

А. Ю. ШЕГЕРА, магістр, каф. ФБМЕКІТ ХНУ імені В.Н. Каразіна, Харків,

О. М. ВЕЛИЧКО, канд. техн. наук, доц. каф. ФБМЕКІТ ХНУ імені В.Н. Каразіна, Харків,

О. М. ДАЦОК, канд. техн. наук, доц. каф. ФБМЕКІТ ХНУ імені В.Н. Каразіна, Харків

ЗАСТОСУВАННЯ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ КЛАСИФІКАЦІЇ ОФТАЛЬМОЛОГІЧНИХ ЗАХВОРЮВАНЬ ЗА ЗОБРАЖЕННЯМИ ОЧНОГО ДНА

У роботі висвітлено актуальність застосування методів машинного навчання для автоматизації діагностики в офтальмології. Проведено аналіз існуючих підходів і проблем, пов'язаних із дисбалансом даних та складністю інтерпретації результатів. Розроблено програмний прототип на основі згорткової нейронної мережі ResNet-18 для мультилейблової класифікації восьми поширених офтальмологічних патологій за знімками очного дна з набору даних ODIR-5K. Продемонстровано, що модель досягає обнадійливих результатів (масго-усереднений ROC AUC $\sim 0,86$), але її ефективність суттєво різниться між класами. Проаналізовано вплив порогів бінаризації на метрики точності та повноти, що є критичним для адаптації моделі до клінічних завдань. Результати підтверджують перспективність підходу, але вказують на необхідність подальшого вдосконалення для подолання дисбалансу класів та підвищення надійності. Л.: 4. Бібліогр.: 10 назв.

Ключові слова: машинне навчання, глибоке навчання, згорткові нейронні мережі, ResNet-18, медичні зображення, офтальмологія, класифікація захворювань, аналіз даних.

Постановка проблеми. Офтальмологічні захворювання, зокрема діабетична ретинопатія та глаукома, є одними з провідних причин незворотної втрати зору в усьому світі. Ключовим інструментом для їх своєчасної діагностики слугують зображення очного дна, аналіз яких є складним процесом, що потребує високої кваліфікації та значних часових витрат. Із постійним зростанням обсягів медичних даних традиційні підходи до їх аналізу стають недостатньо ефективними, що створює ризики пропуску патологій на ранніх стадіях [1].

Методи машинного навчання здатні знаходити складні та неочевидні для людського ока закономірності у великих наборах даних. Застосування алгоритмів штучного інтелекту, а саме глибоких згорткових нейронних мереж (CNN), відкриває значні перспективи для автоматизації аналізу

медичних зображень, що доведено успішними прикладами в суміжних галузях, як-от дерматологія [2]. Ці технології здатні допомагати лікарям у прийнятті клінічних рішень, потенційно підвищуючи точність та швидкість діагностики [3].

Однак, попри значний потенціал, впровадження таких систем у реальну клінічну практику стикається з низкою проблем. Серед них: значний дисбаланс класів у реальних медичних датасетах, де рідкісні патології представлені значно менше; варіабельність якості зображень та умов їх отримання [4]; а також питання довіри до моделей, які часто сприймаються як «чорні скриньки» [5]. Таким чином, існує нагальна потреба в дослідженнях, спрямованих не лише на підвищення технічної точності алгоритмів, а й на вирішення цих практичних викликів для створення надійних та інтерпретованих систем підтримки прийняття рішень.

Аналіз літератури. Сучасна медична наука дедалі активніше інтегрує методи штучного інтелекту, що підтверджується зростаючою кількістю профільних публікацій. Ключовою передумовою цієї тенденції є епоха великих даних (Big Data) в охороні здоров'я. Як зазначається в [1], традиційні статистичні інструменти виявляються недостатньо ефективними для обробки великих та динамічних інформаційних масивів, що породжує гостру потребу в нових, більш гнучких та точних аналітичних підходах, які пропонує машинне навчання.

Огляд [3] категоризує основні методи машинного навчання (включно з регресією, класифікацією та глибокими нейронними мережами) та ілюструє їхній потенціал для підвищення клінічної ефективності. Автори показують, як ці технології можуть слугувати інструментами підтримки лікарських рішень, починаючи від прогнозування результатів терапії й закінчуючи оптимізацією діагностичного процесу. Водночас наголошується на критичній необхідності валідації моделей та дотриманні етичних стандартів під час їх розробці.

