УДК 55.556 *https://doi.org/10.35567/19994508-2025-3-74-94*

Применение нейросетевого моделирования для идентификации водоемов в бассейнах рек по данным дистанционного зондирования Земли

Н.А. Душенко ✉, М.М. Головачева, М.В. Капустин, К.С. Суртаева

✉ dushenko-natali@mail.ru

Российский научно-исследовательский институт комплексного использования и охраны водных ресурсов», г. Ростов-на-Дону, Россия

АННОТАЦИЯ

Актуальность. Эффективность государственного управления водными ресурсами в значительной степени определяют полнота и актуальность информации о водных объектах бассейнов рек. В статье представлена методология сегментации водоемов в бассейнах рек по данным дистанционного зондирования Земли из космоса с применением нейронных сетей и определения с помощью полученных результатов площадей водоемов и объемов потерь на дополнительное испарение с их поверхности в бассейне р. Урал. **Методы.** Сегментация водоемов на космоснимках с применением сверточных и трансформерных нейросетевых моделей. **Результаты.** Приведены основные результаты обучения и сравнения эффективности сверточной и трансформерной нейронных сетей, сегментирующих водные объекты. С помощью наиболее эффективной нейронной сети осуществлена сегментация данных дистанционного зондирования Земли для российской части трансграничного бассейна р. Урал. Проведен анализ количества водоемов и их суммарной площади, идентифицированных с помощью трансформерной нейронной сети, а также объемов потерь на дополнительное испарение с их поверхности. Сформирована база данных сведений о водоемах в разрезе бассейновых округов, бассейнов рек, водохозяйственных участков, административно-территориальных единиц, а также сведений о местоположении водоемов и их площадях, слоях осадков и испарения с водной поверхности.

КЛЮЧЕВЫЕ СЛОВА: нейронная сеть, сверточная нейронная сеть, трансформерная нейронная сеть, данные дистанционного зондирования Земли, идентификация водной поверхности, семантическая сегментация.

Для цитирования: Душенко Н.А., Головачева М.М., Капустин М.В., Суртаева К.С. Применение нейросетевого моделирования для идентификации водоемов в бассейнах рек по данным дистанционного зондирования Земли // Водное хозяйство России: проблемы, технологии, управление. 2025. № 3. С. 74–94. https://doi.org/10.35567/19994508-2025-3-74-94, EDN: XFFMVA

Application of neural network modeling for identification of water bodies in river basins using Earth satellite remote sensing data

Natalia A. Dushenko ✉, Maria M. Golovacheva, Mikhail V. Kapustin, Kristina S. Surtayeva

✉ dushenko-natali@mail.ru

Russian Research Institute for Integrated Water Management and Protection, Rostov-on-Don, Russia

© Душенко Н.А., Головачева М.М., Капустин М.В., Суртаева К.С., 2025

ABSTRACT

Relevance. The effectiveness of state management of water resources largely depends on the completeness and relevance of information about the water resources of river basins. The article presents a methodology of water bodies' segmentation in river basins according satellite Earth remote sensing data with application of neural networks and determination, with the use of the obtained results, water bodies' areas and volumes of losses caused by additional evaporation from their surface in the Ural River basin. **Methods.** Segmentation of water bodies on satellite images using convolutional and transformer-based neural network models. **Results.** The main results of training and comparing the effectiveness of convolutional and transformer neural networks for segmenting water bodies are described. Using the most efficient neural network, segmentation of remote sensing data was performed for the Russian part of the transboundary Ural River basin. An analysis was conducted of the number of water bodies and their total area identified using the transformer neural network, as well as the volume of losses due to additional evaporation from their surfaces. A database was created containing information about water bodies, categorized by basin districts, river basins, water management units, and administrative-territorial units, as well as data on the location of water bodies, their areas, precipitation layers, and evaporation from the water surface of the water bodies.

KEYWORDS: neural network, convolutional neural network, transformer neural network, Earth remote sensing data, identification of the water surface, semantic segmentation, the Ural River.

For citation: Dushenko N. A., Golovacheva M. M., Kapustin M. V., Surtayeva K. S. Application of neural network modeling for identification of water bodies in river basins using Earth satellite remote sensing data. *Water Sector of Russia: Problems, Technologies, Management*. 2025. No. 3. P. 74–94. https://doi.org/10.35567/19994508-2025-3-74-94, EDN: XFFMVA

ВВЕДЕНИЕ

В регионах с неравномерным в течение года стоком рек и высокой водохозяйственной нагрузкой устойчивое водопользование обеспечивается в значительной мере за счет сезонного и многолетнего регулирования стока в многочисленных прудах и водохранилищах. Сток рек, сохраняемый в прудах и водохранилищах в период половодья, позволяет с минимальными ограничениями обеспечить в период маловодья потребности как крупных участников водохозяйственного комплекса, так и небольших хозяйств.

Одним из основных инструментов планирования и принятия решений по вопросам использования и охраны водных объектов являются водохозяйственные балансы[1], которые позволяют оценить наличие и степень использования водных ресурсов по бассейнам водных объектов и соответствующим территориям субъектов Российской Федерации. Точность расчета водохозяйственного баланса напрямую зависит от полноты и достоверности его составляющих в приходной и расходной частях, при этом информация по многочисленным мелководным водоемам в рамках бассейна реки, как правило, усредняется и формируется на основе справочных показателей или исследований бассейна реки полувековой давности. Несмотря на, казалось бы, незначительность мелководных водоемов для расчета водохозяйственного баланса

[1] Об утверждении Методики расчета водохозяйственных балансов водных объектов. Приказ Минприроды России от 30.11.2007 № 314. Инф.-правовой портал «ГАРАНТ.РУ», 2017. [Электр. ресурс]:URL: www.garant.ru/ (дата обращения: 08.07.2024).

крупных бассейнов рек и определения свободных ресурсов в нем, при прохождении половодья суммарно во множестве таких водоемов задерживается внушительный объем стока, часть которого уходит на нужды водопользователей, часть возвращается в речной сток в течение года, отдельные объемы составляют потери на испарение.

С целью повышения качества расчета водохозяйственных балансов при определении их составляющих целесообразно использовать наиболее достоверные и актуальные источники информации, к которым относятся данные дистанционного зондирования Земли из космоса[2]. При расчете водохозяйственных балансов данные дистанционного зондирования Земли (ДЗЗ) могут стать источником информации о расположенных в бассейне реки водоемах и их параметрах для учета потерь на испарение с их поверхности. В сравнении с маршрутными обследованиями дистанционное зондирование Земли из космоса не зависит от состояния транспортной инфраструктуры в районе местоположения объекта наблюдения, может обеспечить наблюдения в труднодоступных зонах и позволяет обследовать больше территорий за короткий промежуток времени. Вместе с тем для обработки данных ДЗЗ требуется специализированное геоинформационное программное обеспечение, навыки дешифрирования, существенные временные и трудовые ресурсы. В связи с этим для эффективной обработки данных ДЗЗ на значительных по площади территориях необходимо применять современные методы, автоматизирующие данный процесс, к которым относятся и методы нейросетевого моделирования.

Современные модели нейронных сетей позволяют с высокой скоростью обрабатывать большие объемы неструктурированных данных с множеством параметров, самостоятельно извлекая признаки и зависимости и адаптируясь под любые данные. Таким образом, нейронные сети могут обеспечить более эффективный анализ и интерпретацию данных дистанционного зондирования Земли, автоматизировать процедуры определения водоемов и их параметров.

В современных исследованиях для решения задач сегментации водных объектов на космических снимках используются глубокие сверточные и трансформерные нейронные сети. Их архитектуры демонстрируют высокую эффективность при определении водной поверхности.

Среди отечественных научных публикаций в области применения методов нейросетевого моделирования для семантической сегментации изображений поверхности Земли описывается бинарная сегментация спутниковых снимков: выделение суши и водной поверхности [1], земли и озер [2]. В рамках таких исследований достигалась точность сегментации водной поверхности 96 %, озер – 86 %.

В зарубежных исследованиях наиболее распространена бинарная сегментация с использованием сверточных и трансформерных нейросетевых моделей на основе данных ДЗЗ и искусственно сгенерированных изображений [3], также встречаются и исследования по применению многоклассовой се-

[2] ГОСТ Р 59753-2021. Данные дистанционного зондирования Земли из космоса. Термины и определения. М.: ФГБУ РСТ, 2021.

