

**МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ:
ТЕОРИЯ И ПРАКТИКА**

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

**СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ ДИСТАНЦИОННОГО
МОНИТОРИНГА ВОДНЫХ РЕСУРСОВ И ЭКОСИСТЕМ ПРИАРАЛЬЯ**

R.T. Gaipnazarov¹

e-mail: gaipnazarovs.uds@gmail.com

Sh.O'. Azimov²

e-mail: hellosherxon@gmail.com

A.A. Choriyev³

e-mail: choriyevanvar08@gmail.com

M.Y. Mamatqulov⁴

e-mail: mamatqulovmavlon006@gmail.com

*Tashkent University of Applied Sciences, Department of "Computer Engineering"
Teacher¹*

*Tashkent University of Applied Sciences, Department of "Computer Engineering"
Assistant²*

*Tashkent University of Applied Sciences, Department of "Computer Engineering"
Assistant³*

*Tashkent University of Applied Sciences, Department of "Computer Engineering"
Assistant⁴*

Аннотация

Истощение водных ресурсов Приаралья вследствие усыхания Аральского моря представляет собой одну из наиболее острых экологических проблем Центральной Азии. В условиях климатических изменений и сокращения водного стока эффективный мониторинг водных объектов становится жизненно важным для устойчивого развития региона. В данной работе предложен подход к автоматизированному мониторингу водных ресурсов Приаралья с использованием методов глубокого обучения, в частности, сверточных нейронных сетей (CNN). Разработана и обучена модель, способная с высокой

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

точностью выделять водные объекты на спутниковых изображениях Sentinel-2, а также учитывать сопутствующие погодные данные. Результаты показали высокую точность сегментации при минимальных ошибках классификации. Исследование демонстрирует потенциал современных методов ИИ для мониторинга водных систем в аридных и полуаридных регионах и подчеркивает их значимость для формирования научно обоснованных стратегий управления природными ресурсами в Приаралье.

Ключевые слова: дистанционное зондирование Земли; глубокое обучение; сверточные нейронные сети; водные ресурсы; Приаралье; спутниковые данные; экология Центральной Азии

Введение

Распад экосистемы Аральского моря стал символом экологической катастрофы XX века. За последние шестьдесят лет площадь водного зеркала сократилась более чем на 90%, что привело к формированию нового пустынного ландшафта — Аралкума. Вместе с исчезновением моря изменились и структуры осадков, биоразнообразие, почвенные и микроклиматические условия обширных территорий Приаралья. Для государств региона, прежде всего Узбекистана, Казахстана и Туркменистана, мониторинг состояния оставшихся водоемов и окружающей среды является не просто задачей научного интереса, но и основой стратегического планирования природопользования и адаптации к изменениям климата.

Традиционные методы наблюдения, основанные на натурных обследованиях, в случае Приаралья сталкиваются с непреодолимыми трудностями: огромная площадь территории, труднодоступность многих участков, нехватка инфраструктуры и людских ресурсов. В этих условиях дистанционное зондирование Земли (ДЗЗ) представляет собой мощный инструмент получения оперативной, репрезентативной и многомерной информации о состоянии водных объектов.

Однако пассивное использование спутниковых данных без углубленного анализа ограничивает потенциал ДЗЗ. Разметка снимков вручную является трудоемким и субъективным процессом, а классические алгоритмы обработки изображений (например, пороговая сегментация, индекс NDWI) часто дают нестабильные результаты в условиях высокоразнообразных пустынных

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

ландшафтов Приаралья, где водные поверхности могут быть визуально схожи с солончаками или влажными песками.

С развитием глубокого обучения, и в частности сверточных нейронных сетей (CNN), появилась возможность значительно повысить точность, скорость и объективность интерпретации спутниковых данных. CNN-модели успешно применяются для задач классификации, детекции объектов и сегментации на спутниковых изображениях в различных регионах мира. Они способны учитывать сложные пространственные и спектральные особенности изображений, обучаться на больших объемах данных и адаптироваться к разнообразным условиям съёмки.

