

УДК 519.688

МЕТОД И АЛГОРИТМЫ ОБРАБОТКИ ТЕПЛОВИЗИОННЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АВТОМАТИЧЕСКОГО ОБНАРУЖЕНИЯ ЗАДАННЫХ ТИПОВ ОБЪЕКТОВ

А. В. Мингалев, начальник сектора АО «НПО ГИПО», Казань, Россия;
orcid.org/0000-0001-5848-1992, e-mail: gipo@shvabe.com

Представлены результаты исследования, направленного на разработку численного метода и алгоритмов обработки сканерных тепловизионных изображений на основе сверточных нейронных сетей для автоматического обнаружения объектов на тепловизионных изображениях с целью обеспечения возможности дешифрирования графических данных, формируемых сканерными тепловизионными съемочными системами, в режиме реального времени. В качестве основных критериев для оценки исследуемых алгоритмов были выбраны скорость обработки данных и точность дешифрирования. Оценка критериев выполнялась на основе практических экспериментов с обучением и запуском нейросетевых алгоритмов в разработанном программном обеспечении на ЭВМ. Разработан численный метод обработки сканерных тепловизионных изображений на основе сверточных нейронных сетей для автоматического обнаружения заданных типов объектов на изображениях, отличающийся от известного способа меньшим количеством параметров нейросетевой модели с более высоким значением отношения точности ко времени дешифрирования, который позволяет выполнять автоматическое обнаружение заданных типов объектов на сканерных тепловизионных изображениях в режиме реального времени в составе различных программно-аппаратных систем автоматизированного дешифрирования графической информации.

Ключевые слова: нейросетевые алгоритмы, семантическая сегментация, машинное обучение, сканерные тепловизионные съемочные системы.

DOI: 10.21667/1995-4565-2025-91-158-167

Введение

Авиационный мониторинг территорий с применением сканерных тепловизионных съемочных систем (сканерных ТПВ-систем) позволяет выполнять обнаружение паводкоопасных и пожароопасных участков местности, мест возгорания, осуществлять контроль за обстановкой при тушении лесных пожаров, выполнять диагностику состояния нефтегазопроводов, тепловых сетей, оперативный поиск людей, кораблей, самолетов при чрезвычайных ситуациях. Объем графической информации, формируемой сканерными ТПВ-системами, значительно превышает объем, который оператор способен просматривать в реальном масштабе времени в процессе выполнения съемочных работ. К примеру, за одну секунду оператору необходимо дешифрировать графический растр размером 22400 на 576 пикселей, что составляет порядка 37 изображений размером 608 на 576 пикселей, в результате чего дешифрирование графической информации выполняется после выполнения съемочных работ на этапе постобработки на Земле вручную оператором либо с применением автоматизированных систем. Дешифрирование на этапе постобработки существенно увеличивает время получения результата и снижает эффективность авиационного мониторинга. Внедрение быстродействующих систем обработки графической информации, которые непосредственно в процессе съемки смогут выделять в автоматическом режиме области на изображениях, близкие по некоторым признакам к искомым объектам, позволит обеспечить дешифрирование в процессе выполнения съемочных работ.

В настоящее время наилучшие результаты по точности, устойчивости к изменению формы, размеров, структуры фона и других характеристик изображения демонстрируют методы на основе сверточных нейронных сетей (СНС). Однако самые точные из них являются требовательными к вычислительным ресурсам и не обеспечивают достаточной скорости обработки.

В связи с этим тема исследования и разработки методов и алгоритмов на основе СНС, эффективных по соотношению скорости и точности для применения в автоматизированных системах дешифрирования непосредственно в процессе выполнения съемочных работ сканерными ТПВ-системами, является актуальной.

На первом этапе представленного исследования проведен анализ некоторых нейросетевых алгоритмов семантической сегментации и определен для дальнейших исследований наиболее оптимальный по соотношению скорости обработки и точности базовый нейросетевой алгоритм семантической сегментации. На втором этапе выполнена модификация базового нейросетевого алгоритма семантической сегментации с целью повышения скорости обработки графических данных без существенной потери в точности дешифрирования. Также определены алгоритмы предварительной обработки изображений, необходимые для обеспечения возможности дешифрирования тепловизионных сканерных изображений с применением нейросетевых алгоритмов. В завершении представлена структура численного метода, предусматривающего выполнение последовательности этапов предварительной обработки и дешифрирования с применением нейросетевых алгоритмов сканерных тепловизионных изображений.

