



ГЕОФИЗИКА

Научная статья

УДК 550

EDN: YBSRRP

DOI: 10.21285/2686-9993-2024-47-4-417-429



Картирование озер и бугров пучения в Арктике с использованием данных синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации с применением технологий глубокого обучения

А.А. Юрьев^a, И.А. Шелохов^b, И.В. Буддо^c, А.А. Рыбченко^d

^{a-d}Институт земной коры СО РАН, Иркутск, Россия

^bНаучный центр изучения Арктики, Салехард, Россия

^cИркутский национальный исследовательский технический университет, Иркутск, Россия

Резюме. В ходе проведенного исследования рассматривался процесс разработки и обучения нейронной сети U-Net для сегментации изображений озер и бугров пучения, основанных на данных синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации. Основной целью работы являлось создание эффективной модели глубокого обучения, способной автоматически выделять озера и бугры пучения на основе сложных радиолокационных изображений. Было проведено несколько этапов, включая сбор и аннотирование данных, выбор архитектуры нейронной сети, обучение и валидацию модели, а также оценку ее производительности. Описан процесс создания обучающего набора данных, который включает в себя аннотирование изображений, выделение признаков, а также подготовку данных для обучения. Рассмотрена архитектура U-Net, которая была выбрана из-за своей способности эффективно сегментировать объекты на изображениях. Обоснован выбор гиперпараметров, таких как количество фильтров, размер ядра свертки и функции активации, использован оптимизатор Adam для достижения быстрой и стабильной сходимости модели. Процесс обучения и валидации модели подробно описан с акцентом на использование валидационного подмножества для мониторинга производительности. Применены методы регуляризации, включая раннюю остановку, с целью предотвращения переобучения и улучшения обобщающей способности модели. В результате продемонстрирована значимость применения глубокого обучения для анализа данных синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации, а также подтверждена эффективность модели U-Net для решения задач сегментации.

Ключевые слова: бугры пучения, радиолокация, космодешифрирование, нейронные сети, глубокое обучение, мерзлота, криолитозона, Арктика

Финансирование: Исследование выполнено за счет гранта Российского научного фонда № 22-17-20009, <https://rscf.ru/project/22-17-20009/>. Проект № 22-17-20009 «Современные методы геофизических исследований для разработки и научного обоснования подходов к изучению внутреннего строения криолитозоны и поверхностных криогенных форм рельефа Арктики и их возможной связи с флюидодинамическими процессами» реализуется при поддержке правительства Ямало-Ненецкого автономного округа.

Благодарности: За активную поддержку исследований авторы признательны научному сотруднику Научного центра изучения Арктики кандидату геолого-минералогических наук доценту А.С. Смирнову, а также советнику генерального директора Западно-Сибирского научно-исследовательского института геологии и геофизики доктору геолого-минералогических наук А.А. Нежданову. Работа выполнена в рамках темы № 1023110300018-4-1.5.4 Министерства науки и высшего образования Российской Федерации в молодежной лаборатории комплексных исследований Арктики Института земной коры СО РАН (г. Иркутск).

Для цитирования: Юрьев А.А., Шелохов И.А., Буддо И.В., Рыбченко А.А. Картирование озер и бугров пучения в Арктике с использованием данных синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации с применением технологий глубокого обучения // Науки о Земле и недропользование. 2024. Т. 47. № 4. С. 417–429. <https://doi.org/10.21285/2686-9993-2024-47-4-417-429>. EDN: YBSRRP.



