

Сегментація судин сітківки на зображеннях очного дна із застосуванням U-Net

Вінницький національний технічний університет

Анотація. Розглянуто застосування згорткової нейронної мережі U-Net для автоматичної сегментації судин на зображеннях очного дна. Проаналізовано архітектуру U-Net та продемонстровано результати її роботи на прикладі набору даних HRF.

Ключові слова: U-Net, сегментація судин, очне дно, фундус-фотографія, глибоке навчання, HRF, коефіцієнт Дайса(Dice), індекс Жаккара(IoU).

Вступ

Рання діагностика захворювань сітківки відіграє вирішальну роль у збереженні зору пацієнтів. Аналіз стану судин сітківки на цифрових зображеннях очного дна є важливим інструментом для виявлення та моніторингу таких захворювань як діабетична ретинопатія, глаукома, вікова макулярна дегенерація. Зміни у морфології судин, такі як мікроаневризми, крововиливи та зміни діаметру судин, можуть бути ранніми ознаками патологічних процесів [1]. Традиційно сегментація судин на фундус-фотографіях виконується офтальмологами вручну, що є трудомістким та тривалим у часі процесом, залежним від кваліфікації лікаря. Тому розробка автоматизованих методів сегментації судин сітківки є актуальною задачею, що має велике практичне значення для покращення якості та доступності офтальмологічної допомоги [2].

Останніми роками значний прогрес у галузі комп'ютерного зору та машинного навчання, зокрема глибокого навчання, відкрив нові можливості для автоматизації аналізу медичних зображень. Згорткові нейронні мережі (ЗНМ) продемонстрували високу ефективність у вирішенні задач сегментації зображень, у тому числі медичних. Однією з найуспішніших архітектур ЗНМ для сегментації біомедичних зображень є U-Net [3], яка завдяки своїй U-подібній формі та використанню skip connections здатна ефективно поєднувати локальний та глобальний контексти зображення, що є особливо важливим для точного виділення тонких структур, таких як судини сітківки.

Метою даної роботи є дослідження можливості застосування згорткової нейронної мережі U-Net для автоматичної сегментації судин сітківки на цифрових зображеннях очного дна. Для досягнення цієї мети було реалізовано та навчено модель U-Net на відкритому наборі даних HRF [4]. Оцінка ефективності сегментації проводилася з використанням стандартних метрик, таких як коефіцієнт Дайса та індекс Жаккара (IoU). Результати дослідження мають практичне значення для розробки систем підтримки прийняття рішень в офтальмології, що може сприяти підвищенню точності та швидкості діагностики захворювань сітківки.

Застосування U-Net для сегментації судин сітківки на зображеннях очного дна

Для дослідження можливостей автоматичної сегментації судин сітківки за допомогою U-Net було використано набір даних High-Resolution Fundus (HRF) image database [4]. Цей набір містить 45 зображень з розширенням 3504×2336 пікселів, для кожного з яких вручну створено маску сегментації судин експертами.

Для реалізації архітектури U-Net було використано мову програмування Python та бібліотеку Keras з TensorFlow [5]. Блок схему алгоритму програми зображено на рисунку 1.