CNN успішно застосовуються для класифікації раку шкіри [2]. Модель продемонструвала точність, порівнянну з рівнем досвідчених дерматологів, що довело принципову можливість використання подібних алгоритмів для первинного скринінгу. Цей успіх став прецедентом, що відкриває шлях до прискорення діагностики та зниження ризику пропущених небезпечних патологій.

Машинне навчання впроваджується в клінічну практику – від автоматизації аналізу електронних медичних карток до створення

розумних систем підтримки прийняття рішень, здатних аналізувати анамнез пацієнта та його біомаркери [6], [7]. Проте таке впровадження пов'язане з викликами, серед яких – потреба у значних обчислювальних ресурсах та формування чітких регуляторних рамок, особливо у сфері конфіденційності даних.

В колективній монографії [5] узагальнено міжнародний досвід використання нейронних мереж, методів обробки природної мови та інших інструментів для вирішення реальних клінічних завдань. Особливий акцент у книзі зроблено на проблемі інтерпретації результатів та питанні довіри до так званих «чорних скриньок» з боку як лікарів, так і пацієнтів.

У специфічній галузі медичної візуалізації, як показано в огляді [4], глибокі згорткові нейронні мережі демонструють значні переваги над традиційними методами аналізу. Особливо вираженим цей прогрес є в офтальмології, де аналіз зображень очного дна є ключовим для діагностики, що детально розглядається у критичному огляді [8]. Сучасні дослідження підтверджують успішне застосування машинного навчання для широкого спектра завдань, пов'язаних з аналізом знімків сітківки [9], зокрема для класифікації таких поширених захворювань, як діабетична ретинопатія [10]. Водночас автори рішуче підкреслюють, що продуктивність моделі фундаментально залежить від якості та репрезентативності даних.

Підсумовуючи, наявна наукова література свідчить, що машинне навчання трансформувалося з академічної концепції у реальний інструмент для медицини. Тим не менш, на шляху до широкого впровадження залишається низка перешкод: відсутність уніфікованих стандартів обміну даними, проблема інтерпретації моделей, високі вимоги до обчислювальних ресурсів та необхідність гарантування безпеки інформації. Незважаючи на ці виклики, досвід передових дослідницьких груп та медичних центрів доводить, що штучний інтелект має трансформаційний потенціал для радикального вдосконалення діагностики, лікування та моніторингу, пропонуючи вищу точність та індивідуалізований підхід.

Мета статті – дослідити потенціал та виявити практичні проблеми застосування згорткових нейронних мереж для автоматизації діагностики в медицині. Як базу було розроблено програмний прототип для класифікації офтальмологічних захворювань. На його прикладі проведено аналіз ефективності моделі на незбалансованих даних, досліджено вплив

ключових параметрів на результат та окреслено основні виклики, що стоять на шляху впровадження таких систем у реальну клінічну практику.

Обґрунтування вибору джерела медичних даних.

Ефективність будь-якого алгоритму машинного навчання безпосередньо залежить від характеру даних, на яких він навчається. У медичній сфері ця різноманітність є особливо вираженою. У межах даної роботи, що фокусується на офтальмології, ключовим джерелом інформації виступають саме медичні зображення, проте важливо розуміти їхнє місце серед інших типів даних.

Традиційно дані поділяють на структуровані, як-от таблиці в електронних медичних картках, що містять поля «вік», «стать» чи «діагноз». Хоча вони корисні для загального аналізу, натомість, для задач, пов'язаних із візуальною діагностикою патологій, як у нашому випадку, такі дані хоч і є цінним контекстом, але не містять первинних візуальних ознак захворювання.

Інший великий пласт становлять неструктуровані дані (наприклад, текстові нотатки лікарів) та напівструктуровані (PDF-звіти). Хоча вони містять безцінні клінічні деталі, їх аналіз потребує складних методів обробки природної мови (NLP), що є окремим напрямком досліджень. В нашому випадку робота зосереджена на прямому аналізі візуальних джерел, а не текстових.

Предметом дослідження є медичні зображення, а саме — фотографії очного дна. Саме цей тип даних є «золотим стандартом» для діагностики більшості поширених офтальмологічних захворювань. На відміну від інших методів візуалізації (MPT чи КТ), які застосовуються для інших цілей, фотографії очного дна дозволяють безпосередньо оцінити стан сітківки, зорового нерва та судин. Тому обробка саме цих зображень за допомогою глибоких згорткових нейронних мереж є завданням роботи.