мантической сегментации водных объектов [4]. Отличительной их особенностью является использование снимков высокого разрешения, а также съемок с камер видеонаблюдения [5], что приводит к высокой точности сегментации (90 % и выше). Однако такой подход не предусматривает возможности анализа общедоступных данных ДЗЗ среднего разрешения (около 30 м).

В данной статье представлены результаты сегментации водоемов в российской части бассейна р. Урал по данным ДЗЗ с применением нейронных сетей, основанных на сверточной и трансформерной архитектурах, а также определения их параметров и объемов потерь на дополнительное испарение с поверхности водных объектов.

ОБУЧЕНИЕ НЕЙРОННЫХ СЕТЕЙ

Для обучения нейронных сетей, осуществляющих многоклассовую семантическую сегментацию, подготовка данных выполнялась в несколько этапов:

1. Сбор данных ДЗЗ по бассейнам рек Урал, Дон, Большой и Малый Узень. Источники данных – снимки Landsat-8[3] и Landsat-9[4] с пространственным разрешением 30 м, при облачности не выше 35 %, за период, когда водная поверхность не покрыта льдом, преимущественно в половодье. Для полного покрытия территорий указанных бассейнов без перекрытия облаками и расширения объема обучающей выборки одна и та же территория анализировалась за разные годы.

2. С целью оптимизации подготовки обучающего набора данных использована модель сверточной нейронной сети DeepWaterMap [6]. Ее предсказание представляет собой изображение, каждый пиксель которого имеет вероятность принадлежности к классу водной поверхности (близкие к 1 значения отражают принадлежность объекта к классу «вода») и позволяет на следующих этапах обработки минимизировать ошибку определения водных объектов на космоснимках. Следует отметить, что модель нейронной сети DeepWaterMap прошла обучение на значительном объеме выборки, сформированном с помощью данных ДЗЗ с космических аппаратов серии Landsat, имеет высокие показатели метрики (точность определения водной поверхности порядка 88 %) и не нуждается в дополнительном обучении.

3. Разметка спутниковых снимков на основе полученных на выходе из сверточной нейронной сети DeepWaterMap предсказаний. На этом этапе оператором выделяются 3 класса: 0 – фоновый класс (земная поверхность), 1 – водоток, 2 – водоем. Полученные маски спутникового изображения используются для последующего обучения нейронных сетей.

4. Фрагментирование композитных шестиканальных спутниковых снимков, предсказаний DeepWaterMap и масок до размера 512 × 512 пикселей. Композитные снимки представляют набор растровых данных в следующих спектральных каналах: красном, зеленом, голубом, ближнем инфракрасном и двух коротковолновых инфракрасных.

[3] Landsat Missions. Landsat 8. [Электр. ресурс]. URL: https://www.usgs.gov/landsat-missions/landsat-8 (дата обращения: 16.03.2024).
[4] Landsat Missions. Landsat 9. [Электр. ресурс]. URL: https://www.usgs.gov/landsat-missions/landsat-9 (дата обращения: 16.03.2024).

5. Добавление к шестиканальному спутниковому снимку седьмого канала – предсказания DeepWaterMap.

6. Осуществление нормализации пикселей изображений, позволяющей сопоставлять данные между собой, независимо от их исходного диапазона значений, посредством центрирования и масштабирования значений пикселей.

7. Расширение обучающей выборки за счет дублирования данных с применением геометрического преобразования и цветовой коррекции изображений.

На этапе обработки получено 250 космоснимков, которые сформированы в обучающий, тестовый и валидационный наборы данных. Обучающий набор данных необходим для обучения модели, валидационный служит для подбора оптимальных гиперпараметров и проверки работоспособности модели оператором, тестовый набор создается для оценки качества сегментации водоемов. Размер обучающей выборки составляет 80 % от имеющихся снимков, валидационной – 10 %, тестовый – 10 %.

Для сегментации водоемов обучены две нейросетевые модели: сверточная (MobileNetV3-Large LR-ASPP) [7] и трансформерная (EfficientNet–MANet) [8]. Выбор сверточных и трансформерных нейросетевых моделей объясняется их направленностью на работу с изображениями в задачах семантической сегментации.

MobileNetV3-Large LR-ASPP – легковесная глубокая сверточная нейронная сеть, специально разработанная для задачи семантической сегментации. Архитектура MobileNetV3-Large используется в качестве основы нейронной сети, а LR-ASPP является декодером[5] – частью архитектуры нейронной сети, использующейся для восстановления исходного изображения после операций свертки (рис. 1).

EfficientNet–MANet – глубокая трансформерная нейронная сеть, которая использует механизмы внимания для улучшения качества сегментации и распознавания объектов в изображениях. В качестве основной архитектуры применяется MANet, энкодером[6] является EfficientNet (рис. 2).

На вход сверточной нейронной сети MobileNetV3-Large LR-ASPP подаются изображения размером 512 × 512 с 7 каналами. Параметры W и H являются шириной и высотой изображения, изменяющимися в ходе операций свертки. Данная архитектура использует слои:

– для изменения изображения с помощью ядра свертки, выявляя признаки для дальнейшего анализа (Conv – слой свертки);

– преобразования линейной комбинации входных данных с весами в диапазон значений между 0 и 1, что позволяет моделировать недостающие нелинейности в данных (Sigmoid – слой активации);

– увеличения данных с целью сбалансирования классов (Multiclass Upsample – слой сэмплинга);

[5] Компонент нейронной сети, восстанавливающий исходное изображение после выполнения операций свертки и сжатия.

[6] Компонент нейронной сети, отвечающий за извлечение и сжатие характеристик исходного изображения.

– уменьшения пространственных размеров входного изображения путем замены каждой области на ее среднее значение (Avg-Pool – слой субдискретизации).

На выходе нейронной сети полученное изображение имеет размер 512 × 512 с 3 каналами.

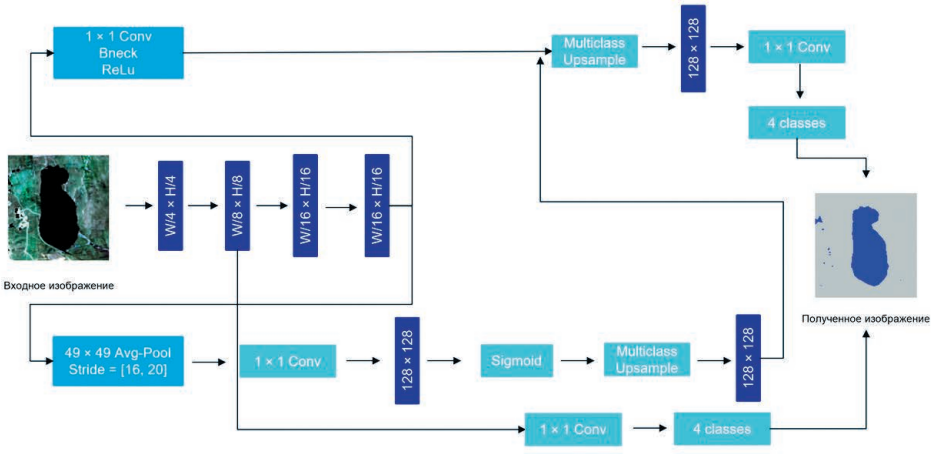


Рис. 1. Архитектура MobileNetV3-Large LR-ASPP.
Fig. 1. MobileNetV3-Large LR-ASPP architecture.

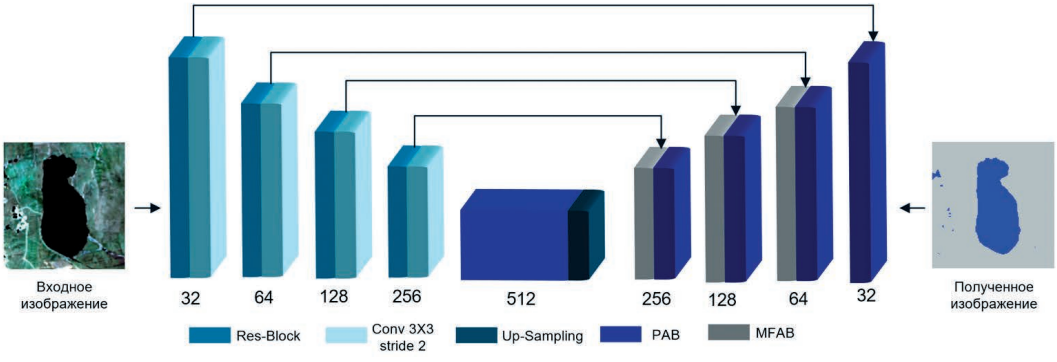


Рис. 2. Архитектура EfficientNet–MANet.
Fig. 2. EfficientNet–MANet architecture.

