

Геоинформатика. 2024. № 4. С. 39–47.
Geoinformatika. 2024;(4):39–47.

Моделирование геообъектов и геопроцессов

Научная статья
 УДК 528.854.2
<https://doi.org/10.47148/1609-364X-2024-4-39-47>

Особенности применения технологии нейронных сетей для распознавания графических образов термокарстовых объектов

© 2024 г. — Василий Васильевич Жебсаин^{1, а)}, Артем Юрьевич Гололобов^{2, б)}, Николай Ильич Башарин^{3, в)}, Айаал Федорович Посельский^{1, д)}

¹ФГАОУ ВО «Северо-Восточный федеральный университет им. М.К. Аммосова»; Якутск, Россия

²Институт космофизических исследований и аэронауки им. Ю.Г. Шафера СО РАН; Якутск, Россия

³Институт мерзлотоведения им. П.И. Мельникова СО РАН; Якутск, Россия

^{а)}zhebs@mail.ru, ^{б)}gololobov@ikfia.ysn.ru, ^{в)}nikolay_b89@mail.ru, ^{д)}al.poselsky@gmail.com

Аннотация: В статье представлены результаты применения нейронных сетей для решения задачи идентификации термокарстовых образований, наблюдающихся в регионах распространения многолетней мерзлоты, в частности, в Центральной Якутии, по графическим данным беспилотных летательных аппаратов и картографических сервисов Google и Яндекс. Используются два различных подхода для решения рассматриваемой задачи на основе применения многослойной и сверточной нейронных сетей. Изучены зависимости эффективности и ошибок нейронных сетей от скорости и количества эпох обучения. Проведено сравнение результатов рассматриваемых подходов и оценена возможность применения нейросетевых технологий для идентификации термокарстовых полигональных образований, характерных для Центральной Якутии.

Ключевые слова: *нейронные сети; термокарстовые образования; моделирование; спутниковые данные; аэрофотосъемка.*

Для цитирования: 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. <https://doi.org/10.47148/1609-364X-2024-4-39-47>.

Modeling of geological objects and geoprocesses

Original article

Features of the use of neural network technology for recognizing graphic images of thermokarst objects

© 2024 — Vasily V. Zhebsain^{1, а)}, Artem Yu. Gololobov^{2, б)}, Nikolay I. Basharin^{3, в)}, Ayal F. Poselsky^{1, д)}

¹North-Eastern Federal University; Yakutsk, Russia

²Yu.G. Shafer Institute of Cosmophysical Research and Aeronomy of Siberian Branch of the Russian Academy of Sciences, Yakut Scientific Centre of Siberian Branch of the Russian Academy of Sciences; Yakutsk, Russia

³Melnikov Permafrost Institute of Siberian Branch of the Russian Academy of Sciences; Yakutsk, Russia

^{а)}zhebs@mail.ru, ^{б)}gololobov@ikfia.ysn.ru, ^{в)}nikolay_b89@mail.ru, ^{д)}al.poselsky@gmail.com

Abstract: The article presents the results of using neural networks to solve the problem of identifying thermokarst formations observed in regions of permafrost, in particular Central Yakutia, using graphical data from UAVs and Google and Yandex mapping services. Two different approaches were used to solve the problem under consideration, based on the use of multilayer and convolutional neural networks. The dependences of the efficiency and errors of neural networks on the speed and number of learning epochs are studied. The results of the approaches under consideration were compared and the possibility of using neural network technologies to identify thermokarst polygonal formations characteristic of Central Yakutia was assessed.

Key words: *neural network; thermokarst; modelling; satellite data; aerospace sensing.*

For citation: Zhebsain V.V., Gololobov A.Yu., Basharin N.I., Poselsky A.F. Features of the use of neural network technology for recognizing graphic images of thermokarst objects. *Geoinformatika*. 2024;(4):39–47. <https://doi.org/10.47148/1609-364X-2024-4-39-47>. In Russ.

