

УДК 004.8

СТАНДАРТИЗОВАНІ КАРТИ ПОМИЛОК ТА ЕНТРОПІЇ ЯК СПОСІБ ВІЗУАЛІЗАЦІЇ ОЦІНКИ ЯКОСТІ РОБОТИ МОДЕЛЕЙ ГЛИБОКОГО НАВЧАННЯ ДЛЯ ОБРОБКИ АЕРОФОТОЗНІМКІВ

Власенко В.О., аспірант*

vlasenko.vitaliy99@gmail.com, ORCID: 0009-0008-6951-8496

Національний технічний університет «Харківський політехнічний інститут» (м. Харків, Україна)

Роботу присвячено процесу дослідження та розробці власного підходу для створення стандартизованої карти помилок якості роботи моделей глибокого навчання та ентропії у випадках аналізу аерофотознімків, отриманих з дронів. За допомогою таких карт можливо зрозуміти на яких ділянках зображень моделі найчастіше помиляються на тестових даних та отримати відповідні невизначеності. Побудова таких карт допомагає виявити слабкі місця в моделях та особливо корисна для випадків, коли середні стандартні метрики майже однакові. Для проведення дослідження та експериментів було використано найпопулярніші архітектури нейронних мереж U-Net, DeepLabV3+ та Feature Pyramid Network, що найчастіше використовуються у задачах сегментації зображень у сфері комп'ютерного зору. Семантична сегментація відіграє ключову роль в аналізі просторових даних у задачах моніторингу навколишнього середовища, картографування та управління земельними ресурсами. Висока точність популярних архітектур не виключає проблему аналізу помилок та невизначеностей. У роботі представлено підхід до побудови теплових карт помилок, які показують у яких місцях зображень моделі найбільш неправильно класифікують пікселі на тестових даних, а для оцінки невизначеностей пропонується будувати спеціальні карти ентропії. Окрім визначення кількісних показників якості роботи моделей (точності, індексу Жаккара, F-метрики) такі візуалізації дозволяють якісно аналізувати слабкі місця, наприклад, у випадках коли зображення мають неоднорідну місцевість або нечіткі контури. У ході проведення експериментів на власному наборі аерофотознімків було визначено, що ефективність запропонованих підходів до візуалізації може значно підвищити розуміння результатів роботи навчених моделей. Результати таких досліджень можуть мати значний вплив на покращення архітектур сегментації, підготовці навчальних даних та аналізу помилок в цілому. Майбутні дослідження можуть фокусуватися на розширенні набору даних аерофотознімків для оцінювання роботи моделей та зниження кількості помилок.

* Науковий керівник – канд. техн. наук, доцент Дашкевич А.О.

Ключові слова: глибоке навчання, семантична сегментація, U-Net, DeepLabV3+, FPN, нейронні мережі, карти помилок, карти ентропії, спосіб візуалізації, дрони, аерофотознімки.

Постановка проблеми. У задачах семантичної сегментації аерофотознімків чітке розпізнавання об'єктів відіграє важливу роль у сферах моніторингу навколишнього середовища, містобудування та управління земельними ресурсами. Сучасні архітектури нейронних мереж U-Net, DeepLabV3+ та Feature Pyramid Network (FPN) показують високу ефективність для вирішення таких задач, але, незважаючи на високі середні метрики точності (Accuracy, IoU, F1-Score), моделі вразливі до виникнення локальних помилок, особливо у випадках складних чи неоднорідних зображень, наприклад, з нечіткими контурами, затемненням або різними шумами.

Стандартні метрики не можуть продемонструвати повну картину походження та розташування помилок моделі на зображеннях. Тому аналіз слабких сторін моделі та робота над її вдосконаленням ускладнюється, неможливо якісно продіагностувати результати сегментації.

