

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Харківський національний університет радіоелектроніки
Факультет Комп'ютерних наук
Кафедра Програмної інженерії

КВАЛІФІКАЦІЙНА РОБОТА

Пояснювальна записка

другий (магістерський)
(рівень вищої освіти)

Розробка рекомендаційної системи медичної діагностики крововиливу
на основі знімків томографії головного мозку

Виконав:

студент 2 курсу, групи ІПЗм-21-3
Антоненко Д. О.
(прізвище, ініціали)

Спеціальність 121 – Інженерія
програмного забезпечення

Тип програми Освітньо-наукова

Керівник проф. Смеляков К. С.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. Кафедри

(підпис)

З.В. Дудар

(прізвище, ініціали)

2023 р.

Харківський національний університет радіоелектроніки

Факультет	Комп'ютерних наук
Кафедра	Програмної інженерії
Рівень вищої освіти	другий (магістерський)
Спеціальність	121 – Інженерія програмного забезпечення (код і повна назва)
Тип програми	освітньо-наукова програма
Освітня програма	Інженерія програмного забезпечення

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)
« ____ » _____ 202_ р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

студенту Антоненко Данилу Олексійовичу

(прізвище, ім'я, по-батькові)

1. Тема роботи «Розробка рекомендаційної системи медичної діагностики крововиливу на основі знімків томографії головного мозку»
затверджена наказом університету від «29» березня 2023 р. № 302Ст
2. Термін подання студентом роботи до екзаменаційної комісії «19» травня 2023 р.
3. Вихідні дані до роботи діагностика крововиливу у мозок на основі знімків комп'ютерної томографії засобами машинного навчання і створення рекомендаційної системи на основі отриманої моделі.
4. Перелік питань, що необхідно опрацювати в роботі вступ, аналіз предметної галузі, методи вирішення проблеми, проведення практичного експерименту та аналіз отриманих результатів, опис прототипу додатку, висновки.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Аналіз предметної галузі	01.04.2023 – 07.04.2023	Виконано
2	Визначення методів та підходів для аналізу знімків томографії	08.04.2023 – 15.04.2023	Виконано
3	Підготовка до експерименту та збір даних	16.04.2023 - 20.04.2023	Виконано
4	Проектування архітектури та розробка прототипу додатку	21.04.2023 - 25.04.2023	Виконано
5	Проведення експерименту	01.04.2023 - 02.05.2023	Виконано
6	Підготовка пояснювальної записки	03.05.2023 – 07.05.2023	Виконано
7	Підготовка презентації та доповіді	08.05.2023 – 09.05.2023	Виконано
8	Перевірка на плагіат	10.05.2023	Виконано
9	Перевірка на нормоконтроль	12.05.2023	Виконано
10	Оцінка роботи рецензентом	13.05.2023	Виконано
11	Попередній захист роботи	15.05.2023	Виконано
	Здача роботи у електронний архів	16.05.2023	Виконано
11	Допуск до захисту завідуючим кафедри	19.05.2023	Виконано

Дата видачі завдання

«23» січня

202_р.

Студент

(підпис)

Антоненко Д.О.

Керівник роботи

(підпис)

проф., д.т.н. Смеляков К. С.

(посада, прізвище, ініціали)

РЕФЕРАТ / ABSTRACT

Кваліфікаційна робота магістра містить: 67 с., 19 рис., 3 табл., 18 джерел.

АЛГОРИТМ, ВНУТРІШНЬОЧЕРЕПНИЙ КРОВОВИЛИВ, МОДЕЛЬ, НЕЙРОННА МЕРЕЖА, КЛАСИФІКАЦІЯ

Об'єктом розробки є рекомендаційна система аналізу крововиливу у мозок на основі знімків комп'ютерної томографії.

Метою роботи є аналіз методів та підходів обробки інформації засобами машинного навчання для виявлення крововиливу у мозок на знімках комп'ютерної томографії.

Методи роботи базуються на таких технологіях як мови програмування Python, Java, бібліотеки PyTorch, Kornia, Pretrainedmodels, фреймворк Spring boot, СКБД PostgreSQL.

У результаті роботи було розроблену рекомендаційну веб-систему, що виконує аналіз знімків томографії головного мозку на наявність кровотечі.

ALGORITHM, INTRACRANIAL HEMORRHAGE, MODEL, NEURAL NETWORK, CLASSIFICATION

The object of development is a recommendation system for analyzing brain hemorrhage based on computed tomography images.

The aim of the work is to analyze methods and approaches of information processing using machine learning techniques for the detection of brain hemorrhage on computer tomography images.

The methods of work are based on such technologies as Python and Java programming languages, PyTorch, Kornia, Pretrainedmodels libraries, Spring boot framework, PostgreSQL DBMS.

Умови публікації пояснювальної записки

Я, Антоненко Данило Олексійович,
студент групи ІІЗМ-21-3 здобувач вищої освіти на другому (магістерському) рівні
кафедра програмної інженерії,
(повна назва кафедри)

заявляю: моя кваліфікаційна робота на тему

Розробка рекомендаційної системи медичної діагностики крововиливу на
основі знімків томографії головного мозку,
(назва роботи)

що буде представлена до ЕК для публічного захисту, виконана самостійно, в ній не містяться елементи плагіату і вона може бути опублікована в електронному архіві відкритого доступу EIArKhNURE. Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

Я ознайомлений з діючим положенням «Про протидію академічному плагіату в ХНУРЕ», згідно з яким виявлення плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту та застосування дисциплінарних заходів.

ЗМІСТ

Вступ.....	7
1 Опис предметної галузі.....	8
1.1 Аналіз предметної галузі	8
1.2 Аналіз існуючих реалізацій	18
1.3 Постановка задачі.....	22
2 Опис вирішення поставленої задачі.....	24
2.1 Аналіз архітектур нейромереж	24
2.2 Аналіз методів ансамблювання	29
2.3 Опис застосованих підходів	31
3 Проведення експерименту та аналіз отриманих результатів.....	36
3.1 Проведення експерименту	36
3.2 Аналіз отриманих результатів	39
3.3 Проблеми та перспективи розвитку	39
4 Архітектура та проектування програмного забезпечення	41
4.1 UML проектування ПЗ	41
4.2 Проектування архітектури ПЗ	42
4.3 Проектування структури зберігання даних	42
4.4 Процес обробки знімків	43
4.5 Створення UI	46
Висновки.....	49
Перелік джерел посилання	50
Додаток А Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії	53
Додаток Б Звіт з результатами перевірки на унікальність тексту в базі ХНУРЕ.	54
Додаток В Апробація роботи.....	55
Додаток Г Слайди презентації.....	58
Додаток Д Експертний висновок результатів перевірки кваліфікаційної роботи на відповідність оформлення вимог ДСТУ 3008:2015	67

ВСТУП

Інсульт є другою провідною причиною смерті в усьому світі, що щороку спричиняє 5,5 мільйонів смертей. Внутрішньо-мозковий крововилив є причиною від 10% до 20% усіх інсультів [1].

Крововилив у мозок є серйозним станом, який викликає пошкодження клітин та тканин мозку. У багатьох випадках він стає причиною інвалідності або смерті, а рання діагностика та лікування мають вирішальне значення для покращення результатів лікування.

Для визначення наявності крововиливу використовується комп'ютерна і магнітно резонансна томографія [2], результати якої мають бути переглянуті висококваліфікованими спеціалістами щоб визначити наявність, локалізацію та тип крововиливу. Це є складною задачею, яка часто займає багато часу.

Пропонується автоматизувати даний процес шляхом використання методів машинного навчання для пришвидшення діагностики крововиливу, що в свою чергу пришвидшить швидкість прийняття рішень щодо надання допомоги пацієнту, що є критичним.

Метою роботи є створення програмної системи для визначення наявності та типу крововиливу у мозок.

Предметом дослідження є аналіз методів та підходів обробки інформації засобами машинного навчання для виявлення крововиливу у мозок на знімках комп'ютерної томографії.

Для проведення дослідження використано емпіричний метод дослідження.

У результаті роботи створено програмну систему визначення наявності та типу крововиливу у мозок за допомогою використання методів машинного навчання.

На основі роботи було опубліковано тези для молодіжного форуму «Радіоелектроніка та молодь у XXI столітті».

1 ОПИС ПРЕДМЕТНОЇ ГАЛУЗІ

1.1 Аналіз предметної галузі

Головний і спинний мозок покриті трьома оболонками [3] — ззовні знаходиться тверда мозкова оболонка, потім - павутинна (арахноїдальна) і м'яка (судинна). Оболонки головного і спинного мозку виконують насамперед захисну функцію.

Тверда оболонка складається з двох листків. Зовнішній листок утворює окістя кісток черепа та спинномозкового каналу; внутрішній листок в межах черепної коробки щільно зростається з зовнішнім і тільки в деяких місцях листки твердої оболонки розходяться утворюючи так звані синусу в яких циркулює венозна кров. В межах спинномозкового каналу листки твердої мозкової оболонки не зростаються і між ними знаходиться субдуральний простір, який заповнений жиром клітковиною.

Павутинна оболонка головного мозку розміщується під твердою і не має судин. Від твердої оболонки головного мозку вона відділена субдуральним простором а від м'якої — підпавутинним, заповненим спинномозковою рідиною. Підпавутинний (субарахноїдальний простір) в межах черепної коробки місцями розширюється утворюючи цистерни головного мозку. Цистерни головного мозку знаходяться в основному на нижній (базальній) його поверхні. Таким чином мозок не травмується об кістки основи черепа під час рухів людини.

М'яка оболонка головного мозку вкриває речовину мозку. Вона пов'язана з мозковою речовиною, заходить у глибину його вздовж судин (навколосудинні простори). Проникаючи у шлуночки мозку (III, IV і бічні), вона бере участь в утворенні судинних сплетень, які виробляють спинномозкову рідину.

На рисунку 1.1 зображено схему оболонок головного мозку




Рисунок 1.1 – Схема оболонок головного мозку

На цій схемі відповідними номерами позначено наступне:

- 1 – тверда оболонка;
- 2 – павутинні зернистості;
- 3 – венозна пазуха;
- 4 – павутинна оболонка;
- 5 – кістка черепа;
- 6 – головний мозок;
- 7 – м'яка оболонка;
- 8 – артерія;
- 9 – підкапілярний простір.

Внутрішньочерепний крововилив є відносно поширеним станом, який має багато причин, починаючи від травми, інсульту, аневризми, судинних

мальформацій, високого кров'яного тиску, заборонених наркотиків і порушень згортання крові. Неврологічні наслідки також сильно відрізняються залежно від розміру, типу крововиливу та локалізації, починаючи від головного болю і закінчуючи смертю. Роль радіолога полягає у виявленні крововиливу, охарактеризуванні підтипу крововиливу, його розмірі та визначенні, чи може крововилив загрожувати критичним ділянкам мозку, які можуть вимагати негайного хірургічного втручання.

