



DOI: <https://doi.org/10.15688/mpcm.jvolsu.2025.2.5>

УДК 004.93+556.5

Дата поступления статьи: 26.03.2025

ББК 32.973-018.2+26.222(2Рос-4Вор)

Дата принятия статьи: 22.05.2025

РАЗРАБОТКА СИСТЕМЫ КОМПЬЮТЕРНОГО ЗРЕНИЯ СРЕДСТВАМИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОЦЕНКИ ЗАРАСТАНИЯ ВЫСШЕЙ ВОДНОЙ РАСТИТЕЛЬНОСТЬЮ ЦИМЛЯНСКОГО ВОДОХРАНИЛИЩА

Александр Александрович Полковников

Кандидат физико-математических наук, доцент кафедры инженерно-математических и естественно-научных дисциплин, Волжский филиал Волгоградского государственного университета
polkovnikov@vgi.volsu.ru
<https://orcid.org/0000-0002-0869-3687>
ул. 40 лет Победы, 11, 404133 г. Волжский, Российская Федерация

Анна Игоревна Кочеткова

Кандидат биологических наук, доцент кафедры инженерно-математических и естественно-научных дисциплин, Волжский филиал Волгоградского государственного университета
kochetkova.ai@vgi.volsu.ru
<https://orcid.org/0000-0003-3134-1839>
ул. 40 лет Победы, 11, 404133 г. Волжский, Российская Федерация

Елена Сергеевна Брызгалина

Старший преподаватель кафедры инженерно-математических и естественно-научных дисциплин, Волжский филиал Волгоградского государственного университета
bryzgalina.es@vgi.volsu.ru
<https://orcid.org/0000-0002-5103-9488>
ул. 40 лет Победы, 11, 404133 г. Волжский, Российская Федерация

Дмитрий Александрович Катунов

Преподаватель Университетского колледжа, Волжский филиал Волгоградского государственного университета
ул. 40 лет Победы, 11, 404133 г. Волжский, Российская Федерация

Аннотация. Моделирование процесса зарастания мелководий высшей водной растительностью имеет важное практическое значение для рыбохозяйственной отрасли нашей страны и является неотъемлемой частью мониторинга водных объектов. В статье представлены результаты разработки системы компьютерного зрения средствами машинного обучения на базе архитектур SegNet и U-Net для оценки зарастания высшей водной растительностью Цимлянского водохранилища. Для обучения и тестирования моделей применялся набор данных, состоящий из 200 пар снимков Landsat, охватывающих 24 различных участка Цимлянского водохранилища за разные годы, а также соответствующих им разметок зарастания. Процесс обучения SegNet продолжался в течение 50 эпох, U-Net обучалась в течение 30 эпох. Каждая эпоха обучения включала итерации по обучающим данным, вычисление функции потерь, обратное распространение градиентов и обновление весов с использованием оптимизатора. После каждой эпохи производилась валидация модели на валидационной выборке для оценки ее производительности. Точность модели SegNet составила 0,869, U-Net – 0,881. Для оценки качества сегментации зарастания на тестовой выборке были измерены коэффициенты Жаккара (IoU). Модель U-Net показала IoU на уровне 0,665, у SegNet этот показатель составил 0,633.

Ключевые слова: система компьютерного зрения средствами машинного обучения, SegNet, U-Net, высшая водная растительность, Цимлянское водохранилище.

Введение

Гидробиологические исследования высшей водной растительности являются важной составляющей при проведении комплексной оценки состояния водных объектов. Они реализуются согласно общепринятым методикам А.П. Белявской (1979), В.Г. Папченкова (1979) и В.М. Катанской (1981), в дальнейшем дополненными и усовершенствованными В.Г. Папченковым (2003, 2006) [1; 4; 8–11]. Исследования высшей водной растительности включают в себя:

- 1) Картографирование и геоботаническое описание растительности.
- 2) Отбор проб растений для определения сырой и надземной воздушно-сухой биомассы в период максимальной физиологической активности ВВР (июль, август).