Існує потреба у створенні підходів до візуалізації помилок та невизначеностей, що зможуть дозволити визначати області з високою ймовірністю неправильних класифікацій та оцінити роботу моделей на рівні пікселів. Вирішення цієї проблеми дозволить використовувати цю інформацію для якіснішого навчання моделей та інтерпретації їх роботи на тестових даних.

Аналіз останніх досліджень і публікацій. Використання та розвиток моделей нейронних мереж глибокого навчання спонукає дослідників до постійного вирішення задач точного та швидкого виявлення об'єктів природного чи штучного походження на великих площах земної поверхні. Семантична сегментація на основі архітектур U-Net, DeepLabV3+ та FPN зарекомендувала себе як потужний інструмент для розпізнавання об'єктів на аерофотознімках у різних сферах людської діяльності. Сучасні дослідження у цій сфері зосереджуються на модифікації таких моделей для того, щоб значно підвищувати та покращувати їх ефективність.

На сьогоднішній день, у задачах сегментації зображень, архітектура U-Net залишається найпоширенішою серед науковців. Для розпізнавання об'єктів (таких як ліси та водойми) на аерофотознімках вона демонструє точність понад 82% на тестових даних [1]. Окрім стандартного використання моделі, її постійно вдосконалюють, наприклад, за рахунок впровадження модулів самоуваги та роздільних згорток [2], що дозволяє досягти точності понад 91% на тестовому наборі. Для досягнення ще кращих результатів, дослідники постійно модифікують U-Net, наприклад, збільшуючи кількість з'єднань у середніх шарах нейронної мережі і зберігаючи, при цьому, більше даних зображення за допомогою S-

подібних кругових з'єднань. У роботі [3] представлено таке покращення і розроблено модифіковану SU-Net, яка досягає точності понад 96% на тестових даних.

Інша поширена архітектура DeepLabV3+ показує значну ефективність розпізнавання об'єктів, особливо у випадку об'єднаних зображень, отриманих із різних джерел [4]. Науковці покращили та адаптували DeepLabV3+ до злиття аерофотознімків із цифровими моделями земної поверхні (даними про висоту), отримавши середнє значення точності на рівні 88.87%. Особливо корисним є використання цієї моделі в обробці зображень у реальному часі. При одночасному використанні DeepLabV3 та DeepLabV3+ можна досягти кращої ефективності, завдяки їх оптимізації та полегшенні, при розгортанні моделей на безпілотних літальних апаратах [5], наприклад, у задачах моніторингу надзвичайних ситуацій, таких як пожежі та повені.

Пірамідальна архітектура FPN, також, широко використовується у задачах семантичної сегментації. Для розпізнавання аерофотознімків класична FPN, із використанням енкодера ResNet50, забезпечує ефективну багатокласову сегментацію земної поверхні, балансуючи між точністю та використанням ресурсів [6]. Така модель може бути особливо корисною у практичному застосуванні. Архітектуру FPN постійно модифікують, наприклад, із застосуванням модуля агрегації уваги, що дозволяє покращити багатомасштабне навчення ознак, які підвищують загальну точність сегментації у випадках високоякісних зображень, отриманих з дронів [7].

Окрім використання архітектур нейронних мереж у задачах сегментації, досить популярним напрямком досліджень є візуалізація результатів роботи моделей, включаючи їх помилки та пошук невизначеностей. Так, на основі проблемних ділянок моделі, у роботі [8] науковці пропонують створити систему інтерактивної візуалізації для аналізу активації мережі U-Net під час сегментації льодовиків, а у сфері медицини, метод прогнозування карти помилок, використали для оцінки якості сегментації зображень серця [9]. Така можливість надала змогу виявити слабкі місця в моделях без використання еталонних розміток. Подібна практика може застосовуватись і при аналізі аерофотознімків.