Введение

Значительная часть территории России относится к регионам распространения криолитозоны, где в последние десятилетия наблюдаются активные термокарстовые процессы, обусловленные глобальным потеплением климата. На начальной стадии термокарстовые процессы верхнего слоя

вечной мерзлоты проявляются в виде полигональных образований (рис. 1), особенно характерны данные объекты для Центральной Якутии [1]. Похожие образования наблюдаются не только в Якутии, но и в других северных регионах России (Таймыр, Ямал и др.), а также в Северной Америке. Последствия термокарстовых процессов могут быть ка-

тастрофическими для инфраструктуры указанных регионов.

С учетом труднодоступности и обширности северных регионов одним из перспективных методов исследования и наблюдения термокарстовых процессов является метод дистанционного зондирования Земли (ДЗЗ) на основе интерпретации спутниковых данных и данных аэрофотосъемки. Как показал обзор научно-практической литературы и интернет-источников, работ, рассматривающих метод ДЗЗ как инструмент для мониторинга процессов деградации верхнего слоя с образованием вышеприведенных термокарстовых образований, не так много. Можно выделить работы [2, 3], посвященные исследованию термокарстовых проявлений в регионах Севера, в том числе в Центральной Якутии, при помощи космических данных и аэрофотоснимков. Проблемам и вопросам разработки

методов автоматизации процесса идентификации термокарстовых явлений на основе аэрокосмических данных в настоящее время не уделяется должного внимания. Между тем разработка автоматизированных методов идентификации термокарстовых объектов по аэрокосмическим данным, на основе современных технологий, в частности нейронных сетей, позволила бы существенно повысить эффективность исследований в данной области. С учетом изложенного, в данной статье представлены практические примеры использования нейронных сетей для решения задачи идентификации термокарстовых образований, характерных для северных регионов России, в частности, Центральной Якутии, по графическим данным картографических сервисов Google (рис. 2), Яндекс и аэрофотоснимков, полученных с использованием беспилотных летательных аппаратов (БПЛА) (рис. 3).

Рис. 1. Полигональные термокарстовые образования в Центральной Якутии [1]

Fig. 1. Polygonal thermokarst formations of Central Yakutia [1]



Рис. 2. Термокарстовые образования в Чурапчинском районе Якутии на фотоснимках картографического сервиса Google

Fig. 2. Thermokarst formations in the Churapchinsky region of Yakutia on photographs from the Google mapping service



Рис. 3. Термокарстовые образования в окрестностях Якутска по данным аэрофотосъемки БПЛА
 Fig. 3. Thermokarst formations in the vicinity of Yakutsk according to UAV aerial photography data



Многослойная нейронная сеть с обратным распространением ошибок

Для реализации нейронной сети данного вида была разработана прикладная компьютерная программа при помощи среды PyCharm (Python). В программе реализована нейронная сеть с тремя слоями: входной, скрытый и выходной. Количество нейронов скрытого слоя переменное. На входной слой сети подается матрица I_i цифровых кодов графического образа. Количество элементов данной матрицы определяется размером графического образа, в частности, для изображения 70×70 пикселей входная матрица содержит 4900 нейронов. Данная матрица умножается на матрицу весовых коэффициентов W_{i+1} , значения элементов которого формируются генератором случайных чисел:

$$X_{i+1} = W_{i+1} \cdot I_i, \tag{1}$$

где I_i — входная матрица сети; W_{i+1} — матрица весовых коэффициентов; X_{i+1} — входная матрица скрытого слоя.

Таким образом, на скрытый слой подается матрица X_{i+1} . В качестве функции активации применяется сигмоида. В результате получаем выходной сигнал первого скрытого слоя в виде

$$O_j = \frac{1}{1 + e^{-X_{i+1}}}. \tag{2}$$

В случае трехслойной сети, выходной сигнал скрытого слоя подается на выходной слой сети. Таким образом, выходной сигнал сети определяется как

$$O_k = W_{jk} \cdot O_j, \tag{3}$$

где O_k — матрица сигналов k -го слоя (выходного); O_j — матрица сигналов предыдущего j -го слоя (скрытого); W_{jk} — матрица весовых коэффициентов между слоями j и k .

