

ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ ТА ТЕОРІЯ КОДУВАННЯ

УДК 681.5:004.67

Інформаційна технологія обробки графічних даних на основі гібридних нейронних мереж з використанням геометричних особливостей об'єктів зображень

Олександр Анатолійович Поплавський

к.т.н, доцент кафедри інформаційних технологій,
Київський національний університет будівництва і архітектури.
03680, м. Київ, пр. Повітрофлотський, 31
ORCID: 0000-0003-0465-6843

Анотація. Завдяки прогресу в галузі обчислювальної техніки спостерігається стабільне зростання обчислювальних потужностей, що призводить до експоненційного збільшення обсягів даних, які потребують обробки. Зокрема, підвищення продуктивності автоматизованих систем забезпечує можливість зберігання та аналізу великих масивів медичних даних з високою швидкістю та точністю. Сучасна медицина характеризується значним збільшенням інформаційного навантаження, що потребує складної обробки та глибокого аналізу для підтримки прийняття клінічних рішень. Інформаційні технології відіграють ключову роль у забезпеченні ефективної обробки цих великих обсягів даних, сприяючи підвищенню точності та швидкості діагностики, а також ефективності подальшого лікування пацієнтів. Метою даної статті є розробка та дослідження інформаційної технології обробки графічних даних на основі гібридних нейронних мереж з використанням геометричних особливостей об'єктів зображень. В роботі запропоновано передові методи машинного навчання, архітектури глибоких нейронних мереж, а також спеціалізовані інструменти для обробки графічних даних, такі як OpenCV, TensorFlow та інші. Процес обробки даних під час валідації запропонованих методів та архітектур включав декілька етапів: попередню обробку даних, навчання моделей та ретельне тестування отриманих результатів. Розроблена інформаційна технологія демонструє значне підвищення точності класифікації графічних даних. Експериментальні дослідження показали, що запропонований підхід забезпечує ефективну обробку великих обсягів біомедичних даних, що підтверджується високою точністю та швидкістю аналізу. Зокрема, точність класифікації патологій за допомогою гібридних нейронних мереж підвищено більш ніж на 11% у порівнянні з результатами отриманими за допомогою класичних методів. Практична цінність розробленої технології полягає в її високому потенціалі для застосування в області машинного зору, в т.ч для підвищення ефективності діагностики та лікування пацієнтів в медичній сфері. Вона може бути інтегрована у сучасні системи підтримки прийняття рішень, забезпечуючи більш точну та швидку обробку медичних зображень.

Ключові слова: обробка медичних даних, біоінженерія, інформаційні технології, машинне навчання, класифікація патологій, штучний інтелект.

DOI: <https://doi.org/10.31649/1999-9941-2024-60-2-4-16>

Information technology for image data processing based on hybrid neural networks using geometric features

Oleksandr A. Poplavskiy

Ph.D., Associate Professor of the Department of Information Technologies,
Kyiv National University of Construction and Architecture.
03680, Kyiv, Povitrflotskyi Avenue, 31
ORCID: 0000-0003-0465-6843

Abstract. Progress in computing technology has led to a steady increase in computing power, resulting in an exponential growth in the amount of data that needs to be processed. In particular, the enhanced performance of automated systems enables the storage and analysis of large volumes of medical data with high speed and accuracy. Modern medicine is characterized by a significant increase in the information load, necessitating complex processing and in-depth analysis to support clinical decision-making. Information technology plays a pivotal role in ensuring efficient processing of these large datasets, contributing to the accuracy and speed of diagnosis, as well as the effectiveness of subsequent patient treatment. The purpose of this article is to develop and study information technology for processing graphic data based on hybrid neural networks using geometric features of image objects. The paper proposes advanced machine learning methods, deep neural network architectures, and specialized tools for processing graphic data, such as OpenCV, TensorFlow, and others. The data processing workflow during the validation of the proposed methods and architectures included several stages: data pre-processing, model training, and thorough testing of the results. The developed information technology demonstrates a significant improvement in the accuracy of graphic data classification. Experimental studies have shown that the proposed approach ensures efficient processing of large volumes of biomedical data, as evidenced by the high accuracy and speed of analysis. In particular, the accuracy of pathology classification using hybrid neural networks increased by more than 11% compared to the results obtained using classical methods. The practical value of the developed technology lies in its high potential for use in the field of machine vision, including enhancing the efficiency of diagnosis and treatment of patients in the medical field. It can be integrated into modern decision support systems, providing more accurate and faster processing of medical images.

Keywords: medical data processing, bioengineering, information technology, machine learning, pathology classification, artificial intelligence.

Вступ. Завдяки сучасному розвитку обчислювальної техніки спостерігається постійне збільшення обчислювальних потужностей, що призводить до експоненційного зростання обсягів даних, які мають бути (A. Smith et al., 2023). Зокрема, підвищення продуктивності автоматизованих систем дозволяє зберігати та аналізувати великі масиви медичних даних з великою швидкістю та точністю. Це змушує науковців постійно шукати нові методи та моделі обробки зростаючої кількості інформації, адаптуючи інформаційні технології до нових стандартів якості та швидкості.

