

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ імені ІГОРЯ СІКОРСЬКОГО»
(КПІ ім. Ігоря Сікорського)**

**ФАКУЛЬТЕТ БІОМЕДИЧНОЇ ІНЖЕНЕРІЇ
кафедра БІОМЕДИЧНОЇ КІБЕРНЕТИКИ**

«До захисту допущено»

В.о. завідувач кафедри БМК

_____ Євген НАСТЕНКО

“ ” _____ 2023р.

**Дипломна робота
на здобуття ступеня бакалавра
за освітньо-професійною програмою
«Комп'ютерні технології в біології та медицині»
спеціальності 122 «Комп'ютерні науки»**

**на тему: Програмний застосунок для сегментації судин сітківки ока з
використанням згорткової нейронної мережі**

Виконав: студент IV курсу, групи БС-91

НАЗАРАГА ЯРОСЛАВ РУСЛАНОВИЧ

(прізвище, ім'я, по батькові)



(підпис)

Керівник: доцент каф. біомедичної кібернетики (БМК)

доц., к.п.н., Добровська Людмила Миколаївна

(посада, науковий ступінь, вчене звання, прізвище, ім'я, по батькові)

(підпис)

Рецензент: проф. каф. біомедичної інженерії, д.т.н. проф.

Лебедев Олексій Володимирович

(підпис)

**Засвідчую, що у цій дипломній роботі немає
запозичень з праць інших авторів без
відповідних посилань.**

Студент



(підпис)

Київ – 2023 року

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Факультет біомедичної інженерії
Кафедра біомедичної кібернетики

Рівень вищої освіти – перший (бакалаврський)

Спеціальність – 122 «Комп'ютерні науки»

Освітньо-професійна програма «Комп'ютерні технології в біології та медицині»

ЗАТВЕРДЖУЮ

В.о. завідувач кафедри БМК

_____ Євген НАСТЕНКО

« 30 » травня 2023 р.

ЗАВДАННЯ
на дипломну роботу студенту

НАЗАРАГА ЯРОСЛАВ РУСЛАНОВИЧ

(прізвище, ім'я, по батькові)

1. Тема роботи Програмний застосунок для сегментації судин
сітківки ока з використанням згорткової нейронної мережі

Керівник роботи

Добровська Людмила Миколаївна, доцент кафедри БМК

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від «31 » травня 2023 р. №2106-с

2. Термін подання студентом роботи **06-08 червня 2023р.**

3. Вихідні дані до роботи *архів зображень судин сітківки ока.*

4. Зміст роботи *анотації (на двох мовах), вступ, огляд літературних джерел, теоретична частина (основні поняття, методи обробки даних), практична частина, висновки, список використаних джерел.*

5. Перелік ілюстративного матеріалу: презентація (12 слайдів, 12 рисунків, 1 таблиця).

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв

7. Дата видачі завдання **30 травня 2023 року.**

Календарний план

№ з/п	Назва етапів виконання дипломної роботи	Термін виконання етапів роботи	Примітка
1	Отримати завдання за темою ДР на практику	До 15.02.2023р.	виконано
2	Переддипломна практика	За графіком	виконано
3	Виконання розділів ДР (Вступ, аналітичний огляд літературних джерел, теоретична частина)	До кінця практики	виконано
4	Виконання розділів ДР (практична частина, загальні висновки, список джерел)	Не пізніше 1 тижня до засідання каф-ри	виконано
5	Перевірка ДР науковим керівником	Не пізніше 1 тижня до засідання каф-ри	виконано
6	Подання в електронному вигляді ДР та анотації до неї на перевірку нормоконтролера та плагіат (UNICHECK).	---- « -----	виконано
7	Надання документів на засідання кафедри	За день до засідання	виконано
8	Предзахист ДР та допуск до захисту дисертації	Згідно плану каф.	виконано
9	Подання ДР рецензенту. Отримання рецензії.	До подання пакету документів до ЕК	виконано
10	Подання пакету документів по ДР та супровідних до неї документів до захисту в ЕК ¹	За 5 днів до дати захисту ДР за графіком	виконано
11	Захист ДР в ЕК		

Студент



(підпис)

Ярослав НАЗАРАГА

(ім'я, ПРІЗВИЩЕ)

Керівник ДР

(підпис)

Людмила ДОБРОВСЬКА

(ім'я, ПРІЗВИЩЕ)

Нормоконтролер

(підпис)

Галина КОРНІЄНКО

(ім'я, ПРІЗВИЩЕ)

АНОТАЦІЯ

Дипломна робота за темою «Програмний застосунок для сегментації судин сітківки ока з використанням згорткової нейронної мережі» виконана студентом кафедри біомедичної кібернетики ФБМІ Назарагою Ярославом Руслановичем зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині» та складається зі: вступу; 3 розділів (огляд літературних джерел, теоретична частина, практична частина), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 57 джерел. Загальний обсяг роботи 67 сторінок.

Актуальність теми. Актуальність теми обумовлена тим, що у сучасному інформатизованому світі кількість офтальмологічних захворювань стрімко зростає, тому своєчасне діагностування проблем судин сітківки ока та розробка програмного застосунку на основі ефективних методів сегментації для подальшого використання отриманих даних в цілях діагностики є надзвичайно важливими.

Мета і завдання роботи

Мета дипломної роботи полягає у розробці програмного застосунку для сегментації зображень судин сітківки ока за допомогою глибокого навчання та умовного випадкового поля. Це дозволить отримати якісну та точну сегментацію, яка є важливою складовою у діагностуванні захворювань ока та плануванні лікування.

Досягнення мети передбачає виконання наступних **завдань**:

- 1) ознайомлення з існуючими методами сегментації медичних зображень;
- 2) вивчення методів глибокого навчання та умовного випадкового поля і застосування їх для сегментації зображень судин сітківки;
- 3) оцінювання основних характеристик програмного застосунку та визначення найбільш ефективного варіанту його реалізації;
- 4) розробка моделі сегментації на основі методу умовного випадкового поля;

5) розробка програмного застосунку на основі обраних методів для сегментації зображень сітківки ока;

6) навчання нейронної мережі та проведення сегментації з використанням загальнодоступного датасету зображень;

7) порівняння створеного методу з наявними методами сегментації зображень судин сітківки ока та з експертними діагнозами; аналіз отриманих результатів.

Використані методи. Для досягнення мети і вирішення поставлених задач застосовуються теорії математичного аналізу, теорії статистики, методи глибокого навчання. Зокрема, використано методи глибокого навчання (для створення та навчання згорткової нейронної мережі на базі архітектур U-net), методи розробки програмного забезпечення (для реалізації програмного продукту); методи комп'ютерної графіки (для аугментації та роботи з зображеннями); матричні методи (для роботи з цифровими зображеннями); методи оптимізації (для оптимізації параметрів нейромережі); методи умовного випадкового поля (для створення моделі сегментації).

Отримані результати. Під час виконання роботи вирішено всі поставлені завдання і, таким чином, досягнуто мету – розроблено програмний застосунок для сегментації зображень судин сітківки ока з використанням згорткової нейронної мережі.

Ключові слова. сегментація, сітківка ока, глибоке навчання, CNN, нейронна мережа.

Бібліографічний опис ДР

Назарага Я. Р. Програмний застосунок для сегментації судин сітківки ока з використанням згорткової нейронної мережі : дипломна роб. бакалавра : 122 Комп'ютерні науки / Назарага Ярослав Русланович. – Київ, 2023. – 70 с.

ABSTRACT

Bachelor's thesis on the topic "Software application for retinal vessel segmentation using convolutional neural network" was completed by Yaroslav Nazaraha, a student of the Department of Biomedical Cybernetics at the Faculty of Biomedical Engineering and Medical Informatics. The thesis was carried out within the educational-professional program "Computer Technologies in Biology and Medicine" and consists of the following parts: introduction; 3 chapters (literature review, theoretical part, practical part); conclusions for each of these chapters; general conclusions; a list of references, which includes 57 sources. The total length of the thesis is 67 pages.

Relevance of the topic.

The relevance of the topic is determined by the rapid increase in the number of ophthalmological diseases in today's computerized world. Therefore, timely diagnosis of retinal vessel problems and the development of a software application based on effective segmentation methods for further use of the obtained data in diagnostics are of utmost importance.

Objective and tasks of the research.

The objective of the thesis is to develop a software application for retinal vessel segmentation using deep learning and conditional random fields. This will allow obtaining high-quality and accurate segmentation, which is an essential component in diagnosing eye diseases and planning treatments.

To achieve the objective, the following tasks were accomplished:

- 1) Familiarization with existing methods of medical image segmentation.
- 2) Study of deep learning and conditional random fields methods and their application for retinal vessel segmentation.
- 3) Evaluation of the main characteristics of the software application and determination of the most effective implementation approach.
- 4) Development of a segmentation model based on the conditional random fields method.

5) Development of a software application for retinal vessel segmentation based on the selected methods.

6) Training of a neural network and performing segmentation using a publicly available dataset of images.

7) Comparison of the developed method with existing retinal vessel segmentation methods and expert diagnoses; analysis of the obtained results.

Methods used. The research utilized mathematical analysis, statistical theory, deep learning methods, computer graphics techniques, matrix methods, optimization methods, and conditional random fields for retinal vessel segmentation.

Results Obtained. All set tasks were successfully accomplished, and the objective was achieved – a software application for retinal vessel segmentation using a convolutional neural network was developed.

Keywords. segmentation, retinal vessel, deep learning, CNN, neural network.

ЗМІСТ

ВСТУП.....	10
РОЗДІЛ 1 ОГЛЯД ЛІТЕРАТУРНИХ ДЖЕРЕЛ.....	14
1.1. Поняття сегментації та її особливості	14
1.2. Традиційні методи сегментації та їх класифікація	15
1.3. Розвиток методів глибокого навчання для сегментації	18
1.4. Приклади застосування методів розв’язання задач сегментації зображень судин сітківки ока	21
Висновки до розділу 1.....	22
РОЗДІЛ 2 ТЕОРЕТИЧНА ЧАСТИНА.....	23
2.1. Сучасні методи глибокого навчання для сегментації зображень	23
2.2. Умовні випадкові поля	27
2.3. Методи аугментації.....	29
2.4. Критерії якості сегментації зображень	30
Висновки до розділу 2.....	35
РОЗДІЛ 3 ПРАКТИЧНА ЧАСТИНА	36
3.1. Архітектура U-NET	36
3.2. Інструменти для реалізації програмного продукту	38
3.3. Структура програмного продукту	39
3.4. Вхідні зображення	40
3.5. Аугментація у розробленому ПЗ.....	41
3.6. Тренування моделі.....	43
3.7. Опис інтерфейсу користувача.....	46
3.8. Застосування програмного продукту	53
3.9. Порівняння застосованого методу з аналогами.....	54
3.10. Системні вимоги	56
3.11. Функціонально-вартісний аналіз програмного застосунку	

ПРИЗНАЧЕНОГО ДЛЯ СЕГМЕНТАЦІЇ СУДИН СІТКІВКИ.....	57
ВАРТІСТЬ ВИТРАТ ДЛЯ ЦЬОГО ВАРІАНТА (В УМОВАХ ВОЄННОГО СТАНУ) СТАНОВИТЬ (ДЕТАЛЬНІ РОЗРАХУНКИ ПОДАНО У ЗВІТІ З ПЕРЕДДИПЛОМНОЇ ПРАКТИКИ):	58
Висновок до розділу 3.....	59
ЗАГАЛЬНІ ВИСНОВКИ.....	61
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	64

ВСТУП

Значна кількість інформації про оточення людини надходить через зорову систему, тому вона є важливою частиною світосприйняття. Одним із найвагоміших елементів у органі зору є сітківка очей, яка відповідає за формування зображення та передачу нервових імпульсів у головний мозок. Наразі своєчасне діагностування патологій сітківки залишається істотною умовою успішної боротьби з хворобами очей. Важливе значення для постановки діагнозу при різних офтальмологічних захворюваннях відіграє дослідження, моніторинг та оцінка судин сітківки ока.

Ідентифікація певних об'єктів-патологій на зображеннях зводиться до розв'язання задач сегментації. Прикладом таких задач є сегментація судин сітківки, які є важливим етапом в аналізі медичних зображень для діагностики та моніторингу захворювань ока, таких як діабетична ретинопатія, глаукома та інші. Варто зауважити, що мануальна сегментація судин сітківки (у яких процесом ідентифікації відхилень займається безпосередньо людина) є трудомісткою та виснажливою. На сьогодні для аналізу медичних зображень застосовуються автоматичні методи - методи машинного навчання з використанням нейронних мереж. Автоматичні методи сегментації мають низку переваг перед ручними, зокрема вони характеризуються кращою точністю та більшою швидкістю.

