

DOI 10.26886/2414-634X.7(43)2020.13

UDC: 004.932.2

**THE MINIMAX APPROACH APPLICATION FOR SEGMENTATION OF
RETINAL VESSELS**

V. Martsenyuk, Dr., Prof.

<https://orcid.org/0000-0001-5622-1038>

e-mail: vmartsenyuk@ath.bielsko.pl

University of Bielsko-Biala, Poland, Bielsko-Biala

N. Milian, Postgraduate student

<https://orcid.org/0000-0003-0825-1384>

e-mail: nazar.milyan@gmail.com

Ternopil Ivan Puluuj National Technical University, Ukraine, Ternopil

R. Milian, Postgraduate student

<https://orcid.org/0000-0003-4568-2845>

e-mail: roksolana.milian@gmail.com

Ternopil Volodymyr Hnatiuk National Pedagogical University, Ukraine,
Ternopil

The paper presents the results of work neural network for segmentation of the fundus vessels using the Tensorflow machine learning library. Training and testing takes place on the public DRIVE data set. The results of work model, namely the recognized blood vessels are presented.

When considering binary cross-entropy as an indicator of efficiency, which is demonstrated in the article, it was determined that the U-Net model with 8x8 tiles is a solution to the problem of minimax ML. In the first step, the value of the loss function is compared for all considered models. In the second step, it is determined that the value of binary cross-entropy for the U-Net model with 8x8 tiles will be the minimum among the maximum characteristics.

When considering training time as an indicator of efficiency, as shown in the relevant table, the U-Net model with 25x25 tiles is a solution to the minimax ML problem. In the first step, we first compare the values of the training time of all the models under consideration. In the second step, it is determined that the time value for the U-Net model with 25x25 tiles will be the minimum among the maximum values.

Keywords: retinal vessels segmentation, neural network, machine learning, minimax approach, machine learning library.

Доктор технічних наук, професор Марценюк В. П., аспірант Мілян Н. В., аспірант Мілян Р. С., Застосування мінімаксного підходу для сегментації судин сітківки/ Університет Бельсько-Бяла, Польща, Бельсько-Бяла, Тернопільський національний технічний університет імені Івана Пулюя, Тернопіль, Україна, Тернопільський національний педагогічний університет імені Володимира Гнатюка, Україна, Тернопіль.

У роботі представлені результати роботи нейронної мережі для сегментації судин очного дна з використанням бібліотеки машинного навчання Tensorflow. Навчання і тестування відбувається на загальнодоступному наборі даних DRIVE. Результати роботи моделі, а саме розпізнані кровоносні судини є представлені.

*При розгляді бінарної крос-ентропії як показника ефективності, що є продемонстровано у статті, визначено, що модель U-Net з плитками 8x8 є рішенням проблеми *minimax ML*. На першому кроці, відбувається порівняння значення функції втрат для всіх розглянутих моделей. На другому кроці визначено, що значення бінарної крос-ентропії для моделі U-Net з плитками 8x8 буде мінімальним серед максимальних характеристик.*

При розгляді часу навчання як показником ефективності, що продемонстровано у відповідній таблиці, модель U-Net з плитками

25x25 є рішенням проблеми *minimax ML*. На першому кроці, спочатку відбувається порівняння значення часу тренування всіх моделей, що розглядаються. На другому кроці визначено, що значення часу для моделі U-Net з плитками 25x25 буде мінімальним серед максимальних показників.

Ключові слова: сегментація судин сітківки, нейронна мережа, машинне навчання, мінімаксни́й підхід, бібліотека машинного навчання.

Постановка проблеми. Кровоносні судини сітківки містять значну інформацію, що стосується здоров'я людини. Спостереження за морфологічною структурою судин сітківки на знімках очного дна використовується не тільки для скринінгу судинних захворювань сітківки, але і для допоміжної діагностики інших захворювань, таких як інсульт [3], гіпертонія [11], індукована діабетом ретинопатія [7] та глаукоми [6]. Зображення очного дна мають такі характеристики: низький контраст між судиною та фоном, серйозні втручання в зону ураження та складна судинна структура, що створює багато проблем для досягнення сегментації судин сітківки [1]. В даний час основним методом сегментації судин сітківки є ручна анотація професійними лікарями.

Основна ідея алгоритмів навчання з вчителем полягає у навчанні моделі сегментації із використанням зображень очного дна з анотаціями сегментації, що дозволяють моделі автоматично витягувати особливості судин для досягнення сегментації судин, наприклад, алгоритми на основі моделі Байєса [5], підтримують векторну машину на основі алгоритмів [4] та алгоритмів глибокого навчання [9], [2], [12], [10]. Однак алгоритми навчання з вчителем вимагають величезних даних із ручним маркуванням, які важко

отримати.