В то же время, большая часть существующих работ по применению CNN для извлечения водных объектов ориентирована на умеренные или тропические регионы и редко учитывает особенности аридных и полуаридных зон, характерных для Центральной Азии. Кроме того, мало исследований интегрируют погодные данные (такие как осадки и температура) для повышения точности идентификации временных водоемов и сезонных изменений береговой линии.

Целью настоящего исследования является разработка и апробация метода дистанционного мониторинга водных объектов Приаралья на основе спутниковых данных Sentinel-2 и погодных данных, с использованием сверточных нейронных сетей нового поколения. В отличие от традиционных подходов, предложенная методика ориентирована на специфику полузасушливого климата, преобладание солончаковых ландшафтов и высокую межгодовую изменчивость площади водоемов.

В работе подробно рассматривается построение обучающего датасета, архитектура разработанной нейронной сети, методика предобработки и интеграции спутниковых и погодных данных, а также результаты тестирования модели на реальных снимках

Методы

1. Исходные данные

1.1 Спутниковые данные

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

В качестве основного источника изображений использовались данные с оптических спутников Sentinel-2, предоставляемые Европейским космическим агентством (ESA) в рамках программы Copernicus. Sentinel-2 предлагает мультиспектральные изображения с пространственным разрешением от 10 до 60 метров и высоким временным разрешением (5 дней в облачно-свободных условиях) [1].

Для исследования были отобраны изображения за период с января 2020 года по декабрь 2024 года, охватывающие весь регион Приаралья, включая высохшее дно Арала, дельту Амударьи и прилегающие орошаемые территории.

При выборе снимков учитывались следующие критерии:

- минимальная облачность (менее 10% по мета-данным);
- максимальная полнота покрытия изучаемых участков;
- наличие как минимум трёх сезонов (весна, лето, осень) в каждом году для анализа сезонных изменений водоёмов.

Использовались мультиспектральные каналы:

- B2 (голубой, 490 нм),
- B3 (зелёный, 560 нм),
- B4 (красный, 665 нм),
- B8 (ближний ИК, 842 нм),
- B11 (средний ИК, 1610 нм).

Эти каналы являются оптимальными для выделения водных объектов с использованием спектральных различий [2].

1.2 Погодные данные

В качестве дополнительных признаков привлекались метеорологические данные из архива ERA5 Reanalysis проекта ECMWF (European Centre for Medium-Range Weather Forecasts), включающие:

- среднюю дневную температуру воздуха,
- общее количество осадков.

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

Данные привязывались ко времени и месту съёмки спутниковых изображений. Интеграция погодных данных была направлена на повышение устойчивости модели к сезонным эффектам, особенно в периоды образования временных водоемов после весенних паводков [3].

2. Предобработка данных

Для подготовки датасета была разработана следующая процедура:

1. Калибровка и коррекция изображений Sentinel-2:

- коррекция атмосферных искажений с использованием алгоритма Sen2Cor [4];
- нормализация спектральных каналов.

2. Аугментация данных:

- повороты, отражения, масштабирование;
- случайные изменения яркости и контрастности;
- добавление случайного гауссовского шума для повышения устойчивости сети к различиям условий съёмки.

3. Генерация целевых масок:

- Использовался водный индекс MNDWI (Modified Normalized Difference Water Index) [5] как базовый способ предварительного выделения водных объектов;
- Ручная верификация и корректировка выделенных объектов экспертами;
- Создание бинарных масок: вода (1) — прочее (0).

4. Совмещение погодных данных:

- Значения температуры и осадков кодировались и добавлялись в качестве дополнительных признаков на уровне батча обучения.

3. Архитектура нейронной сети

Для решения задачи семантической сегментации была выбрана архитектура U-Net++ с дополнением механизмами внимания (*Attention Gates*) [6].

Преимущества выбранной архитектуры:

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

- высокая эффективность при выделении объектов с нечеткими границами (водоемов переменной формы);
- способность эффективно использовать контекст изображения на разных масштабах;
- более глубокие пропуски между слоями повышают точность локализации объектов на фоне солончаков и влажных пустынь.