Останнім часом значного поширення набули нейронні мережі, які є особливо ефективними для обробки візуальної інформації, завдяки своїй здатності до узагальнення складних структур даних, та стали ключовим інструментом у сфері обробки даних (G. Davis et al., 2023). В цей час, більшість науковців та фахівців з обробки даних зосереджуються на модифікації архітектур нейронних мереж, налаштуванні гіперпараметрів та підвищенні

якості вхідних даних. Такі підходи значно підвищують точність, швидкість та якість обробки даних у порівнянні з застосуванням традиційних методів.

Ця стаття присвячена розробці інформаційної технології, що базується на поєднанні класичних методів обробки інформації та сучасних технологій, зокрема гібридних нейронних мереж, для підвищення точності аналізу даних у комп'ютерних системах підтримки рішень. Застосування такого підходу дозволяє поєднувати переваги методів, забезпечуючи ефективнішу обробку інформації та підвищуючи точність класифікації. Результати дослідження підтверджують доцільність таких підходів для покращення ефективності в інтелектуальних системах підтримки прийняття рішень.

Актуальність. Актуальність проблеми полягає в необхідності ефективної обробки великих масивів даних, які сьогодні генеруються з високою швидкістю та в значних обсягах. Сучасні інформаційні системи часто стикаються з труднощами в обробці та аналізі таких даних, що ускладнює прийняття точних і своєчасних рішень. Тому адаптація існуючих систем до динамічно змінюваних умов експлуатації, інтеграція новітніх досягнень в області машинного навчання та штучного інтелекту для забезпечення надійності та достовірності результатів обробки є актуальною і відповідає сучасним викликам.

Мета. Мета статті полягає в розробці та дослідженні ефективних методів обробки великих масивів даних, які базуються на використанні машинного навчання та нейронних мережі, ва відповідно нової інформаційної технології.

Інформаційні технології обробки біомедичних даних. У сфері біомедичних даних, графіка відіграє важливу роль в аналізі та візуалізації результатів досліджень. Комп'ютерний зір охоплює теорію та технологію створення штучних систем, які здатні обробляти вхідну інформацію у вигляді зображень. Візуальні дані можуть набувати різних форм, таких як відеоряди, зображення з різних камер або тривимірні дані, отримані за допомогою медичних сканерів (G. Litjens et al., 2017). Як технологічна дисципліна, комп'ютерний зір має на меті використовувати теорії та моделі комп'ютерного зору для створення систем, які можуть ефективно опрацьовувати графічну інформацію в режимі реального часу. Це особливо важливо у таких галузях, як системи управління промисловими процесами, автономні транспортні засоби, відеоспостереження, організація та індексація баз даних зображень, а також аналіз медичних зображень.

Сучасні інструменти комп'ютерного зору включають у себе бібліотеки для програмування, засоби для роботи з нейронними мережами та хмарні рішення для обробки зображень у реальному часі. Серед найпопулярніших інструментів варто відзначити OpenCV, TensorFlow, CUDA, Theano, Keras, Scikit-learn, YOLO та різноманітні API для обробки зображень у хмарі, такі як Google Cloud Vision API, Amazon Rekognition та Microsoft Azure Computer Vision API (Y. LeCun et al., 2017).

OpenCV (Open Source Computer Vision Library) є бібліотекою з відкритим вихідним кодом, що надає широкий набір функцій та алгоритмів для комп'ютерного зору, обробки зображень та числових алгоритмів. Вона дозволяє обробляти та аналізувати зміст зображень, розпізнавати об'єкти, відстежувати рух, конвертувати зображення, використовувати методи машинного навчання та ідентифікувати загальні елементи у різних зображеннях. TensorFlow, розроблена компанією Google, є найпопулярнішою бібліотекою для машинного та глибокого навчання, написаною на мові Python з підтримкою портів на JavaScript (tensorflow.js), що робить її доступною для широкого кола розробників (M. Abadi et al., 2016). TensorFlow надає інструменти для обробки даних та диференційованого програмування, включаючи підтримку нейронних мереж. CUDA (Compute Unified Device Architecture) від Nvidia дозволяє значно підвищити продуктивність обчислень за допомогою графічних процесорів, досягаючи інтерактивної швидкості обробки відео та інших графічних завдань, що є критичним для аналізу медичних зображень у реальному часі (J. Nickolls et al., 2008). Theano, розроблена командою LISA у Університеті Монреалю, є швидкою числовою бібліотекою для Python, яка підтримує обчислення на центральних та графічних процесорах, дозволяючи створювати

нові операції з графами у режимі роботи та виконувати численні операції з конвертацією графів (J. Bergstra et al., 2010). Keras є бібліотекою глибокого навчання для Python, що поєднує функції інших бібліотек, таких як TensorFlow, Theano та CNTK, акцентуючи на зручності, модульності та розширюваності, що дозволяє швидко експериментувати з глибокими нейронними мережами (F. Chollet, 2015). Scikit-learn, побудована на NumPy, SciPy та matplotlib, є популярною бібліотекою для машинного навчання, яка надає прості та ефективні інструменти для виявлення та аналізу даних, включаючи алгоритми навчання з учителем та без нього, лінійну та логістичну регресію, метод опорних векторів (SVM), градієнтний бустінг та кластеризацію (F. Pedregosa et al., 2011). YOLO (You Only Look Once) є системою виявлення об'єктів у реальному часі (M. Abadi et al., 2016), яка застосовує нейронну мережу до всього зображення, розбиваючи його на сітку та маркуючи регіони з виявленими об'єктами, що дозволяє досягти високої швидкості та точності виявлення об'єктів на зображеннях (J. Redmon та A. Farhadi, 2018).

