

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Кваліфікаційна наукова
праця на правах рукопису

Бабенко Віталій Олегович
(прізвище, ім'я, по батькові)

УДК 004.89:616-073.75
(індекс)

ДИСЕРТАЦІЯ

Технологія ієрархічної класифікації в задачах діагностики патологій за медичними
зображеннями різних модальностей
(назва дисертації)

122 – Комп'ютерні науки
(шифр і назва спеціальності)

12 – Інформаційні технології
(галузь знань)

Подається на здобуття наукового ступеня доктора філософії

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

В.О. Бабенко
(підпис) (ініціали та прізвище здобувача)

Науковий керівник Настенко Євген Арнольдович, д.б.н., к.т.н., проф.
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

АНОТАЦІЯ

Бабенко В.О. Технологія ієрархічної класифікації в задачах діагностики патологій за медичними зображеннями різних модальностей. – Кваліфікаційна наукова праця на правах рукопису.

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

Дисертаційна робота складається зі вступу, чотирьох розділів, висновків, списку використаних джерел і додатків, має загальний обсяг 155 сторінок. У роботі наведено 18 рисунків, 25 таблиць. Список використаних джерел налічує 117 найменувань, з яких 16 – кирилицею та 101 – латиницею. Додаток А містить перелік публікацій та дані про апробацію результатів дисертації на 3 сторінках, а в додатку Б подано відомості про акти впровадження на 5 сторінках.

Об'єкт дослідження. Аналіз діагностичних зображень.

Ціль роботи. Вдосконалення методів класифікації для підвищення точності виявлення патологій за цифровими зображеннями.

Методи дослідження. У рамках дослідження використано методи гістограмної обробки, просторової фільтрації, сегментації згортковими нейронними мережами, текстурного аналізу (зокрема, статистики першого порядку, GLCM, GLDS, GLRLM, NGTDM, SFM, метод енергії текстури Лоу, фрактальний аналіз, LBP, ознаки на основі гістограм, багаторегіональних гістограм, вейвлет-перетворень та згорткових нейронних мереж), кореляційний аналіз, а також ансамблеві підходи машинного навчання (випадковий ліс, XGBoost, LightGBM). Запропоновано метод випадкового лісу дерев оптимальної складності (ВЛДОС), що поєднує принципи МГУА, генетичних алгоритмів і методу аналізу ієрархій. Для побудови моделей застосовувалася технологія ієрархічної класифікації, а оцінювання їхньої

якості здійснювалося на основі метрик правильності, чутливості, специфічності, точності та F-міри. Обчислення проводилися на персональному комп'ютері з процесором Intel Core i5-9300H, 16 ГБ ОЗП, SSD на 512 ГБ і графічним процесором NVIDIA GeForce GTX 1660 Ti (6 ГБ). Використовувалося програмне забезпечення на мові Python.

Результати та їх новизна. Розроблено нову технологію ієрархічної класифікації для аналізу цифрових зображень, що базується на ансамблевих методах машинного навчання, розширеному наборі текстурних ознак та методі ВЛДОС. Запропоновано модифікацію методу випадкового лісу (ВЛДОС), яка інтегрує принципи МГУА, генетичних алгоритмів та методу аналізу ієрархій. Уперше для стадіювання фіброзу печінки (ультразвукові знімки) та ідентифікації COVID-асоційованих легеневих патологій (зображення комп'ютерної томографії) застосовано розширений набір методів текстурного аналізу. Удосконалено методику кореляційного відбору ознак у мультикласових задачах.

Основні характеристики та показники. Розроблена технологія забезпечує підвищення точності класифікації порівняно з традиційними методами. Для задачі стадіювання фіброзу печінки досягнуто правильності 67% (95% довірчий інтервал за методом бутстрепу: [0.58; 0.76]) та F-міри 0.68 на екзанаційній вибірці, для задачі ідентифікації COVID-асоційованих патологій легень – 84% (95% довірчий інтервал: [0.75; 0.92]) та 0.84 відповідно. При мажоритарному голосуванні на рівні пацієнтів точність зросла до 75% (фіброз печінки) й 89% (патології легень) на екзанаційній вибірці, а також до 95% і 94% відповідно на повній когорті пацієнтів.

Впровадження. Результати роботи були впроваджені в ДУ «Інститут ядерної медицини та променевої діагностики НАМН України» (акт впровадження від «3» листопада 2022 року), ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України» (акт впровадження від «13» червня 2024 року), ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф.Г. Яновського НАМН

України» (акт впровадження від «26» грудня 2024 року) та Інститут інформаційних технологій та систем НАН України (акт впровадження від «10 січня 2025 року).

Зв'язок з іншими роботами. Робота виконана виконано в межах науково-дослідних проєктів кафедри біомедичної кібернетики КПІ ім. Ігоря Сікорського за темами № 0117U006934 «Методи та моделі ідентифікації станів біологічних об'єктів» і № 0123U100866 «Методи та моделі ідентифікації станів об'єктів в задачах прийняття медичних рішень».

Рекомендації щодо використання результатів. Рекомендовано застосовувати запропоновану технологію для стадіювання фіброзу печінки на основі ультразвукових зображень та ідентифікації COVID-асоційованих легеневих патологій за даними комп'ютерної томографії у клінічній практиці.

Сфера застосування. Медична діагностика, системи підтримки прийняття рішень, телемедицина.

Економічна ефективність. Впровадження розробленого підходу здатне зменшити потребу в інвазивних методах обстеження (біопсія), скоротити час обробки зображень і підвищити точність діагностики, що може позитивно вплинути на загальні витрати на лікування й покращити результати терапії пацієнтів.

Значимість роботи. Створена технологія становить суттєвий внесок у розвиток методів аналізу медичних зображень, сприяючи підвищенню ефективності діагностики та моніторингу захворювань. Робота має наукову новизну й практичну цінність.

Висновки та пропозиції. Запропонована технологія ієрархічної класифікації на базі методу ВЛДОС і розширеного набору методів текстурного аналізу є ефективним інструментом обробки медичних зображень. Подальші дослідження доцільно спрямувати на вдосконалення методів групування класів, оптимізацію гіперпараметрів, розширення сфери застосування, автоматизацію процесу прийняття рішень, а також організацію

масштабних клінічних випробувань для підтвердження ефективності та безпеки впровадження у клінічну практику. Особлива увага має приділятися етичним аспектам і прозорості алгоритмів машинного навчання в медицині.

Ключові слова: ансамблеві методи, валідація прогностичних моделей, генетичний алгоритм, дерево прийняття рішень, згорткові нейронні мережі, ідентифікація, COVID-19, метод групового урахування аргументів, машинне навчання, надійність, прогнозування, процедура обробки зображень, прийняття рішень, текстурний аналіз, фіброз печінки.

ABSTRACT

Babenko V.O. Technology of Hierarchical Classification in the Diagnosis of Pathologies from Medical Images of Various Modalities. – A qualification research work presented as a manuscript.

Dissertation for the degree of Doctor of Philosophy in Specialty 122 – “Computer Sciences”. – National Technical University of Ukraine “Igor Sikorsky Kyiv Polytechnic Institute,” Kyiv, 2025.

The dissertation consists of an introduction, four chapters, conclusions, a list of references, and appendices, totaling 155 pages. It contains 18 figures and 25 tables. The list of references includes 117 sources, of which 16 are in Cyrillic and 101 in Latin script. Appendix A (3 pages) provides a list of publications and information on the approbation of the dissertation results; Appendix B (5 pages) contains information on implementation statements.

Object of the study. Analysis of diagnostic images.

Aim of the work. To enhance classification methods for improved accuracy in pathology detection using digital images.

Methods of research. The study employed histogram processing, spatial filtering, segmentation with convolutional neural networks, texture analysis (first-order statistics, GLCM, GLDS, GLRLM, NGTDM, SFM, Lowe’s texture energy, fractal analysis, LBP, histogram-based features, multi-region histograms, wavelet transforms, and convolutional neural networks), correlation analysis, and ensemble machine learning methods (Random Forest, XGBoost, LightGBM). A Random Forest of optimal complexity trees (RFOCT) was proposed, integrating the principles of GMDH, genetic algorithms, and the Analytic Hierarchy Process. Hierarchical classification technology was employed to build models, and their quality was evaluated using accuracy, sensitivity, specificity, precision, and F-measure. Calculations were carried out on a PC with an Intel Core i5-9300H CPU, 16 GB of RAM, a 512 GB SSD, and an NVIDIA GeForce GTX 1660 Ti (6 GB) GPU, using Python software.

Results and novelty. A new hierarchical classification technology was developed for digital image analysis, based on ensemble machine learning methods, an extended set of texture features, and the RFOCT method. A modified Random Forest approach (RFOCT) was introduced, incorporating the principles of GMDH, genetic algorithms, and the Analytic Hierarchy Process. For the first time, an extended set of texture-analysis methods was applied to liver fibrosis staging (ultrasound images) and the identification of COVID-associated lung pathologies (CT images). A correlation-based feature selection technique for multiclass problems was improved.

Main characteristics and indicators. The proposed technology increases classification accuracy compared to traditional methods. In the liver fibrosis staging task, accuracy reached 67% (95% bootstrap CI: [0.58; 0.76]) and an F-measure of 0.68 on the test sample. In identifying COVID-associated lung pathologies, accuracy reached 84% (95% CI: [0.75; 0.92]) with an F-measure of 0.84. Majority voting at the patient level increased accuracy to 75% (liver fibrosis) and 89% (lung pathologies) on the test sample, and up to 95% and 94% respectively on the full patient cohort.

Implementation. The research findings have been implemented at the following institutions: State Institution “Institute of Nuclear Medicine and Radiation Diagnostics of the National Academy of Medical Sciences of Ukraine” (implementation certificate dated November 3, 2022), State Institution “O.M. Lukyanova Institute of Pediatrics, Obstetrics and Gynecology of the National Academy of Medical Sciences of Ukraine” (implementation certificate dated June 13, 2024), State Institution “F.G. Yanovsky National Scientific Center of Phthisiology, Pulmonology and Allergology of the National Academy of Medical Sciences of Ukraine” (implementation certificate dated December 26, 2024), and Institute of Information Technologies and Systems of National Academy of Sciences of Ukraine (implementation certificate dated January 10, 2025).

Relation to other works. This research was performed within the scientific projects of the Department of Biomedical Cybernetics at Igor Sikorsky Kyiv

Polytechnic Institute under topics No. 0117U006934 “Methods and Models for Identifying the States of Biological Objects” and No. 0123U100866 “Methods and Models for Identifying Object States in Medical Decision-Making Tasks.”

Recommendations for using the results. It is recommended to apply the proposed technology to stage liver fibrosis based on ultrasound images and to identify COVID-associated lung pathologies from CT data in clinical practice.

Scope of application. Medical diagnostics, decision support systems, telemedicine.

Economic efficiency. Implementation of the proposed approach can reduce the need for invasive examination methods (such as biopsies), shorten image processing time, and improve diagnostic accuracy. This can lower overall treatment costs and enhance patient therapy outcomes.

Significance of the work. The developed technology makes a substantial contribution to advancing medical image analysis methods, helping improve the effectiveness of disease diagnosis and monitoring. The research has scientific novelty and practical value.

Conclusions and proposals. The proposed hierarchical classification technology, based on the RFOCT method and an extended set of texture-analysis techniques, is an effective tool for medical image processing. Future studies should focus on refining class-grouping methods, optimizing hyperparameters, expanding the scope of application, automating decision-making processes, and conducting large-scale clinical trials to confirm clinical effectiveness and safety. Special attention must be paid to ethical considerations and algorithmic transparency in medical machine learning.

Keywords: ensemble methods, validation of prognostic models, genetic algorithm, decision tree, convolutional neural networks, identification, COVID-19, GMDH, machine learning, reliability, prediction, image processing procedure, decision-making, texture analysis, liver fibrosis.

ОПУБЛІКОВАНІ РОБОТИ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЙНОЇ РОБОТИ

– Перелік публікацій:

1. Personalized Clinical Treatment Selection Using Genetic Algorithm and Analytic Hierarchy Process / [O. Nosovets, **V. Babenko**, I. Davydovych et al.]. // Advances in Science, Technology and Engineering Systems Journal. – 2021. – Vol. 6, No. 4. – pp. 406–413. ISSN: 24156698. DOI: [10.25046/aj060446](https://doi.org/10.25046/aj060446) [80]
2. Порівняльний аналіз алгоритмів класифікації при аналізі медичних зображень за відеоданими спекл-трекінг ехокардіографії / [О. Петруніна, Д. Шевага, **В. Бабенко** та ін.]. // Innovative Biosystems and Bioengineering. – 2021. – Том 5, № 3. – С. 153–166. ISSN: 2616–177X. DOI: [10.20535/ibb.2021.5.3.234990](https://doi.org/10.20535/ibb.2021.5.3.234990) [15]
3. Добровська Л. Комбінація локальної порогової бінаризації та машинного навчання для класифікації пухлин молочної залози / Л. Добровська, **В. Бабенко**, А. Іванченко. // Біомедична інженерія і технологія. – 2022. – № 8. – С. 40–47. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2022.8.267793](https://doi.org/10.20535/2617-8974.2022.8.267793) [7]
4. Classification of Pathologies on Medical Images Using the Algorithm of Random Forest of Optimal-Complexity Trees / [**V. Babenko**, I. Nastenka, V. Pavlov et al.]. // Cybernetics and Systems Analysis. – 2023. – Vol. 59, No. 2. – pp. 346–358. ISSN: 15738337, 10600396. DOI: [10.1007/s10559-023-00569-z](https://doi.org/10.1007/s10559-023-00569-z) [18]
5. Використання глибоких нейронних мереж для порівняльного аналізу норми, пневмонії і COVID-19 / [Р. Юхимюк, М. Шкепаст, Є. Настенко, М. Лінник, І. Давидович, **В. Бабенко**]. // Біомедична інженерія і технологія. – 2023. – № 12. – С. 56–64. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2023.12.292729](https://doi.org/10.20535/2617-8974.2023.12.292729) [16]
6. Cardiomyopathy Prediction in Patients with Permanent Ventricular Pacing Using Machine Learning Methods / [E. Perepeka, V. Lazoryshynets, **V. Babenko** et al.]. // System Research and Information Technologies. – 2024. – No.

1. – pp. 33–41. ISSN: 16816048, 23088893. DOI: [10.20535/SRIT.2308-8893.2024.1.03](https://doi.org/10.20535/SRIT.2308-8893.2024.1.03) [85]

7. Давидович І. Методології аналізу зображень для діагностичних застосувань (огляд) / І. Давидович, **В. Бабенко**. // Біомедична інженерія і технологія. – 2024. – № 14. – С. 54–63. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2024.14.302135](https://doi.org/10.20535/2617-8974.2024.14.302135) [6]

8. Ієрархічний алгоритм мультикласифікації стадій фіброзу печінки з інтегрованим аналізом областей інтересу / [**В. Бабенко**, Є. Настенко, В. Солодущенко та ін.]. // Біомедична інженерія і технологія. – 2024. – № 14. – С. 63–73. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2024.14.301108](https://doi.org/10.20535/2617-8974.2024.14.301108) [3]

9. Розробка програм на основі штучного інтелекту для діагностики міокардиту при COVID-19 за даними комп'ютерної томографії грудної клітки / [Є. Настенко, М. Гончарук, **В. Бабенко** та ін.]. // Український журнал серцево-судинної хірургії. – 2024. – Том 32, № 3. – С. 58–65. ISSN: 26645963, 26645971. DOI: [10.30702/ujcvs/24.32\(03\)/NH052-5865](https://doi.org/10.30702/ujcvs/24.32(03)/NH052-5865) [12]

10. Ефективність алгоритмів машинного навчання для класифікації змін структури легень у постковідних та гострих стадіях COVID-19 / В. Лутченко, **В. Бабенко**, Є. Настенко, М. Линник. // Біомедична інженерія і технологія. – 2024. – №15. – С. 27–35. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/.2024.15.306763](https://doi.org/10.20535/.2024.15.306763) [8]

– Апробація матеріалів дисертації:

1. Розпізнавання медичних зображень алгоритмом генетично-індуктивного лісу / **В. Бабенко**, Є. Настенко, В. Павлов, О. Носовець. // Збірник наукових праць IV міжнародної науково-практичної конференції «Інформаційні системи та технології в медицині» (ICM-2021), м. Харків, 25–26 листопада 2021 року. – Національний аерокосмічний університет ім. М. Є. Жуковського «Харківський авіаційний інститут», 2021. – С. 71–73 [2]

2. **Babenko V.** Improved Random Forest Algorithm in the Task of Liver Pathology Classification by Medical Images / **V. Babenko**, I. Nastenko, V. Pavlov.

// Сучасний стан та перспективи біомедичної інженерії: матеріали Міжнародної науково-практичної конференції, присвячена 20-річному ювілею Факультету біомедичної інженерії КПІ ім. Ігоря Сікорського, м. Київ, 15–16 грудня 2022 року. – Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», 2022. – pp. 18–18. DOI: [10.20535/biomedconf.2022.15122022](https://doi.org/10.20535/biomedconf.2022.15122022) [19]

3. Inferring Cognitive Load Level from Physiological and Personality Traits / [O. Shaposhnyk, S. Yanushkevich, **V. Babenko** et al.]. // Proceedings of The International Conference on Information and Digital Technologies, Zilina, Slovakia, 20-22 June 2023. – pp. 233–242. ISSN: 2575–677X, 2575–6753. DOI: [10.1109/IDT59031.2023.10194430](https://doi.org/10.1109/IDT59031.2023.10194430) [93]

4. Unraveling Body Vitals as Traumatic Event-Caused Stress Indicators / [D. Zahorska, **V. Babenko**, M. Chernykh et al.]. // IEEE Symposium Series on Computational Intelligence (SSCI), Mexico City, Mexico, 5-8 December 2023. – pp. 1656–1661. ISSN: 2472–8322, 2770–0097. DOI: [10.1109/SSCI52147.2023.10372048](https://doi.org/10.1109/SSCI52147.2023.10372048) [116]

– **Наукові праці, які додатково відображають наукові результати дисертації:**

1. Аналіз ультразвукових зображень хронічних дифузних захворювань печінки із застосуванням текстурних параметрів градацій сірого / [Є. Настенко, І. Дикан, В. Павлов, Б. Тарасюк, **В. Babenko**, В. Круглий, В. Солодущенко, М. Гончарук, І. Андрущенко, М. Гупало, О. Авер'янова]. // Radiation Diagnostics, Radiation Therapy. – 2023. – Том 13, № 3. – С. 7–20. DOI: [10.37336/2707-0700-2022-3-1](https://doi.org/10.37336/2707-0700-2022-3-1) [14]

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ ВИМІРЮВАННЯ, СКОРОЧЕНЬ	15
ВСТУП.....	16
РОЗДІЛ 1 ОГЛЯД МЕТОДІВ ЦИФРОВОЇ ОБРОБКИ ТА АНАЛІЗУ ЗОБРАЖЕНЬ	24
1.1 Властивості цифрових зображень	24
1.2 Текстурний аналіз цифрових зображень	27
1.2.1 Синергія з ансамблевим навчанням.....	30
1.2.2 Синергія з глибоким навчанням	32
1.3 Задачі класифікації зображень з більше ніж двома класами.....	34
1.4 Обмеження існуючих методів обробки та аналізу зображень	35
1.5 Формулювання методики дослідження	40
Висновки до розділу 1	41
РОЗДІЛ 2 ПОСЛІДОВНІСТЬ ФОРМУВАННЯ МНОЖИНИ ІНФОРМАТИВНИХ ОЗНАК ЦИФРОВИХ ЗОБРАЖЕНЬ	43
2.1 Гістограмна обробка зображень	43
2.1.1 Нормалізація інтенсивності пікселів.....	44
2.1.2 Еквалізація гістограми.....	45
2.1.3 Диференціація пікселів зображення.....	45
2.2 Конструювання дескрипторів зображення.....	47
2.2.1 Текстурні ознаки	48
2.2.2 Ознаки на основі гістограм	65
2.2.3 Ознаки на основі багаторегіональних гістограм.....	65
2.2.4 Багатомасштабні ознаки	65
2.2.5 Ознаки на основі згорткових нейронних мереж.....	67
2.3 Селекція найбільш інформативних ознак.....	68
Висновки до розділу 2	69

РОЗДІЛ 3 РОЗРОБЛЕННЯ МЕТОДИК ДЛЯ КЛАСИФІКАЦІЇ ЦИФРОВИХ ЗОБРАЖЕНЬ	71
3.1 Розроблення модифікованої версії методу випадкового лісу	72
3.1.1 Удосконалення дерева прийняття рішень	73
3.1.2 Оптимізація набору ознак дерева генетичним алгоритмом	75
3.1.3 Використання методу аналізу ієрархій для голосування.....	79
3.1.4 Порівняння з аналогічними методами ансамблевого навчання	81
3.2 Розроблення технології ієрархічної класифікації	85
3.2.1 Етап 1 – побудова множини групових класифікаторів	86
3.2.2 Етап 2 – мультикласифікація на рівні зразків	87
3.2.3 Етап 3 – мультикласифікація на рівні об'єктів.....	88
3.2.4 Порівняння з традиційними методами мультикласифікації.....	89
Висновки до розділу 3	90
РОЗДІЛ 4 ЗАСТОСУВАННЯ РОЗРОБЛЕНОЇ ТЕХНОЛОГІЇ АНАЛІЗУ ЦИФРОВИХ ЗОБРАЖЕНЬ В ПРИКЛАДНИХ ЗАДАЧАХ.....	92
4.1 Умови проведення експериментальних досліджень	92
4.1.1 Розбиття даних перед моделюванням.....	93
4.1.2 Побудова моделі прогнозування.....	94
4.1.3 Оцінка результатів моделювання.....	95
4.2 Стадіювання фіброзу печінки за ультразвуковими обстеженнями	98
4.2.1 Дані знімків ультразвукового обстеження печінки	98
4.2.2 Етап 1 – групова класифікація стадій фіброзу.....	104
4.2.3 Етап 2 – мультикласифікація стадій фіброзу за зображеннями	107
4.2.4 Етап 3 – мультикласифікація стадій фіброзу за пацієнтами	109
4.3 Ідентифікація COVID-асоційованих патологій легень за комп'ютерною томографією	110
4.3.1 Дані зрізів комп'ютерної томографії легень.....	111
4.3.2 Етап 1 – групова класифікація станів легень.....	118
4.3.3 Етап 2 – мультикласифікація станів легень за зображеннями ...	121
4.3.4 Етап 3 – мультикласифікація станів легень за пацієнтами	123

4.4 Практичні рекомендації щодо застосування розробленої технології аналізу цифрових зображень у медичній практиці	124
Висновки до розділу 4	128
ЗАГАЛЬНІ ВИСНОВКИ.....	130
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	133
ДОДАТОК А СПИСОК ПУБЛІКАЦІЙ ТА ВІДОМОСТІ ПРО АПРОБАЦІЮ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЇ	148
ДОДАТОК Б АКТИ ВПРОВАДЖЕННЯ.....	151

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ ВИМІРЮВАННЯ, СКОРОЧЕНЬ

БМК	Біомедична кібернетика
ВЛДОС	Випадковий ліс дерев оптимальної складності
ДУ	Державна установа
ККМ	Коефіцієнт кореляції Меттьюза
КТ	Комп'ютерна томографія
КПІ	Київський політехнічний інститут
МГУА	Метод групового урахування аргументів
НАМН	Національна академія медичних наук
ОІ	Область інтересу
СЗЛ	Синдром зникаючої легені
УЗО	Ультразвукове обстеження
ШІ	Штучний інтелект
ADASYN	Adaptive synthetic sampling
BMP	Bitmap image file
COVID-19	Coronavirus disease 2019
DICOM	Digital imaging and communications in medicine
DWT	Discrete wavelets transform
FDTA	Fractal dimension texture analysis
FOS	First order statistics
FPS	Fourier power spectrum
GLCM	Gray-level co-occurrence matrix
GLDS	Gray level difference statistics
GLRLM	Gray-level run length matrix
HU	Hounsfield units
JPEG	Joint photographic experts' group
LBP	Local binary pattern
LTE	Law's texture energy
NGTDM	Neighborhood gray tone difference matrix
PNG	Portable network graphics
SFM	Statistical feature matrix
SWT	Stationary wavelets transform
TIFF	Tagged image file format

ВСТУП

Обґрунтування вибору теми дослідження.

У сучасних умовах прискореної цифровізації завдання аналізу цифрових зображень набувають пріоритетного значення в галузі комп'ютерних наук, що зумовлює необхідність розроблення й удосконалення методів штучного інтелекту (ШІ) та машинного навчання для вирішення складних завдань класифікації й прогнозування. Особливої актуальності набуває підвищення точності алгоритмів обробки медичних даних, для яких характерні значна варіабельність, обмежений обсяг анотованих вибірок, наявність шуму й артефактів, а також дисбаланс класів [30, 35]. Існуючі методи машинного навчання, зокрема ансамблеві (наприклад, випадковий ліс), не завжди достатньо ефективні для мультикласових задач у разі суттєвої міжкласової схожості [60] та наявності обмежених обчислювальних ресурсів. Серед прикладів подібних сценаріїв – стадіювання фіброзу печінки на основі ультразвукових зображень [36] та ідентифікація COVID-асоційованих патологій за даними комп'ютерної томографії (КТ) [99, 112], які потребують розроблення нових методів формування більш інформативних, артефакт-інваріантних ознак та алгоритмів, здатних до узагальнення на обмежених і незбалансованих вибірках [101].

Метою цієї дисертаційної роботи є подолання згаданих проблем шляхом розроблення й валідації універсальної технології аналізу цифрових зображень, що передбачає поєднання нових методів формування інформативних ознак на основі текстурного аналізу [39, 55] з технологією ієрархічної класифікації як перспективним підходом до мультикласових завдань [68]. Основу запропонованої технології становить модифікований алгоритм «випадковий ліс дерев оптимальної складності» (ВЛДОС), який інтегрує принципи методу групового урахування аргументів (МГУА) [17] для побудови дерев оптимальної складності, генетичні алгоритми [53] для оптимізації наборів ознак і метод аналізу ієрархій Сааті [86] для зваженого

голосування дерев. Така комбінація підвищує точність, стійкість і узагальнюючу здатність моделей машинного навчання під час роботи з високо варіабельними та потенційно незбалансованими даними медичних зображень. Запропоновані рішення розширюють можливості машинного навчання, комп'ютерного зору, штучного інтелекту й методів оптимізації та сприяють удосконаленню процесів аналізу медичних зображень і підтримки діагностичних рішень. Досягнення поставленої мети підвищить ефективність медичної діагностики й оптимізує процес прийняття рішень на основі аналізу зображень.

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

Дослідження виконано в межах двох науково-дослідних проєктів кафедри біомедичної кібернетики:

1) НДР д/р № 0117U006934 «Методи та моделі ідентифікації станів біологічних об'єктів» (zareєстровано 22 листопада 2017 року, завершено 16 жовтня 2022 року) [1].

2) НДР д/р № 0123U100866 «Методи та моделі ідентифікації станів об'єктів в задачах прийняття медичних рішень» (zareєстровано 06 лютого 2023 року) [11].

Об'єкт дослідження.

Аналіз діагностичних зображень.

Предмет дослідження.

Методи та моделі машинного навчання для обробки й аналізу цифрових зображень.

Мета дослідження.

Вдосконалення методів класифікації для підвищення точності виявлення патологій за цифровими зображеннями.

Гіпотеза дослідження.

Застосування технології ієрархічної класифікації, що базується на ансамблевих моделях (зокрема, модифікованому методі випадкового лісу ВЛДОС) і доповнена методами текстурного аналізу для формування

інформативних ознак, забезпечить вищу точність та ефективність аналізу цифрових зображень порівняно з традиційними методами.

Завдання дослідження.

Відповідно до сформульованої мети були визначені такі задачі:

1. Виявити невирішені або недостатньо опрацьовані проблеми в галузі цифрової обробки й аналізу зображень.
2. Розробити послідовність формування множини інформативних ознак із зображень методами текстурного аналізу.
3. Удосконалити метод випадкового лісу з метою підвищення точності прогнозування.
4. Розробити технологію ієрархічної класифікації для мультикласових задач.
5. Застосувати розроблену технологію аналізу цифрових зображень для стадіювання фіброзу печінки (ультразвукові знімки) та ідентифікації COVID-асоційованих патологій (КТ-зображення).
6. Визначити напрями подальших досліджень.

Методи дослідження

У дисертаційному дослідженні був застосований інтегративний підхід, що передбачає використання передових методів комп'ютерних наук для розв'язання завдань діагностики патологій за медичними зображеннями. Вибір таких методів зумовлений їхньою здатністю ефективно обробляти складні, гетерогенні дані та забезпечувати високу точність і надійність діагностичних висновків.

Для попереднього опрацювання зображень використовувалися методи гістограмної обробки, просторової фільтрації та сегментації. Гістограмна обробка охоплювала нормалізацію, еквалізацію та диференціацію гістограм, що дало змогу покращити контрастність зображень, вирівняти розподіл інтенсивностей та підсилити межі між різними структурами. Методи просторової фільтрації застосовувалися для зменшення шумів і артефактів. Для автоматичної сегментації областей інтересу (зокрема, легень на зрізах

КТ та специфічних ділянок на УЗД печінки) використано згорткову нейронну мережу U-Net.

Для вилучення інформативних ознак застосовано широкий спектр методів текстурного аналізу. Зокрема, використано статистику першого порядку, матриці суміжності рівнів сірого, статистику різниці рівнів сірого, матриці різниці відтінків сірого сусідства, статистичну матрицю ознак, метод енергії текстури Лоу, фрактальний аналіз, матриці довжин пробігів рівнів сірого, спектр потужності Фур'є, локальний бінарний шаблон, а також ознаки на основі гістограм, багаторегіональних гістограм, вейвлет-перетворень та згорткових нейронних мереж. Для відбору найбільш інформативних ознак застосовано кореляційний аналіз.

Моделі класифікації побудовано з використанням ансамблевих методів машинного навчання – алгоритму випадкового лісу, алгоритмів градієнтного бустингу XGBoost та LightGBM, а також оригінальної модифікації методу випадкового лісу (ВЛДОС), розробленої в межах цього дослідження. Метод ВЛДОС ґрунтується на поєднанні принципів МГУА, генетичних алгоритмів і методу аналізу ієрархій для побудови дерев оптимальної складності та підвищення точності класифікації.

У межах роботи не застосовувалися методи глибокого навчання (зокрема, згорткові нейронні мережі) для безпосередньої класифікації зображень. Таке рішення було зумовлене кількома чинниками: необхідністю значних обчислювальних ресурсів і великих обсягів розмічених даних, що не завжди доступні в медичній сфері; складністю інтерпретації результатів глибоких моделей, що є критичним у медичній діагностиці, де важлива прозорість рішень; а також акцентом на вилученні та аналізі текстурних ознак, які продемонстрували високу ефективність у розв'язуваних завданнях. Використання глибоких мереж для автоматичного вилучення ознак, хоч і є перспективним напрямом, не входило до цілей цієї роботи.

Також не застосовувалися інші методи машинного навчання, як-от метод опорних векторів або класичні дерева рішень, оскільки в попередніх

дослідженнях та в оригінальній роботі з технологією ієрархічної класифікації ансамблевих методи (передусім випадковий ліс) засвідчили вищу ефективність порівняно з цими підходами.

Для розв'язання завдань мультикласової класифікації впроваджено технологію ієрархічної класифікації, що передбачає групування класів і побудову багаторівневої системи класифікаторів.

Оцінювання ефективності запропонованої технології здійснювалося за допомогою поширених метрик класифікації: правильності, чутливості, специфічності, точності та F-міри. Ці показники дають змогу комплексно оцінити різні аспекти роботи моделей.

Статистичну значущість отриманих результатів оцінювали з використанням 95% довірчого інтервалу, розрахованого методом бутстрепу.

Наукова новизна отриманих результатів

1. Вперше запропоновано технологію класифікації патологій за множиною медичних зображень одного об'єкту дослідження, в якій для кожного зображення за вектором визначених ознак шляхом голосування деревами рішень обчислюється розподіл ймовірностей для бінарних комбінацій класів з подальшим визначенням за ансамблевими методами остаточної приналежності класу; за множиною всіх визначених класів діагностичних показників об'єкту відбувається остаточне визначення класу патології, що надає можливість діагностування за множиною медичних зображень та підвищує його точність по відношенню до класифікації за окремими знімками.

2. Вдосконалено метод машинного навчання «Random Forest» за рахунок: 1) побудови мінімально необхідної кількості дерев рішень, визначених на основі МГУА; 2) визначення на основі генетичних алгоритмів оптимального за критерієм кореляції Меттьюза набору ознак для кожного дерева; 3) визначення ваг дерев методом аналізу ієрархій Сааті, що дозволило підвищити точність класифікації за вектором визначених ознак.

Практичне значення отриманих результатів

Розроблена технологія ієрархічної класифікації на основі методу ВЛДОС і текстурного аналізу має суттєве практичне значення для підвищення ефективності та точності медичної діагностики, зокрема під час стадіювання фіброзу печінки та ідентифікації COVID-асоційованих патологій легень.

Результати роботи впроваджено в ДУ «Інститут ядерної медицини та променевої діагностики НАМН України» (акт впровадження від «3» листопада 2022 року на рис. Б.1) та ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України» (акт впровадження від «13» червня 2024 року на рис. Б.2); у цих установах технологія застосовується для вдосконалення діагностики фіброзу печінки за даними УЗО. Також результати роботи були впроваджені в ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф.Г. Яновського НАМН України» (акт впровадження від «26» грудня 2024 року на рис. Б.3-Б.4) та Інститут інформаційних технологій та систем НАН України (акт впровадження від «10» січня 2025 року на рис. Б.5), де технологія застосовується для вдосконалення ідентифікації COVID-асоційованих патологій за даними КТ. Відповідні акти впровадження наведені у Додатку Б.