Актуальність роботи. Актуальність роботи обумовлена тим, що у сучасному інформатизованому світі кількість офтальмологічних захворювань стрімко зростає, тому своєчасне діагностування проблем судин сітківки ока та розробка програмного застосунку на основі ефективних методів сегментації для подальшого використання отриманих даних в цілях діагностики є надзвичайно важливими.

Мета і завдання роботи

Мета дипломної роботи полягає у розробці програмного застосунку для сегментації зображень судин сітківки ока за допомогою глибокого навчання та

умовного випадкового поля. Це дозволить отримати якісну та точну сегментацію, яка є важливою складовою у діагностуванні захворювань ока та плануванні лікування.

Досягнення мети передбачає виконання наступних **завдань**:

- 1) ознайомлення з існуючими методами сегментації медичних зображень;
- 2) вивчення методів глибокого навчання та умовного випадкового поля і застосування їх для сегментації зображень судин сітківки;
- 3) оцінювання основних характеристик програмного застосунку та визначення найбільш ефективного варіанту його реалізації;
- 4) розробка моделі сегментації на основі методу умовного випадкового поля;
- 5) розробка програмного застосунку на основі обраних методів для сегментації зображень сітківки ока;
- 6) навчання нейронної мережі та проведення сегментації з використанням загальнодоступного датасету зображень;
- 7) порівняння створеного методу з наявними методами сегментації зображень судин сітківки ока та з експертними діагнозами; аналіз отриманих результатів.

Використані методи. Для досягнення мети і вирішення поставлених задач застосовуються теорії математичного аналізу, теорії статистики, методи глибокого навчання. Зокрема, використано методи глибокого навчання (для створення та навчання згорткової нейронної мережі на базі архітектур U-net), методи розробки програмного забезпечення (для реалізації програмного продукту); методи комп'ютерної графіки (для аугментації та роботи з зображеннями); матричні методи (для роботи з цифровими зображеннями); методи оптимізації (для оптимізації параметрів нейромережі); методи умовного випадкового поля (для створення моделі сегментації).

Отримані результати. Під час виконання роботи вирішено всі поставлені завдання і, таким чином, досягнуто мету – розроблено програмний застосунок для сегментації зображень судин сітківки ока з використанням згорткової нейронної

мережі.

Практичне значення результатів. Робота може бути корисною для медичної спільноти, дослідників у галузі комп'ютерного зору, а також може застосовуватися у майбутньому для розробки нових методів діагностики та автоматизації діагностики захворювань ока.

У першому розділі роботи розглянуто основні поняття, проведений огляд традиційних методів сегментації судин сітківки та розглянуто їх класифікацію, описано основні етапи розвитку методів глибокого навчання, а також розглянуто приклади застосування методів розв'язання задач сегментації зображень судин сітківки ока, реалізованими за останні десятиліття.

У другому розділі розглянуто сучасні алгоритми глибокого навчання та метод умовного випадкового поля, які можна використати для сегментації зображень: Також здійснено порівняння нейромережових підходів, описано найпоширеніші методи аугментації зображень та критерії якості сегментації зображень.

У третьому розділі описано структуру розробленого програмного продукту для сегментації зображень судин сітківки, подані основні етапи роботи методу з використанням глибокого навчання, наведені результати сегментації, здійснено порівняння з аналогічними методами та експертними діагнозами, подано оцінку основних характеристик програмного продукту та визначено найефективніший варіант реалізації його функцій.

Структура роботи. Дипломна робота за темою «Програмний застосунок для сегментації судин сітківки ока з використанням згорткової нейронної мережі» виконана студентом кафедри біомедичної кібернетики ФБМІ Назарагою Ярославом Руслановичем зі спеціальності 122 «Комп'ютерні науки» за освітньо-професійною програмою «Комп'ютерні технології в біології та медицині», побудована за класичним типом та викладена на 70 сторінках машинописного тексту. Вона складається з: вступу; 3 розділів (огляд літературних джерел, теоретична частина, практична частина), висновків до кожного з цих розділів; загальних висновків; списку використаних джерел, який налічує 57 джерел. У

роботі представлено 26 рисунків і 2 таблиці.

РОЗДІЛ 1

ОГЛЯД ЛІТЕРАТУРНИХ ДЖЕРЕЛ

1.1. Поняття сегментації та її особливості

На сучасному етапі суспільного розвитку інформаційні технології (ІТ) проникли в усі сфери людської діяльності. Усе більшого значення набуває використання ІТ у сфері охорони здоров'я, завдяки чому медицині стали притаманні нові ознаки. Так, сьогодні складні дослідження в галузі медицини відбуваються за допомогою застосування обчислювальної техніки та спеціального програмного забезпечення, при цьому кількість різноманітних комп'ютерних алгоритмів та математичних методів невпинно зростає. Це пов'язано з необхідністю обробки, аналізу та систематизації нової інформації, отриманої під час різноманітних медичних досліджень.

Одним із напрямків, який отримав розвиток завдяки прискореному темпу удосконалення засобів комп'ютерної техніки, стала розробка теоретичних засад і практична реалізація систем для розпізнавання та обробки зображень.

Важливу роль у задачах обробки медичних зображень, поряд із реєстрацією, класифікацією та локалізацією, відіграє сегментація.

Загалом, під сегментацією розуміють процес (результат) розділення цілого на окремі частини (сегменти). У випадку роботи з цифровими зображеннями, сегментація - це процес розділення цифрового знімка на кілька сегментів (у комп'ютерних термінах - множини пікселів або суперпікселів). При цьому зображення спрощується або змінюється його представлення з метою полегшення його аналізу [1]. У більшості випадків сегментація зображень використовується для виділення певних об'єктів та контурів на зображеннях.

Для встановлення правильного діагнозу з метою подальшого лікування використовуються різноманітні біомедичні зображення, такі як рентгенограми, ультразвукові зображення, зображення цифрової мікроскопії, зображення

магнітно-резонансної томографії тощо.

У загальному, для довільних зображень не існує універсальних методів сегментації, а використовуються спеціалізовані методи, які для певного класу задач є найпоширенішими.

У роботі Харлік Р. та Шапіто Л [2] виділили характеристики, властиві областям, що отримані після сегментації:

- сегменти зображення повинні бути однорідними щодо певної характеристики, наприклад, яскравості або текстур;
- середина області повинна бути суцільною та без багатьох “дірок”;
- сусідні сегменти повинні один від одного суттєво відрізнятись відносно обраної характеристики;
- межі кожної області повинні бути неперервними, простими та просторово точними.

1.2. Традиційні методи сегментації та їх класифікація

Відомо кілька підходів до класифікації алгоритмів сегментації: Фу [3], Пала [4], Скарбека і Кошана [5], Лючеса та Мітра [6]. Це пов'язано з тим, що наразі не існує повної та всеосяжної класифікації методів сегментації зображень, оскільки кожна із запропонованих так чи інакше не враховує деякі алгоритми, наприклад, авторські методики, що є не дуже відомими і поширеними. Існуючі схеми класифікації методів сегментації базуються на таких критеріях: властивості областей, границь областей, точок, апріорні знання про об'єкти тощо. До інших критеріїв поділу алгоритмів сегментації відносяться наступні: тип зображення (бінарні, напівтонові, кольорові), вид обробки зображень під час сегментації (паралельна або послідовна) [7].

Але описані характеристики не завжди є однозначними. Деякі види сегментації (порогова, наприклад) можуть відбуватись як в послідовному, так і в паралельному режимах, а також працювати як з бінарними, так і напівтоновими зображеннями. Для уникнення неоднозначності в класифікації наявних алгоритмів

сегментації, у роботі [8] виділено наступні критерії (рис. 1.1.):

- на основі властивостей точок;
- на основі властивостей взаємозв'язків між точками;
- на основі властивостей областей;
- на основі властивостей текстури;
- на основі підкреслення границь.



Рисунок 1.1 - Класифікація алгоритмів сегментації

Алгоритми сегментації на основі властивостей точок. Прийняття рішення про належність точки до однорідної області відбувається на основі аналізу характеристик самої точки (яскравість, характеристики кольорової компоненти). Цей тип алгоритмів зазвичай використовувати для зображень, у яких наперед відома інформація про характеристики однорідних областей. Серед переваг таких алгоритмів є швидкодія, оскільки рішення про належність точки до однорідної області приймається окремо для кожної точки. Серед недоліків - складність визначення (розрахунку) попередньої інформації на зображеннях, що містять багато однотипних областей зі схожими характеристиками[8].

Алгоритми сегментації на основі властивостей взаємозв'язків між

точками. Прийняття рішення про належність точки до певної однорідної області відбувається після аналізу рівня взаємозв'язків між сусідніми точками. Такі алгоритми використовують для тих зображень, у яких важко визначити характеристики однорідних сегментів. Перевагою цього класу алгоритмів сегментації є точність, бо рішення про належність точки до деякої однорідної області приймається, виходячи з рівня взаємозв'язків, що отримується на базі різних характеристик. Серед недоліків такого класу алгоритмів - складність.

Алгоритми сегментації на основі властивостей областей. Прийняття рішення про приналежність точки до однорідної області відбувається шляхом аналізу характеристик деякої групи точок (положення, яскравість, показники кольорової компоненти). Такий тип алгоритмів зазвичай використовують для таких зображень, у яких однорідні області відрізняються одна від одної суттєво. Серед переваг цих алгоритмів сегментації - універсальність та автоматизація. До недоліків таких алгоритмів відносять незадовільні результати сегментації для зображень із великою кількістю подібних за характеристиками однорідних областей.

Алгоритми сегментації на основі властивостей текстури. Прийняття рішення про належність точки до області відбувається на основі наявності подібної текстурної ознаки для розглянутої точки. Такий тип алгоритмів в основному використовують для зображень, у яких є області, які повторюються.

Процес текстурної сегментації [9, 10] складається з 3 кроків:

- 1) формування з початкового зображення набору характеристик (унікальних ознак), які утворюють багатовимірний простір ознак зображення, у якому кожен вектор представляє особливості конкретної текстури;
- 2) класифікація, тобто співвіднесення кожної точки зображення до певного класу, ґрунтуючись на оцінці відповідного цієї точці вектора ознак із визначеного простору ознак;
- 3) сегментація вихідного зображення на основі класифікації.

Перевагою такого класу алгоритмів сегментації є визначення областей з однаковою текстурою, до недоліків можна віднести складність алгоритмів.

Алгоритми сегментації на основі підкреслення границь. Прийняття рішення про належність точки до однорідної області відбувається шляхом аналізу характеристик точки (яскравість, показники кольору). Такий тип алгоритмів сегментації зазвичай використовують для тих зображень, для яких характерні перепади яскравості на межах областей. Перевагою такого класу алгоритмів є швидкодія, оскільки позитивне рішення про належність точки до однорідної області для кожної точки приймається окремо. До недоліків таких алгоритмів відносять наявність розривів границь (зокрема для алгоритмів на основі фільтрації), а також складність вибору апіорної вхідної інформації (наприклад, для алгоритмів активних контурів).

Варто зауважити, що розглянуті традиційні методи сегментації не надають достатньої точності розпізнавання зображень. Найточнішими наразі є нейромережеві методи сегментації, тобто методи глибокого навчання.

1.3. Розвиток методів глибокого навчання для сегментації

Глибоке навчання (Deep learning) – один з методів машинного навчання, в основі якого – застосування нейронних мереж. Завдяки розвитку глибокого навчання удосконалюються і методи сегментації зображень. Варто зазначити, що у порівнянні з класичними методами сегментації, алгоритми глибокого навчання, як правило, призводять до набагато кращих та точніших результатів, особливо в умовах, що відрізняються від тих, у яких вони проходять тестування.

Перші вагомі кроки в області розвитку нейромереж та глибокого навчання здійснені у 40-х роках XX століття. Модель нейрофізіолога Уоррена МакКалоба та математика Уолтера Піттса була ступінчастою лінійною функцією на базі зважених лінійно інтерпольованих даних. У основі моделі було припущення про внутрішню роботу нейронів, яке дозволило змодельовати першу примітивну нейронну мережу за допомогою електричних ланцюгів [11].

Така модель (названа пороговою логікою) лежить у основі сучасних алгоритмів глибокого навчання, але проблеми фіксованих значень зважених

коефіцієнтів та дискретизація вихідної функції потребували подальших досліджень.

