

«Комп'ютерна модель виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії»

Шифр: «Виявлення переломів»

## АНОТАЦІЯ

наукової роботи під шифром «Виявлення переломів»

Наукова робота: 25 с., 10 рис., 28 джерел.

Наводиться розробка моделі машинного навчання для автоматичного виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії.

**Метою роботи** є створення моделі машинного навчання для автоматичного виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії.

**Наукова новизна** роботи полягає в тому, що розроблено нову, відмінну від наявних у літературі у розрізі поставленої задачі, архітектуру моделі машинного навчання, що досягає значень точності класифікації на рівні найбільш розповсюджених моделей. Зокрема, розроблена модель «Fracture detection 3» демонструє точність класифікації у 98.25%, чутливість у 99%, специфічність у 97.5%.

**Практична цінність** розробленого програмного продукту полягає в тому, що розроблену модель можна використовувати в медичних закладах, що дозволить підвищити продуктивність медичного персоналу, знизити вірогідність медичної помилки.

Основні положення роботи апробовані на таких міжнародних конференціях і форумах: Intelitsis-2023 (індексується у міжнародній наукометричній базі Scopus) [1], 27-й Міжнародний молодіжний форум «РАДІОЕЛЕКТРОНІКА І МОЛОДЬ В ХХІ СТОЛІТТІ» (Харків, 2023) [2], конференція «Тиждень науки» (Запоріжжя, 2022) [3]. Результати опубліковано в науково-технічному журналі «Реєстрація, зберігання і обробка даних» (2022) [4].

МАШИННЕ НАВЧАННЯ, ЗГОРТКОВА НЕЙРОННА МЕРЕЖА, РОЗПІЗНАВАННЯ ОБРАЗІВ, ДЕРЕВА ПРИЙНЯТТЯ РІШЕНЬ, МЕТОД ОПОРНИХ ВЕКТОРІВ.

## ЗМІСТ

	С.
ВСТУП	4
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ	6
1.1 Загальний огляд	6
1.2 Огляд популярних методів вирішення поставленої задачі	7
1.2.1 Метод опорних векторів	7
1.2.2 К-найближчих	9
1.2.3 Дерева прийняття рішень	12
1.2.4 Нейронні мережі прямого поширення	13
1.2.5 Згорткові нейронні мережі	14
1.3 Порівняльний аналіз існуючих методів	16
1.4 Висновки за розділом	18
2 ВИБІР ТА ОБҐРУНТУВАННЯ СТРУКТУРИ СИСТЕМИ	19
2.1 Вибір мови програмування	19
2.1.1 Мова R	19
2.1.2 Мова C++	20
2.1.3 Мова Python	20
2.1.4 Порівняння мов програмування	21
2.2 Вибір бібліотеки графічного інтерфейсу	22
2.2.1 PyQt	22
2.2.2 Tkinter	22
2.2.3 PySimpleGUI	23
2.3 Огляд обраного середовища та інструментарію вирішення задачі	24
2.4 Висновки за розділом	24
ВИСНОВКИ	25
ДОДАТОК А – СТРУКТУРА ПРОЄКТУ	26
ДОДАТОК Б – ПРОГРАМНА РЕАЛІЗАЦІЯ ЗАСТОСУНКА	28
ДОДАТОК В – ПЕРЕЛІК ПОСИЛАНЬ	41

## ВСТУП

Сучасні системи на основі штучного інтелекту здатні вирішувати широкий спектр задач, поліпшуючи різні сфери життя людини. Однією з таких сфер є медицина, в якій машинне навчання та системи штучного інтелекту застосовуються дедалі більше з кожним роком. На основі даних багаторічних наукових досліджень, спостереження за пацієнтами, результатів лікування створюються великі набори даних, які потім використовуються для створення моделей машинного навчання. Такі моделі можуть використовуватися для широкого спектру задач: передбачення майбутнього стану пацієнта, виявлення хвороби на основі діагностичних даних та багатьох інших. Зокрема, в радіології, тобто медичній сфері, пов'язаній в цілому з отриманням та обробкою зображень тіла людини, тобто візуалізацією, набули популярності згорткові нейронні мережі – моделі машинного навчання, які здатні емулювати процеси розпізнавання образів у нейронній системі людини. Особливо ефективними в цій галузі виявляються згорткові нейронні мережі, що імітують процеси, що відбуваються в зоровій корі людини. Згорткові нейромережі, крім традиційних повноз'єднаних шарів нейронів, використовують так звану операцію згортки, що вилучає абстрактні характеристики зображення.

Особлива структура та гнучкість шийного відділу хребта роблять його вразливим до пошкоджень. Травми цього відділу охоплюють широкий спектр, починаючи від незначних розтягнень м'язів і закінчуючи важкими переломами-вивихами, які можуть спричинити пошкодження спинного мозку та поставити під загрозу життя пацієнта. Щоб запобігти додатковим неврологічним травмам, дуже важливо дотримуватися встановлених протоколів початкової оцінки та лікування, включаючи іммобілізацію, щоб захистити шийний відділ хребта від будь-яких непотрібних рухів. Незважаючи на те, що травми шийного відділу хребта часто очевидні, покладатися лише на клінічне обстеження іноді може бути недостатньо. Тоді для адекватної реакції лікарів необхідною є радіографічна візуалізація. Швидка ідентифікація та локалізація

будь-яких переломів хребців мають вирішальне значення для запобігання неврологічного погіршення та паралічу після травматичної події.

Зазвичай, для візуалізації використовують рентгенівські знімки або комп'ютерну томографію. І хоча комп'ютерна томографія є кращим методом, рентгенівські знімки можуть залишатися єдиним варіантом через їх меншу вартість.

Існують і досить вдалі рішення на основі глибоких нейронних мереж, що пов'язані з вирішенням проблеми виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії. Так, в [5] описане використання згорткової нейронної мережі для вирішення подібної задачі. Точність моделі машинного навчання виявилася на рівні в 92%, тоді як результати роботи радіологів для тих же даних були на рівні 95% точності. Ці дані вказують на перспективність використання згорткових нейронних мереж у розрізі поточної задачі.

# 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

## 1.1 Загальний огляд

Травма шийного відділу хребта являє собою різноманітні ушкодження, починаючи від відносно легких розтягнень зв'язок і м'язів до переломів і вивихів кісткових хребців, що може призвести до значних ушкоджень спинного мозку. Спеціальна анатомія зв'язок і кісток забезпечує С-хребту великий діапазон рухів, але також робить його більш сприйнятливим до травм. Різні механізми, що лежать в основі такої гнучкості, роблять шийний відділ хребта вразливим до травм.

Пацієнти з підозрою на перелом шийного відділу хребта лікуються на догоспітальному етапі із застосуванням іммобілізації та утримання хребетного стовпа «на одній лінії» для запобігання надмірним рухам.

Метою початкової оцінки потенційних переломів шийного відділу хребта є швидке розпізнавання та ідентифікація первинної травми та адекватний захист хребта для запобігання подальшому ураженню. Для пацієнти без свідомості діагноз в основному ставиться за допомогою комп'ютерної томографії.

В останні роки машинне навчання дедалі більше застосовується в медицині. На основі даних багаторічних наукових досліджень, спостереження за пацієнтами, результатів лікування створюються великі набори даних, які потім використовуються для створення моделей машинного навчання. Такі моделі можуть використовуватися для широкого спектру задач: передбачення майбутнього стану пацієнта, виявлення хвороби на основі діагностичних даних та багатьох інших. Зокрема, в радіології, тобто медичній сфері, пов'язаній в цілому з отриманням та обробкою зображень тіла людини, тобто візуалізацією, набули популярності згорткові нейронні мережі – моделі машинного навчання, які здатні емулювати процеси розпізнавання образів у нейронній системі людини. Особливо ефективними в цій галузі виявляються згорткові нейронні мережі, що імітують процеси, що відбуваються в зоровій корі людини. Згорткові

нейромережі, крім традиційних повноз'єднаних шарів нейронів, використовують так звану операцію згортки, що вилучає абстрактні характеристики зображення.

Задачу автоматизації виявлення переломів шийного відділу хребта на основі КТ-знімків можна формально описати як проблему бінарної класифікації, де вхідними даними є масив значень пікселів знімка, а вихідними – належність знімку до одного з двох класів: здоровий або перелом.