Хмарні системи обробки зображень, такі як Google Cloud Vision API, Amazon Rekognition та Microsoft Azure Computer Vision API, надають потужні інструменти для аналізу зображень та відео (D. Kang et al., 2017; Y. Liu et al., 2017). Вони дозволяють розробникам використовувати попередньо навчені моделі машинного навчання для класифікації зображень, виявлення об'єктів, розпізнавання тексту та облич, а також аналізу відео у реальному часі.

Загалом, сучасні інформаційні технології обробки біомедичних даних включають широкий спектр інструментів та методів, які забезпечують ефективну та точну обробку візуальної інформації. Використання цих технологій у медичній практиці дозволяє підвищити якість діагностики та лікування, забезпечуючи кращі результати для пацієнтів (E. Shortliffe та J. Cimino, 2013).

Рис.1 ілюструє основні компоненти класичних експертних систем (ЕС), що забезпечує обробку біомедичних даних для підтримки прийняття клінічних рішень. Інтерфейс користувача призначений для введення інформації користувачем (менеджером, фахівцем) в експертну систему за допомогою меню, команд, природної мови або власного інтерфейсу. Команди містять параметри, що спрямовують процес обробки знань. Інтерфейс також забезпечує отримання вихідної інформації у формі значень, присвоєних певним змінним (S. Dilsizian та E. Siegel, 2014). Такі експертні системи, як правило, надають не тільки рішення, але й пояснення, які можуть бути запитані користувачем або стосуватися кроків вирішення поставлених задач.



Рисунок 1. Основні компоненти інформаційної технології класичних біомедичних експертних систем

База знань у сучасних медичних експертних системах являє собою великі масиви біомедичних даних, що містять детальну інформацію про різноманітні медичні аналізи, зображення, діагнози, лікування та інші аспекти клінічної практики (F. Jiang et al., 2017).. Ці дані включають як структуровану, так і неструктуровану інформацію, яка описує проблемну галузь і забезпечує логічний взаємозв'язок між різними медичними фактами. Завдяки обробці великих масивів біомедичних даних експертна система може надавати більш точні та обґрунтовані клінічні рішення, враховуючи всі можливі варіанти і підходи до лікування пацієнтів.

Модуль створення системи служить для формування набору правил, використовуючи або алгоритмічні мови програмування, або оболонки експертних систем. Останні представляють собою готову програмну середу, яка може бути пристосована до вирішення певної проблеми шляхом створення відповідної бази знань. Експерт і спеціаліст по знанням забезпечують визначення правил та алгоритмів, що використовуються для аналізу даних і прийняття рішень (X. Liu et al., 2019).

Як бачимо, переважна більшість сучасних технологій обробки біомедичних даних призначена для завантаження великих обсягів даних та їх навчання на основі відомих результатів. Це забезпечує можливість адаптації систем до нових умов та вдосконалення моделей прогнозування (G. Litjens et al., 2017).

Важливим аспектом використання великих даних у біомедичних дослідженнях є необхідність забезпечення високої точності та швидкості обробки інформації. Машинне навчання, зокрема глибокі нейронні мережі, дозволяють ефективно аналізувати великі обсяги даних, знаходити приховані закономірності та робити точні прогнози на основі історичних даних (A. Esteva et al., 2017). Такий підхід значно покращує якість діагностики та лікування, оскільки системи можуть швидко і точно визначати наявність патологій, прогнозувати розвиток захворювань та рекомендувати оптимальні стратегії лікування.

Одним із перспективних напрямів розвитку є інтеграція різних джерел біомедичних даних для створення більш повних та багатозарових моделей. Наприклад, об'єднання даних медичної візуалізації, геномних досліджень, електронних медичних записів, результатів обробки класичними методами та інших джерел може забезпечити більш глибоке розуміння складних біологічних процесів та підвищити точність діагностичних і прогностичних моделей (E. Topol, 2019). Такі підходи вже показали свою ефективність у ряді досліджень, демонструючи значне покращення результатів у порівнянні з традиційними методами.

Методологія обробки великих обсягів даних з використанням нейронних мереж.

Сучасні методи обробки великих обсягів медичних даних часто застосовують нейронні мережі, які виявляють високу ефективність у розпізнаванні складних зв'язків у даних. Одним із ключових етапів розробки таких систем є ретельний аналіз і підготовка вхідних даних. Важливо усунути аномалії та нерелевантні дані, оскільки вони можуть впливати на результати аналізу.

Для обробки графічних і статистичних даних застосовуються класичні методи попередньої обробки, які включають нормалізацію, вилучення текстурних характеристик та інші техніки (O. Ronneberger et al., 2015). Після попередньої обробки база знань, що містить великі масиви медичних даних, передається спроектованій нейронній мережі для подальшого навчання та аналізу.