GEOPHYSICS

Original article

Mapping of lakes and heave mounds in the Arctic using synthetic aperture radar and interferometric synthetic aperture radar data with deep learning technologies

Anton A. Yuriev^{a✉}, Ivan A. Shelokhov^b, Igor V. Buddo^c, Artem A. Rybchenko^d

^{a-d}Institute of the Earth's Crust SB RAS, Irkutsk, Russia

^bArctic Research Center of the Yamal-Nenets Autonomous District, Salekhard, Russia

^cIrkutsk National Research Technical University, Irkutsk, Russia

Abstract. This paper deals with the process of developing and training a U-Net neural network for image segmentation of lakes and hillocks based on synthetic aperture radar and interferometric synthetic aperture radar data. The main goal of the work is to create an effective deep learning model capable of automatically identifying lakes and heave mounds based on complex radar images. To achieve this goal, several stages were carried out, including data collection and annotation, selection of the neural network architecture, training and validation of the model, as well as evaluation of its performance. At the beginning of the work, the process of creating a training dataset is described, which includes annotating images, highlighting features, and preparing data for training. Next, we consider the U-Net architecture, which was chosen because of its ability to efficiently segment objects in images. The choice of hyperparameters, such as the number of filters, the size of the convolution core and activation functions, is justified, and the Adam optimizer is used to achieve fast and stable convergence of the model. The learning and validation process of the model is described in detail with an emphasis on using the validation subset to monitor performance. Regularization methods, including early stopping, are used to prevent overfitting and improve the generalizing ability of the model. As a result, the importance of using deep learning for synthetic aperture radar and interferometric synthetic aperture radar data analysis is demonstrated, as well as confirmation of the effectiveness of the U-Net model for solving segmentation problems.

Keywords: frost mounds, synthetic aperture radar, satellite image decoding, neural networks, deep learning, permafrost, cryolithozone, Arctic

Funding: The study was funded by grant 22-17-20009 from the Russian Science Foundation (<https://rscf.ru/project/22-17-20009/>). The study, 22-17-20009, was supported by the government of the Yamal-Nenets Autonomous District.

Acknowledgements: For active support of the research, the authors are grateful to the research fellow of the Arctic Research Center of the Yamal-Nenets Autonomous District, Cand. Sci. (Geol. & Mineral.), Associate Professor A.S. Smirnov, as well as to the Advisor to the General Director of the West Siberian Scientific Research Institute of Geology and Geophysics, Dr. Sci. (Geol. & Mineral.) A.A. Nezhdanov. The research was carried out within the topic No. 1023110300018-4-1.5.4 of the Ministry of Science and Higher Education of the Russian Federation in the Laboratory for Integrated Research of the Arctic of the Institute of the Earth's Crust SB RAS (Irkutsk).

For citation: Yuriev A.A., Shelokhov I.A., Buddo I.V., Rybchenko A.A. Mapping of lakes and heave mounds in the Arctic using synthetic aperture radar and interferometric synthetic aperture radar data with deep learning technologies. *Earth sciences and subsoil use*. 2024;47(4):417-429. (In Russ.). <https://doi.org/10.21285/2686-9993-2024-47-4-417-429>. EDN: YBSRRP.

Введение

Актуальность анализа радиолокационных изображений обусловлена необходимостью точного мониторинга изменений в природных экосистемах, что имеет важное значение для экологических исследований, управления водными ресурсами и оценки воздействия климатических изменений в Арктике¹ [1–9]. В данной работе рассматривается процесс разработки и обучения нейронной сети U-Net для сегментации изображений озер и бугров пучения, основанных на данных синтетической

апертурной радиолокации (SAR, *от англ.*: Synthetic Aperture Radar) и интерферометрической синтетической апертурной радиолокации (InSAR, *от англ.*: Interferometric Synthetic Aperture Radar) [9–18].

Основной целью проведенного исследования являлась разработка эффективного метода картирования озер и бугров пучения в регионе Арктики с использованием данных SAR, InSAR и технологий глубокого обучения. Исследование направлено на создание высокоточных карт, которые позволят лучше

¹ Пленарное заседание Международного арктического форума // Kremlin.ru. Режим доступа: <http://www.kremlin.ru/events/president/news/60250> (дата обращения: 11.03.2024).



понять распределение и динамику этих объектов.

К задачам исследования можно отнести:

- сбор и обработку данных, необходимых для анализа и картирования озер и бугров пучения;

- выделение признаков, позволяющих различить озера и бугры пучения на основе спутниковых данных;

- разработку модели глубокого обучения, подходящей для картирования озер и бугров пучения.