Одновременно с гидробиологическими работами, как правило, осуществляется батиметрическая съемка, определение координат на местности с помощью GPS. Наряду с полевыми работами, которые были указаны выше, ученые активно применяют методы дистанционного зондирования Земли из космоса, которые в значительной мере упрощают задачу по выявлению площадей зарастания высшей водной растительностью [6]. В связи с этим становится актуальной разработка системы, которая позволит автоматически выявлять зарастания на космическом снимке.

Технологии компьютерного зрения и машинного обучения стали неотъемлемой частью многих отраслей. Их использование позволяет автоматизировать и улучшить точность многих задач, которые ранее требовали участия человека [2; 3; 5; 12; 13].

Целью данной статьи является разработка системы компьютерного зрения, использующей методы глубокого обучения для автоматизированной разметки зарастания на спутниковых изображениях участков Цимлянского водохранилища.

Для достижения данной цели необходимо выполнить следующие задачи:

- 1) Анализ существующих методов и алгоритмов семантической сегментации изображений.
- 2) Сбор и подготовка набора данных спутниковых снимков участков Цимлянского водохранилища, включающего разметку зарастаний.
- 3) Разработка модели глубокого обучения для автоматизированной разметки зарастания.
- 4) Обучение и оптимизация разработанной модели.

Для разработки системы компьютерного зрения использовался язык программирования Python, наиболее подходящий для задач глубокого обучения. Работа велась в облачной среде Google Colab [14], обеспечивающей доступ к GPU и TPU для ускоренного обучения моделей. Основной библиотекой для глубокого обучения была PyTorch [19], предоставляющая средства для построения и оптимизации нейронных сетей. Для работы с изображениями применялись библиотеки OpenCV (cv2) [17] и scikit-image (skimage) [20], для вычислений и анализа данных — NumPy [16] и pandas [18]. Визуализация данных осуществлялась с помощью Matplotlib [15]. Дополнительно использовались системные библиотеки os и random для работы с файловой системой и генерации случайных чисел.

В контексте мониторинга зарастания Цимлянского водохранилища задача семантической сегментации заключается в том, чтобы каждому пикселю снимка (например, полученного со спутника Landsat) участка этого водохранилища была присвоена определенная метка класса. В данном случае этими метками классов могут быть «зарастание» и «фон». Такой подход позволит автоматизировать процесс разметки зарастания, тем самым упростит и ускорит процесс мониторинга и оценки уровня зарастания в данной области, минуя необходимость ручной разметки каждого пикселя.

В работе будет использоваться модель f_θ с параметрами θ , которая приближает отображение

$$f : X \rightarrow Y,$$

где X – входное изображение. Под семантической сегментацией понимается оптимизация параметров θ модели f_θ , минимизирующая функцию потерь

$$\theta^* = \arg \min_{\theta} L(f_\theta(X), Y),$$

где L – функция потерь, измеряющая расхождение предсказания \hat{Y} с истинной разметкой Y .

В работе будет использоваться алгоритм обратного распространения ошибки (Backpropagation):

- 1) Прямой проход (Forward Pass): пропускаем входные данные через модель и вычисляем предсказанную моделью бинарную маску зарастания \hat{Y} , а также соответствующую ошибку

$$L(\hat{Y}, Y) = 1 - \frac{|\hat{Y} \cap Y|}{|\hat{Y} \cup Y|},$$

где Y – истинные сегментированные пиксели, \hat{Y} – предсказанные сегментированные пиксели, $|\cdot|$ – обозначение мощности множества, а \cap и \cup – пересечение и объединение множеств соответственно.