На вход трансформерной нейронной сети EfficientNet–MANet подается изображение с аналогичными размерами (512 × 512 × 7). Отличительной особенностью трансформерной нейронной сети является совместное применение операций свертки с механизмом внимания, позволяющим учитывать локальные и глобальные зависимости между всеми элементами входных данных. Представленная архитектура состоит из блоков, каждый из которых включает следующие слои:

– Res-Block (слои свертки, активации, групповой нормализации);
– Conv (слои свертки);
– Up-Sampling (деконволюционные слои);

– PAB (слои свертки, активации, механизм внимания);

– MFAB (слои свертки, активации, субдискретизации, полносвязные, механизм внимания).

В ходе обучения сверточной и трансформерной нейронных сетей осуществлялся подбор гиперпараметров (табл. 1), выбор которых основан на экспериментах и анализе полученных результатов. При данных значениях гиперпараметров достигнута высокая точность сегментации водоемов с учетом имеющихся ресурсов и целей.

Таблица 1. Гиперпараметры нейронных сетей
Table 1. The neural networks hyper-parameters

Гиперпараметр	MobileNetV3-Large LR-ASPP	EfficientNet–MANet
Размер батча	64	20
Размер обучающей выборки	80 %	80 %
Размер валидационной выборки	10 %	10 %
Размер тестовой выборки	10 %	10 %
Коэффициент скорости обучения[7]	0,0001	0,001
Оптимизатор[8]	NAdam	Adam
Функция потерь[9]	CrossEntropyLoss	CrossEntropyLoss
Количество эпох	50	50

Для оценки эффективности нейросетевых моделей использована метрика Intersection over Union (IoU). Ее значение в диапазоне от 0 до 1 показывает, насколько у объектов совпадает истинная и предсказанная площадь пересечения, и позволяет оценить точность сегментации:

$$IoU = \frac{A \cap B}{A \cup B}, \quad (1)$$

где A – площадь пересечения; B – площадь объединения.

В ходе обучения на 250 снимках получены значения IoU, приведенные в табл. 2.

Таблица 2. Значения метрики IoU для водоемов
Table 2. IoU metric values for water bodies

Нейронная сеть	IoU на тренировочной выборке	IoU на тестовой выборке
MobileNetV3-Large LR-ASPP	0,62	0,69
EfficientNet–MANet	0,74	0,84

Еще одним способом оценки эффективности нейронных сетей является матрица ошибок – таблица, где строки соответствуют истинным меткам,

[7] Гиперпараметр, определяющий размер каждого шага обновления весов модели в процессе обучения.
[8] Гиперпараметр, определяющий методы и правила, на основе которых выполняется обновление весов.
[9] Математическая функция, используемая в процессе обучения модели для количественной оценки разницы между предсказанными и фактическими значениями.

а столбцы – предсказанным. Каждая ячейка матрицы содержит количество объектов, отнесенных к соответствующему классу истинных и предсказанных меток (рис. 3, рис. 4).

На обучающей выборке сверточная нейронная сеть верно определяет: 99,94 % объектов, относящихся к фону; 58,09 % объектов, принадлежащих классу «водоток»; 87,22 % объектов, определяемых как водоемы. На валидационной выборке точность по объектам фона практически не изменилась (в пределах 0,02 %), точность по классу «водоток» возросла на 13,71 %, по водоемам точность снизилась до 83,63 %.

На обучающих данных трансформерная нейронная сеть верно определяет: 99,34 % объектов, относящихся к фону; 70,46 % объектов класса «водоток»; 98,13 % объектов, определяемых как водоемы. На валидационной выборке точность по объектам фона снизилась до 67,60 %, по классу «водоток» уменьшилась на 46,96 %, по водоемам незначительно снизилась (в пределах 3–4 %).

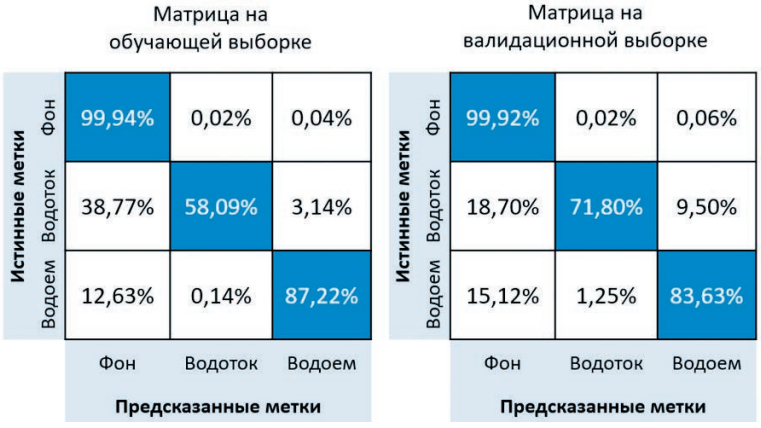


Рис. 3. Матрица ошибок MobileNetV3-Large LR-ASPP.
Fig. 3. MobileNetV3-Large LR-ASPP error metric.

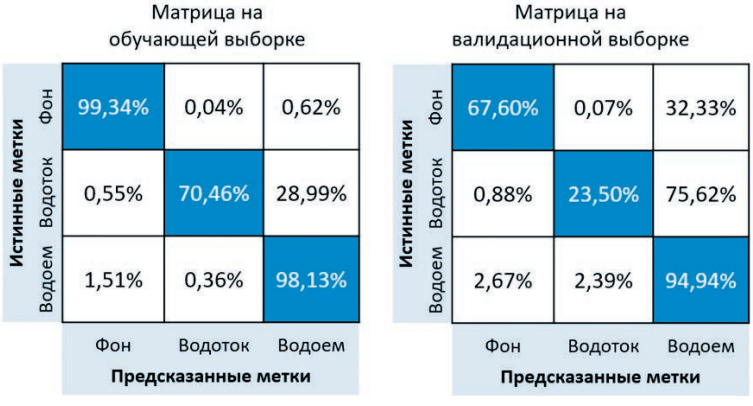


Рис. 4. Матрица ошибок EfficientNet–MANet.
Fig. 4. EfficientNet–MANet error metric.

При детальном сравнении результатов ручного дешифрирования и разметки космоснимков с использованием нейронной сети можно выявить некоторые расхождения, что обусловлено следующими факторами:

– мелководные участки водоемов или небольшие карманы могут быть представлены на космическом снимке в виде пары пикселей, прилегающих к основному водоему, и при разных подходах могут сегментироваться как отдельные объекты либо сливаться с основным водным объектом, в связи с чем при использовании результатов, полученных с использованием нейронной сети, объекты площадью до 0,3 км^2 не учитывались;

– сложность дешифрирования среднего участка р. Урал с огромным количеством наполняемых в половодье пойменных водоемов, которые в пик половодья могут объединяться, образуя внушительные по площади разливы, что требует для определения русла реки изучения архивных снимков за меженный период (рис. 5).



межень половодье

Рис. 5. Пойма р. Урал.
Fig. 5. The Ural River floodplain.

По результатам обучения EfficientNet–MANet оказалась более эффективной в идентификации водоемов на данных ДЗЗ. С использованием этой нейронной сети выполнена сегментация бассейна р. Урал с выделением данных по основным притокам первого порядка: рекам Большой Кизил, Большой Кумак, Губерля, Гумбейка, Илек, Иртек, Орь, Сакмара, Суундук, Таналык, Чаган. Обзорная картосхема бассейна р. Урал с выделением подбассейнов основных притоков первого порядка[10,11], подготовленная на основе цифровой модели рельефа (SRTM) [9] с применением ГИС-технологий[12], приведена на рис. 6.

[10] СТО ГГИ 52.08.40–2017. Определение морфометрических характеристик водных объектов суши и их водосборов с использованием технологии географических информационных систем по цифровым картам Российской Федерации и спутниковым снимкам. М.: РПЦ «Офорт», 2017. 148 с.

[11] Р 52.08.874–2018. Рекомендации. Определение гидрографических характеристик картографическим способом // Mgmtmo.ru. [Электр. ресурс] URL: http://mgmtmo.ru/edumat/rd/52.08.874_2018.pdf (дата обращения: 15.03.2024).

[12] Обзор группы инструментов Гидрология // Pro.arcgis.com: Официальный сайт ArcGIS Pro. [Электр. ресурс] URL: https://pro.arcgis.com/ru/pro-app/latest/tool-reference/spatial-analyst/an-overview-of-the-hydrology-tools.htm (дата обращения: 15.03.2024).