Наступною моделлю так званого нейрону була розроблена Розенблаттом 1958 р. [12], у її основі - робота людського ока. Ця модель отримала назву перцептрон і містить алгоритми для розпізнавання образів.

Основним принципом роботи глибокої нейронної мережі є послідовні лінійні операції, які поєднуються з нелінійними операціями. Завдяки великій кількості вузлів у мережі та простому введенню нелінійних (так званих активаційних) функцій, такі графоподібні структури можуть виявляти численні нелінійні закономірності в даних. Кожна така лінійна операція, зазвичай, є масштабуванням вхідних даних з додаванням певного члена зміщення, і називається шаром. Як правило, в моделях глибокого навчання кожен шар супроводжується використанням нелінійної функції активації. Отже, вихід одного шару обчислюється наступним чином:

$$X_{out} = \varphi(wX_{input} + b),$$

де X_{input} - вхідне значення змінної;

w – параметр масштабу (або «вага»);

b - зміщення лінійної функції;

φ – функція активації.

Вперше з метою семантичної сегментації були використані такі підходи машинного навчання як класифікатори TextonForest і Random Forest. А з появою згорткових нейронних мереж (CNN) у 1998 році задачі обробки зображень вийшли на інший рівень розвитку.

CNN мають високу стійкість до наявності шумів, спотворень, зсувів та зміни ракурсу фотографування. Ці мережі мають двовимірну структуру та проводять аналіз зображень не повністю, а його окремих частин. Це забезпечується спеціальними згортковими та підвибірковими шарами, які зменшують розмір вхідного сигналу з кожним наступним шаром. Описаним способом утворюється

певна «піраміда» шарів мережі, де кожен окремий шар складається з набору площин. Для кожної такої площини використовується власний набір ваг. Згорткові нейронні мережі призводять до швидкого та ефективного навчання внаслідок меншої кількості налаштовуваних вагових коефіцієнтів.

Однією з перших спроб сегментації з використанням CNN була латкова класифікація [13].

За допомогою методу був класифікований кожен піксель зображення після обробки згортковими шарами певної частини зображення (латки), яка містила його, а потім рішення про віднесення до деякого класу приймалося з використанням повнозв'язних шарів. У зв'язку зі збільшенням часу роботи та вимог до обчислювальних машин такий метод не набув поширення.

Зауважимо, що спочатку спроби використати CNN для задач сегментації були невдалими через застосування повнозв'язних шарів та пулінгових шарів (анг. pooling layers). Це призводило до обмежень на розмір вхідного зображення, бо сегментувати можна зображення однакового розміру. Застосування пулінгових шарів дозволяє брати більше ознак з більшої області зображення й об'єднувати їх, втративши інформацію про розташування ознак. Ці недоліки вперше усунуто Jonathan Long у роботі [14].

Більшість мереж для сегментації створюються шляхом поєднання двох мереж: кодувальника (і попередньо проходить тренування класифікаційною мережею), та декодувальника (яка розгортає вихідний вектор кодувальника до маски двовимірного вхідного зображення). Тобто, на першому етапі кодувальником визначається об'єкт на зображенні, а декодувальником – місце знаходження об'єкта. Процедура декодування для різних архітектур мереж виконується по-різному. До нейромереж, які можуть виконувати сегментацію зображень, належать FCN, SegNet, U-Net, FC-Densenet, E-Net, Link-Net, RefineNet, PSPNet.

Для вирішення задачі семантичної сегментації, а саме сегментації зображень судин сітківки ока потрібно обрати один з перелічених нейромережевих методів, який найкраще підходить для сегментації медичних

зображень, тобто враховує специфіку вхідних даних, а також наявну кількість зображень для тренування, розмір зображень, обмеження на час навчання, наявні ресурси.

1.4. Приклади застосування методів розв'язання задач сегментації зображень судин сітківки ока

Ознайомитися із прикладами застосування класичних методів розв'язання задач сегментації кровоносних судин, які включають ручні фільтри, зокрема детектори лінії, можна у [15, 16], а методи розширення судин – у роботах [17, 18, 19].

Для автоматизованого аналізу зображень сітківки за останні десятиліття було запропоновано багато підходів та методів.

У роботі [20] описано метод сегментації кровоносних судин на зображеннях очного дна на основі дискримінаційно навченої повністю пов'язаної моделі CRF, у якому комбінуються різні характеристики судин, а зображення сегментують з допомогою повністю пов'язаних умовних випадкових полів. У [21] пропонується структура посилення градієнта для навчання фільтрів у керований спосіб. У роботах [22, 23] розроблені алгоритми, що здатні покращувати тонкі структури за умови регресії судин сітківки. Метод суперпіксельної класифікації запропоновано в [24]. За останні роки нейромережеві методи глибокого навчання зробили надзвичайний прогрес у сфері комп'ютерного зору. Архітектура CNN спочатку була розроблена для задач природної класифікації зображень [25], і останні дослідження призвели до вражаючих результатів у вирішенні подібних завдань. CNN були використані для сегментації судин сітківки в [26] для класифікації особливостей плям.

У роботі [57] розглядається сегментація судин сітківки як задача визначення меж, яка вирішується за допомогою системи глибокого навчання DeepVessel. Для цього використовується CNN з додатковим виходом на бік, яка вивчає

дискримінативні репрезентації та шар CRF, що враховує нелокальні кореляції пікселів.

У алгоритмах сегментації, які базуються на FCN, структура мережі U-Net, яку запропонував Ronneberger [27], відрізняється способом переходу до карти функцій: замість широко використовуваного методу додавання - використовується конкатенація, що знайшла широке застосування для сегментації зображень у біомедицині. Також з'явилося багато покращених алгоритмів для сегментації зображень судин сітківки ока, які базуються на структурі U-Net. Наприклад, у [28] пропонують модель із зваженим затвором уваги для сегментації малих судин сітківки. У [29] поєднують фільтрування за Гаусом та U-Net з метою сегментації зображень судин сітківки. У роботі [30] сегментацію зображень судин сітківки здійснено за допомогою методів глибокого навчання в умовах невизначеності з використанням мінімаксного підходу. Робота [31] присвячена вирішенню проблеми зашумлених міток при сегментації судин сітківки нейронними мережами.

Висновки до розділу 1

У цьому розділі розглянуто поняття сегментації, її особливості, описано традиційні методи сегментації зображень, які використовуються на практиці. Розглянуто класифікацію алгоритмів сегментації на основі таких критеріїв: властивостей точок, властивостей взаємозв'язків між точками, властивостей областей, на основі властивостей текстури, підкреслення границь. Крім того, описано основні кроки у сфері розвитку нейромереж та глибокого навчання, а також зроблено огляд літератури з прикладами застосування методів розв'язання задач сегментації зображень судин сітківки ока, реалізованими за останні десятиліття.

РОЗДІЛ 2

ТЕОРЕТИЧНА ЧАСТИНА

2.1. Сучасні методи глибокого навчання для сегментації зображень

До найпоширеніших нейронних мереж, які можуть виконувати сегментацію зображень, належать FCN, SegNet, U-Net, FC-Densenet, E-Net, Link-Net, RefineNet, PSPNet.

Розглянемо кожен із нейромережових методів окремо, виділимо переваги, обмеження та сферу застосування.

FCN (Fully Convolutional Network) – повнозгорткова мережа - це архітектура CNN мережі, для якої повнозв'язні шари, які класифікують ознаки, замінені на шар вибірки (анг. upsampling), що локалізує ознаки. Завдяки цьому стало можливим приймати на вхід зображення будь-якого розміру, при цьому проводити сегментацію швидше. Архітектура FCN-8 стала базовою для подальшого удосконалення і розробок архітектур для сегментації зображень. Крім FCN-8, існують варіації FCN-16 та FCN-32. Перевагами цієї мережі є її швидкодія та хороша продуктивність. До обмежень можна віднести необхідність адаптувати мережу для сегментації, низька роздільна здатність карт сегментації на виході та, за сучасними мірками, невелика точність сегментації. Застосовувалася для семантичної сегментації супутникових зображень.

SegNet – нейронна мережа для сегментації зображень з повністю згортковою архітектурою. У SegNet енкодер складається з послідовності згорткових шарів з підвибіркою, а декодер складається з послідовності зворотних згорткових шарів з підвибіркою. У процесі класифікації пікселів, мережа декодерів використовує карти функцій низької роздільної здатності, отриману з енкодера, і збільшує її розмір до повної вхідної роздільної здатності. Удосконалення SegNet полягає в покращенні декодером вибору карти вхідних зображень, які мають нижчу роздільну здатність. Зокрема, з метою здійснення нелінійного підсилення, декодер

застосовує індекси об'єднання, які обчислені на етапі максимального об'єднання відповідного енкодера. Таким чином, SegNet використовує підсумовування для збереження інформації про місцезнаходження об'єктів. SegNet ефективна як з точки зору витрат пам'яті, так і витрат часу, а також містить меншу кількість параметрів, ніж конкуруючі архітектури. Перевагами мережі є висока швидкодія і продуктивність, невелика потреба в оперативній пам'яті, недоліками є необхідність у адаптації для сегментації та недостатньо гарну роздільну здатність карт сегментації, а також низька точність. Застосовувалась для сегментації дороги та класифікації типів дорожніх знаків [32].

U-Net - мережа, яка також містить енкодер та декодер, але має більшу кількість шарів, що забезпечує кращу якість сегментації об'єктів на зображенні [27]. Мережа U-net використовує U-подібну архітектуру та складається з двох частин: підрядної, для обчислення функцій, та розширюваної, для просторової локалізації патернів у зображенні. Карти ознак енкодера напряду передаються та конкатенуються з картами ознак відповідних шарів декодера, паралельно зі звичайними згортковими шарами. Архітектура U-net широко використовується у таких мережах (FPN, DeepLabv3, PSPNet тощо). U-net не використовує жодного повністю пов'язаного шару. Це призводить зменшення кількості параметрів моделі, а головною перевагою є її можливість навчатися на невеликій кількості даних (використавши збільшення даних). Також варто відзначити швидкодію, високу якість карт сегментації на виході. До сфер застосування U-Net належить насамперед медицина, дорожні сцени.

FC-DenseNet - мережа, яка поєднує в собі концепції FCN та DenseNet та дозволяє зменшити кількість параметрів мережі. FC-DenseNet використовує зв'язні шари, які дозволяють отримати більш глибоку інформацію про зображення, та додаткові шари, які забезпечують збільшення роздільної здатності для більш точної сегментації. FC-DenseNet працює краще за SegNet, FCN, DeepLabv1 і DilatedNet [33]. Застосовується для сегментації дорожніх сцен.

RefineNet - мережа, яка використовує багат шарову структуру з фільтрами різного розміру для отримання більш детальної інформації про зображення та

покращення точності сегментації. Вона застосовує такі механізми для покращення якості сегментації: агрегація інформації з багатьох рівнів мережі та додавання контекстної інформації [34]. Переваги мережі - висока якість карт сегментації на виході, висока точність сегментації. Недоліками RefineNet є невисока швидкодія. Сфера застосування досить широка.

PSPNet (Pyramid Scene Parsing Network) використовує пірамідальну структуру для отримання детальнішої інформації про зображення з різних масштабів з метою точнішої сегментації. Мережа виконує об'єднання (через функцію max або average) за допомогою ядер різного розміру та з різними кроками, які застосовуються до вихідних відображень ознак з CNN. Потім здійснюється зміна розмірів всіх виходів із шару пулінгу та остаточного відображення ознак нейромережі (CNN) з використанням білінійної інтерполяції; далі в моделі об'єднуються нові виходи вздовж осі каналу. Фінальна згортка для отримання результату здійснюється на об'єднаному виході [35]. Перевагами PSPNet є висока точність сегментації, а також висока якість карт сегментації на виході. Але мережа має невисоку швидкодію. Сфера застосування - медицина, сегментація доріг.

Link-Net - мережа, яка використовує енкодер-декодер архітектуру з додатковими зв'язками між енкодером та декодером для забезпечення кращої передачі інформації між шарами, є модифікованою версією U-Net та має більшу швидкість роботи. У Link-Net карти ознак із енкодера напряму передаються та додаються з картами ознак на відповідних шарах декодера [36]. Перевагою Link-Net є можливість роботи у реальному часі. Серед обмежень Link-Net – потреба працювати на потужному процесорі. Використовувалася для сегментації супутникових зображень.

E-Net - мережа, яка використовує модифіковану структуру ResNet та ефективно працює з великими зображеннями. E-Net використовує більш ефективні згорткові шари та структуру змінної глибини мережі, що дозволяє зменшити кількість параметрів мережі та скоротити час тренування. Мережа має компактну структуру, що забезпечує можливість її застосування в режимі реального часу на мобільних пристроях [37].

