

Точность сверточных нейронных сетей при идентификации спутниковых изображений термокарстовых полигональных образований

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

¹ Северо-Восточный федеральный университет имени М.К. Аммосова,
677000, Россия, г. Якутск, ул. Белинского, д. 58;

² Институт космических исследований и аэронавтики имени Ю.Г. Шафера СО РАН,
677027, Россия, г. Якутск, пр. Ленина, д. 31;

³ Институт мерзлотоведения им. П.И. Мельникова СО РАН,
677010, Россия, г. Якутск, ул. Мерзлотная, д. 36

Аннотация

В работе представлены результаты исследования метрик точности идентификации термокарстовых изменений ландшафта в космических изображениях при помощи технологии нейронных сетей. Темпы развития термокарстовой деградации ландшафтов в регионах распространения криолитозон, в частности, в Якутии за последние десятилетия существенно ускорились, в связи с глобальными процессами потепления климата. В работе рассмотрены вопросы подготовки обучающего набора для нейросетевых численных экспериментов. Разработан экспериментальный реестр термокарстовых объектов, содержащий большое количество спутниковых изображений термокарстовых полигональных образований. Представлены результаты исследований метрик, характеризующих точность идентификации спутниковых изображений термокарстовых образований при помощи разработанной прикладной компьютерной программы, реализующей многослойную сверточную нейронную сеть, максимальные значения которых составили 0,95-0,96 для Recall и 0,94-0,95 для Precision и F1-score. Выполнено 17 серий численных экспериментов, состоящих в среднем из 7-8 экспериментов, с целью изучения зависимости указанных метрик от моделей сверточных нейронных в результате, которых отобраны модели обеспечивающие наилучшие показатели при решении задач идентификации термокарстовых образований.

Ключевые слова: сверточные нейронные сети, машинное обучение, термокарстовые образования, спутниковые изображения, наборы обучающих данных.

Цитирование: Жебсаин, В.В. Точность сверточных нейронных сетей при идентификации спутниковых изображений термокарстовых полигональных образований / В.В. Жебсаин, А.Ю. Гололобов, А.Ф. Посельский, Н.И. Башарин // Компьютерная оптика. – 2026. – Т. 50, № 3. – 1780. – DOI: 10.18287/COJ1780.

Citation: Zhebsain VV, Gololobov AY, Poselsky AF, Basharin NI. The accuracy of convolutional neural networks in identifying satellite images of thermokarst polygonal formations. Computer Optics 2026; 50(3): 1780. DOI: 10.18287/COJ1780.

Введение

За последние 30 – 40 лет на обширных территориях Евразии и Северной Америки, относящихся к криолитозонам, наблюдается активная термокарстовая деградация ландшафтов, обусловленная глобальным потеплением климата. Начальная стадия деградации ландшафтов в данных регионах проявляется в виде характерных полигональных термокарстовых образований. Особенно типичны подобные ландшафты в Центральной Якутии, темпы формирования которых за последние десятилетия беспрецедентно ускорились и составляют в среднем 25 – 30 лет [1 – 4]. Последствия подобных процессов могут быть катастрофическими для инфраструктуры вышеуказанных регионов. Как показал обзор научно-практической литературы, вопросам и проблемам развития методов мониторинга процессов деградации ландшафтов на основе аэрокосмических данных уделяется недостаточно внимания. По применению технологии нейронных сетей для анализа термокарстовых процессов по графическим данным дистанционного зондирования Земли можно отметить несколько работ по арктическим регионам Аляски, Канады и России [5 – 7] и по горным ландшафтам Тибета [8, 9], где рассматриваются задачи сегментации провалов и оползней, а также одну работу по Центральной Якутии, где рассматривается задача сегментации термокарстовых озер [10]. В настоящее время исследования, посвященные вопросам разработки методов идентификации термокарстовых изменений, находящихся на начальной стадии, по данным аэрокосмического зондирования и с использованием машинного обучения отсутствуют. В данной работе представлены результаты численных экспериментов по идентификации при помощи технологий нейронных сетей термокарстовых образований, характерных для центральной части Якутии, на основе графических данных картографического сервиса Google.