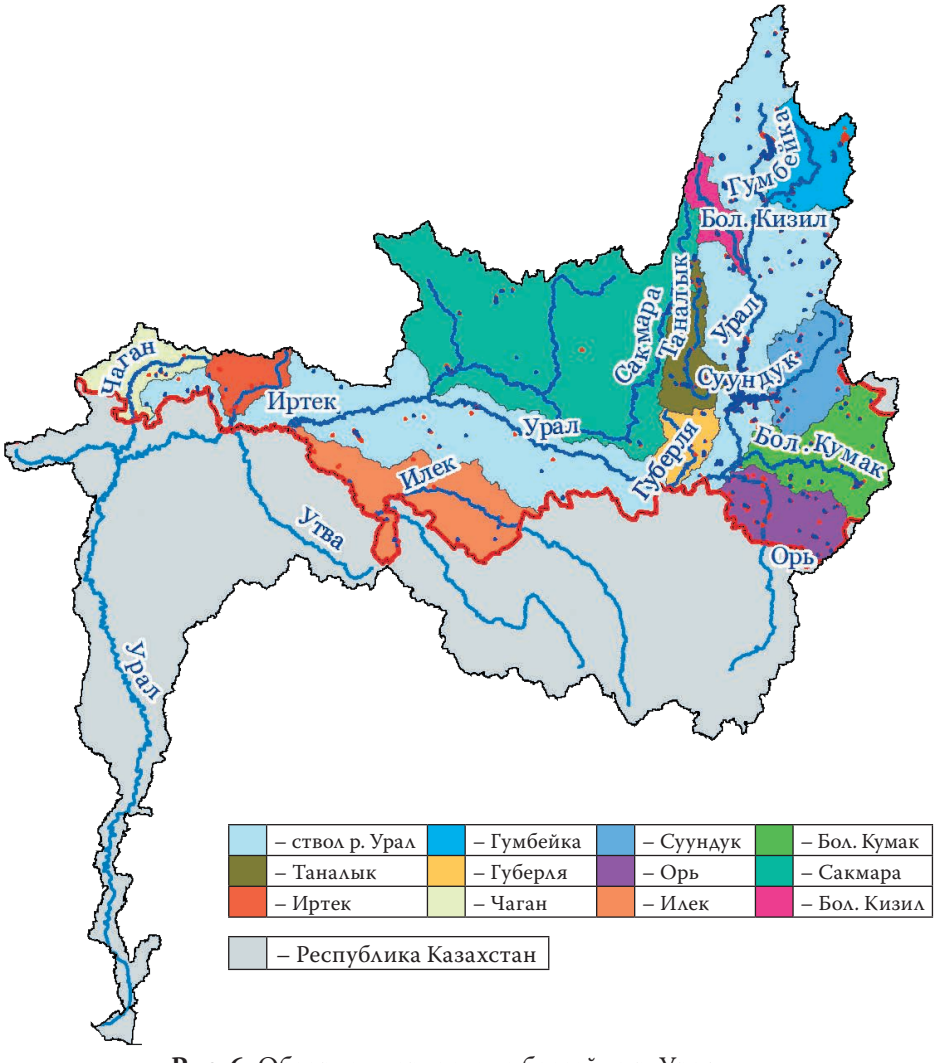


Рис. 6. Обзорная картосхема бассейна р. Урал.
Fig. 6. An overview schematic map of the Ural River basin.

ИДЕНТИФИКАЦИЯ ВОДОЕМОВ С ПРИМЕНЕНИЕМ НАИБОЛЕЕ ЭФФЕКТИВНОЙ НЕЙРОННОЙ СЕТИ

На основе полученных при анализе космоснимков данных с помощью нейронной сети EfficientNet–MANet подготовлены картографические материалы с отображением идентифицированных в границах бассейнов рек русловых прудов и водохранилищ (рис. 7 – рис. 13). По данным ДЗЗ, в российской части бассейна р. Урал идентифицирован 231 русловой водоем (с площадью зеркала более 0,3 км^2), суммарная площадь зеркала которых составляет 692,81 км^2 в период половодья и 485,79 км^2 в межень. Сводная информация о количестве водоемов и их суммарных площадях по группам приведена в табл. 3.

Таблица 3. Количество водоемов и их суммарная площадь в бассейне р. Урал (российская часть), идентифицированных с использованием нейронной сети
Table 3. A number of water bodies and their total area in the Ural River basin (Russian part), identified using a neural network

Бассейн	Количество водоемов, шт. суммарная площадь в половодье/суммарная площадь в межень, км²					Всего	Изменение площади зеркала за год
	группировка водоемов по площади зеркала в половодье, км²						
	[0,3; 1)	[1; 2)	[2; 5)	[5; 10)	> 10		
р. Урал	152 81,19/32,49	38 52,58/25,44	27 77,82/45,54	7 48,22/37,06	7 432,99/345,26	231 692,81/485,79	–30 %
в том числе:							
Ствол р. Урал	50 27,34/12,30	13 18,49/10,77	7 21,23/13,34	3 20,06/18,31	5 404,08/337,34	78 491,20/392,05	–20 %
р. Большой Кизил	2 0,73/0,54	–	1 2,52/1,84	–	–	3 3,25/2,38	–27 %
р. Большой Кумак	14 7,15/2,72	2 2,83/0,96	2 4,19/1,91	–	1 12,69/7,92	19 26,86/13,51	–50 %
р. Губерля	6 3,69/1,47	1 1,08/0,74	–	–	–	7 4,77/2,21	–54 %
р. Гумбейка	8 3,74/2,51	1 1,08/0,79	1 3,39/1,11	1 7,13/5,20	1 16,22/–	12 31,57/9,61	–70 %
р. Илек	9 5,11/0,83	2 2,97/0,35	2 4,99/1,62	–	–	13 13,08/2,80	–79 %
р. Иртек	6 2,38/0,33	1 1,50/–	1 2,32/–	–	–	8 6,2/0,33	–95 %
р. Орь	19 11,42/2,60	7 9,06/1,63	2 5,79/2,87	1 8,40/2,86	–	29 34,67/9,96	–71 %
р. Сакмара	10 4,29/2,42	4 5,82/4,13	2 6,62/4,68	1 5,26/4,67	–	17 21,99/15,89	–28 %
р. Суундук	10 6,56/2,86	5 6,27/3,94	2 5,11/2,98	–	–	17 17,94/9,78	–46 %
р. Таналык	10 4,99/2,90	2 3,47/2,14	6 19,28/13,42	1 7,37/6,03	–	19 35,10/24,49	–30 %
р. Чаган	8 3,81/1,02	–	1 2,37/1,78	–	–	9 6,18/2,80	–55 %

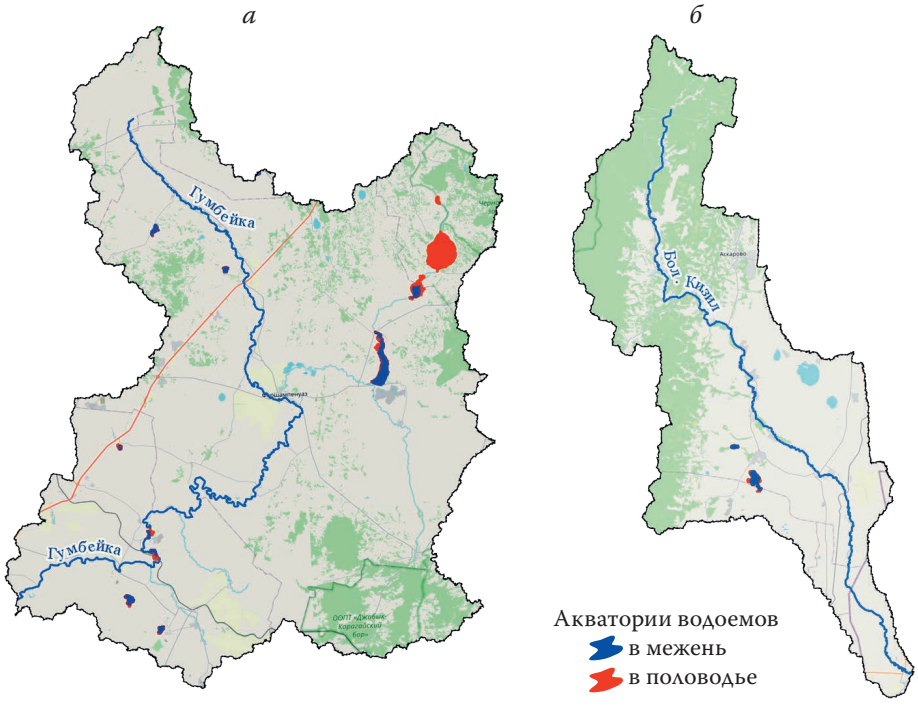


Рис. 7. Картосхемы бассейнов: *а* – р. Гумбейка, *б* – р. Большой Кизил.
Fig. 7. Schematic maps of the basins: *a* – the Gumbeyka River, *b* – the Bolshoy Kizil River.