Для пояснення роботи моделей сегментації, іноді, розробляють спеціальні додатки, наприклад, TorchEsegeta [10], що використовує різноманітні методи візуалізації. Також, будують спеціальні теплові карти [11], порівнюють їх результати та оцінюють ефективність роботи моделей у відповідності до експертних розміток. Побудова карт помилок та ентропії може дозволити візуалізувати результати роботи моделей на різних ітераціях навчання, наприклад, для аналізу поведінки моделей на окремих ділянках зображень та виявлення областей з високою невизначеністю [12]. Теплові карти помилок стають все більш популярними для оцінки довіри до передбачень, тому що вони, як правило,

враховують статистичну достовірність результатів та допомагають виявляти потенційні помилки роботи моделей сегментації [13].

Таким чином, сучасні дослідження підкреслюють не лише розвиток та підвищення точності моделей для сегментації зображень, але й прагнуть глибше зрозуміти аналіз їх поведінки. Використання методів візуалізації помилок, теплових карт, карт ентропії та оцінки невизначеності надає можливість повністю обґрунтовувати результати роботи моделей для подальшого виявлення потенційних зон ризику. У задачах аналізу зображень, отриманих із різних сфер людської діяльності, включаючи аерофотознімки, такі рішення допомагають покращувати загальну якість сегментації, сприяють прозорості та більшій довірі до алгоритмів автоматичного виявлення ознак на зображеннях.

Формулювання цілей статті. Розробка власного підходу для створення стандартизованої карти помилок та карти ентропії роботи сучасних моделей глибокого навчання на тестових даних у випадках аналізу аерофотознімків, отриманих з дронів.

Основна частина. Першим етапом роботи була підготовка зображень та тренування моделей U-Net, DeepLabV3+, FPN. Підготовлений датасет складається з 50 пар зображень аерофотознімків та відповідних їм масок сегментації, розміром 512x512 пікселів (рис. 1).




Рис. 1. Підготовлений набір пар зображень

Для розмітки було налаштовано 7 класів об'єктів, які включають будівлі, дороги, автомобілі, земну поверхню, густу та рідку рослинність, а також водойми. Щоб підвищити узагальнюючу здатність моделей, було використано стандартні методи аугментації, а саме дзеркальне відображення по вертикалі та горизонталі, кут нахилу, змінення яскравості, контрастності, насиченості та відтінку. Таким чином набір даних було

розширено до 250 відповідних пар зображень.

Тренування моделей проводилось упродовж 30 епох, із використанням однакових параметрів: функції активації «softmax», оптимізатора «Adam» з початковою швидкістю 0.0001 та кількістю класів – 7. Моделі навчались на одному і тому ж підготовленому наборі даних із фіксованим розподіленням на тренувальну та тестову вибірку (20% від усіх зображень).

Для оцінки роботи моделей на тестових даних було розраховано функцію втрат (перехресну ентропію) та стандартні метрики точності (Accuracy), індексу Жаккара (IoU) та F-міри (F1-Score), що балансує між влучністю (precision) та повнотою (recall). Результати роботи моделей на тестових даних без використання аугментації приведені у таблиці 1, а з аугментацією – у таблиці 2.

Таблиця 1

Результати роботи моделей на тестових даних без аугментації

Модель	Loss	Accuracy	IoU	F1-Score
U-Net	1.6082	0.6083	0.2917	0.3907
DeepLabV3+	1.5322	0.6524	0.3588	0.4767
FPN	1.5243	0.6362	0.3408	0.4626

Таблиця 2

Результати роботи моделей на тестових даних з аугментацією

Модель	Loss	Accuracy	IoU	F1-Score
U-Net	1.2960	0.8784	0.6611	0.7419
DeepLabV3+	1.2778	0.8930	0.6817	0.7547
FPN	1.2854	0.8803	0.7249	0.8321

Пропонується визначати стандартизовану карту помилки (Error Fingerprint Map) по всім тестовим даним, яка дозволить зрозуміти де саме модель найчастіше помиляється. Для того, щоб виявити слабкі місця в моделях, можна побудувати теплові карти для візуалізації результатів і порівняти їх для всіх моделей. Такий підхід особливо корисно використовувати, коли середні метрики приблизно однакові.