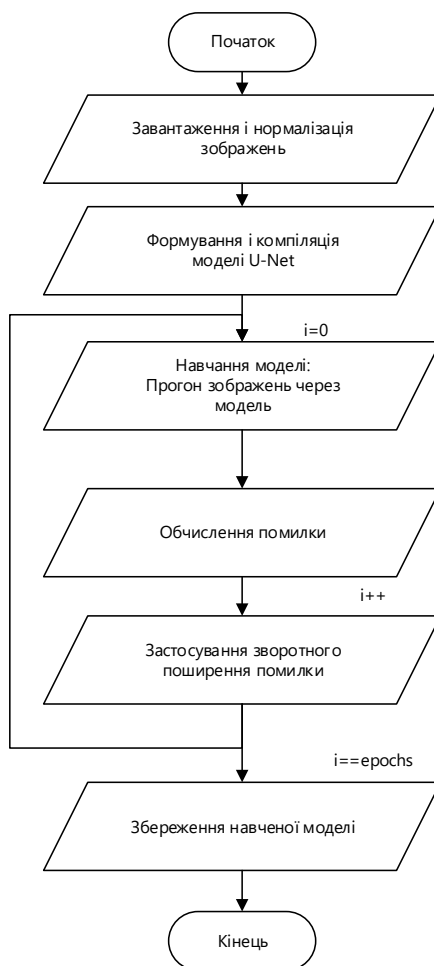


Рисунок 1 – Блок схема алгоритму

Алгоритм сегментації зображень за допомогою нейронної мережі U-Net включає кілька основних етапів: підготовку даних, побудову та навчання моделі. На першому етапі виконується завантаження зображень та відповідних масок, їх масштабування та розбиття на навчальний і валідаційний набори. Далі формується архітектура мережі U-Net, що складається з етапів кодування, компресії ознак (Bottleneck) та декодування. На етапі кодування вхідне зображення поступово згортається за допомогою згорткових шарів, зменшуючи просторові розміри, але збільшуючи кількість каналів(глибину), виділяючи важливі ознаки на різних рівнях абстракції. Компресія ознак представляє собою найнижчий рівень роздільної здатності з найбільшою кількістю каналів ознак, цей процес зберігає найбільш стислу інформацію про зображення. На етапі декодування відбувається поступове відновлення просторових розмірів за допомогою операцій згорткової транспозиції (upsampling) та конкатенації з відповідними ознаками з етапу кодування (skip connections), що дозволяє точно відновити деталі та локалізацію, втрачені під час стиснення, комбінуючи високо- і низькорівневі ознаки для точної сегментації. Приклад реалізації архітектури моделі мовою програмування Python показано на рисунку 2.

```

37 # Функція для створення моделі U-Net
38 def unet_model(input_size):
39     inputs = Input(input_size)
40
41     # Encoder
42     c1 = Conv2D(64, (3, 3), activation='relu', padding='same')(inputs)
43     c1 = BatchNormalization()(c1)
44     p1 = MaxPooling2D((2, 2))(c1)
45
46     c2 = Conv2D(128, (3, 3), activation='relu', padding='same')(p1)
47     c2 = BatchNormalization()(c2)
48     p2 = MaxPooling2D((2, 2))(c2)
49
50     c3 = Conv2D(256, (3, 3), activation='relu', padding='same')(p2)
51     c3 = BatchNormalization()(c3)
52     p3 = MaxPooling2D((2, 2))(c3)
53
54     c4 = Conv2D(512, (3, 3), activation='relu', padding='same')(p3)
55     c4 = BatchNormalization()(c4)
56     p4 = MaxPooling2D((2, 2))(c4)
57
58     # Bottleneck
59     c5 = Conv2D(1024, (3, 3), activation='relu', padding='same')(p4)
60     c5 = BatchNormalization()(c5)
61
62     # Decoder
63     u6 = Conv2DTranspose(512, (2, 2), strides=(2, 2), padding='same')(c5)
64     u6 = concatenate([u6, c4])
65     c6 = Conv2D(512, (3, 3), activation='relu', padding='same')(u6)
66     c6 = BatchNormalization()(c6)
67
68     u7 = Conv2DTranspose(256, (2, 2), strides=(2, 2), padding='same')(c6)
69     u7 = concatenate([u7, c3])
70     c7 = Conv2D(256, (3, 3), activation='relu', padding='same')(u7)
71     c7 = BatchNormalization()(c7)
72
73     u8 = Conv2DTranspose(128, (2, 2), strides=(2, 2), padding='same')(c7)
74     u8 = concatenate([u8, c2])
75     c8 = Conv2D(128, (3, 3), activation='relu', padding='same')(u8)
76     c8 = BatchNormalization()(c8)
77
78     u9 = Conv2DTranspose(64, (2, 2), strides=(2, 2), padding='same')(c8)
79     u9 = concatenate([u9, c1])
80     c9 = Conv2D(64, (3, 3), activation='relu', padding='same')(u9)
81     c9 = BatchNormalization()(c9)
82
83     outputs = Conv2D(1, (1, 1), activation='sigmoid')(c9)
84
85     return Model(inputs, outputs)
86

```

Рисунок 2 – Функція створення моделі U-Net

Навчання здійснюється за допомогою алгоритму зворотного поширення помилки, де модель ітеративно оновлює свої ваги на основі обчисленої функції втрат. Як функцію втрат було обрано бінарну перехресну ентропію (binary cross-entropy), яка є стандартним вибором для бінарної сегментації[3], де кожен піксель потрібно класифікувати як належний або не належний до певного класу (в даному випадку, чи є піксель частиною судини, чи ні). Вона вимірює "відстань" між прогнозованим розподілом ймовірностей (числами від 0 до 1, які видає останній шар моделі з активацією sigmoid) та істинними мітками (0 або 1).