DeepLab на сьогодні є однією з найкращих моделей для задач сегментації. У цій моделі поєднується жорстка згортка, просторове об'єднання пірамід та повністю пов'язані CRF. DeepLab [38] для отримання карток сегментації реалізує архітектуру CNN разом з багатомасштабною обробкою зображень. З метою збільшення кількості інформації, що захоплюється, без збільшення числа параметрів у мережі застосовуються розріджені ядра згорток. Перевагами DeepLab є висока якість карт сегментації на виході та висока точність сегментації. Але DeepLab має невисоку швидкодію. Сфера застосування: сегментації доріг, медицина.

Таким чином, кожен з цих нейромережевих методів має свої особливості та переваги, які можна застосовувати для різних задач сегментації зображень. Для вибору найоптимальнішого методу потрібно враховувати розмір зображень, їхню кількість, сферу застосування, обчислювальні можливості персонального комп'ютера тощо.

У табл. 2.1 подано порівняння нейронних мереж, які призначені для семантичної сегментації зображень, за точністю (показник mIoU описано у підрозділі 2.4), перевагами, обмеженнями та сферою застосування.

З табл. 2.1 можна зробити висновок, що враховуючи точність, найкраще для сегментації медичних зображень підходять DeepLab, PSPNet, U-Net. Варто зауважити, що у медичній галузі дані пацієнтів є конфіденційними, вони захищені законами, через це пошук потрібних зображень, а також їх наявність у достатній кількості викликає певні проблеми. Тому однією з умов вибору методу глибокого навчання буде можливість працювати з базою зображень невеликого розміру. У економічному розділі роботи проведемо аналіз різних варіантів реалізації програмного продукту з використанням апарату функціонально-вартісного аналізу, в результаті якого остаточно буде обрано нейромережевий метод сегментації судин сітківки ока.

Таблиця 2.1

Порівняння нейромережових методів сегментації

Мережа	Точність, mIoU	Переваги	Обмеження	Сфера застосування
FCN-8	~ 57	Швидкодія, хороша продуктивність	Невисока точність сегментації, необхідність адаптації для сегментації	Супутникові зображення
SegNet	~ 56.1	Швидкодія, висока продуктивність	Невисока точність сегментації, необхідність адаптації для сегментації	Класифікація дорожніх знаків; дорожні сцени
U-Net	~ 77.5	Гарні результати сегментації на невеликій кількості даних, швидкодія, висока точність	Невисока точність сегментації для деяких задач	Медицина; дорожні сцени
FC-DenceNet	~ 66.9	Висока точність та якість карток сегментації на виході	Недостатня точність сегментації для деяких задач	Дорожні сцени
RefineNet	~ 73.6	Висока точність	Невисока швидкодія	Широка
PSPNet	~ 81.2	Висока точність	Невисока швидкодія	Широка
Link-Net	~ 76.4	Працює в режимі реального часу	Потрібен потужний процесор	Супутникові зображення
ENet	~ 58.3	Працює в режимі реального часу	Потрібен потужний процесор	Дорожні сцени
DeepLab-v3	~ 81.3	Висока точність	Невисока швидкодія	Медицина, дорожні сцени

2.2. Умовні випадкові поля

Conditional random fields (CRFs) - умовні випадкові поля (УВП) — це клас методів моделювання, які використовуються для розпізнавання образів та машинного навчання з метою передбачення. Відмінністю умовного випадкового поля від дискретного класифікатора (що здійснює передбачення мітки окремого зразка без урахування «сусідніх»), є можливість враховувати контекст.

CRF є одним з типів розрізнявальних (умовних) неспрямованих

(неорієнтованих) імовірнісних графових моделей.

Лафферті, Маккалум та Перейра у своїй роботі [39] визначили CRF на спостереженнях X та випадкових змінних Y таким чином: Нехай $G = (V, E)$ - граф, для якого $Y = (Y_v)_{v \in V}$, причому Y індексовано вершинами G . Тоді (X, Y) є умовним випадковим полем, якщо випадкові змінні Y_v , які обумовлені X , мають марковську властивість по відношенню до цього графу:

$$p(Y_v | X, Y_w, w \neq v) = p(Y_v | X, Y_w, w \sim v),$$

де $w \sim v$ означає, що w та v є сусідами в G .

Це означає, що CRF є неспрямованою графовою моделлю, вершини якої можна поділити на рівно дві множини X та Y , що не перетинаються, тоді спостережувані та вихідні змінні, відповідно; моделюють умовний розподіл $p(Y | X)$.

CRF застосовують в задачах розмітки частин мови, поверхнево-синтаксичному аналізі, для пошуку генів, при розпізнаванні іменованих сутностей [40], в задачах пошуку пептидних критичних областей функцій [41]. Також останніми роками CRF почали успішно застосовувати в області комп'ютерного зору для розпізнавання та сегментування зображень.

Таким чином, CRF складається з набору з'єднаних вузлів, а при використанні CRF у задачах розпізнавання образів і роботі з цифровими зображеннями, з набору пікселів зображення, мітки або значення для яких присвоюються на основі міток чи значень їхніх прямих сусідніх пікселів. CRF часто застосовуються з метою зменшення шуму та виділення границь об'єктів на сильно зашумлених картах сегментації. Використання умовних випадкових полів в поєднанні з нейромережевими методами сприяє вирішенню проблем зашумлення. Завдяки застосуванню методу CRF до вихідних даних глибокої згорткової нейромережі карта сегментації стає більш згладженою та отримує чіткіші межі між сегментами зображення. CRF часто розглядається як метод постобробки, що дозволяє

ітеративно покращити вихідні результати роботи згорткової нейромережі. На рис. 2.1 подано результати роботи нейронної мережі DeepLab на зображеннях з використанням CRF.




Рисунок 2.1 – Результати роботи мережі DeepLab. Зліва-направо: вхідне зображення, маска зображення, результати сегментування до застосування CRF, результати сегментування після застосування CRF.

Отже, поєднання методів CRF у поєднанні з архітектурами глибокого навчання може дати перспективні результати для сегментації зображень судин сітківки ока.

2.3. Методи аугментації

У процесі навчання моделі сегментації, якщо вхідних даних недостатня

кількість, використовуються різні стратегії збільшення їх кількості. Таке збільшення вибірки даних для навчання нейромережі через модифікацію існуючих вхідних даних називають аугментацією. Потім отримані зображення додаються до набору даних у процесі тренування [42].

Серед методів аугментації найпоширенішими є такі:

Віддзеркалення: виконується горизонтальне чи вертикальне перевертання для кожного зображення з базового навчального набору.

Гаусовий шум: генерується масив N , де кожен елемент масиву є вибіркою з гаусового розподілу з $\mu = 0$ і з σ^2 у діапазоні $[0,1,0,9]$. Далі для кожного зображення I отримують зашумлене зображення, $I' = I + N$.

Тремтіння: для кожного I додається невелика кількість контрасту (± 1 -4 значення інтенсивності).

Масштабування: масштабується кожне зображення у напрямку x або y ; зокрема застосовується афінне перетворення.

Розмиття за Гаусом: кожне зображення розмивається за допомогою функції Гауса, що визначається відхиленням від 0,1 до 0,9. Потім розмір фільтра внутрішньо генерується за допомогою scikit-image, де радіус ядра $r = 4$.

Обертання: застосовується таке афінне перетворення $A = \begin{pmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{pmatrix}$, де θ від 10 до 175 градусів.

Афінна трансформація: до кожного зображення I застосовують афінну трансформацію $A = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix}$, де $s \in [0,1,0,35]$ і визначає кількість зрізу зображення.

Випадкова гамма-корекція: використовується на етапі попередньої обробки зображення шляхом зміни інтенсивності зображення в колірному просторі RGB (червоний, зелений, синій).

2.4. Критерії якості сегментації зображень

На сьогодні якість сегментації для більшості практичних завдань

визначається як міра близькості двох зображень: сегментованого деяким експертом та сегментованого відповідними методами. Якість сегментації зображення на практиці визначається як на суб'єктивному (якісному) [43], так і на об'єктивному (кількісному) рівні.

До суб'єктивних критеріїв відносяться критерії візуального сприйняття, що отримуються під час експертизи певною групою експертів. Найпоширенішим є метод оцінок, який дозволяє оцінити такі характеристики зображення; правильність виділення кольорів, контурів, областей тощо

До об'єктивних критеріїв належать критерії, отримані внаслідок деякого порівняння кількісних ознак сегментованого певним методом зображення та зображення, сегментованого експертом (так званого еталонного). Критерії такого типу часто використовуються в системах автоматизованого аналізу зображень, для визначення кількісного еквівалента якості сегментації [44].

До найпоширеніших критеріїв, за якими кількісно можна оцінити якість сегментації, належать метрики [45]:

- 1) intersection over union (IOU);
- 2) accuracy;
- 3) precision;
- 4) recall (sensitivity);
- 5) specificity;
- 6) F1-score;
- 7) dice coefficient;
- 8) loss function.

Введемо позначення [46]:

P (positive) — кількість позитивних відповідей (результатів сегментації).

N (negative) — скільки негативних відповідей.

Тепер подивимось на результат роботи мережі.

Усі позитивні відповіді (мережа сказала "так", тобто правильно сегментувала) поділяють на:

TP (true positive) — мережа відповіла "так" і вгадала,

FP (false positive) — мережа відповіла "так" і помилилася.

Усі негативні відповіді подають аналогічно:

TN (true negative) — мережа відповіла "ні" і це було правильно,


FN (false negative) — мережа відповіла "ні" і це помилка.

Intersection over Union (IOU) є метрикою оцінки, що використовується для визначення достовірності розташування обмежуючої рамки і є відношення площ обмежувальних рамок:


$$IoU = \frac{S(A \cap B)}{S(A \cup B)},$$

де A та B — передбачена рамка, що обмежує, і справжня рамка, що обмежує відповідно. IoU дорівнює 0 у випадку, якщо обмежувальні рамки не перетинаються, і дорівнює 1 у випадку ідеального накладання (рис. 2.2).

IoU: 0.4034



IoU: 0.7330



IoU: 0.9264




Рисунок 2.2 – Вплив взаємного розміщення рамок на метрику IoU

При сегментації зображення область може мати будь-яку форму (правильну чи неправильну) і не обов'язково має бути прямокутною. Це означає, що прогнози — це не обмежувальні рамки, а маски сегментації. У цьому випадку виконується попиксельний аналіз.

$$IoU = \frac{TP}{TP+FP+FN}.$$

$IoU \in [0, 1]$, чим значення ближче до 1, тим краще.

Для багатокласової сегментації середнє значення IoU зображення обчислюється шляхом обчислення IoU кожного класу та усереднення:

$$mIoU = \frac{1}{N} \sum_{i=1}^N IoU_i.$$

Accuracy - це відношення правильно класифікованих елементів до всіх доступних елементів, обчислюється так:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}.$$

$Accuracy \in [0, 1]$, чим ближче до 1, тим краще.

Precision - позитивне прогностичне значення (PPV) - це відношення між істинними позитивними та всіма елементами, класифікованими як позитивні:

$$Precision = \frac{TP}{TP+FP}.$$

$Precision \in [0, 1]$, чим значення ближче до 1, тим краще.

Recall (sensitivity) - справжнє позитивне значення (TPV) - це відношення справжніх позитивних до всіх позитивних елементів:

$$Recall = \frac{TP}{P} = \frac{TP}{TP+FN}.$$

$Recall \in [0, 1]$, чим значення ближче до 1, тим краще.

Specificity (selectivity or true negative rate (TNR)) - це відношення справжніх негативних до всіх негативних елементів:

$$Specificity = \frac{TN}{N} = \frac{TN}{TN+FP}.$$

$Specificity \in [0, 1]$, чим значення ближче до 1, тим краще.

F1-score - це комбінація Recall и Precision (середнє гармонійне):

$$F1 - score = 2 * \frac{Recall * Precision}{Recall + Precision} = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}}.$$

Максимальне значення F1-score ми отримаємо, якщо Recall та Precision достатньо далекі від нуля. За допомогою цієї метрики можна знайти компромісне рішення, фактично, між максимізацією TP за різними шкалами.

Dice coefficient використовується для вимірювання схожості двох зображень, відображає подібність між передбачуваним (сегментованим) зображенням та відповідним оригінальним зображенням.

