

Свёрточные нейронные сети в задачах идентификации термокарстовых образований на основе данных дистанционного зондирования

В. В. Жебсаин¹, А. Ю. Гололобов², А. Ф. Посельский¹, Н. И. Башарин³

¹ *Северо-Восточный федеральный университет им. М. К. Аммосова
Якутск, 677000, Россия
E-mail: zhebs@mail.ru*

² *Институт космических исследований и аэронавтики
им. Ю. Г. Шафера СО РАН, Якутск, 677027, Россия
E-mail: gololobov@ikfia.yzn.ru*

³ *Институт мерзлотоведения им. П. И. Мельникова СО РАН
Якутск, 677010, Россия
E-mail: nikolay_b89@mail.ru*

Представлены результаты численных экспериментов по решению задач идентификации термокарстовых полигональных образований, находящихся на ранней стадии развития и угрожающих инфраструктуре населённых пунктов северных регионов России, в частности Центральной Якутии, при помощи разработанной прикладной компьютерной программы, основанной на технологии нейронных сетей. Рассмотрены вопросы формирования двух наборов данных для проведения численных экспериментов, состоящих из 3204 и 10 044 верифицированных изображений ДЗЗ соответственно. Разработаны реестр базы данных для экспериментальных наборов данных и веб-приложение для быстрого интерактивного его формирования. Проведены серии численных экспериментов по идентификации изображений термокарстовых форм рельефа на основе обучения многослойных свёрточных нейронных сетей и сетей прямого распространения. Получено, что свёрточные нейронные сети обладают большей эффективностью при распознавании термокарстовых образований по сравнению с сетями прямого распространения. Представлены результаты исследования эффективности различных моделей свёрточных нейронных сетей при решении задач идентификации четырёх классов неоднородностей ландшафта, таких как термокарстовые образования, поля, леса и водоёмы. Как показали результаты численных экспериментов, свёрточные нейронные сети позволяют с высоким уровнем эффективности распознавать по графическим данным ДЗЗ полигональные термокарстовые образования, характерные для ландшафтов Центральной Якутии. Отобраны две модели свёрточных нейронных сетей, обеспечивающих наилучшие результаты при идентификации термокарстовых образований со средними значениями точности около 96 %.

Ключевые слова: термокарстовые процессы, нейронные сети, модели нейронных сетей, идентификация изображений, наборы данных

Одобрена к печати: 01.12.2025
DOI: 10.21046/2070-7401-2026-23-1-63-75

Введение

Значительную часть России и Северной Америки занимают территории распространения многолетней мерзлоты. На данных территориях в последние десятилетия наблюдается активная термокарстовая деградация ландшафтов, обусловленная глобальным потеплением климата. Особенно интенсивно термокарстовые процессы проявляются на северо-востоке России, в частности в Центральной Якутии. В разных регионах формы проявления термокарстовых процессов различны. В центральной части Якутии на начальном этапе термокарстовой деградации ландшафтов наблюдаются характерные полигональные образования (Башарин и др., 2020; Гоголева и др., 2016; Константинов и др., 2022; Fedorov, Konstantinov, 2003, 2008; Konstantinov et al., 2020, 2023), приводящие в негодность фундаменты строений и сооружений и представляющие серьёзную опасность для инфраструктуры населённых

пунктов. Как показал обзор научно-практической литературы, количество работ, рассматривающих метод дистанционного зондирования Земли (ДЗЗ) как инструмент для мониторинга процессов деградации ландшафтов, незначительно. Ещё более редки работы по применению технологии нейронных сетей для анализа термокарстовых процессов. Можно отметить лишь несколько по арктическим регионам Аляски, Канады и России (Nitze et al., 2021; Runge et al., 2022; Witharana et al., 2022) и по горным ландшафтам Тибета (Huang et al., 2021; Yin et al., 2021), где рассматриваются задачи сегментации провалов и оползней, а также одну публикацию по Центральной Якутии, в которой рассматривается задача сегментации термокарстовых озёр (Hughes-Allen et al., 2023). Между тем разработка методов идентификации термокарстовых образований, находящихся на ранней стадии развития, на основе аэрокосмических данных и с использованием нейронных сетей позволила бы существенно повысить эффективность исследований по вышеуказанной проблематике. Цель настоящей работы заключается в проведении численных экспериментов по идентификации термокарстовых форм рельефа по данным ДЗЗ при помощи разработанной прикладной программы, основанной на технологии нейронных сетей.

Реестр термокарстовых объектов

Для обучения и тестирования нейронных сетей нужны наборы данных, содержащие в нашем случае верифицированное множество спутниковых изображений ДЗЗ. В настоящее время наиболее распространёнными картографическими сервисами, предоставляющими графические данные ДЗЗ, являются Google Maps (<https://maps.google.com/>) и Яндекс Карты (<https://yandex.ru/maps/>). Указанные сервисы основаны на данных дистанционного зондирования Земли со спутников Landsat, Quickbird, SPOT и топографических карт, обладающих достаточно высоким разрешением на местности. С целью формирования наборов графических данных для численных экспериментов был разработан экспериментальный реестр термокарстовых объектов. Для формирования реестра были проведены сбор, предварительная обработка и анализ данных картографических сервисов Google Maps и Яндекс Карты, а также результатов фотосъёмки с применением беспилотных летательных аппаратов (БПЛА). Одним из вопросов корректности данных реестра является подтверждение термокарстового происхождения объектов, наблюдаемых на спутниковых снимках. Для этого были организованы экспедиции в Чурапчинский р-н Якутии и в окрестности г. Якутска, где наблюдаются термокарстовые образования. Аэровизуальные наблюдения и фотосъёмки проводились с помощью БПЛА DJI Phantom 4 Advanced. Полёты квадрокоптера выполнялись в ручном режиме на разных высотах: 100, 150, 200, 300, 400 и 500 м. На трёх участках около с. Табага и на восьми участках в окрестностях сёл Чурапча и Харбала, а также на нескольких фоновых участках в общей сложности получено 850 кадров с помощью БПЛА, на основе которых были подготовлены 1400 изображений.