Практична реалізація технології можлива за кількома напрямками. Для стадіювання фіброзу печінки вона може інтегруватися в клінічну практику як інструмент скринінгу й первинної діагностики, що зменшує потребу у проведенні інвазивних досліджень у пацієнтів із низьким ризиком. Алгоритми здатні об'єктивізувати оцінку текстурних характеристик і ймовірності різних стадій фіброзу, а також допомогти відстежувати динаміку захворювання та ефективність терапії. З огляду на неінвазивність методу, у певних сценаріях можливо знизити потребу в біопсії печінки.

В задачі ідентифікації COVID-асоційованих патологій технологія сприяє оперативному та точному виявленню різних форм перебігу хвороби

(гостра фаза, консолідація з подальшим розвитком СЗЛ, Long COVID) на основі КТ-зображень. Це дає змогу індивідуалізувати підхід до лікування, оптимізувати прогнозування та створити додаткове навантажувальне «фільтрування» для радіологів. Технологія також може застосовуватися для моніторингу пацієнтів у довгостроковій перспективі та може бути інтегрована в телемедичні платформи, що важливо для регіонів із обмеженими ресурсами.

Важливо враховувати, що точність класифікації початкових стадій фіброзу (F1, F2) нижча, ніж пізніх стадій, що потребує обережності при інтерпретації результатів. Крім того, надійність методу залежить від якості отримуваних зображень і рівня підготовки фахівців. Точність також знижується під час діагностики Long COVID унаслідок неоднозначності паттернів на КТ-зображеннях. Подальші клінічні дослідження за участю розширених і гетерогенних вибірок пацієнтів сприятимуть удосконаленню й широкому впровадженню технології в клінічну практику, а також дозволять розробити рекомендації щодо її інтеграції та навчання персоналу. Окремої уваги потребують етичні й правові аспекти використання ШІ в медицині.

Апробація матеріалів дисертації

Основні положення та результати роботи доповідалися й обговорювалися на таких науково-практичних заходах:

1. IV міжнародна науково-практична конференція «Інформаційні системи та технології в медицині» (ICM-2021), м. Харків, 25–26 листопада 2021 року, заочна форма участі [2]

2. Міжнародна науково-практична конференція «Сучасний стан та перспективи біомедичної інженерії», присвячена 20-річному ювілею Факультету біомедичної інженерії КПІ ім. Ігоря Сікорського, м. Київ, 15–16 грудня 2022 року, онлайн участь з доповіддю [19]

3. Міжнародна IEEE конференція з інформаційних та цифрових технологій, Жиліна, Словаччина, 20–22 червня 2023 року, заочна форма участі з публікацією в Scopus [93]

4. 9й Національний конгрес з міжнародною участю «Радіологія в Україні», Київ, Україна, 19–21 жовтня 2023 року, очна форма участі з доповіддю.

5. Міжнародна серія симпозіумів IEEE з обчислювального інтелекту (SSCI), Мехіко, Мексика, 5–8 грудня 2023 року, заочна форма участі з публікацією в Scopus [116]

6. Семінар з проблеми «Образний комп'ютер», м. Київ, 26 листопада 2024 року, очна форма участі з доповіддю.

Структура та обсяг дисертації

Дисертаційна робота побудована за класичною структурою, що включає: вступ, чотири розділи, висновки до кожного з них, загальні висновки, список використаних джерел та додатки. Загальний обсяг дисертації становить 155 сторінок машинописного тексту. Список використаних джерел налічує 117 найменувань, з яких 16 кирилицею та 101 латиницею. Робота містить 18 рисунків та 25 таблиць.

РОЗДІЛ 1

ОГЛЯД МЕТОДІВ ЦИФРОВОЇ ОБРОБКИ ТА АНАЛІЗУ ЗОБРАЖЕНЬ

Серед ключових завдань у сфері обробки та аналізу цифрових зображень виділяють підвищення якості [42] й деталізації зображень, зниження рівня шуму [83], виокремлення характерних ознак, розпізнавання об'єктів та їхню класифікацію, а також сегментацію на основі певних критеріїв (колір, текстура, інтенсивність) [74]. Існує широкий спектр методів і алгоритмів, які дають змогу автоматизувати відповідні процеси та забезпечувати високу точність отриманих результатів [45, 58].

Актуальність дослідження методів обробки зображень зумовлена як науковими, так і практичними передумовами. У галузі медичної діагностики, приміром, автоматизована попередня обробка та аналіз медичних знімків (зокрема, ультразвукового обстеження або комп'ютерної томографії) суттєво прискорюють і полегшують виявлення патологічних змін [66, 96].

У цьому розділі зосереджено увагу на властивостях цифрових зображень, а також на методах їхнього аналізу методами класифікації. Основна мета полягає у визначенні задач і проблем, які досі залишаються нерозв'язаними або недостатньо опрацьованими, що дасть змогу розробити власну методику дослідження в межах цієї роботи.

1.1 Властивості цифрових зображень

Зображення є масивом даних, сформованим унаслідок дискретизації (аналого-цифрового перетворення) оригінального об'єкта. Після кодування спеціальним алгоритмом і запису на носій цей масив стає окремим файлом.

Цифрове зображення постає у вигляді двовимірної матриці пікселів (елементарних точок), як це проілюстровано на рис. 1.1. Кожен піксель має певну інтенсивність або (у разі кольорового зображення) набір кольірних компонентів.




Рисунок 1.1 – Сірошкальне цифрове зображення та його представлення у вигляді двовимірної матриці пікселів

Дискретна природа зображень означає, що між пікселями відсутня додаткова інформація, а всі операції обробки здійснюються на рівні окремих точок [71]. Просторова роздільна здатність визначається кількістю пікселів уздовж кожного виміру (наприклад, 1920×1080); зі збільшенням кількості пікселів (за незмінних фізичних розмірів) підвищується роздільна здатність і деталізація. У реальних умовах, як-от при комп'ютерній томографії або формуванні супутникових знімків, роздільна здатність істотно впливає на здатність виявляти дрібні деталі [89].

Глибина кольору вказує, скільки біт виділено для кодування інтенсивності (або колірних компонентів) кожного пікселя. Наприклад, 8-бітове зображення у градаціях сірого може відтворити 256 відтінків, тоді як 24-бітне кольорове зображення (8 біт на канал RGB) має 16,7 млн відтінків. Збільшення глибини кольору забезпечує точніше відтворення плавних переходів, проте супроводжується більшим обсягом даних.

Одним із найпоширеніших колірних просторів є RGB, який використовується в моніторах та камерах. Водночас для аналізу або стиснення нерідко обирають інші колірні моделі, оскільки вони краще

відповідають особливостям людського сприйняття або дають змогу ефективніше виділяти об'єкти.

Динамічний діапазон відображає здатність зображення передавати інформацію від найтемніших до найсвітліших ділянок. Він залежить від сенсора (у разі фотокамери) чи розрядності пікселів (для сканованого зображення). Наприклад, у медичній візуалізації застосовується збільшена розрядність (12-біт, 16-біт) задля кращої деталізації в темних і світлих зонах.

Цифрові зображення можуть бути збережені у різних форматах, кожен із яких має власні алгоритми стиснення й можливості запису метаданих (роздільна здатність, колірний профіль тощо) [51, 102, 106]. До основних форматів належать:

- JPEG (JPG). Реалізує алгоритми стиснення з втратами, що суттєво зменшують обсяг файлу шляхом апроксимації колірних областей і зниження деталізації.

- PNG. Забезпечує стиснення без втрат, завдяки чому зберігає всі дані вихідного зображення. Підтримує глибину до 16 біт на канал і прозорість (альфа-канал).

- BMP (Bitmap). Зазвичай зберігає зображення без стиснення, що призводить до великих розмірів файлів і ускладнює обробку великих обсягів даних.

- TIFF (TIF). Підтримує як безвтратне, так і з втратами стиснення, що робить цей формат гнучким для зберігання зображень із високою роздільною здатністю. TIFF може містити до 32 біт на канал, забезпечуючи широкий діапазон колірних градацій.

- DICOM. Універсальний стандарт для зберігання та передачі медичних зображень [40]. Дозволяє зберігати як кольорові, так і чорно-білі зображення з глибиною до 16 біт та більше. Містить великий набір стандартизованих метаданих, що охоплюють не лише технічні параметри сканування, а й відомості про пацієнта, обладнання та специфіку процедури.

Завдяки цьому можливо точно відтворювати умови дослідження й забезпечувати сумісність даних. DICOM використовує растрове представлення зображень, що гарантує збереження інтенсивності сигналу кожного пікселя. Крім того, у ньому підтримується кілька алгоритмів стиснення, у тому числі JPEG 2000 (безвтратне стиснення, критичне для діагностичних знімків). Стиснення з втратами передбачене лише у виняткових випадках, оскільки воно може погіршувати якість і призводити до втрати важливих діагностичних деталей.

Будь-який пристрій, що формує зображення (камера, томограф тощо), може генерувати шум через різноманітні фізичні чинники (теплові, електронні). Крім того, під час стиснення або передавання даних виникають артефакти (наприклад, фрагментація блочних структур або «розмиття» контурів у JPEG) [52]. Характеристики шуму та його типи суттєво впливають на вибір методів подальшої обробки (зокрема, фільтрації чи підвищення різкості).

1.2 Текстурний аналіз цифрових зображень

Цифрові зображення можуть бути представлені у вигляді гістограм інтенсивностей, як це показано на рис. 1.2.




Рисунок 1.2 – Отримання гістограми градацій сірого

У цьому підході гістограма розглядається як емпірична функція розподілу ймовірності щільності для інтенсивностей пікселів у зображенні. Такий метод дає змогу виявляти загальні закономірності в розподілі інтенсивностей, що є визначальними для оцінки текстури та контрастності зображення, а також для формування діагностичних висновків. Це підкреслює потенціал застосування текстурного аналізу для кількісного опису подібних характеристик цифрових зображень.

Текстурний аналіз є комплексним методом обробки зображень, орієнтованим на дослідження структурних параметрів поверхонь чи матеріалів, зокрема їх однорідності, шорсткості, зернистості й регулярності. Цей підхід охоплює низку технік, серед яких виділяють аналіз статистичних розподілів інтенсивностей пікселів, спектральний аналіз, дослідження просторових взаємозв'язків між пікселями, а також фрактальний аналіз. Застосування текстурного аналізу робить можливим виявлення тонких візуальних відмінностей, які не завжди помітні під час стандартного візуального огляду. Сучасні дослідження свідчать про ефективність поєднання текстурного аналізу з іншими методами обробки зображень і алгоритмами машинного навчання для розв'язання широкого спектра завдань.

У медичній діагностиці та біомедичних дослідженнях текстурний аналіз залишається одним із ключових інструментів. Він активно використовується для виявлення й класифікації захворювань на основі даних медичних зображень (рентген, УЗД, КТ тощо). Оскільки зміни в текстурі тканин можуть бути ранніми ознаками патології, текстурний аналіз слугує чутливим методом для ранньої діагностики та моніторингу. Наприклад, у дослідженні [94] застосовано текстурний аналіз на базі глибокого навчання для автоматичної класифікації раку легень за КТ-зображеннями, що дало змогу досягти високої точності та запропонувало перспективне рішення для клінічної практики. Інше дослідження [27] продемонструвало ефективність текстурного аналізу у поєднанні з радіомікою для прогнозування відповіді на

хіміотерапію у хворих на рак прямої кишки, наголошуючи на його прогностичній цінності. Крім того, текстурний аналіз сприяє високоточній сегментації та оцінці тканин, що є важливим для кількісного аналізу органів і виявлення аномалій (наприклад, при сегментації уражень печінки на КТ-зображеннях [41]). У гістопатології методи текстурного аналізу, особливо в поєднанні з глибоким навчанням, застосовують для автоматизованого аналізу мікроскопічних зображень, підтримуючи діагностику раку та інших захворювань на клітинному рівні [46].

У галузі дистанційного зондування та геоінформаційних систем текстурний аналіз суттєво впливає на класифікацію земної поверхні за супутниковими та аерофотознімками. Текстура є одним із визначальних дескрипторів для розрізнення об'єктів зі схожими спектральними характеристиками, але різною структурою, як-от різні типи рослинності або міських забудов. У дослідженні [26] було застосовано текстурний аналіз на основі GLCM (матриць суміжності рівнів сірого) для класифікації типів землекористування за зображеннями Sentinel-2, продемонструвавши поєднання ефективності традиційних методів із сучасними даними дистанційного зондування. Текстурний аналіз також використовується для моніторингу стану довкілля, наприклад, з метою виявлення незаконних рубок лісу шляхом аналізу змін текстурних характеристик у часових рядах супутникових зображень [100]. У геологічних дослідженнях він дає змогу визначати та класифікувати геологічні формації, аналізуючи текстурні показники гірських порід на аерокосмічних знімках [48].

У промисловості та системах контролю якості текстурний аналіз зарекомендував себе як важливий інструмент для автоматичної дефектоскопії й оцінювання відповідності продукції стандартам. Зміни текстурних характеристик можуть свідчити про наявність дефектів, зокрема тріщин, подряпин або неоднорідностей. У дослідженні [104] було запропоновано систему автоматичного контролю якості поверхні керамічної плитки, яка базується на текстурному аналізі і виявляє різноманітні типи дефектів

безпосередньо в процесі виробництва. Текстурний аналіз також застосовують для класифікації матеріалів, наприклад, під час автоматичного сортування різних видів пластику за їхніми текстурними характеристиками для потреб переробки [76].

1.2.1 Синергія з ансамблевим навчанням

Упродовж останніх років значна увага дослідників була зосереджена на поєднанні текстурного аналізу цифрових зображень із методами ансамблевого навчання з метою підвищення точності й узагальнюючої здатності алгоритмів. Концепція ансамблевого навчання [91] передбачає використання кількох базових моделей (так званих «учнів») та подальшу інтеграцію їхніх прогнозів в єдиний результат. Такий підхід дає змогу сформулювати зведений прогноз, який у середньому характеризується вищою правильністю порівняно з окремими моделями, за умови відсутності корельованих помилок на цільових наборах даних.

На рис. 1.3 продемонстровано, що зі зростанням складності моделі її загальна похибка зменшується до певного мінімуму, після чого відбувається різке збільшення похибки, яке свідчить про ризик перенавчання [22].




Рисунок 1.3 – Компроміс між зміщенням та дисперсією [22]

Як показано на рис. 1.3, під час побудови моделей прогнозування виникає ключова проблема компромісу між зміщенням та дисперсією [22]. Вона полягає в тому, що зі збільшенням складності моделі зміщення зменшується й залишається стабільним, тоді як дисперсія, навпаки, зростає. Зміщення визначає відмінність між середнім (очікуваним) прогнозом і реальними значеннями, які модель має передбачити, тоді як дисперсія вказує на варіативність прогнозів для окремих точок даних. Отже, для покращення продуктивності моделі слід знаходити баланс між цими двома характеристиками, особливо зі збільшенням її складності.

У роботі [33] запропоновано підхід із використанням компонентних класифікаторів, що навчаються на різнорідних категоріях, для формування ефективнішої системи класифікації в задачах ідентифікації. Згодом у праці Шاپіра й Роберта [91] розглянуто можливість об'єднання слабких моделей навчання в одну високу точну ансамблеву модель.

Класичні методи текстурного аналізу мають тенденцію легко адаптуватися до сучасних обсягів інформації й високої роздільної здатності зображень, а також інтегруються з ансамблевими моделями. У дослідженні [35], де розглядалися автоматизовані підходи до класифікації гістопатологічних зображень, встановлено, що застосування ансамблю випадкових лісів та бустингу на основі текстурних дескрипторів підвищує специфічність виявлення мікроскопічних ознак пухлинних тканин.

У сфері дистанційного зондування також помітна активна експлуатація цього поєднання, коли текстурні ознаки аеро- та супутникових зображень інтегруються з ансамблевими методами для поліпшення розпізнавання рослинного покриву й аналізу змін ландшафтів. Згідно з результатами дослідження [21], ансамблева модель, яка поєднує градієнтний бустинг та випадкові ліси, виявилася ефективнішою в класифікації текстур лісових масивів порівняно з окремими методами. У промисловому середовищі, де системи контролю якості значною мірою залежать від аналізу зображень конвеєрних ліній, інтеграція текстурних дескрипторів з ансамблевими

методами дала змогу виявляти мікродефекти поверхні об'єктів із високою точністю, що сприяло зниженню виробничого браку [57].

Загалом, синергія текстурного аналізу та ансамблевого навчання продемонструвала перспективні результати, що підкреслює необхідність подальших досліджень у напрямі створення універсальних моделей, здатних ефективно поєднувати локальні й глобальні текстурні ознаки з різноманітними підходами багатомодельного навчання. Така інтеграція, ймовірно, стане потужним рушієм розвитку методів інтелектуального аналізу зображень у найближчі роки.

1.2.2 Синергія з глибоким навчанням

Глибоке навчання базується на багаторівневих штучних нейронних мережах, що здатні автоматично виявляти релевантні ознаки у вхідних даних без прямої участі людини. Для опрацювання цифрових зображень зазвичай застосовують згорткові нейронні мережі, які дають змогу суттєво зменшити кількість параметрів порівняно зі звичайними багат шаровими перцептронами [63]. Згорткові шари дають можливість ефективно навчатися виявляти найважливіші структури пікселів на різних рівнях глибини, що сприяє точнішому розпізнаванню візуальних об'єктів у складних сценах. Хоча алгоритми глибокого навчання вимагають масштабних наборів даних і значних обчислювальних ресурсів для досягнення високої точності, на практиці вони забезпечують побудову потужних моделей для аналізу й класифікації зображень, а також слугують основою для їх генерації та редагування.

Принципова різниця між глибоким навчанням і ансамблевим навчанням полягає у відмінних підходах до побудови моделей. У рамках глибокого навчання зазвичай використовується одна (хоча й багаторівнева) модель, здатна формувати багаторівневі представлення даних із високим рівнем узагальнення. Ансамблеве навчання, натомість, передбачає поєднання кількох окремих моделей, кожна з яких може бути відносно простою, проте їх об'єднаний прогноз часто виявляється точнішим і більш стійким до

перенавчання. У той час як ансамблеві методи, зокрема випадкові ліси чи градієнтний бустинг, зазвичай потребують меншого обсягу налаштувань гіперпараметрів, ніж глибокі нейронні мережі, вони поступаються останнім за здатністю до складного нелінійного узагальнення та роботи зі структурованими вхідними даними, такими як багатовимірні зображення або звукові сигнали [62].

У сучасних дослідженнях спостерігається зростання інтересу до поєднання методів текстурного аналізу цифрових зображень із глибокими нейронними мережами, що дає змогу суттєво підвищити точність класифікації та сегментації в різноманітних галузях. Аналіз засвідчує, що більшість підходів базується на вилученні високорівневих ознак за допомогою глибоких згорткових мереж, доповнених традиційними дескрипторами текстур, зокрема локальними патернами бінаризації та вейвлет перетвореннями. Така стратегія допомагає мінімізувати втрату детальної інформації про структуру об'єктів, що особливо важливо для медичної візуалізації та промислових систем моніторингу зображень.

У роботі [98] продемонстровано, що згорткова мережа, підсилена текстурними дескрипторами, підвищує точність класифікації патологічних змін у рентгенівських зображеннях на 15–20% порівняно з традиційними глибокими архітектурами. Автори [59] запропонували синергетичну модель, у якій попереднє фільтрування текстурних ознак покращило ефективність мережі ResNet при виявленні зношених дорожніх покриттів на аерофотознімках, що дозволило підвищити узагальнюючу здатність алгоритму до 93% на тестових вибірках.

Результати [37] свідчать, що поєднання статистичних дескрипторів Хараліка з глибоким підходом U-Net знижує кількість помилок сегментації тканин на зображеннях мозку приблизно на 12% порівняно з типовими глибокими моделями без використання текстурних індексів. У роботі [92] описано комбіновану стратегію, за якої попередньо обчислені текстурні вектори подаються до глибокої архітектури трансформера як додатковий

вхід. Такий метод дає змогу гнучко адаптувати модель для контролю якості друкованих плат у режимі реального часу, зменшуючи обчислювальне навантаження завдяки селективній увазі до ділянок із високою складністю текстури.

Поглиблений аналіз впливу різних методів текстурної квантизації на здатність глибоких мереж інтерпретувати дрібномасштабні деталі зображень, а також розробка універсальних модулів, які легко інтегруються у сучасні архітектури глибокого навчання, вважаються перспективними напрямками досліджень. Такий підхід відкриває додаткові можливості в медичних системах комп'ютерної діагностики, виявленні дефектів у галузі контролю якості та аналізі складних природних сцен, де необхідно враховувати водночас локальні й глобальні аспекти текстури.

1.3 Задачі класифікації зображень з більше ніж двома класами

Протягом останніх років спостерігається відчутний прогрес у застосуванні глибинних нейронних мереж для мультикласифікації цифрових зображень. Значною мірою це зумовлено розвитком архітектур згорткових мереж і впровадженням трансформерних моделей для задач комп'ютерного зору. У роботі [56] представлено вдосконалену модель на основі глибоких згорткових мереж, що оптимізує функцію втрат із використанням адаптивних методів регуляризації. Автори продемонстрували підвищення точності класифікації складних наборів зображень, які охоплюють різні категорії об'єктів, зокрема природні, технічні та медичні. Аналогічні підходи розвинуто й іншими дослідниками, що зосереджувалися на ефективності моделей і забезпеченні їх стійкості до перенавчання.

Паралельно активно розробляються трансформерні архітектури, спрямовані на аналіз зображень. Одним із ключових кроків стало застосування просторових «вікон» і механізмів самоуваги (англ. self-attention), як описано в роботі [70], де ієрархічні трансформери дають змогу

досягати високої точності на наборах даних ImageNet і COCO. Такий підхід забезпечує обробку зображень різної роздільності й складності сцени за мінімальних обчислювальних витрат без втрати якості.

Актуальні дослідження також демонструють інтеграцію глибоких мереж із блокчейн-технологіями для надійної передачі й зберігання даних у чутливих застосуваннях, зокрема в медичній сфері. У роботі [95] розглянуто модель, що поєднує механізми глибокого навчання для мультикласифікації зображень із розподіленою базою даних на блокчейні, тим самим гарантуючи захист цілісності та конфіденційності даних пацієнтів. Експерименти підтвердили, що гібридний підхід демонструє високі показники точності на медичних наборах зображень, зокрема при класифікації рентгенівських і КТ-знімків.

Окрема увага дослідників зосереджена на гнучкості моделей у реальних умовах, коли брак великої маркованої вибірки навчальних даних ускладнює процес тренування. У роботі [115] наголошено на важливості методів доменної адаптації та попередньо навчених мереж для вирішення задач мультикласифікації. У цьому контексті визначальними залишаються питання оптимальної ініціалізації ваг і добору архітектур, здатних ефективно охопити широкий спектр категорій за мінімальних витрат на перенавчання. Загалом наведені праці підтверджують, що сучасні глибокі та трансформерні моделі забезпечують високі показники класифікації складних наборів зображень, демонструючи належну узагальнюючу здатність і масштабованість для значної кількості класів.

1.4 Обмеження існуючих методів обробки та аналізу зображень

Традиційні методи обробки зображень, хоча й залишаються корисними в окремих випадках, виявляють обмежену здатність до узагальнення. Здебільшого вони розроблені для конкретних типів зображень або завдань і суттєво втрачають ефективність, коли застосовуються до інших даних [114].

Крім того, ці методи чутливі до шуму, змін освітлення, геометричних спотворень та інших варіацій, що часто трапляються у реальних умовах [67]. Значна їхня частина здатна описувати переважно загальні статистичні характеристики пікселів і не враховує складних просторових взаємозв'язків, які мають критичне значення для розрізнення текстурних особливостей. Для більшості класичних підходів потрібне трудомістке ручне налаштування, що потребує експертних знань та витрат часу. У випадку складних задач класифікації з високою внутрішньокласовою варіабельністю та міжкласовою схожістю такі підходи зазвичай виявляються недостатньо дієвими.

Методи машинного та глибокого навчання, зокрема згорткові нейронні мережі, хоч і демонструють суттєві здобутки, все ж мають певні обмеження. По-перше, вони вимагають масштабних якісно розмічених наборів даних, що утруднює їхнє застосування в медичній діагностиці, де формування подібних наборів даних є ресурсномістким [117]. По-друге, навчання моделей глибокого навчання є обчислювально дорогим процесом [107]. Також залишається відкритим питання «чорної скриньки» та інтерпретованості, особливо у випадку медичної сфери, де прозорість прийняття рішень є критично важливою [65]. Окрім цього, ризик перенавчання та обмежена здатність до ефективної адаптації на даних із різних джерел через варіабельність зображень, а також проблема дисбалансу класів, істотно ускладнюють їх інтеграцію в реальну практику [20].

З огляду на ці обмеження постає потреба у розробленні нових, більш ефективних методів обробки та аналізу цифрових зображень, здатних:

- 1) забезпечувати високу точність та надійність класифікації, зокрема для складних медичних завдань;
- 2) зменшувати залежність від великих обсягів маркованих даних;
- 3) гарантувати інтерпретованість та прозорість результатів;
- 4) бути стійкими до шуму й різноманітних варіацій зображень;
- 5) адаптуватися до різних типів вхідних даних і джерел;
- 6) враховувати можливий дисбаланс класів.

Означена проблематика є надзвичайно актуальною в галузі медицини та діагностичної візуалізації, де виявлення причинно-наслідкових зв'язків ускладнюється багаторівневою структурою чинників (рис. 1.4).



Рисунок 1.4 – Дерево проблем діагностичної візуалізації

Це дерево проблем систематично відображає взаємопов'язані аспекти, що впливають на ефективність діагностичної візуалізації. Останні кризові події, зокрема пандемія COVID-19 та військова агресія з боку російської федерації, додатково посилили виклики, які постають перед системою охорони здоров'я України. Основна складність для пересічних громадян виникає під час діагностики патологій, що зумовлено, зокрема, такими факторами:

1) застаріла інфраструктура і низька якість послуг у державних закладах охорони здоров'я;

2) дефіцит кваліфікованих фахівців, особливо у віддалених регіонах та сільській місцевості;

3) висока вартість сучасних діагностичних методів (УЗО, КТ тощо), які часто є ключовими для виявлення патологій.

Незадовільний рівень доступності передових методів діагностики має негативні наслідки для виявлення захворювань, оскільки зменшує шанс вчасного реагування та лікування. Це призводить до погіршення загального стану здоров'я населення, запізнює діагностику та зростання рівня смертності. Ефективність діагностичної візуалізації безпосередньо впливає на точність і оперативність встановлення діагнозу, а отже на результати лікування і рівень медичної допомоги. У її контексті можна виділити такі основні причини низької ефективності:

1) високі вимоги до експертного рівня та досвіду спеціалістів – брак належної підготовки або відсутність достатнього практичного досвіду негативно впливає на точність діагностики;

2) застаріла інфраструктура та обмежені технічні ресурси – у багатьох медичних закладах застосовуються застарілі технології, що унеможлиблює впровадження сучасних методів із вищою точністю та безпечністю;

3) недосконала система підготовки кадрів – не всі навчальні програми відповідають новітнім стандартам, зокрема у сфері діагностичних технологій;

4) недостатнє фінансування системи охорони здоров'я – обмежені фінансові ресурси ускладнюють оновлення обладнання й професійний розвиток персоналу.

Серед вторинних причин виділяють недостатню координацію між різними рівнями медичної допомоги й неефективне управління знаннями у медичній спільноті. Відсутність єдиного підходу до передачі досвіду поглиблює наявні прогалини в діагностиці.

До основних наслідків низької ефективності діагностичної візуалізації належать:

1) підвищення ймовірності хибного діагнозу, що зумовлює неправильне лікування і може призвести до значних ризиків для здоров'я та життя пацієнтів;

2) необхідність вдаватися до інвазивних методів діагностики, оскільки неінвазивні технології виявляються недостатньо точними – це збільшує ризик ускладнень і небажаних наслідків;

3) підвищений ризик розвитку ускладнень, адже невчасне та неточне виявлення патології сприяє прогресуванню захворювань;

Вторинними наслідками є затягування часу на діагностику, ризик ненавмисної шкоди пацієнту (через некоректні рекомендації або втручання), а також додаткові фінансові витрати як для закладів охорони здоров'я, так і для пацієнтів.

Методи машинного та глибокого навчання можуть істотно допомогти менш досвідченим спеціалістам у процесі інтерпретації медичних зображень, передбачаючи використання інтелектуальних асистентів для підтримки діагностичних рішень. Алгоритми машинного навчання, навчені на великому анотованому наборі зображень, здатні розпізнавати характерні патерни й ознаки різних захворювань. Результатом їхньої роботи є прогноз класу (мітки) зображення з відповідною ймовірністю належності до цього класу. Це сприяє обґрунтованим діагностичним рішенням, адже модель спирається на значний масив історичних даних.

За умови усунення або мінімізації перелічених обмежень у сфері обробки та аналізу цифрових зображень з'являється змога принаймні підвищити ефективність діагностичної візуалізації. Хоча проблема має суто медичний характер, її розв'язання через «ефект доміно» може також позитивно вплинути на розв'язання інших нагальних завдань, що постають перед Україною, включно з питаннями соціального та економічного розвитку.

1.5 Формулювання методики дослідження

З урахуванням попередніх результатів було запропоновано технологію аналізу цифрових зображень у вигляді блок-схеми (рис. 1.5), що є універсальною для будь-яких типів цифрових зображень (зокрема УЗО та КТ).

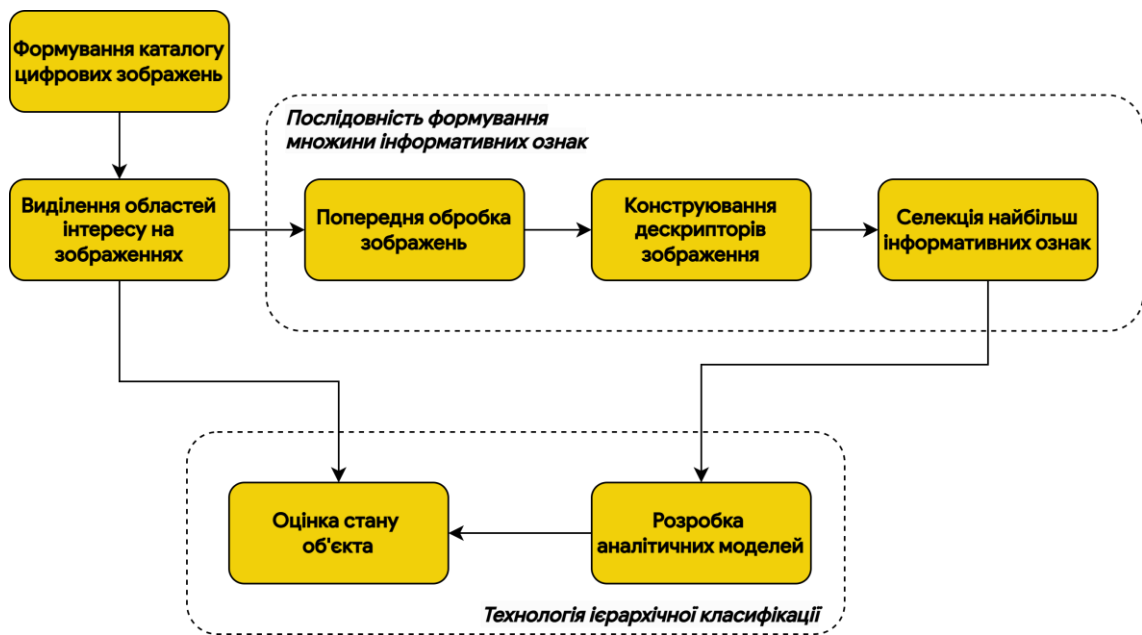


Рисунок 1.5 – Пропонована технологія аналізу цифрових зображень

Ця схема описує процес, заснований на формуванні множини інформативних ознак і подальшому використанні технології класифікації об'єктів. Розглянемо основні етапи технології:

1) формування каталогу цифрових зображень, призначених для аналізу, що передбачає збирання, організацію та зберігання відповідних даних.

2) виокремлення областей інтересу на зображеннях, які містять ключову для аналізу інформацію – це дає змогу суттєво зменшити обсяг оброблюваних даних та зосередитися на найбільш вагомих ділянках.

3) блок послідовності формування інформативних ознак описує процедури вилучення ключових характеристик зображень для подальшого аналізу й класифікації – підетапи попередньої обробки зображень,

розроблення дескрипторів та відбору найбільш інформативних ознак розглядаються в наступному розділі;

4) у межах технології ієрархічної класифікації [3] розробляються моделі, що використовують сформовані ознаки для автоматизованої оцінки стану об'єкта або його класифікації – детальний опис підходів до побудови аналітичних моделей і процесу оцінювання стану об'єкта наведено в розділі 3.

Таким чином, запропонована технологія охоплює послідовний процес від формування вихідного набору зображень, через вилучення та відбір інформативних ознак, до створення аналітичних моделей, що дають змогу автоматизувати оцінку й класифікацію об'єктів. Такий підхід може застосовуватися в різноманітних сферах, включно з медициною, промисловістю та сільським господарством, де потрібна точна обробка цифрових зображень.

Висновки до розділу 1

У даному дослідженні було систематизовано ключові аспекти цифрової обробки та аналізу зображень, а також окреслено напрями для подальших наукових розвідок. Сучасні методи обробки візуальних даних є надзвичайно важливими для медичної діагностики, промисловості, дистанційного зондування та низки інших галузей. Зокрема, автоматизований аналіз медичних зображень (наприклад, КТ та УЗО) значно підвищує точність встановлення діагнозу та скорочує час обробки даних, що має першорядне значення для систем охорони здоров'я.

Основні характеристики зображень, такі як просторова роздільна здатність, глибина кольору, динамічний діапазон і формат зберігання (JPEG, PNG, DICOM тощо), визначають потенційні можливості та обмеження під час їх подальшої обробки. Застосування формату DICOM у медичній

практиці дає змогу зберігати критичні діагностичні деталі, тоді як алгоритми стиснення з втратами можуть спричинити втрату важливої інформації.