1. Сверточные нейронные сети

Из всего комплекса различных нейросетевых технологий сверточные нейронные сети обеспечивают наибольшую точность в решении задач классификации и идентификации графических данных. В ранее опубликованной нами работе [11] было проведено сравнение эффективностей идентификации спутниковых изображений термокарстовых образований полносвязной и сверточной нейронных сетей, которое показало, что последняя демонстрирует большую точность. Для реализации сверточной нейронной сети была разработана прикладная программа на языке Python, основанная на возможностях библиотеки для машинного обучения TensorFlow [12]. В программе реализована сверточная нейронная сеть с последовательной структурой (рис. 1).




Рис. 1. Структура сверточной нейронной сети

Сеть состоит из ряда сверточных (convolution) и подвыборочных (pooling) слоев и завершающего полносвязного слоя. Модели сети состоят из различного количества сверточных слоев, на каждом из которых формируется карта признаков, а также завершающих полносвязных слоев, например:

```
Model = tf.keras.Sequential([
    tf.keras.layers.Rescaling(1. / 255),
    tf.keras.layers.Conv2D(32, 3, activation='relu', padding='same'),
    tf.keras.layers.MaxPooling2D(padding='same'),
    tf.keras.layers.Conv2D(64, 3, activation='relu', padding='same'),
    tf.keras.layers.MaxPooling2D(padding='same'),
    tf.keras.layers.Conv2D(128, 3, activation='relu', padding='same'),
    tf.keras.layers.MaxPooling2D(padding='same'),
    tf.keras.layers.Dense(128, activation='relu'),
    tf.keras.layers.Dense(num_classes)])
```

В данном примере модели сеть состоит из трех сверточных слоев, которые содержат 32, 64 и 128 фильтров соответственно. Завершает сеть один полносвязный слой, содержащий 128 узлов. Размер ядер сверточных слоев одинаковый и составляет 3×3 .

Алгоритм обучения нейронной сети в численных экспериментах основан на методе обратного распространения ошибок, для регулировки скорости обучения применяется метод оптимизации Adam, в качестве функции потерь и функции активации используются SparseCategoricalCrossentropy и RELU соответственно. Выбор гиперпараметров сети обусловлен необходимостью применения простых и малозатратных с точки зрения вычислительных ресурсов параметров. Количество эпох обучения в численных экспериментах эмпирическим методом принято равным 150. Обучение сети производилось на тренировочном и валидационном поднаборах (табл. 1), результаты обучения сохранялись во внешних файлах. Для удобства проведения численных экспериментов разработана прикладная программа, оснащённая пользовательским интерфейсом, главное окно которой представлено на рис. 2.

2. Набор экспериментальных данных для обучения сети

Как известно, точность работы нейронных сетей в немалой степени зависит от набора обучающих данных. Нами были сформированы поднаборы тренировочных, валидационных и тестовых данных, содержащие четыре класса неоднородностей ландшафта: термокарстовые образования, поля, леса и водоемы. Размеры изображений одинаковые и составляют 128×128 пкс, которые соответствуют размерам участков на поверхности земли 32×32 м. Примеры изображений представлены на рис. 3. Здесь на первом верхнем ряду (1.png – 6.png) приведены термокарстовые образования, на втором (7.png–12.png) – поля, на третьем (13.png–18.png) – леса и на четвертом (19.png–24.png) – водоемы. Тренировочный и валидационный поднаборы данных применялись для обучения сети. Для численных экспериментов использовался тестовый поднабор данных.

Количество изображений по классам неоднородностей ландшафта экспериментального набора представлено в табл. 1.

Для систематизации значительного количества спутниковых изображений был разработан реестр термокарстовых объектов, реализованный в виде базы данных MS SQL Server. Для ведения данного реестра была разработана прикладная программа, вид главного окна которой приведен на рис. 4.




Рис. 2. Главное окно пользовательского интерфейса программы




Рис. 3. Примеры изображений различных классов ландшафта

Табл. 1. Количество изображений по видам классов ландшафта

№	Наборы/классы	Термокарстовые образования	Поля	Леса	Водоемы
1	Тренировочный поднабор	1746	2004	1305	1770
2	Валидационный поднабор	470	506	360	360
3	Тестовый поднабор	308	704	151	360




Рис. 4. Главное окно прикладной программы управления реестром термокарстовых объектов

Сформированный реестр термокарстовых объектов позволил подготовить верифицированный обучающий набор изображений для проведения численных экспериментов.