Основные особенности архитектуры:

- **Базовый энкодер:** ResNet-34, предобученный на ImageNet.
- **Блоки внимания:** позволяют модели фокусироваться на релевантных участках изображения, отфильтровывая фоновые шумы.
- **Функция потерь:** комбинированная Dice Loss + Binary Cross-Entropy Loss для балансировки между площадью малых водоемов и большими поверхностями.

Формула комбинированной функции потерь:

$$\Lambda = \alpha * \Lambda_{Dice} + (1 - \alpha) * \Delta_{BCE}$$

где:

- $\Delta_{Dice} = 1 - \frac{2|P \cap G|}{|P| + |G|}$ — Dice Loss
- Δ_{BCE} — стандартная бинарная кросс-энтропия,
- $\alpha = 0.5$ — коэффициент балансировки.

4. Алгоритм обучения

Модель обучалась на 80% имеющихся размеченных данных, а 20% оставлялись для валидации.

Параметры обучения:

- Оптимизатор: Adam;
- Начальная скорость обучения: 1e-4;
- Стратегия уменьшения learning rate на плато;

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

- Размер батча: 16 изображений;
- Число эпох: 100.

Ранняя остановка (Early Stopping) применялась при отсутствии улучшения метрик на валидационной выборке в течение 10 эпох подряд.

5. Базовый код на Python для подготовки данных

```
import rasterio
import numpy as np
import matplotlib.pyplot as plt
# Загрузка изображения Sentinel-2
image_path = 'sentinel2_image.tif'
with rasterio.open(image_path) as src:
    band2 = src.read(1) # голубой
    band3 = src.read(2) # зелёный
    band4 = src.read(3) # красный
    band8 = src.read(4) # ближний ИК
# Расчёт водного индекса MNDWI
mndwi = (band3 - band11) / (band3 + band11)
# Визуализация MNDWI
plt.imshow(mndwi, cmap='Blues')
plt.colorbar()
plt.title('MNDWI (Water Index)')
plt.show()
```

Результаты

1. Метрики оценки

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

Для объективной оценки качества сегментации водных объектов использовались следующие метрики:

- **Intersection over Union (IoU):**

$$IoU = \frac{TP}{TP + FP + FN}$$

где TP — количество пикселей, правильно отнесённых к воде, FP — ложные срабатывания, FN — пропущенные пиксели воды.

- **Коэффициент Dice (Dice Similarity Coefficient, DSC):**

$$DSC = \frac{2 * TP}{2 * TP + FP + FN}$$

- **Точность (Precision):**

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

- **Полнота (Recall):**

$$Recall = \frac{TP}{TP + FN}$$

Эти метрики являются стандартом при оценке качества сегментации в задачах выделения природных объектов на спутниковых снимках [7].

2. Результаты тестирования модели

Обученная модель была протестирована на независимой выборке спутниковых изображений Приаралья за разные сезоны 2022–2024 гг. (весна, лето, осень). В общей сложности для тестирования использовались 182 сцены Sentinel-2, полностью покрывающие территорию высохшего дна Арала, остаточных водоёмов, дельты Амударьи и орошаемых земель Хорезмской области.

Результаты работы модели суммированы в таблице:

Метрика	Значение
IoU (среднее)	0.872

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

Dice коэффициент	0.931
Precision	0.916
Recall	0.946

Таким образом, модель показала **очень высокую точность сегментации**, особенно в условиях сезонных и межгодовых изменений водных поверхностей.

Для наглядности приведены примеры работы модели:

3. Визуализация результатов

На рисунке 1 представлены результаты работы модели на одной из тестовых сцен (дата съёмки: 5 апреля 2023 года), покрывающей западную часть дельты Амударьи.





Рисунок 1. Сегментация водных объектов на примере спутникового снимка дельты Амударьи (5 апреля 2023 г.): слева – оригинальный снимок Sentinel-2, центр – истинная разметка воды, справа – предсказание модели.

На анализируемом участке модель правильно определила многочисленные разрозненные водные объекты:

- старые протоки Амударьи,
- обводнённые участки временных озёр,
- каналы ирригационной системы.