При сборе и анализе данных мы исходили из необходимости учёта следующих факторов, влияющих на дешифровочные признаки графических образов:

- высота полётов БПЛА;
- облачность;
- угол падения солнечного света;
- растительный покров;
- глубина проседания грунта термокарстовых образований;
- время года.

С учётом изложенного аэрофотосъёмки при помощи БПЛА проводились весной (май) и летом (июль) на разных высотах полёта. На *рис. 1* (см. с. 65) представлен снимок с БПЛА (см. *рис. 1а*) в окрестностях с. Харбала Чурапчинского р-на Республики Саха (Якутия). Как видно на изображении, наблюдаются множественные образования овальной формы. Данные образования также видны на спутниковом снимке (см. *рис. 1б*), полученном с помощью картографического сервиса Google Maps на том же участке. На основе аэрофотосъёмки БПЛА

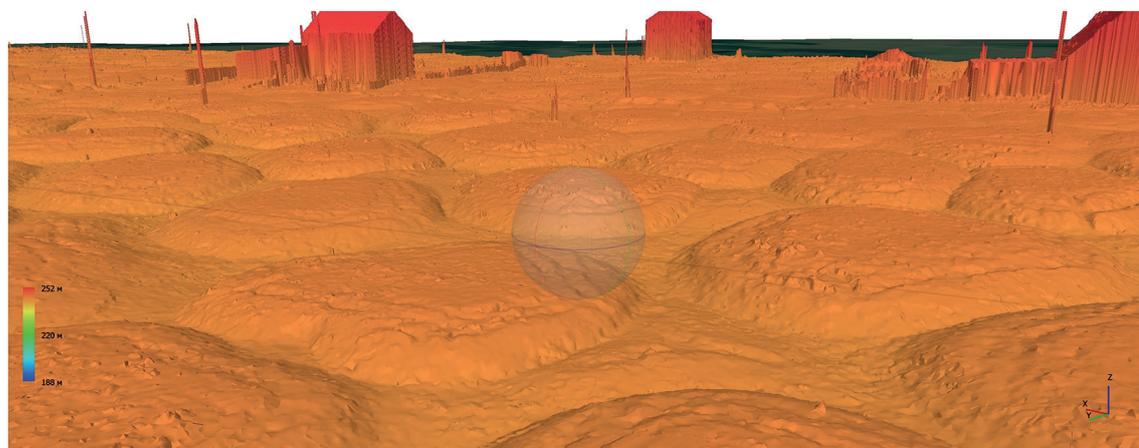
с применением метода фотограмметрии и специализированной программы Agisoft Metashape построена 3D-модель термокарстового ландшафта (рис. 2), что позволило определить геометрические параметры наблюдаемых объектов. В частности, установлено, что у наблюдаемых образований средняя глубина протаивания ландшафта составляет около 1 м.



Рис. 1. Аэроснимок (а) и спутниковый снимок картографического сервиса Google (б) на территории Центральной Якутии в окрестностях с. Харбала Чурапчинского р-на



а



б

Рис. 2. Пример 3D-модели термокарстового ландшафта, созданной специализированной программой Agisoft Metashape на основе серии аэроснимков в естественной цветовой гамме (а) и цветовой градиента по высоте (б)

На *рис. 3* представлен пример сопоставления аэрофотоснимка с БПЛА и снимков с картографических сервисов Google Maps и Яндекс Карты. Как видно, на всех изображениях наблюдаются термокарстовые образования. Отличия между рисунками связаны с разными условиями съёмки (время съёмки, сезон, время суток, облачность и т. д.) и пространственным разрешением спутникового снимка (минимальным размером различимых земных объектов). Проведённое сопоставление подтверждает, что данные картографических сервисов Google Maps и Яндекс Карты могут быть применены для задач идентификации термокарстовых образований на территории Центральной Якутии и для формирования экспериментального реестра термокарстовых объектов.

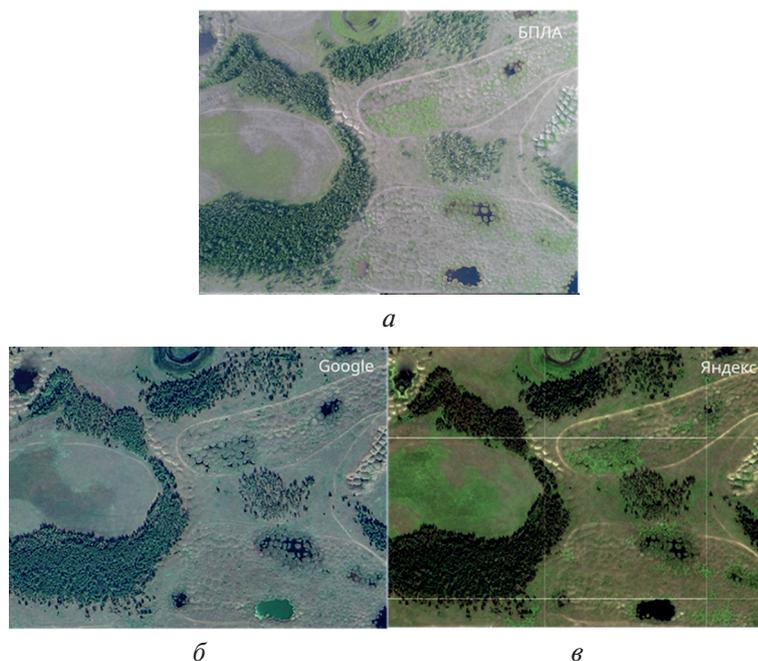


Рис. 3. Аэроснимок с БПЛА (*а*), спутниковые снимки с картографических сервисов Google (*б*) и Яндекс (*в*) в окрестностях с. Чурапча ($61,9915547^\circ$ с. ш., $132,5095944^\circ$ в. д.)