Dice обчислюють наступним чином:

$$Dice = \frac{2 * TP}{(TP + FP) + (TP + FN)}.$$

$Dice \in [0, 1]$, чим значення ближче до 1, тим краще.

Loss function (функція втрат) використовується для розрахунку помилок між реальними й отриманими відповідями. Глобальною метою є мінімізація цієї помилки. Функція втрат одновимірна і може залежати від таких змінних, як ваги та зміщення. Функція дозволяє оцінити, наскільки якісно працює нейромережа. До відомих функцій втрат належать:

- Середньоквадратичне відхилення;
- Кросс-ентропія;
- Експоненціальна (AdaBoost);
- Відстань Кульбака — Лейблера або приріст інформації.

$Loss function \in [0, \infty]$, чим значення ближче до 0, тим краще.

Висновки до розділу 2

У цьому розділі описані нейромережеві методи сегментації зображень, які використовуються на практиці. Детально розглянуто методи глибокого навчання, які можна використати для сегментації зображень: FCN, SegNet, U-Net, FC-Densenet, E-Net, Link-Net, RefineNet, PSPNet. Здійснено порівняння нейронних мереж за точністю, перевагами, обмеженнями та сферою застосування та зроблено висновки, що для сегментації медичних зображень підходять DeepLab, PSPNet, U-Net. Остаточний вибір нейронної мережі буде зроблено за допомогою ФВА. Крім того, розглянуто метод умовного випадкового поля, який використовується як метод постобробки, що дозволяє покращити вихідні результати роботи згорткової нейронної мережі. Також у розділі описано найпоширеніші методи аугментації зображень та критерії якості сегментації зображень, зокрема метрики, за якими можна оцінити якість сегментації. Для практичної реалізації буде використано такі метрики: accuracy, precision, specificity, recall (sensitivity) та dice, які є найуживанішими у сфері глибокого навчання.

РОЗДІЛ 3

ПРАКТИЧНА ЧАСТИНА

У роботі було розроблено програмний продукт (ПП) для сегментації зображень судин сітківки ока. Для створення ПП використано мову програмування Python, архітектуру U-net та бібліотеку Keras.

3.1. Архітектура U-net

Повнозгорткова нейромережа U-Net розроблена у 2015 році у відділенні Computer Science Фрайбургського університету і є підвидом згорткових нейронних мереж (CNN), які призначені для потреб сегментації зображень, насамперед медичних [27].

Цей вид нейронних мереж відрізняється від відомих традиційних мереж тим, що просторова інформація (тобто розміщення у просторі кожного елементу згортки) враховується для кожного шару. Це можливе завдяки тому, що у мережі відсутні повнозв'язні шари. Такий підхід дозволяє також працювати із зображеннями будь-якого розміру, що неможливе для традиційних мереж через прямий зв'язок розміру зображення і кількістю вхідних нейронів першого повнозв'язного шару. Нейромережі подібного типу добре себе показали на різних змаганнях на платформі Kaggle, оскільки можуть навчатися на невеликій кількості навчальних зображень та мають високу швидкості роботи.

На рис. 3.1 подана архітектура мережі U-net (числа, розміщені над прямокутниками означають кількість каналів ознак, а числа у лівому нижньому куті – розмір зображення [27]). Мережа U-Net складається з двох частин: зменшувального шляху (ліворуч) та збільшувального шляху (праворуч) та побудована за описаним в розділі 2 принципом «кодувальник-декодувальник». Схематичне розміщення блоків та зв'язків на архітектурі нагадує літеру “U” латинської абетки, тому нейромережа і отримала таку назву.

Зменшувальний шлях (блок кодування) є типовою згортковою

неймережею. Він складається з двох згорткових шарів (позначені фіолетовою стрілкою) з вікном згортки 3×3 (3 пікселі на 3 пікселі), за кожним з яких розміщується шар ReLU та пулінг-шар (позначено стрілкою червоного кольору) з вікном 2×2 пікселі з функцією максимуму та кроком 2, після чого розмір зображення зменшується вдвічі.




Рисунок 3.1 – Архітектура мережі U-net

На кожному із кроків блоку кодування кількість каналів ознак подвоюється і після проходження зменшувального шляху зображення зменшується до розміру 32×32 з 512 каналами ознак.

Кожен крок блоку декодування (збільшувального шляху) передбачає збільшення карти ознак, після чого здійснюється згортка 2×2 , яка зменшує кількість каналів ознак удвічі, конкатенація (об'єднання) зі зменшеною картою ознак, отриманою на відповідному кроці блоку кодування, та двома згортками 3×3 пікселі $\times$ 3×3 пікселі з шарами ReLU. Об'єднання карт ознак симетричних блоків кодувальника та декодувальника (позначені на рисунку сірою стрілкою) необхідне для відновлення дрібнозернистої інформації.

На останньому кроці роботи мережі згортка 1×1 перетворює вектор ознак

(складається з 64 елементів) у потрібну кількість класів. Всього в архітектурі U-Net використовується 23 шари згортки.

3.2. Інструменти для реалізації програмного продукту

Для реалізації описаного програмного продукту обрано мову Python, яка дуже добре пристосована до вирішення різноманітних наукових задач, зокрема задач глибокого навчання. Серед переваг Python – велика кількість бібліотек програмного забезпечення і подальше їх стрімке зростання, які наявні у відкритому доступі. За допомогою мови Python можна ефективно вирішити усі поставлені перед початком роботи задачі.

Для реалізації нейромережі було обрано відкриту нейромережеву бібліотеку Keras, яка є обгорткою над TensorFlow. Keras написана мовою Python і була створена як частина деякого дослідницького проекту. У наш час Keras використовується для швидких експериментів з нейронними мережами. До основних її переваг належать гнучкість, модульність та можливість розширювання. Бібліотека містить низку поширених компонентів, завдяки чому зручно працювати із задачами, що потребують аналізу. Крім того, у Keras реалізовані «будівельні блоки» нейромереж: шари, цільові функції, оптимізатори та передавальні функції, а також різноманітні інструменти, які спрощують роботу із зображеннями.

На сьогодні існує багато алгоритмів оптимізації для навчання нейромереж. Серед найвідоміших – алгоритм зворотного прояву помилки, який застосовується для мінімізації відхилень поточного значення вихідного сигналу нейромережі від потрібного. Недоліками цього алгоритму є можливість перенавчання у випадку вибору малої швидкості навчання або розбіжність при надто великій швидкості. Для усунення цих недоліків існують різні модифікації алгоритму, основна відмінність яких від класичного алгоритму полягає в тому, що для них використовується адаптивна швидкість навчання для кожної нейромережі, яка адаптується під час навчання. У роботі

використовується алгоритм Adam, який показує кращі результати в порівнянні з іншими алгоритмами: кращу точність класифікації, достатньо простий для реалізації; ефективний у застосуванні; інваріантний до зміни масштабу градієнта по діагоналі; ефективний для завдань з великою кількістю параметрів.

Adam реалізований у фреймворку TensorFlow за допомогою класу Adam з модуля `tensorflow.keras.optimizers`. В коді Adam використовується як оптимізатор під час компіляції моделі наступним чином (рис. 3.2):

```
model.compile(loss=dice_loss, optimizer=Adam(lr), metrics=[dice_coefficient, intersection_over_union, Recall(), Precision()])
```

Рисунок 3.2 – Використання оптимізатора Adam

3.3. Структура програмного продукту

Під час виконання роботи було розроблено дві підсистеми: для навчання нейромережі (рис. 3.3) та для її використання у задачах сегментації зображень судин сітківки ока (рис. 3.4).

Для навчання нейромережі модуль завантаження завантажує з файлового сховища зображення сітківки ока та відповідну маску для цього зображення.




Рисунок 3.3 – Схема навчання моделі




Рисунок 3.4 – Схема роботи системи в режимі передбачень

Після чого для зображення та маски змінюється розмір до заданого (512x512), далі вони подаються на вхід модуля аугментації, у якому виконуються однакові модифікації зображення та відповідної маски. Після аугментації зображення обробляється мережею на базі архітектури U-net. Нейронна мережа генерує маску, яка має вигляд карти ймовірностей. Згенерована маска порівнюється з початковою вхідною маскою, обчислюються метрики, після чого нейромережа корегує ваги.

Робота підсистеми для передбачень відрізняється від роботи підсистеми для навчання нейронної мережі. Метою роботи підсистеми передбачень є генерація маски (сегментоване зображення), тому на вхід подається лише зображення сітківки ока. Аугментація в цій підсистемі не проводиться. Результат роботи мережі - карта ймовірностей належності пікселя поданого вхідного зображення до шуканого сегменту. Після чого отримуємо сегментоване зображення.

Для покращення отриманих результатів початкової моделі сегментації, на етапі постобробки використано умовні випадкові поля (CRF). Це дозволяє позбутися шумів і покращити зовнішній вигляд вихідного зображення.

3.4. Вхідні зображення

У роботі використано загальнодоступний набір даних DRIVE, який містить

40 зображень судин сітківки ока разом з відповідними масками. Перед використанням розмір зображень потрібно змінити за допомогою програмного продукту до потрібного.

На вхід розробленої моделі повинні подаватися зображення однакового розміру. Крім того, час навчання нейромережі залежить від розміру зображень, оскільки при роботі із зображеннями великого розміру будуть виникати проблеми, пов'язані з нестачею оперативної пам'яті.

3.5. Аугментація у розробленому ПЗ

Застосування аугментації, тобто стратегії збільшення даних стало необхідним при використанні нейромережі U-Net. Варто зауважити, що для практичних задач сегментації судин сітківки не дуже багато даних для навчання, що пов'язано насамперед конфіденційністю особистої інформації кожного пацієнта. Застосування аугментації дозволяє збільшити кількість вхідних даних (розмір датасету), а це надає нейронній мережі нову додаткову інформацію для навчання. Крім того, застосування аугментації дозволяє компенсувати втрати точності внаслідок якості зображення та його розмірів. Також збільшення даних допоможе нейромережі U-Net при використанні операції об'єднання (pooling), оскільки модель погано опрацьовує інформацію на краях вхідного зображення.

У роботі застосовано такі методи аугментації:

- віддзеркалення: виконується горизонтальне та вертикальне відображення для кожного зображення та його маски з базового навчального набору;
- еластичне перетворення (ElasticTransform): Зображення та маска були еластично перетворені з використанням аргументів $\alpha=120$, $\sigma=6$, та $\alpha_affine=3.6$.
- розмиття сіткою (GridDistortion): Зображення та маска були розмиті за допомогою розміщення пікселів на сітці.

– оптичне спотворення (OpticalDistortion): Зображення та маска були спотворені за допомогою оптичного спотворення.

У задачах сегментації зображення та його маска повинні відповідати одне одному, тому методи аугментації застосовуються і для зображення, і для його маски. Приклади аугментації подано на рис. 3.5.




Рисунок 3.5 – Оригінальне зображення судин сітківки ока та його маска (знизу), та аугментовані описаними вище способами зображення

3.6. Тренування моделі


Основними кроками тренування моделі є такі: підготовка даних, побудова моделі, налаштування зворотних викликів, навчання моделі.

Перед виконанням тренування моделі потрібно мати встановлені необхідні бібліотеки та модулі.

Підготовка даних передбачає завантаження даних тренувального та валідаційного наборів зображень і еталонних масок, далі виконується аугментація зображень тренувального набору для кращого розподілу даних. При побудові моделі створюється модель UNet з архітектурою, яка складається з енкодера та декодера. Модель компілюється з використанням функції втрат, оптимізатора Adam із заданою швидкістю навчання та метриками.

Потім викликається функція для тренування моделі, якій передаються тренувальний та валідаційний набори даних, кількість епох, кількість кроків на кожну епоху. Під час тренування модель буде прогресивно навчатися, оновлюючи ваги, та зберігати найкращу модель.

Отже, після завантаження підготовлених зображень та масок для тренування у відповідні каталоги, побудови моделі та налаштування зворотних викликів, розпочинається навчання моделі (рис. 3.6).



```
Run train (1) x
C:\Users\yarik\Desktop\RetinalSegment\venv\Scripts\python.exe C:\Users\yarik\
Train data:
Number of images: 120
Number of masks: 120
Validation data:
Number of images: 20
Number of masks: 20
Epoch 1/100
3/60 [>.....] - ETA: 9:54 - loss: 0.8615 - dice_coef
```

Рисунок 3.6 – Навчання моделі (епоха 1/100)

Під час тренування періодично зберігається найкраща версія моделі на основі обчислених метрик, яка буде збережена у файлі model.h5. Ця модель буде мати параметри, які надали найкращий результат на тестовому наборі зображень.