Для вирішення подібних задач використовуються методи машинного навчання. Відмінною особливістю таких методів є можливість вирішувати задачі на основі автоматичного виявлення закономірностей у великих обсягах навчальних даних, а не використання попередньо заданих алгоритмів. [6]

До популярних методів машинного навчання, що використовуються для вирішення задачі класифікації відносяться, крім інших, метод опорних векторів, штучні нейронні мережі, метод k-найближчих, дерева прийняття рішень.

## **1.2 Огляд популярних методів вирішення поставленої задачі**

Як було зазначено вище, різні методи машинного навчання знаходять широке застосування в медицині, а зокрема – в радіології. До найбільш популярних методів машинного навчання, що знаходять застосування в радіології відносяться метод опорних векторів, штучні нейронні мережі, метод k-найближчих, дерева прийняття рішень.

### **1.2.1 Метод опорних векторів**

Метод опорних векторів (SVM) — це алгоритм навчання з учителем, який використовується для вирішення задач класифікації. Він полягає у розділенні екземплярів у просторі ознак за допомогою гіперплощини. Гіперплощина обирається таким чином, щоб якнайкраще класифікувати нові дані. Екземпляри в навчальних даних, які є найближчими до гіперплощини,

називаються опорними векторами. Алгоритм SVM намагається максимізувати відстань між гіперплощинами та опорними векторами в кожній групі класів, що покращує точність моделі, рис. 1.1 ілюструє роботу методу опорних векторів у випадку, коли простір ознак є площиною. В такому разі роздільною гіперплощиною є пряма лінія.

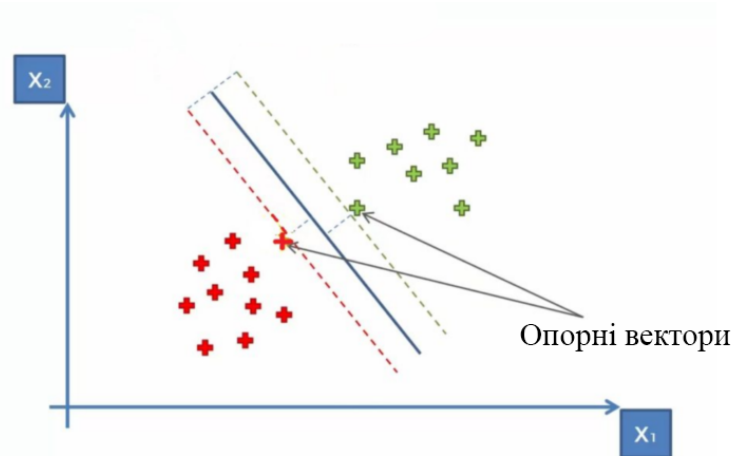


Рисунок 1.1 – Ілюстрація роботи методу опорних векторів

У розрізі радіології SVM є найбільш ефективними, коли існують чіткі відмінності між значеннями ознак двох груп, наприклад, для прогнозування ступеня пухлини або класифікації різних тканин на основі текстури [15].

Так у [16] автори вивчають можливість використання методу опорних векторів для сегментації знімків грудей, отриманих за допомогою МРТ, у розрізі різних типів. Результати дослідження показують, що метод SVM є перспективним та ефективним спектральним методом для класифікації МРТ-зображень. Для МРТ-зображень результати подібної сегментації можуть бути надані лікарям як основа для більш точної діагностики та судження про стан пацієнта.

В дослідженні [17] автори проводять бінарну класифікацію за допомогою методу опорних векторів, а саме визначають наявність шизофренії в пацієнтів на основі МРТ-зображень головного мозку. Розроблена авторами модель досягла точності більш ніж у 70%, що є дуже значним результатом. Однак,



перед використанням у моделі зображення, що були використані у дослідженні, проходили етап значної попередньої обробки.

Таким чином, можна зазначити, що метод опорних векторів є перспективною технологією, яка ефективно працює з попередньо обробленими даними, а також показує високі результати точності при використанні для вирішення задачі сегментації радіологічних знімків.

Однак, метод опорних векторів не є ефективним у разі обробки сирих зображень. Також до недоліків методу можна віднести той факт, що метод опорних векторів є моделлю типу «чорний ящик», тобто моделі на його основі не розкривають принципи прийняття кожного окремого рішення.

### **1.2.2 К-найближчих**

К-найближчих (KNN) – це алгоритм машинного навчання з учителем, що використовується для вирішення задачі класифікації. Під час навчання моделі на основі цього методу усі екземпляри з тренувальної вибірки заносяться в базу даних. Під час роботи моделі значення атрибутів вхідного екземпляру порівнюються з кожним зі значень, що зберігаються в базі даних. Вихідний клас екземпляру визначається класом більшості з  $k$  «найближчих» до нього тренувальних екземплярів.

Критичним є вибір функції «відстані» між двома екземплярами. Зазвичай для кількісних атрибутів використовують манхетенську або евклідову відстані. Для якісних атрибутів можна використовувати відстань Хеммінга.

Вирішальний вплив на якість роботи алгоритму має вибір параметру  $k$ . Алгоритм може бути надто чутливим у випадку малих  $k$ , та навпаки у випадку великих значень  $k$ . Одним зі способів вирішення цієї проблеми є використання так званого зваженого алгоритму  $k$ -найближчих. У зваженому варіанті методу найближчим  $k$  точкам надається вага за допомогою функції, що називається функцією ядра. Сенс полягає в наданні більшої ваги точкам, які знаходяться поруч, і меншій вазі точкам, що знаходяться у віддалені. У якості функції ядра

може виступати будь яка функція, що спадає зі збільшенням аргументу. Наприклад, можна використати функцію оберненої відстані [18].

На рис. 1.2 проілюстровано принцип роботи методу. Зображено класифікацію екземплярів за двома числовими атрибутами у чотири класи.  $K$  має значення 5.




Рисунок 1.2 – Ілюстрація роботи методу  $k$ -найближчих

Теоретично, метод  $k$ -найближчих може бути використаний на даних будь-яких розмірностей та природи. Головною умовою побудови успішної моделі є вибір функції відстані, яка може бути набагато складнішою за просту евклідову відстань у разі, якщо атрибути вхідних екземплярів будуть мати різну природу.

Однак, практика показує, що цей метод не є ефективним у разі, якщо у якості вхідних даних виступають сирі зображення. У разі розв'язання задачі класифікації об'єктів за їхніми зображеннями, зазвичай об'єкти на зображеннях можуть займати різні позиції, перебувати під різними кутами, мати різну палітру кольору через особливості освітлення тощо. Взаємозв'язок між вхідними даними є занадто глибоким, щоб поверхневий метод  $k$ -найближчих міг виявити їх.

Не зважаючи на це, метод k-найближчих знаходить своє застосування і в задачах класифікації зображень, зокрема в сфері радіології. Зазвичай в такому разі переконуються в тому, що зображення є невеликими, об'єкти на них розташовані строго в одному положенні, а палітра кольорів є чорно-білою. Іншим методом є вилучення абстрактних характеристик зображення й подальша обробка їх за допомогою методу k-найближчих.

Так, в [19] автори вивчають можливість автоматично виявляти метастази раку в лімфатичних вузлах за КТ-зображеннями, використовуючи метод k-найближчих. В рамках роботи моделі вхідні дані обробляються, з них вилучаються абстрактні характеристики, які використовуються у якості атрибутів екземплярів для методу k-найближчих. Точність роботи побудованої моделі становить 96.33% для бінарної класифікації, що показує високий потенціал методу.

Подібна задача вирішується в [20], де автори пропонують алгоритм для вирішення важливої задачі бінарної класифікації пухлин на МРТ-зображеннях головного мозку як доброякісних чи злоякісних. Вхідні зображення піддаються обробці: вони кластеризуються методом k-середніх, а з отриманих даних витягують абстрактні характеристики за допомогою Gray level Co-Occurrence matrix. Отримані дані використовуються для класифікації з використанням методу k-найближчих. Автори отримали результат у 85% точності класифікації.

Заголом, до переваг алгоритму можна віднести відсутність необхідності попереднього ресурсномісткого навчання: під час навчання дані навчальних екземплярів вносяться в базу даних без додаткової обробки. Іншою перевагою є той факт, що метод k-найближчих відноситься до прозорих моделей, тобто користувач може дізнатись на основі чого модель приймає рішення. У випадку аналізованого методу можна дізнатися про те, які тренувальні екземпляри з бази даних виявилися найближчими до оброблюваного зразку та яка функція відстані була використана, якій вклад у відстань внесли ті чи інші атрибути екземпляру.