Створення карти помилок базується на піксельному порівнянні прогнозованої маски з оригінальною та накопиченні помилок у зведену бінарну матрицю.

Нехай $P(x, y)$ – прогнозована маска зображення на пікселі з координатою (x, y) , $T(x, y)$ – оригінальна маска зображення на відповідному пікселі, тоді можна розрахувати бінарне значення для кожного пікселя за формулою:

$$E(x, y) = 1 | P(x, y) \neq T(x, y) |. \quad (1)$$

де значення 1 означає, що прогноз та оригінал не збігаються, а 0 – збігаються.

Якщо N – кількість тестових зображень, то, використовуючи (1) можна розрахувати стандартизовану карту помилки (EFN) за формулою:

$$EFN = \frac{1}{N} \sum_{i=1}^N E_i. \quad (2)$$

Отримане з (2) значення $EFN \in [0,1]^{(W \times H)}$ – це матриця розміром $W \times H$ (ширина та висота зображень відповідно), яка показує ймовірність або частоту виникнення помилки у конкретному пікселі на основі усіх передбачень моделі.

Для обчислення невизначеності моделі пропонується знаходити та будувати карти ентропії (Entropy Map), тому що карти помилок, як правило, потребують знання істинної розмітки, а ентропія може обчислюватись під час роботи моделі, тобто у реальному застосуванні і може бути дуже корисною для критичних задач (моніторинг та швидке реагування).

Ентропія базується на ймовірнісному розподілі класів та визначається за формулою Шеннона:

$$H(x, y) = - \sum_{c=1}^C p_c^{\{x,y\}} \log p_c^{\{x,y\}}, \quad (3)$$

де C – загальна кількість класів (у даному випадку $C=7$), $p_c^{\{x,y\}}$ – ймовірність того, що піксель з координатою (x, y) належить до класу c .

Отримане значення з (3) ентропії дозволить визначити рівень невпевненості у прогнозуванні. При однакових значеннях ймовірності ентропія $H(x, y)$ буде максимальною, що говорить про невизначеність моделі. Для того, щоб модель була впевнена у своєму рішенні, одна з ймовірностей повинна бути більшою, щоб ентропія була мінімальною.

Використовуючи розрахунки було визначено значення стандартизованої помилки та ентропії для кожної з моделей. Результати приведені у таблиці 3.

Таблиця 3

Середнє значення карти помилок та ентропії для всіх моделей

Модель	Аугментація	Стандартизована помилка	Ентропія
U-Net	немає	0.3917	1.8966
	є	0.1216	1.8603
DeepLabV3+	немає	0.3476	1.8841
	є	0.1070	1.8606
FPN	немає	0.3638	1.8685
	є	0.1197	1.8598

Було побудовано відповідні теплові карти для стандартизованої помилки, де яскравість вказує на щільність помилок певних ділянок зображень. Для покращення візуального сприйняття помилок, особливо у

випадках їх скупчення, було використано просторову згладжувальну фільтрацію (Gaussian Blur). В результаті, отримано теплові карти для випадку зображень без застосування аугментації (рис. 2) та з аугментацією (рис. 3).




Рис. 2. Теплові карти стандартизованої помилки (без використання аугментації)




Рис. 3. Теплові карти стандартизованої помилки (з використанням аугментації)

Далі, було побудовано відповідні карти для ентропії, де більша яскравість вказує на невизначеність моделі окремих ділянок зображень. Для покращення візуального сприйняття ентропії, також, було використано просторову згладжувальну фільтрацію (Gaussian Blur). В результаті, було отримано теплові карти для випадку зображень без застосування аугментації (рис. 4) та з аугментацією (рис. 5).