3. Результаты численных экспериментов

В проведенных численных экспериментах метрики точности определялись следующим образом:

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

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

$$F1 - score = 2 \times \left(\frac{Recall \times Precision}{Recall + Precision} \right),$$

где

TP – истинно положительные результаты;

FP – ложно положительные результаты;

FN – ложно отрицательные результаты.

Проведенные на тестовом поднаборе данных (табл. 1) численные эксперименты показали, что метрики точности нейронных сетей зависят от конкретной архитектуры (модели) сети. С целью подбора наиболее эффективных с точки зрения точности моделей сети нами были проведены численные эксперименты. В табл. 2 представлены исследованные серии моделей, в обозначениях в формате $N \times Mс$, где N – обозначает количество слоев, M – фильтров, $с$ – признак сверточного слоя. Например, $2 \times 64с, N \times 32с, 256$ обозначает сеть, состоящую из 2 сверточных слоев с 64 фильтрами, N сверточных слоев с 32 фильтрами и одного полносвязного слоя из 256 узлов (нейронов).

Табл. 2. Список серий моделей

№	Серия моделей сети	Кол-во слоев
1	128с, 64с, 32с, 128	4
2	128с, 64с, 32с, 256	4
3	$N \times 128с, 256$	4-6
4	$N \times 128с, 256с, 256$	4-7
5	$N \times 32с, 256$	5-7
6	$N \times 64с, 2 \times 32с, 256$	7-8
7	$2 \times 64с, N \times 32с, 64$	7-8
8	$N \times 32с, 128$	5-8
9	$N \times 64с, 128$	5-8
10	$N \times 32с, N \times 64с, 128$	5-8
11	$64с, N \times 32с, 128, 128$	5-8
12	$2 \times 64с, N \times 32с, 256, 128$	5-8
13	$2 \times 64с, N \times 32с, 2 \times 256, 128$	5-8
14	$2 \times 64с, N \times 32с, 512, 256, 128$	5-8
15	$2 \times 32с, N \times 64с, 128$	5-18
16	$2 \times 64с, N \times 32с, 128$	5-18
17	$2 \times 32с, 2 \times 64с, N \times 128с, 128$	5-17

Из представленных в табл. 2 серий нами отобраны 3 наиболее эффективные:

- серия $2 \times 32с, N \times 64с, 128$;
- серия $2 \times 64с, N \times 32с, 128$;
- серия $2 \times 32с, 2 \times 64с, N \times 128с, 128$.

Зависимость метрик точности идентификации термокарстовых образований тестового поднабора от количества слоев (L) серии моделей $2 \times 32с, N \times 64с, 128$ приведена на рис. 5.




Рис. 5. Зависимость метрик Recall, Precision, F1-score от количества слоев серии моделей $2 \times 32с, N \times 64с, 128$

Как видно из рис. 5, максимальные показатели по метрике Recall, варьирующиеся в пределах 0,95–0,96 для тестового поднабора данной серии, наблюдаются для моделей, состоящих из 10–12 слоев ($2 \times 32c, (7-9) \times 64c, 128$). По метрикам Precision и F1-score максимальные показатели, составляющие около 0,94–0,95, приходятся на L в интервале значений 6–7. Аналогичная зависимость для серии моделей $2 \times 64c, N \times 32, 128$ представлена на рис. 6.




Рис. 6. Зависимость метрик Recall, Precision, F1-score от количества слоев серии моделей $2 \times 64c, N \times 32, 128$

Из рис. 6 видно, что для серии $2 \times 64c, N \times 32c, 128$ наибольшее значение по метрике Recall, составляющее в среднем около 0,95, демонстрируют модели с 14 и 15 слоями, тогда как по метрикам Precision и F1-score наблюдаются два максимума при L, равном 11 и в интервале 17–18. Зависимость метрик точности идентификации термокарстовых образований тестового поднабора от количества слоев для серии моделей $2 \times 32c, 2 \times 64c, N \times 128c, 128$ представлена на рис. 7.