В случае сети со множеством скрытых слоев, матрица выходного слоя выполняет роль следующего скрытого слоя. Алгоритм обучения и расчета

нейронной сети основан на методе обратного распространения ошибок и корректировки весовых коэффициентов. В процессе обучения сети производится минимизация функции ошибки E_k при помощи коррекции весовых коэффициентов [4]:

$$W_{jk} = W_{jk} - \alpha \cdot \frac{\partial E_k}{\partial W_{jk}}, \tag{4}$$

где α — коэффициент обучения; $\frac{\partial E_k}{\partial W_{jk}}$ — градиент функции ошибки.

Здесь $\Delta W_{jk} = \alpha \cdot \frac{\partial E_k}{\partial W_{jk}}$ — матрица коррекции весовых коэффициентов, которая определяется при помощи выражения

$$\Delta W_{jk} = \alpha \cdot E_k \cdot O_k \cdot (1 - O_k) \cdot O_j^T, \tag{5}$$

где $E_k = (t_k - O_k)^2$ — матрица функции ошибки; t_k — целевые (правильные) значения узлов выходного слоя сети; O_k — матрица сигналов k -го слоя; O_j^T — транспонированная матрица сигналов j -го (предыдущего) слоя.

Идентификация термокарстовых объектов программой проводилась на основе метода обучения нейронной сети с использованием тренировочных данных. Для этого были подготовлены наборы оцифрованных графических образов по данным картографического сервиса Google, а также аэрофотосъемок с использованием БПЛА. Обучающий и тестовый наборы данных состояли из предварительно обработанных и оцифрованных фотоснимков в цветовой палитре оттенков серого. Наборы оцифрованных данных содержали 480–2200 и 120–1000 графических образов для тестовых и тренировочных наборов соответственно. Основным критерием качества работы сети служила эффективность, определенная как доля правильных случаев распознавания (идентификации) графических образов от общего их количества, выраженная в процентах. Изучение зависимости эффективности при идентификации данных тестового набора от скорости обучения показало, что максимальная

эффективность наблюдается при скорости обучения в интервале значений 0,003–0,004 для спутниковых данных и 0,0004 для данных БПЛА. Зависимость эффективности сети от скорости обучения для данных БПЛА и спутниковых данных Google приведена на рис. 4. В целом эффективность обученной сети при обработке спутниковых данных Google достигает около 92 %, тогда как при обработке данных БПЛА она составила около 81 %. Данная разница значений эффективности, вероятно, обусловлена географическим различием идентифицируемых данных. Фотоснимки БПЛА относятся к окрестностям Якутска (см. рис. 3), где термокарстовые процессы выражены слабо, тогда как спутниковые данные относятся к Чурапчинскому улусу (см. рис. 2), где термокарстовые процессы выражены в большей степени.

На рис. 5 представлена зависимость эффективности обучения от количества эпох при обработке данных Google. Видно, что максимальные значения эффективности наблюдаются при количестве эпох в диапазоне 19–20, достигая 90–92 %. Дальнейшее увеличение количества эпох не приводит к повышению эффективности, и далее происходит ее постепенное снижение (рис. 5).

**Сверточная нейронная сеть.
Сравнение характеристик сетей**

Как известно, сверточные нейронные сети считаются одними из наиболее эффективных сетей в области классификации графических данных. С учетом изложенного, представляет интерес вопрос применения сверточной нейронной сети в решении рассматриваемой задачи. Для реализации сверточной нейронной сети была разработана программа на языке Python на основе применения библиотеки Tensorflow [5]. Модель сети состоит из трех сверточных слоев, на каждом из которых формируется карта признаков. Для оценки ошибки в качестве функции потерь применена функция кросс-энтропии [5]. Для проведения численного эксперимента был сформирован набор из 600 изображений 70×70 пикселей по данным картографического сервиса Google, соответствующих размерам местности 28×28 м. Из них 480 (80 %) изображений определены для тренировочного (training) набора, а остальные 120 (20 %) — для тестового (validation). Обучающий набор, как и для многослойной нейронной сети, состоит из двух классов — карст (carst) и ландшафт (landshaft)). На рис. 6 приведены примеры тренировочных изображений.