Серед симптомів внутрішньочерепної кровотечі наступні є найпоширенішими:

- головний біль: може варіюватися від легкого до важкого і супроводжуватися нудотою або блювотою;
- слабкість або оніміння: виникає коли крововилив впливає на рухову кору головного мозку, викликаючи слабкість та оніміння однієї сторони тіла;
- судоми: виникають коли крововилив впливає на електричну активність мозку;
- порушення мови: виникають коли крововилив впливає на мовний центр мозку, що може спричинити труднощі як зі здатністю розмовляти, так і з розумінням мови;
- проблеми із зором: крововиливи в потиличну частку мозку можуть спричинити двоїння або втрату зору;
- втрата свідомості: у важких випадках внутрішньочерепний крововилив може спричинити втрату свідомості або кому.

Діагностика внутрішньочерепного крововиливу передбачає поєднання вивчення історії хвороби, фізикального огляду та інструментальних досліджень. Під час вивчення історії хвороби лікар опитує пацієнта про симптоми, коли вони почалися та наскільки вони важкі. Також лікар дізнається інформацію про історію захворювань (анамнез життя) пацієнта та будь-які ліки, які він приймає. Вивчення анамнезу є важливим для оцінки стану пацієнта, оскільки перенесений раніше інсульт підвищує ризики на повторне захворювання [4]. Далі відбувається фізичне

обстеження, під час якого лікар проводить неврологічний огляд для оцінки рефлексів, м'язової сили, координації та рівноваги пацієнта. Також перевіряється життєво важливі показники пацієнта, такі як артеріальний тиск і частота серцевих скорочень. У разі наявності підозри на внутрішньочерепну кровотечу призначається інструментальне дослідження метою якого є підтвердження або спростування діагнозу. Дане дослідження проводиться одним із наступних методів:

- комп'ютерна томографія: зазвичай це перший візуалізаційний тест, який використовується для діагностики внутрішньочерепного крововиливу, який надає детальні зображення мозку та може показати крововилив у мозок;
- магнітно-резонансна томографія: цей тест надає детальні зображення мозку та може виявити менші кровотечі, які можуть бути невидимі на КТ;
- церебральна ангіографія: цей тест передбачає введення барвника в кровоносні судини головного мозку та отримання рентгенівських знімків для визначення місця та ступеня кровотечі;
- транскраніальна доплерографія: цей тест використовує звукові хвилі для вимірювання кровотоку в мозку та може виявити наявність кровотечі.

Хоча всі гострі (тобто нові) крововиливи виглядають щільними (тобто білими) на комп'ютерній томографії (КТ), основними ознаками зображення, які допомагають радіологам визначити підтип крововиливу, є розташування, форма та близькість до інших структур.

Внутрішньочерепний крововилив охоплює п'ять типів крововиливу:

- епідуральний;
- субдуральний;
- субарахноїдальний;
- внутрішньопаренхімальний;
- внутрішньошлуночковий.

Кожен тип крововиливу відрізняється етіологією, симптомами, прогнозом і наслідком.

Епідуральний крововилив — це тип кровотечі, яка виникає між зовнішньою оболонкою мозку, яка називається твердою мозковою оболонкою, і черепом. Епідуральна кровотеча може мати артеріальне або венозне походження. Класична артеріальна епідуральна гематома виникає після тупої травми голови, як правило, скроневої області. Вони також можуть виникати після проникаючої травми голови. Зазвичай має місце перелом черепа з пошкодженням середньої менінгеальної артерії, що викликає артеріальну кровотечу в потенційний епідуральний (між твердою мозковою оболонкою і кістками черепа) простір. Хоча середня менінгеальна артерія є класично описаною артерією, будь-яка менінгеальна артерія може призвести до артеріальної епідуральної гематоми. Венозна епідуральна гематома виникає при переломі черепа, і венозна кровотеча з перелому черепа заповнює епідуральний простір. Венозні епідуральні гематоми часто зустрічаються у дітей. Приклад епідуральної кровотечі зображено на рисунку 1.2.



Рисунок 1.2 – Знімок мозку з епідуральною кровотоєю

Субдуральний крововилив — це тип кровотечі, який виникає між шарами тканини, що оточують мозок, відомими як тверда та павутинна (арахноїдальна) оболонками. Зазвичай субдуральний крововилив виникає після того, як судина, що проходить між мозком і черепом, розтягується або розривається і починає кровоточити в субдуральний простір. Найчастіше вони виникають після тупої травми голови, але також можуть виникати після проникаючих травм голови або спонтанно. Приклад субдуральної кровотечі зображено на рисунку 1.3.



Рисунок 1.3 – Знімок мозку з субдуральною кровотечею

Субарахноїдальний крововилив - це тип кровотечі, який виникає в просторі між мозком і тонкими тканинами, що покривають мозок, відомому як субарахноїдальний простір. Цей простір заповнений спинномозковою рідиною, яка оточує і захищає мозок. Він поділяється на наступні типи:

- аневризмальний – виникає після розриву церебральної аневризми;
- неаневризмальний – найчастіше виникає після тупої або проникаючої травми.

Приклад субарахноїдального крововиливу зображено на рисунку 1.4.



Рисунок 1.4 – Знімок мозку з субарахноїдальною кровотечею

Внутрішньопаренхімальний крововилив — це тип кровотечі, що виникає в самій тканині мозку (паренхімі), на відміну від кровотечі, яка виникає між шарами тканини, що оточують мозок (субдуральних або епідуральних). Він зазвичай спричинюється станами, які послаблюють кровоносні судини головного мозку, такими як високий кров'яний тиск, церебральна амілоїдна ангіопатія або аневризма. Внутрішньопаренхіматозні крововиливи спричиняють приблизно 8-13% усіх інсультів і з великою вірогідністю призводять до смерті або серйозної інвалідності. Внутрішньомозкові крововиливи та супутній набряк можуть порушувати або здавлювати прилеглу тканину мозку, що призводить до неврологічної дисфункції. Значне зміщення паренхіми (тканини) мозку може спричинити підвищення внутрішньочерепного тиску і потенційно смертельні

синдрому грижі. Приклад внутрішньопаренхімального крововиливу зображено на рисунку 1.5.




Рисунок 1.5 – Знімок мозку з внутрішньопаренхімальною кровотечею

Внутрішньошлуночковий крововилив — це тип кровотечі, що виникає всередині шлуночків мозку, які є просторами в мозку, що заповнені рідиною. Найчастіше це вражає недоношених немовлят, але також може виникати у дорослих внаслідок травми, інсульту або інших захворювань. У недоношених немовлят часто спричинений тендітними кровоносними судинами, які не повністю розвинені, і може виникнути в поєднанні з іншими ускладненнями недоношених, такими як респіраторний дистрес-синдром. Ступінь тяжкості цього крововиливу

оцінюється залежно від ступеня кровотечі та ураження суміжних структур мозку. Приклад внутрішньошлуночкової крововиливу зображено на рисунку 1.6.



Рисунок 1.6 – Знімок мозку з внутрішньошлуночковою кровотечею

Також існують випадки коли наявні одразу декілька типів внутрішньочерепного крововиливу. Це може бути спричинено черепно-мозковою травмою, геморагічним інсультом або захворюваннями, такими як церебральна амлоїдна ангіопатія або артеріовенозні мальформації. Такі крововиливи потребують особливої уваги та якомога швидшого лікування.

Знімки комп'ютерної томографії зберігаються у файлах формату .dcm[5], що є міжнародним стандартом для зберігання зображень у медицині (DICOM). Структурно цей файл складається із двох частин – заголовок та безпосередньо саме

зображення у бінарному форматі. У заголовку містяться метадані та елементи даних, які описують різні атрибути зображення, такі як інформація про пацієнта, розмір зображення, тощо. Заголовок використовує формат на основі тегів і відповідає словнику даних DICOM, який є стандартизованим списком кодів тегів і описів. Саме зображення має різний розмір в залежності від типу дослідження, яке виконувалось, для комп'ютерної томографії це зазвичай 512 пікселів в довжину і ширину. Окрім того, зазвичай у метаданих зберігається інформація про номер серії та порядковий номер знімку – вони використовуються для відображення у програмах візуалізації знімків зі збереженням порядку та групуючи по серіям. Готовий результат комп'ютерної томографії зазвичай має три серії знімків, кожна із яких має зображення розрізів вздовж кожної із осей координат. Серед важливої інформації, яка зберігається у заголовках DICOM файлів, варто виділити унікальний ідентифікатор пацієнта. Це дає змогу групувати або фільтрувати знімки серед великих наборів даних, де вони зазвичай розташовані у довільному порядку. Кожен знімок зазвичай займає приблизно 512 кілобайтів (в залежності від типу сканування). Кількість файлів однієї комп'ютерної томографії залежить від розміру зрізу, типу дослідження, розмірів пацієнта та інших. Деякі дослідження можуть мати до декількох сотень тисяч зображень, що значним чином впливає на розмір результуючого набору даних і є недоліком. Кількість знімків головного мозку зазвичай коливається від 80 до 200 штук, тобто результат однієї комп'ютерної томографії займає приблизно від 40 до 100 Мб.

Раннє виявлення внутрішньочерепної кровотечі дає змогу вчасно підібрати та розпочати лікування та подальшу реабілітацію пацієнта та скласти прогнози щодо ступені відновлення рухової, мовленнєвої та розумової діяльності. Окрім того, пришвидшення діагностики надає змогу раніше почати лікування пацієнта, що збільшує шанси на реконвалесценцію.

1.2 Аналіз існуючих реалізацій

Одним із наявних рішень є PatchFCN [6], який заснований на повністю згортковій нейронній мережі (FCN). FCN використовує лише згорткові шари, що

дозволяє опрацьовувати вхідні зображення довільних розмірів і створювати вихідні карти сегментації того самого розміру, що й вхідне зображення. Архітектура FCN складається зі згорткових шарів, які зменшують дискретизацію вхідного зображення. За ними слідує набір згорткових шарів, що збільшують дискретизацію карт функцій до вихідного розміру зображення. На останньому рівні мережі є згортковий рівень із функцією активації softmax, яка створює розподіл ймовірностей за класами у вихідній карті сегментації. Перевагою FCN є його здатність обробляти вхідні зображення довільних розмірів, завдяки чому він добре підходить для завдань пошуку об'єктів. Також він ефективно використовує параметри, що дозволяє навчати його на великих наборах даних. PatchFCN має наступні відмінності від стандартного FCN:

- для врахування контексту в краніокаудальному напрямку використовується 3 вхідних канали, що складаються з «флангових» зображень, розташованих безпосередньо вище та нижче зображення;
- для моделювання контексту осей x–y оцінка мережі на будь-якому окремому проході обмежується підмножиною зображення, що змушує мережу приймати рішення на основі локальної інформації;
- для відокремлення передбачення підмножини від передбачення пікселів з більшим шумом і підвищити точність передбачення підмножини, створюється включає гілка класифікації підмножини.

Даний підхід має наступні недоліки:

- для досягнення точних прогнозів модель потребує щільної вибірки фрагментів із вхідного зображення, що може бути обчислювально дорогим і може потребувати значного обсягу пам'яті;
- для навчання моделі потребується велика кількість епох.

Ще одне рішення було представлено командою під керівництвом Nhan T. Nguyen [7]. Воно представляє собою поєднання згорткової нейронної мережі та довготривалої короткочасної пам'яті (LSTM) для класифікації крововиливів. Попередньо навчений CNN (архітектури ResNet-50 і SE-ResNeXt-5) вилучає

особливості з кожного зображення, а LSTM зв'язує їх між фрагментами. Згідно із авторами, логарифмічна втрата у даного підходу складає 0.0522.