Материалы и методы исследования

Для картирования озер и бугров пучения использовались данные SAR и InSAR, полученные с различных спутников, обеспечивающих высокое качество и разрешение снимков. В табл. 1 приведено описание используемых данных, их источников, спутников и временных рамок.

Сочетание данных SAR и InSAR с методами глубокого обучения создает мощный инструмент для картирования и мониторинга озер и бугров пучения, что имеет большое значение для экологии, геологии и управления природными ресурсами. Применение данных различных спутников в сочетании с современными методами глубокого обучения открывает новые возможности для более точного анализа и мониторинга этих природных объектов [9–17]. В качестве ключевых преимуществ данного подхода можно отметить следующие:

- высокое пространственное разрешение;
- независимость от погодных условий;
- способность к детектированию изменений;
- эффективная обработка больших объемов данных;

- автоматизация процесса картирования;
- улучшенная точность классификации;
- интеграция с другими данными;
- применение в реальном времени.

Преимущества и недостатки методов SAR и InSAR приведены в табл. 2.

В ходе проведенного исследования для обработки данных SAR и InSAR использовались два основных программных продукта: ArcGIS 10.8 и SNAP (Sentinel Application Platform). Эти инструменты обеспечивают мощные возможности для анализа, визуализации и интерпретации спутниковых данных.

В процессе работы с данными SAR и InSAR в ArcGIS 10.8 проводилась предварительная обработка, включающая коррекцию геометрии, фильтрацию шумов и создание картографических представлений для дальнейшего анализа.

В рамках исследования SNAP использовался для обработки и анализа данных InSAR, включая создание интерферограмм, выравнивание изображений и вычисление изменений высоты. Это дало возможность получить точные данные о деформациях и динамике бугров пучения.

Использование ArcGIS 10.8 и SNAP позволило эффективно обрабатывать и анализировать данные SAR и InSAR. Эти программные инструменты обеспечили необходимые функции для выполнения комплексного анализа, визуализации результатов и получения надежных карт озер и бугров пучения, что является важным вкладом в изучение и мониторинг данных объектов.

В процессе работы были использованы конволюционные (сверточные) нейронные сети (CNN), углубленные сети с пропускными соединениями (ResNet), сети U-Net, а также модели глубокого обучения для временного анализа.

Таблица 1. Описание используемых данных синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации

Table 1. Description of used synthetic aperture radar and interferometric synthetic aperture radar data

Параметр	SAR	InSAR
Источники данных	Радиолокационные системы, которые позволяют получать изображения поверхности Земли с высоким пространственным разрешением и в любых погодных условиях	Интерферометрическая обработка последовательных SAR-снимков
Спутник	Sentinel-1 Radarsat-2	Sentinel-1 ALOS-2
Временные рамки	Летний период 2016–2024 гг.	Летний период 2016–2024 гг.



Таблица 2. Преимущества и недостатки синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации

Table 2. Advantages and disadvantages of synthetic aperture radar and interferometric synthetic aperture radar

SAR		InSAR	
Преимущества	Недостатки	Преимущества	Недостатки
Независимость от погодных условий: SAR работает в микроволновом диапазоне, что позволяет получать изображения независимо от облачности, дождя или других атмосферных условий, которые могут ограничивать использование оптических систем	Сложность интерпретации данных: изображения SAR могут быть сложными для интерпретации из-за наличия шумов и артефактов, что требует специальных знаний и навыков	Высокая точность измерений: InSAR позволяет измерять деформации поверхности с микрометровой точностью, что полезно для мониторинга землетрясений, осадков и других геодинамических процессов	Сложность обработки данных: обработка интерферограмм требует значительных вычислительных ресурсов и сложных алгоритмов, что может быть трудоемким процессом
Высокая разрешающая способность: SAR может обеспечивать высокую пространственную разрешающую способность, что позволяет детально исследовать различные объекты и их характеристики	Влияние геометрии и поверхности: результаты обработки SAR могут зависеть от геометрии местности и типа поверхности, что может привести к ошибкам в интерпретации	Картирование изменений: технология позволяет получать карты изменений высоты поверхности, что имеет важное значение для анализа природных катастроф и изменений в экосистемах	Зависимость от временных интервалов: для получения точных результатов требуется наличие временных интервалов между снимками, что может ограничивать возможности мониторинга динамических процессов
Способность работать в ночное время: в отличие от оптической съемки, SAR может осуществлять наблюдения в любое время суток, что делает его особенно полезным для мониторинга динамических процессов	Ограниченная информация о цвете: SAR не предоставляет информации о цвете объектов, что может быть важным для некоторых приложений	Обширное покрытие: InSAR может охватывать большие площади, что делает его эффективным инструментом для мониторинга регионов и территорий	Проблемы с многозначностью: в некоторых ситуациях интерферометрию может быть сложно интерпретировать из-за многозначности, особенно в сложных ландшафтах
Информация о высоте и структуре: SAR предоставляет возможность получать данные о высоте объектов и их трехмерной структуре, что полезно для анализа сложных ландшафтов	—	—	—