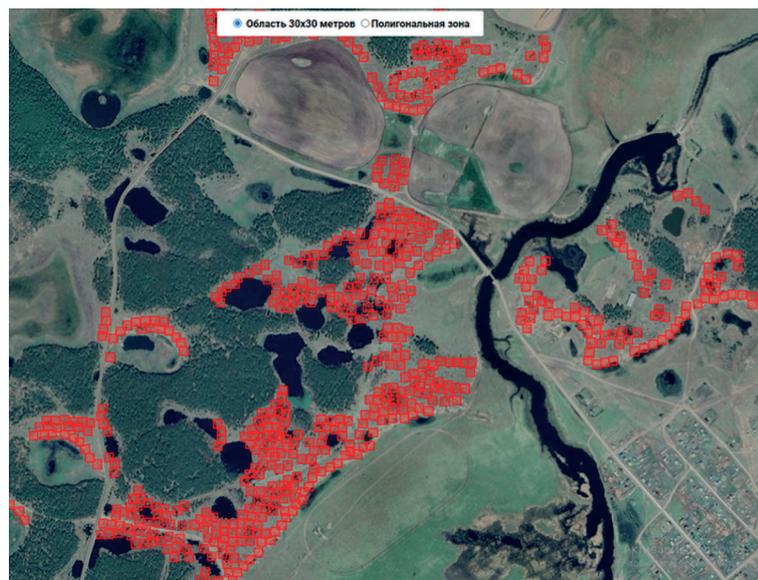


Рис. 4. Примеры термокарстовых объектов, введённых в экспериментальный реестр на основе разработанного веб-приложения и Google Maps API. Добавление объектов осуществлялось в интерактивном режиме с помощью клика мыши в браузере. Размеры объектов соответствуют 32×32 м

Картографические системы Google Maps и Яндекс Карты предоставляют программный интерфейс API (*англ.* Application Programming Interface), позволяющий взаимодействовать с ними на программном уровне. Взаимодействие с Google Maps и Яндекс Карты производится с помощью Google Maps API и Яндекс Карты API на языке javascript. С целью формирования экспериментального реестра термокарстовых объектов Центральной Якутии было разработано веб-приложение на основе технологий HTML, CSS, javascript, jQuery, Google Maps API и Яндекс Карты API. Взаимодействие с базой данных осуществлялось с помощью языка программирования PHP и формата обмена данными JSON. Интерфейс разработанного приложения представлен на *рис. 4* (см. с. 66). Приложение позволяет в интерактивном режиме с помощью клика мыши отмечать на карте участки различных классов (термокарстовые образования, лес, водоём, поля), координаты которых записываются в базу данных реестра термокарстовых объектов.

Экспериментальные наборы данных

Для обучения сети были сформированы наборы тренировочных (*англ.* training), валидационных (*англ.* validation) и тестовых данных. Наборы включали четыре класса изображений: термокарстовые образования, поля, леса и водоёмы — по данным картографического сервиса Google Maps. Размеры изображений были одинаковыми и составляли 128×128 пикселей, которые соответствовали размерам участков на поверхности Земли 32×32 м. Отметим, что первоначальные эксперименты с изображениями 70×70 пикселей оказались недостаточно точными, в связи с чем перешли к наборам с разрешением 128×128 пикселей. Примеры изображений представлены на *рис. 5*.