Наступний підхід представлено командою під керівництвом Mohammad R. Arbabshirani [8]. Вони запропонували архітектуру CNN, що має п'ять згорткових і два повністю з'єднаних шари для виявлення присутності внутрішньочерепної кровотечі. Даний алгоритм обробляє зображення розмірністю 256 x 256 x 24, тобто тривимірні знімки комп'ютерної томографії. Згідно із авторами, досягнута точність склала 95%.

Наступне рішення представлено командою під керівництвом Gleb Danilov [9]. Рішення базується на моделі ResNeXt – простій, високомодулізованій мережевій архітектурі для класифікації зображень. Спеціальний екземпляр ResNeXt (se_resnext50_32x4d) використовувався з оптимізатором Адама та функцією багатозначних логарифмічних втрат (негативна функція логарифмічної правдоподібності для кількох класів). «SE» у назві моделі означає блок «Squeeze-and-Excitation», який адаптивно перекалібрує відповіді функцій каналу шляхом явного моделювання взаємозалежностей між каналами. Об'єднання цих блоків разом дає змогу створювати архітектури, які мають лише кілька гіперпараметрів для встановлення й узагальнення для складних наборів даних. Ця стратегія створює новий вимір під назвою «кардинальність» (розмір набору перетворень), який є істотним фактором на додаток до вимірів рівня та ширини. Остаточна модель була розроблена як середнє значення двох моделей, складених і підігнаних протягом 3 епох. Дані попередньо обробляються встановлюючи відповідні рівні вікна: 40 для мозку, 80 для крові, 40 для м'яких тканин і ширину вікна: 80 для мозку, 200 для крові та 380 для м'яких тканин. Логарифмічні втрати із складають 0,05098.

Ще одне рішення було представлено командою під керівництвом P.D. Chang [10]. Воно використовує R-CNN, що забезпечує гнучку та ефективну структуру для паралельної оцінки різних сегментів знімків. На першому етапі попередньо налаштований розподіл обмежувальних прямокутників різної форми та роздільної здатності перевіряється на наявність потенційної аномалії. Далі визначаються

обмежувальні рамки найвищого рангу, які використовуються для створення пропозицій регіонів, таким чином зосереджуючи увагу алгоритму на конкретних регіонах зображення. Ці пропозиції складених областей обрізаються з використанням немаксимального стискання та використовуються як вхідні дані в класифікатор для визначення наявності або відсутності крововиливу. У разі позитивного виявлення крововиливу для створення бінарних масок використовується кінцева сегментаційна гілка мережі. У даному випадку точність складала від 77% до 93%.

Наступний метод був представлений командою під керівництвом Hai Ye [11]. Вей алгоритм складається з компонента CNN, за яким слідує компонент RNN, щоб імітувати те, як радіологи інтерпретують знімки. Компонент CNN вилучає корисні властивості із фрагментів зображення, в той час як компонент RNN використовує ці властивості та генерує ймовірність наявності кровотечі або її підтипу. Щоб покращити пояснюваність моделей, автори створили карту грубої локалізації, яка виділяє важливі регіони на зображенні, які уточнюються методом Grad-CAM. Автори стверджують, що досягли точності у 98%.

Ще один метод був сформований командою під керівництвом Mihail Burduja [12]. Їхня система заснована на архітектурі легкої нейромережі, що складається зі згорткової нейронної мережі, яка приймає в якості вхідних даних окремі зрізи комп'ютерної томографії, і довготривалої короткочасної пам'яті, яка приймає ознаки у якості вхідних даних, надані CNN. Основна новизна цієї роботи полягає в інтеграції методу вибору ознак для більш ефективного обробки. Перш за все, вибираються ознаки, враховуючи вагу, призначену шаром Softmax CNN для кожної функції щодо кожного підтипу внутрішньочерепного крововиливу. По-друге, розглядається аналіз основних компонентів (Principal Component Analysis) як альтернативний підхід для вибору функцій. Вибрані функції надаються як вхідні дані для LSTM, незалежно від методу вибору ознак. Ще одна новинка даної структури полягає в тому, що передбачення CNN подаються як вхідні дані для шару класифікації Softmax LSTM, об'єднуючи їх із векторами ознак LSTM. Це

забезпечує підвищення точності з незначними обчислювальними витратами. Крім того, масштаб зрізів комп'ютерної томографії зменшується у 2 рази, що дозволяє швидше навчити модель. Логарифмічні втрати складають 0.04989.

1.3 Постановка задачі

Під час проведення аналізу було знайдено наявні інструменти що дозволяють вирішити поставлену задачу. Далі, за допомогою окремого або поєданого застосування цих інструментів виявимо найкращі з них за наступними параметрами:

- точність;
- швидкість роботи;
- ефективність із використанням різної кількості епох.

Отримані результати порівняємо із уже наявними моделями, представленими у цьому розділі.

Пропонується розробити метод виявлення підтипів внутрішньочерепних крововиливів на комп'ютерній томографії головного мозку на основі двогілкового CNN для виділення ознак і двох різних класифікаторів. Згідно з дослідженнями [13], двійкові детектори окремих підтипів часто мають вищу точність, ніж багатокласові підходи.

У результаті буде розроблено клієнт-серверну систему для надання рекомендацій щодо крововиливу орієнтовану на лікарів. Вона надаватиме наступні функції:

- додання нового пацієнта;
- внесення результатів комп'ютерної томографії пацієнта;
- отримання результатів аналізу знімків комп'ютерної томографії на основі результатів створеної нейромережі;
- перегляд списку пацієнтів;
- пошук пацієнтів;
- видалення пацієнта;

- додання акаунту лікаря адміністратором;
- видалення акаунту лікаря адміністратором.

Серверну частину буде розроблено із використанням Java та Spring Framework, клієнтську частину – із використанням Vue.js. У якості СКБД буде використано PostgreSQL. Для створення нейромережі буде використовуватись Python.

2 ОПИС ВИРІШЕННЯ ПОСТАВЛЕНОЇ ЗАДАЧІ

2.1 Аналіз архітектур нейромереж

У досліджених прикладах використовуються згорткові нейронні мережі (Convolutional Neural Networks) [14, 18] – підтип нейронних мереж, який складається з шарів вузлів, що містять вхідний рівень, один або більше прихованих шарів і вихідний рівень. Кожен вузол з'єднується з іншим і має відповідну вагу та поріг. Якщо вихід будь-якого окремого вузла перевищує вказане порогове значення, цей вузол активується, надсилаючи дані на наступний рівень мережі. В іншому випадку дані не передаються на наступний рівень мережі. Зазвичай згорткові нейронні мережі використовуються для завдань класифікації та комп'ютерного зору, забезпечуючи більш масштабований підхід до задач класифікації зображень і розпізнавання об'єктів, використовуючи принципи лінійної алгебри, зокрема множення матриць, для ідентифікації шаблонів у зображенні. Проте вони є вимогливими до обчислень для навчання моделей.

Найбільш поширеними серед архітектур згорткових нейронних мереж є:

- LeNet5;
- VGGNet-16;
- GoogleNet;
- ResNet.

LeNet5 є однією з найпростіших архітектур та складається з 2 згорткових шарів і 3 повністю з'єднаних шарів. Те, що зараз називається «рівнем об'єднання», раніше називалося рівнем понижувальної вибірки та мало можливість навчання ваги (що більше не стосується дизайну CNN). LeNet-5 став стандартною моделлю, архітектура якої має близько 60 000 параметрів. Візуальне відображення цієї архітектури зображено на рисунку 2.1.

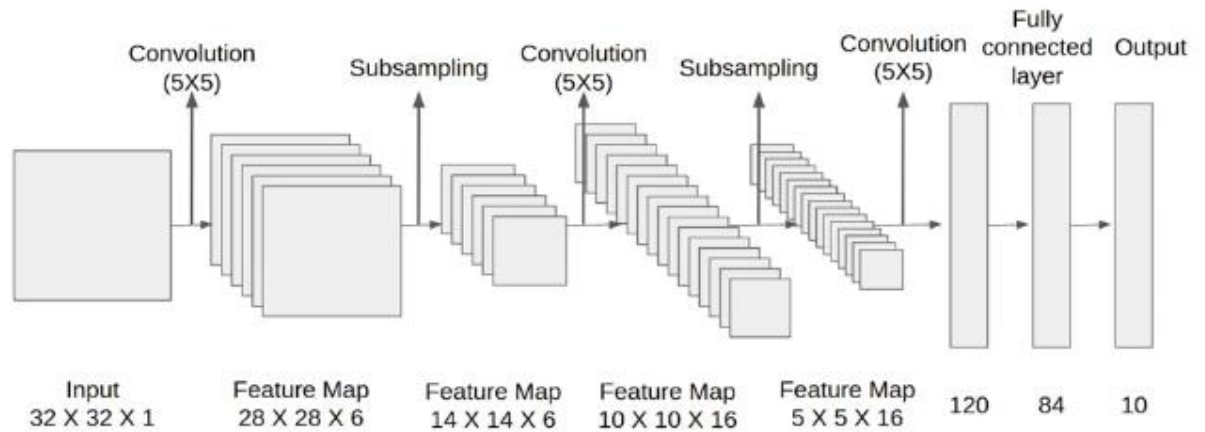


Рисунок 2.1 – Візуальне відображення архітектури LeNet5

Переваги :

- використовує шари зведення, щоб зменшити розмірність карт функцій, що допомагає уникнути перенавчання;
- має відносно невелику кількість параметрів, що полегшує навчання на обмежених наборах даних;
- добре працює для завдань розпізнавання зображень, особливо для розпізнавання рукописних цифр.

Недоліки:

- є неглибокою архітектурою і має проблеми зі складними завданнями розпізнавання зображень;
- розроблений для зображень у градаціях сірого;
- не має технік регуляризації, що може призвести до перенавчання на більш складних наборах даних;
- не має зв'язків пропуску або резидуальних зв'язків.

VGGNet-16 – покращена версія AlexNet, в якій замінені великі фільтри (розміру 11 і 5 в першому і другому шарі згортання, відповідно) на кілька фільтрів розміру 3×3 , розташованих один за одним. Вона змогла досягти частоти помилок у 7,3%. VGG-16 має 13 згорткових шарів, 3 повністю зв'язані шари та використовує

функцію активації ReLU. Ця мережа складається зі 138 мільйонів параметрів. Візуальне відображення цієї архітектури зображено на рисунку 2.2.