Ошибки сегментации наблюдались в основном на участках, где:

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

- солончаки имели аномально высокую влажность после паводков,
- береговые линии сильно изменялись в течение нескольких недель.

Однако суммарная ошибка ложных срабатываний не превышала 7%, что подтверждает высокую устойчивость модели к сложным природным условиям Приаралья.

4. Сезонные различия

Интересным результатом стало выявление сезонных закономерностей:

- **Весной** (апрель–май) водная поверхность максимальна за счёт снеготаяния и паводков.
- **Летом** наблюдается резкое сокращение площадей водоемов из-за интенсивного испарения.
- **Осенью** некоторые небольшие озёра сохраняются за счёт поздних осадков.

Модель уверенно справлялась с изменениями временных водоемов, что особенно важно для построения динамических карт водных ресурсов региона.

5. Влияние погодных данных

Добавление погодных признаков (температура, осадки) позволило:

- увеличить точность детекции на 3–4% по сравнению с базовой моделью, обученной только на изображениях;
- значительно сократить количество ложных срабатываний на участках сезонных болот и пересохших солончаков.

Таким образом, интеграция метеоданных подтверждает свою полезность для более точного мониторинга природной динамики в аридных зонах [8].

Обсуждение

Результаты проведённого исследования подтвердили высокую эффективность методов глубокого обучения для задач мониторинга водных объектов в сложных условиях аридных территорий Приаралья. Полученные значения метрик (IoU = 0.872, Dice = 0.931) свидетельствуют о том, что предложенная архитектура сверточной нейронной сети способна надёжно

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

выделять водные поверхности на спутниковых снимках даже при высокой гетерогенности ландшафта и сезонной изменчивости.

Одной из ключевых особенностей Приаралья является динамическое формирование временных водоёмов, обусловленное сочетанием весеннего снеготаяния, сезонных осадков и ирригационных сбросов. Эти процессы затрудняют классическую интерпретацию спутниковых данных: в одни периоды водные объекты представляют собой хорошо выраженные зеркальные поверхности, а в другие — слабо заметные подтопленные участки или влажные солончаки. Стандартные алгоритмы на основе фиксированных порогов спектральных индексов (например, NDWI) часто ошибаются в таких случаях [9]. Использование сверточных нейросетей позволило преодолеть эту проблему за счёт способности обучаться сложным спектро-пространственным паттернам, характерным для временных водоёмов.

Значимое улучшение результатов при добавлении погодных признаков подчёркивает важность учёта климатических факторов при мониторинге водных систем в аридных регионах. Информация о температуре и осадках позволила модели различать сезонные залитые поверхности и настоящие постоянные водоемы, что особенно ценно для оценки реальных водных ресурсов региона, а не просто кратковременных явлений [10].

Анализ ошибок выявил, что наибольшее количество ложных срабатываний наблюдалось:

- на влажных солончаках после весенних паводков;
- в местах интенсивного испарения, где остаётся тонкий водный слой на поверхности почвы.

Эти пограничные случаи остаются сложными даже для современных нейронных сетей. Дополнительное улучшение точности возможно за счёт интеграции данных активного зондирования, например, радиолокационных снимков Sentinel-1, которые более чувствительны к влажности поверхности [11].

Сравнение с существующими исследованиями в других регионах мира показывает, что качество сегментации в Приаралье находится на уровне лучших мировых результатов. Например, в проектах мониторинга водоемов в Индии и Южной Африке, где также использовались CNN-архитектуры, средние значения

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

IoU колебались в пределах 0.84–0.88 [12]. Таким образом, разработанная модель демонстрирует не только локальную применимость, но и потенциал к масштабированию на другие аридные зоны.

Научная новизна исследования заключается в адаптации современных методов глубокого обучения к специфическим природным условиям Приаралья и в интеграции дополнительных климатических данных в процесс обучения сверточной сети. В практическом плане предложенная методика может стать основой для создания оперативной системы мониторинга водных ресурсов Центральной Азии, что критически важно в условиях продолжающегося обострения водного дефицита.