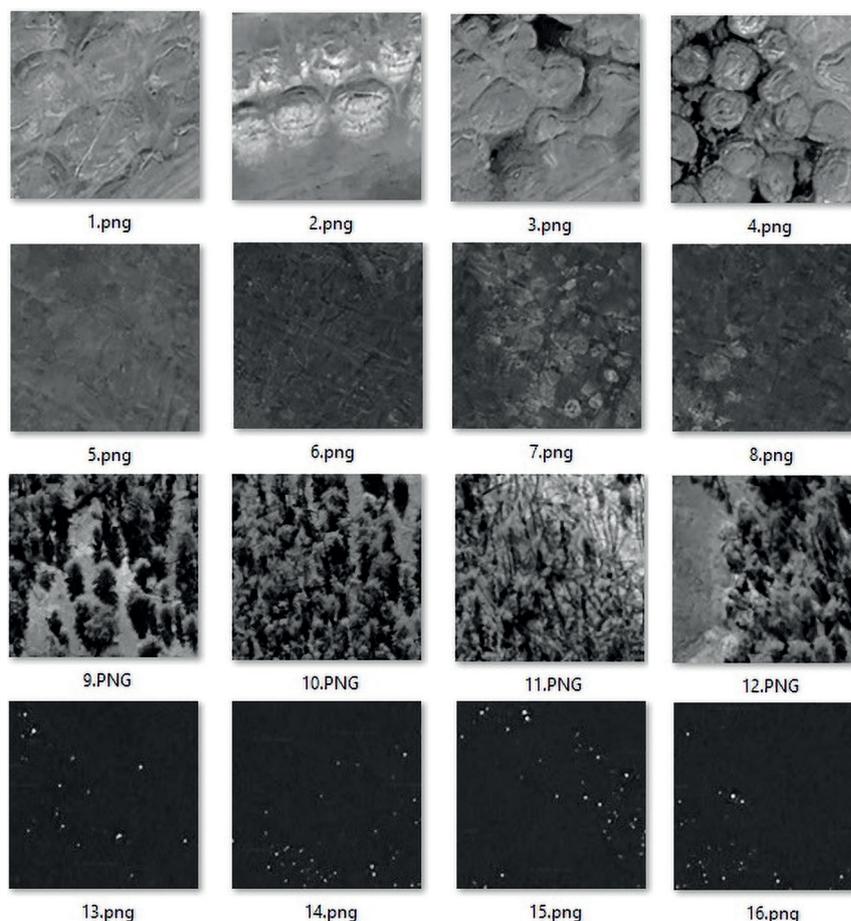


Рис. 5. Примеры изображений классов ландшафта

На данном рисунке в первом верхнем ряду (1.png–4.png) приведены термокарстовые образования, во втором (5.png–8.png) — поля, в третьем (9.png–12.png) — леса и в четвёртом (13.png–16.png) — водоёмы. Всего сформированы два экспериментальных набора DS0 и DS1. В данных экспериментальных наборах DS0 и DS1 содержатся изображения с размерами 70×70 пикселей и 128×128 пикселей соответственно. Количество изображений по отдельным наборам и классам неоднородностей ландшафта представлено в *табл. 1*.

Таблица 1. Количество изображений в наборах по отдельным классам ландшафта

Наборы	Термокарстовые образования	Поля	Леса	Водоёмы
<i>Набор DS0</i>				
Тренировочный поднабор	1242	1242	0	0
Валидационный поднабор	360	360	0	0
<i>Набор DS1</i>				
Тренировочный поднабор	1746	2004	1305	1770
Валидационный поднабор	470	506	360	360
Тестовый поднабор	308	704	151	360

Как видно из *табл. 1*, наборы DS0 и DS1 содержат 3204 и 10 044 верифицированных изображения соответственно.

Численные эксперименты

Для проведения численных экспериментов нами были разработаны две прикладные программы на языке Python: для сетей прямого распространения (*англ.* Feedforward Neural Network — FNN) (Жебсаин, Посельский, 2024) и свёрточных сетей (*англ.* Convolutional Neural Networks — CNN) (Жебсаин и др., 2024). Свёрточные сети реализованы на основе функций модуля tensorflow (Багаев, 2020). Выполнены три серии численных экспериментов, реализующих различные виды нейронных сетей и применяющих разные обучающие наборы. Данные по сериям проведённых численных экспериментов представлены в *табл. 2*.

Таблица 2. Серии численных экспериментов

Серия	Вид нейронной сети	Количество слоёв	Набор данных	Количество экспериментов
ExpFNN	Прямого распространения	3	DS0	122
ExpCNN0	Свёрточная	4	DS0	20
ExpCNN1	Свёрточная	4–19	DS1	186

Первая серия ExpFNN была проведена с нейронной сетью прямого распространения и с набором данных DS0 (*табл. 1*). Эффективность (точность) нейронных сетей прямого распространения существенным образом зависит от таких параметров, как скорость обучения, количество эпох обучения и количество нейронов в скрытом слое. Эффективность сети определялась как доля (в %) правильно идентифицированных изображений относительно их общего количества в валидационном поднаборе. Как показали численные эксперименты данной серии, эффективность нейронной сети при идентификации термокарстовых объектов из валидационного поднабора данных варьируется в пределах 88–92 %. Исследование зависимости эффективности от скорости обучения продемонстрировало, что максимальная результативность сети достигается при значениях скорости обучения в пределах 0,002–0,003 (*рис. 6*, см. с. 69). Изучение зависимости эффективности идентификации от количества

эпох показало, что наибольшая эффективность достигается при 19–25 эпохах, далее происходит ухудшение результатов. Максимальная эффективность сети приходится на количество нейронов в скрытом слое в диапазоне значений 3500–3750.

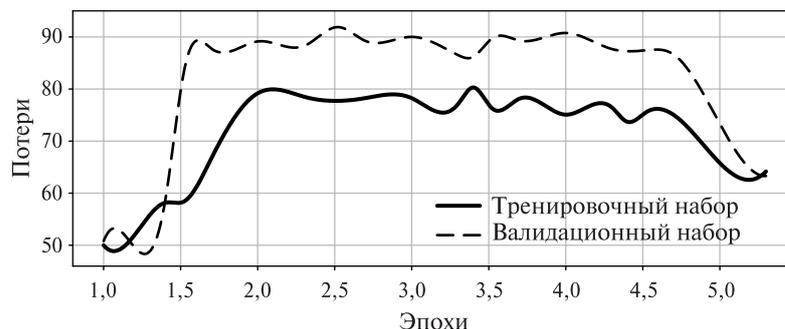


Рис. 6. Зависимость эффективности от скорости обучения

Серия численных экспериментов ExpCNN0 была проведена для сравнения эффективности идентификации изображений термокарстовых образований нейронными сетями прямого распространения (FNN) и свёрточной (CNN). На рис. 7 представлена зависимость точности сети CNN от количества эпох при обработке тренировочного и валидационного поднаборов данных, относящихся Чурапчинскому р-ну в Центральной Якутии (см. рис. 7а). Как видно из рисунка, максимальная точность сети при обработке тренировочных выборок данных может достигать ~99–100 и ~97–98 % для валидационных в диапазоне 20–40 эпох обучения. Зависимость потерь сети от количества эпох при обучении и валидации представлена на рис. 7б. Потери сети определяются как среднее значение ошибок для каждого обучающего или валидационного пакетов данных. Между кривыми потерь тренировочного и валидационного поднаборов присутствует очевидная корреляция, и минимальные потери наблюдаются уже при значениях эпох в районе 21–25 как для тренировочного, так и для валидационного поднаборов.