Рис. 4. Зависимость эффективности сети от скорости обучения для данных БПЛА и картографического сервиса Google

Fig. 4. Dependence of network efficiency on learning speed for UAV data and Google mapping service




Рис. 5. Зависимость эффективности от количества эпох при обработке набора Google

Fig. 5. Dependence of efficiency on the number of epochs when processing a Google set



Рис. 6. Примеры тренировочных изображений с указанием классов carst (содержащие термокарстовые образования) и landshaft (не содержащие термокарстовые образования)

Fig. 6. Examples of training images indicating the classes carst (containing thermokarst formations) and landshaft (not containing thermokarst formations)


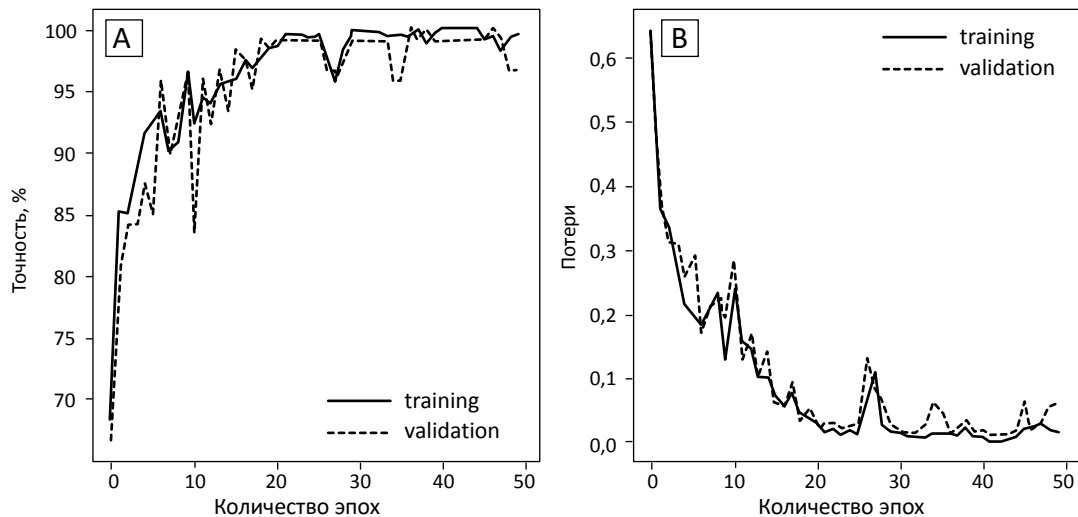


Рис. 7. Зависимости точности (A) и потерь (B) сверточной нейронной сети при обработке тренировочного (training) и тестового (validation) наборов от количества эпох обучения

Fig. 7. Dependences of accuracy (A) and losses (B) of a convolutional neural network when processing training and validation sets on the number of training epochs



Критерием качества работы сети служит точность сверточной сети, определенная как доля правильных ответов от общего количества изображений в наборе данных, выраженная в процентах. На рис. 7А представлена зависимость точности сети при обработке тренировочного (training) и тестового (validation) наборов от количества эпох обучения в Чурапчинском районе в Центральной Якутии. Как видно на рисунке, максимальная точность сети при обработке тренировочных (training) выборок данных может достигать ~99-100 и ~97-98 % для тестовых данных в диапазоне 20–40 эпох обучения. Зависимость потерь (loss) сети, определенных как сумма ошибок для каждого примера в наборе, от количества эпох при различных наборах представлена на рис. 7В. Между кривыми потерь тренировочного и тестового наборов присутствует очевидная корреляция, и минимальные потери наблюдаются уже при количестве эпох в районе 21–25, как для тренировочного (training), так и для тестового (validation) наборов.