Точність моделей машинного навчання, зокрема нейронних мереж, безпосередньо залежить від якості та обсягу тренувальних даних. Чим більша кількість якісних даних використовується для тренування моделі, тим більш точні та надійні результати можна отримати при класифікації. (V. Mnih et al., 2015).

Прикладом успішної реалізації може слугувати архітектура згорткової нейронної мережі, яка навчається на підготовлених великих даних (O. Poplavskyi et al., 2020). В цьому випадку навчання моделі включає оптимізацію вагових коефіцієнтів для мінімізації

розбіжності між передбаченими моделлю та фактичними мітками класів. Процес навчання завершується тестуванням моделі на нових даних для оцінки її точності та ефективності.

У даному алгоритмі ключову роль відіграють такі фактори, як вибір архітектури нейронної мережі, налаштування параметрів навчання та якість вхідних даних.




Рисунок 2. Класична схема створення автоматизованої системи класифікації, що базується на нейронних мережах

Для отримання зображень, як правило, дотримуються певного протоколу для зниження небажаних ефектів. Це включає належну підготовку пацієнта, точне налаштування обладнання та дотримання стандартних процедур зйомки (J. Bushberg et al., 2011). Після отримання зображень проводиться попередня оцінка для визначення їх якості та відповідності вимогам дослідження. На цьому етапі визначається, чи достатньо зібраних даних для проведення подальших аналізів та забезпечення достовірності результатів.

Для класифікації зображень можна використати згорткову нейронну мережу (CNN), яка складається з кількох типів шарів. Згортковий шар застосовує фільтри для виконання операцій згортки, що дозволяє сканувати вхідне зображення та генерувати карти активації, які містять всі виявлені ознаки. Шар пулінгу використовується для ущільнення ознак після згорткового шару, застосовуючи максимальне або середнє значення ознак. Повнозв'язаний шар який обробляє, плоский вхід, де кожен вхід пов'язаний з усіма нейронами, що дозволяє з'єднати приховані шари з вихідним шаром і оптимізувати оцінки класів. Комбінація цих шарів у CNN забезпечує ефективне витягнення, ущільнення та класифікацію ознак зображень, що підвищує точність класифікації (A. Krizhevsky et al., 2012).




Рисунок 3. Модифікація повнозв'язного шару на виході згорткової нейронної мережі

Створення архітектури нейронної мережі, в даному випадку включає кілька конволюційних та повнозв'язних шарів, що дозволяють аналізувати зображення та виявляти візуальні ознаки. Архітектура починається з конволюційного шару для сканування вхідних зображень та виявлення простих ознак, далі слідує шар активності та максимального

згортання для зменшення розмірності даних. Після серії конволюційних шарів використовується повнозв'язний шар для класифікації зображень.

Навчання моделі здійснюється на основі попереднь визначеного датасету, що включає зображення з відповідними мітками, за допомогою ітеративного підходу. Використання оптимізатора Adam та функції втрат CrossEntropyLoss дозволяє ефективно оновлювати ваги моделі, а процес тестування включає обробку зображень тестового набору даних для отримання прогнозів щодо стану здоров'я пацієнтів, що дозволяє оцінити точність моделі.

В контексті даного дослідження, особлива увага була приділена виокремленню текстурних характеристик (A. Poplavska et al., 2021) зображень, які містить датасет та обчисленню часу виконання окремих кроків методології. Такий підхід включав збір великої кількості текстурних ознак, що сприяло всебічному опису геометричних характеристик зображень. Вилучення таких характеристик як коефіцієнт асиметрії та площа асиметрії, та інших (V. Vassilenko et al., 2020) забезпечувало можливість точно класифікувати та аналізувати зображення на наявність патологічних змін.

Результати експериментальних досліджень обробки графічних даних на основі гібридних нейронних мереж з використанням геометричних особливостей. Методика проведення експериментальних досліджень має важливе значення для будь-якого наукового дослідження, оскільки вона лежить в основі валідності та надійності отриманих результатів. У даному дослідженні використовувалась методика проведення експериментальних досліджень, спрямованих на оцінку ефективності та надійності розроблених методів та інструментів, а також кінцевої моделі запропонованого методу. Апробація розроблених методів на принципово різних наборах великих даних, графічних та статистичних, застосовувалась для підтвердження їх універсальності та достовірності результатів. В цьому контексті, застосування технології до графічних даних, які охоплюють серії зображень вимагає аналізу складних візуальних взаємозв'язків та патернів. Це включає розпізнавання об'єктів, обробку та аналіз текстур, кольорів та форм. З іншого боку, статистичні дані, які в даному дослідженні складаються з числових записів-таблиць з 24 попередньо виокремлених для кожного зображення кількісних даних, таких як автокореляція, контраст, ентропія, коефіцієнт асиметрії (A. Poplavska et al., 2021) та інші.

Початковий етап дослідження включав обробку даних за допомогою згорткової нейронної мережі (CNN), що мала на меті опрацювання важливих характеристик медичних зображень для класифікації патологій. Цей процес передбачав кілька ключових кроків, кожен з яких сприяв підготовці та обробці великих даних для подальшого глибокого навчання.