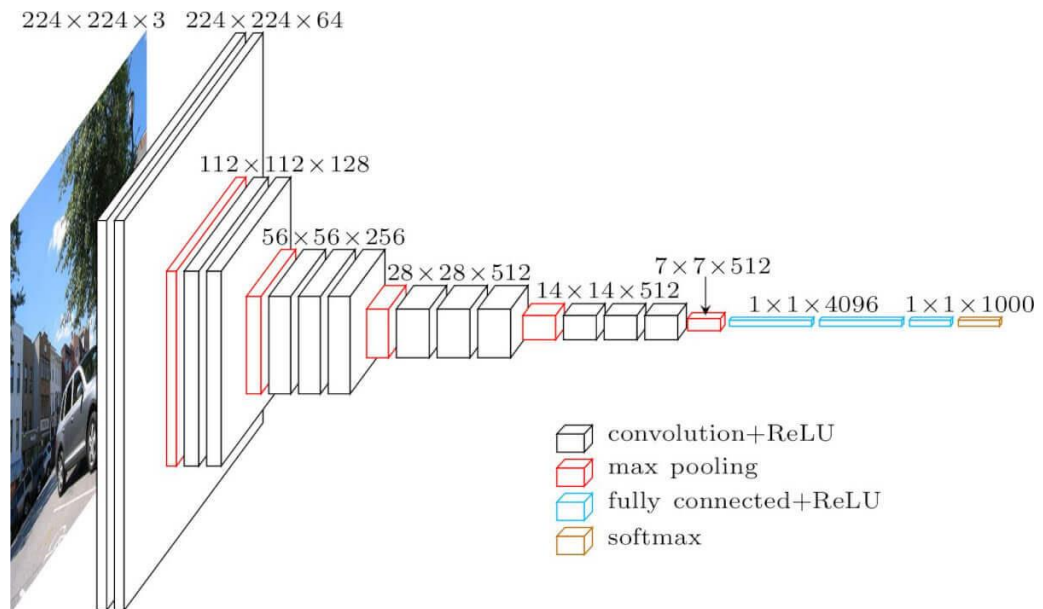


Рисунок 2.2 – Візуальне відображення архітектури VGG-16

Переваги:

- Відносно проста архітектура порівняно з іншими сучасними CNN;
- Може бути використана для передавання навчання на різноманітних завданнях класифікації зображень.

Недоліки:

- мала швидкість навчання;
- сама архітектура мережі важить занадто багато, через що можуть виникнути проблеми із пропускнуою здатністю.

GoogleNet був розроблений, щоб бути глибшим і ефективнішим з точки зору обчислень, ніж попередні моделі CNN. Архітектура має рівень помилок що дорівнює 6,7% та має 22 шари з 5 мільйонами параметрів. Вона включає більш ефективну реалізацію оригінальної архітектури LeNet, що засновано на ідеї початкового модуля, які дозволяють ефективніше використовувати обчислювальні ресурси шляхом використання кількох розмірів фільтрів паралельно. Основна ідея початкових модулів полягає в тому, що замість реалізації згорткових шарів різних

гіперпараметрів у різних шарах ми виконуємо всю згортку разом, щоб отримати результат, що містить матриці всіх операцій фільтрації разом. Загальне відображення цієї архітектури зображено на рисунку 2.3.




Рисунок 2.3 – Візуальне відображення архітектури GoogleNet

На рисунку 2.3 відображена схема початкового модуля.

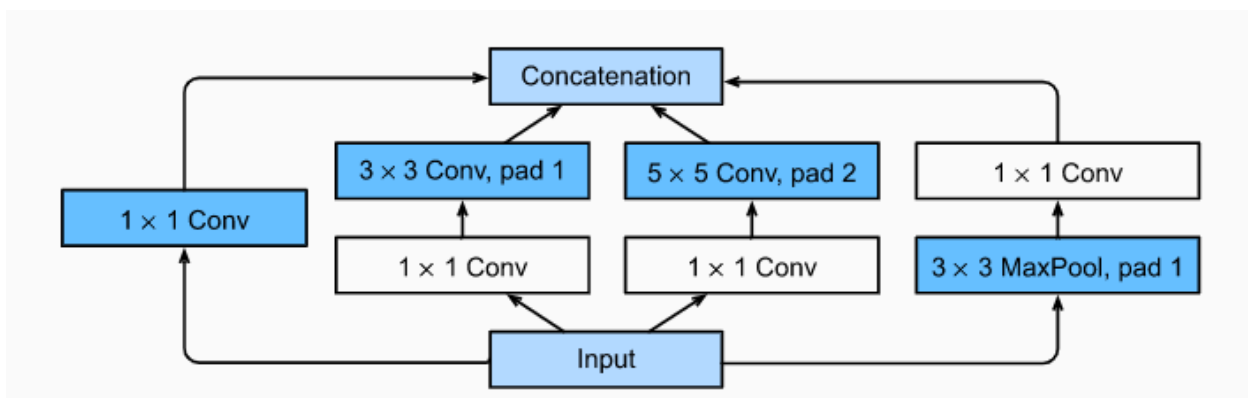


Рисунок 2.3 – Схема початкового модуля архітектури GoogleNet

Переваги:

- гарна продуктивність у задачах класифікації зображень;
- використовує менше обчислювальних ресурсів порівняно з іншими найсучаснішими моделями;
- використання початкових модулів дозволяє ефективніше використовувати обчислювальні ресурси.

Недоліки:

- модель відносно складна та є важкою у розумінні порівняно з більш простими моделями;
- використання згорток 1×1 може потребувати більше обчислювальних ресурсів під час навчання;
- схильна до перенавчання на менших наборах даних.

ResNet є архітектурою що полягає у використанні з'єднань швидкого доступу, які передбачають передачу результатів кількох рівнів на більш глибокі рівні, таким чином пропускаючи певні шари між ними, що допомагає мережі ефективно навчатися на великій кількості шарів без значної втрати продуктивності[15]. Це дозволяє мережі вчитися на вхідних даних, а не лише на помилці між виходом і бажаним виходом. Зберігаючи більше інформації з вхідних даних, ResNet здатний навчати набагато глибші мережі, досягаючи найбільшої продуктивності для широкого кола завдань, включаючи класифікацію зображень, виявлення об'єктів і сегментацію. Архітектура була розроблена для вирішення проблеми зникаючих градієнтів, які можуть виникати в дуже глибоких нейронних мережах і перешкоджати їх здатності навчатися. ResNet-1001 досяг рівня помилок 3,57%. ResNet має декілька варіацій, такі як ResNet-18, ResNet-34, ResNet-50, ResNet-101 і ResNet-152, де числа у суфіксах вказують на кількість шарів у мережі. Було експериментально досліджено, що більш глибокі версії ResNet забезпечують кращу продуктивність, але також потребують більше обчислювальних ресурсів для навчання. Загальне відображення цієї архітектури зображено на рисунку 2.4.




Рисунок 2.4 – Візуальне відображення архітектури ResNet

Переваги:

- велика точність;
- дозволяє навчати дуже глибокі мережі, не стикаючись із проблемою зникаючого градієнта;
- використання резидуальних нівелює проблему деградації;
- можливість використання передтренованих моделей для пришвидшення тренування нових.

Недоліки:

- використання з'єднань швидкого доступу та інших функцій може зробити архітектуру більш складною та важкою для реалізації;
- як і будь-яка архітектура глибокої нейронної мережі є чутливою до перенавчання на малих наборах даних, Щоб пом'якшити цю проблему, можна використовувати методи регуляризації та розширення даних.

2.2 Аналіз методів ансамблювання

Ансамблювання передбачає поєднання кількох моделей для підвищення точності прогнозу. Моделі мають навчатися на спільному наборі даних, але використовувати різні гіперпараметри, алгоритми або архітектури. Ансамблювання ґрунтується на принципі, згідно з яким об'єднання прогнозів декількох моделей видає передбачення, яке буде точнішим, ніж передбачення будь-якої окремої моделі. Об'єднання можна виконувати різними способами:

- Max Voting;
- Averaging;
- Weighted Averaging;
- Stacking;
- Blending;
- Bagging;
- Boosting.

Max Voting – обирається передбачення, на яке вказує більшість моделей.

Averaging – для кожного екземпляру тестового набору даних обчислюються середні прогнози, що зменшує перенавчання і створює більш плавну регресійну модель.

Weighted Averaging – прогноз кожної моделі множиться на ваговий коефіцієнт, а потім обчислюється їх середнє значення.

Stacking – моделі поєднуються за допомогою іншого алгоритму машинного навчання. Основна ідея полягає в тому, щоб навчити алгоритми машинного навчання за допомогою навчального набору даних, а потім створити новий набір даних із цими моделями. Потім цей новий набір даних використовується як вхідні дані для алгоритму машинного навчання комбінатора. Прикладами цього методу ансамблювання є Decision Tree, KNN або SVM.

Blending – передбачає поділ вихідного навчального набору даних на дві або більше частин. Одна частина використовується для навчання кожної окремої моделі, а інша частина використовується як набір перевірки. Набір перевірки використовується для оцінки ефективності окремих моделей і визначення вагових коефіцієнтів, які слід призначити кожній моделі в остаточному ансамблі. Останнім кроком змішування є використання індивідуальних прогнозів моделі як вхідних функцій для остаточної моделі, якою може бути будь-який алгоритм машинного навчання, наприклад лінійна регресія або нейронна мережа [17].

Bagging – часто використовується з алгоритмами дерева рішень, де кожна модель навчається на випадковій підмножині навчальних даних і випадковій

підмножині функцій. Роблячи це, моделі змушені зосереджуватися на різних аспектах даних, що може допомогти підвищити їхню загальну точність у поєднанні.

Boosting – послідовний процес, коли кожна наступна модель намагається виправити помилки попередньої моделі. Наступні моделі залежать від попередньої моделі. Реалізаціями такого підходу є AdaBoost, GBM та XGBM.

2.3 Опис застосованих підходів

Набір даних для цього дослідження було взято із загальнодоступної бази даних Радіологічного Товариства Північної Америки (RSNA), яка використовується для конкурсу з виявлення внутрішньочерепних крововиливів [16]. У цьому наборі міститься 372 500 знімків комп'ютерної томографії голови, серед яких є знімки із зображеннями різних видів кровотеч: субдуральних, епідуральних, внутрішньошлуночкових, інтрапаренхімальних і субарахноїдальних. Деякі із цих знімків не мають ознак кровотечі або містять одразу декілька типів крововиливу. До кожного випадку додається мітка, яка визначає наявність кожного підтипу кровотечі. Кількість зрізів різна для пацієнтів, хоча більшість КТ-досліджень представляє всю область мозку, а не лише його середню частину.

Запропонований підхід включає 3 етапи обробки даних:

- попередня обробка та підготовка знімків комп'ютерної томографії;
- вилучення ознак за допомогою двох гілок згорткових нейронних мереж;
- двокласова класифікація на основі спільного вектору ознак.

На рисунку 2.5 зображено загальну схему моделі.