Аналогичные зависимости для многослойной сети с обратным распространением ошибок приведены на рис. 8. Район расположения термокарстовых образований тот же, что и на рис. 7 (Чурапчинский). Как видно на рис. 8, максимальная точность сети при обработке тренировочных выборок данных достигает ~95 % в диапазоне значений количества эпох обучения 45–50 и ~91 % для тестовых выборок данных в диапазоне 8–20 эпох. Анализ и сравнение рис. 7 и 8 показывают, что точность сверточной сети выше, чем соответствующая характеристика многослойной сети с обратным распространением ошибок. При этом результаты сверточной сети менее устойчивы, чем у многослойной сети. Так, при обработке тестового набора у сверточной сети разброс значений точности меняется в

пределах от 80 % до 98 %, тогда как у многослойной сети с обратным распространением ошибок соответствующий диапазон значений незначителен и составляет ~88–91 %. Отметим, что максимальных значений точности для тестового набора многослойная сеть достигает при меньшем значении количества эпох обучения (8–20).

Результат практического применения обученной сверточной нейронной сети на карте местности около с. Чурапча (~1 × 1 км), полученный по данным картографического сервиса Яндекс, представлен на рис. 9. Выбор картографического сервиса Яндекс вместо Google сделан намеренно, чтобы протестировать, насколько хорошо сверточная нейронная сеть выделила признаки карстов. Как можно видеть, сверточная нейронная сеть корректно распознала большую часть термокарстовых образований на данном графическом фрагменте.

Заключение

По результатам проведенных исследований можно заключить, что точность нейронной сети при решении задачи идентификации графических образов термокарстовых образований по данным картографических сервисов Google и Яндекс может достигать 97-98 % при применении сверточной нейронной сети и 91-92 % для многослойной сети с обратным распространением ошибок. При этом многослойная нейронная сеть с обратным распространением ошибок обучается быстрее (за 8–20 эпох) и показывает более устойчивый результат. Скорость обучения оказывает существенное влияние на эффективность многослойной сети с обратным распространением ошибок. В частности, получено, что при скорости обучения сети в диапазоне 0,003-0,004 наблюдаются максимальные значения эффективности, достигающие 90–92 %.

Рис. 8. Зависимости точности (А) и потерь (В) многослойной нейронной сети при обработке тренировочного (training) и тестового (validation) наборов от количества эпох обучения

Fig. 8. Dependences of accuracy (A) and losses (B) of a multilayer neural network when processing training and validation sets on the number of training epochs