- 2) Обратный проход (Backward Pass): вычисляем градиенты функции ошибки L по отношению к выходным данным модели. Затем с помощью цепного правила вычисляем градиенты для каждого слоя по отношению к параметрам модели θ .
- 3) Обновление параметров: после вычисления градиентов для всех параметров модели обновляем их с использованием градиентного спуска:

$$\theta = \theta - \eta \cdot \nabla_{\theta} L.$$

Для обучения и тестирования модели применялся набор данных

$$D = \{(X_k, Y_k) \mid k = 1, 2, \dots, N\},$$

состоящий из $N = 200$ пар снимков, полученных со спутника Landsat, охватывающих 24 различных участка Цимлянского водохранилища за разные годы, а также соответствующих им разметок зарастания, где $X_k \in R^{H \times W \times C}$ – спутниковый снимок размером $H \times W$ с 3 каналами (RGB), $Y_k \in \{0, 1\}^{H \times W}$ – бинарная маска разметки зарастания:

$$Y_{i,j} = \begin{cases} 1, & \text{если пиксель } (i, j) \text{ относится к зарастанию;} \\ 0, & \text{если пиксель } (i, j) \text{ относится к фону.} \end{cases}$$

В бинарных масках значение 1 соответствует областям зарастания, а значение 0 – остальным областям. Эти маски были созданы на основе снимков с разметкой зарастания. Все снимки и бинарные маски были приведены к размеру 256×256 пикселей. При изменении размера снимков использовалось сглаживание для получения более качественных результатов.

Далее для проверки точности предсказаний была применена кросс-валидация. Все снимки были разделены на три группы: 100 из них использовалось для обучения модели, 50 – для валидации, а еще 50 – для тестирования.

Для последующего использования в обучении модели был задан размер батча, равный 25. Затем снимки и соответствующие им маски были загружены в DataLoader, что позволит эффективно работать с данными во время обучения. DataLoader автоматически разбивает данные на батчи и предоставляет возможность для параллельной загрузки данных во время обучения модели [7].

1. Архитектура модели SegNet

Архитектура SegNet представляет собой сеть, состоящую из трех основных компонентов: энкодера, бутылочного горла и декодера. Энкодер выполняет извлечение признаков с помощью четырех блоков свертки с последующим использованием функции активации ReLU

$$ReLU(X) = \max(0, X)$$

и нормализации по батчу. После каждого блока свертки выполняется пулинг для уменьшения размерности.

Пусть $X = \{x_1, x_2, \dots, x_m\}$ – это батч из m примеров:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i, \quad d_B = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2,$$

где μ_B – среднее значение по батчу, d_B – дисперсия по батчу. Каждый элемент батча нормализуется:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{d_B + \varepsilon}},$$

где ε – это маленькое значение для предотвращения деления на ноль. После нормализации данные могут быть масштабированы и сдвинуты с помощью параметров γ и β , которые обучаются во время тренировки, для обратного перехода к физическим значениям:

$$y_i = \gamma \hat{x}_i + \beta,$$

где γ – параметр масштаба, β – параметр сдвига. Таким образом, итоговая операция нормализации по батчу для каждого примера x_i в батче выглядит так:

$$y_i = \gamma \cdot \frac{x_i - \mu_B}{\sqrt{d_B + \varepsilon}} + \beta.$$

Бутылочное горло содержит две группы сверточных слоев для сжатия и восстановления информации. Декодер начинается с операций транспонированной свертки для увеличения размерности, за которыми следуют четыре блока декодирования. Каждый блок содержит три сверточных слоя, функцию активации ReLU и нормализацию по батчу. В конце декодера используется еще один сверточный слой без функции активации для получения финального сегментационного вывода, представляющего вероятности принадлежности пикселей к классу. Схема архитектуры Segnet представлена на рисунке 1.