Також після навчання буде створений файл data.csv, у якому міститься історія тренування, включаючи значення втрат та метрик на кожній епісі тренування (рис. 3.7).

	A	B	C	D	E	F	G	H	I	J	K	L
1	epoch	dice_coefficient	intersection_over_union	loss	lr	precision	recall	val_dice_coefficient	val_intersection_over_loss	val_precision	val_recall	
2	0	0,329373538	0,200226381	0,670626	0,0001	0,422292	0,654924	0,135533482	0,072711706	0,864466548	0	0
3	1	0,495559275	0,330015749	0,504441	0,0001	0,777416	0,469187	0,104483269	0,055129111	0,895516694	0	0
4	2	0,549268484	0,379115641	0,450732	0,0001	0,834901	0,45192	0,077237092	0,04017413	0,922762871	0,057684768	0,00105257
5	3	0,586798072	0,415727496	0,413202	0,0001	0,870284	0,444595	0,079749659	0,041562933	0,920250297	0,129008472	0,01439434
6	4	0,616137087	0,445698947	0,383863	0,0001	0,893319	0,438504	0,153398648	0,083314195	0,846601367	0,279305696	0,05249428
7	5	0,639164567	0,470140338	0,360835	0,0001	0,906605	0,434625	0,281799257	0,164427698	0,718200803	0,401102781	0,13075817
8	6	0,661965489	0,495150894	0,338034	0,0001	0,919887	0,432254	0,377518356	0,233244032	0,622481644	0,508435011	0,17818098
9	7	0,679650605	0,515139401	0,320349	0,0001	0,927502	0,429887	0,454630613	0,294958651	0,545369387	0,657619238	0,20518737
10	8	0,69486624	0,532860041	0,305134	0,0001	0,932911	0,42719	0,594955087	0,424080074	0,405044973	0,885219634	0,27944398
11	9	0,710266888	0,551104128	0,289733	0,0001	0,940472	0,426084	0,650151372	0,482017934	0,349848628	0,977212787	0,30043811
12	10	0,72562927	0,569786012	0,274371	0,0001	0,947376	0,42566	0,668123245	0,502003729	0,331876785	0,978486419	0,30489162
13	11	0,737862647	0,585008919	0,262137	0,0001	0,951879	0,425515	0,683383465	0,519517899	0,316616565	0,976375282	0,31400615
14	12	0,746904433	0,596443117	0,253096	0,0001	0,954891	0,42358	0,705940723	0,545735955	0,294059247	0,960735559	0,35695398
15	13	0,755080163	0,606884539	0,24492	0,0001	0,957557	0,422026	0,715400934	0,557038844	0,284599155	0,945525885	0,38669237
16	14	0,762341917	0,616359174	0,237658	0,0001	0,959328	0,422235	0,720251441	0,563059866	0,279748589	0,958125174	0,3639535
17	15	0,77035296	0,626849115	0,229647	0,0001	0,963284	0,420582	0,72936213	0,574160576	0,27063784	0,94744575	0,38360801
18	16	0,776977897	0,635686994	0,223022	0,0001	0,965119	0,420728	0,730395079	0,57549113	0,269604981	0,951684058	0,37410182
19	17	0,783999205	0,645094156	0,216001	0,0001	0,968276	0,420095	0,72784102	0,572433352	0,27215901	0,960404634	0,35363171
20	18	0,789680243	0,652788758	0,21032	0,0001	0,970298	0,419721	0,729405224	0,574354231	0,270594776	0,963534832	0,34433568
21	19	0,791961908	0,655929267	0,208038	0,0001	0,970138	0,41942	0,734543681	0,580702543	0,265456289	0,959600389	0,35295027
22	20	0,796471834	0,662133455	0,203528	0,0001	0,971867	0,418201	0,745818913	0,594840646	0,254181057	0,947961032	0,38256708
23	21	0,802328765	0,670222104	0,197671	0,0001	0,974451	0,418456	0,731524706	0,576984346	0,268475324	0,953364193	0,35221249
24	22	0,805942535	0,675296843	0,194058	0,0001	0,975204	0,418181	0,737029076	0,583763719	0,262970924	0,94823724	0,3661105
25	23	0,808062792	0,678289711	0,191937	0,0001	0,975497	0,419076	0,742288947	0,590459704	0,257711053	0,963348567	0,34663308
26	24	0,810498059	0,681704879	0,189502	0,0001	0,976517	0,418162	0,735837817	0,582463741	0,264162213	0,965391695	0,33464792
27	25	0,814742982	0,687711477	0,185257	0,0001	0,978283	0,417967	0,748031139	0,597780228	0,251968801	0,964778781	0,34826156
28	26	0,81818229	0,692655563	0,181818	0,0001	0,979296	0,418241	0,738628268	0,585967898	0,261371672	0,971470773	0,32534739
29	27	0,820251584	0,695664704	0,179749	0,0001	0,979706	0,418156	0,731363118	0,576945066	0,268636942	0,966905236	0,32100299
30	28	0,822552502	0,698957682	0,177448	0,0001	0,980659	0,417961	0,741830587	0,589859486	0,258169413	0,957289338	0,34822133
31	29	0,82513088	0,702648401	0,174869	0,0001	0,981802	0,417196	0,744237781	0,592861772	0,25576219	0,943033993	0,37244472
32	30	0,824545145	0,701809764	0,175455	0,0001	0,980889	0,417471	0,752698541	0,603696227	0,247301459	0,953554153	0,36477625
33	31	0,824911199	0,702359792	0,175679	0,0001	0,980749	0,417472	0,744777753	0,593057566	0,255777753	0,965471269	0,32619691

Рисунок 3.7 – Файл data.csv

Ці результати допомагають оцінити продуктивність моделі, її здатність до узагальнення та ефективність тренування. Можна проаналізувати журнали та результати метрик, а також використати збережену найкращу модель для подальших застосувань, таких як тестування на нових даних (рис. 3.8).




Рисунок 3.8 – Оригінальне зображення, маска, результат сегментації

На рис. 3.9 – рис. 3.11 подано значення функції втрат (loss), dice та precision у залежності від кількості епох навчання.




Рисунок 3.9 - Залежність функції втрат (loss) від кількості епох навчання




Рисунок 3.10 - Залежність метрики dice від кількості епох навчання




Рисунок 3.11 - Залежність метрики precision від кількості епох навчання

3.7. Опис інтерфейсу користувача

Програмний застосунок для сегментації зображень сітківки ока з

використанням згорткової нейронної мережі має простий та зручний інтерфейс користувача (GUI), який дозволяє вибирати, переглядати та обробляти зображення, а потім застосовувати модель для передбачення масок сегментації. Користувачі отримують результати сегментації у зручному форматі (зображення із розширенням .png).

Основні можливості програмного застосунку: завантаження, обробка, перегляд та сегментація зображень, обчислення метрик точності.

Після запуску програмного застосунку генерується основне вікно, у якому користувач має змогу здійснювати сегментацію зображень. Воно має такий вигляд (рис. 3.12):




Рисунок 3.12 - Головне вікно програми

Завантаження зображень передбачає можливість користувачів обрати зображення та його еталонну маску (за її наявності) з файлової системи та завантажити їх у програму для подальшої обробки (рис. 3.13).




Рисунок 3.13 – Вибір зображення

Після завантаження зображення (рис. 3.14) та маски, користувач може переглянути їх у GUI, оригінальні файли збережуться у відповідній директорії.



Рисунок 3.14 – Завантаження зображення

Сегментація зображень - одна з головних функцій програмного продукту. Застосовуючи попередньо навчену модель глибокого навчання, на основі завантажених зображень можна здійснювати сегментацію. Процес сегментації зображення починається після натискання кнопки «Segment», по завершенні сегментації видається відповідне повідомлення (рис. 3.15). Якщо для зображення існує еталонна маска, то отримаємо результат сегментації (рис. 3.16) та будуть

автоматично обчислені метрики, такі як точність (accuracy), чутливість (recall), специфічність (specificity) і коефіцієнт Серенсена (Dice coefficient). Ці метрики дозволяють оцінити якість сегментації, порівнюючи результати з еталонними масками.




Рисунок 3.15 – Повідомлення про успішне завершення сегментації зображення




Рисунок 3.16 – Сегментація зображення

У випадку відсутності еталонної маски для завантаженого зображення видається відповідне повідомлення про те, що метрики обчислені не будуть

(рис. 3.17):




Рисунок 3.17 – Повідомлення про помилку (відсутність еталонної маски та неможливість обчислення метрик)

У такому випадку для зображення без маски сегментація відбувається без обчислення метрик (рис. 3.18):




Рисунок 3.18 – Результат сегментації для зображення без маски (метрики не обчислені)

Також у програмному застосунку є можливість сегментувати весь датасет.

Для цього потрібно натиснути кнопку «Segment Dataset» та обрати датасет (рис. 3.19):




Рисунок 3.19 – Вибір датасету для сегментації

Після цього починається процес сегментації набору зображень (рис. 3.20):




Рисунок 3.20 – Процес сегментації датасету

Після успішної сегментації датасету з'являється відповідне повідомлення (рис. 3.21), виводяться результати сегментації з можливістю перегляду кожного із сегментованих зображень та обчислюються усереднені метрики (рис. 3.22):




Рисунок 3.21 – Повідомлення про успішну сегментацію датасету




Рисунок 3.22 – Результат сегментації датасету
та обчислені усереднені метрики

Результати сегментації набору зображень зберігаються у папці «results» (рис. 3.23):




Рисунок 3.23 – Вміст папки «results» після сегментації датасету

Отже, програмний застосунок надає можливості користувачам для обробки та сегментації зображень, при цьому забезпечуючи простоту використання та інтуїтивний інтерфейс. Його можна використати у різних сферах, зокрема в медицині, для комп'ютерного зору, в науці.

3.8. Застосування програмного продукту

Програмний застосунок може бути використаний в різних сферах, де обробка зображень та сегментація є важливими завданнями. Ось декілька прикладів застосування програмного застосунку:

1) Медична сфера: у медицині програмний продукт може бути використаний для сегментації медичних зображень, наприклад, рентгенівських знімків чи зображень з магнітно-резонансної томографії (МРТ). Це може допомогти лікарям точніше виявляти та діагностувати патологічні зміни та хвороби.

2) Комп'ютерний зір: у цій сфері програмний застосунок можна використати для обробки та аналізу зображень з камер спостереження, наприклад, для виявлення об'єктів, відстеження руху, розпізнавання облич тощо.

3) Автоматизована обробка зображень: в інженерії та промисловості

програмний застосунок можна використати для автоматичної обробки зображень у виробничих процесах. Наприклад, для інспекції виробів, контролю якості, визначення розмірів та форми деталей тощо.

4) Академічні дослідження: науковці в області комп'ютерного бачення та машинного навчання можуть використати програмний застосунок для проведення експериментів та досліджень. Він надає зручний інструментарій для реалізації та тестування нових моделей сегментації та обробки зображень.

Програмний застосунок можна адаптувати до потреб кожного конкретного використання. Він здійснює сегментацію зображень з високою точністю та ефективністю.

3.9. Порівняння застосованого методу з аналогами

Застосований метод оцінювався на публічному наборі даних: DRIVE. Цей набір даних надає еталонні сегментації (маски) для кожного зображення. Це надає змогу обчислити оцінки продуктивності. У роботі оцінки проводяться за метриками accuracy, precision, specificity, recall (sensitivity) та dice.

Accuracy - це відношення правильно класифікованих елементів до всіх доступних елементів:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}.$$

$Accuracy \in [0, 1]$, чим значення ближче до 1, тим краще.

Sensitivity (recall) - справжнє позитивне значення (TPV) - це відношення справжніх позитивних до всіх позитивних елементів:

$$Sensitivity = \frac{TP}{P} = \frac{TP}{TP+FN}.$$

$Sensitivity \in [0, 1]$, чим значення ближче до 1, тим краще.

Precision - позитивне прогностичне значення (PPV) - це відношення між істинними позитивними та всіма елементами, класифікованими як позитивні:

$$Precision = \frac{TP}{TP+FP}.$$

$Precision \in [0, 1]$, чим значення ближче до 1, тим краще.

Specificity - це відношення справжніх негативних до всіх негативних елементів:

$$Specificity = \frac{TN}{N} = \frac{TN}{TN+FP}.$$

$Specificity \in [0, 1]$, чим значення ближче до 1, тим краще.