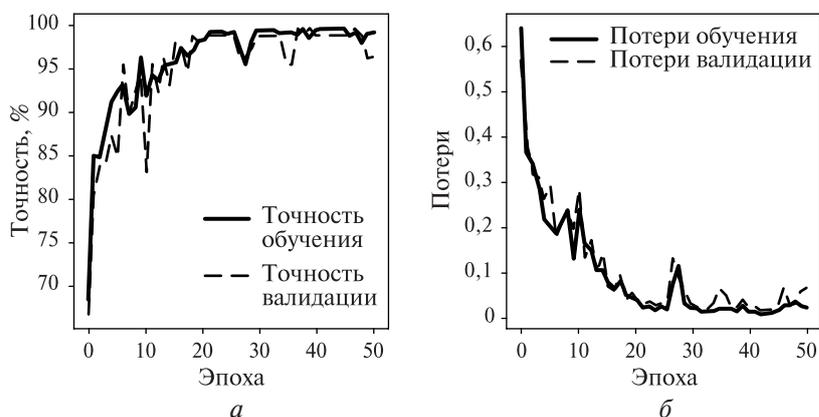


Рис. 7. Зависимость точности (а) и потерь (б) свёрточной нейронной сети при обработке тренировочного и валидационного поднаборов от количества эпох обучения

Аналогичные зависимости для сети прямого распространения приведены на рис. 8 (см. с. 70). Как видно из рисунка, максимальная точность сети FNN при обработке тренировочных выборок данных достигает ~95 % в диапазоне количества эпох обучения 45–50 и ~91 % для валидационных выборок данных в диапазоне 8–20 эпох (см. рис. 8а). Анализ и сравнение рис. 7 и 8 показывают, что точность свёрточной сети выше, чем соответствующая характеристика сети прямого распространения. При этом результаты свёрточной сети менее устойчивы, чем у сети прямого распространения. Так, при обработке валидационного

поднабора у сети CNN разброс точности меняется в пределах от 80 до 98 %, тогда как у сети FNN соответствующий диапазон незначителен и составляет ~88–91 %. Отметим, что максимальные значения точности для валидационного поднабора сеть прямого распространения достигает при меньшем значении количества эпох обучения (8–20).

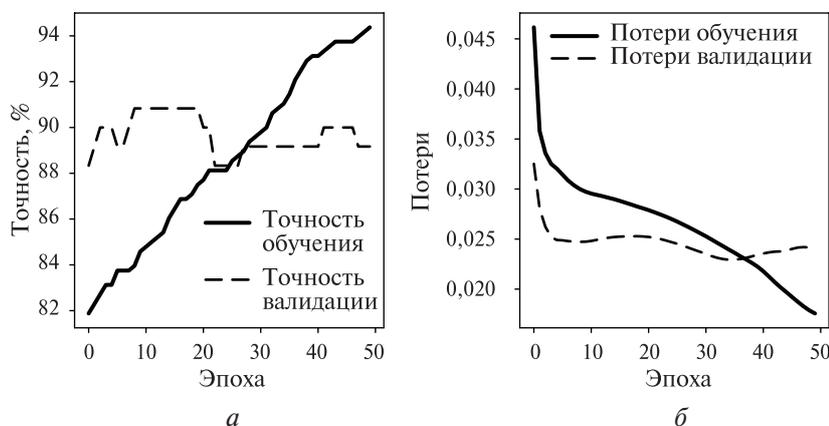


Рис. 8. Зависимость точности (а) и потерь (б) нейронной сети прямого распространения при обработке тренировочного и валидационного поднаборов от количества эпох обучения

Результаты серии численных экспериментов ExpFNN, ExpCNN0 показали, что свёрточные нейронные сети обладают большей эффективностью перед нейронными сетями прямого распространения при решении задач идентификации термокарстовых образований по изображениям космического ДЗЗ.

В третьей серии численных экспериментов ExpCNN1 проведены исследования по поиску оптимальных моделей свёрточных сетей, обеспечивающих наибольшую точность при идентификации не только валидационных, но и тестовых поднаборов данных. В отличие от валидационного поднабора данных, который является частью общего набора по обучению сети, в тестовом поднаборе содержатся неизвестные классы неоднородностей ландшафта, соответственно, в данном случае нейронной сети труднее выполнять идентификацию. Также серия ExpCNN1 применяет экспериментальный набор DS1, в котором размеры изображений увеличены по сравнению с набором DS0 и составляют 128×128 пикселей (табл. 1). Как показали численные эксперименты серии ExpFNN1 точность свёрточной сети по идентификации термокарстовых образований оказалась достаточно высокой для тренировочного и валидационного поднаборов, достигая значений до 1 (100 %) и 0,97–0,98 (97–98 %) соответственно (рис. 9). Для тестового поднабора показатели точности несколько ниже и варьируются в пределах 94–97 %.

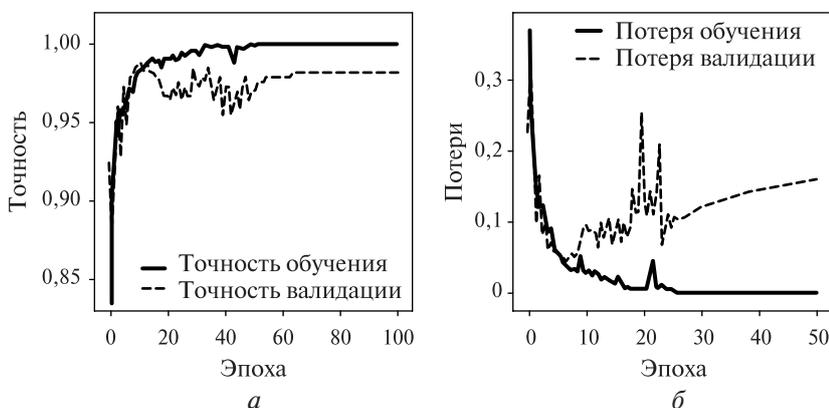


Рис. 9. Зависимость точности (а) и потерь (б) свёрточной сети с восемью слоями ($2 \times 32c$, $2 \times 64c$, $3 \times 128c$, 128) от количества эпох для тренировочного и валидационного поднаборов