Матеріали та підхід до експерименту.

Для експериментальної перевірки гіпотези про доцільність застосування нейронних мереж в офтальмології було використано публічний набір даних ODIR-5K. Цей dataset містить тисячі зображень очного дна та відповідні їм мультилейблові діагностичні мітки (8 класів: норма, діабетична ретинопатія, глаукома, катаракта та ін.) (рис. 1). Ознаки аномальних ділянок не завжди можуть бути виявлені візуальним аналізом. Процес ускладнюється схожими за характеристиками ділянками, які проявляються для різних класів захворювань або їх комбінацій.




Рис. 1. Приклад зображень з набору даних ODIR-5K (діабет та норма відповідно)

Як основний інструмент було обрано методи глибокого навчання, а саме згорткові нейронні мережі (CNN). Порівняльний аналіз методів машинного навчання свідчить, що саме CNN демонструють найвищу ефективність у задачах розпізнавання зображень [7], хоча й потребують великих обсягів даних та є складними для інтерпретації. Програмна реалізація прототипу виконана мовою Python з використанням фреймворку PyTorch.

Архітектура моделі та етапи роботи.

Процес розробки та тестування моделі для класифікації офтальмологічних захворювань проходив у кілька ключових етапів.

Початковим етапом був збір та попередня обробка даних, що включало підготовку датасету ODIR-5K. Це передбачало аугментацію даних для навчальної вибірки (випадкові повороти, віддзеркалення) з метою підвищення стійкості моделі до перенавчання та збільшення різноманітності навчальних прикладів, а також адаптація маркування dataset під потреби моделі (було відкинуто дані про вік і стать пацієнта).

Наступним кроком було формування та очищення вибірки, де увага приділялася якості зображень, коректності діагностичних міток, а також проблемам, пов'язаним із дисбалансом даних, де певні патології представлені значно рідше за інші. Хоча в даній роботі не проводилось заповнення пропусків чи специфічне масштабування окрім нормалізації, ці аспекти є важливими для загальної методології.

Далі здійснювався вибір методу машинного навчання. Як базову архітектуру було обрано згорткову нейронну мережу ResNet-18 з

використанням механізму трансферного навчання, де ваги були попередньо навчені на dataset ImageNet. Цей підхід довів свою ефективність у задачах аналізу медичних зображень.

Центральним етапом було навчання та оптимізація моделі. Для боротьби з дисбалансом класів, що є поширеною проблемою в медичних даних, було використано зважену функцію втрат BCEWithLogitsLoss. Оптимізація ваг моделі здійснювалася за допомогою алгоритму Adam, а також використовувався планувальник швидкості навчання ReduceLROnPlateau для динамічного її коригування.

Після кожної епохи навчання проводилася валідація та тестування моделі на окремій валідаційній вибірці за допомогою ключових метрик, таких як ROC AUC, F1-score, Precision та Recall. Найкраща за результатами валідації модель зберігалася для фінального тестування.

Оцінка точності проводилася не лише за загальними метриками, але й аналізувалася залежність точності та повноти від порогу бінаризації, а також варіабельність точності для різних класів захворювань.

Кінцевою метою подібних розробок є клінічне використання як інструменту підтримки прийняття рішень лікарями, хоча поточний прототип ще потребує вдосконалення для досягнення цієї стадії.

Аналіз отриманих результатів.

Проведені експерименти показали, що розроблений прототип на основі ResNet-18 здатний до навчання та може виявляти патологічні патерни на зображеннях очного дна. Метрикою для оцінки загальної здатності моделі розрізняти різні офтальмологічні стани є площа під кривою ROC (ROC AUC). Динаміка макро-усередненої метрики ROC AUC на валідаційній вибірці протягом епох навчання показана на рис. 2. Макро-усереднення означає, що ROC AUC обчислюється для кожного класу окремо, а потім усереднюється, надаючи однакову вагу кожному класу незалежно від його представленості в датасеті. Це особливо важливо для датасетів з дисбалансом класів, як ODIR-5K.

Як видно з графіку (рис. 2), значення ROC AUC поступово зростає з кількістю епох навчання, що вказує на покращення здатності моделі до класифікації. Після 18 – 20 епох метрика виходить на плато біля значення 0,86. Значення ROC AUC 0,86 значно перевищує 0,5 (що відповідало б випадковому вгадуванню) і свідчить про добру роздільну здатність моделі. Вихід на плато показує, що модель досягла свого максимального потенціалу за даних умов навчання і подальше тренування не призводить

до суттєвого покращення цієї метрики, а може навіть спричинити перенавчання.