Серед алгоритмів сегментації на основі FCN структура U-net, запропонована Ronneberger [8], змінила метод підключення переходу на карту функцій у FCN з додавання на конкатенат, який широко використовується в галузі сегментації біомедичних зображень. Крім того, для сегментації судин сітківки з'явилася велика кількість вдосконалених алгоритмів, заснованих на U-Net. Наприклад, у [14] пропонують модель на основі U-мережі із зваженим затвором уваги для сегментації малих судин сітківки. У [13] поєднують фільтрування за Гаусом та U-Net для досягнення сегментації судин сітківки.

Формулювання мети статті та задач. Мета дослідження: розвиток методів глибокого машинного навчання в умовах невизначеності з використанням мінімаксного підходу.

Задачі дослідження: Реалізація моделі U-Net для сегментації судин очного дна, застосування мінімаксного підходу для оцінки одержаних результатів.

Виклад основного матеріалу. Порівнюючи різні моделі ML, метою машинного навчання є мінімізація очікуваних втрат. Але також потрібно взяти до уваги стратегії передискретизації, за якими також повинні оцінювати функцію втрат. Таке формулювання проблеми ML розглядає два види невизначеності. А саме, невизначеність у передискретизації є алеаторичною, оскільки вона пов'язана з даними. У той же час невизначеність при виборі моделей є епістемічною. Математично мінімальна задача ML описується як пошук моделі h завдяки

$$\arg \min_{h \in \Psi} \max_{\gamma \in \Gamma} E[L(Y, h(X, \gamma))] \quad (1)$$

Нижче представлено реалізація простої U-net моделі для сегментації кровоносних судин сітківки. Модель реалізовано на основі

бібліотек Keras та Tensorflow. Метод протестовано на загальнодоступному наборі даних DRIVE, що складається з 40 зображень. Для завдань прогнозування використовували крос-валідацію як одну зі стратегій передискретизації. Стратегії передискретизації включають cv3, cv5, cv7, cv9.

Для нормалізації зображень використовується контрастне обмежене адаптивне вирівнювання гистограми (CLAHE). При цьому зображення ділиться на невеликі блоки, які називаються "плитками" (за замовчуванням tileSize становить 8x8 у OpenCV). Потім кожен із цих блоків вирівнюється. Отже, на невеликій ділянці гистограма обмежується лише невеликою областю (якщо немає шуму). Якщо шум є, він буде посилений. Щоб уникнути цього, застосовується обмеження контрасту. Якщо перевищено вказану межу контрастності (за замовчуванням 40 у OpenCV), ці пікселі відсікаються та розподіляються рівномірно в інші контейнери перед тим, як застосувати вирівнювання гистограми. Після вирівнювання для видалення артефактів у межах плитки застосовується білінійна інтерполяція. Застосовуємо гамма-корекцію за допомогою таблиці пошуку.

Для нормалізації зображення було поділено на 8x8, 16x16, 25x25, 40x40 плиток. Використовували оптимізатор Адама з `initial_learning_rate=0.0003`, `first_decay_steps=12000`, `t_mul=1000`, `m_mul=0.5`, `alpha=1e-5`.

Для оцінки методу використовуємо точність (Precision), повноту (Recall), матрицю помилок (Confusion matrix), площу під кривою помилок (Receiver Operating Characteristic Curve (AUC-ROC)) (Рис.1, Рис.2).

```
print("average dice score for all predict vessel masks:",np.mean(dice_list))
print("average AUC for all predict vessel masks:",np.mean(roc_list))
print("average PR for all predict vessel masks:",np.mean(pr_list))
print("average recall(sensitivity) for all predict vessel masks:",np.mean(tpr_list))
print("average specificity for all predict vessel masks:",np.mean(tnr_list))
```

```
average dice score for all predict vessel masks: 0.8741437
average AUC for all predict vessel masks: 0.87187457
average PR for all predict vessel masks: 0.6971755
average recall(sensitivity) for all predict vessel masks: 0.76676553
average specificity for all predict vessel masks: 0.9879815
```

Рис. 1. Приклад обчислення метрик Dice Score, Precision, Recall, AUC при використанні плитки 25x25