Однак, метод має недолік, що є особливо важливим у розрізі поточної

задачі – класифікації зображень. Метод k-найближчих зазвичай не може бути ефективно використаний з сирими даними зображень та потребує їх значної попередньої обробки та витягання більш абстрактних характеристик. Побудова моделі, що здатна успішно отримувати важливі абстрактні характеристики з тієї чи іншої візуалізації людського тіла, є складним та не тривіальним завданням.

### 1.2.3 Древа прийняття рішень

Древа прийняття рішень – це ще один популярний метод машинного навчання з учителем, що використовується для вирішення задач класифікації. Вони являють собою ієрархічні деревоподібні структури, кожен вузол яких містить правило, за яким даний об'єкт переходить в один з більш глибоких вузлів. Термінальні вузли дерев називають листами. Кожен лист збігається з одним класом, який і надається об'єкту, що потрапляє в цей лист у процесі класифікації.

Існує багато методів побудови дерев на основі тренувальної вибірки екземплярів: CART, C4.5, CHAID, QUEST. Всі методи використовують загальну концепцію: побудову дерева із розбиттям на кожному кроці множини з деякого вузла за допомогою створення правила розбиття. Вони відрізняються тим, за яким принципом обирається правило для розбиття на кожному кроці, принципом зменшення розміру результуючого дерева, умовою зупинки роботи алгоритму [21].

На рис. 1.3 проілюстровано принцип роботи дерева прийняття рішення. Зображене просте дерево визначає можливість успішної прогулянки за характеристиками поточних погодних умов.

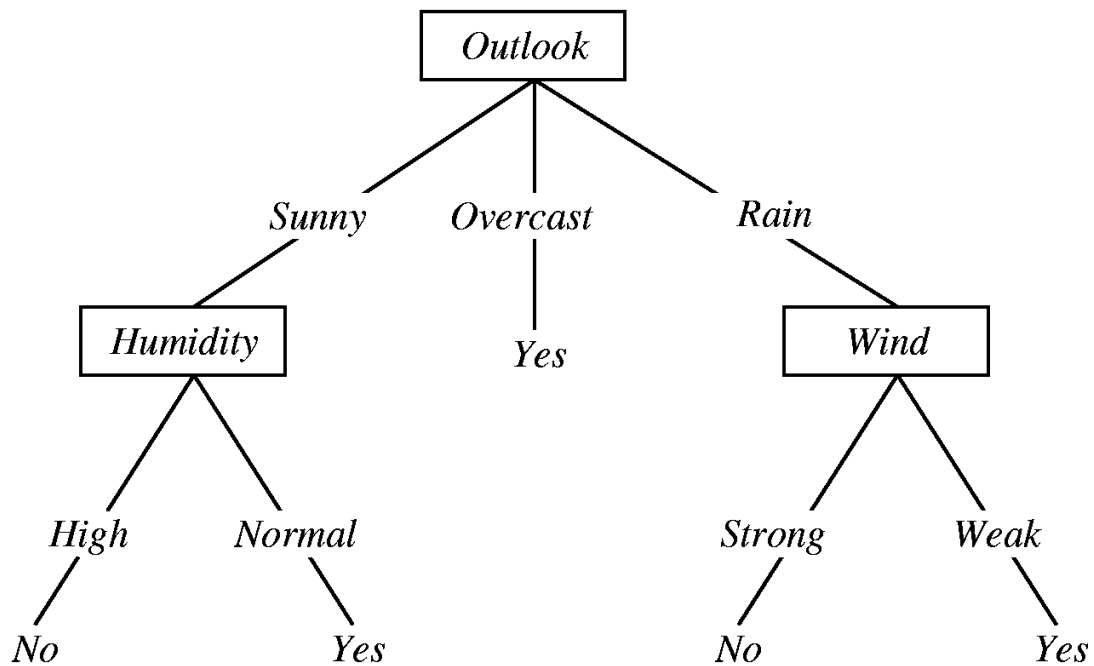


Рисунок 1.3 – Ілюстрація роботи дерев прийняття рішень

Як і у випадку методів, розглянутих вище, дерева прийняття рішень здатні обробляти дані різної природи, але погано підходять до обробки сирих даних зображень.

Загалом, з переваг дерев прийняття рішень можна виділити прозорість фінальної моделі, досить високі результати класифікації зображень після отримання абстрактних характеристик, а також відсутність необхідності нормалізувати вхідні дані.

Очевидним і головним недоліком є відсутність можливості ефективно обробляти сирі дані зображення. Як було показано вище, витягання важливих абстрактних характеристик зображення є нетривіальною задачею і потребує розробки окремої моделі.

#### 1.2.4 Нейронні мережі прямого поширення

Нейронні мережі прямого поширення – це моделі машинного навчання, натхненні структурою мозку. Однак, вони не є точною копією біологічних нейронних мереж, а також не є моделлю, що імітує їх біологічний прообраз.

Нейронна мережа складається з ряду шарів, що включають в себе структури, відомі як штучні нейрони. Нейрони сусідніх шарів пов'язані між собою зв'язками, кожен з яких має певний коефіцієнт, на який множиться значення, що проходить через зв'язок. Під час роботи мережі до поточного нейрона передаються значення усіх нейронів попереднього шару, з'єднаних з ним, а потім до них застосовується функція активації, що виконує нелінійну трансформацію вхідного значення. До широко застосованих функцій активацій відносяться сигмоїда, ReLu, Softmax, гіперболічний тангенс.

У найпростішому варіанті в рамках архітектури нейронної мережі не існує циклів, тобто значення нейронів на кожному шарі залежить лише від значень у попередніх шарах. Такі нейронні мережі називаються мережами прямого зв'язку.

Прикладом використання штучних нейронних мереж для вирішення задач у сфері радіології є [22], де автори вирішують задачу, що є подібною до вирішуваної у цьому проєкті. В статті пропонується метод виявлення переломів кісток на основі штучної нейронної мережі у поєднанні з використанням методу стандартної контурної гістограми на основі ознак (Standard Contour Histogram Feature-Based) для витягання 19 ознак з вхідних зображень. Розроблена модель досягає точності класифікації у 82.98%, що є досить великим результатом.

### **1.2.5 Згорткові нейронні мережі**

Згорткові нейронні мережі є одним з найпопулярніших типів нейронних мереж, що використовуються у сфері класифікації, а особливо – класифікації зображень. Згорткові нейронні мережі імітують структури з зорової кори головного мозку людини, хоча й не моделюють їх роботу точно. На відміну від звичайних повноз'єднаних шарів простих нейронних мереж, згорткові нейронні мережі використовують так звані згорткові шари, що ефективно виявляють закономірності у двовимірних вхідних даних.

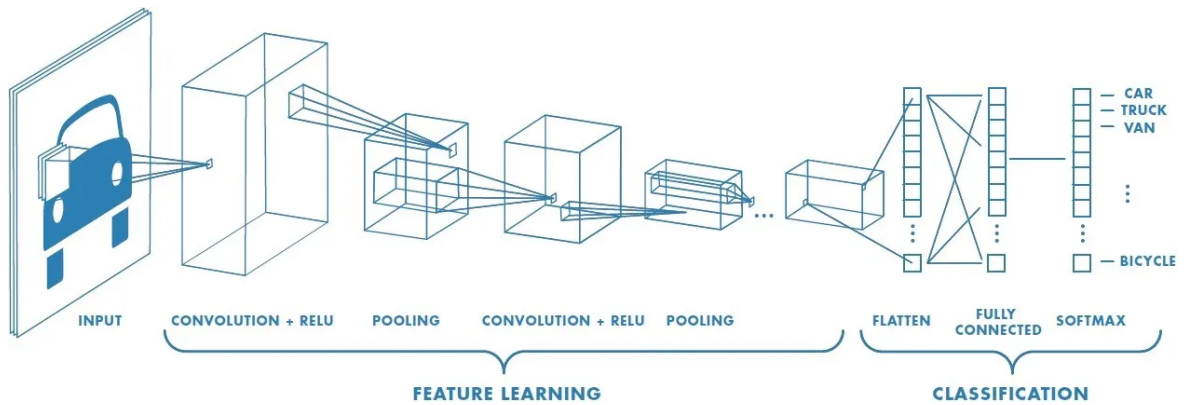


Рисунок 1.4 – Ілюстрація роботи згорткових нейронних мереж [23]

Використання нейронних мереж, а зокрема згорткових нейронних мереж у сферах, пов'язаних з радіологією набуло стрімкої популярності в останні роки та продовжує вдосконалюватися. Згорткові нейромережі використовуються для задач класифікації, сегментації, виявлення захворювань [24].