Рис. 4. Теплові карти ентропії (без використання аугментації)




Рис. 5. Теплові карти ентропії (з використанням аугментації)

На картах помилок моделей без використання аугментації спостерігається значна кількість темно-червоного кольору, вказуючи на стійкі помилки в однакових ділянках зображень. У даному випадку, модель FPN показує найкращі результати, що говорить про меншу сконцентрованість помилок. Карта ентропії для FPN, навпаки, найсвітліша, що говорить про високу невизначеність передбачень. U-Net демонструє найбільш збалансовану карту ентропії, яка означає, що вона має найкращий розподіл невизначеності серед інших моделей.

При використанні аугментації карти помилок моделей показують значно кращі результати, тому що домінує білий та світло-червоний кольори. Моделі все ще допускають помилки, але вони є менш виразними та охоплюють менші області. Найкращі результати мають моделі DeepLabV3+ та FPN, що свідчить про значне покращення просторової узгодженості сегментації. Використання аугментації допомогло покращити здатність моделей до більш точного передбачення.

Карти ентропії, на моделях з аугментацією, показують значне збільшення невизначеності у моделі U-Net, тобто вона стає більш нестабільною у впевненості власних прогнозувань. Моделі DeepLabV3+ та FPN показують кращі результати, що говорить про їх баланс між точністю та впевненістю у результатах.

Висновки. В результаті проведеного дослідження та експериментів на власному наборі аерофотознімків було визначено, що ефективність стандартизованої карти помилок та карти ентропії, як підходи до візуалізації, може значно підвищити розуміння результатів роботи навчених моделей глибоких нейронних мереж. Результати таких досліджень можуть мати значний вплив на покращення архітектур сегментації, підготовці навчальних даних та аналізу помилок в цілому. Підхід реалізовано у вигляді програмного додатку мовою програмування Python.

Обмеження запропонованого підходу полягає в невеликому обсязі навчальних даних, оскільки використання більших та різноманітніших датасетів дало б змогу надійніше оцінити роботу моделей та покращити значення помилок. Майбутні дослідження зосереджені на розширенні

набору даних аерофотознімків для оцінювання роботи моделей та зниження кількості помилок.

Література

1. Filatov, D., Yar, G. Forest and Water Bodies Segmentation Through Satellite Images Using U-Net. ESS Open Archive. 2022. <https://doi.org/10.1002/essoar.10511870.1>
2. Khan, B. A., & Jung, J.-W.,. Semantic Segmentation of Aerial Imagery Using U-Net with Self-Attention and Separable Convolutions. *Applied Sciences*, 2024. 14(9), 3712. <https://doi.org/10.3390/app14093712>
3. Li, W., Li, Y., Gong, J., Feng, Q., Zhou, J., Sun, J., Shi, C., & Hu, W. Urban Water Extraction with UAV High-Resolution Remote Sensing Data Based on an Improved U-Net Model. *Remote Sensing*, 2021. 13(16), 3165. <https://doi.org/10.3390/rs13163165>
4. Akcay, O., Kinaci, A. C., Avsar, E. O., & Aydar, U. Semantic Segmentation of High-Resolution Airborne Images with Dual-Stream DeepLabV3+. *ISPRS International Journal of Geo-Information*, 2022. 11(1), 23. <https://doi.org/10.3390/ijgi11010023>
5. Lee, Y. J., Jung, H. G., & Suhr, J. K., Semantic Segmentation Network Slimming and Edge Deployment for Real-Time Forest Fire or Flood Monitoring Systems Using Unmanned Aerial Vehicles. *Electronics*, 2023. 12(23), 4795. <https://doi.org/10.3390/electronics12234795>
6. Seferbekov, S., Iglovikov, V., Buslaev, A., Shvets, A. Feature Pyramid Network for Multi-class Land Segmentation. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2018. pp. 272–2723. <https://doi.org/10.1109/CVPRW.2018.00051>
7. Li, R., Zheng, S., Zhang, C., Duan, C., Wang, L. A2-FPN for Semantic Segmentation of Fine-Resolution Remotely Sensed Images. *IEEE Trans. Geosci. Remote Sensing*, 2022. 60. 1–13. <https://doi.org/10.1109/TGRS.2021.3093977>
8. Zheng, M., Miao, X., & Sankaran, K. Interactive Visualization and Representation Analysis Applied to Glacier Segmentation. *ISPRS International Journal of Geo-Information*, 2022. 11(8). 415. <https://doi.org/10.3390/ijgi11080415>
9. Zhang, R., Chung, A.C.S. A Fine-Grain Error Map Prediction and Segmentation Quality Assessment Framework for Whole-Heart Segmentation. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019. Lecture Notes in Computer Science*, 2019, Vol. 11765. https://doi.org/10.1007/978-3-030-32245-8_61