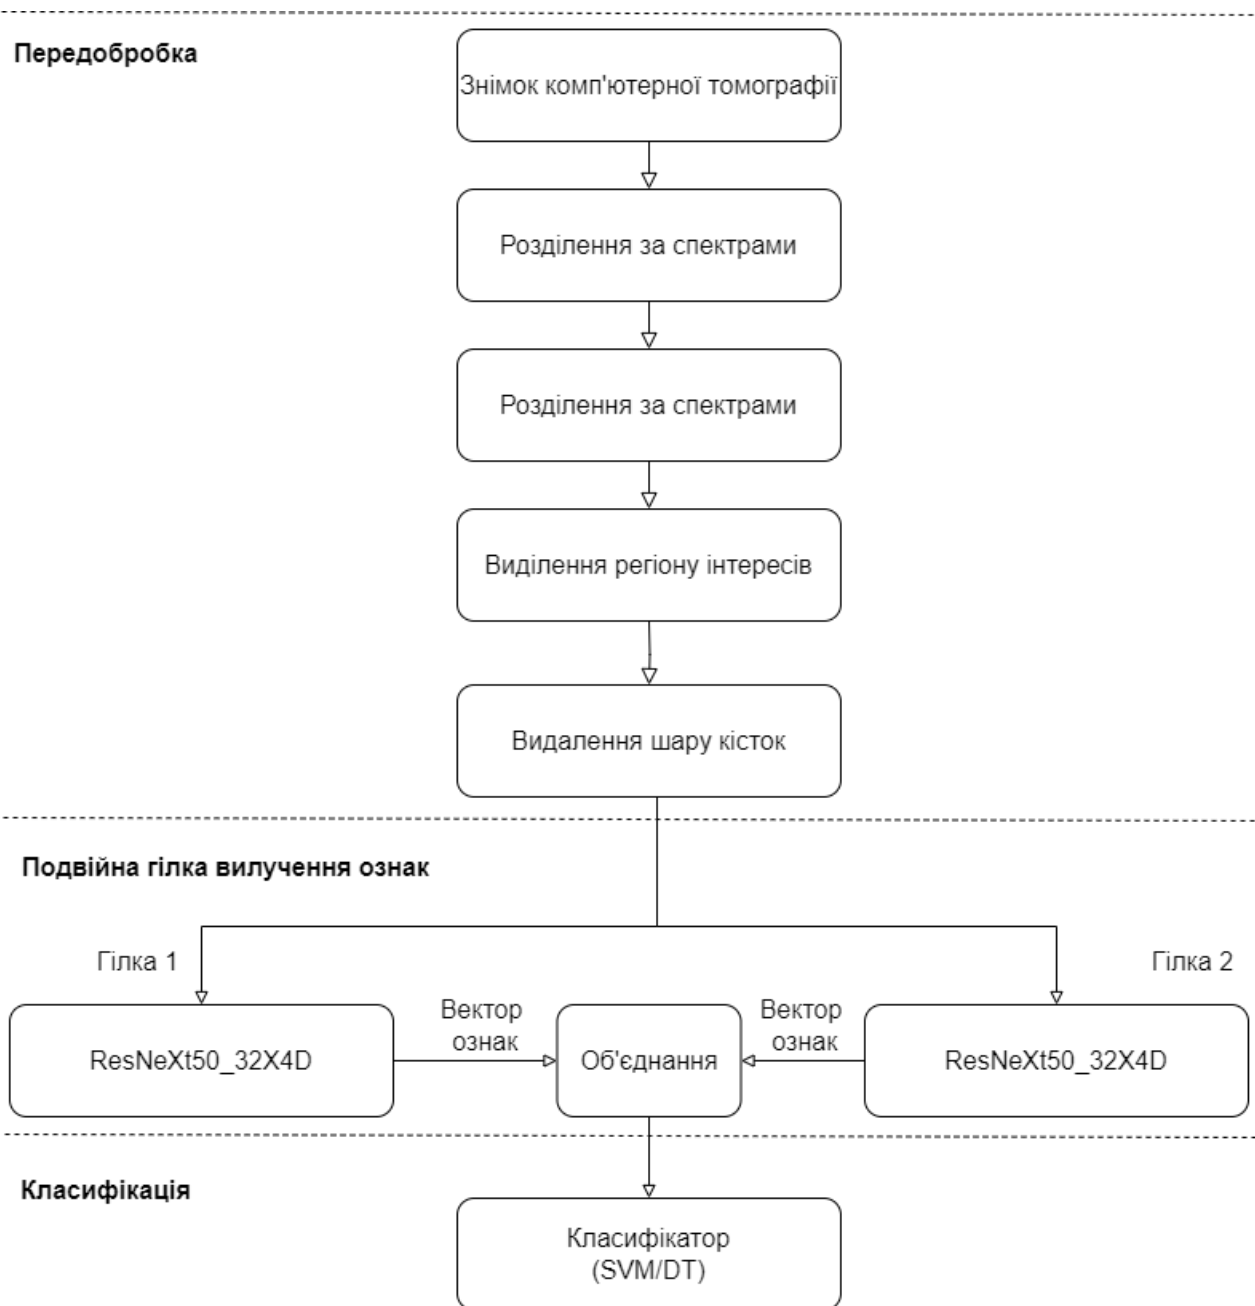


Рисунок 2.5 – Загальна схема моделі

Попередня обробка даних починається із застосування спеціальних вікон інтенсивності до КТ-зображення, після чого виконується алгоритм видалення черепа. Використовується три вікна інтенсивності: $L = 50 - 100$, $W = 130 - 300$ (субдуральне вікно), $L = 600$, $W = 2800$ (кісткове вікно) і $L = 40$, $W = 80$ (вікно мозку). Потім зображення нормалізується до діапазону 0–1. Після цього визначається область інтересу, яка охоплює область черепа як обмежувальну рамку, що обрамляє найбільший бінарний об'єкт на субдуральному зображенні

після бінаризації за допомогою методу Оцу, який використовується для розділення пікселів зображення на два класи: передній план і фон. Він обчислює оптимальне порогове значення шляхом максимізації міжкласової дисперсії рівнів сірого на зображенні. Основна ідея методу Оцу полягає в тому, щоб знайти оптимальне порогове значення для поділу зображення в градаціях сірого на передній і фоновий регіони. Порогове значення визначається шляхом мінімізації внутрішньокласової дисперсії між двома регіонами та максимізації міжкласової дисперсії. Іншими словами, поріг вибирається таким чином, щоб дисперсія в межах кожного класу була мінімізована, а дисперсія між двома класами була максимальною. Цей метод припускає, що гістограма зображення може бути змодельована сумішшю двох розподілів Гауса, що відповідають областям фону та переднього плану. Оптимальний поріг потім розраховується шляхом вичерпного пошуку порогового значення, яке максимізує відношення міжкласової дисперсії до внутрішньокласової дисперсії. Він добре працює для зображень із однорідним освітленням та простим фоном.

Процес видалення черепа виконується на зображенні субдурального вікна шляхом вилучення пікселів з найвищою інтенсивністю, що відповідають ділянкам кісток, і заміни їх пікселями з нульовим значенням. Після видалення черепа підготовка даних розпадається на дві гілки, пов'язані з архітектурою згорткових нейронних мереж (CNN). У обох гілках структура тривимірного зображення складається з трьох віконних фрагментів із пікселями черепа, замінені нулями. Ліва гілка використовує субдуральне вікно $L=50$ $W=130$, а права - $L=100$ $W=300$. Для обох гілок видалено кістки черепа.

Для автоматичного вилучення функцій із підготовлених RGB-зображень обидві гілки використовують аналогічну попередньо навчену архітектуру ResNetXt50_32X4D, що складається з набору блоків згортки та ідентифікаційних блоків.

ResNetXt50_32X4D є варіантом архітектури ResNet, який містить 50 шарів і використовує архітектуру ResNeXt, яка є розширенням ResNet та використовує

згруповані згортки для збільшення потужності представлення без значного збільшення кількості параметрів. 32X4D у назві вказує на те, що вона використовує 32 групи згорток із потужністю 4. Ця модель досягла однієї з найкращих продуктивностей у вирішенні задач комп'ютерного зору. Як глибша мережа, вона дозволяє отримувати більш розширені функції. Однак велика кількість шарів може спричинити зникнення градієнтів і зниження точності, що мінімізується пропусканням шарів в архітектурі ResNet. Мережа приймає вхідні дані розміром $512 \times 512 \times 3$.

Обидві мережі ResNet навчались окремо і були протестовані щоб оцінити їх продуктивність. У даній моделі ознаки, сформовані обома гілками були об'єднані для налаштування спільного вектору ознак для класифікації. Навчання мереж проводилося за допомогою адаптивного оптимізатора оцінки моменту. До зображень застосовувались наступні зміни:

- поворот;
- зміна розміру;
- зсув (горизонтальний та вертикальний).

У кожному експерименті набір даних був випадковим чином розділений базу на навчальні, валідаційні та тестові підмножини у співвідношенні 80%:10%:10%. Параметри мережі, включаючи розмір міні-серії (8) і кількість епох (60), вибиралися експериментально. Навчання припинялося автоматично, якщо кількість хибних результатів не зменшувалось протягом десяти епох.

Для класифікації було використано та порівняно два класифікатори: машину опорних векторів (SVM) і дерево рішень (DT).

SVM є ефективним у регресії та класифікації, особливо в двокласових завданнях. Цей метод спрямований на відокремлення вибірок різних класів в просторі функцій, що максимізує межу між ними з використанням методів оптимізації. У даній моделі класифікатор SVM був використаний з лінійним ядром через його кращу продуктивність порівняно з іншими розглянутими ядрами, включаючи Gaussian і RBF. У результаті інструмент надає ймовірності присутності

певного підтипу кровотечі на зображенні. Кровотеча підтверджується, якщо ймовірність перевищує 50%.

Використання DT як класифікатора для CNN виявилось неефективним рішенням, тому було вирішено замінити якого на рандомний ліс (RF), який являє собою поєднання дерев рішень, де декілька дерев паралельно навчаються на різних даних, а вихідні дані з кожного дерева об'єднуються.

3 ПРОВЕДЕННЯ ЕКСПЕРИМЕНТУ ТА АНАЛІЗ ОТРИМАНИХ РЕЗУЛЬТАТІВ

3.1 Проведення експерименту

Під час проведення експерименту будемо досліджувати наступні параметри:

- точність;
- чутливість (true positive);
- специфічність (true negative);
- Дайсівський індекс.

Введемо позначення для сценаріїв:

- TP – true positive (кількість правильно виявлених позитивних передбачень);
- TN – true negative (кількість правильно виявлених негативних передбачень);
- FP – false positive (кількість неправильно виявлених позитивних передбачень);
- FN – false negative (кількість неправильно виявлених негативних передбачень).

Точність будемо розраховувати за наступною формулою:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} 100 \quad (1)$$

Чутливість будемо розраховувати за наступною формулою:

$$TPR = \frac{TP}{TP + FN} 100 \quad (2)$$

Специфічність будемо розраховувати за формулою 3.

$$TNR = \frac{TN}{TN + FP} 100 \quad (3)$$

Дайсівський індекс будемо розраховувати за наступною формулою:

$$F1 = \frac{2TP}{2TP + FP + FN} 100 \quad (4)$$

Спершу випадковим чином розділюю набір даних на навчальні, валідаційні та тестові підмножини у співвідношенні 80%:10%:10%.

В першому експерименті проводжу тестування гілок моєлі що використовують ResNeXt50_32x4D окремо, пропускаючи конкатенацію ознак і класифікацію. Результати цього експерименту представлені таблиці 1.

Таблиця 1 – Результати експерименту на перевірку гілок моделі

Тип крововиливу	Гілка	ACC (%)	TPR (%)	TNR (%)	F1 (%)
Субдуральний	№1	89.2	86.6	88.6	89.3
	№2	87.3	88.0	86.6	88.4
Епідуральний	№1	57.4	57.1	62.3	58.4
	№2	65.7	46.9	84.2	58.6
Внутрішньопаренхімальний	№1	91.8	92.3	94.1	91.9
	№2	93.2	92.1	93.6	91.4
Внутрішньошлуночковий	№1	93.8	95.3	95.5	94.6
	№2	94.0	95.3	94.5	94.7
Субарахноїдальний	№1	87.2	89.4	89.3	87.3
	№2	86.3	90.8	86.4	86.8

В другому експерименті перевірятьтимо ті самі показники, але вже із використанням конкатенації та класифікації. У таблиці 2 наведено отримані показники для кожного типу кровотечі та класифікатора.