С помощью CNN проводились классификация и сегментация изображений, полученных из данных SAR и InSAR. Архитектура CNN включала несколько последовательных слоев свертки, активации и подвыборки, которые позволяли выявлять низкоуровневые и высокоуровневые признаки, характерные для озер и бугров пучения. Для повышения точно-

сти классификации использовались такие модификации CNN, как VGG, ResNet и Inception (каждая из них имеет свои преимущества в обработке спутниковых изображений).

ResNet применялась для улучшения качества классификации и сегментации объектов на изображениях, полученных из данных SAR и InSAR. Сети U-Net использовались для



сегментации изображений, полученных из данных SAR и InSAR, с целью точного выделения границ озер и бугров пучения. Модели глубокого обучения применялись для анализа временных изменений в высоте поверхности и динамике озер и бугров пучения, полученных из данных InSAR (табл. 3).

Комбинируя эти методики глубокого обучения, исследователи смогли достичь высокой точности и эффективности в картировании озер и бугров пучения на основе данных SAR и InSAR. Применение различных архитектур позволило извлекать ключевые пространственные и временные признаки, что способствовало улучшению качества классификации и сегментации объектов.

Для успешного применения методов глубокого обучения в исследовании озер и бугров пучения на основе данных дистанционного зондирования Земли необходимо выполнить ряд подготовительных этапов. В первую очередь требуется провести предварительную обработку данных SAR и InSAR для повышения их качества и точности. Далее идет создание обучающего набора данных с выделением необходимых признаков. После этого важно правильно выбрать архитектуру модели глубокого обучения и обосновать ее применение. Затем следует описание процессов обучения модели и ее валидации. Для более детального анализа полученных результатов необходимо провести ранжирование выявленных полигонов озер по степени их округлости. Наконец

следует оценить влияние разрешения данных и качества моделей на достоверность результатов.

1. Предварительная обработка данных.

Обработка данных SAR и InSAR требует применения различных методов фильтрации и коррекции для улучшения качества изображений и повышения точности анализа.

Коррекция данных SAR необходима для устранения геометрических и радиометрических искажений, которые могут возникнуть в процессе съемки. Это обеспечивает точное соответствие между полученными изображениями и реальными координатами объектов на Земле.

Данные InSAR требуют дополнительных шагов обработки, связанных с интерференцией и вычислением изменений высоты.

Процессы фильтрации и коррекции данных SAR и InSAR являются критически важными для повышения точности и надежности анализа. Применение различных методов фильтрации и коррекции позволяет минимизировать влияние шумов и искажений, что способствует более точному картированию и мониторингу озер и бугров пучения. Эти этапы обработки являются основой для успешного применения методов глубокого обучения и других аналитических инструментов в исследовании.