Исследование методов дешифрирования

Для исследований определены и выбраны нейросетевые алгоритмы семантической сегментации из списка [1], поддерживаемые программным интерфейсом библиотеки машинного зрения OpenCV [2, 3] с целью обеспечения возможности интеграции и адаптации исследуемых нейросетевых алгоритмов в программное обеспечение, разработанное на языке программирования C++.

В перечень тестируемых нейросетевых алгоритмов семантической сегментации вошли Enet [4, 5], FCN8 [6, 7], DeepLabv3+ [8, 9] с кодером на основе СНС MobileNetv2 [9] (далее – DL MobileNetv2), DeepLabv3+ с кодером на основе СНС Xception65 [8, 9] (далее – DL Xception65), Unet [10], в качестве тестируемых предобученных нейросетевых моделей были соответственно использованы модели [11, 12, 13, 14, 15]. В качестве графического вычислителя использована видеокарта на основе GTX 1080ti. При этом тестирование скорости нейросетевого алгоритма Unet выполнялось с использованием программного интерфейса фреймворка PyTorch на языке Python в связи с тем, что предобученную модель нейросетевого алгоритма Unet в формате ONNX [20] не удалось запустить с использованием фреймворка OpenCV [21]. Результаты тестирования скорости обработки выбранными методами приведены в таблице 1.

Таблица 1 – Результаты тестирования скорости обработки

Table 1 – Processing speed test results

Метод	Фреймворк (обучение)	Фреймворк (тестирование)	Скорость обработки, кадр/с
Enet	Torch [16]	OpenCV	73
FCN8	Caffe [17]	OpenCV	20
DL MbleNetv2	TF1 [18]	OpenCV	46
DL Xception65	TF1	OpenCV	27
Unet	PyTorch [19]	PyTorch	29

Для исследования точности дешифрирования выполнено обучение и тестирование выбранных нейросетевых алгоритмов. Обучение нейросетевых моделей Enet и FCN8 с применением библиотек Torch и Caffe не выполнялось, так как данные библиотеки машинного обучения на момент проведения исследований не имели актуальных версий, совместимых с

библиотеками CUDA и драйверами для используемых в тестах графических ускорителей типа NVidia 1080 Ti. Таким образом, исследования, направленные на определение точности дешифрирования, выполнены для нейросетевых алгоритмов DL MobileNetv2 и DL Xception65 с применением библиотеки машинного зрения OpenCV, а также для нейросетевого алгоритма Unet с применением библиотеки PyTorch.

Для обучения моделей нейросетевых алгоритмов создан набор данных из сканерных тепловизионных снимков, для чего выполнена разметка объектов на 905 тепловизионных снимках, на которых были выделены объекты пяти классов:

- «Roads» – дороги (трассы) с ровными контурами с темным оттенком (рисунок 1, а);
- «Track» – проселочные дороги (колеи) с двумя полосами от колес (рисунок 1, б);
- «Country Road» – проселочные дороги, не имеющие асфальтного покрытия или проходящие через населенные пункты (рисунок 1, в);
- «River» – реки со светлым оттенком в виде тонкой полосы (рисунок 2, а);
- «Lake» – озера – объекты, имеющие характерный светлый ровный оттенок, которые занимает большую по сравнению с объектами «River» площадь изображения (рисунок 2, б).