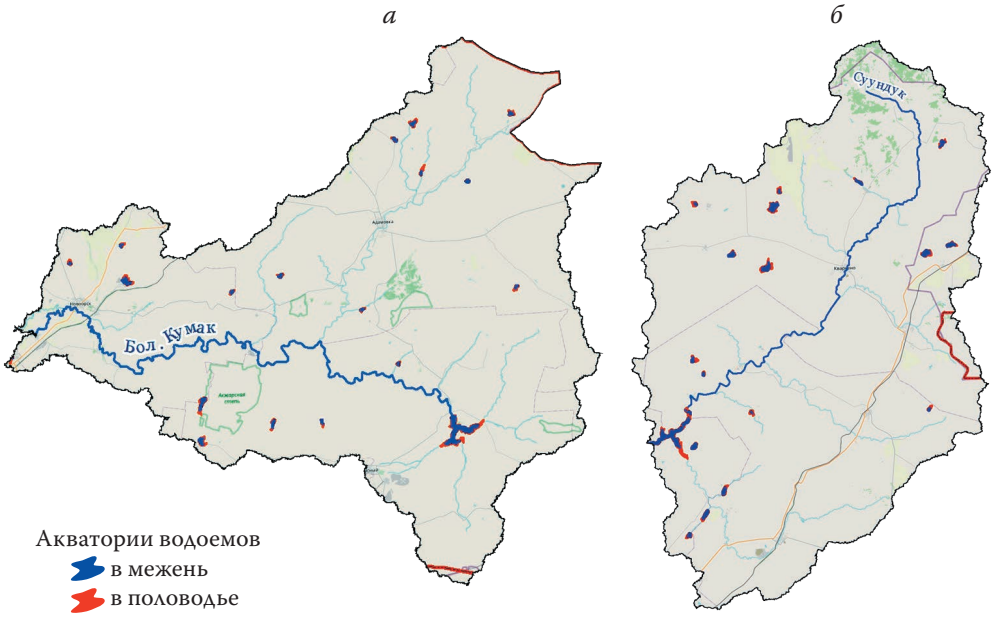


Рис. 8. Картосхемы бассейнов рек: *а* – р. Большой Кумак, *б* – Суундук.
Fig. 8. Schematic maps of the basins: *a* – the Bolshoy Kumak River, *b* – the Suunduk River.

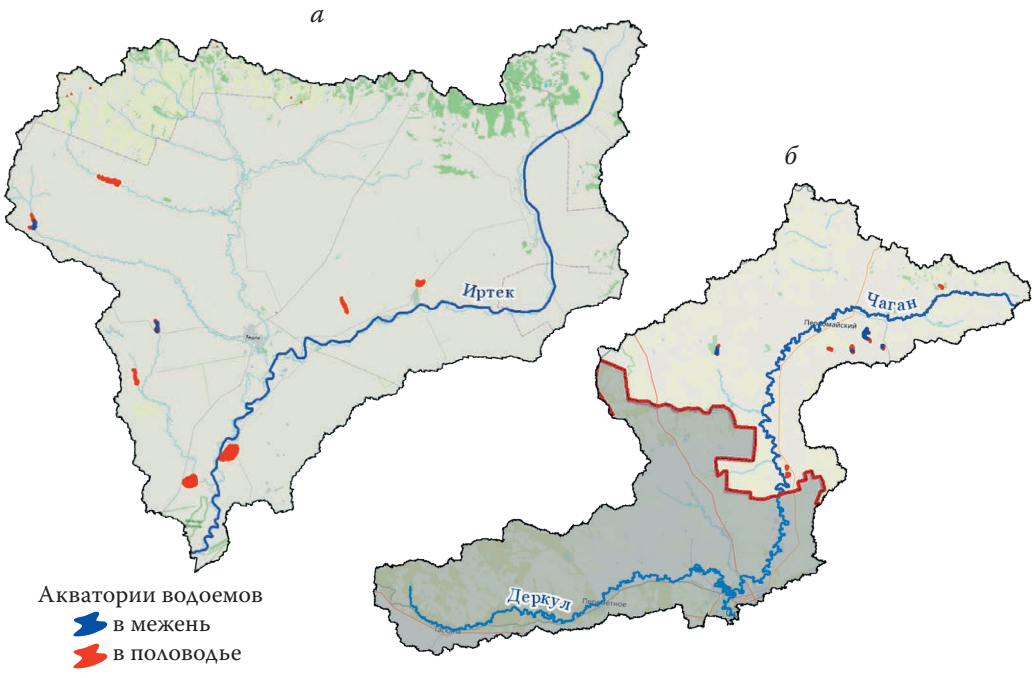


Рис. 9. Картосхемы бассейнов рек: *а* – р. Иртек, *б* – р. Чаган.
Fig. 9. Schematic maps of the basins: *a* – the Irtek River, *b* – the Chagan River.

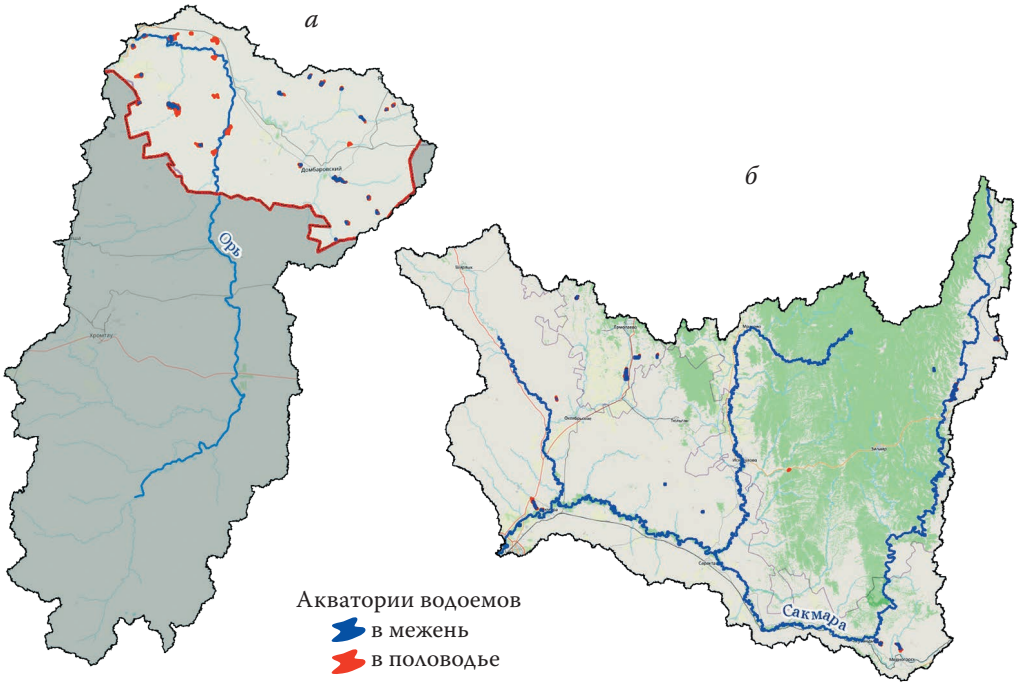


Рис. 10. Картосхемы бассейнов рек: *а* –Орь, *б* – Сакмара.
Fig. 10. Schematic maps of the basins: *a* – the Or River, *b* – the Sakmara River.

