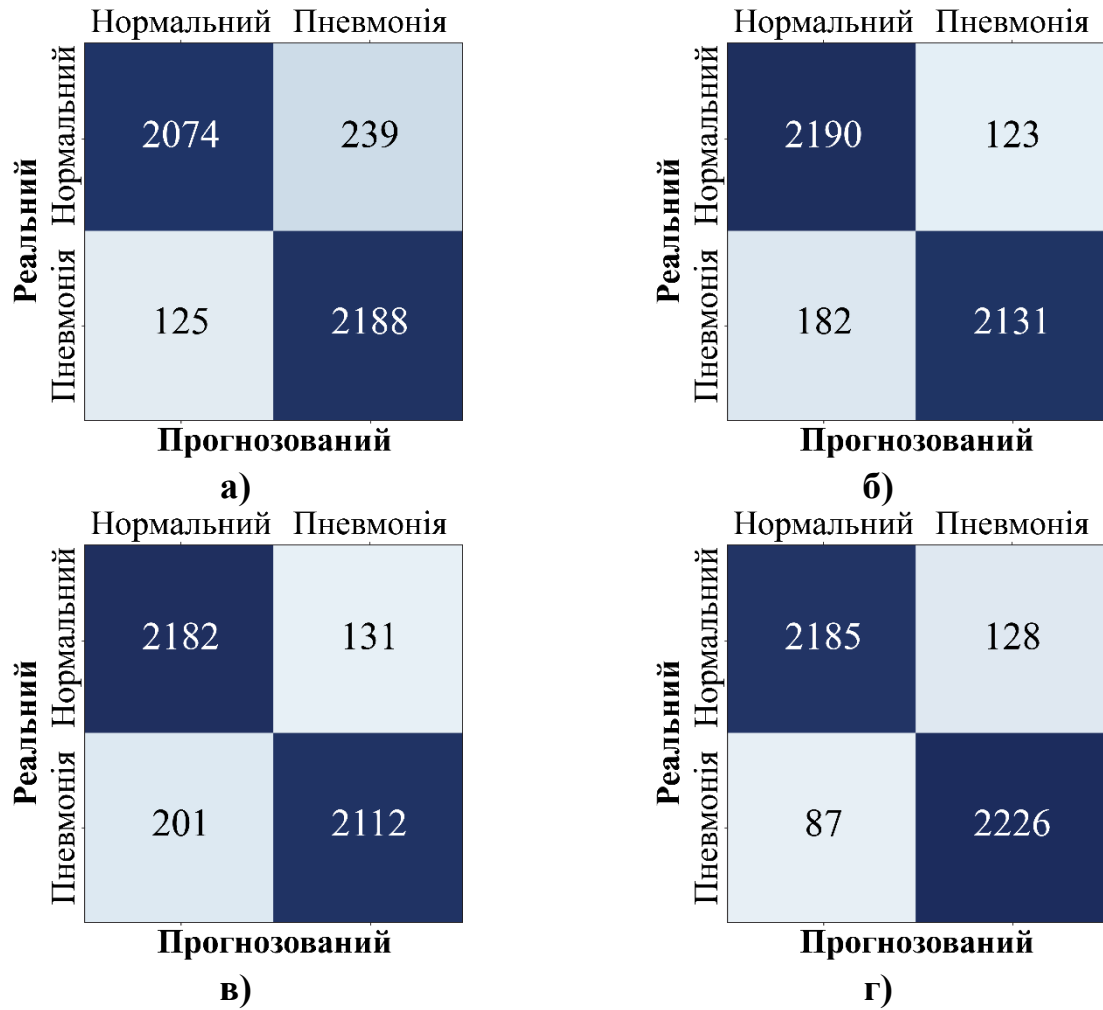


Рис. В.4 – Матриці невідповідностей за набором даних тестування PadChest_small: а) MobileNet; б) NSGANetV1; в) MUXNet-m; г) Запропонована архітектура