Dice coefficient використовується для вимірювання схожості двох зображень, відображає подібність між передбачуваним (сегментованим) зображенням та відповідним оригінальним зображенням:

$$Dice = \frac{2 * TP}{(TP + FP) + (TP + FN)}.$$

$Dice \in [0, 1]$, чим значення ближче до 1, тим краще.

Тут TP, TN, FP та FN відповідають кількості правильних позитивних відповідей, правильних негативних відповідей, помилкових позитивних та помилкових негативних відповідей відповідно.

У табл. 3.1 подано результати порівняння застосувань різних методів сегментації зображень судин сітківки на наборі даних DRIVE, результати взято з оригінальних робіт [30, 31, 47-57]. У останньому рядку таблиці - показники якості, які отримано під час виконання роботи. Як видно з таблиці, у деяких випадках метрики для застосованого у роботі методу кращі за метрики в аналогічних методах, а в деяких - гірші.

Отримані результати свідчать про хорошу роботу мережі на нових даних, і можна говорити про конкурентоспроможність розробленого програмного застосунку на основі методів глибокого навчання та умовного випадкового поля.

Таблиця 3.1

Порівняння різних методів сегментації зображень судин сітківки

Methods	Accuracy	Sensitivity	Specificity	Dice
Human observer	0.9472	0.7761	-	-
Staal	0.9441	0.7194	-	-
Mendonca	0.9452	0.7344	-	-
Marin	0.9452	0.7067	-	-
Fraz	0.9480	0.7406	-	-
Nguyen	0.9407	0.7429	-	-
Zhao	0.9477	0.7354	-	-
Melinscak	0.9466	0.7276	-	-
Azzopardi	0.9442	0.7655	-	-
Roychowdhury	0.9494	0.7395	-	-
HED	0.9435	0.7364	-	-
DeepVessel w/o S	0.9335	0.7164	-	-
DeepVessel	0.9523	0.7603	-	-
LadderNet	0.9561	0.7856	0.9810	0.8202
IterNet	0.9574	0.7791	0.9831	0.8218
Hrychaniuk, Nosovets	0.9691	0.8341	0.9829	0.8259
Martsenyuk	-	0.7668	0.9879	0.8741
My model	0.9452	0.8991	0.9468	0.8247

3.10. Системні вимоги

Для коректної та безвідмовної роботи ПП для сегментації зображень судин сітківки ока персональний комп'ютер повинен бути з такими параметрами:

- Процесор не гірший, ніж Intel ® Pentium ® або з тактовою частотою не

меншою 1,8 Грц для AMD.

- Оперативна пам'ять не менше 4 Gb та графічне ядро не гірше, ніж Nvidia 210 GPU.
- Операційна система Windows 10, Windows 7.
- Повинен бути встановлений Python 3.6.
- 2 Gb і більше вільного місця на жорсткому диску для завантаження зображень та запуску програмного продукту.

При запуску навчання мережі, швидкість проходження навчання залежить від потужності комп'ютера. Для комп'ютерів меншої потужності, можливо, доведеться зменшити у процесі навчання кількість епох та кількість файлів, що будуть оброблятися одночасно, оскільки це залежить від об'єму відеопам'яті.

3.11. Функціонально-вартісний аналіз програмного застосунку призначеного для сегментації судин сітківки

Під час проходження переддипломної практики проведено оцінку основних характеристик програмного застосунку, який призначений для сегментації судин сітківки з використанням згорткової нейронної мережі. Програмний додаток може бути встановлений та використаний на комп'ютерах з операційними системами Windows, Linux та MacOS. Інтерфейс користувача програмного продукту створено за допомогою мови програмування Python з використанням архітектури нейронної мережі U-Net та бібліотеки Keras.

Аналіз різних варіантів реалізації програмного застосунку здійснювався з використанням апарату функціонально-вартісного аналізу (ФВА). Метою такого аналізу є вибір оптимального варіанту, враховуючи як економічні фактори, так і характеристики програмного продукту. Тобто, у нашому випадку проведено аналіз функцій розробленого програмного застосунку та виявлено усі витрати на їхню реалізацію.

Головною функцією є F_0 – розробка програмного застосунку, який сегментує судини сітківки за допомогою нейронної мережі для подальшого діагностування

офтальмологічної патології. Основними функціями програмного застосунку та варіанти їх реалізації є наступні:

F_1 – вибір однієї з мов програмування (А – мова Python; Б – мова C++);

F_2 – вибір бібліотек для машинного навчання (А - TensorFlow; Б – Keras);

F_3 – вибір архітектури нейронної мережі (А - DeepLabV3+; Б – U-Net).

Побудувавши морфологічну карту та позитивно-негативну матрицю варіантів основних функцій та проаналізувавши їх, розглянуто такі варіанти реалізації ПЗ:

– $F_1(A) - F_2(B) - F_3(A)$;

– $F_1(A) - F_2(B) - F_3(B)$.

Щоб оцінити якість представлених вище функцій було обрано такі параметри ПЗ, які будуть його характеризувати і потрібні для обчислення коефіцієнта технічного рівня. Далі із залученням експертів методом попарного порівняння визначається ступінь важливості кожного параметра для розробки програмного застосунку.

У підсумку, рівень якості кожного з варіантів реалізації ПЗ дорівнює:

$K_{K1} = 4,819$ (для варіанта $F_1(A) - F_2(B) - F_3(A)$) та

$K_{K2} = 4,923$ (для варіанта $F_1(A) - F_2(B) - F_3(B)$).

Згідно з проведеними розрахунками, кращим є другий варіант (хоч коефіцієнти технічного рівня відрізняються не сильно), для якого обчислений коефіцієнт технічного рівня має найбільше значення.

Вартість витрат для цього варіанта (в умовах воєнного стану) становить (детальні розрахунки подано у звіті з переддипломної практики):

$$C_{\text{ПП}} = 398277,94 \text{ грн.}$$

Коефіцієнт техніко-економічного рівня дорівнює:

$$K_{\text{ТЕР}} = \frac{K_K}{C_{\text{ПП}}} = \frac{4,923}{398277,94} = 1,236 \cdot 10^{-5}$$

Висновок до розділу 3

У розділі представлена архітектура та реалізація мережі U-net сегментації кровоносних судин сітківки. Програмний продукт реалізовано на основі бібліотек Keras та Tensorflow з використанням мови Python. Для покращення якості сегментації застосовано метод умовного випадкового поля CRF, що використовує інформацію про сусідні пікселі для визначення меж судин.

Також у розділі подано структуру розробленого програмного застосунку, описано основні етапи його роботи. Його протестовано на датасеті DRIVE, що є у вільному доступі та містить 40 зображень, для половини з яких застосовано аугментацію.

Крім того, наведені метрики, які отримано у результаті навчання мережі, а також метрики, що отримано після етапу прогнозування, тобто роботи підсистеми передбачення. Для оцінювання якості роботи обраного методу використовувались accuracy, precision, specificity, recall (sensitivity) та dice.

Також у розділі здійснено порівняння застосувань різних методів сегментації зображень судин сітківки. Отримані результати пояснюються хорошою роботою нейромережі в режимі передбачень та свідчать про конкурентоспроможність обраного методу.

Точність роботи розробленого програмного застосунку можна покращити шляхом навчання нейромережі на більшій кількості навчальних даних.

Таким чином, у результаті поєднання методів глибокого навчання та CRF можна отримати конкурентоспроможну модель для сегментації зображень судин сітківки, яку можна використати для автоматичної сегментації зображень судин великої бази даних зображень.

Загалом, удосконалення та використання нейромережевих технологій у галузі семантичної сегментації зображень є дуже перспективним напрямом досліджень, і ефективність подібних методів щороку буде збільшуватися.

Також у цьому розділі виконано функціонально-вартісний аналіз програмного застосунку, призначеного для сегментації судин сітківки з

використанням нейронної мережі. Беручи до уваги основні функції, які повинен виконувати створений програмний продукт, були визначені два найперспективніші варіанти його реалізації, з яких найбільш ефективним виявився другий варіант, оскільки для нього величина коефіцієнта техніко-економічного рівня є максимальною, вартість витрат для цього варіанта становить 398277,94 грн.

Оптимальний варіант реалізації ПЗ дає користувачу високу точність сегментації, прийнятний час навчання мережі та непоганий функціонал і передбачає використання мови програмування Python, бібліотеки Keras та архітектури нейронної мережі U-Net.

ЗАГАЛЬНІ ВИСНОВКИ

У сучасному світі комп'ютерних технологій з'являється все більше можливостей для застосування штучного інтелекту у медицині. Однією з важливих задач в діагностиці захворювань ока є сегментація зображень судин сітківки, яка є ключовим етапом у виявленні і лікуванні офтальмологічних захворювань.

Традиційні методи сегментації судин сітківки мають деякі недоліки, такі як недостатня точність, невелика швидкість та неспроможність працювати в великими масивами даних. Тому розробка програмного застосунку на основі методів машинного навчання є важливим для забезпечення точної та швидкої сегментації зображень судин сітківки.

Результати роботи

Під час виконання роботи було ознайомлено з методами сегментації медичних зображень; вивчено методи глибокого навчання та умовного випадкового поля і застосовано їх для розробки моделі сегментації зображень судин сітківки. Було оцінено основні характеристики програмного застосунку та визначено найефективніший варіант його реалізації. Також створено програмний застосунок на основі обраних методів для сегментації зображень судин сітківки ока. Проведено навчання нейронної мережі та проведено сегментацію зображень судин сітківки ока, для цього використано загальнодоступний набір даних DRIVE з відкритих джерел. У роботі зроблено порівняння застосованого методу сегментації з загальнодоступними методами-аналогами та експертними діагнозами та проаналізовано отримані результати.

Обговорення результатів роботи

Програмний застосунок реалізовано на основі бібліотек Keras та Tensorflow

з використанням мови Python та архітектури нейронної мережі U-Net. Для покращення якості сегментації застосовано метод умовного випадкового поля CRF. Створений програмний застосунок дає можливість користувачам сегментувати зображення, при цьому його ключовими перевагами є простий та інтуїтивно зрозумілий інтерфейс, використання новітніх алгоритмів та сучасного інструментарію розробки, застосування сучасних методів глибокого навчання та умовного випадкового поля, висока точність сегментації зображень.

Для оцінювання якості роботи програмного застосунку на основі обраних методів використовувались такі метрики: *accuracy*, *recall (sensitivity)*, *specificity* та *dice*, усереднені значення яких після сегментації загальнодоступного датасету зображень DRIVE дорівнюють 0.9452, 0.8991, 0.9468, 0.8247. Порівнюючи обчислені у роботі метрики з метриками для аналогічних методів сегментації зображень судин сітківки, доходимо висновку, що в деяких випадках ці метрики кращі, а в деяких – гірші. Отримані результати сегментації пояснюються хорошою роботою нейромережі в режимі передбачень та свідчать про конкурентоспроможність розробленого програмного застосунку на основі обраних методів. Точність роботи розробленого програмного застосунку можна покращити шляхом навчання нейромережі на більшій кількості навчальних даних.

Висновки

Отже, під час виконання роботи вирішено всі поставлені завдання і, таким чином, досягнуто мету – розроблено програмний застосунок для сегментації зображень судин сітківки ока за допомогою глибокого навчання.

Результати роботи можна використати у медичній галузі для розробки нових методів діагностики офтальмологічних захворювань, що спростить роботу фахівців та дозволить зменшити витрати на діагностику внаслідок автоматизації діагностування патологій ока.