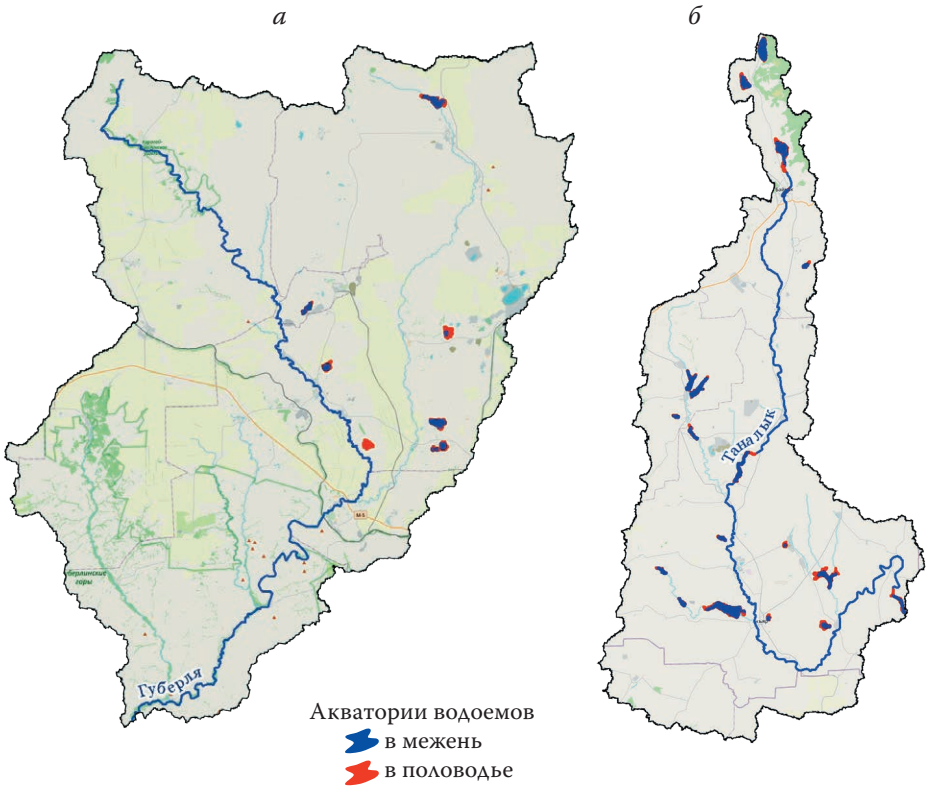


Рис. 11. Картосхемы бассейнов рек: *а* – Губерля, *б* – Таналык.
Fig. 11. Schematic maps of the basins: *a* – the Guberlya River, *b* – the Tanalyk River.



Рис. 12. Картосхема бассейна р. Илек (российская часть)
Fig. 12. Schematic map of the basin the Ilek River (Russian part).

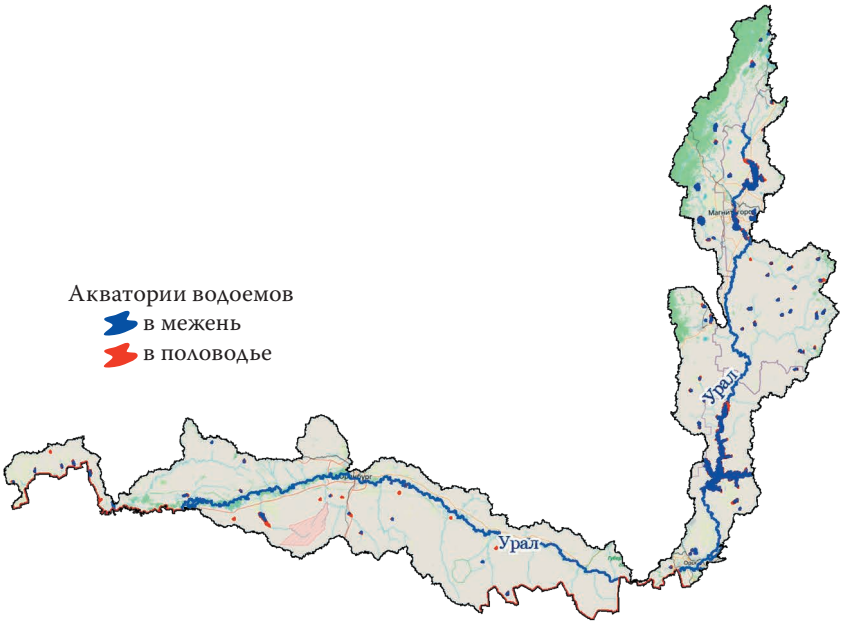


Рис. 13. Картосхема ствола р. Урал (российская часть)
Fig. 13. Schematic map of the Ural River trunk stream (Russian part).

РАСЧЕТ ПОТЕРЬ НА ДОПОЛНИТЕЛЬНОЕ ИСПАРЕНИЕ С ПОВЕРХНОСТИ ВОДОЕМОВ

Для расчета потерь на дополнительное испарение с поверхности водоемов отобраны данные о среднем многолетнем слое испарения с водной поверхности за теплый период, с 5-го по 9-й месяц включительно, по испарителю ГГИ-3000 [10], о среднем многолетнем слое скорректированных осадков с устранением систематических погрешностей осадкомерных приборов за аналогичный период по данным наблюдений[13]. Исходные данные представлены в табл. 4 и 5.

С использованием геоинформационных программных средств выполнено интерполирование значений среднего многолетнего слоя испарения с водной поверхности (рис. 14) и скорректированных значений осадков с устранением систематических погрешностей осадкомерных приборов (рис. 15) по методу обратного взвешенного расстояния.

Для каждого основного притока первого порядка р. Урал с учетом средней площади зеркал водоемов, идентифицированных нейронной сетью, определен объем осадков и испарения с водной поверхности. На основе полученных данных рассчитаны потери на дополнительное испарение с водной поверхности по площадям зеркал в разрезе основных притоков первого порядка р. Урал (табл. 6).

[13] Всероссийский научно-исследовательский институт гидрометеорологической информации – Мировой центр данных (ВНИИГМИ – МЦД). [Электр. ресурс]. URL: http://meteo.ru (дата обращения: 03.10.2024).

Таблица 4. Среднее многолетнее испарение с водной поверхности по испарителю ГГИ-3000 по станциям с 5-го по 9-й месяц
Table 4. Average many-year evaporation from water surface according to GGI-3000 evaporator by stations from 5th to 9th months

Станция	Среднее многолетнее испарение с водной поверхности, мм	Станция	Среднее многолетнее испарение с водной поверхности, мм
Аргаяш	512	Росташи	613
Лаишево	522	Оренбург	853
Бирск	560	Нижнедевицк	517
Чишмы	482	Ершов	898
Бугульма	498	Обоянь	599
Верхнеуральск	621	Орск	799
Болхов	505	Каменная степь	573
Красная гора	615	Казанская	593
Мичуринск	509	Серафимович	694
Зилаир	511	Эльтон	1019

Таблица 5. Средние многолетние скорректированные значения осадков с устранением систематических погрешностей по данным наблюдений с 5-го по 9-й месяц
Table 5. Average many-year revised values of precipitation with elimination of systematic errors according to the observation data from 5th to 9th months

Пункт	Средние многолетние значения осадков, мм	Пункт	Средние многолетние значения осадков, мм
Троицк	244,13	Домбаровский	159,79
Златоуст	413,77	Бреды	209,24
Дуван	324,11	Зилаир	259,81
Кушнаренково	260,79	Акбулак	157,21
Аксаково	279,36	Оренбургский	186,03
Стерлитамак	274,84	Серноводск	239,53
Тукан	362,70	Безенчук	219,83
Сорочинск	194,83	Перелюб	185,86
Верхнеуральск	251,76		

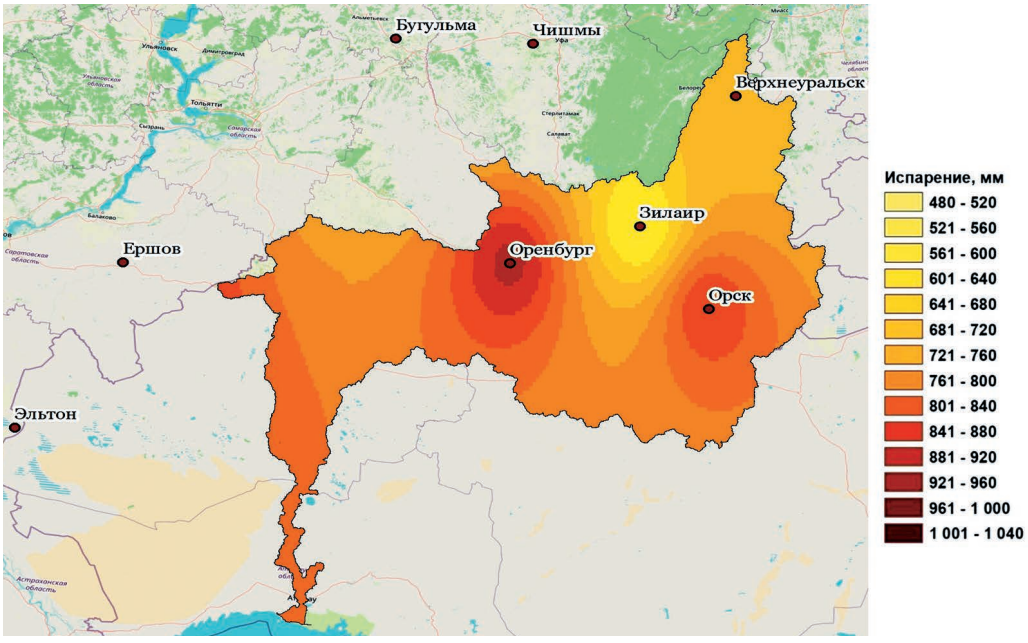


Рис. 14. Среднемноголетний слой испарения с водной поверхности в бассейне р. Урал.
Fig. 14. Average many-year layer of evaporation from water surface in the Ural River basin.