Таблиця 2 – Результати експерименту на перевірку класифікаторів

Тип крововиливу	Класифікатор	ACC (%)	TPR (%)	TNR (%)	F1 (%)
Субдуральний	SVM	86.5	82.6	91.1	86.2
	RF	88.3	84.7	90.2	89.8
Епідуральний	SVM	75.7	74.0	79.3	74.6
	RF	74.1	69.1	70.9	73.9
Внутрішньопаренхімальний	SVM	92.4	93.1	90.2	92.5
	RF	94.1	92.8	91.6	94.2
Внутрішньошлуночковий	SVM	94.8	96.3	92.3	95.7
	RF	95.8	96.2	92.5	96.1
Субарахноїдальний	SVM	87.3	86.8	86.4	84.1
	RF	88.4	88.2	89.3	88.5

У третьому тесті порівняємо результативність наявних моделей із запропонованою за Дайсівським індексом. Результати порівняння відображені у таблиці 3.

Таблиця 3 – Порівняння існуючих моделей із запропонованою

	Chang [10]	Ye [11]	Danilov [9]	Burduja [12]	Власна
Субдуральний	86.3	84.0	54.1	71.8	89.8
Епідуральний	86.3	72.0	62.3	48.9	73.9
Внутрішньопаренхімальний	93.1	93.0	81.3	83.8	94.2
Внутрішньошлуночковий	-	87.0	82.2	88.4	96.1

Продовження таблиці 3

	Chang	Ye	Danilov	Burduja	Власна
	[10]	[11]	[9]	[12]	
Субарахноїдальний	77.2	78.0	61.8	73.2	88.5

Таким чином отримуємо підтвердження, що дана модель працює краще, ніж взяті до порівняння.

3.2 Аналіз отриманих результатів

У першому експерименті найкращі результати були досягнуті для внутрішньошлуночкового крововиливу, тоді як найгірші показники спостерігалися у випадку епідурального крововиливу. Жодна гілка не перевершила іншу у жодному з тестів.

У другому експерименті найкращі показники спостерігалися при внутрішньошлуночкових крововиливах, тоді як найгірші результати спостерігалися при епідуральних кровотечах, підтверджуючи результати першого експерименту. RF виробляє вимірювання вищої якості в більшості категорій, крім епідуральної. Крім того, з точки зору точності та оцінки F1 класифікатора RF перевершив будь-яку модель ResNeXt50_32x4D з першого експерименту.

3.3 Проблеми та перспективи розвитку

З результатів експериментів видно, що визначення епідуральної кровотечі є менш точним, ніж усіх інших. Найнижчі показники, отримані в класифікації цього типу, викликають питання про дисбаланс між класами в одному завданні класифікації. Кількість випадків епідуральної кровотечі на порядок менша, ніж в інших типах. Ймовірно, це так у цій конкретній кровотечі, і класове зважування, яке використовується під час навчання, недостатнє для вирішення цієї проблеми. Характер появи того чи іншого крововиливу при КТ має вирішальний вплив на можливості виявлення. Також можливі подібності між різними ознаками кровотечі. Деякі складні випадки являють собою комбінацію кількох підтипів одночасно.

Тому правильна класифікація, безсумнівно, є складним завданням. Для вирішення цієї проблеми можливо добре підійшли б моделі GAN, у яких одна з мереж генерує дані для входу, за допомогою чого можливо було б нівелювати різну частоту появи тих чи інших типів кровотечі.

Використання зовнішнього класифікатора машинного навчання, що використовує переваги глибоких функцій подвійного джерела, є вигідним для виявлення внутрішньочерепної кровотечі.

Ще одним недоліком є те, що модель здатна аналізувати лише один зріз комп'ютерної томографії. В цілому це легко піддається покращенню і досягається модифікацією другої гілки таким чином, щоб вона групувала декілька знімків.

4 АРХІТЕКТУРА ТА ПРОЕКТУВАННЯ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ

4.1 UML проектування ПЗ

Веб додаток є відносно простим та має 2 типи користувачів – адміністратор та лікар. На рисунку 4.1 зображено діаграму із їх функціональними можливостями.

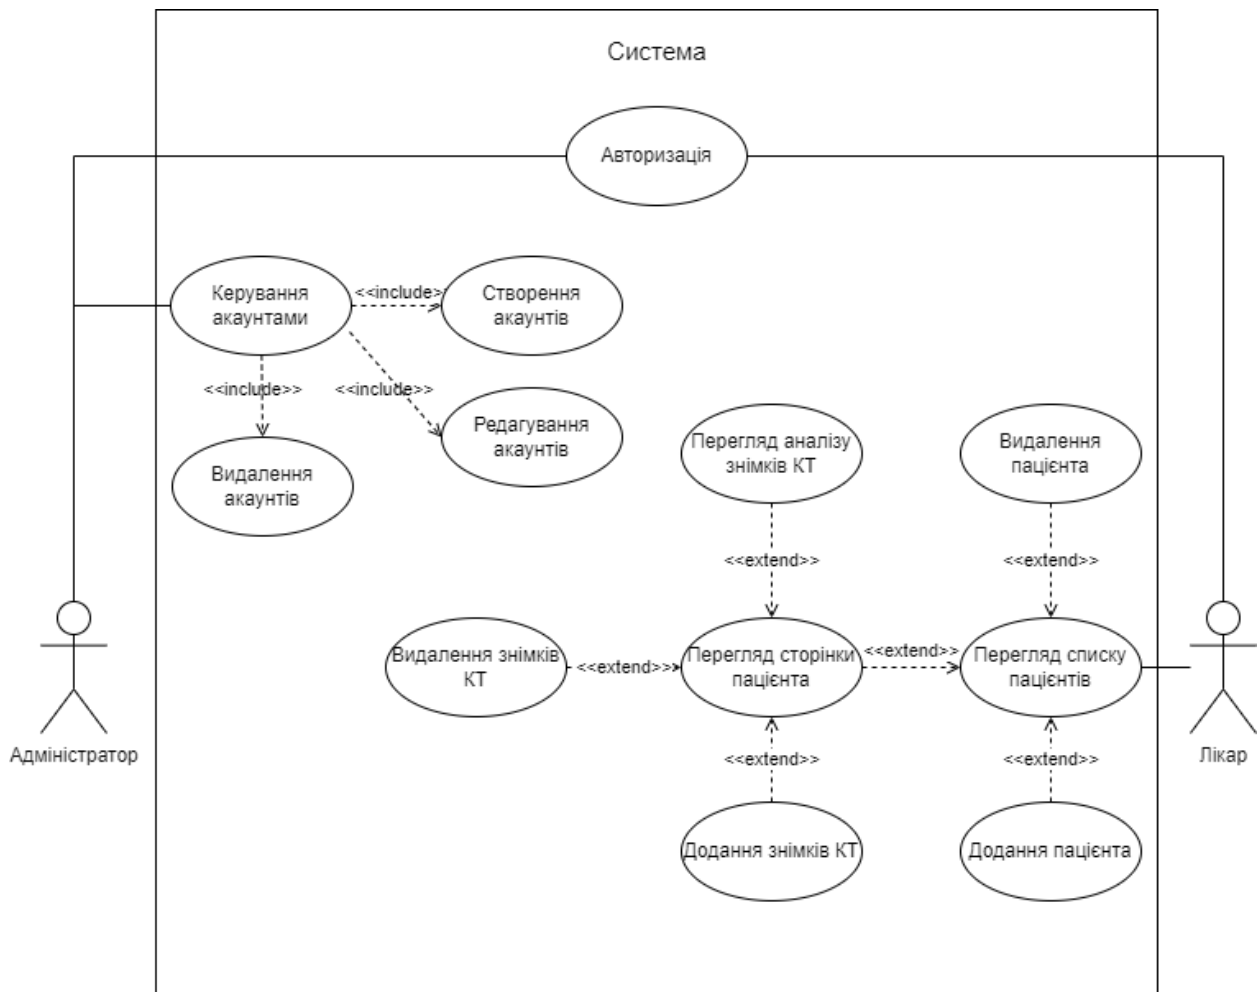


Рисунок 4.1 – UML діаграма із функціональними можливостями

Задача адміністратора це керування акаунтами, що включає:

- створення акаунтів;
- редагування акаунтів;
- видалення акаунтів.

Для лікаря основною цінністю додатку є функція аналізу знімку комп'ютерної томографії. Для того щоб ця функція мала сенс у контексті роботи лікаря додатково він матиме можливість:

- переглядати список своїх пацієнтів;
- додавати нових пацієнтів;
- видаляти пацієнтів;
- переглядати сторінку пацієнта;
- додавати знімок комп'ютерної томографії пацієнта;
- видаляти знімок комп'ютерної томографії пацієнта.

4.2 Проектування архітектури ПЗ

Додаток має клієнт-серверну архітектуру. Серверна частина створена за допомогою Java та Spring boot і використовує нейромережу написану на Python для виконання аналізу знімків КТ, запускаючи відповідний скрипт. Клієнтська частина створена за допомогою Vue.js, що спрощує та пришвидшує розробку. Діаграма розгортання для даної архітектури зображена на рисунку 4.2.

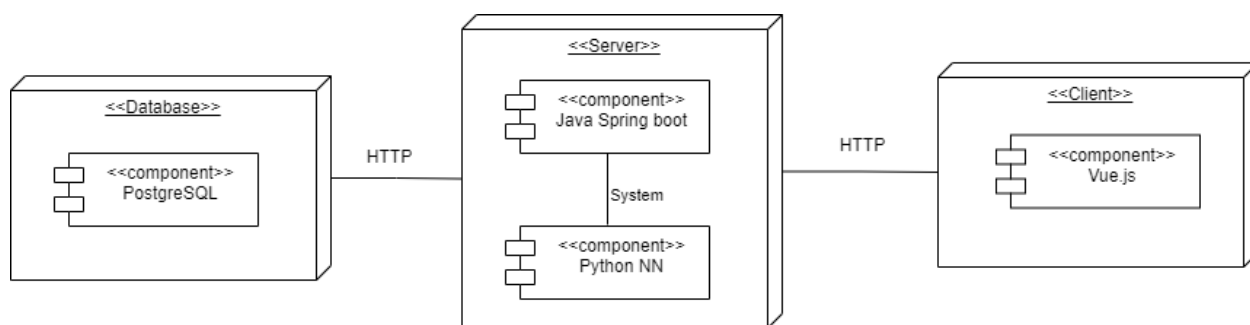


Рисунок 4.2 – Діаграма розгортання для додатку

Для обміну інформацією між клієнтською та серверною частинами використовується протокол HTTP. Для зберігання даних використовується СКБД PostgreSQL.

4.3 Проектування структури зберігання даних

У базі даних мають існувати наступні таблиці:

- user_type – список типів користувачів для обмеження їх прав доступу;
- user – список користувачів
- patient – інформація про пацієнта
- processing_status – зберігає інформацію про статус обробки знімку томографії нейромережею.