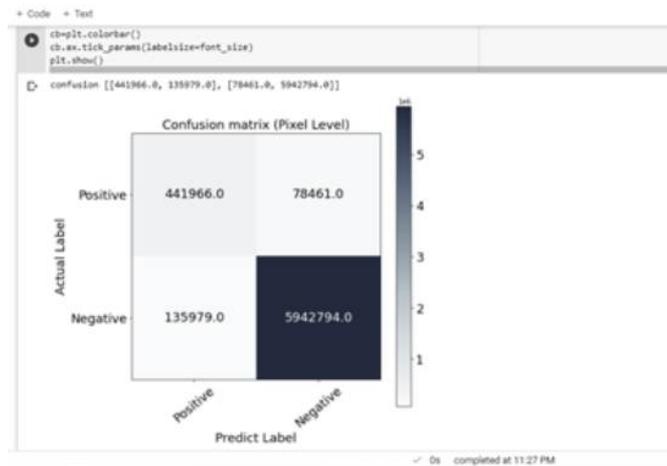


Рис. 2. Матриця помилок для оцінки моделі при використанні плитки 25x25

Для визначення помилки між реальними і отриманими результатами та її мінімізації в якості функції втрат використовували бінарну крос-ентропію (binary cross entropy). Процес обчислення функції втрат та індексу Соренса відбувався безпосередньо у програмному середовищі.

Таблиця 1.

Обчислення крос-ентропії для U-Net моделі

Крос-валідація	Розмір плиток (CLAHЕ)			
	8*8	16*16	25*25	36*36
cv3	0.0342	0.0349	0.0353	0.0347
cv5	0.0301	0.0311	0.0374	0.0345

Крос-валідація	Розмір плиток (CLAHЕ)			
	8*8	16*16	25*25	36*36
cv7	0.0295	0.0302	0.0323	0.0328
cv9	0.0303	0.0298	0.0318	0.0307
max	0.0342	0.0349	0.0374	0.0347
minimax	0.0342			

Таблиця 2.

Час навчання U-Net моделі

Крос-валідація	Розмір плиток (CLAHЕ)			
	8*8	16*16	25*25	36*36
cv3	3.207	3.167	4.301	3.252
cv5	6.267	4.312	3.883	4.321
cv7	8.812	5.896	5.231	6.127
cv9	12.356	9.564	8.462	9.052
max	12.356	9.564	8.462	9.052
minimax			8.462	

Результат роботи нейромережі добре прослідковується, коли порівняти, початкове зображення очного дна на одинадцятому зображенні (рис. 3а) і результати роботи U-net моделі представлені на рис. 3б з розпізнаними кровоносними судинами для зображення під номером одинадцять.

Висновки. Автоматична сегментація судин сітківки на знімках очного дна є важливим завданням, так як за знімками з виявленими кровоносними судинами можна діагностувати деякі захворювання. У цій роботі пропонується реалізація архітектури нейронної мережі на основі щільної U-Net мережі у середовищі Google Collab на загальнодоступному наборі даних DRIVE з використанням бібліотеки

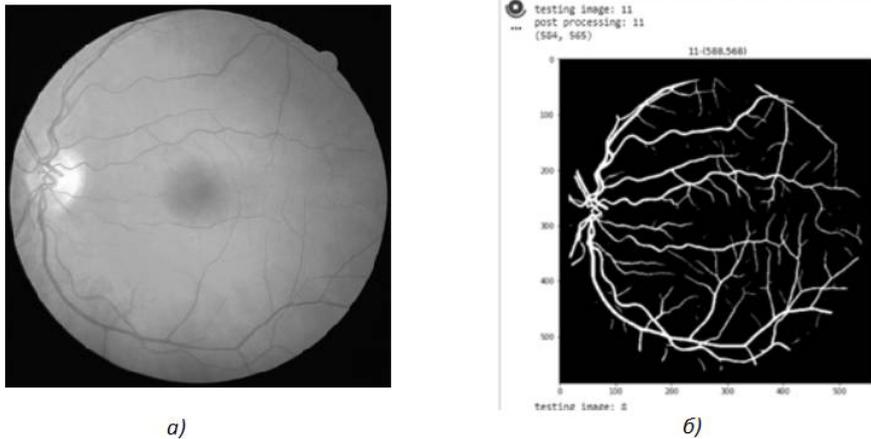


Рис. 3. а – початкове зображення очного дна на одинадцятому зображенні при використанні плитки 25x25; б – Результати роботи U-net моделі для одинадцятого зображення при використанні плитки 25x25

машинного навчання Tensorflow для сегментації судин сітківки очного дна. Загальний процес роботи нейромережі представлено. Для визначення помилки між реальними і отриманими результатами та її мінімізації в якості функції втрат використовували бінарну крос-ентропію, результати представлені у таблиці. Для оцінки методу використано точність, повноту, матрицю помилок, площу під кривою помилок. Показники бінарної крос-ентропії та часу навчання при використанні різних розмірів плиток представлено, на основі цих даних розв'язок задачі minimax ML для бінарної крос-ентропії та часу навчання.

У випадку бінарної крос-ентропії як показника ефективності, що продемонстровано у таблиці 1, модель U-Net з плитками 8x8 є розв'язком задачі minimax ML . На першому кроці, ми порівнюємо значення функції втрат для всіх розглянутих моделей. На другому кроці ми бачимо, що значення бінарної крос-ентропії для моделі U-Net з плитками 8x8 буде мінімальним серед максимальних характеристик.