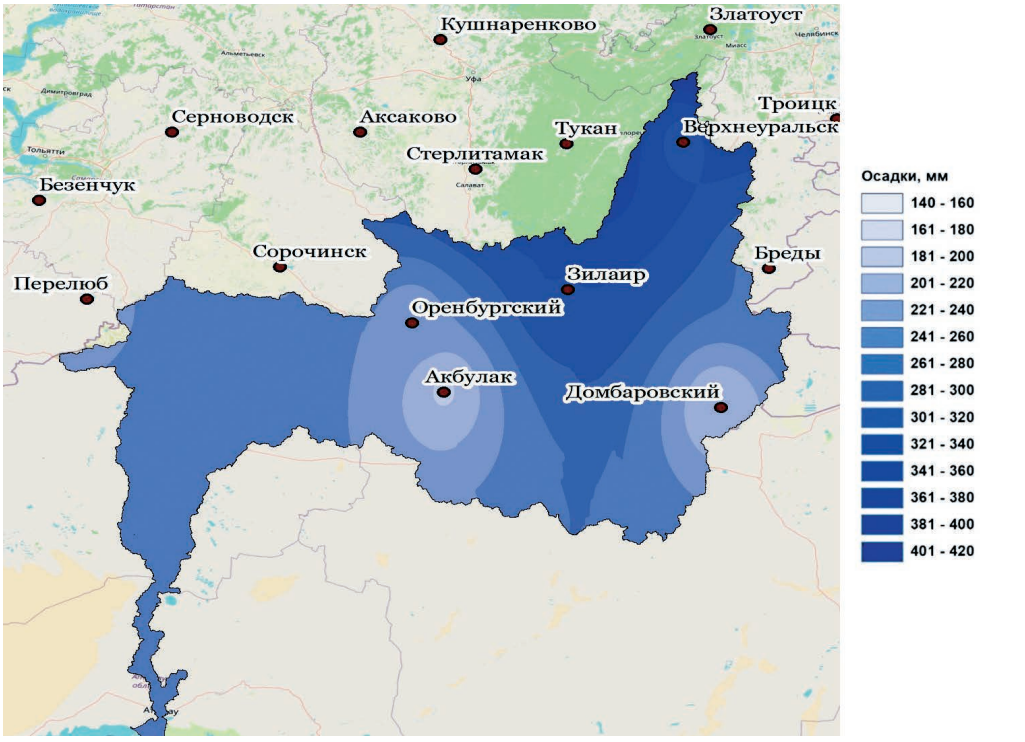


Рис. 15. Среднемноголетний слой скорректированных осадков в бассейне р. Урал.
Fig. 15. Average many-year layer of revised precipitations in the Ural River basin.

Таблица 6. Средние многолетние осадки, испарение с водной поверхности и потери на дополнительное испарение с водоемов в российской части бассейна р. Урал за теплый период (5–9-й месяцы)
Table 6. Average many-year precipitations, evaporation from water surface and losses attributed to additional evaporation from water bodies in the Russian part of the Ural River basin over the warm period (5th – 9th months)

Подбассейн	Площадь водоемов в межень, км^2	Площадь водоемов в половодье, км^2	Средняя площадь, км^2	Объем скорректированных значений осадков, выпавших на поверхность водоемов, млн м^3	Объем испарений с поверхности водоемов, млн м^3	Потери на дополнительное испарение, млн м^3
р. Большой Кизил	2,38	3,25	2,81	0,76	1,73	–0,96
р. Большой Кумак	13,51	26,86	20,19	3,85	14,31	–10,46
р. Губерля	2,21	4,77	3,49	0,83	2,59	–1,76
р. Гумбейка	9,61	31,57	20,59	5,44	12,63	–7,19
р. Илек	2,80	13,08	7,94	1,48	6,06	–4,58
р. Иртек	0,33	6,20	3,27	0,68	2,19	–1,51
р. Орь	9,96	34,67	22,31	4,17	17,11	–12,94
р. Сакмара	15,89	21,99	18,94	4,59	12,30	–7,71
р. Суундук	9,78	17,94	13,86	3,16	9,73	–6,57
р. Таналык	24,49	35,10	29,79	7,72	18,37	–10,65
ствол р. Урал	392,05	491,20	441,63	106,60	300,16	–193,55
р. Чаган	2,80	6,18	4,49	0,95	3,03	–2,09
ИТОГО	**485,79**	**692,81**	**589,30**	**140,23**	**400,19**	**–259,97**

ФОРМИРОВАНИЕ БАЗЫ ДАННЫХ ВОДОЕМОВ

По результатам обработки данных ДЗЗ с применением наиболее эффективной нейронной сети сформирована база данных, которая содержит информацию о координатах и расположении водоемов относительно бассейновых округов, бассейнов рек, водохозяйственных участков, административно-территориальных единиц, данные о площади водоемов, слоях осадков и испарения с водной поверхности, а также информацию об исходных данных ДЗЗ. Структура базы данных представлена на рис. 16.

Ведение базы данных позволяет формировать массивы данных о водоемах и их параметрах за различные периоды в разрезе бассейновых округов, бассейнов рек, водохозяйственных участков, административно-территориальных единиц и использовать их для расчета водохозяйственных балансов бассейнов рек.

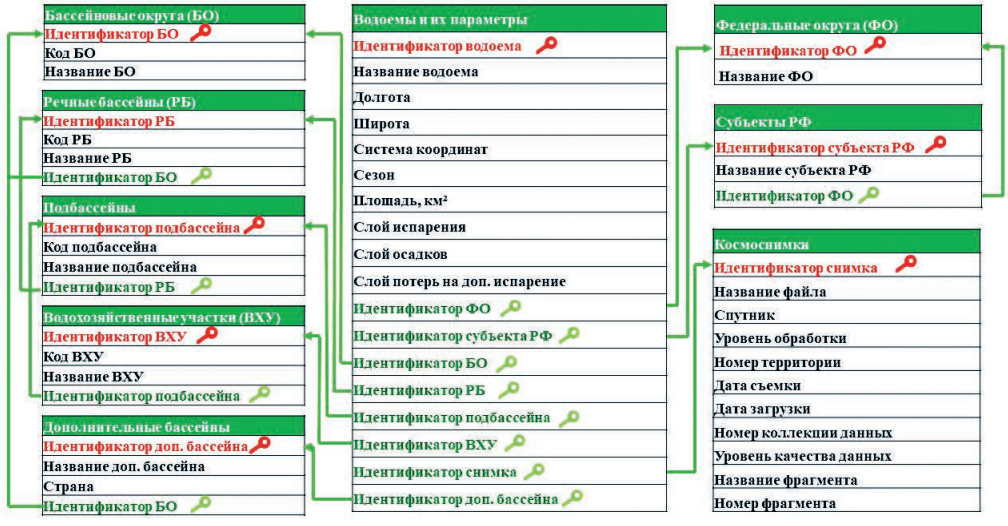


Рис. 16. Структура базы данных водоемов.
Fig. 16. The water bodies' data base structure.

ЗАКЛЮЧЕНИЕ

По результатам выполненных исследований применения методов нейросетевого моделирования для идентификации водоемов по данным дистанционного зондирования Земли достигнута высокая точность сегментации объектов с характерными признаками водоемов по космоснимкам со средним пространственным разрешением. Применение нейронных сетей имеет существенные преимущества перед методами ручной дешифровки данных дистанционного зондирования Земли по соотношению затраченного времени и качества результатов. Универсальность обученной модели нейронной сети позволяет использовать ее при анализе данных ДЗЗ практически любого бассейна реки за период, когда территория не покрыта снегом, и по сравнению с другими методами обследования территорий при минимальных трудозатратах получать достаточно объективную информацию о количестве водоемов, их расположении и параметрах.