Подготовка данных для анализа в ArcGIS и SNAP является критически важным этапом, который включает в себя сбор, обработку и

Таблица 3. Преимущества и недостатки моделей глубокого обучения
Table 3. Advantages and disadvantages of deep learning models

Преимущества	Недостатки
Автоматизация анализа данных: глубокое обучение позволяет автоматизировать процесс анализа больших объемов данных, что значительно ускоряет обработку и интерпретацию информации	Необходимость больших объемов данных: для достижения высокой производительности модели глубокого обучения требуется большое количество аннотированных данных, что может быть трудоемким и дорогостоящим процессом
Высокая точность: современные модели глубокого обучения (например, U-Net) демонстрируют высокую точность в задачах сегментации и классификации, что делает их полезными для анализа изображений SAR и InSAR	Проблемы с интерпретируемостью: модели глубокого обучения могут являться так называемыми черными ящиками, и интерпретация их решений может быть сложной, что затрудняет понимание причин ошибок
Способность к обобщению: модели глубокого обучения могут эффективно обобщать информацию и выявлять сложные паттерны, что позволяет получать более точные предсказания в условиях неопределенности	Зависимость от гиперпараметров: производительность модели может сильно зависеть от выбора гиперпараметров, что требует тщательной настройки и валидации
Гибкость и адаптивность: глубокие нейронные сети можно настраивать и адаптировать под различные задачи и типы данных, что делает их универсальными инструментами в области анализа данных	—



анализ данных SAR и InSAR. Правильная подготовка данных гарантирует высокую точность результатов и их надежность в контексте исследования. Комбинирование возможностей двух программных комплексов позволяет добиться более полного и глубокого анализа природных объектов.

2. Создание обучающего набора данных: выделение признаков для озер и бугров пучения.

Создание обучающего набора данных – это важный процесс, в ходе которого извлекаются и формируются признаки, необходимые для обучения моделей глубокого обучения. В контексте анализа озер и бугров пучения на основе данных SAR и InSAR выделение признаков включает несколько ключевых этапов: сбор исходных данных, непосредственно выделение признаков, создание обучающего набора данных, подготовка данных для обучения.

Создание обучающего набора данных и выделение признаков для озер и бугров пучения – это многоэтапный процесс, требующий внимания к деталям и тщательной обработки данных. Корректное выделение спектральных, пространственных и временных признаков, а также создание аннотированного обучающего набора обеспечивают основу для успешного обучения моделей глубокого обучения. Это, в свою очередь, способствует достижению высокой точности классификации и сегментации объектов на изображениях SAR и InSAR, что имеет важное значение для изучения динамики природных экосистем.

3. Архитектура модели глубокого обучения.

В данном исследовании была выбрана архитектура нейронной сети U-Net для решения задач сегментации изображений озер и бугров пучения на основе данных SAR и InSAR. U-Net является одной из наиболее популярных архитектур для задач сегментации, особенно в области медицинской визуализации, но также успешно применяется и в других областях, связанных с анализом изображений [19–21].

Архитектура U-Net является мощным инструментом для решения задач сегментации изображений, ее применение в данном исследовании позволяет достичь высокой точ-

ности в выделении озер и бугров пучения из данных SAR и InSAR. Преимущества данной архитектуры, такие как сохранение пространственной информации и эффективность работы с малыми наборами данных, делают ее идеальным выбором для решения поставленных задач.

4. Обоснование выбора архитектуры и гиперпараметров U-Net.

Выбор архитектуры U-Net и гиперпараметров был тщательно обоснован с учетом специфики задачи сегментации, требования к точности и доступности данных. U-Net, благодаря своей архитектуре и особенностям, обеспечивает высокую эффективность в выделении объектов на изображениях SAR и InSAR, что критически важно для анализа озер и бугров пучения. Настройка гиперпараметров позволяет оптимизировать обучение модели и достичь качественных результатов, что делает этот подход подходящим для решения поставленных задач.

5. Описание процесса обучения модели и валидации.

Обучение модели и валидация – это сложный и многоэтапный процесс, который требует тщательной подготовки данных, настройки гиперпараметров и мониторинга производительности.

Настройка и обучение модели включает в себя четыре основных этапа, успешное выполнение которых позволяет создать устойчивую и точную модель для сегментации изображений, что критически важно для анализа данных SAR и InSAR:

- подготовку данных для обучения;
- обучение модели;
- валидацию модели;
- тестирование модели.