Прикладом високої ефективності згорткових нейронних мереж у подібних задачах може бути [25]. Автори вивчали можливість використання моделей на основі згорткових нейронних мереж для виявлення ряду різних захворювань за КТ-знімками легень. Також було проведено порівняння отриманих моделей з моделями на основі методу опорних векторів. Дослідження показує, що моделі на основі згорткових нейромереж випереджають моделі на основі методу опорних векторів на 6-9% точності, досягаючи значень у 81-95%.

У [26] було продемонстровано, що згорткові нейронні мережі можна успішно використовувати не лише для виявлення захворювань (у даному випадку хронічне обструктивне захворювання легень), а також для визначення стадії хвороби, а також для прогнозування смертності серед пацієнтів.

Як продемонстровано вище, згорткові нейронні мережі можуть ефективно використовуватися для вирішення задачі класифікації на основі радіологічних знімків, причому такі моделі здатні досягати разючих результатів точності.

Необхідно, однак, зазначити, що нейронні мережі відносяться до

моделей типу «чорний ящик», а тому користувачі не можуть дізнатися про принципи прийняття рішень моделлю. Звичайно, цю проблему можна частково вирішити, як було показано в [26], тобто навчити нейронну мережу виявляти не лише хворобу, а й більш точні дані про її статус, але подібне розширення функціоналу потребуватиме більш складної моделі структури та додаткових ресурсів для навчання.

### **1.3 Порівняльний аналіз існуючих методів**

Загальне порівняння розглянутих методів наведено в табл. 1.1. Необхідно враховувати, що дані в стовпці “Точність класифікації моделей на основі методу при вирішенні подібних задач в літературі” табл. 1.1 наведено з урахуванням попередньої обробки даних для всіх алгоритмів, які вимагають цього, тобто для методу k-найближчих, дерев прийняття рішень, методу опорних векторів, штучних нейронних мереж. При цьому для моделі на основі згорткових нейронних мереж наведений результат обробки сирих даних моделлю.

Ключовим рішенням під час розробки моделі машинного навчання для виявлення переломів шийного відділу хребта на основі знімків комп’ютерної томографії є вибір між алгоритмами, що здатні обробляти сирі дані зображень та розробкою додаткової моделі для витягання абстрактних характеристик з сирого зображення.

Як було показано вище, у подібних задачах, пов’язаних з радіологією, згорткові нейронні мережі здатні обробляти сирі дані зображень, причому ефективно вирішувати задачі їх класифікації, досягаючи точності роботи близько 90%. Інші методи зазвичай досягають подібного рівня точності лише після розробки додаткової моделі для вилучення характеристик зображення, що в даному випадку є надто складним завданням, розробка моделі для вирішення якого за своєю складністю може випереджати розробку основної моделі для обробки вже вилучених абстрактних ознак.



Таблиця 1.1 – Порівняння розглянутих алгоритмів

Назва методу	Обробка сирих даних	Значний розмір бази даних	Прозорість	Витрата значних ресурсів для навчання	Витрата значних ресурсів для роботи	Точність класифікації для подібних задач
KNN	Ні	Так	Так	Ні	Так	83.93% [27]
Decision trees	Ні	Ні	Так	Так	Ні	80.36% [27]
SVM	Ні	Ні	Ні	Так	Ні	92.86% [27]
FNN	Ні	Ні	Ні	Так	Так	82.98% [22]
CNN	Так	Ні	Ні	Так	Так	92% [28]

До інших критеріїв відносяться розміри моделі. Не можна сподіватися, що навчальна вибірка даних для вирішення подібної комплексної задачі виявиться відносно малою. Через це використання методу k-найближчих, який полягає у зберіганні всієї навчальної вибірки не є раціональним у розрізі поточної задачі.

Об'єктивна можливість порівняння обчислювальної складності навчання моделей та їх роботи не існує, оскільки це залежить від багатьох параметрів, а також від вибору алгоритму витягання більш абстрактних характеристик зображення, який буде необхідний для всіх моделей, не заснованих на згорткових нейронних мережах. Проте, обчислювальна складність навчання моделі і не може бути вирішальним чинником у питанні вибору алгоритму машинного навчання, оскільки поточне завдання не накладає особливих обмежень на час навчання моделі. Щодо обчислювальної складності роботи

моделі, то проблема надто високої складності завжди може бути вирішена збільшенням обчислювальних ресурсів. Особливо це стосується нейронних мереж, для яких розроблені різні методи збільшення продуктивності, такі як прискорення за допомогою графічного процесора.

Ще однією характеристикою, що розрізняє згадані моделі, є прозорість їх роботи. Безсумнівно, прозорі моделі є більш підходящими для використання у сфері радіології, де обґрунтування рішень належить до основних принципів. Однак, навіть моделі, що лише видають вердикт щодо належності вхідного екземпляру деякому класу можуть допомогти радіологам, за якими залишається фінальне рішення.

З огляду на всі фактори можна зробити висновок, що саме модель на основі згорткової нейронної мережі є найкращим вибором для виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії.

#### **1.4 Висновки за розділом**

У ході виконання роботи було проведено порівняння алгоритмів машинного навчання. Було зроблено висновок про те, що у розрізі поставленої задачі найкращим вибором є модель на основі згорткової нейронної мережі.

## 2 ВИБІР ТА ОБҐРУНТУВАННЯ СТРУКТУРИ СИСТЕМИ

### 2.1 Вибір мови програмування

Для подальшої розробки моделі на основі обраного алгоритму необхідну вибрати мову програмування, яка б могла бути ефективно використана для реалізації поставленої задачі. Зазвичай у сфері машинного навчання використовується одна з наступних мов: R, C++, Python.

#### 2.1.1 Мова R

Мова R відноситься до відкритого програмного забезпечення, поширюється під ліцензією GNU. R є інтерпретованою кросплатформеною мовою програмування.

Однією з найважливіших особливостей мови R є той факт, що ця мова від самого початку створювалася у якості потужного інструменту статистичної обробки даних. Через це навіть стандартна бібліотека R включає до себе широкий набір функцій, пов'язаних з машинним навчанням.

До R інтегрована можливість розширення базового функціоналу за допомогою так званих пакетів, що представляють собою набір коду, підготовлений до розповсюдження. Існує також централізована система розповсюдження пакетів.

Відомою перевагою R є надзвичайно широкий набір інструментів для створення складної візуалізації багатовимірних даних. Навіть базова система графіки в R надає багато можливостей, а наявність користувальницьких пакетів ще більше розширює їх.

Завдяки надзвичайно зручній системі створення та розповсюдження пакетів, для R створені тисячі бібліотек, у тому числі ряд бібліотек для роботи з машинним навчанням, зокрема наявний пакет, що надає інтерфейс до

найпопулярнішого високорівневого фреймворку для роботи зі штучними нейронними мережами – Keras.

### **2.1.2 Мова C++**

C++ – відома компільована мова загального призначення. C++ розробляється з 1983 року, має безліч бібліотек для роботи з будь-якими програмними рішеннями, використовується в усіх сферах, пов'язаних з інформаційними технологіями.

Скомпільовані програми на C++ відрізняються своєю швидкістю, яка виявляється вищою за швидкість програм на більшості мов, що є інтерпритованими або використовують JIT-компіляцію.

Наразі існує багато різних реалізацій стандарту C++, які розповсюджуються під різними ліцензіями. Деякі з цих реалізацій є комерційними продуктами.

### **2.1.3 Мова Python**

Python – інтерпретована мова програмування загального призначення. Вона є найпопулярнішою мовою програмування у світі та наразі широко використовується у таких сферах: веб-розробка, розробка прикладних програм, машинне навчання. Python відноситься до вільного програмного забезпечення та розповсюджується під ліцензією Python Software Foundation License.