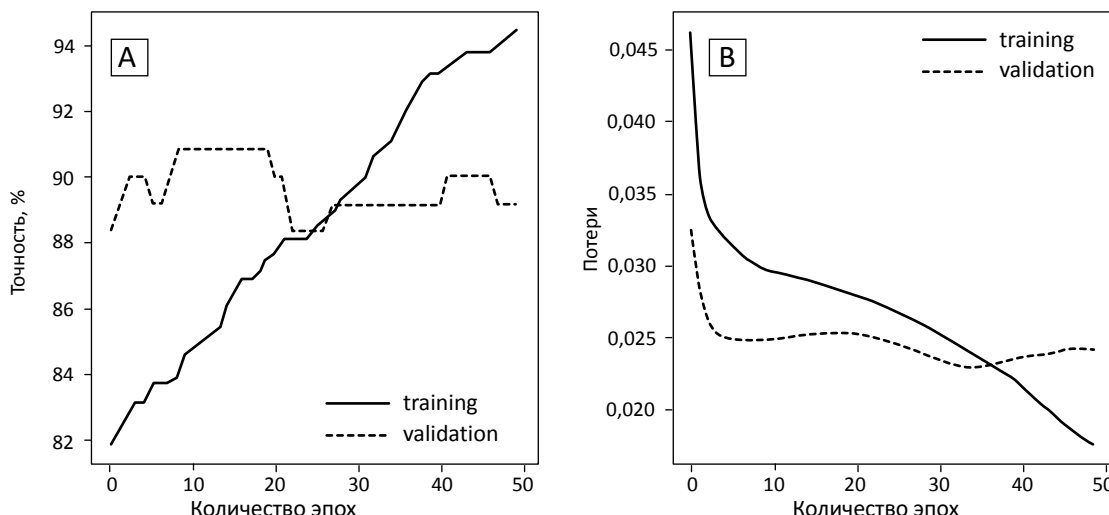



Рис. 9. Пример применения обученной сверточной нейронной сети на карте местности около с. Чурапча (1225 изображений)
Fig. 9. An example of using a trained convolutional neural network on an area map near the village Churapcha (1225 images)



Красными квадратами обозначены участки, где определены признаки карстовых процессов
Red squares indicate areas where signs of karst processes have been identified

Применение данных БПЛА наряду с космическими обосновывает достоверность метода, поскольку не всякие «выпуклости» ландшафта могут иметь термокарстовое происхождение. Отметим, что метод дешифровки термокарстовых образований на основе фотосъемок БПЛА без применения нейронных сетей разработан и успешно применяется [3]. В этом заключается особенность обучения нейронных сетей в решении данной конкретной задачи. Кроме того, обучение сетей и тестовые испытания возможны исключительно по результатам БПЛА

без применения космических данных. В данном направлении требуются дальнейшие исследования.

В целом результаты исследования показали перспективность применения нейронных сетей для решения задач идентификации (распознавания) графических образов термокарстовых образований в интересах развития автоматизированных средств дистанционного мониторинга термокарстовых процессов, происходящих в частности, в Центральной Якутии.

Исследование выполнено за счет гранта Российского научного фонда № 24-21-20043.

Список источников

1. Сальва А.М. Отслеживание участков термокарстовых проявлений по космическим снимкам (на примере трассы магистрального водовода в центральной Якутии) // Арктика и Антарктика. – 2020. – № 2. – С. 126–137. DOI: 10.7256/2453-8922.2020.2.32860.
2. Konstantinov P., Zhelezniak M., Basharin N., Misailov I., Andreeva V. Establishing of Permafrost Thermal Monitoring Sites in East Siberia // Land. – 2020. – Vol. 9. – No. 12. – P. 1–10. DOI: 10.3390/land9120476.
3. Башарин Н.И., Егорова Л.С., Васильев Н.Ф., Федоров Н.А., Федоров А.Н. Применение беспилотных летательных аппаратов для оценки активизации термокарста // Вестник СВФУ. Серия: Науки о Земле. – 2020. – № 3 (19). – С. 36–44. DOI: 10.25587/SVFU.2020.19.3.005.
4. Рашид Т. Создаем нейронную сеть. — М.: Диалектика, 2017. — 272 с.
5. Багаев И.И. Анализ понятий нейронная сеть и сверточная нейронная сеть, обучение сверточной нейросети при помощи модуля TensorFlow // Математическое и программное обеспечение систем в промышленной и социальной сферах. – 2020. – Т. 8. – № 1. – С. 15–22. DOI: 10.18503/2306-2053-2020-8-1-15-22.

References

1. Sal'va A.M. Tracking of areas of thermokarst occurrences from satellite images (on the example of the main water pipeline route in central Yakutia). *Arctic and Antarctica*. 2020;(2):126–137. DOI: 10.7256/2453-8922.2020.2.32860.
2. Konstantinov P., Zhelezniak M., Basharin N., Misailov I., Andreeva V. Establishing of Permafrost Thermal Monitoring Sites in East Siberia. *Land*. 2020;9(12):1–10. DOI: 10.3390/land9120476.
3. Basharin N.I., Egorova L.S., Vasilev N.F., Fedorov N.A., Fedorov A.N. Using unmanned aerial vehicles for thermokarst activity assessment. *Vestnik of North-Eastern Federal University. Earth sciences*. 2020;(3):36–44. DOI: 10.25587/SVFU.2020.19.3.005.
4. Rashid T. Make Your Own Neural Network. Scotts Valley: CreateSpace, 2016. 222 p.
5. 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;8(1):15–22. DOI: 10.18503/2306-2053-2020-8-1-15-22.