10. Chatterjee, S., Das, A., Mandal, C., Mukhopadhyay, B., Vipinraj, M., Shukla, A., Nagaraja Rao, R., Sarasaen, C., Speck, O., & Nürnberger, A. TorchEsegeta: Framework for Interpretability and Explainability of Image-Based Deep Learning Models. *Applied Sciences*, 2022. 12(4), 1834. <https://doi.org/10.3390/app12041834>
11. Van Craenendonck, T., Elen, B., Gerrits, N., De Boever, P., Systematic Comparison of Heatmapping Techniques in Deep Learning in the Context of Diabetic Retinopathy Lesion Detection. *Translational Vision Science & Technology*, 2020. 9, 64. <https://doi.org/10.1167/tvst.9.2.64>
12. Wang, H., Wang, Y., Zhang, Q., Xiang, S., & Pan, C. Gated Convolutional Neural Network for Semantic Segmentation in High-Resolution Images. *Remote Sensing*, 2017. 9(5), 446. <https://doi.org/10.3390/rs9050446>
13. Mossina, L., Dalmau, J., Andéol, L. Conformal Semantic Image Segmentation: Post-hoc Quantification of Predictive Uncertainty. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2024. <https://doi.org/10.1109/CVPRW63382.2024.00361>

ERROR FINGERPRINT AND ENTROPY MAPS AS A WAY TO VISUALIZE THE EVALUATION OF THE QUALITY OF PERFORMANCE OF DEEP LEARNING MODELS FOR AERIAL IMAGE PROCESSING

Vitalii Vlasenko

The work is devoted to the research process and the development of our own approach to create a standardized error map of the quality of deep learning models and entropy in cases of analysis of aerial images obtained from drones. With the help of such maps, it is possible to understand in which areas of the images the models are most often mistaken in the test data and obtain the corresponding uncertainties. Building such maps helps to identify weaknesses in models and is especially useful for cases where the average standard metrics are almost the same. To conduct research and experiments, the most popular neural network architectures U-Net, DeepLabV3+ and Feature Pyramid Network, which are most often used in image segmentation problems in the field of computer vision, were used. Semantic segmentation plays a key role in the analysis of spatial data in the tasks of environmental monitoring, mapping and land management. The high accuracy of popular architectures does not eliminate the problem of analyzing errors and uncertainties. The paper presents an approach to building error heat maps, which show where models most incorrectly classify pixels on test data, and to estimate uncertainties, it is

proposed to build special entropy maps. In addition to determining quantitative indicators of the quality of models (accuracy, Jaccard index, F-metrics), such visualizations allow for a qualitative analysis of weaknesses, for example, in cases where images have heterogeneous terrain or fuzzy contours. In the course of experiments on our own set of aerial photographs, it was determined that the effectiveness of the proposed imaging approaches can significantly increase the understanding of the results of the trained models. The results of such studies can have a significant impact on improving segmentation architectures, training data preparation, and error analysis in general. Future research may focus on expanding the aerial imagery dataset to evaluate model performance and reduce errors.

Keywords: deep learning, semantic segmentation, U-Net, DeepLabV3+, FPN, neural networks, error maps, entropy maps, visualization method, drones, aerial images.