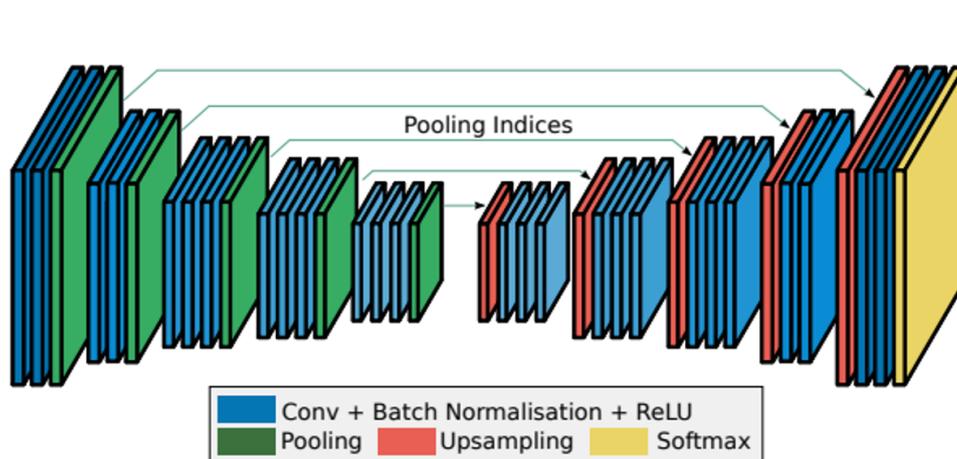


Рис. 1. Схема архитектуры SegNet

2. Архитектура модели U-Net

Архитектура U-Net также состоит из трех основных частей: энкодера, бутылочного горла и декодера. Энкодер включает четыре блока свертки с функцией активации ReLU и нормализацией по батчу, а также операцию пулинга для уменьшения размерности. Стоит отметить, что в энкодере сети выделяются основные признаки изображения, такие как края, текстуры и общие контуры объектов. Эти признаки кодируются на разных уровнях абстракции.

После последнего блока энкодера следует бутылочное горло (Bottleneck), которое помогает увеличить глубину модели и сжать информацию, передаваемую из энкодера в декодер.

Декодер начинается с операций транспонированной свертки для увеличения размерности изображения, а затем последовательно выполняются четыре блока декодирования. Каждый блок декодирования начинается с операции объединения признаков (skip-connections), где используются пропускающие соединения для объединения признаков из соответствующего слоя энкодера с признаками текущего блока декодирования. Затем следуют несколько сверточных слоев, которые выполняют восстановление пространственных деталей изображения.

Пропускающие соединения позволяют передавать пространственную информацию с низких уровней энкодера на высокие уровни декодера, что помогает сохранить и восстановить пространственные детали изображения в процессе декодирования.

В конце декодера используется сверточный слой с функцией активации сигмоиды для получения финального сегментационного вывода, представляющего вероятности принадлежности пикселей к классу.

На рисунке 2 представлена схема архитектуры U-Net.