Статья поступила в редакцию 10.06.2024 г., одобрена после рецензирования 25.06.2024 г., принята к публикации 01.08.2024 г.
The article was submitted 10.06.2024; approved after reviewing 25.06.2024; accepted for publication 01.08.2024.

Информация об авторах

Жебсаин Василий Васильевич

Кандидат физико-математических наук,
заведующий кафедрой
Северо-Восточный федеральный университет
им. М.К. Аммосова
677013 Якутск, ул. Кулаковского, д. 48
e-mail: zhebs@mail.ru
ORCID ID: 0000-0002-2976-8721
SCOPUS ID: 57198444070
ResearcherID: AAP-4230-2020
SPIN: 7080-6266

Гололобов Артем Юрьевич

Кандидат физико-математических наук,
старший научный сотрудник
Институт космофизических исследований и аэронауки
им. Ю.Г. Шафера СО РАН
677027 Якутск, пр-кт Ленина, д. 31
e-mail: gololobov@ikfia.ysn.ru
ORCID ID: 0000-0002-3869-4728
SCOPUS ID: 57196248457
ResearcherID: S-7094-2018
SPIN: 2298-7721

Information about authors

Vasily V. Zhebsain

PhD of Physical and Mathematical Sciences
Head of the Department
North-Eastern Federal University
48, Kulakovskiy str., Yakutsk, 677000, Russia
e-mail: zhebs@mail.ru
ORCID ID: 0000-0002-2976-8721
SCOPUS ID: 57198444070
ResearcherID: AAP-4230-2020
SPIN: 7080-6266

Artem Yu. Gololobov

PhD of Physical and Mathematical Sciences
Senior Researcher
Yu.G. Shafer Institute of Cosmophysical Research and Aeronomy
of Siberian Branch of the Russian Academy of Sciences
31, Lenin Ave, Yakutsk, 677000, Russia
e-mail: gololobov@ikfia.ysn.ru
ORCID ID: 0000-0002-3869-4728
SCOPUS ID: 57196248457
ResearcherID: S-7094-2018
SPIN: 2298-7721

Башарин Николай Ильич

Младший научный сотрудник
Институт мерзлотоведения им. П.И. Мельникова СО РАН
677010 Якутск, ул. Мерзлотная, д. 36
e-mail: nikolay_b89@mail.ru
ORCID ID: 0000-0002-8501-9186
SCOPUS ID: AAC-8710-2019
ResearcherID: 57204391163
SPIN:1617-5177

Nikolay I. Basharin

Junior Researcher
Permafrost Institute of Siberian Branch of the Russian Academy
of Sciences
36, Merzlotnaya str., Yakutsk, 677000, Russia
e-mail: nikolay_b89@mail.ru
ORCID ID: 0000-0002-8501-9186
SCOPUS ID: AAC-8710-2019
ResearcherID:57204391163
SPIN:1617-5177

Посельский Айаал Федорович

Аспирант
Северо-Восточный федеральный университет
им. М.К. Аммосова
677013 Якутск, ул. Кулаковского, д. 48
e-mail: al.poselsky@gmail.com
ORCID ID: 0009-0003-2602-8044
ResearcherID: KWT-7859-2024
SPIN: 3432-2450

Ayal F. Poselsky

Graduate Student
North-Eastern Federal University in Yakutsk
48, Kulakovsky str. Yakutsk, 677000, Russia
e-mail: al.poselsky@gmail.com
ORCID ID: 0009-0003-2602-8044
ResearcherID: KWT-7859-2024
SPIN: 3432-2450