Наибольшую эффективность идентификации демонстрируют модели сети $2 \times 32c$, $7 \times 64c$, 128 и $2 \times 32c$, $2 \times 64c$, $9 \times 128c$, 128 со средними значениями точности идентификации термокарстовых образований около 96 %. Здесь модели сети обозначены в формате $N \times Mс$, где N — количество слоёв, M — фильтров, $с$ — признак свёрточного слоя. Например, $2 \times 32c$, $N \times 64c$, 128 обозначает сеть, состоящую из двух свёрточных слоёв с 32 фильтрами, N свёрточных слоёв с 64 фильтрами и одного полносвязного слоя из 128 узлов (нейронов). В табл. 3 приведены средние значения точности идентификации различных классов неоднородностей ландшафта для вышеуказанных моделей сети. При этом в первом случае максимальная точность наблюдается при 10 слоях, а во втором при 14.

Таблица 3. Средняя точность идентификации различных классов неоднородностей ландшафта

Модель	Количество слоёв	Средняя точность, %			
		Термокарстовые образования	Поля	Леса	Водоёмы
$2 \times 32c$, $7 \times 64c$, 128	10	96,04	94,98	90,84	99,40
$2 \times 32c$, $2 \times 64c$, $9 \times 128c$, 128	14	96,10	95,17	90,47	99,50

Зависимость точности идентификации термокарстовых образований тестового поднабора от количества слоёв для серии моделей $2 \times 32c$, $2 \times 64c$, $N \times 128c$, 128 представлена на рис. 10.

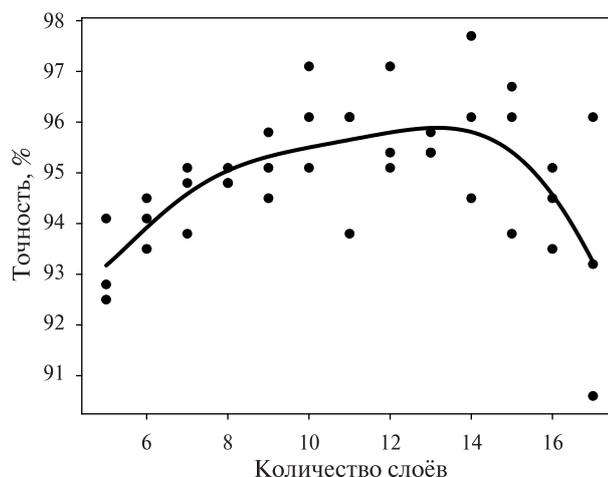


Рис. 10. Зависимость точности идентификации термокарстовых образований тестового поднабора от количества слоёв моделей серии $2 \times 32c$, $2 \times 64c$, $N \times 128c$, 128

Численные эксперименты показали, что свёрточная нейронная сеть в состоянии достаточно точно идентифицировать не только термокарстовые объекты, но и другие классы ландшафта, такие как поля, леса и водоёмы. Наивысшую точность, достигающую 99,7–100 %, сеть демонстрирует при идентификации изображений водоёмов. Наименьшая точность идентификации, варьирующаяся в пределах 90–91 %, наблюдается для изображений лесов, что обусловлено большей неоднородностью и сложностью лесных ландшафтов. Как видно из рис. 5, изображения лесов более сложны по фактуре, могут содержать и сплошные лесные массивы, редколесье и кустарники, а также выгоревшие в результате пожаров леса. В подобных случаях, видимо, возникает необходимость в детализации обучающих наборов, например, обучать сеть идентифицировать отдельно сплошные лесные массивы, редколесье и выгоревшие леса.

Заключение

Применение методов машинного обучения в задачах идентификации термокарстовых образований по аэрокосмическим фотоснимкам является одним из перспективных направлений в исследовании деградации термокарстовых ландшафтов на северо-востоке России. В настоящей работе проведено исследование эффективности различных видов и моделей нейронных сетей для решения задачи идентификации термокарстовых полигональных образований в Центральной Якутии. Как показали численные эксперименты, эффективность идентификации изображений термокарстовых образований набора данных DS0 (табл. 1) нейронной сетью прямого распространения варьируется в пределах 88–92 %. При этом максимальная результативность данной сети достигается при значениях скорости обучения в пределах 0,002–0,003. Наибольшая эффективность наблюдается при количестве эпох обучения сети в интервале от 19 до 25, при количестве нейронов в скрытом слое в диапазоне 3500–3750. При экспериментах с тем же набором данных свёрточная сеть демонстрирует большую точность идентификации. Так, при обработке тестового набора у свёрточной сети разброс точности меняется в пределах от 80 до 98 %, тогда как у сети прямого распространения соответствующий диапазон составляет ~88–91 %. Но при этом максимальная точность для валидационного поднабора сети прямого распространения достигается при меньшем количестве эпох обучения (8–20).

При экспериментах с набором данных DS1 (табл. 1) многослойная свёрточная сеть демонстрирует достаточно высокую точность идентификации термокарстовых образований, достигающую до 1 (100 %) для тренировочного поднабора данных и 0,97–0,98 (97–98 %) для валидационного. Поиски оптимальной модели многослойной свёрточной сети по тестовому поднабору показали, что наибольшую эффективность идентификации демонстрируют модели сети 2×32с, 7×64с, 128 (10 слоёв) и 2×32с, 2×64с, 9×128с, 128 (14 слоёв) со средними значениями точности идентификации термокарстовых образований, составляющими около 96 %. Оценка и сравнение точности идентификации нейронной сетью изображений различных других классов ландшафта: полей, лесов, водоёмов — показали, что свёрточные сети могут успешно решать идентификационные задачи и для данных классов. В целом исследования продемонстрировали, что технология свёрточных нейронных сетей может с достаточно высокой точностью решать задачи автоматизированной идентификации не только термокарстовых образований, но и других классов ландшафтов при условии наличия верифицированных наборов обучающих данных. Разработанное в работе исследовательское программное обеспечение может применяться в качестве средства мониторинга за состоянием ландшафтов регионов распространения криолитозон.