Рис. 7. Зависимость метрик Recall, Precision, F1-score от количества слоев серии моделей $2 \times 32c, 2 \times 64c, N \times 128c, 128$

Из рис. 7 видно, что для серии $2 \times 32c, 2 \times 64c, N \times 128, 128$ максимальный показатель по метрике Recall составляет в среднем около 0,96 и наблюдается при количестве слоев, равном 13, т.е. для модели $2 \times 32c, 2 \times 64c, 8 \times 128c, 128$. По метрикам Precision и F1-score наибольшую точность демонстрирует модель, состоящая из 6 и 11 слоев соответственно.

Как показал анализ матриц ошибок, в численных экспериментах наибольшие ошибки наблюдаются при дифференциации изображений термокарстовых образований и полей. На рис. 8 и рис. 9 представлены матрицы ошибок (confusion matrix) моделей $2 \times 32c, 3 \times 64c, 128$ и $2 \times 32c, 2 \times 64c, 6 \times 128c, 128$ соответственно. На данных рисунках отчетливо видна «путаница» при идентификации термокарстовых образований и полей, что отражает реальную географию распространения термокарстовых образований. Поля в большей степени подвержены

нарушению температурного режима, чем леса, поскольку растения создают защиту от протаивания мерзлых пород и по данной причине термокарстовая деградация наблюдается в основном на фоне полей.




Рис. 8. Матрица ошибок для модели $2 \times 32c, 3 \times 64c, 128$




Рис. 9. Матрица ошибок для модели $2 \times 32c, 2 \times 64c, 6 \times 128c, 128$

Заключение

Сверточная нейронная сеть позволяет с высоким уровнем значений метрик, характеризующих точность, решать задачи идентификации спутниковых изображений термокарстовых образований ландшафтов центральной Якутии. В результате анализа предварительных численных экспериментов подобраны три серии ($2 \times 32c, N \times 64c, 128$; $2 \times 64c, N \times 32, 128$; $2 \times 32c, 2 \times 64c, N \times 128c, 128$) моделей многослойных сверточных сетей, демонстрирующих достаточно качественные показатели по метрикам Recall, Precision, F1-score при идентификации термокарстовых образований тестового поднабора. Для первой серии по метрике Recall максимальные значения, составляющие 0,95-0,96, наблюдаются для моделей $2 \times 32c$, $(7-9) \times 64c, 128$ (10 – 12 слоев). Для этой же серии по метрикам Precision и F1-score максимальные значения, составляющие около 0,94-0,95, приходится на модели $2 \times 32c$, $(3-4) \times 64c, 128$ (6 – 7 слоев). Для второй серии моделей максимальные показатели по метрике Recall (около 0,95) демонстрируют модели с 14 и 15 слоями, тогда как по метрикам Precision и F1-score наблюдаются два максимума, также составляющие около 0,95, при количестве слоев, равном 11 и в интервале 17 – 18. Для третьей серии моделей $2 \times 32c, 2 \times 64c, N \times 128, 128$ максимальные показатели метрик Recall, Precision и F1-score наблюдаются при разных моделях. Так, максимальное значение Recall (0,96), Precision (0,94) и F1-score (0,943) наблюдаются при 13-, 6- и 11-слойных моделях соответственно. Также в численных экспериментах наибольшие ошибки наблюдаются при дифференциации изображений термокарстовых образований и полей, что отражает реальную географию распространения термокарстовых образований. Представленный в работе метод идентификации спутниковых изображений термокарстовых образований, находящихся на ранней стадии развития, а также разработанное прикладное программное обеспечение могут применяться для автоматизированного мониторинга за состоянием ландшафтов не только для условий Центральной Якутии, но и других регионов распространения криолитозон при условии верификации и подготовки соответствующих обучающих наборов данных.

Благодарности

Проведенные в работе исследования выполнены при поддержке Российского научного фонда за счет гранта № 24-21-20043.