Об'єднання текстурних дескрипторів (GLCM, статистичних розподілів, фрактального аналізу) з ансамблевими методами та технологіями глибинного навчання дає змогу суттєво підвищити ефективність класифікації й сегментації зображень. Синергія цих підходів набуває особливої ваги в задачах виявлення патологій, моніторингу навколишнього середовища та контролю якості.

Традиційні методи часто вразливі до шумів, геометричних спотворень та потребують ручного налаштування. Натомість глибинні мережі демонструють високу продуктивність, але вимагають масштабних обсягів розмічених даних, значних обчислювальних ресурсів і мають складнощі з інтерпретацією результатів.

У роботі пропонується методика, що інтегрує технологію ієрархічної класифікації, виділення інформативних ознак та поєднання текстурного аналізу з машинним навчанням, спрямована на усунення існуючих обмежень. Передбачено розроблення універсальних моделей, здатних адаптуватися до різних типів зображень, мінімізувати вплив шуму і забезпечувати прозорість ухвалення рішень.

Запропоновані підходи можуть стати основою для автоматизованих систем підтримки діагностичних рішень, зокрема у медичній сфері, що набуває особливої актуальності за умов дефіциту висококваліфікованих фахівців та недостатньо оновленої інфраструктури. Застосування таких систем сприятиме зниженню ризику хибних діагнозів, оптимізації витрат та покращенню доступності медичних послуг.

РОЗДІЛ 2

ПОСЛІДОВНІСТЬ ФОРМУВАННЯ МНОЖИНИ ІНФОРМАТИВНИХ ОЗНАК ЦИФРОВИХ ЗОБРАЖЕНЬ

Даний розділ детально розглядає етап технології аналізу цифрових зображень, на якому відбувається екстракція колективу інформативних ознак, які дозволяють здійснити кількісну оцінку характеристик зображень. Такий підхід забезпечує можливість створення стандартизованих метрик, які можна співвідносити з традиційними лабораторними показниками, як-от рівень глюкози або кількість тромбоцитів у крові пацієнта. Це створює важливе підґрунтя для інтеграції результатів візуального аналізу у комплексну систему діагностики, підвищуючи її об'єктивність та відтворюваність.

2.1 Гістограмна обробка зображень

Використані в роботах [7, 12, 13, 13–16, 18, 77, 78] медичні зображення були зібрані за допомогою різних сканерів, кожен із яких використовував індивідуальні параметри калібрування, контрастності та інших налаштувань, адаптованих до конкретних особливостей пацієнта. Це призвело до значної варіабельності гістограм піксельних інтенсивностей у зображеннях, що потенційно впливає на надійність та якість подальшого аналізу. Тому для стандартизації зображень і підвищення ефективності порівняльного аналізу було вирішено застосувати методи гістограмної обробки, які дозволяють уніфікувати характеристики піксельних значень у визначених ОІ.

Гістограмна обробка зображень, як один із методів покращення контрастності, стала важливим елементом попередньої обробки даних. Було обрано кілька підходів, зокрема нормалізацію інтенсивності, еквалізацію гістограми та диференціацію пікселів, кожен з яких має свої унікальні переваги.

2.1.1 Нормалізація інтенсивності пікселів

Результат застосування *max-min* нормалізації наведений на рис. 2.1.




Рисунок 2.1 – Сірошкальне зображення та його гістограма після нормалізації

Нормалізація є важливою операцією в підготовці даних, де початкові значення піксельної інтенсивності переводяться до стандартного діапазону, зазвичай від 0 до 1. Це забезпечує уніфікацію масштабу даних, що є критично важливим, оскільки багато алгоритмів машинного навчання є чутливими до значень інтенсивності. Як видно на рис. 2.1, нормалізоване зображення демонструє покращений контраст, із посиленими відмінностями між темними та світлими ділянками, що дозволяє краще візуалізувати структури, які раніше були слабо помітними.

Формула нормалізації має вигляд:

$$I'(x, y) = \frac{I(x, y) - \min}{\max - \min}, \quad (2.1)$$

де $I(x, y)$ – оригінальне значення інтенсивності пікселя;

$I'(x, y)$ – нове значення інтенсивності;

\min та \max – відповідно мінімальне та максимальне можливі значення інтенсивності (0 і 255).

2.1.2 Еквалізація гістограми

Результат застосування еквалізації наведений на рис. 2.2.




Рисунок 2.2 – Сірошкальне зображення та його гістограма після еквалізації

Еквалізація гістограми дозволяє вирівняти розподіл інтенсивностей, підвищуючи контрастність, особливо в зонах із низькою варіабельністю. На рис. 2.2 видно, що після еквалізації зображення стало значно більш контрастним, із рівномірним розподілом яскравості, що поліпшує видимість тонких структур, особливо в областях із раніше низькою контрастністю.

Формула еквалізації виглядає наступним чином:

$$I'(x, y) = \min + \frac{\max - \min}{N} * \sum_{i=\min}^k n_i, \quad (2.2)$$

де N – загальна кількість пікселів зображення;

k – рівень яскравості, що дорівнює інтенсивності $I(x, y)$;

n_i – кількість пікселів із рівнем інтенсивності i .

2.1.3 Диференціація пікселів зображення

Метод диференціації був запропонований як засіб підвищення інформативності оброблених зображень, що дозволяє виділити особливості на межах між різними зонами. Як було показано в попередніх роботах

дисертанта [5, 9, 10, 78], найбільш корисна інформація міститься в комбінаціях сусідніх пікселів, особливо в контексті зображень, отриманих із різними рівнями контрастності.

Диференціація змінює зображення шляхом обчислення різниці в інтенсивності між сусідніми пікселями по горизонталі або вертикалі, що дозволяє виділити контури й межі структур. На рис. 2.3 показано результати горизонтальної диференціації, яка підсилює контури, роблячи однорідні області темними та акцентуючи увагу на переходах між різними зонами.




Рисунок 2.3 – Сірошкальне зображення та його гістограма після горизонтальної диференціації

Зображення після вертикальної диференціації, представлене на рис. 2.4, демонструє підсилення горизонтальних структур, що може бути корисним для аналізу витягнутих горизонтально елементів.

Формула горизонтальної диференціації:

$$I'(x, y) = I(x, y) - I(x - 1, y) \quad (2.3)$$

Формула вертикальної диференціації:

$$I'(x, y) = I(x, y) - I(x, y - 1) \quad (2.4)$$




Рисунок 2.4 – Сірошкальне зображення та його гістограма після вертикальної диференціації

Після обчислення диференціації, аби уникнути негативних значень, від кожного піксельного значення віднімається мінімальне значення, що дозволяє зберегти коректний діапазон інтенсивностей.

2.2 Конструювання дескрипторів зображення

Первинним етапом для будь-якого алгоритму машинного навчання, спрямованого на розв'язання задач комп'ютерного зору, є вилучення ознак із заданих зображень. Процес вилучення ознак є критичним компонентом будь-якої системи класифікації зображень, оскільки він безпосередньо впливає на якість подальшого розпізнавання. Для забезпечення можливості успішного розпізнавання необхідно трансформувати вихідні зображення в їхні відповідні дескриптори (ознаки) – стиснені представлення, що зберігають лише найбільш релевантну інформацію. Ознаки виступають як характеристики зображення в формі, яка підлягає аналітичному порівнянню, що дозволяє здійснювати класифікацію. Процес вилучення ознак може бути реалізований як вручну, так і автоматизовано.

Ручне виділення ознак потребує ідентифікації та детального опису релевантних ознак, а також створення методології їх вилучення. У багатьох

випадках глибоке розуміння контексту або предметної області є необхідною умовою для обґрунтованого вибору корисних ознак. Протягом багатьох років досліджень інженери та науковці розробили низку методів вилучення ознак для зображень. Серед них можна виокремити такі типи ознак, як текстурні, ознаки на основі гістограм, багаторегіональних гістограм, багатомасштабні ознаки, а також на основі згорткової нейронної мережі.

2.2.1 Текстурні ознаки

2.2.1.1 Статистики першого порядку. Нехай позначимо $f(x, y)$ як зображення в градаціях сірого. Гістограма першого порядку H_i визначається як:

$$H_i = \frac{n_i}{N}, \quad (2.5)$$

де n_i – кількість пікселів із рівнем сірого всередині ОІ,
 N – загальна кількість пікселів в ОІ.

Ця гістограма являє собою емпіричну функцію щільності ймовірності, що описує розподіл рівнів сірого для окремих пікселів у вибраній області. На її основі обчислюються FOS обчислюються на основі гістограми зображення. До набору ознак FOS належать:

1) середнє значення, яке характеризує середню яскравість зображення:

$$\mu = f_1 = \sum_i i H_i \quad (2.6)$$

2) стандартне відхилення, що визначає розсіювання значень яскравості відносно середнього:

$$\sigma = f_2 = \sqrt{\sum_i (i - \mu)^2 H_i} \quad (2.7)$$

3) медіана, що слугує показником центральної тенденції розподілу:

$$f_3 s. t. \sum_{i=0}^{f_3} H_i = 0.5 \quad (2.8)$$

4) мода, яка відображає найчастіше зустрічаюче значення яскравості:

$$f_4 = \operatorname{argmax}_i \{H_i\} \quad (2.9)$$

5) асиметрія, що характеризує симетрію розподілу яскравості:

$$f_5 = \sum_i \left(\frac{i - \mu}{\sigma} \right)^3 H_i \quad (2.10)$$

6) ексцес, який оцінює гостроту піка розподілу:

$$f_6 = \sum_i \left(\frac{i - \mu}{\sigma} \right)^4 H_i \quad (2.11)$$

7) енергія, що є мірою однорідності зображення:

$$f_7 = \sum_i H_i^2 \quad (2.12)$$

8) ентропія, яка відображає ступінь невизначеності або складності розподілу:

$$f_8 = - \sum_i H_i \ln[H_i] \quad (2.13)$$

9) мінімальний рівень сірого:

$$f_9 = \min\{f(x, y)\} \quad (2.14)$$

10) максимальний рівень сірого:

$$f_{10} = \max\{f(x, y)\} \quad (2.15)$$

11) коефіцієнт варіації, що вимірює відносне розсіювання рівнів яскравості:

$$f_{11} = \frac{\sigma}{\mu} \quad (2.16)$$

12-15) перцентилі (10, 25, 50, 75, 90), які представляють порогові значення рівнів яскравості для відповідних часток вибірки:

$$f_n s.t. \sum_{i=0}^{f_n} H_i = c \quad (2.17)$$

16) ширина гістограми (різниця між 90-м та 10-м перцентилями), що визначає діапазон значень яскравості в зображенні:

$$f_{16} = f_{15} - f_{12} \quad (2.18)$$

2.2.1.2 Матриця суміжності рівнів сірого. Оцінка функцій щільності умовної ймовірності другого порядку $p(i, j; d, \theta)$ базуються на GLCM, запропонованих Хараліком [44]. Тут $p(i, j; d, \theta)$ – це ймовірність того, що два пікселі (x_1, y_1) та (x_2, y_2) , які знаходяться на відстані d в напрямку, заданому кутом θ , мають інтенсивності рівнів сірого i та j відповідно. Оцінені значення цих функцій щільності ймовірності позначаються як $P(i, j; d, \theta)$.

Набір текстурних мір, які можуть бути отримані з GLCM, включає:

1) кутовий другий момент:

$$f_{17} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} [p(i, j)]^2 \quad (2.19)$$

2) контраст:

$$f_{18} = \sum_{n=0}^{N-1} n^2 \left\{ \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p(i, j), |i - j| = n \right\} \quad (2.20)$$

3) кореляція:

$$f_{19} = \frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.21)$$

4) сума квадратів (дисперсія):

$$f_{20} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu)^2 p(i, j) \quad (2.22)$$

5) момент оберненої різниці:

$$f_{21} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (2.23)$$

6) середнє суми:

$$f_{22} = \sum_{k=2}^{2N} k p_{x+y}(k) \quad (2.24)$$

7) дисперсія суми:

$$f_{23} = \sum_{k=2}^{2N} (k - \mu_{x+y})^2 p_{x+y}(k) \quad (2.25)$$

8) ентропія суми:

$$f_{24} = - \sum_{k=2}^{2N} p_{x+y}(k) \ln[p_{x+y}(k)] \quad (2.26)$$

9) ентропія:

$$f_{25} = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p(i, j) \ln[p(i, j)] \quad (2.27)$$

10) дисперсія різниці:

$$f_{26} = \sum_{k=0}^{N-1} (k - \mu_{x+y})^2 p_{x-y}(k) \quad (2.28)$$

11) ентропія різниці:

$$f_{27} = - \sum_{k=0}^{N-1} p_{x-y}(k) \ln[p_{x-y}(k)] \quad (2.29)$$

Для обраної відстані d маємо чотири кутові матриці GLCM. Отже, отримуємо набір з чотирьох значень для кожної з наведених мір. Середнє та розмах кожної з цих мір, усереднені по чотирьох значеннях, складають набір текстурних ознак.

2.2.1.3 Статистика різниці рівнів сірого. Алгоритм GLDS [64] використовує статистичні характеристики першого порядку локальних значень властивостей, базуючись на абсолютних різницях між парами рівнів

сірого або середніми рівнями сірого, для вилучення мір текстури. Нехай $f(x, y)$ – функція інтенсивності зображення, і для будь-якого заданого зсуву $\delta = (\Delta x, \Delta y)$, нехай:

$$f_{\delta}(x, y) = |f(x, y) - f(x + \Delta x, y + \Delta y)| \quad (2.30)$$

Нехай p_{δ} – щільність ймовірності $f_{\delta}(x, y)$. Якщо є N рівнів сірого, це має форму N -вимірного вектора, де i -та компонента є ймовірністю того, що $f_{\delta}(x, y)$ матиме значення i . Щільність ймовірності p_{δ} можна легко обчислити, підрахувавши кількість разів, коли кожне значення $f_{\delta}(x, y)$ зустрічається, де Δx і Δy – цілі числа.

У грубій текстурі, якщо d мале, $f_{\delta}(x, y)$ також буде малим, тобто значення p_{δ} повинні бути зосереджені поблизу $i = 0$. Навпаки, у тонкій текстурі значення p_{δ} повинні бути більш розподіленими. Таким чином, хорошим способом аналізу грубості текстури є обчислення, для різних величин δ , певної міри розсіювання значень у p_{δ} , віддалених від початку координат. Такими мірами є:

1) однорідність:

$$f_{28} = \sum_i \frac{p_{\delta}(i)}{i^2 + 1} \quad (2.31)$$

2) контраст:

$$f_{29} = \sum_i i^2 p_{\delta}(i) \quad (2.32)$$

3) енергія (кутовий другий момент):

$$f_{30} = \sum_i [p_{\delta}(i)]^2 \quad (2.33)$$

4) ентропія:

$$f_{31} = - \sum_i p_{\delta}(i) \ln[p_{\delta}(i)] \quad (2.34)$$

5) середнє значення:

$$f_{32} = \sum_i i p_{\delta}(i) \quad (2.35)$$

2.2.1.4 Матриця різниці відтінків сірого сусідніх точок. NGTDM [69]

відповідає візуальним властивостям текстури. Нехай $f(x, y)$ – відтінок сірого пікселя в точці (x, y) , який має значення відтінку сірого i . Тоді середній відтінок сірого в околі, зосередженому в (x, y) , але виключаючи саму точку (x, y) , можна знайти за формулою:

$$A_i = A(x, y) = \frac{1}{W-1} \sum_{x'=-d}^d \sum_{y'=-d}^d f(x+x', y+y'), \quad (2.36)$$

де $(x', y') \neq (0, 0)$;

d – розмір околу;

$W = (2d + 1)^2$.

Набір текстурних мір, які можуть бути отримані з NGTDM, включає:

1) грубість:

$$f_{33} = \left[\varepsilon + \sum_{i=0}^{G_h} p_i s(i) \right]^{-1} \quad (2.37)$$

2) контраст:

$$f_{34} = \left[\frac{1}{N_g(N_g - 1)} \sum_{i=0}^{G_h} \sum_{j=0}^{G_h} p_i p_j (i - j)^2 \right] \left[\frac{1}{n^2} \sum_{i=0}^{G_h} s(i) \right] \quad (2.38)$$

3) активність:

$$f_{35} = \frac{\sum_{i=0}^{G_h} p_i s(i)}{\sum_{i=0}^{G_h} i p_i - \sum_{j=0}^{G_h} j p_j}, p_i \neq 0, p_j \neq 0 \quad (2.39)$$

4) складність:

$$f_{36} = \sum_{i=0}^{G_h} \sum_{j=0}^{G_h} \left\{ \frac{|i - j|}{n^2(p_i + p_j)} \right\} \{p_i s(i) + p_j s(j)\}, p_i \neq 0, p_j \neq 0 \quad (2.40)$$

5) сила:

$$f_{37} = \frac{\sum_{i=0}^{G_h} \sum_{j=0}^{G_h} (p_i + p_j)(i - j)^2}{\varepsilon + \sum_{i=0}^{G_h} s(i)}, p_i \neq 0, p_j \neq 0 \quad (2.41)$$

2.2.1.5 Статистична матриця ознак. SFM [113] вимірює статистичні властивості пар пікселів на декількох відстанях у зображенні, які використовуються для статистичного аналізу. Нехай $f(x, y)$ – функція інтенсивності зображення в точці (x, y) , і нехай $\delta = (\Delta x, \Delta y)$ представляє вектор відстані між зразками, де $\Delta x, \Delta y$ – цілі числа. Контраст (CON) δ , коваріація (COV) δ та несхожість (DSS) δ обчислюються за формулами (2.42), (2.43) та (2.44) відповідно.

SFM (M_{sf}) – це матриця розміру $(L_r + 1) \times (2L_c + 1)$, елемент (i, j) якої є статистичною ознакою δ зображення, де $\delta = (j - L_c, i)$ – вектор відстані між зразками для $i = 0, 1, \dots, L_r, j = 0, 1, \dots, 2L_c$, а L_r, L_c – константи, що визначають максимальну відстань між зразками.

$$CON(\delta) = E\{[f(x, y) - f(x + \Delta x, y + \Delta y)]^2\} \quad (2.42)$$

$$COV(\delta) = E\{[f(x, y) - \eta][f(x + \Delta x, y + \Delta y) - \eta]\} \quad (2.43)$$

$$DSS(\delta) = E\{f(x, y) - f(x + \Delta x, y + \Delta y)\} \quad (2.44)$$

Аналогічно, матриці контрасту (M_{con}), коваріації (M_{cov}) та несхожості (M_{dss}) можна визначити як матриці, елементи (i, j) яких є відповідно контрастом δ , коваріацією δ та несхожістю δ .

На основі SFM можна обчислити наступні текстурні ознаки:

1) грубість:

$$f_{38} = c \cdot \frac{\sum_{(i,j) \in N_r} DSS(i, j)}{n}, \quad (2.45)$$

де c – нормалізуючий фактор;

N_r – множина векторів зсуву, визначена як $N_r = \{(i, j) : |i|, |j| < r\}$;

n – кількість елементів у множині.

2) контраст:

$$f_{39} = \left[\sum_{(i,j) \in N_r} [CON(i, j)]^4 \right]^{1/2} \quad (2.46)$$

3) періодичність:

$$f_{40} = \frac{\overline{M}_{dss} - M_{dss}(\min)}{\overline{M}_{dss}} \quad (2.47)$$

4) шорсткість:

$$f_{41} = \frac{D_f(h) + D_f(v)}{2} \quad (2.48)$$

2.2.1.6 Метод енергії текстури Лоу. LTE [32, 61] походять від трьох простих векторів довжини 3:

- $L3 = (1, 2, 1)$;
- $E3 = (-1, 0, 1)$;
- $S3 = (-1, 2, -1)$.

Вони представляють одномірні операції центровано-зваженого локального усереднення, симетричного першого диференціювання для виявлення країв та другого диференціювання для виявлення плям.

Якщо ці вектори згортати самі з собою, отримуються нові вектори довжини 5:

- $L5 = (1, 4, 6, 4, 1)$;
- $E5 = (-1, -2, 0, 2, 1)$;
- $S5 = (-1, 0, 2, 0, -1)$.

Подальшою самозгорткою отримуються нові вектори довжини 7:

- $L7 = (1, 6, 15, 20, 15, 6, 1)$;
- $E7 = (-1, -4, -5, 0, 5, 4, 1)$;
- $S7 = (-1, -2, 1, 4, 1, -2, -1)$.

$L7$ знову виконує локальне усереднення, $E7$ діє як детектор країв, а $S7$ діє як детектор плям.

Якщо стовпцеві вектори довжини l множити на рядкові вектори тієї ж довжини, отримуються маски Лоу розміру $l \times l$. Наступні комбінації використовуються для отримання масок (для $l = 7$):

- $LL = L7^T L7$;
- $LE = L7^T E7$;
- $LS = L7^T S7$;
- $EL = E7^T L7$;
- $EE = E7^T E7$;
- $ES = E7^T S7$;
- $SL = S7^T L7$;

$$- SE = S^T E^T;$$

$$- SS = S^T S.$$

Для вилучення текстурних ознак із зображення, ці маски згортаються із зображенням, і статистичні характеристики (наприклад, енергія) отриманого зображення використовуються для опису текстури. Були вилучені наступні текстурні ознаки:

- 1) LL – енергія текстури з ядра LL ;
- 2) EE – енергія текстури з ядра EE ;
- 3) SS – енергія текстури з ядра SS ;
- 4) LE – середня енергія текстури з ядер LE та EL ;
- 5) ES – середня енергія текстури з ядер ES та SE ;
- 6) LS – середня енергія текстури з ядер LS та SL .

Осереднення пар узгоджених мір енергії забезпечує інваріантність до обертання.

2.2.1.7 Аналіз текстури за фрактальною розмірністю. FDTA [32] базується на моделі фракційного броунівського руху. Дана модель використовується для опису шорсткості природних поверхонь. Вона розглядає природні поверхні як кінцевий результат випадкових блукань, які є базовими фізичними процесами у нашому всесвіті. Одним із найважливіших параметрів для представлення фрактальної поверхні є фрактальна розмірність. Теоретично фрактальна розмірність D_f оцінюється за рівнянням:

$$E(\Delta I^2) = c \cdot (\Delta r)^{6-2D_f}, \quad (2.49)$$

де $E(\cdot)$ позначає оператор математичного сподівання;

$\Delta I = I(x_2, y_2) - I(x_1, y_1)$ – варіація інтенсивності між двома пікселями;

c – константа;

$\Delta r = \|(x_2, y_2) - (x_1, y_1)\|$ – просторова відстань.

Більш простий метод полягає в оцінці параметра H (коефіцієнта Херста) з відношення:

$$E(|\Delta I|) = k \cdot (\Delta r)^H \quad (2.50)$$

Застосовуючи логарифмічну функцію, отримуємо:

$$\log E(|\Delta I|) = \log k + H \cdot \log(\Delta r) \quad (2.51)$$

З наведеного рівняння можемо вивести процедуру для оцінки параметра H , і фрактальна розмірність легко обчислюється з відношення:

$$D_f = 3 - H \quad (2.52)$$

Мале значення фрактальної розмірності D_f (велике значення параметра H) означає гладку поверхню, а велике D_f (мале H) – шорстку поверхню.

Для заданого зображення розміром $M \times M$ вектор різниці інтенсивностей визначається як:

$$IDV = [id(1), id(2), \dots, id(s)], \quad (2.53)$$

де s – максимальний можливий масштаб;

$id(k)$ – середнє абсолютне значення різниці інтенсивностей усіх пар пікселів з вертикальною або горизонтальною відстанню k .

Значення параметра H можна отримати, використовуючи лінійну регресію найменших квадратів для оцінки нахилу кривої $id(k)$ відносно k у логарифмічних масштабах.

Якщо зображення розглядається на різних роздільностях, то багатороздільний фрактальний вектор ознак (MF) визначається як:

$$MF = (H_m, H_{m-1}, \dots, H_{m-n+1}), \quad (2.54)$$

де $M = 2^m$ – розмір оригінального зображення;

H_k – параметр H , оцінений із зображення I_k ;

k – кількість вибраних роздільностей.

MF також описує лакуарність зображення. Він може бути використаний для розділення текстур з однаковою фрактальною розмірністю D_f , розглядаючи всі компоненти векторів MF , крім першої.

2.2.1.8 Матриця довжин пробігів рівнів сірого. Пробіг сірого – це набір послідовних, колінеарних точок зображення, які мають однакове значення рівня сірого. Довжина пробігу – це кількість точок зображення в цьому пробігу [87]. Для заданого зображення можна обчислити матрицю довжин пробігів рівнів сірого для пробігів у будь-якому заданому напрямку θ . Часто напрямок θ встановлюється як 0° , 45° , 90° , 135° . Елемент матриці $p_\theta(i, j)$ визначає кількість разів, коли зображення містить пробіг довжини j у заданому напрямку, який складається з точок з рівнем сірого i (або в діапазоні рівня сірого i).

Обчислення цих матриць є дуже простим. Кількість обчислень прямо пропорційна кількості точок у зображенні. Також немає потреби зберігати все зображення в оперативній пам'яті; для обчислення матриць в будь-який момент часу потрібні лише два рядки значень зображення. Щоб отримати числові текстурні характеристики з матриць, можна обчислити функції, аналогічні тим, що використовував Харалік для матриць сумісності рівнів сірого.

Характеристики GLRLM є наступними:

1) підкреслення коротких пробігів:

$$f_{42} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} \frac{p_\theta(i, j)}{j^2}}{N_z} \quad (2.55)$$

2) підкреслення довгих пробігів:

$$f_{43} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} j^2 p_\theta(i, j)}{N_z} \quad (2.56)$$

3) нерівномірність рівнів сірого (розподіл рівнів сірого):

$$f_{44} = \frac{\sum_{i=0}^{N_g-1} (\sum_{j=0}^{N_r-1} p_{\theta}(i, j))^2}{N_z} \quad (2.57)$$

4) нерівномірність довжин пробігів (розподіл довжин пробігів):

$$f_{45} = \frac{\sum_{j=0}^{N_g-1} (\sum_{i=0}^{N_r-1} p_{\theta}(i, j))^2}{N_z} \quad (2.58)$$

5) відсоток пробігів:

$$f_{46} = \frac{N_z}{N_p} \quad (2.59)$$

6) підкреслення низьких рівнів сірого в пробігах:

$$f_{47} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} \frac{p_{\theta}(i, j)}{i^2}}{N_z} \quad (2.60)$$

7) підкреслення високих рівнів сірого в пробігах:

$$f_{48} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} p_{\theta}(i, j) i^2}{N_z} \quad (2.61)$$

8) підкреслення коротких пробігів з низькими рівнями сірого:

$$f_{49} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} \frac{p_{\theta}(i, j)}{i^2 j^2}}{N_z} \quad (2.62)$$

9) підкреслення коротких пробігів з високими рівнями сірого:

$$f_{50} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} \frac{p_{\theta}(i, j)}{j^2}}{N_z} \quad (2.63)$$

10) підкреслення довгих пробігів з низькими рівнями сірого:

$$f_{51} = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_r-1} \frac{p_{\theta}(i, j)}{i^2}}{N_z} \quad (2.64)$$

11) підкреслення довгих пробігів з високими рівнями сірого:

$$f_{52} = \frac{\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_r-1} p_{\theta}(i, j) i^2 j^2}{N_z} \quad (2.65)$$

2.2.1.9 Спектр потужності Фур'є. Перетворення Фур'є [32, 64] зображення $f(x, y)$ визначається як:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{-2\pi i(ux+vy)} f(x, y) dx dy \quad (2.66)$$

Спектр потужності Фур'є – це $|F|^2 = FF^*$ (де * позначає комплексно спряжене). Добре відомо, що радіальний розподіл значень у $|F|^2$ чутливий до грубості текстури в f . Груба текстура матиме високі значення $|F|^2$, зосереджені поблизу початку координат, тоді як у тонкій текстурі значення $|F|^2$ будуть більш розподілені. Отже, якщо бажано аналізувати грубість текстури, корисним буде набір ознак, які є середніми значеннями $|F|^2$, взятими по кільцеподібних областях, зосереджених у початку координат, тобто ознаки виду:

$$\varphi_r = \int_0^{2\pi} |F(r, \theta)|^2 d\theta \quad (2.67)$$

Аналогічно, відомо, що кутовий розподіл значень у $|F|^2$ чутливий до направленості текстури в f . Текстура з багатьма краями або лініями в заданому напрямку θ матиме високі значення $|F|^2$, зосереджені навколо перпендикулярного напрямку, тоді як у ненаправленій тектурі $|F|^2$ також має бути ненаправленим. Тому хорошим набором ознак для аналізу направленості текстури будуть середні значення $|F|^2$, взяті по клиноподібних областях, зосереджених у початку координат, тобто ознаки виду:

$$\varphi_\theta = \int |F(r, \theta)|^2 dr \quad (2.68)$$

Для цифрових зображень розміром $N \times N$, замість безперервного перетворення Фур'є, визначеного вище, використовується дискретне перетворення, визначене як:

$$F(u, v) = \frac{1}{N^2} \sum_{i,j=0}^{N-1} f(i, j) e^{-2\pi i (iu + jv)}, \quad (2.69)$$

де $0 \leq u;$
 $v \leq N - 1.$

Однак це перетворення розглядає вхідне зображення $f(x, y)$ як періодичне. Якщо насправді це не так, перетворення зазнає впливу розривів, які існують між одним краєм f та протилежним краєм. Це призводить до появи помилкових горизонтальних та вертикальних напрямленостей, так що високі значення присутні в $|F|^2$ вздовж осей u та v .

Стандартний набір текстурних ознак, оснований на кільцеподібних вибірках дискретного спектру потужності Фур'є, має вигляд:

$$\varphi_{r_1, r_2} = \sum_{r_1 \leq u^2 + v^2 \leq r_2} |F(u, v)|^2 \quad (2.70)$$

Аналогічно, ознаки, основані на клиноподібних вибірках, мають вигляд:

$$\Phi_{\theta_1, \theta_2} = \sum_{\theta_1 \leq \tan^{-1}\left(\frac{v}{u}\right) \leq \theta_2} |F(u, v)|^2 \quad (2.71)$$

2.2.1.10 Локальний бінарний шаблон. LBP, надійний та ефективний дескриптор текстури, був вперше представлений Ояла [81, 82]. Вектор ознак LBP у найпростішій формі визначається за допомогою наступного методу: навколо пікселя розглядається кругове околі. На окружності кола з радіусом R вибираються P точок таким чином, що вони всі знаходяться на однаковій відстані від центрального пікселя [105]. Нехай g_c – значення рівня сірого центрального пікселя, а g_p , де $p = 0, \dots, P - 1$, відповідають значенням рівнів сірого цих P точок. Ці P точок перетворюються у круговий бітовий потік із 0 та 1 залежно від того, чи значення рівня сірого пікселя менше або більше, ніж значення рівня сірого центрального пікселя.

Автори [82] ввели поняття однорідності в аналіз текстур. Однорідні фундаментальні патерни мають однорідну кругову структуру, яка містить дуже мало просторових переходів U (кількість просторових побітових переходів 0/1). У цій роботі була обчислена інваріантна до обертання міра, названа $LBP_{P,R}$, з використанням міри однорідності U . LBP-код присвоювався лише патернам з $U \leq 2$, тобто якщо кількість бітових переходів у круговому бітовому потоці менше або дорівнює 2, центральний піксель позначався як однорідний.

Мультишкальний аналіз зображення з використанням LBP виконується шляхом вибору кіл з різними радіусами навколо центральних пікселів, таким чином будуючи окреме LBP-зображення для кожного масштабу. Енергія та ентропія LBP-зображення, побудованого на різних масштабах ($R = 1, 2, 3$ з відповідною кількістю пікселів $P = 8, 16, 24$ відповідно), використовувалися як дескриптори ознак.

2.2.2 Ознаки на основі гістограм

Гістограма рівнів сірого ОІ зображення бляшки обчислюється для 32 бінів рівної ширини і використовується як набір ознак. Незважаючи на свою простоту, гістограма надає хороше описання структури бляшки.

2.2.3 Ознаки на основі багаторегіональних гістограм

Три рівновіддалені ОІ були визначені шляхом ерозії контуру зображення бляшки на фактор, заснований на розмірі бляшки. Гістограма була обчислена для кожної з трьох областей, як описано вище, і 96 значень склали новий вектор ознак. Ця ознака була обчислена з метою дослідження, чи має діагностичну цінність розподіл структури бляшки в рівновіддалених ROI, і більш конкретно, чи є структура зовнішньої області бляшки критичною для визначення, чи розірветься бляшка чи ні.

2.2.4 Багатомасштабні ознаки

2.2.4.1 Дискретне вейвлет-перетворення. DWT сигналу $x[n]$ визначається як його скалярний добуток із сімейством функцій $\phi_{j,k}(t)$ та $\psi_{j,k}(t)$, які утворюють ортонормований набір векторів [110]. Комбінація цих функцій може повністю описати сигнал, що дозволяє проводити його аналіз на багатьох рівнях роздільної здатності j :

$$\phi_{j,k}(t) = 2^{j/2} \cdot \phi(2^j t - k) \quad (2.72)$$

$$\psi_{j,k}(t) = 2^{j/2} \cdot \psi(2^j t - k) \quad (2.73)$$

Функції $\phi_{j,k}(t)$ та $\psi_{j,k}(t)$ є версіями базових функцій масштабування $\phi(t)$ та вейвлет-функцій $\psi(t)$, дискретизованих на рівні j та зі зсувом k . Однак для реалізації DWT потрібні лише коефіцієнти двох напівсмугових фільтрів: низькочастотного $h(k)$ та високочастотного $g(k) = (-1)^k h(1 - k)$, які задовольняють умовам формул (2.74) та (2.75).