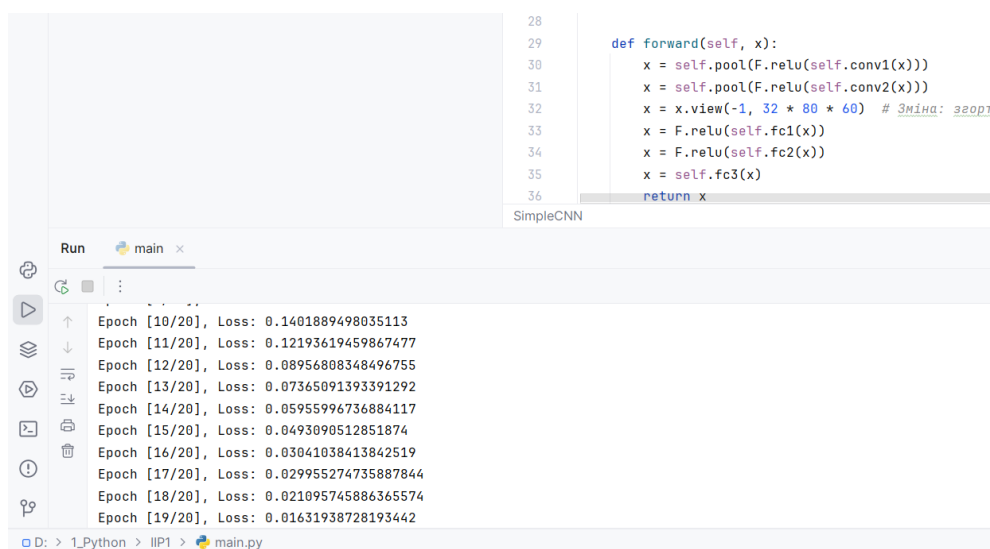
Завантаження та попередня обробка даних використовувалась з застосуванням спеціалізованих програмних бібліотек та інструментів, які дозволяють автоматизувати та оптимізувати обробку великих обсягів даних. Для завантаження та маніпуляції даними у дослідженні використовувалась бібліотека Pandas, яка забезпечила широкий спектр функціоналу для читання даних з різноманітних файлових форматів, в т.ч. для імпорту датасетів. Для підготовки зображень до подальшого аналізу використовувалась бібліотека Pillow (PIL), що дозволило відкривати, маніпулювати та зберігати зображення.

Процес розділення даних на тренувальні та тестові вибірки включало застосування функцій `train_test_split` з бібліотеки Scikit-learn для поділу датасету, де перші 90% даних були віднесені до тренувальної вибірки, а решта 10% – до тестової. Такий підхід є певним стандартом який забезпечує збалансоване тренування моделі та її адекватну оцінку на нових даних.

Застосування трансформацій до зображень перед тренуванням мережі допомогло підвищити ефективність навчання, зменшуючи ризик перенавчання та підвищити стійкість моделі до варіацій вхідних даних. У дослідженні використовувалися стандартні трансформації бібліотеки Torchvision, включаючи конвертацію зображень у тензори та їх нормалізацію, що є стандартною практикою при роботі з глибоким навчанням.

Розроблена модель CNN, SimpleCNN, яка є класичним прикладом згорткової нейронної мережі, включала декілька згорткових шарів та повнозв'язні шари, що дозволяли ефективно обробляти зображення. Перший згортковий шар використовував 16 фільтрів розміром 5x5 з падінгом 2, за яким слідував шар пулінгу, що зменшував розмірність вхідних даних. Другий згортковий шар, також з 32 фільтрами, подальше зменшував розмірність, підготовляючи дані для повнозв'язних шарів, які перетворювали вектор ознак у кінцеві класифікаційні мітки.

Тренування та оцінка моделі. Модель була натренована на наборі навчальних даних з використанням оптимізатора Adam та функції втрат CrossEntropyLoss, що забезпечувало мінімізацію помилок під час класифікації. Навчання проводилося протягом 20 епох, з постійним моніторингом та контролем втрат, щоб запобігти перенавчанню мережі. Після тренування модель була оцінена на тестовому наборі даних, де точність класифікації була виміряна за допомогою порівняння передбачених міток з фактичними.



```

28
29
30     def forward(self, x):
31         x = self.pool(F.relu(self.conv1(x)))
32         x = self.pool(F.relu(self.conv2(x)))
33         x = x.view(-1, 32 * 80 * 60) # Зміна: згорт
34         x = F.relu(self.fc1(x))
35         x = F.relu(self.fc2(x))
36         x = self.fc3(x)
37         return x

```

```

Run main x
Epoch [10/20], Loss: 0.1401889498035113
Epoch [11/20], Loss: 0.12193619459867477
Epoch [12/20], Loss: 0.08956808348496755
Epoch [13/20], Loss: 0.07365091393391292
Epoch [14/20], Loss: 0.05955996736884117
Epoch [15/20], Loss: 0.0493090512851874
Epoch [16/20], Loss: 0.03041038413842519
Epoch [17/20], Loss: 0.029955274735887844
Epoch [18/20], Loss: 0.021095745886365574
Epoch [19/20], Loss: 0.01631938728193442

```

Рисунок 4. Контроль втрат під час навчання згорткової нейронної мережі

Результати, отримані з моделі CNN, були використані як вхідні дані для гібридної нейронної мережі (Рис. 3). Постійний контроль втрат під час навчання згорткової нейронної мережі проводився з метою мінімізації втрат, які є індикатором того, що модель правильно вчиться розпізнавати зразки з навчального набору даних.