На рисунку 4.3 відображена ER-діаграма запропонованої структури зберігання даних.

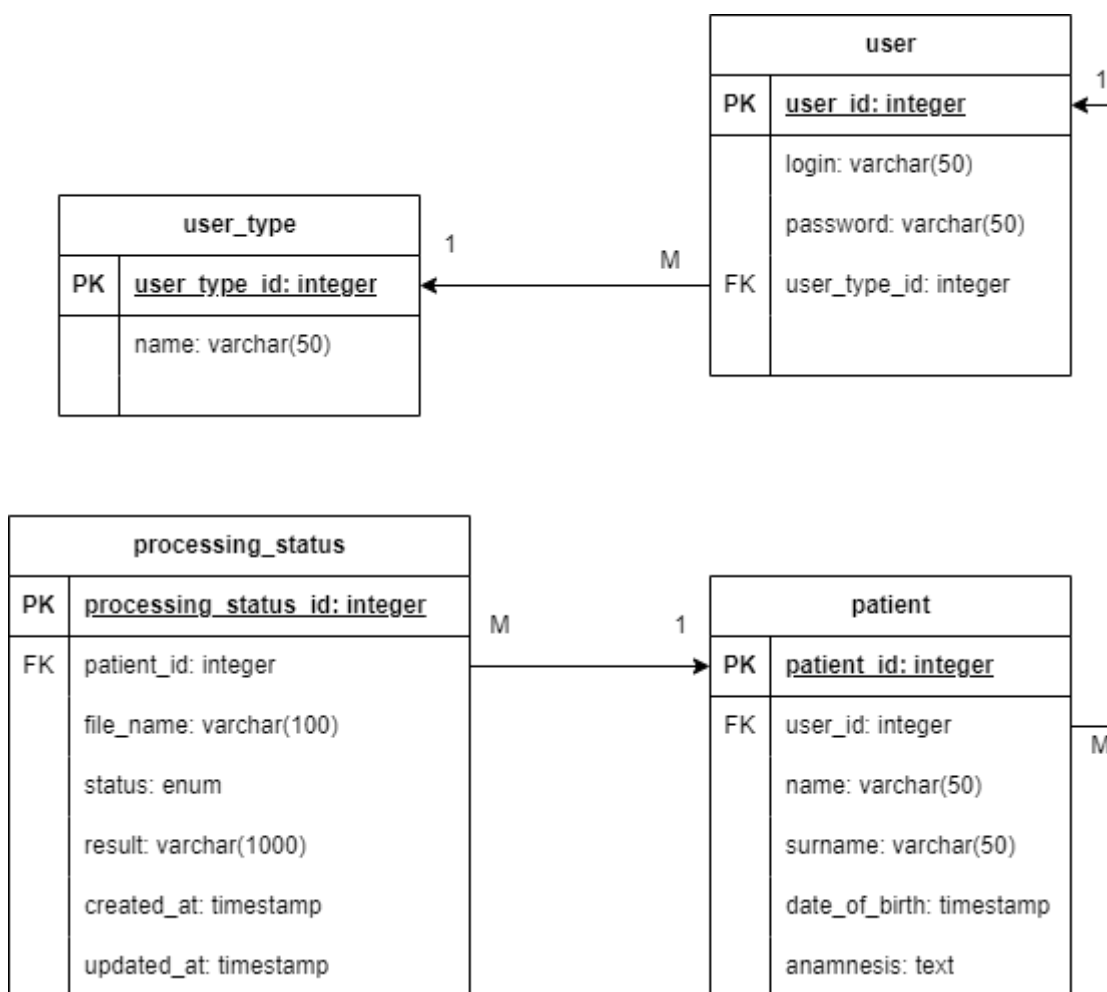


Рисунок 4.3 – ER-діаграма системи

4.4 Процес обробки знімків

Для виконання аналізу знімків комп'ютерної томографії було створено 2 фонових процеси, які запускаються при старті Java сервісу. Перший процес

перевіряє наявність зображень для обробки та запускає скрипт обробки якщо знайшов такі зображення. Другий процес перевіряє чи були оброблені зображення, для яких запускався скрипт та оновляє статус у базі даних, записуючи туди результат. На рисунку 4.4 зображено діаграму послідовності обробки та аналізу зображення цими процесами.

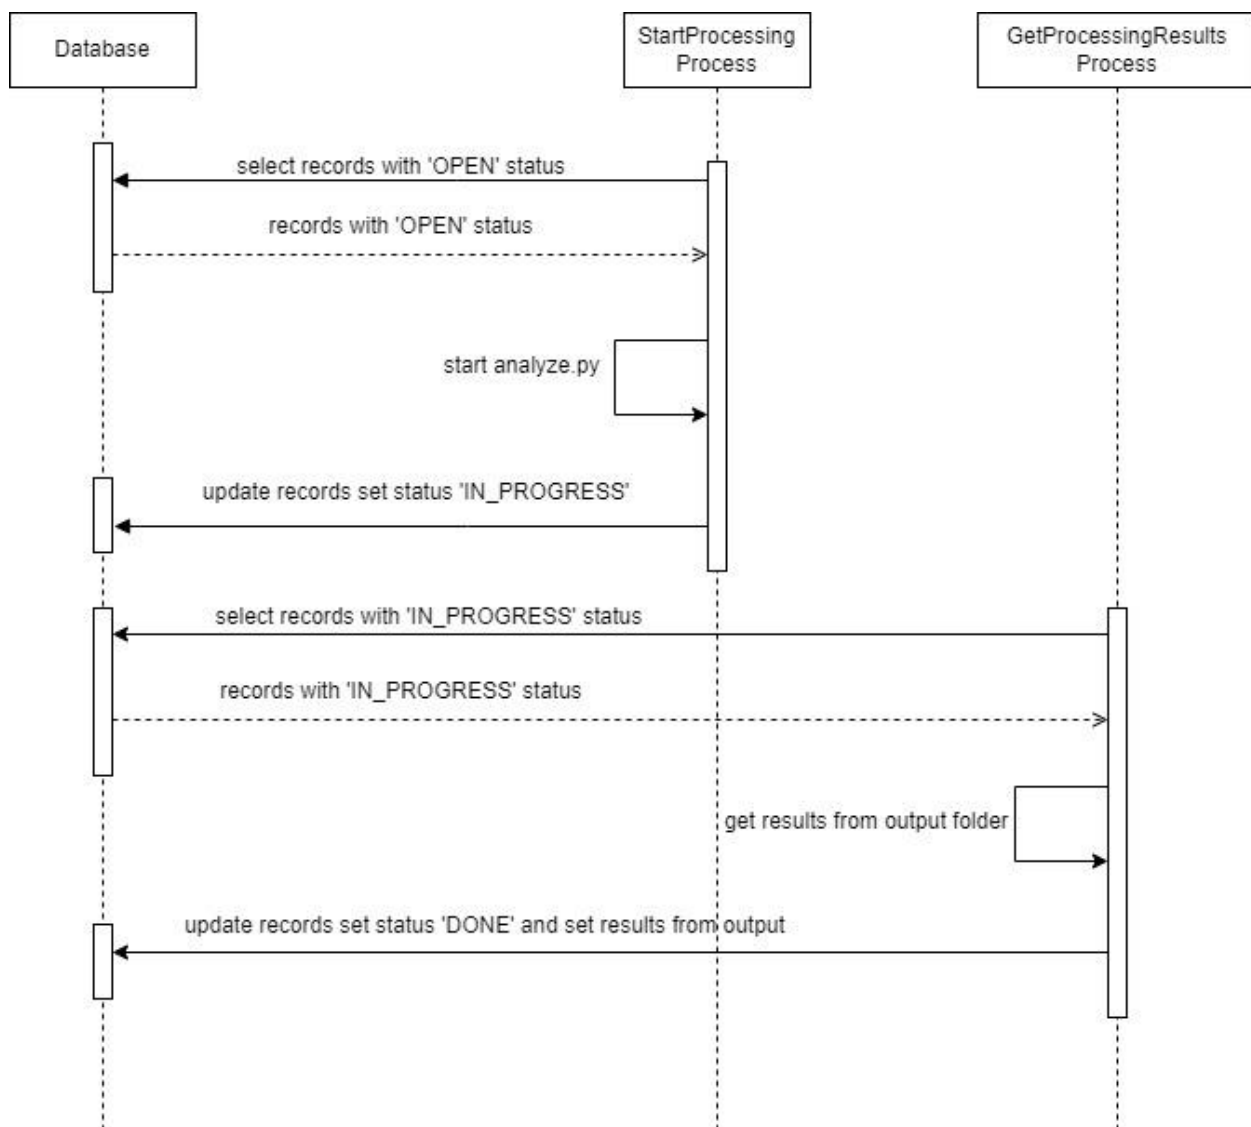


Рисунок 4.4 – Діаграма послідовності обробки зображення

При завантаженні нового знімка комп'ютерної томографії йому присвоюється унікальне ім'я файлу, а сам файл зберігається у директорії input. Після цього у таблиці processing_status створюється запис, який зберігає ім'я цього файлу та якому при створенні встановлюється статус «OPEN». Цей статус означає

що зображення було додано у файлову систему та очікує обробки. Далі у роботу вступають фонові процеси `StartProcessing` та `GetProcessingResults`. Кожні 10 секунд вони сканують таблицю `processing_status` на наявність записів із певним статусом.

`StartProcessing` вибирає із таблиці записи із статусом «OPEN» та запускає для них скрипт `analyze.py`, який використовує вже навчену модель для аналізу переданих знімків. Поки скрипт обробляє зображення `StartProcessing` процес оновлює статус відповідних записів у таблиці, змінюючи його на «IN_PROGRESS», що означає що обробку знімку було розпочато, проте вона ще не завершилась. Як тільки скрипт завершить свою роботу він створить файл із результатами `[ім'я_файлу]_analyzed` у директорії `output`. Таким чином маючи ім'я файлу, який було завантажено для обробки, програма має змогу за цим ім'ям знайти результати обробки у відповідній директорії.

`GetProcessingResults` вибирає із таблиці записи зі статусом «IN_PROGRESS» та перевіряє чи наявні для них результати обробки у директорії `output`. У разі якщо файл із результатом дійсно є, то процес його відкриває та вилучає контент. Він представлений у вигляді пар «ключ: значення», де ключем є тип кровотечі, а значенням – передбачення щодо наявності цього типу кровотечі на проаналізованому знімку у відсотковому вираженні, отримане у результаті опрацювання скриптом `analyze.py`. Ці результати конвертуються у JSON-рядок. У фіналі відповідний запис у таблиці `processing_status` оновлюється – для нього виставляється статус «DONE», який означає що обробку було успішно завершено, та у поле `result` записується отриманий на попередньому кроці JSON-рядок із результатом. Тепер щоб отримати результати аналізу знімку достатньо обрати із бази даних відповідний запис за ім'ям файлу та за значенням статусу «DONE». У випадку, коли відповідний файл результатів аналізу не було знайдено після першої спроби, виконується ще 3 спроби. Якщо і після них не було знайдено файл запису виставляється статус «ERROR».

4.5 Створення UI

Було розроблено графічний інтерфейс сторінки пацієнта, який зображено на рисунку 4.5.