Таким чином, DWT визначається за формулами (2.76) та (2.77)

$$\phi_{j+1,0}(t) = \sum_k h[k] \phi_{j,k}(t) \quad (2.74)$$

$$\psi_{j+1,0}(t) = \sum_k g[k] \psi_{j,k}(t) \quad (2.75)$$

$$A_{j+1,n} = \sum_k A_{j,k} \cdot h_j[k - 2n] \quad (2.76)$$

$$D_{j+1,n} = \sum_k D_{j,k} \cdot g_j[k - 2n] \quad (2.77)$$

$A_{j, n}$ та $D_{j, n}$ називаються коефіцієнтами апроксимації та деталізації відповідно на рівні j та позиції n . Результати $A_{j, n}$ та $D_{j, n}$ згортки піддаються дискретизації з коефіцієнтом два на кожному рівні аналізу, що призводить до зменшення часової роздільності вдвічі та подвоєння частотної роздільної здатності.

Для зображень, тобто двовимірних сигналів, використовується двовимірне дискретне вейвлет-перетворення (2-D DWT). Воно складається з застосування DWT до рядків зображення та DWT до стовпців отриманого після цього зображення. Результат кожного DWT супроводжується дискретизацією по стовпцях та рядках відповідно. Розклад зображення призводить до отримання чотирьох фрагментів на кожному рівні.

2.2.4.2 Стаціонарне вейвлет-перетворення. Двовимірне SWT схоже на двовимірне DWT, але дискретизація не виконується. Натомість здійснюється передискретизація низькочастотних і високочастотних фільтрів. Головною перевагою SWT над DWT є його властивість інваріантності до зсуву. Однак, він є неортогональним і високо надлишковим, а отже, обчислювально затратним [110].

2.2.5 Ознаки на основі згорткових нейронних мереж

Згорткові нейронні мережі продемонстрували високу результативність у широкому спектрі завдань комп'ютерного зору, зокрема в класифікації, сегментації та виявленні об'єктів. Їхня здатність автоматично засвоювати ієрархічні уявлення даних робить їх особливо корисними для аналізу складних цифрових зображень, де ручне вилучення ознак може бути трудомістким та малоефективним.

Для створення додаткових дескрипторів цифрових зображень обрано архітектуру згорткової нейронної мережі ResNet-50 [45], що містить п'ять блоків згорткових шарів. Кожен блок складається з кількох згорткових шарів, за якими розташовані шари активації (ReLU) й пакетної нормалізації. Ключова особливість ResNet полягає у використанні залишкових зв'язків, що дають змогу уникнути проблеми зникаючого градієнта під час навчання глибоких мереж і, відповідно, підвищити ефективність моделі.

Для інтеграції ResNet-50 у процес формування інформативних ознак зображень застосовано таку методику. Спочатку зображення проходять попередню обробку, що включає зміну їхнього розміру до 224×224 пікселів. Потім вони подаються на вхід попередньо навчених на ImageNet мережі ResNet-50. Виходи передостаннього шару (усереднююче агрегування) слугують векторами ознак, які відображають високорівневі семантичні представлення зображень, сформовані в процесі навчання.

Отримані вектори ознак з ResNet-50 об'єднують із вектором текстурних ознак, визначених шляхом ручного конструювання. Це дозволяє сформувати розширений набір ознак, що поєднує низькорівневі текстурні характеристики й високорівневі семантичні представлення, вивчені згортковими нейронними мережами. Подібне комбінування враховує різні аспекти зображень, у результаті чого підвищується точність і надійність класифікації.

2.3 Селекція найбільш інформативних ознак

Відбір інформативних ознак є ключовим етапом у процесі побудови моделей машинного навчання, оскільки він дозволяє зменшити розмірність вхідних даних, зберігаючи при цьому лише найсуттєвіші ознаки для моделювання. Це важливо не лише для зменшення обчислювальної складності, але і для покращення інтерпретованості моделі та зниження ризику перенавчання. Відбір ознак слід відрізняти від «виділення ознак», яке передбачає створення нових, похідних ознак на основі існуючих.

У задачах мультикласової класифікації цільова змінна Y може приймати значення з множини класів $\{C_1, C_2, \dots, C_m\}$. Для отримання оптимальної підмножини ознак було прийнято рішення кореляційний відбір ознак [75], заснований на аналізі статистичних залежностей між кожною ознакою та цільовою змінною. Оскільки зазвичай розподіл даних є відмінним від нормального (Гаусівського), для визначення кореляції використовується коефіцієнт Спірмена, який здатен виявляти монотонні, але не обов'язково лінійні залежності.

Основний підхід полягає у бінаризації цільової змінної шляхом створення m бінарних змінних Y_k , де $Y_k = 1$ якщо клас C_k і $Y_k = 0$ в іншому випадку, для $k = 1, 2, \dots, m$. Для кожної ознаки X_i розраховується коефіцієнт кореляції Спірмена з кожною бінарною змінною Y_k :

$$\rho_{ik} = \text{Spearman}(X_i, Y_k) \quad (2.78)$$

Після обчислення коефіцієнтів кореляції для всіх пар (X_i, Y_k) , визначається середнє абсолютне значення кореляції для кожної ознаки X_i :

$$\bar{\rho}_i = \frac{1}{m} \sum_{k=1}^m |\rho_{ik}| \quad (2.79)$$

Це середнє значення характеризує загальну важливість ознаки для класифікації між усіма класами. Ознаки з вищим значенням за формулою (2.79) вважаються більш інформативними.

Включення ознак, які демонструють сильну кореляцію між собою, може спричинити проблему мультиколінеарності, що негативно впливає на стабільність та інтерпретованість моделі. Для запобігання цьому слід оцінювати кореляцію між самими ознаками.

Кореляція між ознаками X_i та X_j також розраховується з використанням коефіцієнта Спірмена:

$$\rho_{ij} = \text{Spearman}(X_i, X_j) \quad (2.80)$$

Якщо абсолютне значення за формулою (2.80) перевищує заданий поріг θ (наприклад, 0.7), то ознаки X_i та X_j вважаються сильно корельованими, і в такому разі доцільно залишити лише одну з них – ту, яка має вище значення за формулою (2.79).

Таким чином, кореляційний відбір ознак забезпечує ефективне зменшення розмірності даних шляхом виключення як малозначущих, так і надлишкових ознак, що дозволяє покращити продуктивність моделі та уникнути негативних ефектів мультиколінеарності. Це особливо важливо у задачах з високою розмірністю, де зменшення кількості ознак є критично важливим для підвищення якості класифікації та зменшення обчислювальної складності.

Висновки до розділу 2

В даному розділі було представлено методологію та детальний опис послідовності формування сукупності інформативних ознак цифрових зображень. Показано значущість етапу вилучення ознак як початкового кроку у процесі їх оброблення та аналізу.

Проаналізовано й систематизовано широкий спектр сучасних методів вилучення ознак: від попереднього опрацювання, спрямованого на стандартизацію зображень, до різноманітних підходів формування описових характеристик (зокрема текстурних, гістограмних і багатомасштабних). Особливу увагу приділено методам, що дають змогу кількісно оцінювати різні аспекти зображень, створюючи базу для подальшого аналізу та класифікації.

Окремо розглянуто методи відбору найбільш інформативних ознак, критично важливі для зменшення розмірності даних і підвищення ефективності майбутніх моделей машинного навчання. В обґрунтуванні вибору кореляційного відбору ознак наголошено на його дієвості як засобу забезпечення якості та стабільності аналізу.

Таким чином, у розділі закладено методологічне підґрунтя для подальших етапів дисертаційного дослідження. Наведений комплекс методів формування та відбору інформативних ознак буде використано в аналізі цифрових зображень і розробленні системи підтримки прийняття рішень.

РОЗДІЛ 3

РОЗРОБЛЕННЯ МЕТОДИК ДЛЯ КЛАСИФІКАЦІЇ ЦИФРОВИХ ЗОБРАЖЕНЬ

На рис. 3.1 наведено приклад реалізації послідовності формування множини інформативних ознак на одному зі зображень ОІ.

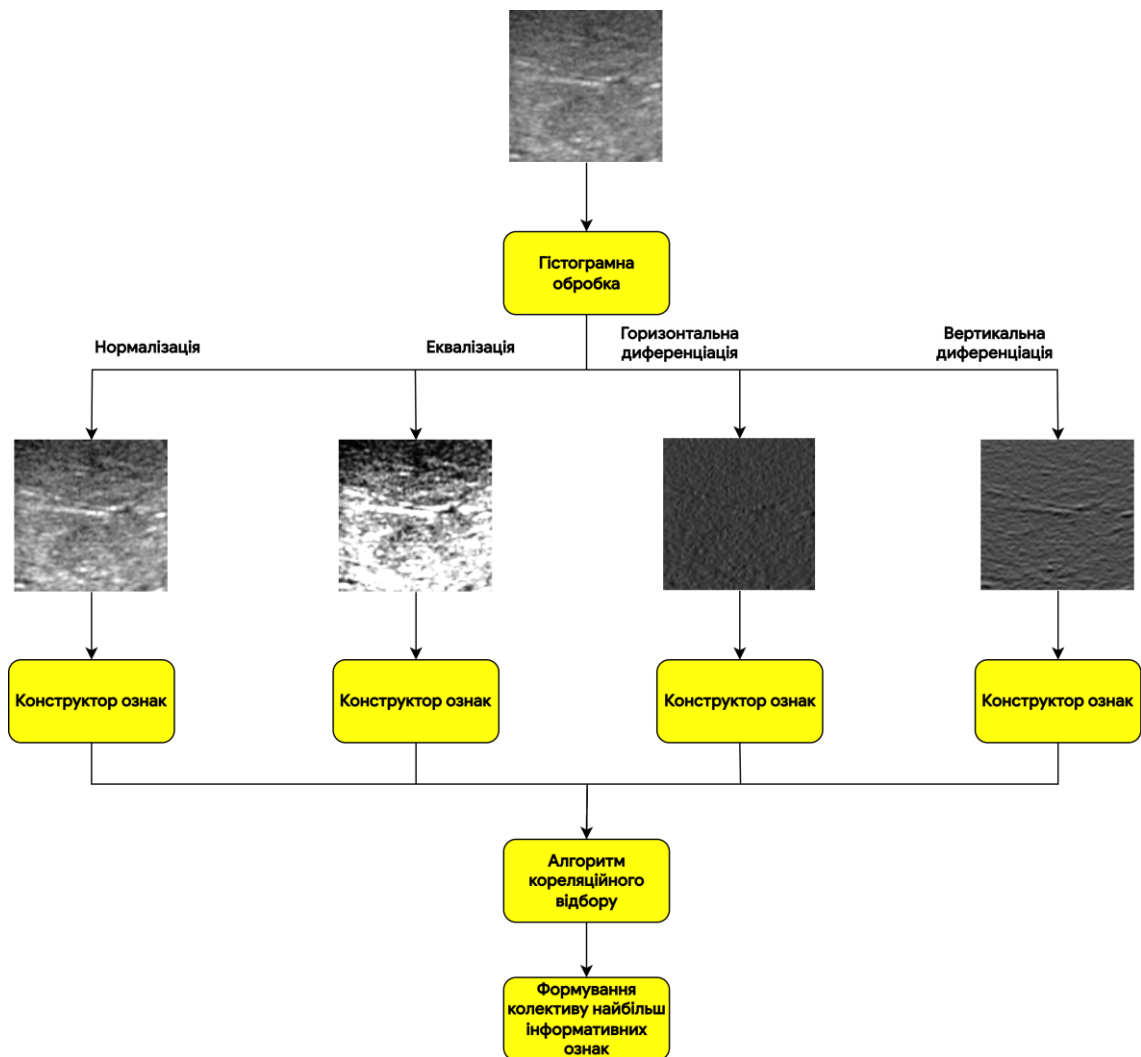


Рисунок 3.1 – Отримання колективу інформативних ознак зображення

Схема з рисунку вище відображає такі ключові етапи обробки:

- 1) подання первинного цифрового зображення на вхід послідовності;
- 2) паралельна гістограмна обробка зображення методами нормалізації, еквалізації та диференціації (горизонтальної й вертикальної);

- 3) формування нових зображень із модифікованими характеристиками після кожного етапу обробки;
- 4) генерування числових текстурних характеристик за допомогою «конструктора ознак» для кожного з отриманих результатів;
- 5) зведення отриманих числових характеристик у єдиний набір і проведення кореляційного відбору ознак;
- б) завершення процесу з формуванням набору найбільш значущих ознак для подальшого використання.

Відібрані інформативні ознаки надалі використовуються під час розроблення аналітичних моделей прогнозування з метою оцінювання стану об'єкта. Для цього було реалізовано технологію ієрархічної класифікації, що передбачає використання модифікації методу випадкового лісу [18] як одного з підходів. Дані методики класифікації цифрових зображень детальніше описані нижче.

3.1 Розроблення модифікованої версії методу випадкового лісу

Ансамблеве навчання базується на концепції використання сукупності моделей, які називають «слабкими учнями», для вирішення певної проблеми. Основна гіпотеза полягає в тому, що оптимальне поєднання прогнозів ансамблю моделей дозволяє досягти більш точних та надійних результатів. Мета-алгоритм ансамблевого навчання включає три основні методи об'єднання слабких учнів: бегінг, бустинг та стекінг.

Випадковий ліс є типовим прикладом реалізації бегінгу, де для розв'язання задачі застосовуються однорідні слабкі учні, які навчаються паралельно та незалежно один від одного. Їх результати агрегуються через процедуру усереднення. Цей підхід був розроблений в роботі [109] і залишається одним з провідних методів у сучасних класифікаційних задачах. Проте, класичний випадковий ліс має певні обмеження, що стали об'єктом дослідження та оптимізації у подальших роботах.

У попередніх дослідженнях дисертанта було запропоновано новий підхід до удосконалення класу алгоритмів випадкового лісу [5, 77]. В основу було покладено використання принципів методу групового урахування аргументів (МГУА) [17] під час навчання дерев рішень, що дозволяло отримати дерева оптимальної складності. Запропонований алгоритм був успішно застосований для розпізнавання патології на зображеннях УЗО печінки, де правильність класифікації досягала від 96% до 99%. Проте, попередній варіант алгоритму мав ряд недоліків, які в даному дослідженні були усунені.

Однією з ключових характеристик алгоритму випадкового лісу є застосування методу бутстреп-агрегації (бегінгу), що передбачає паралельне навчання різних дерев, незалежних одне від одного, з подальшою агрегацією для отримання узагальненого результату. Концепція бегінгу спрямована на зменшення впливу мінливості внаслідок варіативності вхідних даних, що дозволяє зменшити загальну похибку класифікації. Завдяки бутстреп-агрегації модель має можливість перетворити свої властивості з локальної апроксимації на глобальне узагальнення, підвищуючи стійкість і правильність прогнозів.

Кількість дерев у випадковому лісі є важливим параметром, що визначається мінімізацією похибки на контрольній вибірці. У класичній реалізації випадкового лісу цей підхід забезпечує ефективний механізм для запобігання перенавчанню, завдяки чому модель залишається стійкою до перенавчання під час роботи з великими даними. Для підвищення ефективності задач класифікації пропонується ряд додаткових механізмів, що включають оптимізацію параметрів моделі, структури дерев, а також покращення методів агрегації результатів, зокрема адаптивний вибір критеріїв розбиття та регуляризацію складності дерев у ансамблі.

3.1.1 Удосконалення дерева прийняття рішень

Алгоритми побудови випадкових лісів зазвичай використовують міри неоднорідності, такі як індекс Джині [38] або ентропія [34], для визначення

оптимальних порогів поділу в кожному вузлі дерева. У цій роботі пропонується використання коефіцієнта кореляції Метьюза (ККМ) [29] як критерію для визначення порогів розбиття діапазонів значень ознак. ККМ є узагальненою мірою якості класифікації, яка враховує всі аспекти задачі та забезпечує збалансовану оцінку, особливо у випадках зі значним дисбалансом між класами [29].

Побудова структури дерева рішень, включаючи вибір змінних у вузлах та визначення їх порогів, здійснюється через ітеративний пошук тих змінних і порогів, які максимізують значення функції вартості W :

$$W = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}, \quad (3.1)$$

де TP (True Positives) – кількість правильних прогнозів для позитивного класу; TN (True Negatives) – кількість правильних прогнозів для негативного класу; FP (False Positives) – кількість хибних позитивних прогнозів (помилка першого роду); FN (False Negatives) – кількість хибних негативних прогнозів (помилка другого роду) [10].

Чисельник формули (3.1) відображає коваріацію між спостережуваними та передбаченими значеннями, тоді як знаменник нормує W до діапазону $[-1, +1]$, забезпечуючи адекватну збалансованість навіть у випадках із сильною асиметрією класів.

Процес синтезу дерева рішень базується на принципах МГУА [17], із використанням двох вибірок: A (навчальна вибірка) та B (перевірна вибірка). Такий індуктивний підхід дозволяє створювати моделі зростаючої складності та обирати ту модель, яка досягає найвищої точності на перевірній вибірці B , тим самим забезпечуючи оптимальну складність.

У кожному вузлі дерева оптимальний поріг t_i для кожної незалежної змінної X_i визначається на основі навчальної вибірки A шляхом максимізації функції вартості W за формулою (3.2):

$$t_i^* = \arg \max_{t_i} W(X_i, t_i; A) \quad (3.2)$$

Після цього вибір змінної X_i для розбиття здійснюється на основі її ефективності на перевірній вибірці B :

$$X^* = \arg \max_{X_i} W(X_i, t_i^*; B) \quad (3.3)$$

Таким чином, використання функції вартості W (3.1) у поєднанні з індуктивним підходом МГУА дозволяє отримати моделі оптимальної складності, які демонструють високу здатність до узагальнення та високу точність (див. рис. 3.2).

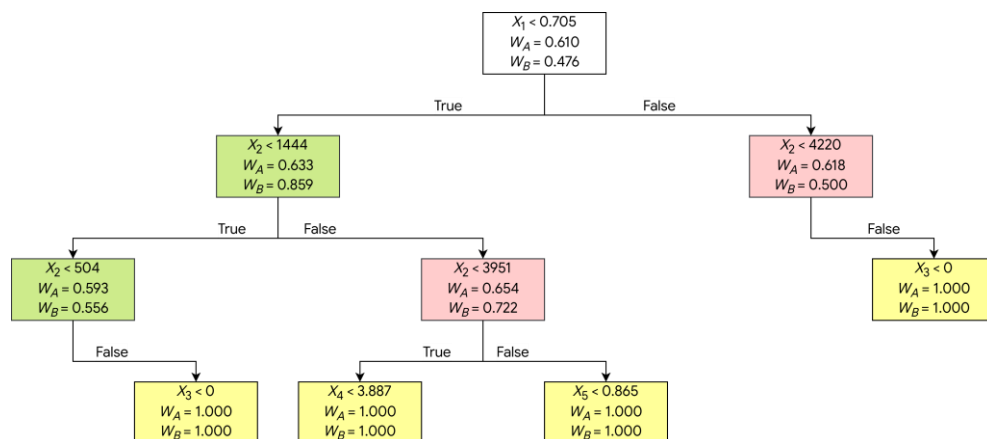


Рисунок 3.2 – Приклад дерева оптимальної складності.

На рис. 3.1 показано приклад дерева оптимальної складності, побудованого для задачі розпізнавання патологій на ультразвукових зображеннях печінки [77]. Правильність класифікації на контрольній вибірці склала від 94% до 97%, що підтверджує ефективність запропонованого методу.

3.1.2 Оптимізація набору ознак дерева генетичним алгоритмом

Побудова лісу дерев оптимальної складності ґрунтується на застосуванні принципу бегінгу (рис. 3.3), вперше запропонованого Лео Брейманом [23, 25].

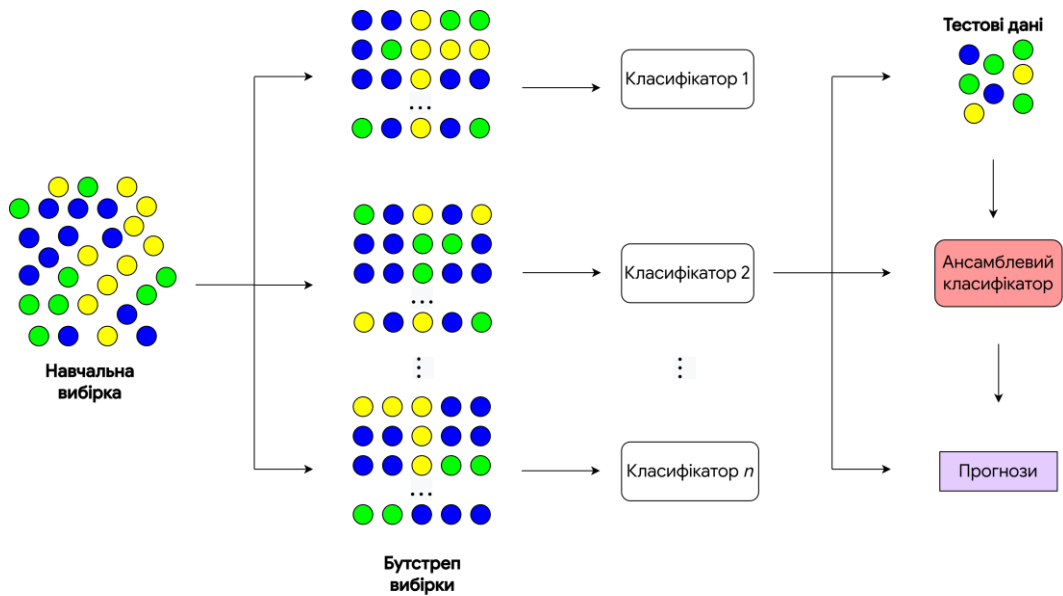


Рисунок 3.3 – Демонстрація принципу бегінгу

Основна мета бегінгу полягає у підвищенні точності прогнозування шляхом агрегування результатів, отриманих з різних випадково згенерованих підвбірок навчальних даних. Як було доведено Брейманом [24], цей підхід суттєво покращує результати для нестабільних алгоритмів, таких як дерева рішень та нейронні мережі. Бегінг використовує концепцію «мудрості натовпу», тобто кінцевий прогноз формується на основі колективного рішення множини моделей, а не окремої моделі. Це дає змогу зменшити вплив випадкових помилок, за умови, що ці помилки некорельовані між різними моделями. Формула агрегованого прогнозу наступна:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N T_i(x) \quad (3.4)$$

де $T_i(x)$ – прогноз i -го дерева для об'єкта x , N – загальна кількість дерев у лісі.

Для досягнення ефективності такого підходу необхідна різноманітність і спеціалізація моделей, що у випадку дерев рішень досягається шляхом навчання на різних підвбірках даних. Оскільки дерева рішень є чутливими

до варіацій у вхідних даних, навіть незначні зміни у складі навчальної вибірки можуть призводити до побудови різних структур дерев.

При формуванні лісу дерев оптимальної складності бегінг генерує N навчальних підвибірок D_i , де $i = 1, 2, \dots, N$, шляхом випадкового вибору з початкової вибірки D_i з поверненням. Кожна навчальна підвибірка D_i відповідно до принципів МГУА [17] поділяється на підвибірки A_i (тренувальна вибірка) та B_i (перевірна вибірка), що продемонстровано на рис. 3.4.

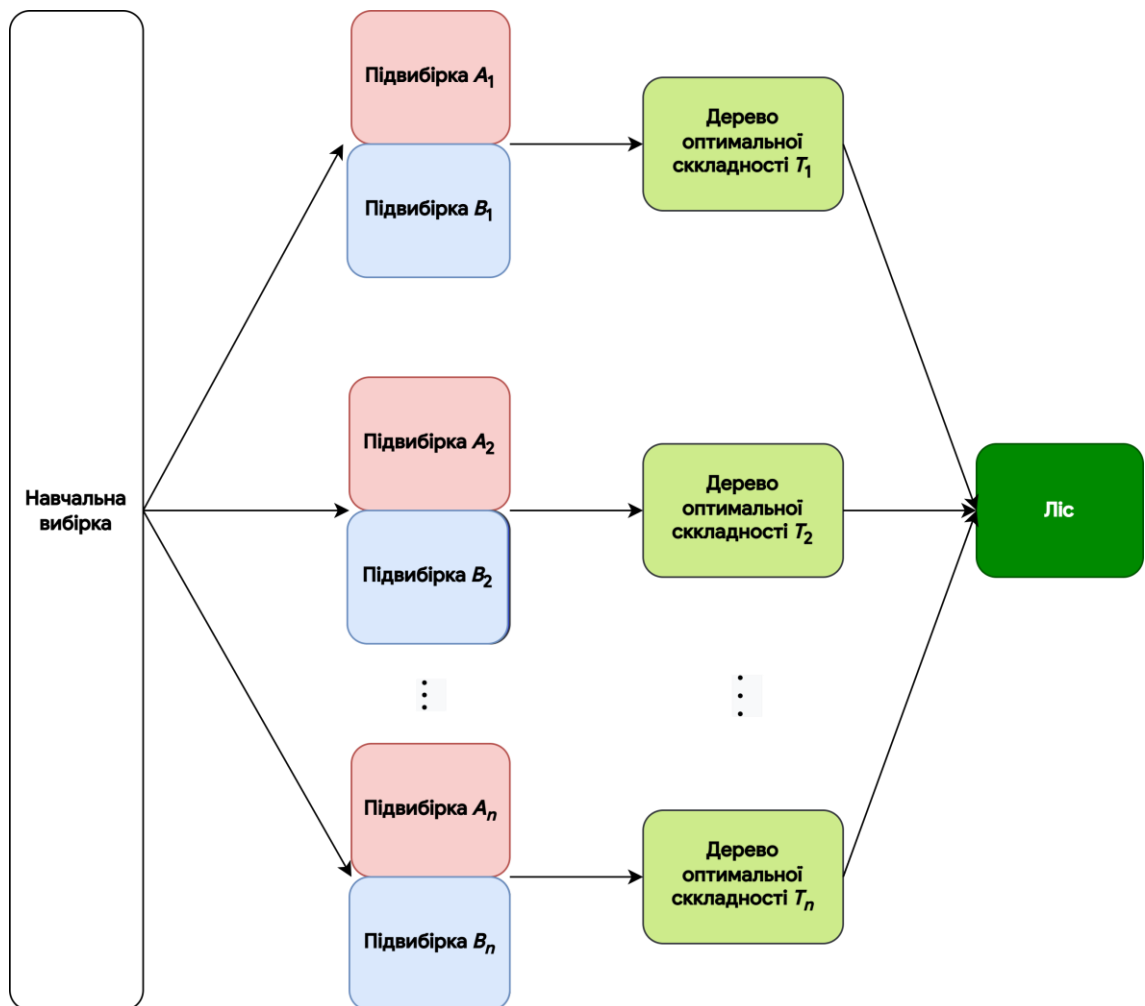


Рисунок 3.4 – Узагальнений ліс дерев оптимальної складності

Як і у випадку класичного випадкового лісу, запропонований підхід спрямований на формування ансамблю дерев рішень, кожне з яких навчається на підвибірках A_i та B_i , що частково перетинаються між собою

при $N \rightarrow \infty$. Використовуючи принципи МГУА разом із бегінгом, формується випадковий ліс дерев оптимальної складності (ВЛДОС), що забезпечує ефективну класифікацію. Особливістю цього підходу є застосування випадкового підпростору ознак для кожного дерева [109]. Для кожного вузла дерева випадково вибирається підмножина ознак $F \subseteq \{X_1, X_2, \dots, X_M\}$, де M – загальна кількість ознак, а розмір підмножини $|F| = m \ll M$. Це дозволяє зменшити кореляцію між окремими деревами в лісі. Проте, проблема оптимальності побудованих дерев залишається актуальною, оскільки результати можуть варіюватися при повторному запуску алгоритму. Для вирішення цієї проблеми використовується генетичний алгоритм [4, 5, 53, 80]. Оптимізація реалізується через такі кроки:

1) генерація початкової популяції з N хромосом, де кожна хромосома C_i представляє підмножину ознак F_i (3.5) для підвибірок A_i та B_i ;

$$C_i = (F_i), \quad i = 1, 2, \dots, N \quad (3.5)$$

2) для кожної хромосоми C_i будується дерево оптимальної складності T_i , тренуване на підвибірці A_i з використанням ознак з F_i .

3) оцінка пристосованості кожного дерева T_i на валідаційній вибірці V_i за допомогою цільової функції генетичного алгоритму W (3.1); пристосованість хромосоми C_i визначається як $W_i = W(T_i, V)$

4) відбір найкращих хромосом на основі значень пристосованості, що здійснюється методом пропорційного відбору (рулетка):

$$P(C_i) = \frac{W_i}{\sum_{j=1}^N W_j} \quad (3.6)$$

5) застосування оператора кросоверу для пар хромосом для обміну інформацією та створення нових підмножин ознак; використовується одноточковий кросовер між хромосомами C_i та C_j :

$$C'_i = (F_i[1:k] \cup F_j[k+1:m]), \quad (3.7)$$

$$C'_j = (F_j[1:k] \cup F_i[k+1:m]), \quad (3.8)$$

де k – точка кросоверу, m – довжина хромосоми.

6) застосування оператора мутації для окремих хромосом для випадкової зміни ознак у підмножині F_i . Імовірність мутації p_m зазвичай обирається малою ($p_m \approx 0.01$). Мутація полягає у випадковій зміні значення гена:

$$F'_i = F_i \oplus \delta, \quad (3.9)$$

де δ – випадкова зміна.

7) формування нового покоління хромосом із нащадків та кращих особин попереднього покоління (елітна селекція);

8) якщо досягнуто максимуму цільової функції або перевищено заданий ліміт епох G , алгоритм зупиняється; інакше повертаємося до кроку 2.

Цільова функція генетичного алгоритму W визначається як ККМ. Результатом цього процесу є ансамбль моделей ВЛДОС, що складається з N дерев із оптимальними підвибірками незалежних змінних.

3.1.3 Використання методу аналізу ієрархій для голосування

Оптимізація колективного прийняття рішень у задачах машинного навчання може бути досягнута шляхом застосування зважених підходів до процедури голосування. Зокрема, один із ефективних способів покращення агрегації результатів різних моделей полягає у використанні зваженого голосування, базованого на методі аналізу ієрархій Сааті [4, 5, 80, 86].

Запропонований підхід передбачає надання кожному дереву в моделі ВЛДОС вагового коефіцієнта w_i , який визначає пріоритет кращих моделей під час голосування. Вагові коефіцієнти визначаються через механізм

попарного порівняння критеріїв (табл. 3.1), що реалізується за допомогою методу аналізу ієрархій.

Таблиця 3.1 – Загальна форма попарного порівняння критеріїв

	y_1	y_2	...	y_n
y_1	$\frac{v_1}{v_1}$	$\frac{v_2}{v_1}$...	$\frac{v_n}{v_1}$
y_2	$\frac{v_1}{v_2}$	$\frac{v_2}{v_2}$...	$\frac{v_n}{v_2}$
...
y_n	$\frac{v_1}{v_n}$	$\frac{v_2}{v_n}$...	$\frac{v_n}{v_n}$

де v_i є рангом моделі (v_1 відповідає найкращій моделі, v_n – найгіршій).

Після визначення v_i для кожної моделі, матриця попарних порівнянь заповнюється, і для кожного рядка i обчислюється середнє геометричне значення G_i :

$$G_i = \left(\prod_{j=1}^n a_{ij} \right)^{\frac{1}{n}}, \quad (3.10)$$

де a_{ij} – елемент матриці попарних порівнянь з табл. 3.1.

Потім значення середніх геометричних нормуються за формулою:

$$w_i = \frac{G_i}{\sum_{k=1}^n G_k}, \quad i = 1, 2, \dots, n \quad (3.11)$$

де w_i – ваговий коефіцієнт для i -го дерева, $0 < w_i < 1$.

Якість моделі визначається за значеннями функції W (див. 3.1) на валідаційній вибірці.

Приклад:

Припустимо, що побудовано модель ВЛДОС із $n = 11$ дерев, а значення функції W на валідаційній вибірці наступні: $\{0.821, 0.766, 0.749, 0.747, 0.766, 0.745, 0.575, 0.808, 0.749, 0.821, 0.823\}$. Ранжований ряд виглядає так: $v = \{2, 4, 5, 6, 4, 7, 8, 3, 5, 2, 1\}$.

Після побудови матриці попарних порівнянь та обчислення середніх геометричних значень G_i для кожного рядка за формулою (4.10) виконуємо їхню нормалізацію за формулою (4.11).

Отримані вагові коефіцієнти: $\{w_1 = 0.14, w_2 = 0.093, w_3 = 0.07, w_4 = 0.047, w_5 = 0.093, w_6 = 0.047, w_7 = 0.023, w_8 = 0.116, w_9 = 0.07, w_{10} = 0.14, w_{11} = 0.163\}$.

Отримані коефіцієнти використовуються як ваги для дерев моделі ВЛДОС під час голосування.

Остаточна класифікація здійснюється за допомогою функції адитивної згортки F_{ac} :

$$F_{ac} = \sum_{i=1}^n w_i \cdot y_i, \quad (3.12)$$

де y_i результат класифікації (-1 або $+1$), отриманий i -им деревом моделі ВЛДОС.

Значення функції F_{ac} варіюється в інтервалі $[-1, +1]$. Остаточний результат класифікації визначається за правилом: «Якщо $F_{ac} < 0$, то об'єкт належить до першого класу; інакше – до другого класу».

Таким чином, застосування зваженого голосування із використанням методу аналізу ієрархій Сааті дозволяє підвищити точність колективного рішення, оскільки надає більшу вагу моделям, що продемонстрували вищу якість на валідаційній вибірці.

3.1.4 Порівняння з аналогічними методами ансамблевого навчання

Найбільш відомими й широко застосовуваними методами ансамблевого навчання є:

1) випадковий ліс [25, 79, 109] – це метод, що використовує множину дерев рішень із подальшим голосуванням більшості (класифікація) або усередненням (регресія). Головними його особливостями є застосування бутстреп-зразків і випадкового вибору підмножини ознак, що знижує кореляцію між деревами й підвищує узагальнюючу здатність моделі.