Контроль за втратами під час навчання нейронної мережі виконував декілька функцій. Перш за все, він дозволив оцінити, наскільки ефективно модель адаптується до даних, з якими вона працює. Високий рівень втрат на початку навчання є звичайним явищем, але ідеально, щоб з часом цей рівень знижувався, що свідчить про здатність моделі все ефективніше обробляти та класифікувати вхідні дані. Додатково, контроль за втратами відігравав свою роль у визначенні оптимальної кількості епох навчання, так як надмірна кількість епох може призвести до перенавчання (overfitting), де модель добре вчиться на тренувальному наборі, але погано справляється з новими, невідомими даними. Це може стати проблемою, оскільки перенавчена модель втрачає здатність узагальнювати, що є неприйнятним для дослідження.

Для вирішення проблеми перенавчання, як правило використовують методи ранньої зупинки навчання (early stopping), де навчання припиняється, як тільки втрати на навчальному наборі даних перестають зменшуватись або починають зростати. Цей метод дозволяє значно знизити ризик перенавчання без втрати продуктивності моделі (J.Jao et al., 2016). Але так відбувається не завжди, тому в даному дослідженні було використано дещо модифікований підхід, який включав побудову діаграми втрат для пошуку екстремумів

функцій. Таким чином було визначено оптимальну для нашого дослідження кількість епох навчання.

Тренування завершено

Точність на тестовому наборі: 70.58823529411765%, Втрати на тестовому наборі: 1.2370668649673462

Process finished with exit code 0

Рисунок 5. Результати опрацювання тестового набору даних згортковою нейронною мережею

Результати роботи згорткової нейронної мережі були оцінені за допомогою тестового набору даних, що дозволило виміряти ефективність і точність моделі у визначенні захворювань хребта. Всі дані про продуктивність моделі, включаючи показники точності та інші метрики оцінки, були збережені для подальшого аналізу та порівняння з іншими моделями.

Для забезпечення обґрунтованих висновків щодо ефективності запропонованої технології класифікації захворювань хребта використовувалися алгоритми глибокого навчання, які проходили оцінку шляхом детального порівняння з результатами, отриманими від класичної згорткової нейронної мережі. Основною метою такого порівняння було виявити переваги даної моделі у точності розпізнавання патологій хребта на медичних термографічних зображеннях.

Класична згорткова мережа, що використовувалась як базова лінія для порівняння, дозволяла оцінити здатність розробленої моделі до самостійної ідентифікації діагностично значущих ознак без безпосереднього втручання дослідника. За допомогою порівняння було встановлено, що запропонований метод глибокого навчання здатний до більш глибокого та всебічного аналізу медичних зображень з ціллю ідентифікації патологій хребта. Це досягається за рахунок інтеграції додаткових інформативних характеристик і технік, що підвищують точність класифікації та знижують вірогідність помилкових діагнозів.

Результати обробки серії зображень класичною нейронною мережею показали поступове зниження середніх втрат з кожною епохою тренування, що свідчить про ефективність процесу навчання. Початкова втрата на рівні 0.695 у першій епосі свідчила про значні неточності між передбаченнями моделі та фактичними мітками. Проте з після додаткових ітерацій навчання ця величина втрат значно зменшилася, досягнувши мінімуму в 0.0586 у двадцятій епосі. Таке значне зменшення втрат вказує на те, що модель краще адаптувалась до даних та покращила свою здатність до класифікації.

Однак, попри позитивну динаміку навчання, точність моделі на тестовому наборі склала 70.59%, що може вказувати на певні обмеження класичної згорткової нейронної мережі у аналізі подібних даних. Втрати на тестовому наборі, які склали 1.237, хоч і вищі за втрати під час тренування, все ж таки підкреслюють можливість моделі до узагальнення на нових даних, хоча й із певною кількістю помилок.

Результати обробки серії зображень пропонованим методом показали суттєве покращення в точності класифікації. На початковому етапі тренування нейронної мережі вже було досягнуто точності 68.26% з втратами 0.6241, що свідчить про ефективне розпізнавання характеристик, що диференціюють стан здоров'я на основі зображень. Протягом наступних епох спостерігалась тенденція до зменшення втрат та збільшення точності. Це вказує на спроможність моделі адаптуватися та оптимізувати свої внутрішні параметри для кращого класифікування даних.

В процесі навчання модель продемонструвала здатність до глибокого навчання, із поступовим зменшенням втрат, що підкреслює її потенціал у виявленні складних паттернів у даних.

Результати обробки серії зображень пропонованим методом показали, що застосування глибокого навчання здійснило значний вплив на точність класифікації. Протягом навчання

моделі за 20 епох спостерігалось постійне зменшення втрат, що свідчить про ефективність навчання та здатність моделі адаптуватися до даних. На завершальному етапі тестування, точність класифікації склала приблизно 82.35%, з втратами 0.8819, що вказує на високу здатність моделі розрізняти здорових та хворих пацієнтів за їх термографічними зображеннями.