Python є й основною мовою у сфері машинного навчання. Вона займає перше місце за популярністю у цій сфері, причому з великим відривом від інших мов. Для Python розроблено безліч пакетів, пов'язаних з математикою, обробкою та візуалізацією даних, розробкою моделей машинного навчання та штучного інтелекту усіх типів. Зокрема, бібліотека Keras, що є стандартом у сфері розробки штучних нейронних мереж розробляється саме для Python.

Важливою перевагою Python також є наявність зручної централізованої системи розповсюдження користувальницьких бібліотек, яка значно спрощує процес розробки.

### 2.1.4 Порівняння мов програмування

Порівняння розглянутих мов програмування наведено в табл. 2.1.

Таблиця 2.1 – Порівняння мов програмування

Мова програмування	R	C++	Python
Ліцензія	GNU	Залежить від реалізації	Python Software Foundation License
Чи є вільним ПО	Так	Залежить від реалізації	Так
Відносна швидкість роботи	Низька	Висока	Низька
Централізована система розповсюдження бібліотек	Так	Ні	Так
Реалізація Keras та TensorFlow	Так	Ні	Так
Широкий вибір бібліотек для візуалізації даних	Так	Ні	Так
Широкий вибір бібліотек для загальних задач	Ні	Так	Так
Простота синтаксису	Так	Ні	Так

Зважаючи на дані, наведені в табл. 2.1, можна зробити висновок про те, що саме Python є найкращою мовою для вирішення поставленої задачі. Наявність як необхідних спеціалізованих бібліотек, так і бібліотек загального призначення, які можуть бути необхідними для розробки зручного користувацького інтерфейсу, простій синтаксис, а також простота роботи з бібліотеками зумовлюють такий вибір.

## **2.2 Вибір бібліотеки графічного інтерфейсу**

Графічний інтерфейс – невід’ємна частина будь-якого програмного комплексу, що призначений для дистрибуції кінцевим користувачам. Простий та зручний графічний інтерфейс є запорукою задоволення користувачів та ефективного використання продукту.

Популярними графічними бібліотеками для проєктів, що розробляються на Python, є PyQt, Tkinter, PySimpleGUI.

### **2.2.1 PyQt**

PyQt – бібліотека, що є інтерфейсом між Python та відомим фреймворком Qt. Програми, розроблені з PyQt, працюють під Linux, Windows, Mac OS. Для бібліотеки наявний графічний дизайнер форм, що значно спрощує розробку інтерфейсу. Однак, бібліотека має особливості ліцензування: якщо розроблені з нею програми не можуть бути розповсюджені з ліцензією GPL, то необхідно придбати комерційну ліцензію.

### **2.2.2 Tkinter**

Tkinter – стандартна графічна бібліотека Python, що працює під Linux, Windows, Mac OS. Вона надає досить простий, однак потужний інтерфейс для розробки графічної частини настільних застосунків. Вона розповсюджується

під ліцензією Python License та є безкоштовною для використання. Наявні графічні дизайнери форм, що можуть бути використані з цією бібліотекою.

### 2.2.3 PySimpleGUI

PySimpleGUI – безкоштовна кросплатформна бібліотека для побудови графічних інтерфейсів на Python. Її особливістю є крайня простота використання. Бібліотека, однак, не має графічного дизайнера форм.

### 2.2.4 Порівняння бібліотек графічного інтерфейсу

Порівняння розглянутих бібліотек графічного інтерфейсу наведено в табл. 2.2.

Таблиця 2.2 – Порівняння бібліотек графічного інтерфейсу

Середовище	PyQt	Tkinter	PySimpleGUI
Чи є безкоштовною	Залежить від версії	Так	Так
Кросплатформеність	Так	Так	Так
Наявність графічного дизайнера форм	Так	Так	Ні
Відносні можливості з побудови графічних інтерфейсів	Високі	Високі	Низькі

Особливості ліцензування PyQt та відсутність графічного дизайнера форм, а також відносно низька графічна потужність PySimpleGUI зумовлюють вибір Tkinter у якості бібліотека графічного інтерфейсу для вирішення поточної задачі.

## **2.3 Огляд обраного середовища та інструментарію вирішення задачі**

Visual Studio Code є безкоштовною та вільною IDE, що може використовуватися у тому числі для розробки проектів на Python. Більшість необхідних інструментів, як то підсвічування синтаксису, відображення синтаксичних помилок, інтеграція з системами контролю версій наявні в Visual Studio Code. А потужна система аддонів, що розробляються користувачами, дозволяє доповнювати IDE необхідними інструментами, розширюючи можливості майже до нескінченності.

## **2.4 Висновки за розділом**

У ході виконання роботи було обрано мову програмування Python. У якості бібліотеки для розробки користувальницького інтерфейсу обрано Tkinter. Середовищем розробки було обрано Visual Studio Code.



## ВИСНОВКИ

Було розглянуто проблему автоматичного виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії з використанням алгоритмів машинного навчання.

Проведено огляд літературних аналогів, за результатами якого прийнято рішення про розробку моделі машинного навчання на основі згорткової нейронної мережі для вирішення поставленої задачі.

Було використано публічно доступний датасет [9], що містить зображення КТ знімків шийного відділу хребта.

Розроблено ряд моделей, зокрема найкращу – «Fracture detection 3», що продемонструвала точність класифікації у 98.25%, чутливість у 99%, специфічність у 97.5%.

Було розроблено моделі на основі методу опорних векторів, дерева прийняття рішень та методу k-найближчих з використанням аналогічного датасету. «Fracture detection 3» випередила всі розроблені моделі на основі традиційних методів за рівнем точності класифікації..

Продемонстровані за результатами тестування показники моделі випереджають аналогічні показники подібних систем з літератури, а також інших методів на тому ж датасеті, що дає змогу вважати, що розроблена модель є інноваційною та високоефективною в розрізі поставленої задачі.

## ДОДАТОК А – СТРУКТУРА ПРОЄКТУ

### А.1 Структура модулів проекту

Програмний комплекс призначений для виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії. Він складається з модулів Python, що дозволяють створювати моделі для розпізнавання хвороби за зображеннями, завантажуючи навчальну вибірку даних, а також використовувати створену модель за допомогою графічного інтерфейсу. Структуру модулів проекту наведено в табл. А.1.

Таблиця А.1 – Структура модулів проекту

Модуль	Функціонал	Застосування	На які модулі посилається
App.py	Надає графічний інтерфейс	Кінцевим користувачем	Detection.py, зовнішні
Detection.py	Керує завантаженням та роботою створених моделей	Службовий	Зовнішні
CNNBuilder.py	Керує навчанням моделі «Fracture detection 3» на основі згорткових нейронних мереж	Службовий	Зовнішні
KNeighborsBuilder.py	Керує навчанням моделей на методу k-найближчих	Службовий	Зовнішні
SVMBuilder.py	Керує навчанням моделей на основі методу опорних векторів	Службовий	Зовнішні
TreesBuilder.py	Керує навчанням моделей на основі дерев прийняття рішень	Службовий	Зовнішні

## А.2 Структура програмного комплексу

На рис. А.1 міститься загальна схема структури програмного комплексу. Відображені основні розроблені компоненти та шляхи обміну даними між ними.