У випадку з часом навчання як показником ефективності, що продемонстровано у таблиці 2, модель U-Net з плитками 25x25 є розв'язком задачі minimax ML. На першому кроці, ми порівнюємо значення часу тренування всіх моделей, що розглядаються. На другому кроці бачимо, що значення часу для моделі U-Net з плитками 25x25 буде мінімальним серед максимальних показників.

Подяка за фінансування. Робота співфінансувалась програмою Європейського Союзу «Еразмус +» для освіти в рамках гранту KA2 (проєкт № 2020-1-PL01-KA203-082197 «Інновації для великих даних у реальному світі»).

References:

1. C. L. Srinidhi, P. Aparna, and J. Rajan, "Recent advancements in retinal vessel segmentation," *J. Med. Syst.*, vol. 41, no. 4, Mar. 2017.
2. C. Wang, Z. Zhao, Q. Ren, Y. Xu, and Y. Yu, "Dense U-net based on patchbased learning for retinal vessel segmentation," *Entropy*, vol. 21, no. 2, p. 168, Feb. 2019.
3. C. Y.-L. Cheung, M. K. Ikram, C. Chen, and T. Y. Wong, "Imaging retina to study dementia and stroke," *Prog. Retinal Eye Res.*, vol. 57, pp. 89–107, Mar. 2017.
4. E. Tuba, L. Mrkela, and M. Tuba, "Retinal blood vessel segmentation by support vector machine classification," present at the 27th Int. Conf. Radioelektronika (RADIOELEKTRONIKA), 2017. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7936649>.
5. F. Uslu and A. A. Bharath, "A recursive Bayesian approach to describe retinal vasculature geometry," *Pattern Recognit.*, vol. 87, pp. 157–169, Mar. 2019.
6. H. Akil, A. S. Huang, B. A. Francis, S. R. Sadda, and V. Chopra, "Retinal vessel density from optical coherence tomography angiography to

- differentiate early glaucoma, pre-perimetric glaucoma and normal eyes,” PLoS ONE, vol. 12, no. 2, Feb. 2017, Art. no. e0170476.
7. H. Lee, M. Lee, H. Chung, and H. C. Kim, “Quantification of retinal vessel tortuosity in diabetic retinopathy using optical coherence tomography angiography,” *Retina*, vol. 38, no. 5, pp. 976–985, May 2018.
 8. O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” presented at the Med. Image Comput. Comput.-Assist. Intervent. (MICCAI), 2015. [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-319-24574-4_28
 9. Q. Jin, Z. Meng, T. D. Pham, Q. Chen, L. Wei, and R. Su, “DUNet: A deformable network for retinal vessel segmentation,” *Knowl.-Based Syst.*, vol. 178, pp. 149–162, Aug. 2019.
 10. S. Feng, Z. Zhuo, and D. Pan, “CcNet: A cross-connected convolutional network for segmenting retinal vessels using multi-scale features,” *Neurocomputing*, vol. 392, pp. 268–2767, Jun. 2020.
 11. S. Fraser-Bell, R. Symes, and A. Vaze, “Hypertensive eye disease: A review,” *Clin. Experim. Ophthalmol.*, vol. 45, no. 1, pp. 45–53, Jan. 2017.
 12. S. Guo, K. Wang, H. Kang, Y. Zhang, Y. Gao, and T. Li, “BTSDSN: Deeply supervised neural network with short connections for retinal vessel segmentation,” *Int. J. Med. Informat.*, vol. 126, pp. 105–113, Jun. 2019.
 13. X. Gao, Y. Cai, and C. Qiu, “Retinal blood vessel segmentation based on the Gaussian matched filter and U-net,” presented at the CISP-BMEI, 2017. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8302199>.
 14. X. Xiao, S. Lian, and Z. Luo, “Weighted Res-UNet for highquality retina vessel segmentation,” presented at the 9th Int. Conf. Inf. Technol. Med. Educ. (ITME), 2018. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8589312>.

Citation: V. Martsenyuk, N. Milian, R. Milian (2020). THE MINIMAX APPROACH APPLICATION FOR SEGMENTATION OF RETINAL VESSELS. New York. TK Meganom LLC. Innovative Solutions in Modern Science. 7(43). doi: 10.26886/2414-634X.7(43)2020.13

Copyright: V. Martsenyuk, N. Milian, R. Milian ©. 2020. This is an openaccess article distributed under the terms of the Creative Commons Attribution License (CC BY). The use, distribution or reproduction in other forums is permitted, provided the original author(s) or licensor are credited and that the original publication in this journal is cited, in accordance with accepted academic practice. No use, distribution or reproduction is permitted which does not comply with these terms.