2) XGBoost [28] – це оптимізований алгоритм градієнтного бустингу, який базується на поетапному додаванні дерев для мінімізації певної функції втрат. Цільова функції алгоритму XGBoost має вигляд:

$$L = \sum_{i=1}^N l(y_i, \hat{f}(x_i)) + \sum_k \Omega(h_k), \quad (3.13)$$

де: l – функція втрат (наприклад, квадратична), $h_k(x)$ – дерево, додане на k -му кроці, а $\Omega(h_k)$ – функція регуляризації, що контролює складність дерев. Кожне наступне дерево додається завдяки градієнтній мінімізації втрат, що дає змогу швидко й ефективно знаходити оптимальні розбиття.

3) LightGBM [54] – ще один метод градієнтного бустингу з низкою оптимізацій. Модель формується як сума дерев $h_k(x)$. Серед основних особливостей LightGBM – використання гістограмної апроксимації ознак для дискретизації значень, методу односторонньої вибірки на основі градієнту для зменшення обсягу вибірки та агрегації мало корельованих ознак. Ці рішення підвищують ефективність побудови глибоких дерев на великих наборах даних.

Метод ВЛДОС виявляє низку переваг у порівнянні з іншими ансамблевими підходами, проте водночас має певні обмеження. Ключовою особливістю ВЛДОС є використання принципів МГУА для побудови дерев оптимальної складності, що дає змогу мінімізувати перенавчання та підвищити узагальнюючу здатність моделі. Це істотно вирізняє метод від класичного випадкового лісу, де складність дерев нерідко визначається евристично.

Важливим елементом ВЛДОС є застосування ККМ як критерію розбиття вузлів. Такий критерій забезпечує збалансовану оцінку якості класифікації навіть у ситуаціях зі значним дисбалансом класів, що підвищує ефективність методу в завданнях медичної діагностики чи виявлення шахрайства порівняно з XGBoost і LightGBM, які зазвичай використовують індекс Джині або ентропію. Крім того, у ВЛДОС результати агрегуються за допомогою зваженого голосування з використанням методу аналізу ієрархій Сааті, що дає змогу надавати вищі ваги деревам із кращою якістю прогнозу та підвищувати загальну точність класифікації порівняно з простим усередненням.

Оптимізація набору ознак у ВЛДОС здійснюється за допомогою генетичного алгоритму, який надає змогу адаптивно відбирати ознаки з урахуванням мінімізації кореляції між деревами. Цей підхід відрізняється від традиційного випадкового лісу, де підмножини ознак формуються випадково, та від градієнтного бустингу (XGBoost, LightGBM), що підбирає ознаки через мінімізацію втрат. Водночас використання генетичних операторів (кросовер, мутація) й ітеративна оцінка якості дерев істотно збільшують обчислювальні витрати, унаслідок чого масштабованість ВЛДОС обмежена у завданнях із великою кількістю даних.

Серед недоліків ВЛДОС варто відзначити потребу в ретельному налаштуванні гіперпараметрів (ймовірність мутацій, кількість поколінь тощо), що може ускладнювати використання методу порівняно зі стандартизованими рішеннями, як-от XGBoost. Крім того, ефективність зваженого голосування значною мірою залежить від якості та репрезентативності валідаційної вибірки, і за недостатніх даних можуть виникати похибки.

Таким чином, ВЛДОС є перспективним інструментом у задачах, які потребують високої точності й супроводжуються дисбалансом класів (наприклад, у медичній діагностиці чи виявленні рідкісних подій). Переваги методу роблять його конкурентоспроможним у нішах, де критичною є саме

точність. Натомість для великомасштабних або потокових завдань доцільніше застосовувати XGBoost та LightGBM, що пропонують кращу масштабованість та нижчі обчислювальні витрати. Подальші дослідження можуть бути зосереджені на підвищенні обчислювальної ефективності ВЛДОС та автоматизації вибору його параметрів.

Крім того, експериментальні результати, наведені в попередніх дослідженнях [3, 7, 8, 18, 93, 116], свідчать про високу ефективність методу ВЛДОС у розв'язанні задач класифікації, оскільки спостерігається істотне покращення точності та узагальнюючої здатності моделей. Як приклад, у табл. 3.2 наведено результати бінарної класифікації типу «норма-патологія», отримані за допомогою моделей логістичної регресії, AdaBoost, випадкового лісу та ВЛДОС, побудованих на множині текстурних ознак [18].

Таблиця 3.2 – Результати класифікації «норма-патологія»

Метод класифікації	Точність	F-score	ККМ
Дані конвексного датчику			
Логістична регресія	0.71	0.66	0.33
AdaBoost	0.71	0.64	0.32
Випадковий ліс	0.74	0.63	0.44
ВЛДОС	0.90 (0.87)*	0.89 (0.788)	0.80 (0.69)
Дані лінійного датчику			
Логістична регресія	0.88	0.87	0.78
AdaBoost	0.75	0.75	0.50
Випадковий ліс	0.88	0.87	0.78
ВЛДОС	1.00 (0.88)	1.00 (0.87)	1.00 (0.78)
Дані посиленого лінійного датчику			
Логістична регресія	0.92	0.90	0.82
AdaBoost	0.62	0.58	0.16
Випадковий ліс	0.62	0.38	-0.19
ВЛДОС	1.00 (0.92)	1.00 (0.90)	1.00 (0.822)

З наведених результатів видно, що в задачі виявлення патології печінки на основі ультразвукових зображень точність класифікації моделей ВЛДОС

* в дужках наведені результати застосування ВЛДОС із голосуванням за більшістю.

коливалася від 90.3% до 100% на тестовій вибірці. Серед інших методів найбільш ефективними виявилися моделі логістичної регресії, які досягли точності в діапазоні від 71% до 92.3%. Окрім того, застосування зваженого голосування на основі методу аналізу ієрархій дозволило отримати максимальну точність на вибірках лінійних датчиків обох типів. Такий результат частково пояснюється невеликим обсягом цих вибірок, про що свідчить зниження точності до 90.3% для більшої вибірки об'єктів дослідження, отриманої за допомогою конвексного датчика.

3.2 Розроблення технології ієрархічної класифікації

Принцип технології ієрархічної класифікації подано у вигляді пірамідної діаграми (рис. 3.5).

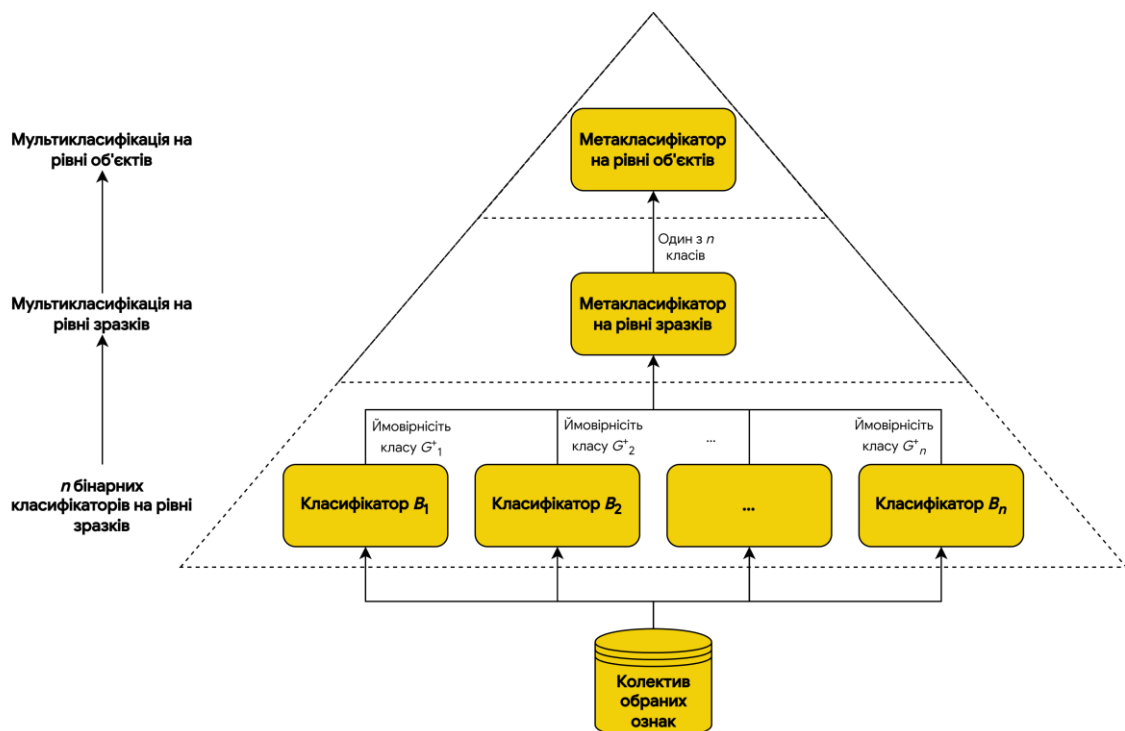


Рисунок 3.5 – Технологія ієрархічної класифікації

Подана блок-схема відображає процес багаторівневої класифікації об'єктів на основі ансамблю класифікаторів [3]. Система призначена для

ефективного розв'язання мультикласових задач, використовуючи характеристики, отримані з зображень ОІ. Технологія ієрархічної класифікації застосовує групову техніку побудови моделей як альтернативу класичним підходам «один проти всіх» і «один проти одного». Передбачається об'єднання схожих класів у групи з метою зменшення кількості моделей і мінімізації проблеми дисбалансу класів. Нижче наведено детальний покроковий аналіз цієї схеми.

3.2.1 Етап 1 – побудова множини групових класифікаторів

На першому етапі будується множина n бінарних класифікаторів B_i , кожен із яких розрізняє між двома групами класів, об'єднаних за схожістю. Для множини класів $C = \{C_0, C_1, \dots, C_K\}$ групові класифікатори ділять класи наступним чином:

- 1) класифікатор B_1 : розрізняє групу $G_1^- = \{C_0\}$ від групи $G_1^+ = \{C_1, C_2, \dots, C_K\}$.
- 2) класифікатор B_2 : розрізняє групу $G_2^- = \{C_0, C_1\}$ від групи $G_2^+ = \{C_2, C_3, \dots, C_K\}$.
- 3) класифікатор B_3 : розрізняє групу $G_3^- = \{C_0, C_1, C_2\}$ від групи $G_3^+ = \{C_3, C_4, \dots, C_K\}$.

Цей процес продовжується, доки не будуть враховані всі класи. Кожен класифікатор B_i діє згідно з наступною функцією:

Переваги подібного підходу:

- 1) Менша кількість моделей у порівнянні з традиційними стратегіями побудови. Це дозволяє менше навантажувати систему і спрощує процес моделювання, що сприяє підвищенню загальної ефективності [22].

- 2) Мінімізація впливу дисбалансу класів: об'єднання класів у групи дозволяє збалансувати розподіл даних між позитивним і негативним класами.

- 3) Підвищення узагальнюючої здатності: зменшення кількості моделей зменшує ризик перенавчання, що робить модель більш стійкою до змін у даних та підвищує її здатність до узагальнення.

Навчання базових класифікаторів здійснюється шляхом мінімізації бінарної функції втрат, а саме – логістичної втрати:

$$\mathcal{L}_i = -\frac{1}{N} \sum_{j=1}^N \left[y_{ij} \log P_i(x_j) + (1 - y_{ij}) \log (1 - P_i(x_j)) \right], \quad (3.14)$$

де $P_i(x_j)$ – ймовірність позитивного класу, передбачена класифікатором B_i для зразка x_j , а y_{ij} – істинна мітка (1 або 0).

3.2.2 Етап 2 – мультикласифікація на рівні зразків

Виходи базових класифікаторів для кожного зразка (OI) об'єднуються у вектор ймовірностей позитивних класів:

$$p_S = [P_1(x), P_2(x), \dots, P_n(x)]^T \in [0,1]^n \quad (3.15)$$

Мета-класифікатор на рівні OI, позначений як M_S , використовує цей вектор ймовірностей для прогнозування класу OI:

$$y_S = M_S(p_S) = \arg \max_{c \in \mathcal{C}} P(c | p_S) \quad (3.16)$$

Навчання мета-класифікатора може бути здійснено за допомогою мультиноміальної логістичної регресії, нейронних мереж або інших методів, мінімізуючи функцію втрат:

$$\mathcal{L}_S = -\frac{1}{N} \sum_{j=1}^N \sum_{c=0}^K y_{jc} \log P(c | p_{S_j}), \quad (3.17)$$

де y_{jc} є індикаторною функцією, що дорівнює 1, якщо зразок j належить класу c , і 0 в іншому випадку.

Переваги використання мета-класифікатора:

1) обробка складних залежностей: мета-класифікатор може враховувати залежності між виходами окремих класифікаторів, що забезпечує більш точний і надійний результат.

2) підвищення стійкості до шумів: завдяки використанню узагальнених характеристик від базових моделей мета-класифікатор має підвищену стійкість до наявності шумів та викидів у даних.

3.2.3 Етап 3 – мультикласифікація на рівні об'єктів

Для кожного об'єкта (пацієнта) збираються вектори ймовірностей із усіх його ОІ, тобто кожен регіон, що був визначений і проаналізований на попередніх етапах, передає інформацію, яка узагальнюється для формування єдиного вектора ймовірностей для об'єкта:

$$P_o = [p_{s_1}, p_{s_2}, \dots, p_{s_m}]^T \in [0,1]^{m \times n} \quad (3.18)$$

Це забезпечує урахування всіх можливих проявів патології в межах зразка. Мета-класифікатор на рівні зразка використовує ці вектори для остаточного прогнозу, здійснюючи інтеграцію інформації з різних областей, що дозволяє формувати більш надійний діагноз. Кожен вектор ймовірностей, отриманий на рівні ОІ, є індикатором потенційних патологічних ознак, і цей підхід дозволяє комбінувати їх для отримання комплексної оцінки стану пацієнта:

$$y_o = M_o(P_o) = \arg \max_{c \in C} P(c | P_o) \quad (3.19)$$

Важливо зазначити, що мета-класифікатор на рівні об'єктів приймає вхідний вектор ймовірностей, що дозволяє врахувати не тільки самі прогнози, але і ступінь їхньої впевненості. Це означає, що при прийнятті рішення враховується невизначеність та вірогідність прогнозів базових класифікаторів, що особливо важливо у випадках, коли діагностика повинна бути дуже точною.

Методи інтеграції:

1) агрегація ймовірностей: обчислення середнього або максимального значення ймовірності для кожного класу. Цей метод дозволяє отримати загальну оцінку, яка базується на середньостатистичній або найбільш вірогідній оцінці кожної з областей інтересу.

2) ймовірнісні моделі: побудова моделей, що враховують кореляцію між прогнозами різних ОІ. Це дозволяє врахувати можливі залежності між областями, які можуть містити подібні чи взаємозалежні патологічні ознаки, що підвищує загальну ефективність діагностики.

3.2.4 Порівняння з традиційними методами мультикласифікації

Запропонована технологія ієрархічної класифікації має низку суттєвих переваг порівняно з класичними підходами на кшталт «один проти всіх» та «один проти одного». По-перше, вона дає змогу зменшити кількість моделей завдяки стратегії групування схожих класів. На відміну від методу «один проти всіх», що потребує створення k моделей для k класів, або «один проти одного», де їх кількість сягає $k(k - 1) / 2$, ієрархічний підхід об'єднує класи в групи, помітно скорочуючи обчислювальні витрати й спрощуючи управління моделями. Таке групування також допомагає збалансувати дані за позитивними та негативними прикладами, що важливо для рідкісних або малопредставницьких категорій.

Серед ключових переваг варто відзначити підвищення узагальнюючої здатності системи. Зменшення кількості моделей знижує ризик перенавчання, сприяючи кращій стійкості до шуму та варіацій у вхідних даних. Крім того, використання мета-класифікаторів на рівні зразків і об'єктів дає змогу інтегрувати прогнози базових моделей з урахуванням складних залежностей між ними. Наприклад, у медичній діагностиці такий підхід підвищує точність визначення стану пацієнта завдяки агрегації ймовірностей із різних сфер дослідження. Мета-класифікатори в такому разі виявляють стійкість до шуму, оскільки використовують узагальнені характеристики, отримані від ансамблю базових класифікаторів.

Утім, дана технологія не позбавлена недоліків. Насамперед її ефективність значною мірою залежить від коректності групування класів: помилкове об'єднання може призвести до втрати інформації та зниження точності класифікації. Це часто вимагає залучення експертних знань або проведення глибокого аналізу даних для визначення оптимальних груп. Крім того, реалізація мета-класифікаторів (зокрема, на основі нейронних мереж чи мультиноміальної логістичної регресії) ускладнює процес навчання та інтерпретації результатів порівняно зі спрощеними методами. Технологія також менше підходить для задач із неструктурованими або хаотично розподіленими класами, де традиційні ансамблеві методи можуть виявитися більш практичними. Окрему складність становлять обчислювальні витрати на тренування мета-моделей у випадку великих наборів даних, що може обмежувати можливості застосування в реальному часі.

Загалом, технологія ієрархічної класифікації є перспективною методикою для розв'язання багатокласових задач, у яких чітко простежується структура або схожість між класами. Вона пропонує збалансований компроміс між зниженням обчислювального навантаження, вирівнюванням класів і підвищенням стійкості моделей. Успішне застосування цієї технології вимагає ретельного проектування ієрархічної структури та врахування специфіки даних. Майбутні дослідження можуть бути зосереджені на розробленні автоматизованих методів групування класів і вдосконаленні архітектур мета-класифікаторів з метою розширення сфери її використання.

Висновки до розділу 3

В даному розділі були розглянуті теоретичні та методологічні засади розроблення вдосконалених методів класифікації цифрових зображень. Наукова новизна запропонованих рішень полягає в інтеграції сучасних підходів машинного навчання з адаптивними алгоритмами оптимізації,

орієнтованими на підвищення точності та узагальнюючої здатності моделей в умовах дисбалансу даних.

Було розроблено модифікацію ансамблевих методів, що базується на поєднанні ітеративного відбору ознак, критеріїв класифікації та механізмів колективного ухвалення рішень. Такий підхід дає змогу мінімізувати перенавчання, зменшити кореляцію між компонентами ансамблю й забезпечити збалансоване оцінювання результатів навіть за суттєвої нерівномірності розподілу класів. Особливу увагу приділено впровадженню ієрархічного підходу, що передбачає стратегічне групування класів і багаторівневу інтеграцію прогнозів. Така методологія сприяє зниженню обчислювального навантаження, підвищенню стійкості моделей до шуму та ефективному вирівнюванню дисбалансу даних.

Порівняльний аналіз розроблених методів із традиційними підходами підтвердив їхню дієвість у контексті складних багатокласових задач, зокрема тих, що вимагають високої інтерпретованості результатів. Водночас виявлено обмеження, пов'язані з обчислювальною складністю та необхідністю ретельного добору гіперпараметрів, що зумовлює важливість подальшої оптимізації алгоритмів.

У перспективі передбачено розроблення автоматизованих механізмів налаштування моделей, удосконалення методів групування класів у межах ієрархічних структур та адаптацію запропонованих підходів до роботи з динамічними або великомасштабними наборами даних. Отримані результати можуть слугувати теоретичним підґрунтям для впровадження розроблених методик у сферах, де надзвичайно важливими є точність, надійність та здатність до інтерпретації, зокрема у спеціалізованій візуалізації та аналізі складних мультимодальних даних.

РОЗДІЛ 4

ЗАСТОСУВАННЯ РОЗРОБЛЕНОЇ ТЕХНОЛОГІЇ АНАЛІЗУ ЦИФРОВИХ ЗОБРАЖЕНЬ В ПРИКЛАДНИХ ЗАДАЧАХ

У цьому розділі представлено реалізацію запропонованої універсальної технології аналізу цифрових зображень, яка дозволяє розв'язати дві основні задачі, сформульовані в межах даного дослідження:

- 1) стадіювання фіброзу печінки;
- 2) ідентифікація COVID-асоційованих патологій легень.

Реалізація цих завдань дасть змогу оцінити ефективність запропонованої технології та визначити її потенційне застосування в аналогічних дослідницьких і практичних задачах. Водночас, перш ніж перейти до безпосереднього розгляду способів розв'язання зазначених задач, необхідно детально описати умови, за яких здійснювалися експериментальні дослідження.

4.1 Умови проведення експериментальних досліджень

В даній роботі для розробки та навчання моделей класифікації використовувалась мова програмування *Python*, що давно є золотим стандартом. Обчислення здійснювалися на персональному комп'ютері, оснащеному процесором Intel Core i5-9300H (4 ядра, 2.4 ГГц). Система мала 16 ГБ оперативної пам'яті типу DDR4, що дозволяло забезпечити ефективну обробку великих обсягів даних без суттєвих втрат продуктивності. Для прискорення операцій моделювання використовувався графічний процесор NVIDIA GeForce GTX 1660 Ti з 6 ГБ пам'яті. Зберігання даних відбувалося на SSD об'ємом 512 ГБ, що забезпечувало високошвидкісний доступ до даних. Операційна система Windows 10 22H2 слугувала стабільною платформою для експериментального дослідження.

4.1.1 Розбиття даних перед моделюванням

Для аналізу медичних зображень було розроблено методологію поділу даних, яка забезпечує унікальність віднесення зображень одного пацієнта до певної вибірки (або навчальної, або перевірної, або контрольної). Такий підхід запобігає феномену витіку даних (англ. data leakage) [90], який виникає, коли модель отримує доступ до інформації, що в реальних умовах не є доступною на момент використання. Витік даних означає, що модель «передбачає» результати на основі непрямой інформації, яку не мала б мати під час навчання, що призводить до завищених показників точності на етапі тренування, але поганої узгодженості з реальними даними під час практичного застосування. Ця проблема суттєво впливає на узагальнюючу здатність моделі, знижуючи її ефективність у реальних умовах експлуатації, що є критично важливим у клінічному середовищі.

Існують два основні підходи до поділу даних:

- 1) поділ на навчальну, перевірну і контрольну вибірки;
- 2) перехресна перевірка.

Традиційний підхід передбачає виділення 60%, 20% та 20% даних для навчання, перевірки та контролю відповідно. У цьому процесі модель тренується на навчальній вибірці, а оптимізація гіперпараметрів здійснюється з використанням перевірної вибірки. Після визначення оптимальних гіперпараметрів, модель дотреновується на об'єднаній навчальній і перевірній вибірках, а остаточна оцінка її ефективності проводиться на контрольній вибірці, яка не бере участі в навчанні моделі. Це можна порівняти з підготовкою студента до екзамену: спочатку він вирішує завдання на основі вивчених прикладів (навчальна вибірка), потім тренується на схожих завданнях (перевірна вибірка), а на екзамені вирішує нові, ще не знайомі завдання (контрольна вибірка).

Перехресна перевірка передбачає поділ даних на навчальну і контрольну вибірки (наприклад, 80/20), з подальшим навчанням за допомогою перехресної перевірки. Під час перехресної перевірки навчальна

вибірка поділяється на навчальні та перевірні підвибірки k разів, що дозволяє моделі тренуватись і тестуватись на різних наборах даних. Остаточні гіперпараметри обираються шляхом усереднення результатів на всіх k перевірних вибірках, а остаточна перевірка моделі виконується на контрольній вибірці.

З урахуванням складності задачі мультикласифікації, що розв'язується в цьому дослідженні за допомогою ієрархічного підходу із 3-рівневою структурою моделювання (рис. 3.5), було прийнято рішення поєднати два вищенаведені підходи. Спочатку загальна вибірка даних поділяється на навчальну вибірку (T), контрольну (C_1) та другу контрольну (C_2) вибірки. Перехресна перевірка застосовується для підбору оптимальних гіперпараметрів кожної моделі з використанням вибірки T . Після цього множина моделей оцінюється на C_1 для вибору найкращої, а остаточна оцінка ієрархії моделей виконується на C_2 .

З огляду на специфіку даних (медичні зображення пацієнтів), важливо, щоб навчальна, перевірна та контрольна вибірки містили дані від різних, незалежних груп пацієнтів. Стратифікація вибірок гарантує збереження початкового розподілу класів, що підвищує репрезентативність та надійність моделі.

Для підбору оптимальних гіперпараметрів моделі рекомендовано використовувати метод стратифікованої групової перехресної перевірки, де стратифіковане групування здійснюється за ідентифікаторами пацієнтів, щоб запобігти перекриттю інформації між вибірками. Також необхідно ретельно відстежувати ідентифікатори пацієнтів протягом усього процесу поділу даних, щоб забезпечити відсутність перетину між навчальною, перевірною та контрольною вибірками.

4.1.2 Побудова моделі прогнозування

Було прийнято рішення скористатися підходом ансамблевого навчання, який надає змогу поєднувати прогнози кількох моделей для підвищення надійності та правильності класифікації. Попередні дослідження дисертанта

свідчать про високу ефективність цього підходу, що обґрунтовує його доцільність для даного контексту.

В межах даного дослідження окрім використання алгоритму ВЛДОС, описаного у розділі 3, було обрано низку інших алгоритмів ансамблевого навчання для розв'язання поставлених завдань, а саме: випадковий ліс, XGBoost та LightGBM. Дані методи ансамблевого навчання здатні швидко та ефективно обробляти великі дані, оскільки реалізовані в них алгоритми побудови дерев можуть бути паралелізовані та оптимізовані під апаратні архітектури. Крім того, деревоподібні структури під час моделювання дозволяють ефективно знаходити важливі ознаки та враховувати складні взаємодії без необхідності спеціальної інженерії ознак.

Для кожного з чотирьох методів ансамблевого навчання (випадковий ліс, XGBoost, LightGBM та ВЛДОС) були прийнято рішення обрати два ключові гіперпараметри для оптимізації під час стратифікованої групової перехресної перевірки: кількість дерев та максимальна глибина дерева. Вибір цих гіперпараметрів має на меті збалансувати здатність моделі до навчання та її узагальнюючу здатність, що є важливим для побудови стійких і ефективних моделей. Оптимізація цих параметрів дозволяє досягти кращої узгодженості між точністю моделі та її здатністю уникати перенавчання, що особливо критично для ансамблевих методів.

4.1.3 Оцінка результатів моделювання

При побудові моделей класифікації для їхньої оцінки частіше за все використовуються наступні міри [111]:

- 1) Правильність (англ. Ассурасу), формула якої:

$$\frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

де TP (True Positives) – кількість правильних прогнозів для позитивного класу; TN (True Negatives) – кількість правильних прогнозів для негативного

класу; *FP* (False Positives) – кількість хибних позитивних прогнозів (помилка першого роду); *FN* (False Negatives) – кількість хибних негативних прогнозів (помилка другого роду) [10].

Правильність відображає загальну частку правильно класифікованих прикладів (як позитивних, так і негативних) від загальної кількості даних. Ця міра є корисною у випадках, коли класи у вибірці збалансовані. Однак вона може вводити в оману при сильному дисбалансі класів, наприклад, якщо позитивний клас є значно рідкіснішим за негативний. У такому випадку висока правильність може приховувати значну кількість помилок в одному з класів, зокрема, не виявлені позитивні приклади.

2) Чутливість (або повнота), що розраховується за формулою:

$$\frac{TP}{TP + FN} \quad (4.2)$$

Чутливість показує, яку частку дійсно позитивних прикладів модель змогла правильно ідентифікувати як позитивні. Ця метрика є особливо важливою, коли критичним є пропуск позитивних випадків (*FN*), наприклад, в діагностиці небезпечних захворювань, де пропуск хвороби може мати важкі наслідки для пацієнта.

3) Специфічність, формула якої:

$$\frac{TN}{TN + FP} \quad (4.3)$$

Специфічність відображає, яку частку дійсно негативних зразків модель правильно класифікувала як негативні. Висока специфічність означає низьку частоту помилкових тривог, що є важливим у задачах, де важливо зменшити кількість неправильно ідентифікованих позитивних випадків. Наприклад, у фінансових застосуваннях, таких як виявлення шахрайства, висока специфічність дозволяє мінімізувати кількість помилкових позначень

нормальних транзакцій як шахрайських, що зменшує незручності для користувачів.

4) Точність (англ. precision, відома також як влучність, прецизійність, прогностична значущість позитивного результату). Дана міра класифікації обчислюється за формулою нижче:

$$\frac{TP}{TP + FP} \quad (4.4)$$

Точність вказує, яку частку серед усіх передбачених позитивів складають дійсно позитивні приклади. Висока точність означає, що модель майже не допускає помилкових тривог (FP). Чутливість і точність часто використовуються разом для оцінки балансу між хибними позитивами та хибними негативами.

5) Зважена F-міра. Звичайна F-міра є гармонійним середнім між чутливістю та точністю:

$$\frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (4.5)$$

Для зваженої F-міри використовуються ваги, пропорційні кількості прикладів у кожному класі:

$$F_{weighted} = \sum_c w_c F_c, \quad (4.6)$$

Зважена F-міра враховує дисбаланс класів, забезпечуючи, що кожен клас робить внесок у загальний результат, пропорційний до своєї частоти в даних. Це є особливо корисним у випадках, коли дані мають нерівномірний розподіл між класами, оскільки проста F-міра або правильність можуть бути менш інформативними через домінування одного з класів.

4.2 Стадіювання фіброзу печінки за ультразвуковими обстеженнями

Клінічний матеріал для виконання даної задачі був отриманий в реальних умовах, що включає як планові, так і екстрені обстеження пацієнтів. Пацієнти, знімки яких використовувались у дослідженні, були анонімізовані для забезпечення захисту їх персональних даних згідно з міжнародними етичними стандартами та нормами конфіденційності.

4.2.1 Дані знімків ультразвукового обстеження печінки

База знімків УЗО печінки (рис. 4.1), що використовувалась у даному дослідженні, була надана згідно договорів про співпрацю:

- 1) №Д/0002.01/0105.01/273/2022 від 13 грудня 2022 року між КПІ ім. Ігоря Сікорського та ДУ «Інститут ядерної медицини та променевої діагностики НАМН України» [3, 5, 9];
- 2) №Д/0002.01/3400.02/291/2023 від 27 жовтня 2023 року між КПІ ім. Ігоря Сікорського та ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України» [3, 5, 9].



Рисунок 4.1 – Приклад ультразвукового зображення печінки

Фіброз печінки – це складний патологічний процес, який характеризується заміщенням нормальної паренхіми печінки фіброзною тканиною у відповідь на тривале пошкодження органу [103]. Це спричиняє поступове зниження еластичності та функціональної здатності печінки, що підвищує ризик розвитку печінкової недостатності та гепатоцелюлярної карциноми. Визначення стадії фіброзу на ранніх етапах є критично важливим, саме тому, для можливості проведення даного дослідження, радіологи Інституту ядерної медицини та променевої діагностики надали знімки УЗО печінки, отриманих від 162 пацієнтів.

Контрольна група складалася з 63 осіб, у яких не виявлено жодних клінічних або біохімічних ознак, що свідчили б про наявність патології печінки. У 99 пацієнтів з основної групи було діагностовано дифузне захворювання печінки, яке спровокувало фіброз. Зокрема, у 7 пацієнтів спостерігалася перша стадія фіброзу (F1), у 17 – друга стадія (F2), у 21 – третя стадія (F3), а у 11 – четверта стадія фіброзу (F4) [3]. У 43 пацієнтів на момент ультразвукового дослідження стадія фіброзу не була визначена [3].

Конкретна стадія фіброзу печінки оцінювалась клініцистами за допомогою біопсії [31] разом зі шкалою METAVIR [50]. Біопсія печінки є інвазивною процедурою, під час якої через шкіру за допомогою спеціальної голки відбирається невеликий зразок печінкової тканини. Даний метод вважається «золотим стандартом» у визначенні ступеня фіброзу, оскільки він дозволяє провести детальну морфологічну оцінку ураження тканини.

Однак, біопсія має низку суттєвих недоліків, таких як дискомфорт для пацієнта, біль, ризик ускладнень (зокрема кровотеча, інфекція, пошкодження суміжних структур), а також можливість нерепрезентативності отриманого зразка, що може призводити до помилок у визначенні стадії фіброзу через неоднорідність ураження печінки.

У зв'язку з подібними проблемами, лікарі та пацієнти віддають перевагу неінвазивним методам оцінки стану печінки, таким як УЗО. Дані методи дозволяють оцінити ступінь фіброзу без болю, без ризику ускладнень

та без потреби у стаціонарному спостереженні. Тим не менш неінвазивні методи, включно з ультразвуковими методиками, мають свої обмеження. Основна проблема полягає у посередній правильності встановлення конкретної стадії фіброзу, особливо у випадках, коли стадії фіброзу мають незначні морфологічні відмінності. Згідно з дослідженнями, чутливість та специфічність неінвазивних методів, заснованих на стандартних ультразвукових зображеннях, у розпізнаванні окремих стадій фіброзу не перевищують 70% [47, 72, 84, 97, 108]. Це вказує на необхідність подальшого вдосконалення неінвазивних технологій та їх комбінації з іншими методами для підвищення діагностичної точності, чому і присвячене дане дослідження.

УЗО печінки здійснюється із використанням спеціалізованих апаратів, що генерують зображення у сірій шкалі. Залежно від клінічних цілей застосовуються різні типи ультразвукових датчиків, зокрема конвексні та лінійні. Конвексні датчики зазвичай функціонують на частотах від 3 до 5 МГц, що дозволяє отримати глибоке проникнення ультразвукових хвиль і забезпечити широке поле зору, необхідне для візуалізації об'ємних структур.

Лінійні датчики, які працюють на вищих частотах (8-10 МГц), забезпечують більшу роздільну здатність, що дозволяє більш детально оцінювати поверхневі та мікроструктурні зміни органу. У даному дослідженні для виконання УЗО печінки використовувався також лінійний датчик у посиленому режимі [3], що забезпечило точність діагностичної інформації щодо стадій фіброзу.