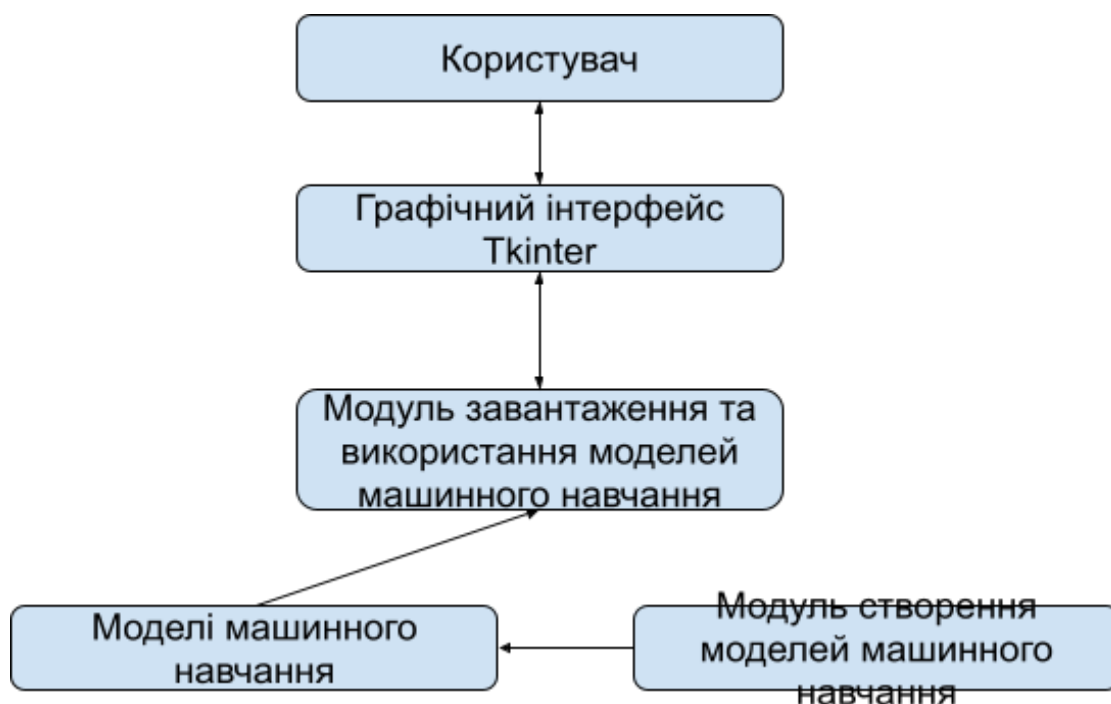


Рисунок А.1 – Структура програмного комплексу

## ДОДАТОК Б – ПРОГРАМНА РЕАЛІЗАЦІЯ ЗАСТОСУНКА

Була розроблена програмна реалізація системи автоматичного виявлення переломів шийного відділу хребта на основі знімків комп'ютерної томографії за допомогою моделі машинного навчання на основі згорткової нейронної мережі.

Розглянуто проблеми запобігання перенавчанню моделі, розробки її архітектури, вибору функцій для оцінювання її якості.

### Б.1 Попередня обробка вхідних даних

Всі зображення з датасету [9] вже приведені до однакового розміру – 224 на 224 пікселів. Всі дані, що надходять на вхід моделі, мають однакову розмірність. Інші зображення, що можуть подаватися на вхід моделі, повинні бути приведені до цього ж формату.

Перед обробкою в моделі значення пікселів з зображення проходять процедуру нормалізації, тобто приводяться до одного невеликого діапазону, значення з якого можуть бути ефективно оброблені моделлю.

Оскільки значення вхідних пікселів можуть приймати значення від 0 до 255, то значення кожного пікселю приводиться до проміжку від 0 до 1.

Приклад вхідного зображення до моделі наведено на рис. Б.1.




Рисунок Б.1 – Зображення КТ-знімку шийного відділу хребта.  
Зображення отримано з датасету [9]

## **Б.2 Вибір функції витрат та функцій оцінки якості моделей**

Для формального числового оцінювання результату роботи моделі під час її навчання використовують функцію витрат (loss-function). Функція витрат обчислюється як числове значення від виходів моделі та реальних значень вихідних ознак екземплярів навчальної вибірки. Вона показує значення помилки моделі, тому під час навчання функція витрат мінімізується для досягнення найкращої оцінки роботи моделі [10].

Оскільки модель вирішує задачу бінарної класифікації, то природнім є використання функції витрат, що називається бінарна перехресна ентропія. Ця функція може бути використана, коли значення вихідних атрибутів екземплярів вибірки приймають бінарні значення: 0 чи 1. При цьому прогнозовані моделлю значення можуть належати проміжку від 0 до 1. Значення бінарної перехресної ентропії збільшуються зі збільшенням відстані між реальними та прогнозованими значеннями класів екземплярів.

Для оцінювання результатів роботи моделі під час її тестування будуть використані так метрики, як точність, чутливість та специфічність. Ці метрики зазвичай використовуються для оцінки моделей, що прогнозують дискретний вихідний аргумент, тобто вирішують задачу класифікації. Вони також використовуються в медицині для оцінювання методик діагностики [11].

## **Б.3 Запобігання перенавчанню**

Перенавчання (overfitting) – це явище, що виникає під час навчання моделей машинного навчання. Воно може бути визначено як результат, який занадто точно відповідає конкретному набору даних, і тому може недостатньо точно обробляти нові дані. Поява перенавчання свідчить про те, що модель недостатньо узагальнює дані, тобто не може виявити важливі закономірності в навчальному наборі даних, але має достатньо інформації про цей набір, щоб мати високу точність розпізнавання саме на ньому.

Найкращим способом усунення ефекту перенавчання є збільшення навчальної вибірки даних [12]. Однак, оскільки використовується публічно доступний датасет, що має обмежений розмір, необхідно застосувати інші методики.

Однією з широко відомих методик боротьби з перенавчанням в моделях на основі нейронних мереж є використання шарів прорідження (dropout-layer) [13].

Прорідження, яке застосовується до шару, полягає у видаленні (встановленні нульового значення) ознак на етапі навчання моделі. Коефіцієнт проріджування – це частка ознак, що обнулюються. Прорідження застосовується лише під час навчання моделі. Для того щоб компенсувати ефект зменшення кількості ознак під час прорідження, ознаки, що не були обнулені, домножуються на значення  $1/(1 - R)$ , де  $R$  – коефіцієнт проріджування.

Прорідження в побудованій моделі реалізовано за допомогою шару dropout з бібліотеки Keras. Значення коефіцієнту прорідження встановлено в 0.1. Воно було підібране емпіричним методом.

#### **Б.4 Побудова та тестування моделі**

Для вирішення поставленої задачі було побудовано модифіковану модель «Fracture detection 1» на основі згорткової нейронної мережі. Архітектуру моделі наведено в табл. Б.1. Мережа приймає на вхід зображення розміром 56 на 56 пікселів.

У порівнянні з однією з відомих моделей з літератури [7], розроблена модель має ряд відмінностей. «Fracture detection 1» складається з лінійної послідовності шарів, тоді як Visual Recognition V3 [7] має складну розгалужену структуру та використовує concat-шари для об'єднання результатів різних гілок. В [7] також використовується avgpool-шар, який не використовується в «Fracture detection 1». У якості функції для двох вихідних нейронів в [7] використовують softmax, тоді як у «Fracture detection 1» використано сигмоїду та наявний лише

один вихідний нейрон. Загалом, «Fracture detection 1» має простішу архітектуру, досягаючи при цьому дещо кращих результатів точності бінарної класифікації.

Таблиця Б.1 – Архітектура «Fracture detection 1»

Шар	Вихідний вектор
Convolution (4x4x1@4)	(None, 56, 56, 4)
MaxPooling2D (f=2;s=2)	(None, 28, 28, 4)
Convolution (4x4x4@8)	(None, 28, 28, 8)
MaxPooling2D (f=2;s=2)	(None, 14, 14, 8)
Convolution (4x4x6@16)	(None, 14, 14, 16)
MaxPooling2D (f=2;s=2)	(None, 7, 7, 16)
Convolution (4x4x16@32)	(None, 7, 7, 32)
MaxPooling2D (f=2;s=2)	(None, 3, 3, 32)
Dense (128)	(None, 128)
Dense (1)	(None, 1)

Результати навчання моделі наведено на рис. Б.2. Загалом, модель досягла точності класифікації у 85.00%.



Рисунок Б.2 – Графічне зображення навчання моделі «Fracture detection 1». Ліва частина зображення містить графіки значень точності, права – значень функції витрат

Для досягнення більших результатів точності класифікації було побудовано модель «Fracture detection 2», що має більш складну структуру. На відміну від моделі «Fracture detection 1», «Fracture detection 2» має подвоєну кількість фільтрів у кожному згортковому шарі, подвоєну кількість нейронів в повноз'єднаному шарі, а також один додатковий повноз'єднаний шар. Такі зміни дозволили моделі виявляти більш глибокі закономірності у вхідних даних, що призвело до збільшення рівня точності класифікації. Архітектуру моделі наведено в табл. Б.2. Результати навчання моделі наведено на рис. Б.3. Загалом, модель досягла точності класифікації у 88.75%.