Сформированная по результатам обработки данных ДЗЗ с применением нейронной сети информационная база позволяет формировать массивы данных о водоемах и их параметрах за различные периоды по бассейновым округам, бассейнам рек, по водохозяйственным участкам, административным территориям и использовать их в том числе для повышения качества расчетов водохозяйственных балансов.

В перспективе планируется дальнейшее наполнение базы данных по другим бассейнам рек и повышение точности определения водоемов с использованием нейронной сети за счет увеличения объема обучающей выборки и расширения географии территорий обследования.

КОНФЛИКТ ИНТЕРЕСОВ

Авторы заявляют об отсутствии конфликта интересов.

CONFLICT OF INTERESTS

The authors declare no relevant conflict of interests.

СПИСОК ЛИТЕРАТУРЫ

1. Krivoguz D. *et al*. A deep neural network method for water areas extraction using remote sensing data // Journal of Marine Science and Engineering. 2022. Vol. 10. No. 10. P. 1392.
2. Коваленко А. С., Ковалевский В.Н. Детектирование водных объектов по спутниковым снимкам // Применение и развитие нейросетевого моделирования для решения фундаментальных задач в науке и технике: мат-лы Международной молодежной научно-практ. конф., Новочеркасск, 3–4 декабря 2018 г. Новочеркасск: ООО «Лик», 2018. С. 67–71. EDN: VSJKLK.
3. Pai M. M.M. *et al*. Improved semantic segmentation of water bodies and land in SAR images using generative adversarial networks // International Journal of Semantic Computing. 2020. Vol. 14. No. 1. P. 55–69.
4. Zhang X. *et al*. An Enhanced Dual-Stream Network Using Multi-Source Remote Sensing Imagery for Water Body Segmentation // Applied Sciences. 2023. Vol. 14. No. 1. P. 178.
5. Muhadi N. A. *et al*. Deep learning semantic segmentation for water level estimation using surveillance camera // Applied Sciences. 2021. Vol. 11. No. 20. P. 9691.
6. Isikdogan F., Bovik A.C., Passalacqua P. Surface Water Mapping by Deep Learning // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017.
7. Howard A., Sandler M., Chu G., Chen L., Chen B., Tan M., Wang W., Zhu Y., Pang R., Vasudevan V. Searching for MobileNetV3. 2019.
8. Fan T., Wang G., Li Y., Wang H. MA-Net: A Multi-Scale Attention Network for Liver and Tumor Segmentation // IEEE Access, 2020. Vol. 8. P. 179656–179665.
9. Джарвис А., Рейтер Х.И., Нельсон А., Гевара Э. Бесшовные данные SRTM с заполнением отверстий, версия 4 // Международный центр тропического сельского хозяйства (CIAT). [Электр. ресурс]. URL: https://srtm.csi. .cgiar.org (дата обращения: 16.03.2024).
10. Многолетние изменения испарения на Европейской территории России по данным водно-испарительной сети: научно-прикладной справочник / под ред. В.С. Вуглинского. СПб.: РИАЛ, 2021. С. 61–62.

REFERENCES

1. Krivoguz D. *et al*. A deep neural network method for water areas extraction using remote sensing data. *Journal of Marine Science and Engineering*. 2022. Vol. 10. No. 10. P. 1392.
2. Kovalenko A.S., Kovalevskiy V.N. Detection of water bodies with satellite images. Application and development of neural network modelling for solution of fundamental tasks in science and engineering. *Proceedings of International Youth Scientific-practical conference.* Novocherkassk, December 3–4, 2018. Novocherkassk: OOO "Lik", 2018. P. 67–71. EDN: VSJKLK.
3. Pai M. M.M. *et al*. Improved semantic segmentation of water bodies and land in SAR images using generative adversarial networks. *International Journal of Semantic Computing*. 2020. Vol. 14. No. 1. P. 55–69.
4. Zhang X. *et al*. An Enhanced Dual-Stream Network Using Multi-Source Remote Sensing Imagery for Water Body Segmentation. *Applied Sciences*. 2023. Vol. 14. No. 1. P. 178.
5. Muhadi N. A. *et al*. Deep learning semantic segmentation for water level estimation using surveillance camera. *Applied Sciences*. 2021. Vol. 11. No. 20. P. 9691.
6. Isikdogan F., Bovik A.C., Passalacqua P. Surface Water Mapping by Deep Learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017.
7. Howard A., Sandler M., Chu G., Chen L., Chen B., Tan M., Wang W., Zhu Y., Pang R., Vasudevan V. Searching for MobileNetV3, 2019.
8. Fan T., Wang G., Li Y., Wang H. MA-Net: A Multi-Scale Attention Network for Liver and Tumor Segmentation. *IEEE Access*. 2020. Vol. 8. P. 179656–179665.
9. Jarvis A. Reiter, H.I., Nelson A., Gevara E. Джарвис А., Рейтер Х.И., Нельсон А., Гевара Э. The SRTM seamless data with the holes filling, version 4. International Tropical Agriculture Center (CIAT). [Electronic resource]. URL: https://srtm.csi. .cgiar.org (date of address 16.03.2024).

10. Many-year changes of evaporation of the Russia European territory according to the water evaporation network data: scientific/applied reference book / edited by V.S. Vuglinskiy. St. Petersburg.: RIAL, 2021. P. 61–62.

Сведения об авторах:

Душенко Наталья Андреевна, заместитель заведующего отделом применения технологий искусственного интеллекта в управлении водными ресурсами, ФГБУ «Российский научно-исследовательский институт комплексного использования и охраны водных ресурсов», Россия, 344019, г. Ростов-на-Дону, ул. Ченцова, д. 10а; ORCID: 0009-0005-2988-4895; e-mail: dushenko-natali@mail.ru

Головачева Мария Михайловна, заведующий отделом применения технологий искусственного интеллекта в управлении водными ресурсами, ФГБУ «Российский научно-исследовательский институт комплексного использования и охраны водных ресурсов», Россия, 344019, г. Ростов-на-Дону, ул. Ченцова, д. 10а; ORCID: 0009-0007-0512-4116; e-mail: mariya_200218@mail.ru

Капустин Михаил Владимирович, заведующий отделом обработки данных и подготовки информационно-аналитических материалов, ФГБУ «Российский научно-исследовательский институт комплексного использования и охраны водных ресурсов», Россия, 344019, г. Ростов-на-Дону, ул. Ченцова, д. 10а; ORCID: 0009-0000-6494-4981; e-mail: kap.miha@mail.ru

Суртаева Кристина Сергеевна, главный специалист отдела применения технологий искусственного интеллекта в управлении водными ресурсами, ФГБУ «Российский научно-исследовательский институт комплексного использования и охраны водных ресурсов», Россия, 344019, г. Ростов-на-Дону, ул. Ченцова, д. 10а; ORCID: 0009-0000-1125-1014; e-mail: fusewik@outlook.com

About the authors:

Natalia A. Dushenko, Deputy Head of the Department for the Application of Artificial Intelligence in Water Resource Management, Russian Research Institute for integrated water management and protection, 344019**,** Rostov-on-Don, Chentsova street, 10a, ORCID: 0009-0005-2988-4895; e-mail: dushenko-natali@mail.ru

Maria M. Golovacheva, Head of the Department for the Application of Artificial Intelligence in Water Resource Management, Russian Research Institute for integrated water management and protection, 344019, Rostov-on-Don, Chentsova street, 10a, ORCID: 0009-0007-0512-4116; e-mail: mariya_200218@mail.ru

Mikhail V. Kapustin, Head of the Data Processing and Information-Analytical Materials Preparation Department, Russian Research Institute for integrated water management and protection, 344019, Rostov-on-Don, Chentsova street, 10a, ORCID: 0009-0000-6494-4981; e-mail: kap.miha@mail.ru

Kristina S. Surtayeva, The main specialist of the Department for the Application of Artificial Intelligence in Water Resource Management, Russian Research Institute for integrated water management and protection, 344019, Rostov-on-Don, Chentsova street, 10a, ORCID: ORCID: 0009-0000-1125-1014; e-mail: fusewik@outlook.com

Поступила в редакцию / Received 15.01.2025.
Поступила после рецензирования / Revised 03.02.2025.
Принята к публикации / Accepted 29.05.2025.