Загалом, удосконалення та використання нейромережевих технологій у

галузі семантичної сегментації зображень є дуже перспективним напрямом досліджень, і ефективність подібних методів щороку буде збільшуватися.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Linda G. Shapiro and George C. Stockman. Computer Vision. New Jersey: Prentice-Hall, 2001. 608 p. (pp. 279–325).
2. Haralick R.M, Shapiro L.G. Image Segmentation Techniques. *Computer Vision, Graphics and Image Processing*. 1985. Vol. 29. P. 100-132.
3. Fu K., Mui J. A survey on image segmentation. *Pattern Recognition*. 1981. Vol. 13. P. 3 - 16.
4. Pal N., Pal S. A survey on image segmentation techniques. *Pattern Recognition*. 1993. Vol. 26. P. 1277 - 1294.
5. Skarbek W., Koschan A. Color Image Segmentation - A Survey. *Technischer Bericht: Technical University of Berlin*. 1994. P. 94 - 32.
6. Lucchese L., Mitra S. Color Image Segmentation: A State-of-the-Art Survey, Image Processing, Vision, and Pattern Recognition. Proc. of the Indian National Science Academy (INSA-A). New Delhi, India: CRC, 2001. P. 207 - 221.
7. Zhang Y. Advances in Image And Video Segmentation. USA: IRM Press, 2006. 457 p.
8. Березький О.М., Мельник Г.М., Батько Ю.М. Методи сегментації біомедичних зображень. *Вісник Хмельницького національного університету. Технічні науки*. 2010. №1. С. 251 - 258.
9. Forsyth D. A., Ponce J. Computer Vision: A Modern Approach. Pearson, 2nd edition, 2011. 800 p.
10. Gonzalez R. C., Woods R. E. Digital Image Processing. Цифровая обработка изображений. New York: Pearson, 2018. 1022 с. **URL:** <https://dl.icdst.org/pdfs/files4/01c56e081202b62bd7d3b4f8545775fb.pdf/>
11. McCulloch Warren; Walter Pitts. A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*. 1943. 5 (4). P. 115 – 133. **DOI:10.1007/BF02478259/**
12. Rosenblatt, F. The Perceptron: A Probabilistic Model For Information Storage

- And Organization In The Brain. *Psychological Review*. 1958. 65 (6). P. 386 –408. **DOI:10.1037/h0042519/**
13. Le Hou, Dimitris Samaras, Tahsin M. Kurc. Patch-Based Convolutional Neural Network for Whole Slide Tissue Image Classification. *Proc. IEEE Conference on Computer Vision and Pattern Recognition*. 2016. P. 2424 – 2433. **DOI: 10.1109/CVPR.2016.266/**
 14. Jonathan Long, Evan Shelhamer, Trevor Darrell. Fully Convolutional Networks for Semantic Segmentation. *Computer Vision and Pattern Recognition*. 2015. **DOI: 10.48550/arXiv.1411.4038/**
 15. Nguyen U.T., Bhuiyan A., Park L.A., Ramamohanarao K. An effective retinal blood vessel segmentation method using multi-scale line detection. *Pattern Recognition*. 2013. Vol. 46. Issue 3. P.703 – 715. **DOI: 10.1016/j.patcog.2012.08.009/**
 16. Ricci, E., Perfetti, R. Retinal blood vessel segmentation using line operators and support vector classification. *IEEE Transactions On Medical Imaging*. 2007. Vol. 26. N 10. P. 1357 – 1365. **DOI: 10.1109/TMI.2007.898551/**
 17. Fraz M.M., Remagnino P., Hoppe A., Uyyanonvara B., Rudnicka A.R., Owen C.G., Barman S.A. Blood vessel segmentation methodologies in retinal images - A survey. *Computer Methods and Programs in Biomedicine*. 2012. Vol.108, Issue 1, P. 407 – 433. **DOI: 10.1016/j.cmpb.2012.03.009/**
 18. Soares J.V., Leandro J.J., Cesar R.M., Jelinek H.F., Cree M.J. Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification. *IEEE Transactions On Medical Imaging*. 2006. Vol. 25(9). P. 1214 – 1222. **DOI: 10.1109/tmi.2006.879967/**
 19. Zhang B., Zhang L., Zhang L., Karray, F. Retinal vessel extraction by matched filter with first-order derivative of gaussian. *Comput. Biol. Med.* 2010. Vol. 40(4). P. 438 – 445. **DOI: 10.1016/j.combiomed.2010.02.008/**
 20. Orlando J., Blaschko M. Learning fully-connected CRFs for blood vessel segmentation in retinal images. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2014. Vol. 8673. P. 634 – 641. **DOI:10.1007/978-3-319-**

10404-1_79/

21. Becker C., Rigamonti R., Lepetit V., Fua P. Supervised feature learning for curvilinear structure segmentation. *MICCAI*. 2013. Vol. 8149. P. 526 – 533. **DOI: 10.1007/978-3-642-40811-3 66/**
22. Gu L., Cheng L. Learning to boost filamentary structure segmentation. *IEEE International Conference on Computer Vision (ICCV): Proc. of the Conf.*, 2015. P. 639 – 647. **URL: https://www.ece.ualberta.ca/~lcheng5/papers/GuChe_ICCV15.pdf/**
23. Sironi A., Lepetit V., Fua P. Projection onto the manifold of elongated structures for accurate extraction. *IEEE International Conference on Computer Vision (ICCV): Proc. of the Conf.*, 2015. P. 316 – 324. **URL: https://openaccess.thecvf.com/content_iccv_2015/html/Sironi_Projection_onto_the_ICCV_2015_paper.html/**
24. Cheng J. et al. Superpixel Classification Based Optic Cup Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2013. Vol. 8151. P. 421–428. **DOI: 10.1007/978-3-642-40760-4_53/**
25. Krizhevsky A., Sutskever I., Hinton G.E. Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25 (NIPS)*. 2012. **URL: https://papers.nips.cc/paper_files/paper/2012/**
26. Ganin Y., Lempitsky V. N4-fields: neural network nearest neighbor fields for image transforms. *ACCV*. 2014. **DOI: 10.48550/arXiv.1406.6558/**
27. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2015. Vol 9351. P. 234 – 241. **DOI: 10.1007/978-3-319-24574-4_28**
28. Xiao X., Lian S., Luo Z., Weighted Res-UNet for highquality retina vessel segmentation. *9th Int. Conf. Inf. Technol. Med. Educ. (ITME): Proc. Of Conf.*, 2018. **URL: <https://ieeexplore.ieee.org/abstract/document/8589312/>**
29. Gao X., Cai Y., Qiu C. Retinal blood vessel segmentation based on the Gaussian matched filter and U-net. *CISP-BMEI*, 2017. **URL:**

<https://ieeexplore.ieee.org/abstract/document/8302199>.

30. Martsenyuk V., Milian N., Milian R. The Minimax Approach Application For Segmentation Of Retinal Vessels. *Innovative Solutions in Modern Science*. 2020. Vol. 7(43). **DOI: 10.26886/2414-634X.7(43)2020.13**
31. Гричанюк І.О., Носовець О.К. Навчання нейронної мережі для сегментації судин сітківки за допомогою зашумлених міток. *Розвиток наукових міжгалузевих досліджень: зб. матер. конф.* 26-27 лист. 2021р. Вінниця, 2021. с.73 - 76.
32. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. 2015. **URL:** [arXiv:1511.00561\[cs.CV\]](https://arxiv.org/abs/1511.00561)
33. Sik-Ho Tsang. Review: FC-DenseNet — One Hundred Layers Tiramisu, Fully Convolutional DenseNet (Semantic Segmentation). **URL:** <https://towardsdatascience.com/review-fc-densenet-one-hundred-layer-tiramisu-semantic-segmentation-22ee3be434d5/>
34. Lin G., Milan A., Shen Ch., Reid I. RefineNet: Multi-path refinement networks for high-resolution semantic segmentation. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR): Proc. of.conf.*, 2016. P. 5168 - 5177. **DOI: 10.48550/arXiv.1611.06612/**
35. Hengshuan Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, Jiaya Jia Pyramid Scene Parsing Network. *arXiv:1612.01105v2 [cs.CV]* 27 Apr 2017. **URL:** <https://arxiv.org/pdf/1612.01105.pdf/>
36. Chaurasia A., Culurciello E. LinkNet: Exploiting encoder representations for efficient semantic segmentation. *IEEE Visual Communications and Image Processing (VCIP)*. 2017. **DOI: 10.1109/VCIP.2017.8305148/**
37. Paszke A., Chaurasia A., Kim S., Culurciello E. ENet: a Deep Neural Network Architecture for Real-Time Semantic Segmentation. *5th International Conference on Learning Representations: Proc. of Conf. Toulon, France*, 2017. P. 1–10. **DOI: 10.48550/arXiv.1606.02147/**
38. Chen L., Papandreou G., Kokkinos I., Murphy K., Yuille A. L. DeepLab:

- Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2018. Vol. 40, N. 4, P. 834–848. **DOI** **10.1109/TPAMI.2017.2699184**
39. Lafferty J., McCallum A., Pereira F. *18th International Conference on Machine Learning*: Proc. of Conf. San Francisco, CA, USA, 2001. Morgan Kaufmann Publishers Inc. P. 282 - 289. **URL**: <http://dl.acm.org/citation.cfm?id=645530.655813/>
40. Settles B. Biomedical named entity recognition using conditional random fields and rich feature sets. *Proceedings of the International Joint Workshop on Natural Language Processing in Biomedicine and its Applications*. Geneva, Switzerland, 2004. P. 104 – 107. **URL**: <https://aclanthology.org/W04-1221/>
41. Chang K.Y., Lin T.P., Shih L.Y., Wang C.K. Analysis and prediction of the critical regions of antimicrobial peptides based on conditional random fields. *PLoS One*. Mar. 24, 10(3): e0119490. 2015. **DOI**: **10.1371/journal.pone.0119490/**
42. Гричанюк І.О., Носовець О.К. Аналіз методів аугментації даних для задач сегментації судин сітківки. *Young Scientist*. № 10 (98). 2021. **DOI**: **10.32839/2304-5809/2021-10-98-23/**
43. Батько. Ю.М. Метод і алгоритми сегментації біомедичних зображень на основі попередніх розміток. *Штучний інтелект*. 2010. N 4.
44. Глушков Г.А. Комп'ютерна графіка. Харків: Фоліо, 2000. 500 с
45. David Martin Ward Powers. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*. 2011. Vol. 2 (1). P. 37 – 63. **DOI**: **10.9735/2229-3981/**
46. Метрики в машинному навчанні: precision, recall і не тільки. Веб-сайт. **URL**: <http://www.michurin.net/computer-science/ml-precision-recall.html/>
47. Staal J., Abramoff M. and all. Ridge- based vessel segmentation in color images of the retina. *IEEE Trans. Med. Imaging*. 2004. Vol. 23 (4). P. 501 – 509. **DOI**: **10.1109/TMI.2004.825627/**
48. Mendonca A., Campilho A. Segmentation of retinal blood vessels by

- combining the detection of centerlines and morphological reconstruction. *IEEE Trans. Med. Imaging*. 2006. Vol. 25 (9), P. 1200 – 1213. **DOI: 10.1109/tmi.2006.879955/**
49. Marin D, Aquino A., Gegundez M. E., Bravo J. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. *IEEE Trans. Med. Imaging*. 2011. Vol. 30(1). P. 146 – 158. **DOI: 10.1109/TMI.2010.2064333**
50. Fraz M., Remagnino P., Hoppe A., Uyyanonvara B., Rudnicka A., Owen C., Barman S. An ensemble classification-based approach applied to retinal blood vessel segmentation. *IEEE Trans. Biomed. Eng.* 2012. Vol. 59(9), P. 2538 – 2548. **DOI: 10.1109/TBME.2012.2205687/**
51. Nguyen U., Bhuiyan A., Park L., Ramamohanarao K. An effective retinal blood vessel segmentation method using multi-scale line detection. *Pattern Recogn.* 2013. Vol. 46 (3). P. 703 – 715. **DOI: 10.1016/j.patcog.2012.08.009**
52. Zhao Y., Wang X., Wang X., Shih F. Retinal vessels segmentation based on level set and region growing. *Pattern Recogn.* 2014. Vol. 47 (7), P. 2437–2446. **DOI: 10.1016/j.patcog.2014.01.006**
53. Melinscak M., Prentasic P., Loncaric S. Retinal vessel segmentation using deep neural networks. *International Conference on Computer Vision Theory and Applications: Proc. of Conf.*, 2015. P. 577–582. **DOI: 10.5220/0005313005770582/**
54. Azzopardi G., Strisciuglio N., Vento M., Petkov N. Trainable COSFIRE filters for vessel delineation with application to retinal images. *Med. Image Anal.* 2015. Vol. 19 (1), P. 46–57. **DOI: 10.1016/j.media.2014.08.002/**
55. Roychowdhury S., Koozekanani D., Parhi K.: Iterative vessel segmentation of fundus images. *IEEE Trans. Biomed. Eng.* 2015. Vol. 62 (7), P. 1738–1749. **DOI: 10.1109/TBME.2015.2403295/**

- 56.Xie S., Tu Z. Holistically-nested edge detection. Int. Conf. on Computer Vision (ICCV 2015): Proc. of. Conf., 2015. P. 1395–1403. **URL:** https://openaccess.thecvf.com/content_iccv_2015/html/Xie_Holistically-Nested_Edge_Detection_ICCV_2015_paper.html/
- 57.Fu H., Xu Y., Lin S., Kee Wong D.W., Liu J. DeepVessel: Retinal Vessel Segmentation via Deep Learning and Conditional Random Field. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2016. **Vol. 9901**. **DOI: 10.1007/978-3-319-46723-8_16/**