Таблиця Б.2 – Архітектура «Fracture detection 2»

Шар	Вихідний вектор	Коментар
Convolution (4x4x1@8)	(None, 56, 56, 8)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 28, 28, 8)	
Convolution (4x4x4@16)	(None, 28, 28, 16)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 14, 14, 16)	
Convolution (4x4x6@32)	(None, 14, 14, 32)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 7, 7, 32)	
Convolution (4x4x16@64)	(None, 7, 7, 64)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 3, 3, 64)	
Dense (256)	(None, 256)	Кількість нейронів у шарі подвоєно
Dense (256)	(None, 256)	Шар додано
Dense (1)	(None, 1)	




Рисунок Б.3 – Графічне зображення навчання моделі «Fracture detection 2». Ліва частина зображення містить графіки значень точності, права – значень функції витрат

Вочевидь, в зображеннях, що проходять стискання залишається замало інформації, а структура моделей є недостатньо складної для її виділення, тому для досягнення ще кращих результатів точності класифікації було побудовано модифіковану модель «Fracture detection 3» на основі згорткової нейронної мережі. На відміну від моделі «Fracture detection 2», «Fracture detection 3» має подвоєну кількість фільтрів у кожному згортковому шарі, подвоєну кількість нейронів в повноз'єднаному шарі, один додатковий повноз'єднаний шар, а також dropout-шар, якого не було в попередній моделі. Додавання dropout-шару дозволило зменшити ефект перенавчання моделі та призвело до збільшення максимальних результатів точності, отриманих під час навчання. Мережа приймає на вхід зображення розміром 224 на 224 пікселі. Графічне зображення архітектури наведено на рис. Б.4. Архітектуру моделі наведено в табл. Б.3.

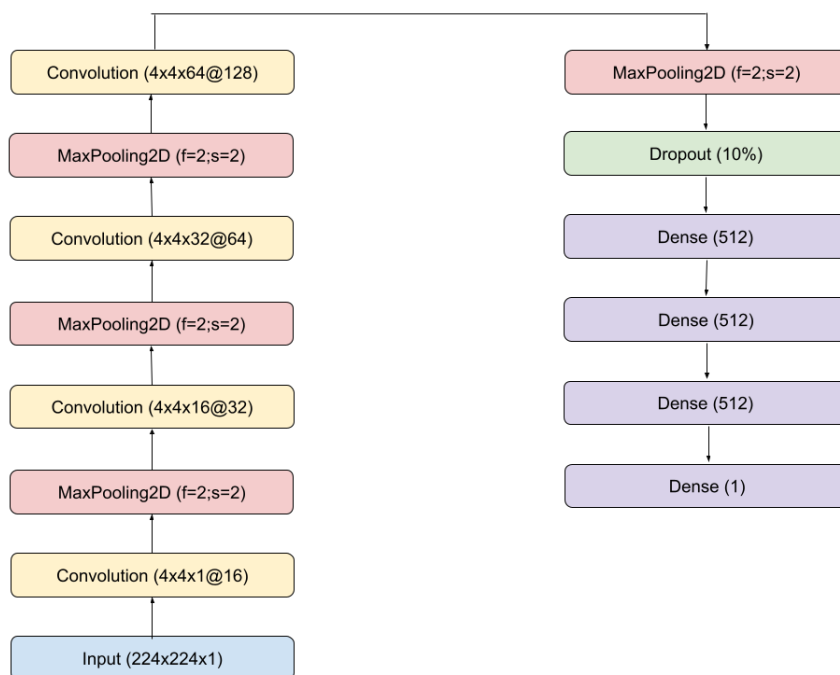


Рисунок Б.4 – Архітектура «Fracture detection 3»

Результати навчання моделі наведено на рис. Б.5. На останній епосі модель «Fracture detection 3» досягла точності класифікації в 98.25%. Значення чутливості склало 99%, а специфічності – 97.5%.



Рисунок Б.5 – Графічне зображення навчання моделі «Fracture detection 3». Ліва частина зображення містить графіки значень точності, права – значень функції витрат

Таблиця Б.3 – Архітектура «Fracture detection 3»

Шар	Вихідний вектор	Коментар
Convolution (4x4x1@16)	(None, 224, 224, 16)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 112, 112, 16)	
Convolution (4x4x4@32)	(None, 112, 112, 32)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 56, 56, 32)	
Convolution (4x4x6@64)	(None, 56, 56, 64)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 28, 28, 64)	
Convolution (4x4x16@128)	(None, 28, 28, 128)	Подвоєно кількість фільтрів в згортковому шарі
MaxPooling2D (f=2;s=2)	(None, 14, 14, 128)	
Dropup (10%)	(None, 14, 14, 128)	Шар додано
Dense (512)	(None, 512)	Кількість нейронів у шарі подвоєно
Dense (512)	(None, 512)	Кількість нейронів у шарі подвоєно
Dense (512)	(None, 512)	Шар додано
Dense (1)	(None, 1)	

### Б.5 Порівняння розробленої моделі з традиційними методами

Для порівняння моделей «Fracture detection 3» з моделями на основі традиційних методів було створено моделі на основі методу опорних векторів, методу k-найближчих та дерева прийняття рішень. Для розробки цих моделей використано бібліотеку Scikit-learn [14]. Для навчання та тестування кожної з

цих моделей використано аналогічний датасет [9].

Оскільки вищеназвані традиційні методи не здатні ефективно обробляти сирі дані зображень, необхідно зменшити розмірність входу для цих моделей. Для вирішення цієї задачі використано реалізацію методу головних компонент (principal component analysis) з бібліотеки Scikit-learn. Розмірність даних для кожного з екземплярів зменшувалася з 50176 до 25 атрибутів.

Для моделі на основі методу опорних векторів після навчання були отримані наступні результати на тестовому наборі даних: точність класифікації – 77.25%, чутливість – 97.5%, специфічність – 57%. Для моделі на основі методу k-найближчих після навчання були отримані наступні результати на тестовому наборі даних: точність класифікації – 82.25%, чутливість – 100%, специфічність – 64.5%. Для моделі на основі дерев прийняття рішень після навчання були отримані наступні результати на тестовому наборі даних: точність класифікації – 58.25%, чутливість – 68.5%, специфічність – 48%.

Порівняння результатів традиційних методів з результатами «Fracture detection 3» наведено в табл Б.4.

Таблиця Б.4 – Порівняння результатів традиційних методів з результатами моделей «Fracture detection 3»

Використана модель	Точність	Чутливість	Специфічність
CNN «Fracture detection 3»	98.25%	99%	97.5%
SVM	77.25%	97.5%	57%
K-neighbours	82.25%	100%	64.5%
Decision tree	58.25%	68.5%	48%

### **Б.6 Порівняння моделі з відомими аналогами**

Порівняння результатів тестування «Fracture detection 3» з відомими аналогами в табл. Б.5.

Таблиця Б.5 – Порівняння моделі з відомими аналогами

Використана модель	Джерело інформації	Точність	Чутливість	Специфічність
Згорткова нейронна мережа «Fracture detection 3»	СТ	98.25%	99%	97.5%
CNN Aidoc [5]	СТ	92%	76%	97%
Оцінка експертів [5]	СТ	95%	93%	96%
IBM Watson Visual Recognition V3 [7]	X-ray	86%	84.7%	87.3%
DCNN [8]	СТ	77.6%	77.2%	77.6%

Подібна до поставленої проблема вирішується в [5]. Була використана згорткова нейромережа, розроблена компанією Aidoc. Також було проведено порівняння результатів роботи нейромержері з середніми результатами оцінки радіологів різних рівнів. Точність згорткової нейронної мережі у виявленні переломів шийного відділу хребта становила 92%, чутливість – 76%, специфічність – 97%. Точність радіологів становила 95%, з 93% чутливості і 96% специфічності. Переломи, пропущені згортковою нейронною мережею та радіологами, були подібними за рівнем і місцем розташування та включали

зламани передні остеофіти, поперечні відростки та остисті відростки, а також переломи нижнього шийного відділу хребта, які часто приховуються ослабленням променя комп'ютерної томографії.

Подібна задача вирішується у [7]. У цій роботі автори вивчають можливість розробки моделі для виявлення будь-яких переломів хребта за рентгенівськими знімками. У якості алгоритму машинного навчання використовується згортова нейронна мережа. За результатами тестування модель досягла рівня точності, чутливості та специфічності у 86% , 84.7% та 87.3%, відповідно.

Задача виявлення переломів шийного відділу хребта з використанням моделі для аналізу результатів комп'ютерної томографії вирішується також у [8]. Розроблена авторами модель на основі згорткової нейронної мережі з шаром двонаправленої довго-короткочасно пам'яті досягла точності у 77.6%, чутливості та специфічності у 77.2% та 77.6%, відповідно.