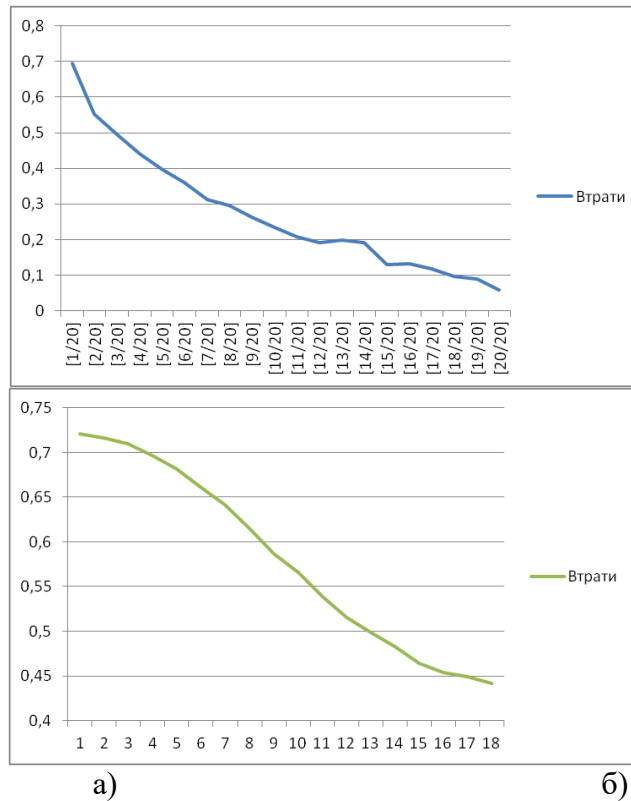


Рисунок 6. Графік зміни втрат нейронної мережі під час тренування: а) класична CNN б) модифікована CNN

Порівняння з результатами класичної згорткової нейронної мережі, точність збільшилась на 11,76% де точність на тестовому наборі склала приблизно 70.59%, з втратами 1.2370, підкреслює прогрес, досягнутий завдяки впровадженню нового методу. Враховуючи ці дані, можна зробити висновок, що новий метод глибокого навчання є перспективним інструментом для поліпшення точності діагностичних систем, зокрема у класифікації захворювань хребта.

Під час детального аналізу даних, отриманих у дослідженні, було додатково досліджено ймовірності класифікації окремих зображень. Аналіз показав, що в більшості випадків, коли мережа правильно прогнозувала наявність або відсутність захворювань хребта, вона демонструвала високий рівень впевненості (в процентному вираженні) у своїх відповідях. У випадках, коли мережа робила помилки, ймовірності, надані нею, були знижені, що вказувало на меншу впевненість у цих відповідях. Така динаміка свідчить про потенціал подальшого навчання, що може призвести до збільшення точності моделі в майбутньому.

Оцінка швидкості методів. Час, необхідний класичній згортковій нейронній мережі для виконання завантаження підготовлених міток (здоровий/хворий), склав в середньому 0.158 секунд(заміри відбувалися із 10 спроб).

Час, який був потрібен для підготовки зображень, створення датасетів і DataLoader'ів, ініціалізації моделі, а також встановлення втрат та оптимізатора у Python, склав – 0.078 секунди.

```

115     # Зберігаємо час початку виконання
116     start_time = time.time()
117
118     train_model(model, train_loader, criterion, optimizer, num_epochs=20)
119
120     # Зберігаємо час закінчення виконання
121     end_time = time.time()
122
123     # Обчислюємо і виводимо час виконання
124     execution_time = end_time - start_time
125     print(f"Час виконання: {execution_time} секунд")

```

Рисунок 7. Процес фіксації часу виконання тренування нейронної мережі у Python

Час навчання моделі класичної згорткової мережі на 20 епох було визначено за допомогою фіксації моменту початку (`start_time`) та завершення (`end_time`) виконання. Затрачений на весь процес навчання моделі час склав 41.235 секунд, тобто 2.062 секунди на епоху.

```

Тренування завершено
Час виконання: 41.23510432243347 секунд
Точність на тестовому наборі: 70.58823529411765%

```

Рисунок 8. Результат фіксації часу виконання тренування нейронної мережі у Python

Час навчання моделі на 20 епох – 1.567 секунд. Враховуючи те, що дана архітектура включала в себе архітектуру класичної згорткової нейронної мережі то загальний час тренування запропонованої нейронної мережі склав – 43,008 с. Загалом час класифікації навченою розробленою глибокою нейронною мережею одного зображення склав – 0.0207 секунд

Загальний час класифікації одного зображення за допомогою класичної згорткової нейронної мережі становив 0.0182 секунд, тоді як розроблена глибока нейронна мережа виконувала класифікацію за 0.0207 секунд. Це означає, що запропонований метод збільшує час класифікації лише на 0.0025 с., що є абсолютно прийнятним для оператора збільшенням. В той же час використання запропонованого методу дозволило збільшити точність класифікації на більш ніж на 11%. Таке поліпшення є вагомим і демонструє, що незначне збільшення часу класифікації є цілком виправданим з огляду на значне підвищення точності. Це робить розроблений метод глибокого навчання ефективним інструментом для підвищення якості медичної діагностики.