Рисунок 1 – Пример исходных изображений – верхний ряд, пример изображений из верхнего ряда с выполненной разметкой для классов:

а – «Road», б – «Track», в – «CountryRoad» - нижний ряд

Figure 1 – Examples of original images (upper row); examples of images from upper row with marking applied to classes: а – «Road», б – «Track», с – «CountryRoad» (lower row)




Рисунок 2 – Пример исходных изображений – верхний ряд, пример изображений из верхнего ряда с выполненной разметкой для классов: а – «River»; б – «Lake» - нижний ряд

Figure 2 – Examples of original images (upper row); examples of images from upper row with marking applied to classes а – «River», б – «Lake» (lower row)

Для оценки качества обучения алгоритмов, была сделана разметка на 195 тестовых снимках. Оценка точности семантической сегментации объектов выполнялась согласно формуле 1 [22]:

$$P = \frac{T_p}{T_p + F_p + F_n} \quad (1)$$

где P – точность семантической сегментации (далее – точность сегментации), T_p – количество верно определенных пикселей изображения, F_p – количество неверно определенных пикселей, F_n – количество не найденных пикселей, заданных в разметке.

Обучение нейросетевых алгоритмов DL MobileNetv2 и DL Xception65 выполнялось с применением библиотеки DeepLab. Обучение нейросетевого алгоритма Unet выполнялось с применением библиотеки PyTorch. Для всех тестируемых нейросетевых алгоритмов обучение прекращалось, когда значения функции потерь достигали определенного минимального уровня, при котором среднее значение функции потерь не изменялось на протяжении нескольких десятков итераций.

При визуальной оценке результатов выполнения семантической сегментации с применением обученных моделей нейросетевых алгоритмов установлено, что модель нейросетевого алгоритма Unet существенно уступает по точности нейросетевым алгоритмам DL MobileNetv2 и DL Xception65 (рисунок 3). В связи с этим для сокращения времени обработки результатов тестирования реализован программный интерфейс, обеспечивающий вычисления по формуле 1, только на языке C++ для нейросетевых алгоритмов Xception_65 и MobileNetV2, запускаемых с применением библиотеки DeepLab. Для нейросетевого алгоритма Unet, обученного с применением библиотеки PyTorch и тестируемого на языке программирования Python, вычисления по формуле 1 не выполнялись.




Рисунок 3 – Примеры семантической сегментации:

а – исходные изображения; б – семантическая сегментация алгоритмом DL Xception65;

в – семантическая сегментация алгоритмом Unet

Figure 3 – Examples of semantic segmentation:

а – original images; б – semantic segmentation by DL Xception65 algorithm,

в – semantic segmentation by Unet algorithm

Результаты оценки точности выполнения семантической сегментации нейросетевыми алгоритмами DL MobileNetv2 и DL Xception65 приведены в таблице 2.

Таблица 2 – Результаты оценки точности выполнения семантической сегментации

Table 2 – Semantic segmentation accuracy assessment results

Алгоритм	Точность сегментации для различных классов, %					
	Road	Track	CountryRoad	River	Lake	Среднее
DL MobileNetV2	50,2	39,7	31,3	31,5	87,6	48,1
DL Xception65	82,9	64,6	56,0	60,6	93,7	71,5

По результатам исследования алгоритм DL Xception65 показал наибольшее значение точности, при этом скорость обработки графических данных этим алгоритмом составила 27 кадров/с. При выборе между двумя алгоритмами, представленными в таблице 2, сделав

упор на точность дешифрирования, определим алгоритм DL Xception65 как базовый алгоритм семантической сегментации, который необходимо доработать в плане повышения скорости обработки без потери точности дешифрирования.

Поскольку базовый алгоритм семантической сегментации DL Xception65 обеспечивает скорость обработки графической информации не более 27 кадров/с, что меньше минимально требуемого значения 37 кадров/с, необходимо выполнить исследования, направленные на повышение скорости обработки без существенной потери точности дешифрирования.

Нейросетевой алгоритм семантической сегментации DL Xception65 [6] (рисунок 4) состоит из кодера (encoder), который отвечает за извлечение признаков и уменьшение размеров карт признаков, и декодера (decoder) – блока, который увеличивает разрешение карт признаков до размеров исходного изображения.




Рисунок 4 – Структура нейросетевого алгоритма DL Xception65

Figure 4 – Structure of DL Xception65 neural network algorithm

Кодер нейросетевого алгоритма DL Xception65 построен на основе СНС Xception65 (рисунок 5), которая состоит из модулей «Entry flow», «Middle flow» и «Exit flow». Модуль «Middle flow» включает 16 блоков «Sep Conv 728, 3x3», состоящих из трех одинаковых групп слоев – слой раздельной свертки по глубине, слой пакетной нормализации и сверточный слой, где также предусмотрена передача с блока на блок сигналов остаточной связи.