References

- [1] Fedorov AN, Konstantinov PY. Observations of surface dynamics with thermokarst initiation. In: Proceedings of the Eighth International Conference on Permafrost; 2003. pp. 239-243.
- [2] Fedorov AN, Konstantinov PY. Observations of surface dynamics with thermokarst initiation. In: Proceedings of the Ninth International Conference on Permafrost; 2008. pp. 433-438.
- [3] Konstantinov P, Basharin N, Fedorov A, Iijima Y, Andreeva V, Semenov V, Vasiliev N. Impact of climate change on the ground thermal regime in the lower Lena region, Arctic Central Siberia. Land 2023; 12(1): 19. doi:10.3390/land12010019.
- [4] Konstantinov P, Zhelezniak M, Basharin N, Misailov I, Andreeva V. Establishing permafrost thermal monitoring sites in East Siberia. Land 2020; 9(12): 496. doi:10.3390/land9120496.
- [5] Witharana C, Udawalpola M, Liljedahl A, Jones M, Jones B, Hasan A, Joshi D, Manos E. Automated detection of retrogressive thaw slumps in the High Arctic using high-resolution satellite imagery. Remote Sens 2022; 14(17): 4132. doi:10.3390/rs14174132.
- [6] Runge A, Nitze I, Grosse G. Remote sensing annual dynamics of rapid permafrost thaw disturbances with LandTrendr. Remote Sens Environ 2022; 268: 112752. doi:10.1016/j.rse.2021.112752.
- [7] Nitze I, Heidler K, Barth S, Grosse G. Developing and testing a deep learning approach for mapping retrogressive thaw slumps. Remote Sens 2021; 13(21): 4294. doi:10.3390/rs13214294.
- [8] Huang L, Liu L, Luo J, Lin Z, Niu F. Automatically quantifying evolution of retrogressive thaw slumps in Beiluhe (Tibetan Plateau) from multi-temporal CubeSat images. Int J Appl Earth Obs Geoinf 2021; 102: 102399. doi:10.1016/j.jag.2021.102399.
- [9] Yin G, Luo J, Niu F, Lin Z, Liu M. Machine learning-based thermokarst landslide susceptibility modeling across the permafrost region on the Qinghai-Tibet Plateau. Landslides 2021; 18(12): 3939-3955. doi:10.1007/s10346-021-01669-7.
- [10] Lara HA, Bouchard F, Saint-Jean G, Farid G, Laurent E. Automated identification of thermokarst lakes using machine learning in the ice-rich permafrost landscape of central Yakutia (Eastern Siberia). Remote Sens 2023; 15(5): 1226. doi:10.3390/rs15051226.
- [11] Zhebsain VV, Gololobov AYU, Basharin NI, Poselsky AF. Features of the application of neural network technology for the recognition of graphic images of thermokarst objects [in Russian]. Geoinformatika 2024; 4: 39-47.
- [12] Bagaeva II. Analysis of the concepts of neural network and convolutional neural network. Training a convolutional neural network using the TensorFlow module [in Russian]. Matematicheskoe Modelirovanie i Programmnoe Obespechenie Sistem v Promyshlennoy i Sotsialnoy Sferakh 2020; 8(1): 15-22. doi:10.18503/2306-2053-2020-8-1-15-22.

Сведения об авторах

Жебсанин Василий Васильевич, 1959 года рождения, в 1989 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук по специальности 01.04.03 «Радиофизика, включая квантовую радиофизику». В настоящий момент работает в должности заведующего кафедрой радиофизики и электронных систем Физико-технического института Северо-Восточного федерального университета им. М.К. Аммосова. Сфера научных интересов: идентификация графических образов, нейронные сети, машинное обучение, базы данных, разработка прикладного программного обеспечения. E-mail: zhebs@mail.ru

Гололобов Артем Юрьевич, 1987 года рождения, в 2018 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук по специальности 05.13.18 «Математическое моделирование, численные методы и комплексы программ». В настоящее время работает старшим научным сотрудником в лаборатории магнитосферно-ионосферных исследований Института космических исследований им. Ю.Г. Шафера СО РАН. Сфера научных интересов: математическое моделирование, численные методы, машинное обучение, комплексы программ, физика ионосферы и магнитосферы, солнечно-земные связи. E-mail: golart87@gmail.com

Посельский Айаал Федорович, 1997 года рождения, в 2021 году окончил МГТУ им. Н.Э. Баумана по специальности 11.05.01 «Радиоэлектронные системы и комплексы». Аспирант и по совместительству ассистент кафедры радиофизики и электронных систем Физико-технического института Северо-Восточного федерального университета им. М.К. Аммосова. Области научных интересов: машинное обучение. E-mail: al.poselsky@gmail.com

Башарин Николай Ильич, 1989 года рождения, выпускник Северо-Восточного федерального университета им. М.К. Аммосова. Работает младшим научным сотрудником в институте мерзлотоведения им. П.И. Мельникова СО РАН. Область научных интересов: термокарсты, мерзлотные ландшафты, ГИС, картография. E-mail: Nikolay_B89@mail.ru

Поступила в редакцию 19 июля 2025 г. Окончательный вариант – 24 сентября 2025 г.