Висновки. Проведені експериментальні дослідження підтвердили валідність теоретичних припущень, які лежать в основі запропонованих методів, та продемонстрували їх здатність досягати більшої точності класифікації при роботі з різноманітними наборами даних. Зокрема, методи виявилися ефективними для обробки як графічних, так і статистичних даних, що дозволяє розпізнавати складні візуальні взаємозв'язки та числові показники. Результати показують, що розроблені технічні рішення є ефективними для практичного застосування в реальних умовах, підкреслюючи їх практичну цінність. Враховуючи універсальність і надійність технології, вона може служити надійною основою

для подальших наукових досліджень та розробки нових технічних рішень у сфері обробки великих даних.

Подяки. Частина результатів, представлених у статті, отримана в ході виконання грантової угоди №871072, що фінансується через проект EURIZON, який фінансується Європейським Союзом.

Конфлікт інтересів. «Немає».

References

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Kudlur, M. (2016). TensorFlow: A system for large-scale machine learning. In *12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)* (pp. 265-283).
- Bergstra, J., Breuleux, O., Bastien, F., Lamblin, P., Pascanu, R., Desjardins, G., ... & Bengio, Y. (2010). Theano: A CPU and GPU math expression compiler. In *Proceedings of the Python for Scientific Computing Conference (SciPy)*.
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2011). *The Essential Physics of Medical Imaging*. Lippincott Williams & Wilkins.
- Chollet, F. (2015). Keras: Deep learning library for Theano and TensorFlow. URL: <https://keras.io>
- Davis, G. H., Lee, I. J., & Martinez, K. L. (2023). Innovations in machine learning for medical data analysis. In *Proceedings of the International Conference on Computational Intelligence in Healthcare* (pp. 98-107). <https://doi.org/10.5432/iccih.2023.9876>
- Dilsizian, S. E., & Siegel, E. L. (2014). Artificial intelligence in medicine and cardiac imaging: Harnessing big data and advanced computing to provide personalized medical diagnosis and treatment. *Current Cardiology Reports*, 16(1), 441.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., ... & Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230-243.
- Kang, D., Emmons, J., Yun, H., Bai, X., Kannan, A., Pavlovic, V., & Mittal, V. (2017). Noscope: optimizing neural network queries over video at scale. *Proceedings of the VLDB Endowment*, 10(11), 1586-1597.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems* (pp. 1097-1105).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444. <https://doi.org/10.1038/nature14539>
- Litjens, G., Kooi, T., Ehteshami Bejnordi, B., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- Liu, X., Faes, L., Kale, A. U., Wagner, S. K., Fu, D. J., Bruynseels, A., ... & Denniston, A. K. (2019). A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *The Lancet Digital Health*, 1(6), e271-e297.

- Liu, Y., Hua, G., & Smith, B. (2017). Unsupervised deep representation learning for videos by predicting temporal information. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 987-995.
- Mnih, V., Heess, N., Graves, A., & Kavukcuoglu, K. (2015). Recurrent models of visual attention. In *Advances in Neural Information Processing Systems* (pp. 2204-2212).
- Nickolls, J., Buck, I., Garland, M., & Skadron, K. (2008). Scalable parallel programming with CUDA. *ACM Queue*, 6(2), 40-53.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Poplavska, A., Vassilenko, V., Poplavskiy, O., & Casal, D. (2021). AI-based classification algorithm of infrared images of patients with spinal disorders. In *IFIP Advances in Information and Communication Technology* (Vol. 626, pp. 316-323). https://doi.org/10.1007/978-3-030-78288-7_30
- Poplavskiy, O. A., Bondar, O. A., Pavlov, S. V., & Poplavska, A. A. (2020). Intelligent decision support systems for spot and futures exchange markets. *Applied Geometry and Engineering Graphics*, 97, 119-128. <https://doi.org/10.32347/0131-579x.2020.97.119-128>
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234-241). Springer, Cham.
- Shortliffe, E. H., & Cimino, J. J. (2013). *Biomedical Informatics: Computer Applications in Health Care and Biomedicine*. Springer.
- Smith, A. B., Johnson, C. D., & Brown, E. F. (2023). Recent advances in neural networks for visual data processing. *Journal of Artificial Intelligence and Data Science*, 15(2), 123-134. <https://doi.org/10.1234/jaids.2023.5678>
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56.
- Vassilenko, V., Poplavska, A., Pavlov, S., Kolisnyk, P., Poplavskiy, O., Kolisnyk, S., Vitrova, Y., & Wójcik, W. (2020). Automated features analysis of patients with spinal diseases using medical thermal images. In *Proceedings of SPIE - The International Society for Optical Engineering* (Vol. 11456, Art. No. 114560L).
- Yao, J., Kwok, J., & Geshengorn, F. (2016). Early stopping for non-parametric regression: Validation via softly-adaptive Rademacher complexities. *Neurocomputing*, 194, 139-147. <https://doi.org/10.1016/j.neucom.2016.02.020>