Математична формула (для одного пікселя):

$$L = -[y \cdot \log(p) + (1 - y) \cdot \log(1 - p)] \quad (1)$$

де y – істинна мітка (0 або 1), p – прогнозована ймовірність (число від 0 до 1).

Для всього зображення функція втрат усереднюється за усіма пікселями. Числове значення функції втрат бінарної перехресної ентропії теоретично може бути будь-яким невід'ємним числом (від 0 до нескінченності), де менше значення вказує на меншу розбіжність між прогнозованими ймовірностями та істинними мітками, а отже, на кращу якість моделі.

Процес навчання триває до досягнення заданої кількості епох або критерію зупинки. Навчання проводилося протягом 160 циклів (епох) з розміром пакету (batch size) 8 рядків. Графік зміни функції втрат, зображений на рисунку 3, демонструє зменшення як Training Loss, так і Validation Loss зі збільшенням кількості навчальних циклів. Training Loss відображає помилку моделі на навчальному наборі даних, а Validation Loss – помилку на валідаційному наборі, який не використовувався для навчання. Зменшення обох показників свідчить про те, що модель успішно навчається, покращуючи свою здатність до сегментації, і при цьому узагальнює свої знання на нові дані. Після завершення навчання модель зберігається для подальшого використання у задачах сегментації медичних зображень.

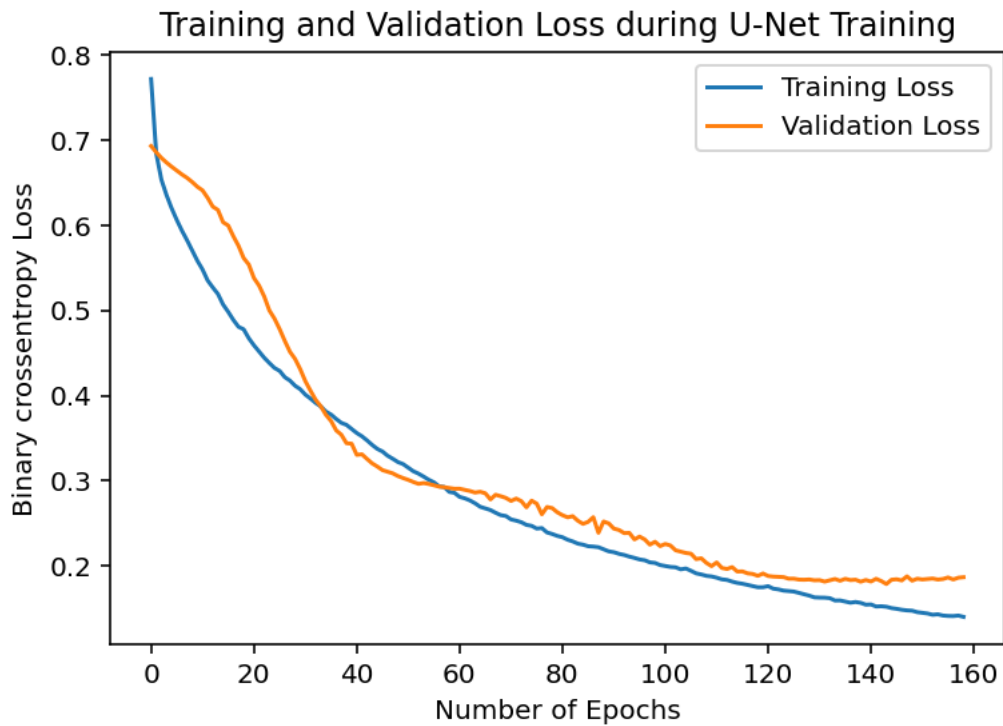



Рисунок 3 – Графік зміни функції втрат від циклів навчального процесу

Для оцінки якості роботи навченої моделі було використано одне зображення з набору даних HRF, яке не входило до навчальної вибірки. На рисунку 4 представлено оригінальне зображення з набору даних HRF, відповідна йому істинна маска сегментації, створена експертами, та передбачена маска навченою мережею U-Net.



а) Вхідне зображення

б) Істинна маска

в) Передбачена маска

Рисунок 4 – Приклади зображень

Для кількісної оцінки точності сегментації було розраховано коефіцієнт Дайса (Dice) та індекс Жаккара (IoU), які визначаються наступними формулами:

$$Dice = \frac{2 \cdot |A \cap B|}{|A| + |B|} \quad (2)$$

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (3)$$

де A - множина пікселів істинної маски, B - множина пікселів передбаченої маски, \cap - операція перетину множин, \cup - операція об'єднання множин.