С целью уменьшения количества весов нейросетевого алгоритма и увеличения скорости обработки изображений исходная структура кодера на основе СНС Xception65 была преобразована так, чтобы модуль «Middle flow» состоял не из шестнадцати, а из четырех блоков «Sep Conv 728, 3x3» (рисунок 6), и данный нейросетевой алгоритм обозначен как DL Xception65_4. Результаты сравнительного анализа базового метода, и метода на основе модифицированного нейросетевого алгоритма приведены в таблице 3. Отметим, что для исходного нейросетевого алгоритма DL Xception65 наиболее высокое значение точности получено после 120000 итераций обучения, а для модифицированного нейросетевого алгоритма DL Xception65_4 – после 60000 итераций обучения.

Таблица 3 – Результаты анализа DL Xception65 и DL Xception_65_4

Table 3 – DL Xception65 and DL Xception_65_4 analysis results

Параметр	Метод	DL Xception65	DL Xception65_4
Количество обучаемых параметров		40 949 638	21 581 926
Точность семантической сегментации, P	Класс «Road»	0,88	0,83
	Класс «Track»	0,80	0,75
	Класс «Country Road»	0,84	0,81
	Класс «Lake»	0,96	0,96
	Класс «River»	0,61	0,55
Средняя точность сегментации, P		0,82	0,78
Время обработки одного кадра, с		0,036	0,025
Эффективность алгоритма, Eff		22,90	31,20




Рисунок 5 – Структура кодера Xception_65 базового метода
Figure 5 – Structure of Xception_65 basic method encoder




Рисунок 6 – Структура кодера модифицированного метода DL Xception_65_4
Figure 6 – Structure of DL Xception_65_4 modified method encoder

Для сравнения базового и разработанного алгоритмов введена метрика Eff :

$$Eff = \frac{P}{t_{обр}}, \quad (2)$$

где P – точность семантической сегментации, измеряемая в относительных единицах и вычисляемая по формуле 1, $t_{обр}$ – время обработки одного кадра изображения, измеряемое в секундах.

Разработанный алгоритм семантической сегментации DL Xception65_4 отличается от базового нейросетевого алгоритма DL Xception65 меньшим количеством параметров нейросетевой модели, что позволило получить более высокое значение отношения точности ко времени дешифрирования, при этом у разработанного алгоритма снижение точности составило 5 % со значения 0,82 до значения 0,78, а значение скорости повысилось на 30 % – с 27 до 40 кадров/с.

Исследование методов предварительной обработки


В исследовании [23] обоснована необходимость применения алгоритмов предварительной обработки изображений при реализации методов обработки сканерных тепловизионных изображений на основе сверточных нейронных сетей для автоматического обнаружения заданных типов объектов. Результаты исследования [23] приведены в таблице 4. Они позволяют сделать вывод о том, что для решения поставленных задач целесообразно применять наиболее простые с вычислительной точки зрения алгоритмы предварительной обработки, например, алгоритм линейного контрастирования.

Таблица 4 – Результаты исследования для алгоритма DL Xception65_4

Table 4 – DL Xception65_4 algorithm research results

Метод предварительной обработки	Точность сегментации, Р	
	Класс «Дороги»	Класс «Водный объект»
Линейное контрастирование	0,758	0,904
DDE	0,743	0,908
DDE+CLAHE	0,724	0,900

Следует отметить, что применительно к сканерным тепловизионным изображениям на этапе предварительной обработки также целесообразно применение методов компенсации неоднородности чувствительности элементов фотоприемного устройства (далее – компенсация неоднородности ФПУ), например по методике, приведенной в [24], так как при резком изменении интенсивности излучения подстилающей поверхности формируемое сканерное тепловизионное изображение может быть существенно искажено строчной структурой (рисунок 7, а), что может привести к снижению точности автоматического дешифрирования. Применение компенсации неоднородности ФПУ на этапе предварительной обработки позволяет устранить данный эффект (рисунок 7, б)



а (a)

б (b)

Рисунок 7 – Пример выполнения компенсации неоднородности ФПУ:

а – искаженное изображение, б – изображение после выполнения фоновой коррекции

Figure 7 – Example of photodetector heterogeneity compensation:

a – distorted image, b – image after background correction

Структура разработанного метода дешифрирования

На основе выполненных исследований разработан численный метод, предусматривающий выполнение последовательности этапов предварительной обработки и дешифрирования на основе СНС сканерных ТПВ-изображений (рисунок 8).