Проведённые в работе исследования выполнены за счёт гранта Российского научного фонда № 24-21-20043.

Литература

1. Багаев И. И. Анализ понятий нейронная сеть и свёрточная нейронная сеть. Обучение свёрточной нейросети при помощи модуля TensorFlow // Мат. и программное обеспечение систем в пром. и социальной сферах. 2020. Т. 8. № 1. С. 15–22. DOI: 10.18503/2306-2053-2020-8-1-15-22.
2. Башарин Н. И., Егорова Л. С., Васильев Н. Ф. и др. Применение беспилотных летательных аппаратов для оценки активизации термокарста // Вестн. Северо-Восточного федер. ун-та. 2020. № 3 (19). С. 36–44. DOI: 10.25587/SVFU.2020.19.3.005.
3. Гоголева П. А., Стручкова С. Г., Федорова Е. Д. Физико-географические условия развития аласных форм рельефа и закономерности распределения растительности // Успехи современ. естествознания. 2016. № 12(2). С. 368–374.
4. Жебсаин В. В., Посельский А. Ф. Идентификация термокарстовых объектов по спутниковым графическим данным с помощью нейронной сети // Тр. ин-та системного программирования РАН. 2024. Т. 36. № 4. С. 183–190. DOI: 10.15514/ISPRAS-2024-36(4)-14.

5. Жебсаин В. В., Гололобов А. Ю., Башарин Н. И., Посельский А. Ф. Особенности применения технологии нейронных сетей для распознавания графических образов термокарстовых объектов // Геоинформатика. 2024. № 4. С. 39–47. DOI: 10.47148/1609-364X-2024-4-39-47.
6. Константинов П. Я., Трезубов О. Д., Чжан М., Ли Г. Динамика температуры вечномёрзлых пород за последние 30 лет в отдельных районах восточного сектора российской Арктики // Международный журнал приклад. наук и технологий Integral. 2022. № 1. С. 260–267. DOI: 10.55186/02357801_2022_7_1_11.
7. Fedorov A. N., Konstantinov P. Y. Observations of surface dynamics with thermokarst initiation // Proc. 8th Intern. Conf. on Permafrost. 2003. P. 239–243.
8. Fedorov A. N., Konstantinov P. Y. Recent changes in ground temperature and the effect on permafrost landscapes in Central Yakutia // Proc. 9th Intern. Conf. on Permafrost. 2008. P. 433–438.
9. Huang L., Liu L., Luo J. et al. Automatically quantifying evolution of retrogressive thaw slumps in Beiluhe (Tibetan Plateau) from multi-temporal CubeSat images // Intern. J. Applied Earth Observation and Geoinformation. 2021. V. 102. Article 102399. DOI: 10.1016/j.jag.2021.102399.
10. Hughes-Allen L., Bouchard F., Séjourné A. et al. Automated identification of thermokarst lakes using machine learning in the ice-rich permafrost landscape of Central Yakutia (Eastern Siberia) // Remote Sensing. 2023. V. 15. Iss. 5. Article 1226. DOI: 10.3390/rs15051226.
11. Konstantinov P., Zhelezniak M., Basharin N. et al. Establishing of permafrost thermal monitoring sites in East Siberia // Land. 2020. V. 9. Iss. 12. Article 476. 10 p. DOI: 10.3390/land9120476.
12. Konstantinov P., Basharin N., Fedorov A. et al. Impact of climate change on the ground thermal regime in the lower Lena region, Arctic Central Siberia // Land. 2023. V. 12. Iss. 1. Article 19. 13 p. DOI: 10.3390/land12010019.
13. Nitze I., Heidler K., Barth S., Grosse G. Developing and testing a deep learning approach for mapping retrogressive thaw slumps // Remote Sensing. 2021. V. 13. Iss. 21. Article 4294. DOI: 10.3390/rs13214294.
14. Runge A., Nitze I., Grosse G. Remote sensing annual dynamics of rapid permafrost thaw disturbances with LandTrendr // Remote Sensing of Environment. 2022. V. 268. Article 112752. DOI: 10.1016/j.rse.2021.112752.
15. Witharana C., Udawalpola M. R., Liljedahl A. K. et al. Automated detection of retrogressive thaw slumps in the high Arctic using high-resolution satellite imagery // Remote Sensing. 2022. V. 14. Iss. 17. Article 4132. DOI: 10.3390/rs14174132.
16. Yin G., Luo J., Niu F. et al. Machine learning-based thermokarst landslide susceptibility modeling across the permafrost region on the Qinghai-Tibet Plateau // Landslides. 2021. V. 18. P. 2639–2549. DOI: 10.1007/s10346-021-01669-7.