References

1. Filatov, D., Yar, G. (2022). Forest and Water Bodies Segmentation Through Satellite Images Using U-Net. ESS Open Archive. <https://doi.org/10.1002/essoar.10511870.1> [in English]
2. Khan, B. A., & Jung, J.-W. (2024). Semantic Segmentation of Aerial Imagery Using U-Net with Self-Attention and Separable Convolutions. Applied Sciences, 14(9), 3712. <https://doi.org/10.3390/app14093712> [in English]
3. Li, W., Li, Y., Gong, J., Feng, Q., Zhou, J., Sun, J., Shi, C., & Hu, W. (2021). Urban Water Extraction with UAV High-Resolution Remote Sensing Data Based on an Improved U-Net Model. Remote Sensing, 13(16), 3165. <https://doi.org/10.3390/rs13163165> [in English]
4. Akcay, O., Kinaci, A. C., Avsar, E. O., & Aydar, U. (2022). Semantic Segmentation of High-Resolution Airborne Images with Dual-Stream DeepLabV3+. ISPRS International Journal of Geo-Information, 11(1), 23. <https://doi.org/10.3390/ijgi11010023> [in English]
5. Lee, Y. J., Jung, H. G., & Suhr, J. K. (2023). Semantic Segmentation Network Slimming and Edge Deployment for Real-Time Forest Fire or Flood Monitoring Systems Using Unmanned Aerial Vehicles. Electronics, 12(23), 4795. <https://doi.org/10.3390/electronics12234795> [in English]
6. Seferbekov, S., Iglovikov, V., Buslaev, A., Shvets, A. (2018). Feature Pyramid Network for Multi-class Land Segmentation. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, pp. 272–2723. <https://doi.org/10.1109/CVPRW.2018.00051> [in English]
7. Li, R., Zheng, S., Zhang, C., Duan, C., Wang, L. (2022). A2-FPN for

- Semantic Segmentation of Fine-Resolution Remotely Sensed Images. *IEEE Trans. Geosci. Remote Sensing* 60, 1–13. <https://doi.org/10.1109/TGRS.2021.3093977> [in English]
8. Zheng, M., Miao, X., & Sankaran, K. (2022). Interactive Visualization and Representation Analysis Applied to Glacier Segmentation. *ISPRS International Journal of Geo-Information*, 11(8), 415. <https://doi.org/10.3390/ijgi11080415> [in English]
 9. Zhang, R., Chung, A.C.S. (2019). A Fine-Grain Error Map Prediction and Segmentation Quality Assessment Framework for Whole-Heart Segmentation. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019. Lecture Notes in Computer Science()*, vol 11765. https://doi.org/10.1007/978-3-030-32245-8_61 [in English]
 10. Chatterjee, S., Das, A., Mandal, C., Mukhopadhyay, B., Vipinraj, M., Shukla, A., Nagaraja Rao, R., Sarasaen, C., Speck, O., & Nürnberger, A. (2022). TorchEsegeta: Framework for Interpretability and Explainability of Image-Based Deep Learning Models. *Applied Sciences*, 12(4), 1834. <https://doi.org/10.3390/app12041834> [in English]
 11. Van Craenendonck, T., Elen, B., Gerrits, N., De Boever, P. (2020). Systematic Comparison of Heatmapping Techniques in Deep Learning in the Context of Diabetic Retinopathy Lesion Detection. *Translational Vision Science & Technology* 9, 64. <https://doi.org/10.1167/tvst.9.2.64> [in English]
 12. Wang, H., Wang, Y., Zhang, Q., Xiang, S., & Pan, C. (2017). Gated Convolutional Neural Network for Semantic Segmentation in High-Resolution Images. *Remote Sensing*, 9(5), 446. <https://doi.org/10.3390/rs9050446> [in English]
 13. Mossina, L., Dalmau, J., Andéol, L. (2024). Conformal Semantic Image Segmentation: Post-hoc Quantification of Predictive Uncertainty. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. <https://doi.org/10.1109/CVPRW63382.2024.00361> [in English]