Конвексні датчики, завдяки своїй вигнутій випромінюючій поверхні, оптимізовані для дослідження великих об'ємів тканин, тоді як лінійні датчики з плоскою поверхнею ідеально підходять для детальної візуалізації поверхневих та дрібноструктурних об'єктів.

У межах дослідження було проведено аналіз 585 ультразвукових знімків печінки [3]. Кожне зображення мало розмір 800x608 пікселів, що відповідає стандартному формату 4:3 [3]. З контрольної групи, яка включала пацієнтів без патологічних змін у печінці, було отримано 241 знімок. Для


пацієнтів з діагностованими патологіями печінки було зібрано 344 знімки [3]. Зокрема, 19 знімків відповідали першій стадії фіброзу, 63 – другій стадії, 70 – третій стадії, а 33 – четвертій стадії [3]. Для 159 знімків стадію фіброзу печінки не вдалося визначити.

Як було зазначено раніше, роздільна здатність кожного ультразвукового зображення печінки складала 800x608 пікселів [3]. Зображення були збережені у форматі BMP, що є одним зі стандартних форматів для медичної візуалізації [3], оскільки дозволяє забезпечити збереження оригінальної якості знімків. Формат BMP не використовує жодних методів компресії, що дозволяє уникнути втрати даних, важливих для точного діагностичного аналізу.

На рис. 4.1 наведено ультразвукове зображення печінки, де виділені специфічні регіони у вигляді прямокутників із червоними межами. Ці регіони представляють собою ОІ, які були відсегментовані вручну кваліфікованими фахівцями з метою акцентування на найбільш релевантних ділянках для діагностики. Кожне ультразвукове зображення містить від однієї до п'яти таких ОІ [3]. Було прийнято рішення вирізати ОІ для подальшого використання як основних об'єктів аналізу [3]. На рис. 4.2 представлені приклади подібних сегментованих ОІ, які використовувались у подальшому аналізі медичних зображень.



а)



б)

Рисунок 4.2 – Приклад вирізаних ОІ: а) норми; б) патології

ОІ, отримані з ультразвукових зображень печінки, були збережені у форматі PNG. Формат PNG забезпечує безвтратну компресію даних, що дозволяє значно зменшити розмір файлу при збереженні всіх необхідних діагностичних деталей [3]. Загалом було виділено 1059 ОІ, середні розміри яких становили 88.6 пікселів у ширину та 113.5 пікселів у висоту [3]. З цієї сукупності, 480 ОІ належать до контрольної групи пацієнтів з відсутністю патологічних змін печінки. Решта 579 ОІ були пов'язані з патологічними змінами, включаючи 44 ОІ, що відповідали першій стадії фіброзу, 103 ОІ – другій стадії, 129 ОІ – третій стадії, 50 ОІ – четвертій стадії, та 253 ОІ, що належали до випадків з не визначеною на момент аналізу стадією фіброзу.

Радіологами Інституту ядерної медицини та променевої діагностики була поставлена задача виконати стадіювання фіброзу печінки на основі вирізаних з ультразвукових зображень ОІ. Для вирішення цієї задачі було ухвалено рішення виключити з загальної вибірки ті зображення, стадія фіброзу яких була невідомою.

Враховуючи значний дисбаланс у кількості ОІ між різними стадіями фіброзу в межах кожного датчика, було вирішено об'єднати всі зображення, отримані з різних датчиків, в одну спільну вибірку для навчання моделей ШІ. Щоб не втратити інформацію про вплив конкретного датчика на якість діагностичної візуалізації, тип датчика включили як окрему інформативну ознаку. Оскільки ця ознака є категоріальною, для її представлення було застосовано метод «one-hot encoding», що дозволив розділити ознаку на три бінарні змінні, спрощуючи таким чином процес навчання моделі.

В табл. 4.1 наведена статистика по остаточній (для дослідження) вибірці зображень ОІ в межах стадій фіброзу печінки від 0 (норми) до 4 (цирозу).

Дисбаланс даних між стадіями фіброзу може суттєво вплинути на точність прогностичних моделей ШІ, особливо в контексті класифікації, оскільки недостатня кількість прикладів певних класів може призводити до зміщення результатів та погіршення якості передбачення.

Таблиця 4.1 – Розподіл зображень ОІ по стадіям фіброзу

Стадія фіброзу	Кількість ОІ
0 (норма)	480 (59.55%)
1	44 (5.46%)
2	103 (12.78%)
3	129 (16.00%)
4	50 (6.20%)
Сума	806

Для виділеної вибірки з 806 зображень ОІ був здійснений текстурний аналіз для оцінки стадій фіброзу. Описаний в другому розділі конструктор ознак, що використовує чотири різні методи гістограмної обробки зображень, дозволив виділити початковий набір із 720 ознак (по 180 ознак для кожного методу).

Згідно рекомендацій з пункту 4.1.1, пацієнти перед моделюванням були стратифіковано розділені на три вибірки: навчальну (80%), контрольну (10%) та екзаменаційну (10%). Навчальна вибірка використовувалась для тренування моделей, контрольна для первинної перевірки результатів, а екзаменаційна – для остаточної оцінки продуктивності моделей та перевірки узагальнюючої здатності. Співвідношення стадій фіброзу в різних вибірках наведене в табл. 4.2.

Таблиця 4.2 – Співвідношення пацієнтів в різних вибірках для моделювання

Стадія фіброзу	Кількість пацієнтів		
	Навчальна вибірка (80%)	Контрольна вибірка (10%)	Екзаменаційна вибірка (10%)
0 (норма)	51 (53.68%)	6 (50.00%)	6 (50.00%)
1	5 (5.26%)	1 (8.33%)	1 (8.33%)
2	13 (13.68%)	2 (16.67%)	2 (16.67%)
3	17 (17.89%)	2 (16.67%)	2 (16.67%)
4	9 (9.47%)	1 (8.33%)	1 (8.33%)
Сума	95	12	12

На основі навчальної вибірки (з метою уникнення витоку даних) було виконано алгоритм селекції найбільш інформативних ознак, який сформував фінальну множину з 178 ознак, що стали фундаментом для побудови моделей ансамблевого машинного навчання.

Моделювання стадій фіброзу печінки проводилося у три етапи відповідно до ієрархічного підходу, описаного у попередньому розділі.

4.2.2 Етап 1 – групова класифікація стадій фіброзу

Для побудови моделей на даному етапі використовувались лише навчальна і контрольна вибірки. Моделі випадкового лісу, XGBoost, LightGBM та ВЛДОС були розроблені для розв'язання чотирьох окремих задач бінарної класифікації стадій фіброзу:

1) «F0 проти F1-4» [3]. Даним з нульовою стадією фіброзу присвоювалася мітка класу «0» (негативний), а всім іншим (стадії від F1 до F4) – мітка «1» (позитивний).

2) «F0-1 проти F2-4» [3]. Даним зі стадіями фіброзу F0 та F1 присвоювалася мітка класу «0» (негативний), тоді як решта (стадії від F2 до F4) отримували мітку «1» (позитивний).

3) «F0-2 проти F3-4» [3]. Даним зі стадіями фіброзу F0, F1 та F2 присвоювалася мітка «0» (негативний), а стадіям F3 та F4 – мітка «1» (позитивний).

4) «F0-3 проти F4» [3]. Даним зі стадіями фіброзу F0, F1, F2 та F3 присвоювалася мітка класу «0» (негативний), а стадії F4 – мітка «1» (позитивний).

Співвідношення спостережень в різних задачах бінарної класифікації наведене в табл. 4.3. Даний підхід дозволяє враховувати особливості кожної стадії фіброзу та поступове ускладнення завдань, що сприяє більш точному і детальному аналізу ефективності моделей у розрізненні стадій патології. В кожній задачі виконувалась 10-кратна стратифікована групова перехресна перевірка з метою знаходження оптимальних гіперпараметрів для кожної моделі ансамблевого навчання.

Таблиця 4.3 – Співвідношення спостережень в чотирьох задачах бінарної класифікації

Задача	Навчальна вибірка		Контрольна вибірка	
	К-сть спостережень у негативному класі	К-сть спостережень у позитивному класі	К-сть спостережень у негативному класі	К-сть спостережень у позитивному класі
F0 проти F1-4	384 (59.72%)	259 (40.28%)	48 (63.16%)	28 (36.84%)
F0-1 проти F2-4	420 (65.32%)	223 (34.68%)	49 (64.47%)	27 (35.53%)
F0-2 проти F3-4	501 (77.92%)	142 (22.08%)	60 (78.95%)	16 (21.05%)
F0-3 проти F4	604 (93.93%)	39 (6.07%)	73 (96.05%)	3 (3.95%)

Крім того, при навчанні моделі використовувався метод адаптивного синтетичного семплінгу (ADASYN) [43]. Це метод генерації синтетичних зразків для міноритарного класу у задачах класифікації з незбалансованими наборами даних. Основна ідея полягає в адаптивному створенні нових прикладів для міноритарної групи з фокусом на підкласи, що є найбільш складними для класифікації, тим самим покращуючи здатність класифікатора відрізняти ці складні зразки та знижуючи загальну упередженість моделі до мажоритарного класу.

В табл. 4.4 наведені результати моделювання в задачі бінарної класифікації «F0 проти F1-4» на контрольній вибірці.

Таблиця 4.4 – Результати задачі «F0 проти F1-4» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.70	0.68	0.71	0.58	0.70
XGBoost	0.82	0.79	0.83	0.73	0.82
LightGBM	0.79	0.79	0.79	0.69	0.79
ВЛДОС	0.80	0.71	0.85	0.74	0.80

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 82% (95% довірчий інтервал, розрахований бутстреп методом: [0.72, 0.89]) було отримано за допомогою методу XGBoost.

В табл. 4.5 наведені результати моделювання в задачі бінарної класифікації «F0-1 проти F2-4» на контрольній вибірці.

Таблиця 4.5 – Результати задачі «F0-1 проти F2-4» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.76	0.67	0.82	0.67	0.76
XGBoost	0.75	0.59	0.84	0.67	0.75
LightGBM	0.78	0.63	0.86	0.71	0.77
ВЛДОС	0.79	0.74	0.82	0.69	0.79

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 79% (95% довірчий інтервал: [0.70, 0.87]) було отримано за допомогою методу ВЛДОС.

В табл. 4.6 наведені результати моделювання в задачі бінарної класифікації «F0-2 проти F3-4» на контрольній вибірці.

Таблиця 4.6 – Результати задачі «F0-2 проти F3-4» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.79	0.44	0.83	0.50	0.78
XGBoost	0.82	0.63	0.87	0.56	0.82
LightGBM	0.78	0.63	0.82	0.48	0.79
ВЛДОС	0.70	0.44	0.77	0.33	0.71

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 82% (95% довірчий інтервал: [0.70, 0.89]) було отримано за допомогою методу XGBoost.

В табл. 4.7 наведені результати моделювання в задачі бінарної класифікації «F0-3 проти F4» на контрольній вибірці.

Таблиця 4.7 – Результати задачі «F0-3 проти F4» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.97	0.67	0.99	0.67	0.97
XGBoost	0.95	0.67	0.96	0.40	0.95
LightGBM	0.92	1.00	0.92	0.33	0.94
ВЛДОС	0.93	0.67	0.95	0.33	0.94

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 97% (95% довірчий інтервал: [0.93, 1.00]) було отримано за допомогою методу випадкового лісу.

Виходи чотирьох найкращих моделей у вигляді значень ймовірностей позитивних класів використовувались для наступного етапу.

4.2.3 Етап 2 – мультикласифікація стадій фіброзу за зображеннями

Для побудови метакласифікатора на основі виходів чотирьох моделей бінарної класифікації з попереднього етапу також порівнювались методи випадкового лісу, XGBoost, LightGBM та ВЛДОС. На навчальній вибірці здійснювалось тренування метакласифікаторів, а контрольна використовувалась для вибору найкращої з них. В табл. 4.8 наведена оцінка побудованих моделей мірами правильності та зваженої F-міри:

Таблиця 4.8 – Результати задачі мультикласифікації стадій фіброзу груповим методом на контрольній вибірці

Метод класифікації	Правильність	F-міра
Випадковий ліс	0.68	0.70
XGBoost	0.70	0.70
LightGBM	0.70	0.71
ВЛДОС	0.70	0.70

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 70% (95% довірчий інтервал: [0.59, 0.79]) було отримано за допомогою методу LightGBM.

Правильність підходу з груповою класифікацією виявився на 6% більшою ніж стандартна стратегія «один проти всіх», результати застосування якої наведені в табл. 4.9.

Таблиця 4.9 – Результати задачі мультикласифікації стадій фіброзу за стратегією «один проти всіх» на контрольній вибірці

Метод класифікації	Правильність	F-міра
Випадковий ліс	0.54	0.55
XGBoost	0.64	0.64
LightGBM	0.53	0.52
ВЛДОС	0.53	0.55

Слід відмітити, що модель LightGBM при такій стратегії виявилась найгіршою у порівнянні з моделями інших методів.

Після того, як було обрано модель LightGBM в якості метакласифікатора, її було перетреновано на комбінації навчальної і контрольної вибірок з метою виконання фінальної її оцінки на екзаменаційній вибірці. В табл. 4.10 наведені результати оцінювання моделі на екзаменаційній вибірці.

Таблиця 4.10 – Результати задачі мультикласифікації стадій фіброзу груповим методом на екзаменаційній вибірці

Стадія фіброзу	Чутливість	Точність	Правильність	F-міра
F0	0.71	0.87	—	0.78
F1	0.71	0.38		0.50
F2	0.64	0.47		0.54
F3	0.62	0.50		0.55
F4	0.50	1.00		0.67
Усього	—	—	0.67	0.68

Результати, подані в таблиці вище, свідчать про різний рівень ефективності моделі для кожної зі стадій. Для стадії F0 встановлено високу точність (0.87) та помірну чутливість (0.71), що вказує на надійне виявлення відсутності фіброзу; значення F-міри (0.78) додатково підтверджує збалансованість між цими показниками.

Для стадії F1 точність різко знижується до 0.38 за чутливості 0.71, що може свідчити про значну кількість хибнопозитивних результатів; F-міра (0.50) підкреслює труднощі в класифікації цього класу. Стадія F2 характеризується чутливістю 0.64 і точністю 0.47, а F-міра (0.54) вказує на обмежену ефективність моделі для даної категорії.

Для стадії F3 показники чутливості й точності є помірними (0.62 та 0.50 відповідно), що разом із F-мірою 0.55 свідчить про необхідність подальшого вдосконалення. Водночас, F4 відзначається ідеальною точністю (1.00) за недостатньої чутливості (0.50), тобто модель правильно визначає випадки F4, однак пропускає половину справжніх випадків; F-міра 0.67 відображає наявний дисбаланс.

Загальна правильність моделі становить 0.67 (95% довірчий інтервал: [0.58, 0.76]), що відповідає коректній класифікації 67% усіх випадків. Значення F-міри (0.68) засвідчує помірний баланс між точністю та чутливістю для всіх стадій. Водночас залишаються проблеми з низькою точністю для стадій F1 і F2, відсутністю даних щодо правильності для F2, а також дисбалансом між високою точністю та низькою чутливістю для F4. Імовірно, вони зумовлені нерівномірністю розподілу даних або складністю диференціації окремих стадій.

4.2.4 Етап 3 – мультикласифікація стадій фіброзу за пацієнтами

На цьому етапі здійснювалась оцінка стану пацієнта шляхом мажоритарного голосування за прогнозуваннями фінального метакласифікатора на кожному зображенні ОІ. На попередньому етапі машина виконала прогнозування на кожному зображенні ОІ окремо, в той час як на цьому етапі вона виконує агрегацію власних прогнозувань, щоб

отримати достатню впевненість у діагнозі, що встановлюється пацієнту. Це можна порівняти з процесом мислення лікаря, який аналізує різні зображення ОІ для того, щоб скласти повну картину.

В табл. 4.11 наведені результати мажоритарного голосування на пацієнтах з екзаменаційної вибірки.

Таблиця 4.11 – Результати мажоритарного голосування по зображенням ОІ на екзаменаційній вибірці пацієнтів

Стадія фіброзу	Чутливість	Точність	Правильність	F-міра
F0	0.67	1.00	—	0.80
F1	1.00	0.50		0.67
F2	0.50	0.50		0.50
F3	1.00	0.67		0.80
F4	1.00	1.00		1.00
Усього	—	—	0.75	0.76

В табл. 4.12 наведені результати мажоритарного голосування на когорті усіх пацієнтів.

Таблиця 4.12 – Результати мажоритарного голосування по зображенням ОІ на когорті усіх пацієнтів

Стадія фіброзу	Чутливість	Точність	Правильність	F-міра
F0	0.97	0.99	—	0.98
F1	0.86	0.75		0.80
F2	0.88	0.94		0.91
F3	0.95	0.91		0.93
F4	1.00	1.00		1.00
Усього	—	—	0.95	0.95

4.3 Ідентифікація COVID-асоційованих патологій легень за комп'ютерною томографією

Як і в попередній задачі, клінічний матеріал був отриманий в реальних умовах, що включає як планові, так і екстрені обстеження пацієнтів.

Пацієнти, знімки яких використовувались у дослідженні, були анонімізовані для забезпечення захисту їх персональних даних згідно з міжнародними етичними стандартами та нормами конфіденційності.

4.3.1 Дані зрізів комп'ютерної томографії легень

База зрізів КТ легень (рис. 4.3), що використовувалась у даному дослідженні, була надана згідно договорів про співпрацю:

1) №Д/0002.01/3400.02/5/2023 від 05 січня 2023 року між КПІ ім. Ігоря Сікорського та ДУ «Національний інститут фтизіатрії і пульмонології імені Ф. Г. Яновського НАМН України» [8];

2) №Д/0002.01/4047.01/34/2023 від 02 лютого 2023 року між КПІ ім. Ігоря Сікорського та ДУ «Національний інститут серцево-судинної хірургії імені М.М. Амосова НАМН України» [8].




Рисунок 4.3 – Приклад зрізу КТ легень

Для проведення даного дослідження використовувались 19321 зріз КТ легень, отримані від 48 анонімізованих пацієнтів. Контрольна група включала 12 пацієнтів з легенями, які не містили ознак інфільтрації, консолідації або фіброзних змін. У 14 пацієнтів, які були обстежені через три або більше місяців після гострої фази COVID-19, на КТ легень зберігалися ознаки синдрому «Long COVID» [88], що проявлялися у вигляді помірних залишкових змін, таких як легкі фіброзні смужки та поодинокі матові затемнення, але без вираженої динамічної консолідації або об'ємних кавітаційних порожнин. Інші 22 пацієнти були діагностовані на COVID-асоційовані легеневі патології, зокрема: 16 пацієнтів обстежувались під час гострої фази COVID-19, тоді як у 6 пацієнтів було діагностовано консолідацію, пов'язану з COVID-19, що в подальшому призвела до розвитку синдрому зникаючої легені (СЗЛ) [73].

СЗЛ характерна втратою нормальної легеневої структури (фактично, «зникання» частини легені). На відміну від Long COVID, де переважно спостерігаються легкі фіброзні залишки, або гострої фази, де домінують запальні інфільтрати, при СЗЛ відмічають більш стійкі та масивні структурні руйнування з формуванням бул, кіст та деформацією бронхів.

Враховуючи високий обсяг досліджень та складність оцінки тонких рентгенологічних ознак, радіологи поставили задачу провести ідентифікацію цих станів за допомогою методів ШІ.

Таким чином, для дослідження використовувались КТ-зрізи, що відображали чотири різні стани легень.

Зрізи КТ легень розміром 512x512 пікселів були надані в форматі DICOM. Цей формат забезпечує збереження зображень із 16-бітною роздільною здатністю, що дозволяє охоплювати широкий динамічний діапазон відтінків сірого, важливих для точної діагностики. Крім зображень, DICOM містить численні метадані – так звані DICOM теги, які несуть інформацію про параметри проведення процедури, технічні характеристики сканування та інші релевантні аспекти, що необхідні для коректного аналізу

даних. Такі метадані є критично важливими для забезпечення точності та узгодженості при обробці медичних зображень і дозволяють дослідникам краще розуміти контекст отримання даних, що є невід'ємною складовою сучасного медичного аналізу.

Серед ключових DICOM тегів слід виділити наступні:

– «Bits Stored» (0028,0101) – визначає кількість бітів, що використовуються для збереження значущої інформації пікселів. Наприклад, для зображення виділено 16 біт, але фактично використовується лише 12, що обмежує діапазон значень, з яких складається зображення. Цей параметр забезпечує розуміння потенційної глибини зображення та впливає на якість візуалізації. У дев'яти пацієнтів тег «Bits Stored» дорівнює 12 біт, у одного – 13 біт, у інших 38 пацієнтів – 16 біт.

– «Body Part Examined» (0018,0015) – визначає анатомічну область дослідження, таку як грудна клітка ('CHEST') або черевна порожнина ('ABDOMEN'). Цей тег дозволяє автоматизованим системам або радіологам ідентифікувати тип сканованої області, що є важливим для належного налаштування алгоритмів аналізу та збереження відповідного контексту.

– «Convolution Kernel» (0018,1210) – описує фільтр або ядро реконструкції, яке використовувалося для перетворення сирих даних у фінальне зображення. Залежно від обраного ядра, можна підсилити чи згладити певні структури: від кісткової тканини до м'яких тканин. Таким чином, тип застосованого ядра визначає характеристичні особливості отриманих зображень.

– «Exposure» (0018,1152) – відображає загальну дозу рентгенівського випромінювання, яку отримав пацієнт під час процедури, вимірюється в міліампер-секундах. Цей параметр має безпосередній вплив на співвідношення сигналу до шуму та, відповідно, на якість зображення.

– «Exposure Time» (0018,1150) – тривалість експозиції, яка визначає час впливу рентгенівського випромінювання на детектор, вимірюється в

мілісекундах. Тривалість експозиції впливає на якість зображення, рівень шуму та ефективну дозу, яку отримує пацієнт. Значення даного тегу у пацієнтів варіюється від 250 до 1000 мілісекунд.

– «Image Type» (0008,0008) – містить множину значень, що описують характеристики зображення, такі як тип даних (наприклад, 'ORIGINAL', 'PRIMARY', 'AXIAL'). Це дозволяє ідентифікувати, чи є зображення первинним або вже обробленим, що впливає на вибір методики аналізу.

– «KVP» (0018,0060) – пікова напруга рентгенівської трубки під час сканування, вимірюється в кіловольтах. Цей параметр визначає енергію випромінювання, що, у свою чергу, впливає на контрастність зображення та його проникність через тканини різної щільності. Значення даного тегу у пацієнтів варіюється від 100 до 150 кіловольт.

– «Manufacturer» (0008,0070) – містить назву виробника обладнання, використаного для сканування. Ця інформація важлива для забезпечення сумісності апаратури та розуміння характеристик зображень, оскільки різні виробники можуть застосовувати різні технологічні рішення та алгоритми обробки. Семи пацієнтам КТ легень виконували на сканерах від «GE Medical Systems», одному пацієнту – на сканерах від «Hitachi Medical Corporation», семи пацієнтам – на сканерах від «Philips», одинадцятьом пацієнтам – на сканерах від «Siemens Healthineers», іншим 22 пацієнтам – на сканерах від «Toshiba».

– «Pixel Spacing» (0028,0030) – фізична відстань між центрами сусідніх пікселів у напрямку рядків та стовпців, вимірюється в міліметрах. Ця величина важлива для визначення масштабу зображення та виконання точних анатомічних вимірювань, особливо при аналізі 3D-реконструкцій. Значення даного тегу у пацієнтів варіюється від 0.595 до 0.977.

– «Rescale Intercept» (0028,1052) та «Rescale Slope» (0028,1053) – ці два параметри використовуються для перетворення сирих піксельних значень у фізичні одиниці вимірювання, наприклад, в одиниці Хаунсфілда (HU) для

КТ-зображень. Вони застосовуються для лінійного перетворення піксельних значень, що дозволяє отримати адекватні числові показники, які є критично важливими для точного діагностичного аналізу.

– Slice Thickness (0018,0050) – фізична товщина зрізу, вимірювана в міліметрах. Цей параметр визначає глибинну роздільну здатність, що безпосередньо впливає на якість тривимірних реконструкцій і можливості об'ємних вимірювань, таких як обчислення об'ємів уражених тканин. Значення даного тегу у пацієнтів варіюється від 0.5 до 5 міліметрів.

В цій конкретній задачі ідентифікації станів легень за зрізами КТ сегментація виконувалась автоматично. Для цього було використано CNN U-Net (R231CovidWeb) [49]. Дана нейронна мережа дозволяє виконувати високоточне виділення меж легень, що є надзвичайно важливим для подальшого аналізу КТ-зображень, особливо при ідентифікації патологічних процесів [49]. Архітектура U-Net базується на багат шарових згорткових шарах, що дозволяють екстрагувати як локальні, так і глобальні особливості, забезпечуючи при цьому високу точність та узагальнюваність моделі при роботі з широким спектром медичних зображень. Крім того, U-Net ефективно вирішує задачу сегментації за рахунок симетричної архітектури, що включає шари декодування та кодування, забезпечуючи максимальну деталізацію результату навіть для складних та неоднорідних структур легень. Дана процедура сегментації дозволила виділити 2355 масок легень, збережених у форматі PNG. На рис. 4.4 представлено приклад однієї з таких масок, що демонструє контури легеневої тканини, виділені з КТ-зрізу.

Кількість сегментованих масок виявилася меншою порівняно з загальною кількістю зрізів КТ. Це пояснюється тим, що не всі зрізи в серії містять зображення легень, а деякі зрізи відображають лише анатомічні структури, які не входять до зони інтересу для даного дослідження. В табл. 4.13 представлено детальний розподіл кількості сегментованих масок для кожного із станів легень, що були досліджені.




Рисунок 4.4 – Приклад сегментованої маски легень

Таблиця 4.13 – Розподіл масок по станам легень

Стан легень	Кількість масок
Норма	565 (23.99%)
Гостра фаза COVID-19	841 (35.71%)
Консолідація, що призвела до СЗЛ	315 (13.38%)
Long COVID	634 (26.92%)
Сума	2355

Таким чином, для подальшого аналізу медичних зображень використовувалися ОІ, представлені у вигляді масок легень, сегментованих із КТ-зрізів. Цей підхід дозволяє здійснювати більш точний аналіз структурних змін у легенях, що є особливо важливим для ідентифікації патологій та оцінки динаміки захворювань.

Враховуючи той факт, що для отримання зрізів КТ легень, виділені для даного дослідження, використовувались різні сканери та різне калібрування налаштувань, було вирішено виконати наступні етапи по попередньому перетворенню зрізів КТ:

1) Використання DICOM тегів «Rescale Intercept» та «Rescale Slope» для лінійного масштабування пікселів, щоб значення HU відповідали фізичним властивостям тканин.

2) Коригування яскравості та контрасту за допомогою операції «вікно-рівень» (значення вікна становило 1500 HU, а рівень становив -600 HU). Ця операція є необхідною для забезпечення адекватної візуалізації легеневих структур, а також вона дозволяє більш чітко ідентифікувати аномалії.

3) Нормалізація зображень до 8-бітного формату та збереження у форматі PNG для зменшення обсягу даних. Перетворення з 16-бітного формату до 8-бітного значно зменшує розмір файлів, що є критичним у контексті масивного збереження та передачі даних. Проте важливо зазначити, що нормалізація здійснюється таким чином, щоб зберегти найбільш діагностично значущі особливості. Формат PNG обраний через його безвтратний характер стиснення, що дозволяє зберігати зображення без погіршення якості, яке може мати критичне значення для подальшого діагностичного аналізу.

Таким чином, перелічені операції над зображеннями забезпечують оптимізацію даних для подальшого діагностичного аналізу.

Для виділеної вибірки з 2355 зображень був здійснений текстурний аналіз для ідентифікації COVID-асоційованих патологій. Як і в попередньому підрозділі, використання конструктора дозволило одержати початковий набір із 720 ознак.

Далі, пацієнти перед моделюванням були стратифіковано розділені на три вибірки: навчальну (60%), контрольну (20%) та екзаменаційну (20%). Співвідношення станів легень в різних вибірках наведене в табл. 4.14.

Таблиця 4.14 – Співвідношення пацієнтів в різних вибірках для моделювання

Стан легень	Кількість пацієнтів		
	Навчальна вибірка (60%)	Контрольна вибірка (20%)	Екзаменаційна вибірка (20%)
Норма	8 (26.67%)	2 (22.22%)	2 (22.22%)
Гостра фаза COVID-19	10 (33.33%)	3 (33.33%)	3 (33.33%)
Консолідація, що призвела до СЗЛ	4 (13.33%)	1 (11.11%)	1 (11.11%)
Long COVID	8 (26.67%)	3 (33.33%)	3 (33.33%)
Сума	30	9	9

На основі навчальної вибірки було виконано алгоритм селекції найбільш інформативних ознак, який сформував фінальну множину з 26 ознак, які стали фундаментом для побудови моделей ансамблевого машинного навчання.

Аналогічно до попереднього підрозділу, моделювання різних станів легень проводилося у три етапи.

4.3.2 Етап 1 – групова класифікація станів легень

Для побудови моделей на даному етапі використовувались лише навчальна і контрольна вибірки. Моделі випадкового лісу, XGBoost, LightGBM та ВЛДОС були розроблені для розв'язання трьох окремих задач бінарної класифікації стадій фіброзу:

1) «N проти LCV». Даним з нормою присвоювалася мітка класу «0» (негативний), а всім іншим (long COVID, гостра фаза COVID-19 та СЗЛ) – мітка «1» (позитивний).

2) «NL проти CV». Даним з нормою та long COVID присвоювалася мітка класу «0» (негативний), тоді як решта (гостра фаза COVID-19 та СЗЛ) отримували мітку «1» (позитивний).

3) «NLC проти V». Даним з нормою, long COVID та гострою фазою COVID-19 присвоювалася мітка класу «0» (негативний), а СЗЛ – мітка «1» (позитивний).

Під «N» розуміється норма, під «L» – long COVID, під «C» – гостра фаза COVID-19, та під «V» – консолідація, що призвела до СЗЛ. Співвідношення класів в різних задачах бінарної класифікації наведене в табл. 4.15.

Таблиця 4.15 – Співвідношення спостережень в трьох задачах бінарної класифікації

Задача	Навчальна вибірка		Контрольна вибірка	
	К-сть спостережень негативних класів	К-сть спостережень позитивних класів	К-сть спостережень негативних класів	К-сть спостережень позитивних класів
N проти LCV	361 (24.08%)	1138 (75.92%)	100 (24.88%)	302 (75.12%)
NL проти CV	744 (49.63%)	755 (50.37%)	205 (51.00%)	197 (49.00%)
NLC проти V	1265 (84.39%)	234 (15.61%)	347 (86.32%)	55 (13.68%)

Даний підхід дозволяє враховувати особливості кожного стану легень та поступове ускладнення завдань, що сприяє більш точному і детальному аналізу ефективності моделей у розрізненні COVID-асоційованих патологій.

В кожній задачі виконувалась 5-кратна стратифікована групова перехресна перевірка з метою знаходження оптимальних гіперпараметрів для кожної моделі ансамблевого навчання. Також, як і в попередньому підрозділі, при навчанні моделей використовувався метод ADASYN.

В табл. 4.16 наведені результати моделювання в задачі бінарної класифікації «N проти LCV» на контрольній вибірці.

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 94% (95% довірчий інтервал, розрахований бутстреп методом: [0.88, 1.00]) було отримано за допомогою методу ВЛДОС.

Таблиця 4.16 – Результати задачі «N проти LCV» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.94	0.99	0.79	0.93	0.93
XGBoost	0.93	0.93	0.91	0.97	0.93
LightGBM	0.88	0.88	0.88	0.96	0.88
ВЛДОС	0.94	0.93	0.97	0.99	0.94

В табл. 4.17 наведені результати моделювання в задачі бінарної класифікації «NL проти CV» на контрольній вибірці.

Таблиця 4.17 – Результати задачі «NL проти CV» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.91	0.85	0.97	0.97	0.91
XGBoost	0.84	0.76	0.91	0.89	0.83
LightGBM	0.75	0.74	0.77	0.75	0.75
ВЛДОС	0.81	0.68	0.93	0.90	0.80

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 91% (95% довірчий інтервал: [0.86, 0.99]) було отримано за допомогою випадкового лісу.

В табл. 4.18 наведені результати моделювання в задачі бінарної класифікації «NLC проти V» на контрольній вибірці.

Таблиця 4.18 – Результати задачі «NLC проти V» на контрольній вибірці

Метод класифікації	Правильність	Чутливість	Специфічність	Точність	F-міра
Випадковий ліс	0.97	0.84	0.99	0.94	0.97
XGBoost	0.94	0.89	0.95	0.73	0.94
LightGBM	0.95	0.78	0.97	0.83	0.95
ВЛДОС	0.92	0.71	0.95	0.71	0.92

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 97% (95% довірчий інтервал: [0.92, 1.00]) було отримано за допомогою методу випадкового лісу.

Виходи трьох найкращих моделей у вигляді значень ймовірностей позитивних класів використовувались для наступного етапу.

4.3.3 Етап 2 – мультикласифікація станів легень за зображеннями

Для побудови метакласифікатора на основі виходів трьох моделей бінарної класифікації з попереднього етапу також порівнювались методи випадкового лісу, XGBoost, LightGBM та ВЛДОС. На навчальній вибірці здійснювалось тренування метакласифікаторів, а контрольна використовувалась для вибору найкращої з них. В табл. 4.19 наведена оцінка побудованих моделей мірами правильності та зваженої F-міри:

Таблиця 4.19 – Результати задачі мультикласифікації станів легень груповим методом на контрольній вибірці

Метод класифікації	Правильність	F-міра
Випадковий ліс	0.86	0.86
XGBoost	0.88	0.88
LightGBM	0.85	0.85
ВЛДОС	0.82	0.83

Порівнявши пораховані на контрольній вибірці F-міри кожної моделі між собою, для даної задачі найкращу модель з правильністю 88% (95% довірчий інтервал: [0.79, 0.94]) було отримано за допомогою методу XGBoost. Правильність підходу з груповою класифікацією виявилась на 4% більшою порівняно зі стандартною стратегією «один проти всіх», результати застосування якої наведені в табл. 4.20.