Convolutional neural networks in problems of identification of thermokarst formations based on remote sensing data

V. V. Zhebsain¹, A. Yu. Gololobov², A. F. Poselsky², N. I. Basharin³

¹ M. K. Ammosov North-Eastern Federal University, Yakutsk 677000, Russia
E-mail: zhebs@mail.ru

² Yu. G. Shafer Institute of Cosmophysical Research and Aeronomy SB RAS
Yakutsk 677027, Russia
E-mail: gololobov@ikfia.ysn.ru

³ Melnikov Permafrost Institute SB RAS, Yakutsk 677010, Russia
E-mail: nikolay_b89@mail.ru

The paper presents the results of numerical experiments to solve the problems of identifying thermokarst polygonal formations that are at an early stage of development and threaten the infrastructure of settlements in the northern regions of Russia, in particular Central Yakutia, using a computer program developed on the basis of neural network technology. The issues of forming two sets of data for conducting numerical experiments, consisting of 3204 and 10 044 verified remote sensing images,

respectively, are considered. A database registry for experimental datasets and a web application for its rapid interactive generation have been developed. A series of numerical experiments were conducted to identify images of thermokarst landforms based on training of multilayer convolutional neural networks and direct propagation networks. It is found that convolutional neural networks are more efficient at recognizing thermokarst formations compared to direct propagation networks. The results of a study of the effectiveness of various convolutional neural network models in solving problems of identifying four classes of landscape inhomogeneities, such as thermokarst formations, fields, forests, and reservoirs, are presented. As the results of numerical experiments show, convolutional neural networks make it possible to recognize polygonal thermokarst formations typical of the landscapes of Central Yakutia with a high level of efficiency from graphical remote sensing data. Two models of convolutional neural networks are selected that ensure the best results in the identification of thermokarst formations with average accuracy of about 96 %.

Keywords: thermokarst processes, neural networks, neural network models, image identification, datasets

Accepted: 01.12.2025

DOI: 10.21046/2070-7401-2026-23-1-63-75

References

1. Bagaev I. I., Concept analysis neural network and conventional neural network, conventional neural network training using the TensorFlow module, *Software of systems in the industrial and social fields*, 2020, V. 8, No. 1, pp. 15–22 (in Russian), DOI: 10.18503/2306-2053-2020-8-1-15-22.
2. Basharin N. I., Egorova L. S., Vasiliev N. F. et al., Using unmanned aerial vehicles for thermokarst activity assessment, *Vestnik of North-Eastern Federal University Series "Earth Sciences"*, 2020, No. 3(19), pp. 36–44 (in Russian), DOI: 10.25587/SVFU.2020.19.3.005.
3. Gogoleva P. A., Struchklova S. G., Fedorova E. D., Physico-geographical conditions of the alas landscape development and regularities of the vegetation distribution, *Advances in current natural sciences*, 2016, No. 12(2), pp. 368–374 (in Russian).
4. Zhebsain V. V., Poselsky A. F., Identification of thermokarst objects from satellite graphical data using a neural network, *Proc. Institute for System Programming of RAS*, 2024, V. 36, Iss. 4, pp. 183–190 (in Russian), DOI: 10.15514/ISPRAS-2024-36(4)-14.
5. Zhebsain V. V., Gololobov A. Yu., Basharing N. I., Poselsky A. F., Features of the use of neural network technology for recognizing of thermokarst objects, *Geoinformatika*, 2024, No. 4, pp. 39–47 (in Russian), DOI: 10.47148/1609-364X-2024-4-39-47.
6. Konstantinov P. Ya., Tregubov O. D., Zhang M., Li G., Permafrost temperature dynamics over the last 30 years in certain regions of the eastern sector of the Russian Arctic, *Intern. J. Applied Sciences and Technology Integral*, 2022, No. 1, pp. 260–267 (in Russian), DOI: 10.55186/02357801_2022_7_1_11.
7. Fedorov A. N., Konstantinov P. Y., Observations of surface dynamics with thermokarst initiation, *Proc. 8th Intern. Conf. on Permafrost*, 2003, pp. 239–243.
8. Fedorov A. N., Konstantinov P. Y., Recent changes in ground temperature and the effect on permafrost landscapes in Central Yakutia, *Proc. 9th Intern. Conf. on Permafrost*, 2008, pp. 433–438.
9. Huang L., Liu L., Luo J. et al., Automatically quantifying evolution of retrogressive thaw slumps in Beiluhe (Tibetan Plateau) from multi-temporal CubeSat images, *Intern. J. Applied Earth Observation and Geoinformation*, 2021, V. 102, Article 102399, DOI: 10.1016/j.jag.2021.102399.
10. Hughes-Allen L., Bouchard F., Séjourné A. et al., Automated identification of thermokarst lakes using machine learning in the ice-rich permafrost landscape of Central Yakutia (Eastern Siberia), *Remote Sensing*, 2023, V. 15, Iss. 5, Article 1226, DOI: 10.3390/rs15051226.
11. Konstantinov P., Zhelezniak M., Basharin N. et al., Establishing of permafrost thermal monitoring sites in East Siberia, *Land*, 2020, V. 9, Iss. 12, Article 476, 10 p., DOI: 10.3390/land9120476.
12. Konstantinov P., Basharin N., Fedorov A. et al., Impact of climate change on the ground thermal regime in the lower Lena region, Arctic Central Siberia, *Land*, 2023, V. 12, Iss. 1, Article 19, 13 p., DOI: 10.3390/land12010019.
13. Nitze I., Heidler K., Barth S., Grosse G., Developing and testing a deep learning approach for mapping retrogressive thaw slumps, *Remote Sensing*, 2021, V. 13, Iss. 21, Article 4294, DOI: 10.3390/rs13214294.
14. Runge A., Nitze I., Grosse G., Remote sensing annual dynamics of rapid permafrost thaw disturbances with LandTrendr, *Remote Sensing of Environment*, 2022, V. 268, Article 112752, DOI: 10.1016/j.rse.2021.112752.

15. Witharana C., Udawalpola M. R., Liljedahl A. K. et al., Automated detection of retrogressive thaw slumps in the high Arctic using high-resolution satellite imagery, *Remote Sensing*, 2022, V. 14, Iss. 17, Article 4132, DOI: 10.3390/rs14174132.
16. Yin G., Luo J., Niu F. et al., Machine learning-based thermokarst landslide susceptibility modeling across the permafrost region on the Qinghai-Tibet Plateau, *Landslides*, 2021, V. 18, pp. 2639–2549, DOI: 10.1007/s10346-021-01669-7.