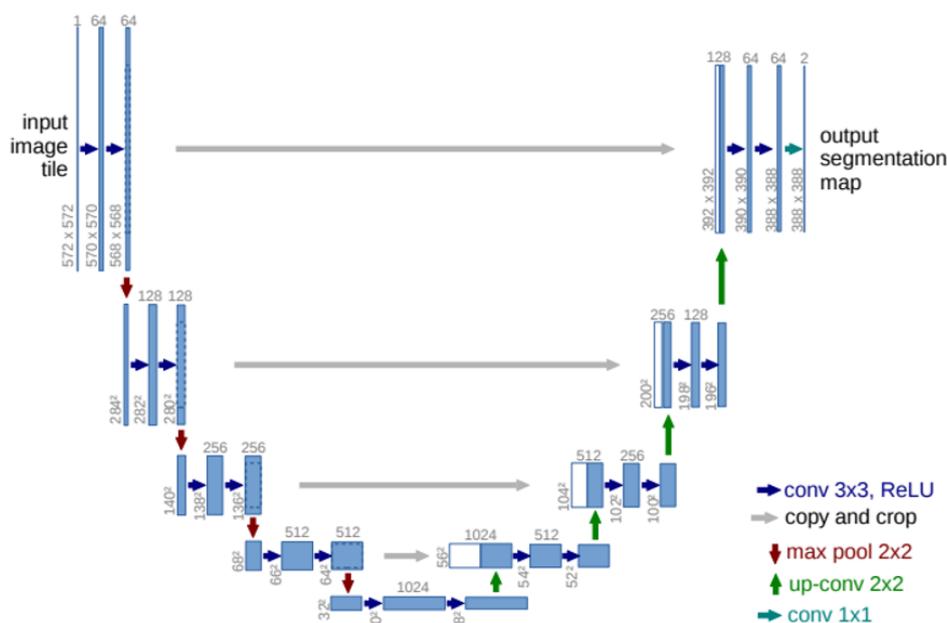


Рис. 2. Схема архитектуры U-Net

3. Обучение моделей SegNet и U-Net

Обучение моделей SegNet и U-Net проводилось с использованием стандартного набора инструментов библиотеки PyTorch. Для обеих моделей была выбрана функция потерь взвешенной бинарной кросс-энтропии. Для SegNet использовался вес класса зарастания, равный 20, для U-Net этот вес составил 30. Для оптимизации был выбран алгоритм Adam с начальной скоростью обучения 0,0001.

Процесс обучения SegNet продолжался в течение 50 эпох, U-Net обучалась в течение 30 эпох. Каждая эпоха обучения включала итерации по обучающим данным, вычисление функции потерь, обратное распространение градиентов и обновление весов с использованием оптимизатора. После каждой эпохи производилась валидация модели на валидационной выборке для оценки ее производительности.

Тестирование моделей включало выбор оптимальных функций активации, оптимизатора и весов классов, которые обеспечивали наилучшую производительность на тестовом наборе данных. Важно отметить, что в ходе обучения модели не проявлялись признаки переобучения, что подтверждается ее стабильной производительностью как на обучающем, так и на валидационном наборах данных.

Для мониторинга процесса обучения и анализа качества полученных результатов использовалась визуализация результатов обучения, включающая визуализацию входных изображений, оригинальных масок и предсказанных масок.

4. Оценка и интерпретация результатов

Для оценки качества работы моделей была вычислена точность (precision) предсказаний по формуле

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

где TP – количество истинно положительных пикселей; FP – количество ложно положительных пикселей.

На этапе валидации моделей SegNet и U-Net были получены следующие результаты: точность модели SegNet составила 0,869, в то время как модель U-Net продемонстрировала немного более высокое значение точности – 0,881.

Дополнительно для оценки качества сегментации объектов на тестовой выборке были измерены коэффициенты Жаккара (IoU)

$$IoU = \frac{|\hat{Y} \cap Y|}{|\hat{Y} \cup Y|}.$$

Модель U-Net показала IoU на уровне 0,665, у SegNet этот показатель составил 0,633. Эти результаты подтверждают превосходство U-Net как по точности, так и по качеству сегментации объектов на данном наборе данных. Это может быть объяснено тем, что архитектура U-Net включает механизм пропуска соединений (skip-connections), который эффективно передает градиенты и информацию о пространственных деталях с низких уровней энкодера на высокие уровни декодера. Это позволяет модели более точно выделять объекты на изображении и лучше улавливать контекст изображения.

Заключение

В данной работе был проведен анализ современных методов и алгоритмов семантической сегментации изображений. Это позволило выбрать наиболее подходящие подходы для решения задачи автоматизированной разметки зарастания водоемов. Собран и подготовлен набор данных спутниковых снимков участков Цимлянского водохранилища с размеченными областями зарастания. На основе современных архитектур нейронных сетей была разработана модель глубокого обучения, специально адаптированная для задачи разметки зарастания. Обучение модели проводилось на подготовленных данных с использованием облачных вычислительных ресурсов Google Colab. Были настроены гиперпараметры модели, такие как скорость обучения, размер батча и количество эпох, подобрана функция потерь, что позволило достичь высокой точности сегментации. Оценено качество работы модели, проведена интерпретация результатов.

В результате работы была создана система для автоматизированной разметки зарастания водоемов, которая может быть интегрирована в существующую инфраструктуру экологического мониторинга. Полученные результаты демонстрируют высокую точность и надежность разработанной модели, что подтверждает ее практическую значимость и потенциал для дальнейшего использования и совершенствования.