Следует отметить и существующие ограничения работы. Во-первых, обучение модели проводилось на относительно ограниченном наборе размеченных данных, поскольку качественная ручная разметка спутниковых изображений Приаралья требует значительных ресурсов. Во-вторых, учитывались только оптические спутниковые данные, что ограничивает возможности мониторинга в периоды высокой облачности и песчаных бурь. В будущем необходимо расширить датасет за счёт активных данных (SAR) и провести обучение моделей на более разнообразных климатических сценариях.

Тем не менее, представленные результаты закладывают основу для дальнейших исследований и развития систем ИИ в сфере мониторинга природных ресурсов Узбекистана и всего региона Приаралья.

Заключение

Настоящее исследование продемонстрировало, что методы глубокого обучения, основанные на сверточных нейронных сетях, обладают значительным потенциалом для эффективного мониторинга водных объектов в условиях аридных и полуаридных ландшафтов Приаралья. Разработанная архитектура, основанная на модифицированной U-Net++ с механизмами внимания, показала высокую точность сегментации водных поверхностей на спутниковых изображениях Sentinel-2, успешно справляясь с сезонной и межгодовой изменчивостью региона.

Интеграция погодных данных (осадки, температура воздуха) позволила повысить устойчивость модели к сложным природным условиям, что особенно

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

важно для достоверной идентификации временных и пересыхающих водоемов. В результате среднее значение Intersection over Union (IoU) составило 0.872, а коэффициент Dice достиг 0.931 на тестовых данных за разные сезоны 2022–2024 годов.

Проведённый анализ подтвердил применимость предложенного подхода для практических задач мониторинга водных ресурсов Приаралья. Модель может служить основой для построения систем оперативного экологического мониторинга, которые будут востребованы в процессе планирования водопользования, аграрного менеджмента и оценки последствий климатических изменений в Центральной Азии.

Перспективы дальнейших исследований включают:

- расширение набора данных за счёт использования радарных спутниковых снимков Sentinel-1 для повышения устойчивости моделей к погодным условиям;
- развитие методов мультизадачной сегментации для одновременного мониторинга воды, растительности и деградации земель;
- разработку динамических карт временной эволюции водных объектов на основе рекуррентных нейронных сетей.

Таким образом, глубокие нейронные сети открывают новые горизонты в изучении и сохранении хрупких экосистем Приаралья, обеспечивая научно обоснованную поддержку устойчивого управления водными ресурсами региона.

Список литературы

1. Drusch, M. et al. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
2. McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
3. Hersbach, H. et al. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999–2049. <https://doi.org/10.1002/qj.3803>
4. Louis, J. et al. (2016). Sentinel-2 Sen2Cor: L2A Processor for Users. *Proceedings of the Living Planet Symposium 2016*.

МЕДИЦИНА, ПЕДАГОГИКА И ТЕХНОЛОГИЯ: ТЕОРИЯ И ПРАКТИКА

Researchbib Impact factor: 13.14/2024

SJIF 2024 = 5.444

Том 3, Выпуск 05, Мая

5. Xu, H. (2006). Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
6. Zhou, Z. et al. (2018). UNet++: A Nested U-Net Architecture for Medical Image Segmentation. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. <https://arxiv.org/abs/1807.10165>
7. Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. https://doi.org/10.1007/978-3-319-24574-4_28
8. Beiranvand Pour, A., Hashim, M. (2015). Detection of Water Bodies Using Remote Sensing Satellite Data. *Geocarto International*, 30(3), 300–312. <https://doi.org/10.1080/10106049.2014.905040>
9. McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
10. Foga, S. et al. (2017). Cloud detection algorithm comparison and validation for operational Landsat data products. *Remote Sensing of Environment*, 194, 379–390. <https://doi.org/10.1016/j.rse.2017.03.026>
11. Paloscia, S. et al. (2013). Soil moisture retrieval from Sentinel-1 data. *Remote Sensing of Environment*, 134, 115–124. <https://doi.org/10.1016/j.rse.2013.02.001>
12. Pekel, J.-F. et al. (2016). High-resolution mapping of global surface water and its long-term changes. *Nature*, 540, 418–422. <https://doi.org/10.1038/nature20584>