Рис. 2. Динаміка метрики ROC AUC (макро) протягом епох навчання

Важливим для адаптації моделі до клінічних завдань є аналіз залежності ключових метрик від порогу бінаризації. Цей поріг визначає, з якої ймовірності, виданої моделлю, випадок буде віднесено до позитивного класу. На рис. 3 показано, як макро-усереднені метрики Precision (точність), Recall (повнота), F1-score та загальна точність (Accuracy overall) змінюються залежно від обраного порогу бінаризації на валідаційній вибірці.

Precision (точність) показує, яка частка випадків, визначених моделлю як позитивні, дійсно є такими. Зі збільшенням порогу бінаризації модель стає обережнішою, класифікуючи лише найбільш впевнені випадки як позитивні, що призводить до зростання точності.

Recall (повнота або чутливість) показує, яку частку всіх реальних позитивних випадків модель змогла правильно ідентифікувати. Зі збільшенням порогу, певні справді позитивні випадки з меншою прогнозованою ймовірністю можуть бути пропущені, тому повнота падає.

F1-score є гармонійним середнім між Precision та Recall і дає збалансовану оцінку, особливо корисну за умови дисбалансу класів. Ця метрика досягає максимуму за умови певного оптимального порога, де досягається найкращий баланс між точністю та повнотою.

Accuracy (overall) – загальна точність, яка показує частку всіх правильно класифікованих зразків. Хоча вона також змінюється з порогом,

для медичних задач з дисбалансом класів вона менш інформативна, ніж Precision, Recall та F1-score.




Рис. 3. Залежність макросереднєх метрик від порогу бінаризації

Існує обернена залежність між Precision та Recall: підвищення одного часто призводить до зниження іншого. Цей компроміс є критичним. Наприклад, для скринінгових завдань, де важливо не пропустити хворого, пріоритетом є високий Recall, навіть якщо це дещо знизить Precision (тобто буде більше хибнопозитивних результатів, що потребуватимуть подальшої перевірки). Для завдань підтвердження діагнозу, навпаки, може бути важливішою висока Precision, щоб уникнути хибних діагнозів та непотрібного лікування. Залежності (рис. 3) дозволяють візуально оцінити цей компроміс та обрати оптимальний поріг (або пороги для різних класів) відповідно до специфіки задачі.

Проведений експеримент підтверджує, що обраний підхід є життєздатним. Модель продемонструвала здатність вивчати складні патерни з медичних зображень. Головна практична цінність моделі в її поточному стані полягає не в постановці остаточного діагнозу, а у функції системи підтримки прийняття рішень. Навіть коли модель помиляється в певному класі, вона часто видає декілька ймовірних діагнозів, серед яких є правильний. Це дозволяє лікарю значно звужити коло пошуку та звернути увагу на найбільш вірогідні патології.

Водночас результати демонструють значну варіабельність точності для різних класів (рис. 4.), що переважно пов'язано з їх дисбалансом у

навчальній вибірці. Тут представлені метрики Precision, Recall та F1-score для кожного з восьми класів офтальмологічних патологій, розраховані на валідаційній вибірці. Дані показують, що для класів з більшою кількістю прикладів у навчальному датасеті (наприклад, 'N' – норма) або з більш виразними ознаками, модель демонструє вищі показники (наприклад, F1-score для 'N' становить 0,71, для 'M' – 0,85). Натомість, для рідкісних класів або класів з менш специфічними ознаками (наприклад, 'H' – гіпертонічна ретинопатія, F1-score 0,19) метрики значно нижчі. Це підкреслює проблему впливу дисбалансу класів на продуктивність моделі та необхідність подальших методологічних удосконалень для її подолання.

	precision	recall	f1-score
N	0.60	0.88	0.71
D	0.35	0.73	0.48
G	0.23	0.68	0.35
C	0.58	0.86	0.69
A	0.19	0.74	0.30
H	0.11	0.77	0.19
M	0.74	1.00	0.85
O	0.18	0.80	0.29

Рис. 4. Метрики для різних класів

Висновки. У даній роботі досліджено потенціал застосування згорткової нейронної мережі ResNet-18 для автоматизованої класифікації восьми поширених офтальмологічних захворювань за зображеннями очного дна з набору даних ODIR-5K.