Після того, як було обрано модель XGBoost в якості метакласифікатора, її було перетреновано на комбінації навчальної і контрольної вибірок з метою виконання фінальної її оцінки.

Таблиця 4.20 – Результати задачі мультикласифікації станів легень за стратегією «один проти всіх» на контрольній вибірці

Метод класифікації	Правильність	F-міра
Випадковий ліс	0.84	0.84
XGBoost	0.82	0.82
LightGBM	0.78	0.77
ВЛДОС	0.66	0.64

В табл. 4.21 наведені результати оцінювання моделі на екзаменаційній вибірці.

Таблиця 4.21 – Результати задачі мультикласифікації станів легень груповим методом на екзаменаційній вибірці

Стан легень	Чутливість	Точність	Правильність	F-міра
Норма	0.76	0.91	–	0.83
Гостра фаза COVID-19	0.91	0.94		0.93
СЗЛ	0.90	0.76		0.83
Long COVID	0.79	0.72		0.75
Усього	–	–	0.84	0.84

Результати мультикласифікації станів легень груповим методом на екзаменаційній вибірці свідчать про високу ефективність моделі, особливо для виявлення гострої фази COVID-19. Для стану «норма» спостерігається точність 0.91 та чутливість 0.76, що вказує на надійне розпізнавання нормальних станів, а F-міра 0.83 підкреслює збалансованість цих показників. «гостра фаза COVID-19» виділяється найвищими результатами: чутливість 0.91, точність 0.94 та F-міра 0.93, що підтверджує високу надійність моделі для цього класу.

Для стану «СЗЛ» чутливість становить 0.90, але точність знижується до 0.76, що може свідчити про наявність хибно позитивних прогнозів. F-міра 0.83 все ще залишається високою. «Long COVID» має найнижчі показники: чутливість 0.79, точність 0.72 та F-міра 0.75, що вказує на потребу вдосконалення класифікації цієї категорії.

Загальна правильність моделі становить 0.84 (95% довірчий інтервал: [0.75, 0.92]), а F-міра – 0.84, що підкреслює збалансованість між точністю та чутливістю на глобальному рівні. Основні проблеми пов'язані з нижчою ефективністю для стану Long COVID, а також можливим дисбалансом у даних або труднощами у розрізненні окремих класів.

4.3.4 Етап 3 – мультикласифікація станів легень за пацієнтами

На цьому етапі здійснювалась оцінка стану пацієнта шляхом мажоритарного голосування за прогнозуваннями фінального метакласифікатора на кожному зображенні ОІ. В табл. 4.22 наведені результати мажоритарного голосування на пацієнтах з екзаменаційної вибірки.

Таблиця 4.22 – Результати мажоритарного голосування по зображенням ОІ на екзаменаційній вибірці пацієнтів

Стан легень	Чутливість	Точність	Правильність	F-міра
Норма	1.00	1.00	–	1.00
Гостра фаза COVID-19	0.67	1.00		0.80
СЗЛ	1.00	0.50		0.67
Long COVID	1.00	1.00		1.00
Усього	–	–	0.89	0.90

В табл. 4.23 наведені результати мажоритарного голосування на когорті усіх пацієнтів.

Таблиця 4.23 – Результати мажоритарного голосування по зображенням ОІ на когорті усіх пацієнтів

Стан легень	Чутливість	Точність	Правильність	F-міра
Норма	1.00	0.92	–	0.96
Long COVID	0.93	1.00		0.96
Гостра фаза COVID-19	0.88	0.93		0.90
СЗЛ	1.00	0.86		0.92
Усього	–	–	0.94	0.94

4.4 Практичні рекомендації щодо застосування розробленої технології аналізу цифрових зображень у медичній практиці

Отримані результати підтверджують перспективність запропонованої технології аналізу цифрових зображень для розв'язання двох важливих медичних завдань: стадіювання фіброзу печінки та ідентифікації COVID-асоційованих патологій легень. Технологію можливо інтегрувати в клінічну практику як інструмент для скринінгу та первинної діагностики пацієнтів із підозрою на фіброз печінки. Система забезпечує високу точність виявлення відсутності фіброзу (F0), що потенційно знижує потребу в інвазивних методах, зокрема біопсії печінки, у групі пацієнтів із низьким ризиком. Крім того, технологія може слугувати допоміжним засобом для стандартних ультразвукових методів. Аналіз текстурних характеристик зображень надає лікарям додаткову об'єктивну інформацію при встановленні стадії фіброзу, особливо у клінічних випадках із ускладненою або нечіткою візуальною інтерпретацією даних УЗД. Використання системи також є перспективним для моніторингу прогресування фіброзу при хронічних захворюваннях печінки. Регулярний аналіз ультразвукових зображень із залученням технології забезпечує об'єктивне відстеження динаміки фіброзу, що дає змогу оперативно оцінювати ефективність терапії та своєчасно коригувати лікувальні підходи. За умови подальшої розробки методології, технологія може зменшити потребу у біопсії печінки у деяких клінічних сценаріях (наприклад, при рутинному моніторингу або скринінгу), враховуючи її неінвазивний характер та зниження ризиків, пов'язаних із інвазивними процедурами.

Водночас точність класифікації стадій фіброзу є нижчою для початкових (F1, F2), аніж для пізніх стадій та випадків відсутності фіброзу. Тому за наявності сумнівних результатів або за високої клінічної підозри рекомендовано базувати діагностичні та лікувальні рішення на

комплексному аналізі клінічних даних, результатів лабораторних досліджень і, за потреби, на даних біопсії печінки.

Запропонована технологія аналізу цифрових зображень ефективно застосовується для оперативної ідентифікації різноманітних COVID-асоційованих патологій легень (гостра фаза COVID-19, консолідація з подальшим розвитком СЗЛ, Long COVID). Швидка та точна діагностика надає можливість оптимального розподілу пацієнтів, визначення тактики лікування та прогнозування перебігу захворювання, що є особливо важливим у контексті пандемії. Система також може виконувати допоміжну функцію для радіологів під час інтерпретації великого масиву КТ-зображень, зокрема за підвищеного робочого навантаження на медичний персонал. Аналіз текстурних ознак, який виконується автоматизованою системою, зменшує суб'єктивність оцінки та поліпшує точність діагностичних висновків. Крім того, технологію можливо застосовувати для довгострокового моніторингу COVID-асоційованих патологій легень, що передбачає аналіз динаміки змін на КТ-зображеннях, а також оцінювання ефективності лікування. Система має потенціал для впровадження в телемедичні платформи й у віддалених регіонах, забезпечуючи доступ до спеціалізованої діагностики в умовах обмежених ресурсів та браку кваліфікованих фахівців.

Слід ураховувати, що точність класифікації знижується при діагностиці Long COVID, імовірно через менш виражені та неоднозначні прояви патологій на КТ-зображеннях. Удосконалення алгоритмів аналізу та комплексна інтеграція результатів з іншими клінічними даними можуть покращити діагностику Long COVID.

Перед масовим упровадженням у клінічну практику розроблені технології потребують подальшої клінічної валідації на розширених та гетерогенних вибірках пацієнтів у різних клінічних умовах, щоб підтвердити їхню надійність та ефективність. Інтеграція нових рішень у чинні робочі процеси медичних установ має враховувати потреби та можливості медичних працівників. Інтерфейс системи має відповідати вимогам інтуїтивної

зрозумілості та зручності користування. Крім того, необхідне навчання медичного персоналу використанню розробленої технології, правильній інтерпретації отриманих результатів та застосуванню цих результатів у клінічній практиці. Регулярне оновлення алгоритмів і моделей штучного інтелекту з урахуванням сучасних наукових даних, клінічних рекомендацій і технологічних досягнень є визначальним чинником збереження довгострокової ефективності та актуальності таких технологій.

Впровадження запропонованих методів аналізу цифрових зображень може істотно підвищити ефективність діагностики та моніторингу фіброзу печінки й COVID-асоційованих патологій легень, поліпшити якість медичної допомоги та клінічні результати лікування.

Водночас практичне застосування технології супроводжується низкою обмежень, що вимагають додаткових досліджень. По-перше, ефективність моделей штучного інтелекту значною мірою залежить від характеристик даних, використаних для навчання. Якість і репрезентативність навчальної вибірки визначають здатність моделі до узагальнення. Недостатня репрезентативність (через обмеження у розмаїтті клінічних ситуацій, демографічних груп або технічних характеристик устаткування) зумовлює потенційне зниження точності класифікації. Дисбаланс класів у медичних даних, де деякі стани або патології зустрічаються значно рідше, може також призводити до погіршення здатності моделі розпізнавати рідкісні класи. Хоча у дослідженні застосовувалися методи компенсації дисбалансу (зокрема ADASYN), їхня дієвість може бути недостатньою. Існує ризик виникнення «витоку даних», коли приховані кореляції між вибірками тренування й тестування штучно завищують точність моделі, що унеможливорює відтворення результатів за реальних клінічних умов.

По-друге, важливими є технічні та алгоритмічні аспекти функціонування розробленої технології. Ансамблеві методи навчання часто складні для інтерпретації, що знижує прозорість роботи системи і може викликати сумніви у клініцистів щодо її висновків. Крім того, впровадження

такої системи вимагає належних апаратних та програмних ресурсів. Ефективність роботи може залежати від вибору гіперпараметрів; навіть оптимізація, проведена в даному дослідженні, не гарантує стабільного результату за інших умов або на іншому наборі даних.

По-третє, існують перешкоди, пов'язані з клінічним упровадженням технології. Перш ніж отримати широке поширення, система має пройти ретельну клінічну валідацію, бажано незалежними дослідницькими групами, щоб підтвердити її ефективність і безпеку. У різних юрисдикціях необхідне регуляторне схвалення, процес отримання якого складний і тривалий. Крім того, успішне впровадження може ускладнюватися організаційними й психологічними чинниками. Інтеграція інноваційних рішень у поточний робочий процес потребує планування, навчання персоналу й додання можливого опору серед фахівців. У застосуванні штучного інтелекту в медичній практиці постають етичні та юридичні питання, зокрема щодо відповідальності за діагностичні помилки, збереження конфіденційності даних та потенційної зміни ролі лікаря в ухваленні клінічних рішень. Також високу актуальність має питання вартості впровадження, включно з витратами на апаратне та програмне забезпечення, підтримку й навчання персоналу. Для запобігання посиленню нерівності в наданні медичної допомоги бажано забезпечити доступність технології для закладів із різними фінансовими можливостями.

З огляду на перелічені обмеження, подальші дослідження мають бути спрямовані на їхнє подолання й мінімізацію негативного впливу. Критичними кроками у цьому напрямку є незалежна клінічна валідація, покращення інтерпретованості моделей, розроблення практичних рекомендацій для інтеграції у клінічний робочий процес, а також урегулювання етичних і регуляторних питань. Здійснення таких заходів сприятиме безпечному, відповідальному й ефективному застосуванню технології аналізу цифрових зображень у медичній практиці.

Висновки до розділу 4

В даному розділі була наведена оцінка результатів застосування розробленої технології аналізу цифрових зображень, спрямованої на розв'язання двох прикладних задач медичної діагностики: стадіювання фіброзу печінки на основі ультразвукових зображень та ідентифікації COVID-асоційованих патологій легень за даними комп'ютерної томографії. Проведені експериментальні дослідження засвідчили результативність запропонованого підходу для обох зазначених завдань.

Для стадіювання фіброзу печінки продемонстровано високу ефективність ансамблевих методів машинного навчання, зокрема XGBoost, який забезпечив найкращі показники точності та F-міри під час класифікації стадій фіброзу на підставі текстурних ознак ультразвукових зображень. Використання технології ієрархічної класифікації, що охоплює метакласифікатор, дало змогу отримати задовільний рівень точності на контрольній і екзаменаційній вибірках, особливо у випадку виявлення відсутності фіброзу (F0).

У завданні ідентифікації COVID-асоційованих патологій легень на основі комп'ютерної томографії розроблена технологія також продемонструвала перспективні результати. Зокрема, ансамблеві методи, серед яких випадковий ліс та XGBoost, виявилися високоефективними й збалансованими при розрізненні станів легень: норми, гострої фази COVID-19, консолідації, що призводить до синдрому «зникаючої легені», та Long COVID. Застосування групового підходу з використанням метакласифікатора дало змогу досягти високої точності розмежування зазначених станів, особливо для гострої фази COVID-19 та нормальних легень.

Результати експериментальних досліджень підтверджують перспективність універсальної технології аналізу цифрових зображень у медичній діагностиці. Запропонований підхід може бути інтегрований у клінічну практику як допоміжний інструмент для скринінгу, первинної

діагностики та моніторингу фіброзу печінки й COVID-асоційованих патологій легень. Він здатен сприяти підвищенню об'єктивності та точності діагностики, водночас зменшуючи потребу в інвазивних процедурах і поліпшуючи якість медичної допомоги.

Попри позитивні результати, окреслено низку напрямів подальшого розвитку та вдосконалення:

- Додаткова клінічна валідація на ширших та гетерогенних вибірках пацієнтів для підтвердження надійності та ефективності.

- Підвищення інтерпретованості моделей задля зміцнення довіри фахівців і прозорості ухвалення рішень.

- Розроблення практичних рекомендацій для інтеграції технології в клінічний робочий процес, а також урегулювання етичних та регуляторних питань.

- Подолання обмежень, пов'язаних із дисбалансом даних, складністю диференціації окремих стадій і станів, а також із технічними та організаційними аспектами впровадження.

Незважаючи на зазначені обмеження, проведене дослідження є вагомим кроком у розробленні та впровадженні інноваційних технологій штучного інтелекту в медичну практику, що здатні істотно поліпшити діагностику та лікування широкого спектра захворювань.

ЗАГАЛЬНІ ВИСНОВКИ

Метою дисертаційної роботи є підвищення якості прийняття рішень у задачах аналізу цифрових зображень шляхом розроблення технології ієрархічної класифікації. Для досягнення цієї мети було визначено низку завдань, виконання яких дало змогу отримати наступні наукові результати:

1. Виявлено обмеження сучасних методів оброблення та аналізу медичних зображень. Зокрема, традиційні методи характеризуються недостатньою здатністю до узагальнення, а методи машинного та глибокого навчання відзначаються високими вимогами до обчислювальних ресурсів, великими обсягами даних і складністю інтерпретації результатів. Це підкреслює необхідність розроблення нових підходів, які забезпечують вищу точність. Теоретичне значення полягає у виявленні ключових проблем у сфері аналізу медичних зображень, що визначає напрям подальших наукових пошуків.

2. Розроблено послідовність формування множини інформативних ознак на основі текстурного аналізу. Було запропоновано комбінацію методів попередньої обробки (нормалізація, еквалізація, диференціація), побудови дескрипторів (текстурні та багатомасштабні ознаки, а також на основі гістограм, багаторегіональних гістограм, вейвлет-перетворень та згорткових нейронних мереж) і селекції найбільш значущих ознак за допомогою кореляційного аналізу. Наукова новизна полягає у розробленні комплексної методики формування простору ознак цифрових зображень. Теоретичне значення полягає у розширенні інструментарію для аналізу текстурних особливостей зображень, а практичне – у створенні їхнього більш повного й репрезентативного опису, що підвищує точність класифікації.

3. Удосконалено метод випадкового лісу шляхом інтеграції принципів МГУА, генетичних алгоритмів і методу аналізу ієрархій. Наукова новизна запропонованого методу ВЛДОС (випадкового лісу дерев оптимальної складності) містить кілька ключових аспектів:

– Побудова дерев оптимальної складності на основі МГУА дає змогу уникнути перенавчання та поліпшити узагальнюючу здатність моделей, на відміну від традиційних підходів зі здебільшого емпіричним регулюванням складності.

– Використання генетичних алгоритмів для оптимізації наборів ознак підвищує точність класифікації в середньому на 10% порівняно з випадковим добором ознак у класичному випадковому лісі.

– Застосування методу аналізу ієрархій для зваженого голосування враховує індивідуальний внесок кожного дерева ансамблю та збільшує загальну точність класифікації на 5–10% у порівнянні з простим усередненням.

– Запропонований метод ВЛДОС продемонстрував вищу точність, ніж класичний випадковий ліс і провідні ансамблеві методи (XGBoost, LightGBM), особливо за умови дисбалансу класів, що підтверджує коректність сформульованої гіпотези.

– Теоретичне значення полягає у створенні нового методу ансамблевого навчання, який поєднує переваги різних підходів для підвищення точності та стійкості моделей. Практичне значення полягає у формуванні інструменту для високоточної класифікації, включно з розв’язанням задач із дисбалансом класів.

4. Розроблено технологію ієрархічної класифікації, що базується на групуванні семантично споріднених класів і побудові багаторівневої системи класифікаторів (базові класифікатори, метакласифікатор рівня зразків та метакласифікатор рівня об’єктів). Наукова новизна полягає у формуванні нової схеми ієрархічної класифікації, що зменшує кількість моделей порівняно зі схемами «один проти всіх» і «один проти одного» та знижує негативний вплив дисбалансу класів (на 5–10%), підтверджений поліпшенням показників зваженої F-міри. Теоретичне значення полягає у формалізації нового підходу до розв’язання задач мультикласової

класифікації з урахуванням семантичної спорідненості класів. Практичне значення полягає у зниженні обчислювальної складності та підвищенні стійкості моделей.

5. Запропоновану технологію успішно застосовано для вирішення прикладних задач:

- У стадіюванні фіброзу печінки на рівні зразків (OI) досягнуто 67% правильності класифікації (95% довірчий інтервал [0.58; 0.76]) та F-міри 0.68 на незалежній екзаменаційній вибірці. На рівні пацієнтів правильність становила 75% на екзаменаційній вибірці та 95% у межах усієї когорти.

- В ідентифікації COVID-асоційованих патологій легень правильність класифікації на рівні зразків сягала 84% (95% довірчий інтервал [0.75; 0.92]) за F-міри 0.84. На рівні пацієнтів показник правильності становив 89% на екзаменаційній вибірці та 94% у межах усієї когорти.

Практичне значення результатів полягає у створенні інструменту для автоматизації та підвищення точності медичної діагностики. Запропоновану технологію можна інтегрувати в клінічну практику для скринінгу, первинної діагностики, моніторингу захворювань і підтримки лікарського рішення. Для мінімізації ризиків неправильної класифікації слід використовувати запропоновану систему як допоміжний інструмент для лікарів, а не як остаточний діагностичний засіб.

Таким чином, у роботі досягнуто мети дослідження, підтверджено висунуту гіпотезу та виконано всі поставлені завдання. Отримані результати характеризуються науковою новизною, теоретичним і практичним значенням. Крім того, запропонована технологія може використовуватись для цифрових зображень будь-якого типу, включно з такими як магнітно-резонансна томографія, рентген тощо. Подальші дослідження будуть спрямовані на автоматизацію процесу групування класів, оптимізацію гіперпараметрів, розширення сфери застосування технології та її клінічну валідацію.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Методи та моделі ідентифікації станів біологічних об'єктів [Електронний ресурс] / [О. Авер'янова, **В. Бабенко**, К. Бовсуновська та ін.] – 2023. – С. 1–74. – Режим доступу: <https://nrat.ukrintei.ua/searchdoc/0223U000145/>
2. Розпізнавання медичних зображень алгоритмом генетично-індуктивного лісу / **В. Бабенко**, Є. Настенко, В. Павлов, О. Носовець. // Збірник наукових праць IV міжнародної науково-практичної конференції «Інформаційні системи та технології в медицині» (ІСМ-2021), м. Харків, 25–26 листопада 2021 року. – Національний аерокосмічний університет ім. М. Є. Жуковського «Харківський авіаційний інститут», 2021. – С. 71–73
3. Ієрархічний алгоритм мультикласифікації стадій фіброзу печінки з інтегрованим аналізом областей інтересу / [**В. Бабенко**, Є. Настенко, В. Солодущенко та ін.]. // Біомедична інженерія і технологія. – 2024. – № 14. – С. 63–73. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2024.14.301108](https://doi.org/10.20535/2617-8974.2024.14.301108)
4. **Бабенко В.** Система аналізу ризиків після хірургічного лікування у ранньому післяопераційному періоді : дипломна робота бакалавра. – 2019. – 118 с. – DOI: [10.13140/RG.2.2.17972.27524](https://doi.org/10.13140/RG.2.2.17972.27524)
5. **Бабенко В.** Класифікація ультразвукових зображень методом генетичного лісу дерев оптимальної складності : дипломна робота магістра. – 2021. – 125 с. – DOI: [10.13140/RG.2.2.18348.18562/1](https://doi.org/10.13140/RG.2.2.18348.18562/1)
6. Давидович І. Методології аналізу зображень для діагностичних застосувань (огляд) / І. Давидович, **В. Бабенко**. // Біомедична інженерія і технологія. – 2024. – № 14. – С. 54–63. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2024.14.302135](https://doi.org/10.20535/2617-8974.2024.14.302135)
7. Добровська Л. Комбінація локальної порогової бінаризації та машинного навчання для класифікації пухлин молочної залози / Л. Добровська, **В. Бабенко**, А. Іванченко. // Біомедична інженерія і технологія. –

2022. – № 8. – С. 40–47. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2022.8.267793](https://doi.org/10.20535/2617-8974.2022.8.267793)

8. Ефективність алгоритмів машинного навчання для класифікації змін структури легень у постковідних та гострих стадіях COVID-19 / В. Лутченко, **В. Бабенко**, Є. Настенко, М. Линник. // Біомедична інженерія і технологія. – 2024. – №15. – С. 27–35. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/.2024.15.306763](https://doi.org/10.20535/.2024.15.306763)

9. Класифікація станів печінки при дифузних захворюваннях на основі статистичних показників текстури ультразвукових зображень та МГУА / [Є. Настенко, І. Дикан, Б. Тарасюк, В. Павлов, О. Носовець, **В. Бабенко**, В. Круглий, М. Диба, В. Солодущенко] // Індуктивне моделювання складних систем. – 2019. – № 11. – С. 54–66.

10. Науково-дослідні теми та проєкти кафедри [Електронний ресурс] / Є. Настенко, С. Алхімова, В. Павлов, **В. Бабенко** // Кафедра біомедичної кібернетики, 2024. – Режим доступу: <https://bmc.fbmi.kpi.ua/naukovo-doslidni-temi-ta-projects/>

11. Застосування методу групового урахування аргументів для побудови алгоритмів діагностики ішемічної хвороби серця / [Є. Настенко, В. Максименко, С. Поташев, В. Павлов, **В. Бабенко**, С. Рисін, О. Матвійчук, В. Лазоришинець] // Біомедична інженерія і технологія. – 2021. – № 5. – С. 1–9. – DOI: 10.20535/2617-8974.2021.5.227141

12. Застосування текстурного аналізу у вирішенні задачі класифікації медичних зображень / [Є. Настенко, В. Павлов, О. Носовець, В. Круглий, М. Гончарук, А. Карлюк, Д. Грішко, О. Трофименко, **В. Бабенко**] // Біомедична інженерія і технологія. – 2020. – № 4. – С. 69–82. – DOI: 10.20535/2617-8974.2020.4.221876

13. Розробка програм на основі штучного інтелекту для діагностики міокардиту при COVID-19 за даними комп'ютерної томографії грудної клітки / [Є. Настенко, М. Гончарук, **В. Бабенко** та ін.]. // Український журнал

серцево-судинної хірургії. – 2024. – Том 32, № 3. – С. 58–65. ISSN: 26645963, 26645971. DOI: [10.30702/ujcvs/24.32\(03\)/NH052-5865](https://doi.org/10.30702/ujcvs/24.32(03)/NH052-5865)

14. Аналіз ультразвукових зображень хронічних дифузних захворювань печінки із застосуванням текстурних параметрів градацій сірого / [Є. Настенко, І. Дикан, В. Павлов, Б. Тарасюк, **В. Бабенко**, В. Круглий, В. Солодущенко, М. Гончарук, І. Андрущенко, М. Гупало, О. Авер'янова]. // Radiation Diagnostics, Radiation Therapy. – 2023. – Том 13, № 3. – С. 7–20. DOI: [10.37336/2707-0700-2022-3-1](https://doi.org/10.37336/2707-0700-2022-3-1)

15. Порівняльний аналіз алгоритмів класифікації при аналізі медичних зображень за відеоданими спекл-трекінг ехокардіографії / [О. Петруніна, Д. Шевага, **В. Бабенко** та ін.]. // Innovative Biosystems and Bioengineering. – 2021. – Том 5, № 3. – С. 153–166. ISSN: 2616–177X. DOI: [10.20535/ibb.2021.5.3.234990](https://doi.org/10.20535/ibb.2021.5.3.234990)

16. Використання глибоких нейронних мереж для порівняльного аналізу норми, пневмонії і COVID-19 / [Р. Юхимюк, М. Шкепаст, Є. Настенко, М. Лінник, І. Давидович, **В. Бабенко**]. // Біомедична інженерія і технологія. – 2023. – № 12. – С. 56–64. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2023.12.292729](https://doi.org/10.20535/2617-8974.2023.12.292729)

17. Anastasakis L., Mort N. The development of self-organization techniques in modelling: A review of the group method of data handling (GMDH) // Research Report-University of Sheffield Department of Automatic Control and Systems Engineering. – 2001. – № 813. – P. 39–39.

18. Classification of Pathologies on Medical Images Using the Algorithm of Random Forest of Optimal-Complexity Trees / [**V. Babenko**, I. Nastenka, V. Pavlov et al.]. // Cybernetics and Systems Analysis. – 2023. – Vol. 59, No. 2. – pp. 346–358. ISSN: 15738337, 10600396. DOI: [10.1007/s10559-023-00569-z](https://doi.org/10.1007/s10559-023-00569-z)

19. **Babenko V.** Improved Random Forest Algorithm in the Task of Liver Pathology Classification by Medical Images / **V. Babenko**, I. Nastenka, V. Pavlov. // Сучасний стан та перспективи біомедичної інженерії: матеріали Міжнародної науково-практичної конференції, присвячена 20-річчю

ювілею Факультету біомедичної інженерії КПІ ім. Ігоря Сікорського, м. Київ, 15–16 грудня 2022 року. – Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», 2022. – pp. 18–18. DOI: [10.20535/biomedconf.2022.15122022](https://doi.org/10.20535/biomedconf.2022.15122022)

20. Basha S. J., Madala S. R., Vivek K. et al. A Review on Imbalanced Data Classification Techniques. – 2022. – P. 1–6. – DOI: 10.1109/ICACTA54488.2022.9753392.

21. Belgiu M., Drăguț L. Random Forest in remote sensing: A review of applications and future directions // ISPRS Journal of Photogrammetry and Remote Sensing. – 2016. – Vol. 114. – P. 24–31. – DOI: 10.1016/j.isprsjprs.2016.01.011.

22. Belkin M., Hsu D., Ma S. et al. Reconciling modern machine-learning practice and the classical bias–variance trade-off // Proceedings of the National Academy of Sciences. – 2019. – Vol. 116, № 32. – P. 15849–15854. – DOI: 10.1073/pnas.1903070116.

23. Breiman L. Bagging predictors: Technical Report No. 421. – Department of Statistics University of California, 1994. – 2 p.

24. Breiman L. Bagging predictors // Machine Learning. – 1996. – Vol. 24, № 2. – P. 123–140. – DOI: 10.1007/BF00058655.

25. Breiman L. Random Forests // Machine Learning. – 2001. – Vol. 45, № 1. – P. 5–32. – DOI: 10.1023/A:1010933404324.

26. Chairet R., Ben Salem Y., Aoun M. Features extraction and land cover classification using Sentinel 2 data. – 2019. – P. 497–500. – DOI: 10.1109/STA.2019.8717307.

27. Chen R., Fu Y., Yi X. et al. Application of Radiomics in Predicting Treatment Response to Neoadjuvant Chemoradiotherapy in Locally Advanced Rectal Cancer: Strategies and Challenges // Journal of Oncology. – 2022. – P. 1–17. – DOI: 10.1155/2022/1590620.

28. Chen T., Guestrin C. XGBoost. – 2016. – P. 785–794. – DOI: 10.1145/2939672.2939785.

29. Chicco D., Jurman G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation // BMC Genomics. – 2020. – Vol. 21, № 1. – P. 6–6. – DOI: 10.1186/s12864-019-6413-7.
30. Ching T., Himmelstein D. S., Beaulieu-Jones B. K. et al. Opportunities and obstacles for deep learning in biology and medicine // Journal of The Royal Society Interface. – 2018. – Vol. 15, № 141. – P. 20170387–20170387. – DOI: 10.1098/rsif.2017.0387.
31. Chowdhury A. B., Mehta K. J. Liver biopsy for assessment of chronic liver diseases: A synopsis // Clinical and Experimental Medicine. – 2022. – Vol. 23, № 2. – P. 273–285. – DOI: 10.1007/s10238-022-00799-z.
32. Das A., Connell M., Khetarpal S. Digital image analysis of ultrasound images using machine learning to diagnose pediatric nonalcoholic fatty liver disease // Clinical Imaging. – 2021. – Vol. 77. – P. 62–68. – DOI: 10.1016/j.clinimag.2021.02.038.
33. Dasarathy B. V., Sheela B. V. A composite classifier system design: Concepts and methodology // Proceedings of the IEEE. – 1979. – Vol. 67, № 5. – P. 708–713. – DOI: 10.1109/PROC.1979.11321.
34. Dong X., Qian M., Jiang R. Packet classification based on the decision tree with information entropy // The Journal of Supercomputing. – 2020. – Vol. 76, № 6. – P. 4117–4131. – DOI: 10.1007/s11227-017-2227-z.
35. Esteva A., Kuprel B., Novoa R. A. et al. Dermatologist-level classification of skin cancer with deep neural networks // Nature. – 2017. – Vol. 542, № 7639. – P. 115–118. – DOI: 10.1038/nature21056.
36. Friedrich–Rust M., Ong M., Martens S. et al. Performance of Transient Elastography for the Staging of Liver Fibrosis: A Meta-Analysis // Gastroenterology. – 2008. – Vol. 134, № 4. – P. 960–974.e8. – DOI: 10.1053/j.gastro.2008.01.034.

37. Fu Y., Lei Y., Wang T. et al. A review of deep learning based methods for medical image multi-organ segmentation // *Physica Medica*. – 2021. – Vol. 85. – P. 107–122. – DOI: 10.1016/j.ejmp.2021.05.003.
38. Furman E., Kye Y., Su J. Computing the Gini index: A note // *Economics Letters*. – 2019. – Vol. 185. – P. 108753–108753. – DOI: 10.1016/j.econlet.2019.108753.
39. Ghalati M. K., Nunes A., Ferreira H. et al. Texture Analysis and Its Applications in Biomedical Imaging: A Survey // *IEEE Reviews in Biomedical Engineering*. – 2022. – Vol. 15. – P. 222–246. – DOI: 10.1109/RBME.2021.3115703.
40. Graham R. N. J., Perriss R. W., Scarsbrook A. F. DICOM demystified: A review of digital file formats and their use in radiological practice // *Clinical Radiology*. – 2005. – Vol. 60, № 11. – P. 1133–1140. – DOI: 10.1016/j.crad.2005.07.003.
41. Gul S., Khan M. S., Bibi A. et al. Deep learning techniques for liver and liver tumor segmentation: A review // *Computers in Biology and Medicine*. – 2022. – Vol. 147. – P. 105620–105620. – DOI: 10.1016/j.compbimed.2022.105620.
42. Guo L., Chen W., Liao Y. et al. Multi-scale structural image quality assessment based on two-stage low-level features // *Computers & Electrical Engineering*. – 2014. – Vol. 40, № 4. – P. 1101–1110. – DOI: 10.1016/j.compeleceng.2014.01.004.
43. He H., Yang B., Garcia E. A. et al. ADASYN: Adaptive synthetic sampling approach for imbalanced learning. – 2008. – P. 1322–1328. – DOI: 10.1109/IJCNN.2008.4633969.
44. Haralick R. M., Shanmugam K., Dinstein I. Textural Features for Image Classification // *IEEE Transactions on Systems, Man, and Cybernetics*. – 1973. – Vol. SMC-3, № 6. – P. 610–621. – DOI: 10.1109/TSMC.1973.4309314.
45. He K., Zhang X., Ren S. et al. Deep Residual Learning for Image Recognition. – 2016. – P. 770–778. – DOI: 10.1109/CVPR.2016.90.

46. Herdiantoputri R. R., Komura D., Fujisaka K. et al. Deep texture representation analysis for histopathological images // STAR Protocols. – 2023. – Vol. 4, № 2. – P. 102161–102161. – DOI: 10.1016/j.xpro.2023.102161.
47. Hetland L. E., Kronborg T. M., Thing M. et al. Suboptimal diagnostic accuracy of ultrasound and CT for compensated cirrhosis: Evidence from prospective cohort studies // Hepatology Communications. – 2023. – Vol. 7, № 9. – DOI: 10.1097/HC9.0000000000000231.
48. Hively W. D., McCarty G. W., Reeves J. B. et al. Use of Airborne Hyperspectral Imagery to Map Soil Properties in Tilled Agricultural Fields // Applied and Environmental Soil Science. – 2011. – P. 1–13. – DOI: 10.1155/2011/358193.
49. Hofmanninger J., Prayer F., Pan J. et al. Automatic lung segmentation in routine imaging is primarily a data diversity problem, not a methodology problem // European Radiology Experimental. – 2020. – Vol. 4, № 1. – P. 50–50. – DOI: 10.1186/s41747-020-00173-2.
50. Irawati E. S., Pratomo B. Correlation Between Fibrosis-4 (FIB-4) Score and Metavir Score of Chronic Hepatitis C (CHC) Patients in Saiful Anwar Hospital Malang // The Indonesian Journal of Gastroenterology, Hepatology, and Digestive Endoscopy. – 2020. – Vol. 20, № 1. – P. 23–26. – DOI: 10.24871/201201923-26.
51. Ishware T., Metkar S. Comparative Analysis of Various Standards for Medical Image Compression. – 2023. – P. 351–363. – DOI: 10.1007/978-981-19-8094-7_27.
52. Jebur R. S., Der C. S., Hammood D. A. A Review and Taxonomy of Image Denoising Techniques. – 2020. – P. 1–6. – DOI: 10.1109/ICIDM51048.2020.9339674.
53. Katoch S., Chauhan S. S., Kumar V. A review on genetic algorithm: Past, present, and future // Multimedia Tools and Applications. – 2021. – Vol. 80, № 5. – P. 8091–8126. – DOI: 10.1007/s11042-020-10139-6.
54. Ke G., Meng Q., Finley T. et al. LightGBM: A highly efficient gradient boosting decision tree. – 2017.