СПИСОК ЛИТЕРАТУРЫ

1. Белявская, А. П. К методике изучения водной растительности / А. П. Белявская // Ботанический журнал. — 1979. — Т. 64, № 1. — С. 32–41.
2. Варламова, Л. П. Применение метода скользящего окна для обработки изображений / Л. П. Варламова, Х. А. Турсунов // Scientific Progress. — 2023. — № 4. — С. 151–156.
3. Казанцева, Л. В. Сегментация изображений в алгоритмах беспилотных автомобилей / Л. В. Казанцева, И. И. Юров // Colloquium-Journal. — 2020. — С. 24–26.
4. Катанская, В. М. Высшая водная растительность континентальных водоемов СССР. Методы изучения / В. М. Катанская. — Л. : Наука, 1981. — 187 с.
5. Клячин, А. А. Метод интегральных преобразований в решении задачи обнаружения малогабаритных транспортных средств на изображениях / А. А. Клячин, В. А. Клячин // Математическая физика и компьютерное моделирование. — 2024. — Т. 27, № 4. — С. 23–38. — DOI: <https://doi.org/10.15688/mpcm.jvolsu.2024.4.3>
6. Кочеткова, А. И. Традиционные и современные подходы в оценке зарастания водных объектов высшей водной растительностью / А. И. Кочеткова, Е. С. Брызгалова // Современные проблемы и перспективы развития рыбохозяйственного комплекса : материалы XI Междунар. науч.-практ. конф. молодых ученых и специалистов. — М., 2023. — С. 123–125.
7. Краснова, А. Ю. Изучение принципа работы сверточной нейронной сети / А. Ю. Краснова // E-Scio. — 2020. — С. 1–7.
8. Папченков, В. Г. К методике изучения продуктивности водной растительности в средних и малых реках / В. Г. Папченков // Растительные ресурсы. — 1979. — Т. 15, № 3. — С. 454–459.
9. Папченков, В. Г. Картирование растительного покрова водоемов и водотоков / В. Г. Папченков // Материалы VI Всерос. школы-конференции по водным макрофитам «Гидробиотаника 2005» (п. Борок, 11–16 октября 2005 г.). — Рыбинск : Рыбинский дом печати, 2006. — С. 135–143.
10. Папченков, В. Г. Картирование растительности водоемов и водотоков / В. Г. Папченков // Гидробиотаника: методология, методы : материалы Школы по гидробиотанике (п. Борок, 8–12 апреля 2003 г.). — Рыбинск : Рыбинский дом печати, 2003. — С. 132–136.

11. Папченков, В. Г. Продукция макрофитов и методы ее изучения / В. Г. Папченков // Гидробиология: методология, методы : материалы Школы по гидробиологии (п. Борок, 8–12 апреля 2003 г.). — Рыбинск : Рыбинский дом печати, 2003. — С. 137–145.
12. Разработка классификатора фотоизображений патологий для ультрамалого набора данных / А. А. Адамов, И. А. Гндоян, А. И. Дятчина, В. Н. Храмов // Математическая физика и компьютерное моделирование. — 2023. — Т. 6, № 1. — С. 33–48. — DOI: <https://doi.org/10.15688/mpcm.jvolsu.2023.1.3>
13. CRF and CKD: Modern Approaches to Terminology, Classification, Diagnosis and Treatment / М. Т. Achilov, Y. Khursanov, A. Fayziyev, K. Bahronov // Research Focus. — 2023. — Vol. 2. — P. 79–90.
14. Google Colab. — URL: <https://colab.research.google.com>
15. Matplotlib – Visualization with Python. — URL: <https://matplotlib.org>
16. NumPy. — URL: <https://numpy.org>
17. OpenCV – Open Computer Vision Library. — URL: <https://opencv.org>
18. Pandas – Python Data Analysis Library. — URL: <https://pandas.pydata.org>
19. PyTorch. — URL: <https://pytorch.org>
20. scikit-image: Image processing in Python – scikit-image. — URL: <https://scikit-image.org>