The accuracy of convolutional neural networks in identifying satellite images of thermokarst polygonal formations

V.V. Zhebsain ¹, A.Y. Gololobov ², A.F. Poselsky ¹, N.I. Basharin ³

¹North-Eastern Federal University, Belinskogo Str. 59, Yakutsk, 677000, Russia;

²Yu. G. Shafer Institute of Cosmophysical Research and Aeronomy of Siberian Branch of Russian Academy of Sciences, Prospekt Lenina 31, Yakutsk, 677000, Russia;

³Melnikov Permafrost Institute of the Siberian Branch of the Russian Academy of Sciences, Merzlotnaya Str. 36, Yakutsk, 677000, Russia

Abstract

The paper presents the results of a study of the accuracy metrics for identifying thermokarst landscape changes in space images using neural network technology. The rate of thermokarst degradation of landscapes in regions with permafrost, particularly in Yakutia, has significantly accelerated in recent decades due to global climate warming. The paper discusses the preparation of a training set for neural network numerical experiments. An experimental registry of thermokarst objects has been developed, containing a large number of satellite images of thermokarst polygonal formations. The results of studies of metrics characterizing the accuracy of identification of satellite images of thermokarst formations using a developed applied computer program implementing a multilayer convolutional neural network, the maximum values of which were 0.95-0.96 for Recall and 0.94-0.95 for Precision and F1-score, are presented. 17 series of numerical experiments were performed, consisting of an average of 7-8 experiments, in order to study the dependence of these metrics on convolutional neural models, as a result of which models were selected that provide the best performance in solving problems of identifying thermokarst formations.

Keywords: convolutional neural networks, machine learning, thermokarst formations, satellite images, training datasets.

Citation: Zhebsain VV, Gololobov AY, Poselsky AF, Basharin NI. The accuracy of convolutional neural networks in identifying satellite images of thermokarst polygonal formations. *Computer Optics* 2026; 50(3): 1780. DOI: 10.18287/COJ1780.

Acknowledgements: This work was financially supported by the Russian Science Foundation under project No. 24-21-20043.

Author's information

Vasiliy Vasilyevich Zhebsain (b. 1959), defended his dissertation in 1989 for the degree of Candidate of Physical and Mathematical Sciences in specialty 01.04.03 "Radiophysics, including quantum radiophysics". At present he works as the head of Radiophysics and Electronic Systems Department of the Physics and Technology Institute of the North-Eastern Federal University named after M.K. Ammosov. The area of interests includes identification of graphic images, neural networks, machine learning, databases, development of application software. E-mail: zhebs@mail.ru

Artem Yuryevich Gololobov (b. 1987), defended his dissertation in 2018 for the degree of Candidate of Physical and Mathematical sciences in specialty 05.13.18 "Mathematical modeling, numerical methods and software packages". At present he works as a senior researcher in the laboratory of magnetospheric and ionospheric research at the Yu.G. Shafer Institute of Cosmophysical Research SB RAS. The area of interests includes: mathematical modeling, numerical methods, machine learning, software packages, physics of the ionosphere and magnetosphere, solar-terrestrial relations. E-mail: golart87@gmail.com

Ayal Fedorovich Poselsky (b. 1997), graduated from Bauman Moscow State Technical University in 2021, specializing in 11.05.01 "Radioelectronic systems and complexes". Postgraduate student and part-time assistant of Radiophysics and Electronic Systems Department at the Physics and Technology Institute of the North-Eastern Federal University named after M.K. Ammosov. Research interests: machine learning. E-mail: al.poselsky@gmail.com

Nikolay Ilyich Basharin (b. 1989), graduated from the North-Eastern Federal University named after M.K. Ammosov. Works as a junior researcher at the Melnikov Permafrost Institute of the Siberian Branch of the Russian Academy of Sciences. Research interests: thermokarsts, permafrost landscapes, GIS, cartography. E-mail: Nikolay_B89@mail.ru

Received July 19, 2025. The final version – September 24, 2025.