Рисунок 4.5 – Графічний інтерфейс сторінки пацієнта

Ця сторінка відповідає функціональним вимогам:

- містить кнопку додання нового знімку;
- містить кнопки видалення старих знімків;
- містить результат аналізу знімків;
- містить інформацію про пацієнта;
- містить кнопку видалення пацієнта.

Далі було створено графічний інтерфейс для сторінки перегляду усіх пацієнтів, який зображено на рисунку 4.6.

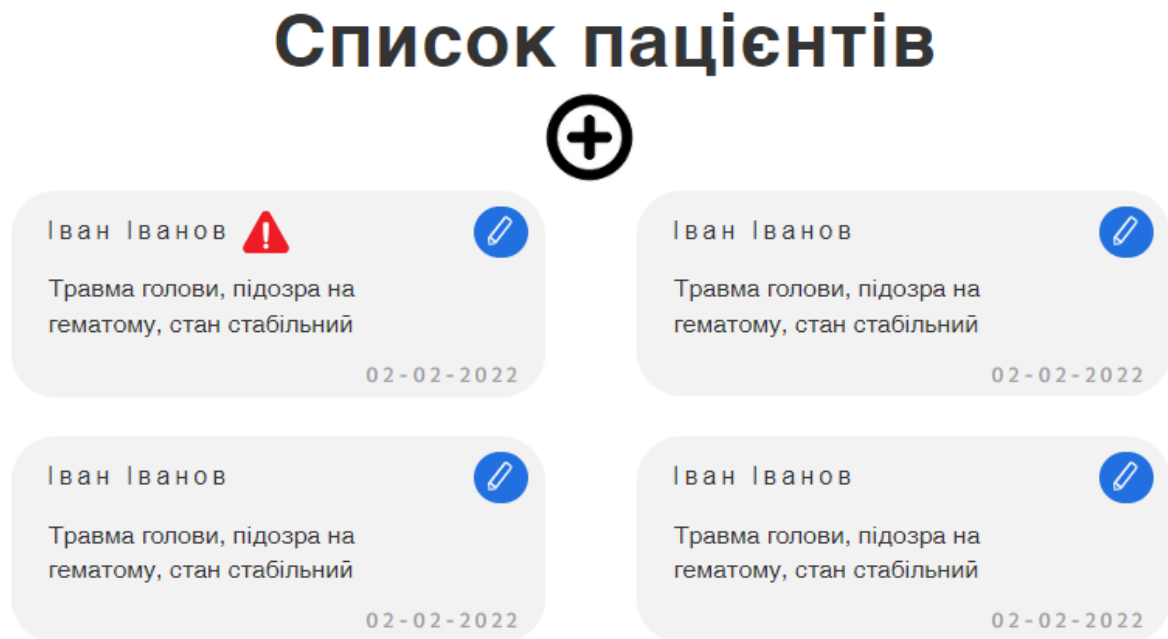


Рисунок 4.6 – Графічний інтерфейс сторінки пацієнтів

Дана сторінка відповідає функціональним вимогам:

- містить перелік пацієнтів;
- інформація про пацієнта включає його ім'я, дату звернення, стислий анамнез, іконку попередження у разі якщо було виконано аналіз знімку і знайдено кровотечу;
- кнопку додавання пацієнтів
- кнопку видалення пацієнтів.

Далі було створено графічний інтерфейс для сторінки додання пацієнтів, який зображений на рисунку 4.7.

Додання нового пацієнта

The image shows a user interface for adding a new patient. At the top, there is a light blue header with the text 'Текст текст' and a plus sign icon. Below this, the form is organized into several sections:

- Ім'я** and **Прізвище**: Two text input fields.
- Ел. пошта** and **Дата народження**: Two text input fields. The date field includes a calendar icon.
- Чи були раніше інсульти** and **Чи були раніше травми голови**: Two sections, each with radio buttons for 'Ні' and 'Так'.
- Анамнез та історія хвороби**: A large text area for notes.
- Додати**: A large, dark green button with a white camera icon, used for uploading images.

Рисунок 4.7 – Графічний інтерфейс для сторінки додання пацієнта

Ця сторінка відповідає функціональним вимогам:

- містить необхідні для вводу поля;
- містить кнопку для завантаження знімків комп'ютерної томографії.

ВИСНОВКИ

У цій роботі було проаналізовано наявні рішення для виявлення внутрішньочерепної кровотечі та її типів шляхом нейронних мереж, доступні алгоритми для класифікації зображень та розглянуто використання двогілкового глибокого виділення ознак і класифікаторів машинного навчання.

Запропонований інструмент класифікації ефективно працює як у вигляді окремої мережі ResNeXt50_32x4D, так і у вигляді архітектури з подвійною гілкою. Існує збалансованість результатів, отриманих автономними мережами з однією гілкою, здебільшого незначними відмінностями. Це означає, що обидва представлення вхідних даних майже однаково сприяють правильній класифікації кровотечі. Внутрішньошлуночковий тип є найкраще класифікованим і характеризується точністю та балами F1, що перевищують 95% в обох гілках. Найгірші показники можна спостерігати у визначенні епідурального типу (точність нижче 70%, оцінка F1 нижче 60%).

Випадковий ліс (RF) має невелику перевагу над SVM, за винятком визначення епідурального типу. Подвійна гілка архітектури покращує класифікацію в кожному типі. Підвищення точності та оцінки F1 відрізняються між підтипами — від близько 1–3% у до понад 10%.

Результати виправдовують ідею пошуку релевантних ознак та їх об'єднання для класифікації за допомогою випадкового лісу (RF). Система забезпечує найвищу ефективність виявлення внутрішньошлуночкових і внутрішньопаренхіматозних крововиливів серед проаналізованих систем.

Запропонований підхід приносить практичну користь та може бути застосований для діагностики внутрішньочерепних крововиливів, що дасть змогу швидше та ефективніше надавати допомогу пацієнтам.

Кваліфікаційна робота пройшла апробацію на науково-технічній конференції 27-й Міжнародний молодіжний форум «Радіоелектроніка та молодь у XXI столітті».

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Carlsson, M., Wilsgaard, T., Johnsen, S. H., Johnsen, L.-H., Løchen, M.-L., Njølstad, I., Mathiesen, E. B., Long-Term Survival, Causes of Death, and Trends in 5-Year Mortality After Intracerebral Hemorrhage: The Tromsø Study, *Stroke* (2021). doi: 10.1161/strokeaha.120.032750
2. van Gijn, J., Rinkel, G. J. E., Subarachnoid haemorrhage: diagnosis, causes and management, *Brain* (2001), 124(2), 249–278. doi: 10.1093/brain/124.2.249
3. Оболонки головного і спинного мозку. Спинномозкова рідина, StudFiles [Електронний ресурс]. – 2016. – Режим доступу до ресурсу: <https://studfile.net/preview/5343207/page:3/>
4. Kuohn, L. R., Leasure, A. C., Acosta, J. N., Vanent, K., Murthy, S. B., Kamel, H., Matouk, C. C., Sansing, L. H., Falcone, G. J., Sheth, K. N., Cause of death in spontaneous intracerebral hemorrhage survivors, *Neurology* (2020). doi: 10.1212/wnl.00000000000010736
5. Dandu R. V., Managing DICOM images: Tips and tricks for the radiologist, *Thieme* (2012). doi: 10.4103/0971-3026.95396
6. Kuo, W., Häne, C., Mukherjee, P., Malik, J., Yuh, E. L., Expert-level detection of acute intracranial hemorrhage on head computed tomography using deep learning, *Proceedings of the National Academy of Sciences* (2019). doi: 10.1073/pnas.1908021116
7. Nhan T. Nguyen, Dat Q. Tran, Nghia T. Nguyen, Ha Q. Nguyen, A CNN-LSTM Architecture for Detection of Intracranial Hemorrhage on CT scans, *Medrxiv* (2020). doi: 10.1101/2020.04.17.20070193
8. Arbabshirani, M. R., Fornwalt, B. K., Mongelluzzo, G. J., Suever, J. D., Geise, B. D., Patel, A. A., Moore, G. J., Advanced machine learning in action: identification of intracranial hemorrhage on computed tomography scans of the head with clinical workflow integration, *npj Digital Medicine* (2018). doi: 10.1038/s41746-017-0015-z
9. G. Danilov, K. Kotik, A. Negreeva, T. Tsukanova, M. Shifrin, N. Zakharova, A. Batalov, I. Pronin, A. Potapov, Classification of Intracranial Hemorrhage Subtypes Using Deep Learning on CT Scans, *IOS Press, Volume 272* (2019). doi: 10.3233/SHTI200572

10. Chang, P. D., Kuoy, E., Grinband, J., Weinberg, B. D., Thompson, M., Homo, R., Chen, J., Abcede, H., Shafie, M., Sugrue, L., Filippi, C. G., Su, M. Y., Yu, W., Hess, C., Chow, D., Hybrid 3D/2D Convolutional Neural Network for Hemorrhage Evaluation on Head CT, *American Journal of Neuroradiology* (2018), 1609–1616. doi: 10.3174/ajnr.a5742

11. Ye, H., Gao, F., Yin, Y., Guo, D., Zhao, P., Lu, Y., Wang, X., Bai, J., Cao, K., Song, Q., Zhang, H., Chen, W., Guo, X., Xia, J., Precise diagnosis of intracranial hemorrhage and subtypes using a three-dimensional joint convolutional and recurrent neural network, *European Radiology* (2019), 6191–6201. doi: 10.1007/s00330-019-06163-2

12. Burduja, M., Ionescu, R. T., Verga, N., Accurate and Efficient Intracranial Hemorrhage Detection and Subtype Classification in 3D CT Scans with Convolutional and Long Short-Term Memory Neural Networks, *Sensors* (2020), 5611. doi: 10.3390/s20195611

13. Cho, J., Park, K.-S., Karki, M., Lee, E., Ko, S., Kim, J. K., Lee, D., Choe, J., Son, J., Kim, M., Lee, S., Lee, J., Yoon, C., Park, S., Improving Sensitivity on Identification and Delineation of Intracranial Hemorrhage Lesion Using Cascaded Deep Learning Models, *Journal of Digital Imaging* (2019), 450–461. doi: 10.1007/s10278-018-00172-1

14. Iqbal, S., N. Qureshi, A., Li, J., Mahmood, T., On the Analyses of Medical Images Using Traditional Machine Learning Techniques and Convolutional Neural Networks, *Archives of Computational Methods in Engineering* (2023). doi: 10.1007/s11831-023-09899-9

15. Shafiq, M., Gu, Z., Deep Residual Learning for Image Recognition: A Survey, *Applied Sciences* (2022). 8972. doi: 10.3390/app12188972

16. RSNA Intracranial Hemorrhage Detection competition [Электронный ресурс]. – 2019. – Режим доступа до ресурсу: <https://www.kaggle.com/competitions/rsna-intracranial-hemorrhage-detection/overview>

17. Smelyakov K., Honchar Y., Bohomolov O., Chupryna A., Machine Learning Models Efficiency Analysis for Image Classification Problem, CEUR-WS, Vol-3171 (2022), 942 – 959

18. Smelyakov K., Antonenko D., Development of a recommendation system for medical diagnosis of hemorrhage based on brain tomography images, 27th International Youth Forum Radio electronics and youth in the 21st century, May 10–12, 2023, Kharkiv, Ukraine.