Розроблений програмний прототип продемонстрував здатність до навчання та виявлення патологічних патернів. Використання трансферного навчання та аугментації даних дозволило досягти обнадійливих результатів на валідаційній вибірці, зокрема макросереднений ROC AUC близько 0,86, що свідчить про хорошу загальну роздільну здатність моделі.

Аналіз залежності метрик Precision та Recall від порогу бінаризації підкреслив важливість налаштування цього параметра для адаптації моделі до специфічних клінічних завдань, таких як скринінг чи підтвердження діагнозу. Було показано, що зміна порогу дозволяє балансувати між чутливістю та специфічністю моделі.

Водночас, виявлено суттєву варіабельність ефективності класифікації між різними класами патологій, що значною мірою пов'язано з дисбалансом класів у навчальній вибірці та складністю візуальних ознак певних захворювань. Це вказує на те, що хоча модель є перспективним інструментом для асистування фахівцям, вона ще не може вважатися достатньо надійною для повної автоматизації діагностики.

Практична цінність розробленої моделі на поточному етапі полягає в її потенціалі як складовій системи підтримки прийняття рішень, що може допомогти лікарю звужити коло можливих діагнозів. Подальші дослідження мають бути спрямовані на вдосконалення архітектури, методів боротьби з дисбалансом класів та підвищення інтерпретабельності результатів для створення більш надійного діагностичного інструменту.

Список літератури:

1. Obermeyer, Z., Emanuel, E.J. Predicting the Future—Big Data, Machine Learning, and Clinical Medicine // *New England Journal of Medicine*, 375(13), 2016, pp. 1216–1219.
2. Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M., Thrun, S Dermatologist-level classification of skin cancer with deep neural networks // *Nature*, 542(7639), 2017, pp. 115–118.
3. Rajkomar, A., Dean, J., Kohane, I. Machine Learning in Medicine // *New England Journal of Medicine*, 380(14), 2019, pp. 1347–1358.
4. Deep convolutional neural networks in medical image analysis: a review / I. D. Mienye et al. *Information*. 2025. Vol. 16, no. 3. P. 195.
5. Bohr, A., Memarzadeh, K., *Artificial Intelligence in Healthcare*. Academic Press. 2020.
6. Topol. E.J. High-performance medicine: the convergence of human and artificial intelligence // *Nature Medicine*, 2019, pp. 44–56.
7. Beam, A.L., Kohane, I.S. Big Data and Machine Learning in Health Care // *JAMA*. 320(11), 2018, pp. 1101–1102.
8. Ophthalmic diagnosis using deep learning with fundus images – A critical review / S. Sengupta et al. *Artificial intelligence in medicine*. 2020. Vol. 102. P. 101758.
9. Jeong Y., Hong Y.-J., Han J.-H. Review of machine learning applications using retinal fundus images. *Diagnostics*. 2022. Vol. 12, no. 1. P. 134.
10. A survey on deep-learning-based diabetic retinopathy classification / A. Sebastian et al. *Diagnostics*. 2023. Vol. 13, no. 3. P. 345.

References:

1. Obermeyer, Z. and Emanuel, E. J. (2016). Predicting the Future - Big Data, Machine Learning, and Clinical Medicine. *The New England journal of medicine*, 375(13), 1216–1219. <https://doi.org/10.1056/NEJMp1606181>.
2. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. and Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>.
3. Rajkomar, A., Dean, J. and Kohane, I. (2019). Machine Learning in Medicine. *The New England journal of medicine*, 380(14), 1347–1358. <https://doi.org/10.1056/NEJMr1814259>

4. Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M. and Ilono, P. (2025). Deep Convolutional Neural Networks in Medical Image Analysis: A Review. *Information*, 16(3), 195. <https://doi.org/10.3390/info16030195>
5. Bohr, A. and Memarzadeh, K. (Ed.). (2020), *Artificial Intelligence in Healthcare*. Academic Press.
6. Topol E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature medicine*, 25(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>.
7. Beam, A. L. and Kohane, I. S. (2018). Big Data and Machine Learning in Health Care. *JAMA*, 319(13), 1317–1318. <https://doi.org/10.1001/jama.2017.18391>.
8. Sengupta, S., Singh, A., Leopold, H. A., Gulati, T. and Lakshminarayanan, V. (2020). Ophthalmic diagnosis using deep learning with fundus images - A critical review. *Artificial intelligence in medicine*, 102, 101758. <https://doi.org/10.1016/j.artmed.2019.101758>.
9. Jeong, Y., Hong, Y.-J. and Han, J.-H. (2022). Review of Machine Learning Applications Using Retinal Fundus Images. *Diagnostics*, 12(1), 134. <https://doi.org/10.3390/diagnostics12010134>.
10. Sebastian, A., Elharrouss, O., Al-Maadeed, S. and Almaadeed, N. (2023). A Survey on Deep-Learning-Based Diabetic Retinopathy Classification. *Diagnostics*, 13(3), 345. <https://doi.org/10.3390/diagnostics13030345>.

Статтю представив д.т.н., проф. Національного технічного університету "Харківський політехнічний інститут" В.І. Носков.

Надійшла (received) 15.06.2025

Shegera Andrii, master's student
V. N. Karazin Kharkiv National University
4 Svobody Sq., Kharkiv, 61022
Tel: +380959143643, e-mail: <shehera2020.8954422@student.karazin.ua>
ORCID ID: 0009-0002-4364-3201

Velychko Olga, Cand.Sc.Tech, Associate Professor
V. N. Karazin Kharkiv National University
4 Svobody Sq., Kharkiv, 61022
Tel: (057) 707-55-51, e-mail: <olga.velychko@karazin.ua>
ORCID ID: 0000-0001-9202-8411

Datsok Oleh, Cand.Sc.Tech, Associate Professor
V. N. Karazin Kharkiv National University
4 Svobody Sq., Kharkiv, 61022
Tel: (057) 707-55-51, e-mail: <datsok@karazin.ua>
ORCID ID: 0000-0003-4489-3819

УДК 004.9:61

Застосування згорткової нейронної мережі для класифікації офтальмологічних захворювань за зображеннями очного дна / Шегера А.Ю., Величко О.М., Дацок О.М. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2025. – № 2 (14). – С. 172 – 183.

У роботі висвітлено актуальність застосування методів машинного навчання для автоматизації діагностики в офтальмології. Проведено аналіз існуючих підходів та їхніх недоліків, зокрема, проблем, пов'язаних із дисбалансом даних та складністю інтерпретації результатів. Розроблено програмний прототип на основі згорткової нейронної мережі ResNet-18 для мультилейблової класифікації восьми поширених офтальмологічних патологій за знімками очного дна з набору даних ODIR-5K. Продемонстровано, що модель досягає обнадійливих результатів (маско-усереднений ROC AUC $\sim 0,86$), але її ефективність суттєво різниться між класами. Проаналізовано вплив порогів бінаризації на метрики точності та повноти, що є критичним для адаптації моделі до клінічних завдань. Результати підтверджують перспективність підходу, але вказують на необхідність подальшого вдосконалення для подолання дисбалансу класів та підвищення надійності. Лл.: 4. Бібліогр.: 10 назв.

Ключові слова: машинне навчання, глибоке навчання, згорткові нейронні мережі, ResNet-18, медичні зображення, офтальмологія, класифікація захворювань, аналіз даних.

UDC 004.9:61

Application of convolutional neural network for classification of ophthalmic diseases by fundus images / Shegera A, Velychko O, Datsok O. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkov: NTU "KhPI". – 2025. – № 2 (14). – P. 172 – 183.

The relevance of applying machine learning techniques to automated diagnostics in ophthalmology is substantiated. Existing approaches are systematically reviewed, and their limitations are critically assessed, with particular attention given to issues of class imbalance and the interpretability of model outputs. A software prototype was implemented utilizing the ResNet-18 convolutional neural network architecture for multi-label classification of eight prevalent ophthalmic pathologies, based on fundus images from the ODIR-5K dataset. A macro-averaged ROC AUC of approximately 0.86 was attained, although substantial variability in performance across individual classes was observed. The influence of binarization thresholds on precision and recall metrics is examined, as this parameter is recognized as pivotal for the adaptation of the model to clinical requirements. The obtained results underscore the potential of the proposed approach, while simultaneously highlighting the necessity for further methodological refinements to mitigate class imbalance and improve overall diagnostic reliability. Figs. 4. Bibliography: 10 titles.

Keywords: machine learning, deep learning, convolutional neural networks, ResNet-18, medical images, ophthalmology, disease classification, data analysis.