Дані таблиці вказують на те, що розроблена модель є інноваційною та високоефективною в розрізі проблеми виявлення переломів шийного відділу хребта. Вона випереджає відомі аналоги за показниками точності, чутливості, специфічності класифікації.



## ДОДАТОК В – ПЕРЕЛІК ПОСИЛАНЬ

1. Modified convolutional neural network for pattern recognition of malaria cells / I. Fedorchenko [та ін.] // Proceedings of the 4th international workshop on intelligent information technologies – 2023. – С. 239–248
2. Модифікована згортоква нейронна мережа для автоматизованого розпізнавання ураження малярією за знімками зразків крові пацієнтів / Є. Федорченко, А. Олійник, М. Чорнобук // Радіоелектроніка та молодь у ХХІ столітті. – 2023. – Т. 6, №1. – С. 5 – 6.
3. Розробка моделі машинного навчання для виявлення захворювання COVID-19 за зображеннями / А. Олійник, С. Корнієнко, Є. Федорченко, М. Чорнобук // Тиждень науки. – 2022. – С. 838 – 839.
4. Гібридна згортоква мережа для обробки зображень рентгенівських знімків для виявлення захворювання COVID-19 / Є. Федорченко [та ін.] // Реєстрація, зберігання і обробка даних. – 2022. – Т. 24, № 2. – С. 11.
5. CT cervical spine fracture detection using a convolutional neural network [Електронний ресурс] / J. E. Small [та ін.] // American journal of neuroradiology. – 2021. – Т. 42, № 7. – С. 1341–1347. – Режим доступу: <https://doi.org/10.3174/ajnr.a7094>.
6. Machine learning [Електронний ресурс] // Oxford Advanced Learner's Dictionary. – Режим доступу: <https://www.oxfordlearnersdictionaries.com/us/definition/english/machine-learning>.
7. Artificial intelligence for the detection of vertebral fractures on plain spinal radiography [Електронний ресурс] / Kazuma Murata [та ін.] // Scientific reports. – 2020. – Т. 10, № 1. – Режим доступу: <https://doi.org/10.1038/s41598-020-76866-w>.
8. Deep sequential learning for cervical spine fracture detection on computed tomography imaging [Електронний ресурс] / Hojjat Salehinejad [та ін.] // 2021 IEEE 18th international symposium on biomedical imaging (ISBI), Nice,

- France, 13–16 квіт. 2021 р. – 2021. – Режим доступу: <https://doi.org/10.1109/isbi48211.2021.9434126>.
9. Spine fracture prediction from C.T [Електронний ресурс] // Kaggle: Your Machine Learning and Data Science Community. – Режим доступу: <https://www.kaggle.com/datasets/vuppalaadithyasairam/spine-fracture-prediction-from-xrays>.
  10. A comprehensive survey of loss functions in machine learning [Електронний ресурс] / Qi Wang [та ін.] // Annals of data science. – 2020. – Режим доступу: <https://doi.org/10.1007/s40745-020-00253-5>.
  11. Wong H. B. Measures of diagnostic accuracy: sensitivity, specificity, PPV and NPV / H. B. Wong, G. H. Lim // Proceedings of singapore healthcare. – 2011. – С. 316–318.
  12. Ying X. An overview of overfitting and its solutions [Електронний ресурс] / Xue Ying // Journal of physics: conference series. – 2019. – Т. 1168. – С. 022022. – Режим доступу: <https://doi.org/10.1088/1742-6596/1168/2/022022>.
  13. Dropout: a simple way to prevent neural networks from overfitting / Nitish Srivastava [та ін.] // The journal of machine learning research. – 2014. – Т. 15, № 1. – С. 1929–1958.
  14. Scikit-learn, machine learning in python [Електронний ресурс] // [scikit-learn.org](https://scikit-learn.org). – Режим доступу: <https://scikit-learn.org>.
  15. Moore C. M. Support vector machine (machine learning) [Електронний ресурс] / Candace Makeda Moore // Radiopaedia.org, the peer-reviewed collaborative radiology resource. – Режим доступу: <https://radiopaedia.org/articles/support-vector-machine-machine-learning>
  16. Lo C.-S. Support vector machine for breast MR image classification [Електронний ресурс] / Chien-Shun Lo, Chuin-Mu Wang // Computers & mathematics with applications. – 2012. – Т. 64, № 5. – С. 1153–1162. – Режим доступу: <https://doi.org/10.1016/j.camwa.2012.03.033>
  17. Support vector machine-based classification of schizophrenia patients and

- healthy controls using structural magnetic resonance imaging from two independent sites [Электронный ресурс] / Maeri Yamamoto [та ін.] // Plos one. – 2020. – Т. 15, № 11. – С. e0239615. – Режим доступу: <https://doi.org/10.1371/journal.pone.0239615>
18. A brief review of nearest neighbor algorithm for learning and classification [Электронный ресурс] / Kashvi Taunk [та ін.] // 2019 international conference on intelligent computing and control systems (ICCS), Madurai, India, 15–17 трав. 2019 р. – 2019. – Режим доступу: <https://doi.org/10.1109/iccs45141.2019.9065747>
19. Using the k-nearest neighbor algorithm for the classification of lymph node metastasis in gastric cancer [Электронный ресурс] / Chao Li [та ін.] // Computational and mathematical methods in medicine. – 2012. – Т. 2012. – С. 1–11. – Режим доступу: <https://doi.org/10.1155/2012/876545>
20. Venkatesh. MRI brain image segmentation and detection using K-NN classification [Электронный ресурс] / Venkatesh, M. Judith Leo // Journal of physics: conference series. – 2019. – Т. 1362. – С. 012073. – Режим доступу: <https://doi.org/10.1088/1742-6596/1362/1/012073>
21. Song Y.-y. Decision tree methods: applications for classification and prediction [Электронный ресурс] / Yan-yan Song, Ying Lu // Shanghai arch psychiatry. – 2015. – Т. 27, № 2. – С. 130–150. – Режим доступу: <https://doi.org/10.11919/j.issn.1002-0829.215044>
22. Yang A. Y. Long-Bone fracture detection using artificial neural networks based on contour features of x-ray images [Электронный ресурс] / Alice Yi Yang, Ling Cheng // arXiv.org. – Режим доступу: <https://doi.org/10.48550/arXiv.1902.07897>
23. Saha S. A comprehensive guide to convolutional neural networks – the ELI5 way [Электронный ресурс] / Sumit Saha // towardsdatascience.com. – Режим доступу: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

24. Convolutional neural networks for radiologic images: a radiologist's guide [Електронний ресурс] / Shelly Soffer [та ін.] // Radiology. – 2019. – Т. 290, № 3. – С. 590–606. – Режим доступу: <https://doi.org/10.1148/radiol.2018180547>
25. Comparison of shallow and deep learning methods on classifying the regional pattern of diffuse lung disease [Електронний ресурс] / Guk Baе Kim [та ін.] // Journal of digital imaging. – 2017. – Т. 31, № 4. – С. 415–424. – Режим доступу: <https://doi.org/10.1007/s10278-017-0028-9>
26. Disease staging and prognosis in smokers using deep learning in chest computed tomography [Електронний ресурс] / Germán González [та ін.] // American journal of respiratory and critical care medicine. – 2018. – Т. 197, № 2. – С. 193–203. – Режим доступу: <https://doi.org/10.1164/rccm.201705-0860oc>
27. Dlshad Ahmed K. Detection of image processing fracture based on machine learning techniques [Електронний ресурс] / Kosrat Dlshad Ahmed, Roojwan Hawezi // Measurement: sensors. – 2023. – С. 100723. – Режим доступу: <https://doi.org/10.1016/j.measen.2023.100723>
28. CT cervical spine fracture detection using a convolutional neural network [Електронний ресурс] / J. E. Small [та ін.] // American journal of neuroradiology. – 2021. – Т. 42, № 7. – С. 1341–1347. – Режим доступу: <https://doi.org/10.3174/ajnr.a7094>
29. Модифікована згорткова нейронна мережа для автоматизованого розпізнавання ураження малярією за знімками зразків крові пацієнтів / Є. Федорченко, А. Олійник, М. Чорнобук // Радіоелектроніка та молодь у ХХІ столітті. – 2023. – Т. 6, №1. – С. 5 – 6.