REFERENCES

1. Belyavskaya A.P. K metodike izucheniya vodnoy rastitelnosti [Towards a Methodology for Studying Aquatic Vegetation]. *Botanicheskiy zhurnal*, 1979, vol. 64, no. 1, pp. 32-41.
2. Varlamova L.P., Tursunov Kh.A. Primenenie metoda skolzyashchego okna dlya obrabotki izobrazheniy [Application of the Sliding Window Method for Image Processing]. *Scientific Progress*, 2023, no. 4, pp. 151-156.
3. Kazantseva L.V., Yurov I.I. Segmentatsiya izobrazheniy v algoritmakh bespilotnykh avtomobiley [Image Segmentation in Self-Driving Car Algorithms]. *Colloquium-Journal*, 2020, pp. 24-26.
4. Katanskaya V.M. *Vysshaya vodnaya rastitelnost kontinentalnykh vodoemov SSSR. Metody izucheniya* [Higher Aquatic Vegetation of Continental Reservoirs of the USSR. Study Methods]. Leningrad, Nauka Publ., 1981. 187 p.
5. Klyachin A.A., Klyachin V.A. Metod integralnykh preobrazovaniy v reshenii zadachi obnaruzheniya malogabaritnykh transportnykh sredstv na izobrazheniyakh [Method of Integral Transformations in Solving the Problem of Detecting Small Vehicles in Images]. *Matematicheskaya fizika i kompyuternoe modelirovanie* [Mathematical Physics and Computer Simulation], 2024, vol. 27, no. 4, pp. 23-38. DOI: <https://doi.org/10.15688/mpcm.jvolsu.2024.4.3>
6. Kochetkova A.I., Bryzgalina E.S. Traditsionnye i sovremennye podkhody v otsenke zarastaniya vodnykh obyektov vysshey vodnoy rastitelnostyu [Traditional and Modern Approaches to Assessing the Overgrowth of Water Bodies by Higher Aquatic Vegetation]. *Sovremennye problemy i perspektivy razvitiya rybokhozyaystvennogo kompleksa: materialy XI Mezhdunar. nauch.-prakt. konf. molodykh uchenykh i spetsialistov*. Moscow, 2023, pp. 123-125.
7. Krasnova A.Yu. Izuchenie printsipa raboty svertochnoy neyronnoy seti [Studying the Principle of Operation of a Convolutional Neural Network]. *E-Scio*, 2020, pp. 1-7.
8. Papchenkov V.G. K metodike izucheniya produktivnosti vodnoy rastitelnosti v srednikh i malykh rekakh [Towards a Methodology for Studying the Productivity of Aquatic Vegetation in Medium and Small Rivers]. *Rastitelnye resursy*, 1979, vol. 15, no. 3, pp. 454-459.
9. Papchenkov V.G. Kartirovanie rastitel'nogo pokrova vodoemov i vodotokov [Mapping of Vegetation Cover of Reservoirs and Watercourses]. *Materialy VI Vseros. shkoly-konferentsii po vodnym makrofitam «Gidrobotanika 2005» (p. Borok, 11–16 oktyabrya 2005 g.)*. Rybinsk, Rybinskiy dom pečati, 2006, pp. 135-143.

10. Papchenkov V.G. Kartirovanie rastitelnosti vodoemov i vodotokov [Mapping of Vegetation of Reservoirs and Watercourses]. *Gidrobotanika: metodologiya, metody: materialy Shkoly po gidrobotanike (p. Borok, 8–12 aprelya 2003 g.)*. Rybinsk, Rybinskiy dom pechati, 2003, pp. 132-136.

11. Papchenkov V.G. Produktsiya makrofitov i metody ee izucheniya [Macrophyte Production and Methods of Its Study]. *Gidrobotanika: metodologiya, metody: materialy Shkoly po gidrobotanike (p. Borok, 8–12 aprelya 2003 g.)*. Rybinsk, Rybinskiy dom pechati, 2003, pp. 137-145.