В результаті обчислень було отримано наступні значення метрик: $Dice = 0.5644$, $IoU = 0.3931$.

Аналізуючи отримані результати сегментації, можна зробити наступні висновки. Візуальний аналіз передбаченої маски показує, що модель U-Net загалом коректно виділяє основні судини сітківки, що помітні на оригінальному зображенні та істинній масці. Проте, спостерігаються певні неточності у сегментації дрібних судин, особливо на периферії зображення, де контрастність між судинами та фоном є низькою. Кількісна оцінка, виконана за допомогою метрик Dice та IoU, підтверджує ці спостереження. Отримані значення Dice = 0.5644 та IoU = 0.3931 є відносно невисокими і вказують на наявність значної кількості як хибно-позитивних, так і хибно-негативних результатів сегментації. Це може бути пов'язано з обмеженим розміром навчальної вибірки, складністю самого зображення, а також з потребою подальшої оптимізації архітектури U-Net. На відміну від попередніх досліджень, де було проведено порівняльний аналіз різних методів сегментації [6], даний підхід на основі U-Net демонструє вищу точність, незважаючи на певні обмеження. Отримані результати демонструють принципову можливість застосування U-Net для автоматичної сегментації судин сітківки, хоча й потребують подальшого вдосконалення для досягнення клінічно прийнятної точності.

Висновок

Отримані результати свідчать про перспективність використання U-Net для автоматизованої сегментації судин сітківки, проте підкреслюють необхідність подальшого вдосконалення моделі та алгоритму її реалізації. Подальші дослідження можуть бути спрямовані на оптимізацію архітектури U-Net, а також на використання більшого та різноманітнішого набору даних для навчання. Крім того, перспективним є подальше удосконалення методів сегментації медичних зображень із застосуванням сукупностей моделей на основі інших типів ЗНМ. Успішне вирішення таких завдань дозволить розробити надійний інструмент для автоматизованого аналізу зображень очного дна, що може знайти широке застосування в системах підтримки прийняття рішень в офтальмологічній діагностиці та моніторингу захворювань сітківки.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Yau JW, Rogers SL, Kawasaki R, et al. Global prevalence and major risk factors of diabetic retinopathy. *Diabetes Care*. 2012;35(3):556-564. <https://doi.org/10.2337/dc11-1909>
2. Fraz, M. M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A. R., Owen, C. G., & Barman, S. A. (2012). An ensemble classification-based approach applied to retinal blood vessel segmentation. *IEEE Transactions on Biomedical Engineering*, 59(9), 2538-2548. <https://pub.ncbi.nlm.nih.gov/articles/PMC3322721/>
3. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28
4. Dataset Ninja. Visualization Tools for High Resolution Fundus Dataset. Dataset Ninja; 2025. Accessed February 10, 2025. <https://datasetninja.com/high-resolution-fundus>
5. TensorFlow Developers. (n.d.). Keras: The Python deep learning API. TensorFlow. Retrieved February 11, 2025, from <https://www.tensorflow.org/guide/keras>
6. Андрікевич, С. і Тужанський, С. 2024. Методи сегментації оптичних зображень очного дна. *Оптико-електронні інформаційно-енергетичні технології*. 47, 1 (Лип 2024), 155–165. DOI: <https://doi.org/10.31649/1681-7893-2024-47-1-155-165>.

Андрікевич Сергій Анатолійович - аспірант кафедри біомедичної інженерії, Вінницького національного технічного університету, м. Вінниця, andrikevuch.serhii@gmail.com.

Тужанський Станіслав Євгенович – к.т.н, доцент кафедри біомедичної інженерії та оптико-електронних систем, Вінницький національний технічний університет, slavat@vntu.edu.ua.

APPLICATION OF U-NET FOR RETINAL VESSEL SEGMENTATION IN FUNDUS IMAGES

Abstract. *The application of the convolutional neural network U-Net for automatic vessel segmentation in fundus images is considered. The architecture of U-Net is analyzed and the results of its operation are demonstrated using the HRF dataset as an example.*

Keywords: vesselsegmentation, fundus, fundus photography, deep learning, HRF, Dice coefficient, Jacquard index (IoU).

Andrikevych Serhii Anatoliiovych - Postgraduate student, Department of Biomedical Engineering, Vinnytsia National Technical University, Vinnytsia, andrikevuch.serhii@gmail.com.

Tuzhanskyi Stanislav Yevhenovych - Candidate of Technical Sciences, Associate Professor, Department of Biomedical Engineering and Optoelectronic Systems, Vinnytsia National Technical University, slavat@vntu.edu.ua.