Разработанный численный метод автоматического дешифрирования сканерных ТПВ-изображений позволяет обеспечить быстрое и точное обнаружение заданных типов объектов.




Рисунок 8 – Структура метода дешифрирования сканерных ТПВ-изображений
Figure 8 – Structure of the scanner thermal image decoding method

Заключение

Разработан численный метод обработки сканерных тепловизионных изображений на основе сверточных нейронных сетей для автоматического обнаружения заданных типов объектов на изображениях, отличающийся от известного способа меньшим количеством параметров нейросетевой модели с более высоким значением отношения точности ко времени дешифрирования. Разработанный метод позволяет автоматизировать процесс дешифрирования графической информации для обработки графических данных, формируемых сканерными тепловизионными съемочными системами, в режиме реального времени. Разработанный метод реализован в программном комплексе дешифрирования сканерных тепловизионных изображений для автоматического обнаружения заданных типов объектов, который зарегистрирован в государственном реестре программ для ЭВМ [25].

Библиографический список

1. Электронный ресурс. URL: <https://github.com/opencv/opencv/wiki/Deep-Learning-in-OpenCV>.
2. **Shubho F.H., Iftekhhar F., Hossain E., Siddique S.** Real-time traffic monitoring and traffic offense detection using YOLOv4 and OpenCV DNN // Сборник: IEEE Region 10 Annual International Conference, Proceedings/TENCON. Сер. «TENCON 2021 – 2021 IEEE Region 10 Conference». 2021. С. 46-51.
3. Электронный ресурс. URL: <https://opencv.org>.
4. **Paszke A., Chaurasia A., Kim S., Culurciello E.** ENet: a deep neural network architecture for real-time semantic segmentation. DOI: 10.48550/arXiv:1606.02147, 2016.
5. **Wang Y.** Remote sensing image semantic segmentation network based on ENet // The Journal of Engineering. 2022. Т. 2022. № 12. С. 1219-1227.
6. **Long J., Shelhamer E., Darrel T.** Fully convolutional networks for semantic segmentation // arXiv: 1411.4038, 2015.
7. **Saeedizadeh N., Jalali S.M.Ja., Khan B., Kebria P.M., Mohamed Sh.** A new optimization approach based on neural architecture search to enhance deep U-NET for efficient road segmentation // Knowledge-Based Systems. 2024. Vol. 296. P. 111966.
8. **Chen L., Yukun Z., Papandreou G., Schroff F., Adam H.** Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation // arXiv: 1802.02611, 2018.
9. **Peng H., Xiang S., Chen M., Li H., Su Q.** DCN-DEEPLABV3+: Novel road segmentation algorithm based on improved DEEPLABV3+ // IEEE Access. 2024. Vol. 12. Pp. 87397-87406.
10. **Ronneberger O., Fischer P., Brox T.** U-Net: Convolutional Networks for Biomedical Image Segmentation // Сборник конференции: Medical image computing and computer-assisted intervention – MICCAI 2015. С. 234-241.
11. Электронный ресурс. URL: <https://www.dropbox.com/s/tdde0mawbi5dugq/Enet-model-best.net?dl=1>.
12. Электронный ресурс. URL: <http://dl.caffe.berkeleyvision.org/fcn8s-heavy-pascal.caffemodel>.
13. Электронный ресурс. URL: http://download.tensorflow.org/models/deeplabv3_mnv2_pascal_trainval_2018_01_29.tar.gz.