55. Keyvanpour M. R., Vahidian S., Mirzakhani Z. An analytical review of texture feature extraction approaches // *International Journal of Computer Applications in Technology*. – 2021. – Vol. 65, № 2. – P. 118–118. – DOI: 10.1504/IJCAT.2021.114990.

56. Khan A., Sohail A., Zahoora U. et al. A survey of the recent architectures of deep convolutional neural networks // *Artificial Intelligence Review*. – 2020. – Vol. 53, № 8. – P. 5455–5516. – DOI: 10.1007/s10462-020-09825-6.

57. Konovalenko I., Maruschak P., Brevus V. Steel Surface Defect Detection Using an Ensemble of Deep Residual Neural Networks // *Journal of Computing and Information Science in Engineering*. – 2022. – Vol. 22, № 1. – DOI: 10.1115/1.4051435.

58. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // *Communications of the ACM*. – 2017. – Vol. 60, № 6. – P. 84–90. – DOI: 10.1145/3065386.

59. Kulambayev B. A Deep Learning-Based Approach for Road Surface Damage Detection // *Computers, Materials & Continua*. – 2022. – Vol. 73, № 2. – P. 3403–3418. – DOI: 10.32604/cmc.2022.029544.

60. Kumar A., Kaur A., Singh P. et al. Efficient Multiclass Classification Using Feature Selection in High-Dimensional Datasets // *Electronics*. – 2023. – Vol. 12, № 10. – P. 2290–2290. – DOI: 10.3390/electronics12102290.

61. Laws K. I. Rapid Texture Identification / Ed. by T. F. Wiener. – 1980. – P. 376–381. – DOI: 10.1117/12.959169.

62. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. – 2015. – Vol. 521, № 7553. – P. 436–444. – DOI: 10.1038/nature14539.

63. Lee J., Mukhanov L., Molahosseini A. S. et al. Resource-Efficient Convolutional Networks: A Survey on Model-, Arithmetic-, and Implementation-Level Techniques // *ACM Computing Surveys*. – 2023. – Vol. 55, № 13s. – P. 1–36. – DOI: 10.1145/3587095.

64. Li H., Cui J., Zhang X. et al. Dimensionality Reduction and Classification of Hyperspectral Remote Sensing Image Feature Extraction // Remote Sensing. – 2022. – Vol. 14, № 18. – P. 4579–4579. – DOI: 10.3390/rs14184579.
65. Linardatos P., Papastefanopoulos V., Kotsiantis S. Explainable AI: A Review of Machine Learning Interpretability Methods // Entropy. – 2020. – Vol. 23, № 1. – P. 18–18. – DOI: 10.3390/e23010018.
66. Litjens G., Kooi T., Bejnordi B. E. et al. A survey on deep learning in medical image analysis // Medical Image Analysis. – 2017. – Vol. 42. – P. 60–88. – DOI: 10.1016/j.media.2017.07.005.
67. Liu J., Jin Y. A comprehensive survey of robust deep learning in computer vision // Journal of Automation and Intelligence. – 2023. – Vol. 2, № 4. – P. 175–195. – DOI: 10.1016/j.jai.2023.10.002.
68. Liu W., Wang Z., Liu X. et al. A survey of deep neural network architectures and their applications // Neurocomputing. – 2017. – Vol. 234. – P. 11–26. – DOI: 10.1016/j.neucom.2016.12.038.
69. Liu X., Aldrich C. Deep Learning Approaches to Image Texture Analysis in Material Processing // Metals. – 2022. – Vol. 12, № 2. – P. 355–355. – DOI: 10.3390/met12020355.
70. Liu Z., Lin Y., Cao Y. et al. Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. – 2021. – P. 9992–10002. – DOI: 10.1109/ICCV48922.2021.00986.
71. Mahmood Z. Digital Image Processing: Advanced Technologies and Applications // Applied Sciences. – 2024. – Vol. 14, № 14. – P. 6051–6051. – DOI: 10.3390/app14146051.
72. Malik P., Pillai S., Agarwal K. et al. Diagnostic Accuracy of Elastography and Liver Disease: A Meta-Analysis // Gastroenterology Research. – 2022. – Vol. 15, № 5. – P. 232–239. – DOI: 10.14740/gr1557.

73. Mansour M., Kessler S., Khreisat A. et al. Vanishing Lung Syndrome: A Case Report and Systematic Review of the Literature // *Cureus*. – 2024. – DOI: 10.7759/cureus.53443.

74. Minaee S., Boykov Y. Y., Porikli F. et al. Image Segmentation Using Deep Learning: A Survey // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2021. – P. 1–1. – DOI: 10.1109/TPAMI.2021.3059968.

75. Mohamad M., Selamat A., Krejcar O. et al. Enhancing Big Data Feature Selection Using a Hybrid Correlation-Based Feature Selection // *Electronics*. – 2021. – Vol. 10, № 23. – P. 2984–2984. – DOI: 10.3390/electronics10232984.

76. Nahiduzzaman M., Ahamed M. F., Naznine M. et al. An automated waste classification system using deep learning techniques: Toward efficient waste recycling and environmental sustainability // *Knowledge-Based Systems*. – 2025. – Vol. 310. – P. 113028–113028. – DOI: 10.1016/j.knosys.2025.113028.

77. Nastenکو I., Maksymenko V., Dykan I. et al. Liver Pathological States Identification in Diffuse Diseases with Self-Organization Models Based on Ultrasound Images Texture Features. – 2020. – P. 21–25. – DOI: 10.1109/CSIT49958.2020.9321999.

78. Nastenکو I., Maksymenko V., Galkin A. et al. Liver Pathological States Identification with Self-organization Models Based on Ultrasound Images Texture Features // In: Shakhovska N., Medykovskyy M. O. (Eds.). *Advances in Intelligent Systems and Computing V.* – Springer International Publishing, 2021. – P. 401–418. – DOI: 10.1007/978-3-030-63270-0_26.

79. Nastenکو I., Maksymenko V., Potashev S. et al. Random Forest Algorithm Construction for the Diagnosis of Coronary Heart Disease Based on Echocardiography Video Data Streams // *Innovative Biosystems and Bioengineering*. – 2021. – Vol. 5, № 1. – P. 61–69. – DOI: 10.20535/ibb.2021.5.1.225794.

80. Personalized Clinical Treatment Selection Using Genetic Algorithm and Analytic Hierarchy Process / [O. Nosovets, **V. Babenko**, I. Davydovych et al.]. //

Advances in Science, Technology and Engineering Systems Journal. – 2021. – Vol. 6, No. 4. – pp. 406–413. ISSN: 24156698. DOI: [10.25046/aj060446](https://doi.org/10.25046/aj060446)

81. Ojala T., Pietikäinen M., Harwood D. A comparative study of texture measures with classification based on featured distributions // Pattern Recognition. – 1996. – Vol. 29, № 1. – P. 51–59. – DOI: 10.1016/0031-3203(95)00067-4.

82. Ojala T., Pietikainen M., Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2002. – Vol. 24, № 7. – P. 971–987. – DOI: 10.1109/TPAMI.2002.1017623.

83. Papkov M., Roberts K., Madisson L. A. et al. Noise2Stack: Improving Image Restoration by Learning from Volumetric Data. – 2021. – Vol. 12964 LNCS. – DOI: 10.1007/978-3-030-88552-6_10.

84. Parikh P., Ryan J. D., Tsochatzis E. A. Fibrosis assessment in patients with chronic hepatitis B virus (HBV) infection // Annals of Translational Medicine. – 2017. – Vol. 5, № 3. – P. 40–40. – DOI: 10.21037/atm.2017.01.28.

85. Cardiomyopathy Prediction in Patients with Permanent Ventricular Pacing Using Machine Learning Methods / [E. Perepeka, V. Lazoryshynets, V. **Babenko** et al.]. // System Research and Information Technologies. – 2024. – No. 1. – pp. 33–41. ISSN: 16816048, 23088893. DOI: [10.20535/SRIT.2308-8893.2024.1.03](https://doi.org/10.20535/SRIT.2308-8893.2024.1.03)

86. Petrillo A., Salomon V., Tramarico C. State-of-the-Art Review on the Analytic Hierarchy Process with Benefits, Opportunities, Costs, and Risks // Journal of Risk and Financial Management. – 2023. – Vol. 16, № 8. – P. 372–372. – DOI: 10.3390/jrfm16080372.

87. Raju P. P. C., Balachander B., Neeharika S. et al. Comparison of Haralick Texture Features and Gray Level Run Length Matrix Features for Analyzing Textural Variation in Cotton Leaves to Identify Spot Disease. – 2022. – P. 1–17. – DOI: 10.1109/MACS56771.2022.10023043.

88. Raveendran A. V., Jayadevan R., Sashidharan S. Long COVID: An overview // *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*. – 2021. – Vol. 15, № 3. – P. 869–875. – DOI: 10.1016/j.dsx.2021.04.007.

89. Razzak M. I., Naz S., Zaib A. Deep Learning for Medical Image Processing: Overview, Challenges and the Future. – 2018. – P. 323–350. – DOI: 10.1007/978-3-319-65981-7_12.

90. Rosenblatt M., Tejavibulya L., Jiang R. et al. Data leakage inflates prediction performance in connectome-based machine learning models // *Nature Communications*. – 2024. – Vol. 15, № 1. – P. 1829–1829. – DOI: 10.1038/s41467-024-46150-w.

91. Schapire R. E. The strength of weak learnability // *Machine Learning*. – 1990. – Vol. 5, № 2. – P. 197–227. – DOI: 10.1007/BF00116037.

92. Shang H., Sun C., Liu J. et al. Defect-aware transformer network for intelligent visual surface defect detection // *Advanced Engineering Informatics*. – 2023. – Vol. 55. – P. 101882–101882. – DOI: 10.1016/j.aei.2023.101882.

93. Inferring Cognitive Load Level from Physiological and Personality Traits / [O. Shaposhnyk, S. Yanushkevich, **V. Babenko** et al.]. // *Proceedings of The International Conference on Information and Digital Technologies, Zilina, Slovakia, 20-22 June 2023*. – pp. 233–242. ISSN: 2575–677X, 2575–6753. DOI: [10.1109/IDT59031.2023.10194430](https://doi.org/10.1109/IDT59031.2023.10194430)

94. Shatnawi M. Q., Abuein Q., Al-Quraan R. Deep learning-based approach to diagnose lung cancer using CT-scan images // *Intelligence-Based Medicine*. – 2025. – Vol. 11. – P. 100188–100188. – DOI: 10.1016/j.ibmed.2024.100188.

95. Shen B., Guo J., Yang Y. MedChain: Efficient Healthcare Data Sharing via Blockchain // *Applied Sciences*. – 2019. – Vol. 9, № 6. – P. 1207–1207. – DOI: 10.3390/app9061207.

96. Shen D., Wu G., Suk H.-I. Deep Learning in Medical Image Analysis // *Annual Review of Biomedical Engineering*. – 2017. – Vol. 19, № 1. – P. 221–248. – DOI: 10.1146/annurev-bioeng-071516-044442.

97. Shen L. Correlation between ultrasonographic and pathologic diagnosis of liver fibrosis due to chronic virus hepatitis // *World Journal of Gastroenterology*. – 2006. – Vol. 12, № 8. – P. 1292–1292. – DOI: 10.3748/wjg.v12.i8.1292.

98. Shetty R., Bhat V. S., Pujari J. Content-based medical image retrieval using deep learning-based features and hybrid meta-heuristic optimization // *Biomedical Signal Processing and Control*. – 2024. – Vol. 92. – P. 106069–106069. – DOI: 10.1016/j.bspc.2024.106069.

99. Shi F., Wang J., Shi J. et al. Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation, and Diagnosis for COVID-19 // *IEEE Reviews in Biomedical Engineering*. – 2021. – Vol. 14. – P. 4–15. – DOI: 10.1109/RBME.2020.2987975.

100. Shimizu K., Ponce-Hernandez R., Ahmed O. S. et al. Using Landsat time series imagery to detect forest disturbance in selectively logged tropical forests in Myanmar // *Canadian Journal of Forest Research*. – 2017. – Vol. 47, № 3. – P. 289–296. – DOI: 10.1139/cjfr-2016-0244.

101. Shorten C., Khoshgoftaar T. M. A survey on Image Data Augmentation for Deep Learning // *Journal of Big Data*. – 2019. – Vol. 6, № 1. – P. 60–60. – DOI: 10.1186/s40537-019-0197-0.

102. Singh J. Image Compression—An Overview // *International Journal Of Engineering And Computer Science*. – 2016. – DOI: 10.18535/ijecs/v5i8.18.

103. Šmíd V. Liver fibrosis // *Vnitřní Lékařství*. – 2020. – Vol. 66, № 4. – P. e36–e41. – DOI: 10.36290/vnl.2020.078.

104. Smith M. L., Stamp R. J. Automated inspection of textured ceramic tiles // *Computers in Industry*. – 2000. – Vol. 43, № 1. – P. 73–82.

105. Srilatha N., Reddy V. L. Image Texture Analysis with Local Binary Patterns: A Review. – 2021. – P. 1–6. – DOI: 10.1109/i-PACT52855.2021.9696847.

106. Sriramakrishnan P., Kalaiselvi T., Padmapriya S. T. et al. An Medical Image File Formats and Digital Image Conversion // *International Journal of*

Engineering and Advanced Technology. – 2019. – Vol. 9, № 1s4. – P. 74–78. – DOI: 10.35940/ijeat.A1093.1291S419.

107. Strubell E., Ganesh A., McCallum A. Energy and policy considerations for deep learning in NLP // ACL 2019 – 57th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference. – 2020.

108. Tas E., Sundararajan D., Lo J. S. et al. Diagnostic Accuracy of Transient Elastography in Hepatosteatosi in Youth With Obesity // Journal of the Endocrine Society. – 2024. – Vol. 8, № 7. – DOI: 10.1210/jendso/bvae110.

109. Tin Kam Ho. Random decision forests. – 1995. – Vol. 1. – P. 278–282. – DOI: 10.1109/ICDAR.1995.598994.

110. Tsiaparas N., Golemati S., Andreadis I. et al. Comparison of Multiresolution Features for Texture Classification of Carotid Atherosclerosis From B-Mode Ultrasound // IEEE Transactions on Information Technology in Biomedicine. – 2011. – Vol. 15, № 1. – P. 130–137. – DOI: 10.1109/TITB.2010.2091511.

111. Vujovic Ž. Đ. Classification Model Evaluation Metrics // International Journal of Advanced Computer Science and Applications. – 2021. – Vol. 12, № 6. – DOI: 10.14569/IJACSA.2021.0120670.

112. Wang S., Kang B., Ma J. et al. A deep learning algorithm using CT images to screen for Corona virus disease (COVID-19) // European Radiology. – 2021. – Vol. 31, № 8. – P. 6096–6104. – DOI: 10.1007/s00330-021-07715-1.

113. Wu C.-M., Chen Y.-C. Statistical feature matrix for texture analysis // CVGIP: Graphical Models and Image Processing. – 1992. – Vol. 54, № 5. – P. 407–419. – DOI: 10.1016/1049-9652(92)90025-S.

114. Xia Q., Zheng H., Zou H. et al. A comprehensive review of deep learning for medical image segmentation // Neurocomputing. – 2025. – Vol. 613. – P. 128740–128740. – DOI: 10.1016/j.neucom.2024.128740.

115. Yan S., Zhao J., Xu L. Adaptive multi-task learning for cross domain and modal person re-identification // Neurocomputing. – 2022. – Vol. 486. – P. 123–134. – DOI: 10.1016/j.neucom.2021.11.016.

116. Unraveling Body Vitals as Traumatic Event-Caused Stress Indicators / [D. Zahorska, **V. Babenko**, M. Chernykh et al.]. // IEEE Symposium Series on Computational Intelligence (SSCI), Mexico City, Mexico, 5-8 December 2023. – pp. 1656–1661. ISSN: 2472–8322, 2770–0097. DOI: [10.1109/SSCI52147.2023.10372048](https://doi.org/10.1109/SSCI52147.2023.10372048)

117. Zhao J., Kong L., Lv J. An Overview of Deep Neural Networks for Few-Shot Learning // Big Data Mining and Analytics. – 2025. – Vol. 8, № 1. – P. 145–188. – DOI: 10.26599/BDMA.2024.9020049.

ДОДАТОК А
СПИСОК ПУБЛІКАЦІЙ ТА ВІДОМОСТІ ПРО АПРОБАЦІЮ
РЕЗУЛЬТАТІВ ДИСЕРТАЦІЇ

– Перелік публікацій:

1. Personalized Clinical Treatment Selection Using Genetic Algorithm and Analytic Hierarchy Process / [O. Nosovets, **V. Babenko**, I. Davydovych et al.]. // Advances in Science, Technology and Engineering Systems Journal. – 2021. – Vol. 6, No. 4. – pp. 406–413. ISSN: 24156698. DOI: [10.25046/aj060446](https://doi.org/10.25046/aj060446) [80]
2. Порівняльний аналіз алгоритмів класифікації при аналізі медичних зображень за відеоданими спекл-трекінг ехокардіографії / [О. Петруніна, Д. Шевага, **В. Бабенко** та ін.]. // Innovative Biosystems and Bioengineering. – 2021. – Том 5, № 3. – С. 153–166. ISSN: 2616–177X. DOI: [10.20535/ibb.2021.5.3.234990](https://doi.org/10.20535/ibb.2021.5.3.234990) [15]
3. Добровська Л. Комбінація локальної порогової бінаризації та машинного навчання для класифікації пухлин молочної залози / Л. Добровська, **В. Бабенко**, А. Іванченко. // Біомедична інженерія і технологія. – 2022. – № 8. – С. 40–47. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2022.8.267793](https://doi.org/10.20535/2617-8974.2022.8.267793) [7]
4. Classification of Pathologies on Medical Images Using the Algorithm of Random Forest of Optimal-Complexity Trees / [**V. Babenko**, I. Nastenکو, V. Pavlov et al.]. // Cybernetics and Systems Analysis. – 2023. – Vol. 59, No. 2. – pp. 346–358. ISSN: 15738337, 10600396. DOI: [10.1007/s10559-023-00569-z](https://doi.org/10.1007/s10559-023-00569-z) [18]
5. Використання глибоких нейронних мереж для порівняльного аналізу норми, пневмонії і COVID-19 / [Р. Юхимюк, М. Шкепаст, Є. Настенко, М. Лінник, І. Давидович, **В. Бабенко**]. // Біомедична інженерія і технологія. – 2023. – № 12. – С. 56–64. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2023.12.292729](https://doi.org/10.20535/2617-8974.2023.12.292729) [16]
6. Cardiomyopathy Prediction in Patients with Permanent Ventricular Pacing Using Machine Learning Methods / [E. Perepeka, V. Lazoryshynets, **V.**

Babenko et al.] // System Research and Information Technologies. – 2024. – No. 1. – pp. 33–41. ISSN: 16816048, 23088893. DOI: [10.20535/SRIT.2308-8893.2024.1.03](https://doi.org/10.20535/SRIT.2308-8893.2024.1.03) [85]

7. Давидович І. Методології аналізу зображень для діагностичних застосувань (огляд) / І. Давидович, **В. Бабенко**. // Біомедична інженерія і технологія. – 2024. – № 14. – С. 54–63. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2024.14.302135](https://doi.org/10.20535/2617-8974.2024.14.302135) [6]

8. Ієрархічний алгоритм мультикласифікації стадій фіброзу печінки з інтегрованим аналізом областей інтересу / [**В. Бабенко**, Є. Настенко, В. Солодущенко та ін.]. // Біомедична інженерія і технологія. – 2024. – № 14. – С. 63–73. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/2617-8974.2024.14.301108](https://doi.org/10.20535/2617-8974.2024.14.301108) [3]

9. Розробка програм на основі штучного інтелекту для діагностики міокардиту при COVID-19 за даними комп'ютерної томографії грудної клітки / [Є. Настенко, М. Гончарук, **В. Бабенко** та ін.]. // Український журнал серцево-судинної хірургії. – 2024. – Том 32, № 3. – С. 58–65. ISSN: 26645963, 26645971. DOI: [10.30702/ujcvs/24.32\(03\)/NH052-5865](https://doi.org/10.30702/ujcvs/24.32(03)/NH052-5865) [12]

10. Ефективність алгоритмів машинного навчання для класифікації змін структури легень у постковідних та гострих стадіях COVID-19 / В. Лутченко, **В. Бабенко**, Є. Настенко, М. Линник. – 2024. – №15. – С. 27–35. ISSN: 2617–8974, 2707–8434. DOI: [10.20535/.2024.15.306763](https://doi.org/10.20535/.2024.15.306763) [8]

• **Апробація матеріалів дисертації:**

1. IV міжнародна науково-практична конференція «Інформаційні системи та технології в медицині» (ICM-2021), м. Харків, 25–26 листопада 2021 року, заочна форма участі з публікацією тез [2]

2. Міжнародна науково-практична конференція «Сучасний стан та перспективи біомедичної інженерії», присвячена 20-річному ювілею Факультету біомедичної інженерії КПІ ім. Ігоря Сікорського, м. Київ, 15–16 грудня 2022 року, онлайн участь з доповіддю та публікацією тез [19]

3. Міжнародна IEEE конференція з інформаційних та цифрових технологій, Жиліна, Словаччина, 20–22 червня 2023 року, заочна форма участі з публікацією тез в Scopus [93]


4. 9й Національний конгрес з міжнародною участю «Радіологія в Україні», Київ, Україна, 19–21 жовтня 2023 року, очна форма участі з доповіддю.

5. Міжнародна серія симпозіумів IEEE з обчислювального інтелекту (SSCI), Мехіко, Мексика, 5–8 грудня 2023 року, заочна форма участі з публікацією тез в Scopus [116]

6. Семінар з проблеми «Образний комп'ютер», м. Київ, 26 листопада 2024 року, очна форма участі з доповіддю.

ДОДАТОК Б

АКТИ ВПРОВАДЖЕННЯ



Інститут Ядерної
Медицини та
Променевої Діагностики

«ЗАТВЕРДЖУЮ»

Директор ДУ «Інститут ядерної медицини та променевої діагностики НАМН України»
чл.-кор. НАМН України, проф. Дикан І.М.

« 3 » листопада 2022 р.

Акт

впровадження в практичну охорону здоров'я

матеріалів наукових досліджень

Найменування пропозиції для впровадження:

Система підтримки прийняття діагностичних рішень «норма-патологія» при дифузних захворюваннях печінки за даними УЗ зображень

Ким запропоновано:

НТУУ «Київський політехнічний інститут імені Ігоря Сікорського», Факультет біомедичної інженерії, кафедра біомедичної кібернетики, Настенко Є.А., Павлов В.А., Бабенко В.О., Гончарук М.О., Білошицька О.К., Городецька О.К., Бовсуновська К.С., Авер'янова О.А., Корнієнко Г.А.

Джерело інформації:

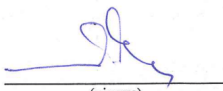
- Дыкан И. Н. Разностные гистограммы матриц смежности изображений УЗ в задаче диагностики заболеваний печени / И. Н. Дыкан, В. В. Круглый, Е. А. Настенко, В. А. Павлов, В. В. Солодущенко // Международный научный журнал "Интернаука". - 2019. - №11.
- Ievgen Nastenko, Olena Nosovets, Vitalii Babenko, Marina Dyba, Vitalii Maksymenko, Boris Tarasiuk, Vladyslav Kruhlyi, Vitalij Umanets, Irina Dykan, Volodymyr Pavlov, Volodymyr Solodushchenko / Liver Pathological States Identification in Diffuse Diseases with Self-Organization Models Based on Ultrasound Images Texture Features. // Proceedings of the XV IEEE International Conference CSIT-20& International Workshop on Inductive Modeling. Zbarazh Castle, UKRAINE, 23-26 September, 2020 – 314 p. / P. 21-26, DOI: 10.1109/CSIT49958.2020.9321999
- Hrishko D., Trofymenko O., Nosovets O., Bovsunoskaja K., Dykan I., Tarasiuk B. Pavlov V., Nastenko Ie. Optimal Complexity Structures of Ultrasound Image Models in Diagnostic Decision-Making System// Proceedings of the XVI IEEE International Conference CSIT-21& International Workshop on Inductive Modeling. Lviv, UKRAINE, 23-26 September, 2021 P. 390-393. DOI: 10.1109/CSIT52700.2021.9648686
- Іванченко А.С. Класифікатор диференціальної діагностики аутоімунного гепатиту та хвороби Вільсона на основі аналізу ультразвукових зображень печінки / А.С. Іванченко, К.С. Бовсуновська, І.М. Дикан, Б.А. Тарасюк, В.А. Павлов, Є.А. Настенко // Біомедична інженерія і технологія – 2021. – № 6. – С. 62-73
- Патент України на корисну модель № 139916 «Спосіб діагностики дифузних захворювань печінки у дітей». Винахідники: Дикан Ірина Миколаївна, Настенко Євген Арнольдович, Максименко Віталій Борисович, Павлов Володимир Анатолійович, Круглий Владислав Володимирович, Тарасюк Борис Андрійович, Березенко Валентина Сергіївна, Солодущенко Володимир Вячеславович. Зареєстровано у державному реєстрі патентів України на корисну модель 27.01.2020
- Майнові права на твір наукового характеру: «Система підтримки прийняття рішень при діагностиці фіброзних змін печінки у дітей» авторів Дикан Ірина Миколаївна, Максименко Віталій Борисович, Настенко Євген Арнольдович, Тарасюк Андрій Борисович, Павлов Володимир Анатолійович, Круглий Владислав Володимирович, Носовець Олена Константинівна, Бабенко Віталій Олегович, Гончарук Максим Олександрович, Березенко Валентина Сергіївна, Солодущенко Володимир Вячеславович. ДП «Український інститут державної властності» Реєстраційний номер 6461 від 29 грудня 2021 року.

Рекомендовано впровадити:

Система підтримки прийняття діагностичних рішень «норма-патологія» при дифузних захворюваннях печінки за даними УЗ зображень

Строки впровадження: з травня 2022р.

Заступник директора з наукової роботи ДУ «ІЯМНД», доктор медичних наук



(підпис)

Тарасюк Б.А.

Рисунок Б.1 – Акт впровадження в ДУ «Інститут ядерної медицини та променевої діагностики НАМН України»

«ЗАТВЕРДЖУЮ»

Заступник директора з наукової роботи
державної установи «Інститут педіатрії,
акушерства і гінекології імені академіка
О.М.Лук'янової НАМН України»
доктор медичних наук Наталя ГОРБАНЬ

«13» червня 2024 р.

**Акт
впровадження в практичну охорону здоров'я
матеріалів наукових досліджень**

Найменування пропозиції для провадження: «Система підтримки прийняття діагностичних рішень деталізованого ступеню фіброзу у дітей при аутоімунному гепатиті за станом судин на УЗ зображеннях печінки» у ДУ «Інститут педіатрії акушерства і гінекології імені академіка О. М. Лук'янової НАМН України», розробленої згідно договору про співпрацю Д/0002.01/3400.02/291/2023 від 27.10.2023 року з НТТУ «Київський політехнічний інститут ім. Ігоря Сікорського»

Ким запропоновано: ДУ «Інститут педіатрії акушерства і гінекології імені академіка О. М. Лук'янової НАМН України», Дибя М.Б., НТТУ «Київський політехнічний інститут ім. Ігоря Сікорського», Урсу І.О., Шевченко О.О., Буднік Ю.С., Бабенко В.О., Настенко Є. А., Павлов В.А., ДУ «Інститут ядерної медицини та променевої діагностики НАМН України», Тарасюк Б.А.

Джерело інформації:

1. Урсу І.О., Буднік Ю.С., Шевченко О.О., Дибя М.Б., Тарасюк Б.А., Павлов В.А. Система визначення ступеню фіброзу по ультразвуковим зображенням печінки дітей при аутоімунному гепатиті. *Control Systems and Computers*. 2024 № 2.
2. В. Бабенко, Є. Настенко, В. Солодушенко, В. Павлов, І. Дикан. Ієрархічний алгоритм мультикласифікації стадій фіброзу печінки з інтегрованим аналізом областей інтересу. *Biomedical Engineering and Technology*. Issue 14 (2024).

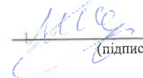
Строки впровадження: травень-червень 2024 р.

Загальна кількість спостережень: в межах клінічно-консультативної роботи відділення гепатології і коморбідних захворювань у дітей ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України» обстежено 34 дитини з проведенням оцінки ступеня фіброзу при аутоімунному гепатиті за станом судин на УЗ-зображеннях.

Результати впровадження: за результатами проведеного впровадження було покращено діагностику ступеня фіброзу при аутоімунному гепатиті за станом судин на УЗ-зображеннях печінки у 34 дітей. Результати стали підґрунтям для подальшого вдосконалення діагностичного процесу у дітей з аутоімунним гепатитом.

Пропозиції та зауваження: відсутні.

Старший науковий співробітник відділення
гепатології і коморбідних захворювань у
дітей, кандидат медичних наук


(підпис)

Марина ДИБА

Рисунок Б.2 – Акт впровадження в ДУ «Інститут педіатрії, акушерства і гінекології імені академіка О.М. Лук'янової НАМН України»

«ЗАТВЕРДЖУЮ»

Заступник генерального директора
з наукової роботи ДУ «Національний
науковий центр фтизіатрії, пульмонології
та алергології ім. Ф. Г. Яновського»
НАМН України
д.мед.н. професор Кашуба І.А.

«26» 12 2024 р.

АКТ ВПРОВАДЖЕННЯ

1. **Назва запропонованого впровадження:** «Технологія визначення Ковід-асоційованих змін легень за даними комп'ютерної томографії» на основі алгоритмів машинного навчання.
2. **Установа-розробник:** Національний технічний університет України "Київський політехнічний інститут імені Ігоря Сікорського" МОН України
3. **Джерела інформації:**
 - 3.1. Використання глибоких нейронних мереж для порівняльного аналізу норми, пневмонії і COVID-19 /Biomedical Engineering and Technology. Issue 12, 2023. Р. 56-64. // Юхимюк Р., Шкепаст М., Настенко Є., Линник М., Давидович І., Бабенко В./ <http://biomedtech.kpi.ua/article/view/292729> (автори: Настенко С.А., Максименко В.Б., Линник М.І., Бабенко В.О., Давидович І.В.)
 - 3.2. Ефективність алгоритмів машинного навчання для класифікації змін структури легень у постковідних та гострих стадіях COVID-19 / В. Лутченко, В. Бабенко, С. Настенко, М. Линник. – 2024. – №15. – С. 27–35. ISSN: 2617–8974, 2707–8434. DOI: 10.20535/2024.15.306763
4. **Де і коли впроваджено:** Відділ епідеміологічних та організаційних проблем фтизіопульмонології _____;

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

5. **Ефективність впровадження у відповідності з критеріями, викладеними у джерелі інформації:** впровадження технології дозволило підвищити точність діагностики Ковід-асоційованих змін легень на основі алгоритмів машинного навчання.

6. **Зауваження, пропозиції:** запропонована методика відповідає потребам клінічної практики.

Відповідальний за впровадження:  / д.мед.н. Линник М. /

26 грудня 2024 р.

Рисунок Б.4 – Акт впровадження в ДУ «Національний науковий центр фтизіатрії, пульмонології та алергології ім. Ф.Г. Яновського» (друга сторінка)

«ЗАТВЕРДЖУЮ»

Т.в.о. Заступника директора
Інституту інформаційних технологій
та систем НАН України
Волошенюк Д.О.

 10 січня 2025 р.

ДОВІДКА ПРО ВИКОРИСТАННЯ

- Назва запропонованого наукового продукту:** «Технологія визначення Ковід-асоційованих змін легень за даними комп'ютерної томографії» на основі алгоритмів машинного навчання.
- Установа-розробник:** Національний технічний університет України "Київський політехнічний інститут імені Ігоря Сікорського" МОН України
- Джерела інформації:**
 - Використання глибоких нейронних мереж для порівняльного аналізу норми, пневмонії і COVID-19 /Biomedical Engineering and Technology. Issue 12, 2023. Р. 56-64. // Юхимюк Р., Шкепаст М., Настенко С., Линник М., Давидович І., Бабенко В./ <http://biomedtech.kpi.ua/article/view/292729> (автори: Настенко С.А., Максименко В.Б., Линник М.І., Бабенко В.О., Давидович І.В.)
 - Ефективність алгоритмів машинного навчання для класифікації змін структури легень у постковідних та гострих стадіях COVID-19 / В. Лутченко, В. Бабенко, Є. Настенко, М. Линник. – 2024. – №15. – С. 27–35. ISSN: 2617–8974, 2707–8434. DOI: 10.20535/.2024.15.306763
- Де і коли використано: Відділ медичних інформаційних технологій;
- Ефективність технології у відповідності з критеріями, викладеними у джерелі інформації:** використання технології дозволить підвищити точність діагностики Ковід-асоційованих змін легень за даними комп'ютерної томографії. Елементи технології будуть застосовані в наукових дослідженнях відділу МІТ

Відповідальний за використання:  / О.Коваленко /

10 січня 2025 р.

Рисунок Б.5 – Акт впровадження в Інститут інформаційних технологій та систем НАН України