12. Adamov A.A., Gndoyan I.A., Dyatchina A.I., Khramov V.N. Razrabotka klassifikatora fotoizobrazheniy patologiy dlya ultramalogo nabora dannykh [Development of a Classifier of Photo Images of Pathologies for an Ultra-Small Data Set]. *Matematicheskaya fizika i kompyuternoe modelirovanie* [Mathematical Physics and Computer Simulation], 2023, vol. 6, no. 1, pp. 33-48. DOI: <https://doi.org/10.15688/mpcm.jvolsu.2023.1.3>

13. Achilov M.T., Khursanov Y., Fayziyev A., Bahronov K. CRF and CKD: Modern Approaches to Terminology, Classification, Diagnosis and Treatment. *Research Focus*, 2023, vol. 2, pp. 79-90.

14. *Google Colab*. URL: <https://colab.research.google.com>

15. *Matplotlib – Visualization with Python*. URL: <https://matplotlib.org>

16. *NumPy*. URL: <https://numpy.org>

17. *OpenCV – Open Computer Vision Library*. URL: <https://opencv.org>

18. *Pandas – Python Data Analysis Library*. URL: <https://pandas.pydata.org>

19. *PyTorch*. URL: <https://pytorch.org>

20. *scikit-image: Image processing in Python – scikit-image*. URL: <https://scikit-image.org>

DEVELOPMENT OF A COMPUTER VISION SYSTEM USING MACHINE LEARNING TO ACCESS THE OVERGROWING OF HIGHER AQUATIC VEGETATION IN THE TSIMLYANSK RESERVOIR

Alexander A. Polkovnikov

Candidate of Sciences (Physics and Mathematics), Associate Professor,
Department of Engineering, Mathematics and Natural Sciences,
Volzhskiy branch of the Volgograd State University
polkovnikov@vgi.volsu.ru
<https://orcid.org/0000-0002-0869-3687>
40 let Pobedy St, 11, 404133 Volzhskiy, Russian Federation

Anna I. Kochetkova

Candidate of Sciences (Biology), Associate Professor,
Department of Engineering, Mathematics and Natural Sciences,
Volzhskiy branch of the Volgograd State University
kochetkova.ai@vgi.volsu.ru
<https://orcid.org/0000-0003-3134-1839>
40 let Pobedy St, 11, 404133 Volzhskiy, Russian Federation

Elena S. Bryzgalina

Senior Lecturer, Department of Engineering, Mathematics and Natural Sciences,
Volzhskiy branch of the Volgograd State University
bryzgalina.es@vgi.volsu.ru
<https://orcid.org/0000-0002-5103-9488>
40 let Pobedy St, 11, 404133 Volzhskiy, Russian Federation

Dmitriy A. Katunov

Lecturer, University College,
Volzhskiy branch of the Volgograd State University
40 let Pobedy St, 11, 404133 Volzhskiy, Russian Federation

Abstract. Modeling the process of overgrowing of shallow waters with higher aquatic vegetation is of great practical importance for the fisheries industry of our country and is an integral part of monitoring water bodies. The paper presents the results of developing a computer vision system using machine learning based on the SegNet and U-Net architectures to assess the overgrowing of the Tsimlyansk Reservoir with higher aquatic vegetation. A dataset consisting of 200 pairs of Landsat images covering 24 different sections of the Tsimlyansk Reservoir for different years, as well as the corresponding overgrowing marks, was used to train and test the models. The SegNet training process lasted for 50 epochs, U-Net was trained for 30 epochs. Each training epoch included iterations on the training data, calculating the loss function, backpropagating gradients, and updating weights using an optimizer. After each epoch, the model was validated on a validation sample to assess its performance. The accuracy of the SegNet model was 0,869, U-Net – 0,881. To assess the quality of overgrowth segmentation, the Jaccard coefficients (IoU) were measured on the test sample. The U-Net model showed an IoU of 0,665, while SegNet showed an IoU of 0,633.

Key words: computer vision system using machine learning, higher aquatic vegetation, SegNet, U-Net, Tsimlyansk reservoir.