14. Электронный ресурс. URL: http://download.tensorflow.org/models/deeplabv3_pas-cal_train_aug_2018_01_04.tar.gz.
15. Электронный ресурс. URL: <http://github.com/mateuszbuda/brain-segmentation-pytorch/> weights/unet.pt.
16. Электронный ресурс. URL: <https://torch.ch>.
17. Электронный ресурс. URL: <http://Caffe.berkeleyvision.org>.
18. Электронный ресурс. URL: <https://www.tensorflow.org>.
19. Электронный ресурс. URL: <https://pytorch.org>.
20. Электронный ресурс. URL: <https://onnx.ai>.
21. Электронный ресурс. URL: <https://github.com/opencv/opencv/issues/18072>. 21. OpenCV does not support ONNX models with dynamic input/output shape.
22. Everingham M., Eslami S.M.A., Van G.L., Williams C.K.I., Winn J, Zisserman A. The Pascal Visual Object Classes Challenge – a Retrospective // International Journal of Computer Vision manuscript. 2015. No. 111. Pp. 98-136. DOI:10.1007/s11263-014-07335.
23. Мингалева А.В. Исследование влияния методов предварительной обработки тепловизионных сканерных изображений на качество автоматизированного дешифрирования с применением нейросетевых алгоритмов семантической сегментации // Региональные проблемы дистанционного зондирования Земли: Материалы XI Международной научной конференции (Красноярск, 10-13 сентября 2024 г.) / Красноярск: Сиб. Федер. ун-т, 2024. С. 59-63.
24. Батавин М.Н., Мингалева А.В., Савин Д.Е., Шушарин С.Н. Коррекция неоднородностей характеристик фоточувствительных элементов субматричного приемника инфракрасного излучения в системе дистанционного зондирования Земли // X юбилейный Международный форум «Оптические системы и технологии – OPTICS-EXPO 2014»: Официальный каталог. М.: ОАО «ВДНХ», 2014. С. 54.
25. Свидетельство о государственной регистрации программы для ЭВМ № 2023611283 РФ. Программа автоматизированной обработки графической информации / Мингалева А.В., Белов А.В., Габдуллин И.М., Марданова Д.А, заявитель и правообладатель Акционерное общество «Научно-производственное объединение «Государственный институт прикладной оптики»

UDC 519.688

METHOD AND ALGORITHMS OF PROCESSING SCANNER THERMAL IMAGES BASED ON HIGH-ACCURACY NEURAL NETWORKS FOR AUTOMATIC DETECTION OF SPECIFIED TYPES OF OBJECTS

A. V. Mingalev, Head of Department in JSC «NPO GIPO», Kazan, Russia;
orcid.org/0000-0001-5848-1992, e-mail: gipo@shvabe.com

This paper presents the results of research conducted to develop a numerical method and processing algorithms for scanner thermal images based on high-accuracy neural networks for automatic detection of objects in thermal images. The aim was to ensure the possibility of decoding graphic data generated by scanner thermal imaging systems in real time. The main criteria of evaluating the algorithms under research were data processing speed and decoding accuracy. The criteria were assessed on the basis of practical experiments involving training and running neural network algorithms using the developed software on a computer. A numerical method of processing scanner thermal images based on high-accuracy neural networks for automatic detection of specified types of objects in thermal images has been developed that is different from the known method by a smaller number of neural network model parameters with higher accuracy-to-decoding time ratio. This allows for automatic detection of specified types of objects in scanner thermal images in real time as part of various software and hardware systems for automated decoding of graphic information.

Keywords: neural network algorithms, semantic segmentation, machine learning, scanner thermal imaging systems.

DOI: 10.21667/1995-4565-2025-91-158-167

References

1. Electronic resource. URL: <https://github.com/opencv/opencv/wiki/Deep-Learning-in-OpenCV>.
2. **Shubho F.H., Iftekhar F., Hossain E., Siddique S.** Real-time traffic monitoring and traffic offense detection using YOLOv4 and OpenCV DNN. *Sbornik: IEEE Region 10 Annual International Conference, Proceedings/TENCON*. Cep. «TENCON 2021 – 2021 IEEE Region 10 Conference». 2021, pp. 46-51.
3. **Elektronnnyj resurs** URL: <https://opencv.org>.
4. **Paszke A., Chaurasia A., Kim S., Culurciello E.** ENet: a deep neural network architecture for real-time semantic segmentation. DOI:10.48550/arXiv:1606.02147, 2016.
5. **Wang Y.** Remote sensing image semantic segmentation network based on ENet. *The Journal of Engineering*. 2022, no. 12, pp. 1219-1227.
6. **Long J., Shelhamer E., Darrel T.** *Fully convolutional networks for semantic segmentation*. ArXiv: 1411.4038, 2015.
7. **Saeedizadeh N., Jalali S.M.Ja., Khan B., Kebria P.M., Mohamed Sh.** A new optimization approach based on neural architecture search to enhance deep U-NET for efficient road segmentation. *Knowledge-Based Systems*. 2024, vol. 296, pp. 111966.
8. **Chen L., Yukun Z., Papandreou G., Schroff F., Adam H.** Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. ArXiv: 1802.02611, 2018.
9. **Peng H., Xiang S., Chen M., Li H., Su Q.** DCN-DEEPLABV3+: *Novel road segmentation algorithm based on improved DEEPLABV3+ IEEE Access*. 2024, vol. 12, pp. 87397-87406.
10. **Ronneberger O., Fischer P., Brox T.** U-Net: Convolutional Networks for Biomedical Image Segmentation. *Sbornik konferencii. Medical image computing and computer-assisted intervention – MICCAI* 2015, pp. 234-241.
11. Electronic resource. URL: <https://www.dropbox.com/s/tdde0mawbi5dugq/Enet-model-best.net?dl=1>.
12. Electronic resource. URL: <http://dl.caffe.berkeleyvision.org/fcn8s-heavy-pascal.caffemodel>.
13. Electronic resource. URL: http://download.tensorflow.org/models/deeplabv3_mnv2_pas-cal_train_val_2018_01_29.tar.gz.
14. Electronic resource. URL: http://download.tensorflow.org/models/deeplabv3_pas-cal_train_aug_2018_01_04.tar.gz.
15. Electronic resource. URL: <http://github.com/mateuszbuda/brain-segmentation-pytorch/weights/unet.pt>.
16. Electronic resource. URL: <https://torch.ch>.
17. Electronic resource. URL: <http://caffe.berkeleyvision.org>.
18. Electronic resource. URL: <https://www.tensorflow.org>.
19. Electronic resource. URL: <https://pytorch.org>.
20. Electronic resource. URL: <https://onnx.ai>.
21. Electronic resource. URL: <https://github.com/opencv/opencv/issues/18072>. 21. *OpenCV does not support ONNX models with dynamic input/output shape*.
22. **Everingham M., Eslami S.M.A., Van G.L., Williams C.K.I., Winn J., Zisserman A.** The Pascal Visual Object Classes Challenge – a Retrospective. *International Journal of Computer Vision manuscript*. 2015, no. 111, pp. 98-136. DOI:10.1007/s11263-014-07335
23. **Mingalev A.V.** Issledovanie vliyaniya metodov predvaritelnoy obrabotki teplovizionnykh skanernykh izobrazheniy na kachestvo avtomatizovannogo deshifrovaniya s primeneniem neyrosetevykh algoritmov semanticheskoy segmentatsii. *Regional Problems of Remote Sensing of the Earth: Materials of the 11th International Scientific Conference (Krasnoyarsk, 10-13 September 2024)*, Krasnoyarsk, Siberian Federal University. 2024, pp. 59-63 (in Russian).
24. **Batavin M.N., Mingalev A.V., Savin D.Ye., Shusharin S.N.** Korrektsiya neodnorodnostey kharakteristik fotochuvstvitelnykh elementov submatrichnogo priemnika infrakrasnogo izlucheniya v sisteme distantsionnogo zondirovaniya Zemli. *10th International Forum «Optical Systems and Technologies – OPTICS-EXPO 2014»: official catalogue*, Moscow, OAO «VDNKH», 2014.
25. State registration certificate for computer program no. 2023611283, Russian Federation. *Program for automated processing of graphic information*. **Mingalev A.V., Belov A.V., Gabdullin I.M., Mardanova D. A.**, applicant and copyright holder JSC «Scientific and Production Association «State Institute of Applied Optics»».