Правильная настройка и оценка модели помогают достигать высоких результатов и обеспечивают надежность выводов, сделанных на основе проведенного анализа.

6. Ранжирование получаемых полигонов озер по степени округлости.

Коэффициент округлости R_c является важным показателем, который позволяет оценить форму водоемов и их отклонение от идеальной круглой формы². Для вычисления данного коэффициента используется следующая формула:

² Miller V.C. A quantitative geomorphic study of drainage basin characteristics in the Clinch Mountain area, Virginia and Tennessee. Project NR 389-402: technical report 3. New York: Columbia University, Department of Geology, 1953. 51 p.



$$Rc = \frac{4\pi A}{P^2},$$

где A – площадь бассейна; P – периметр бассейна.

Коэффициент округлости определяется как отношение площади бассейна к площади круга, имеющего тот же периметр, что и бассейн. При значении, близком к 1, форма бассейна сходна с кругом.

Для реализации подхода было написано специальное программное решение (скрипт) на базе программы ArcGIS. После выполнения скрипта можно использовать инструменты ArcGIS для ранжирования полигонов по значению коэффициента округлости. Это можно сделать с помощью анализа атрибутов или визуализации на карте, что позволит легко идентифицировать более округлые и вытянутые формы озер.

Создание скрипта для вычисления коэффициента округлости в ArcGIS позволяет автоматизировать процесс анализа форм полигонов озер. Использование этого коэффициента помогает в экологических исследованиях и управлении водными ресурсами, так как предоставляет полезную информацию о геометрии водоемов. Подобный подход может быть адаптирован и для других параметров, связанных с формой объектов, что расширяет возможности анализа в географических информационных системах.

7. Влияние разрешения данных и качества моделей на результаты.

Разрешение данных и качество моделей являются ключевыми факторами, определяющими точность и достоверность результатов в задачах анализа и интерпретации изображений, особенно в контексте применения SAR, InSAR и методов глубокого обучения.

Высокое пространственное разрешение позволяет детально выявлять мелкие объекты и структуры на изображениях. Например, в задачах сегментации озер и бугров пучения высокое разрешение способствует точному определению границ объектов, что критически важно для экологических исследований и мониторинга. Низкое пространственное разрешение может привести к потере информации и нечеткой сегментации, что затрудняет анализ и интерпретацию данных. Объекты могут сливаться или терять детали, что может привести к ошибкам в классификации.

В таких задачах мониторинга изменений, как отслеживание деформаций или изменений в экосистемах, высокое временное разрешение обеспечивает более частые снимки и позволяет выявлять динамику процессов. Это особенно важно для InSAR, где регулярные наблюдения помогают отслеживать изменения высоты поверхности. Низкое временное разрешение может привести к упущению важных событий или изменений, снизив общую эффективность мониторинга.

Качество моделей, используемых для анализа данных, непосредственно влияет на точность и надежность результатов. Выбор архитектуры нейронной сети U-Net может существенно повлиять на результаты сегментации. Архитектуры, специально разработанные для задач обработки изображений, обычно лучше справляются с выявлением сложных паттернов и форм. Неподходящая архитектура может привести к низкой точности и затруднениям в извлечении значимой информации из данных.

Качество обучения модели, которое включает в себя выбор гиперпараметров, метод предобработки данных и использование методов регуляризации, напрямую влияет на ее производительность. Правильная настройка гиперпараметров может значительно улучшить точность модели и ее способность обобщать. Переобучение модели на обучающих данных может привести к плохим результатам на валидационных и тестовых наборах, что подчеркивает важность регуляризации и кросс-валидации.

Наличие аннотированных данных высокого качества критично для успешного обучения моделей глубокого обучения. Ошибки и несоответствия в аннотациях могут приводить к неправильному обучению и низкой точности предсказаний.

Разрешение данных и качество моделей являются взаимосвязанными факторами, которые в совокупности определяют успешность анализа. Даже самая продвинутая модель не сможет показать высокие результаты на данных низкого разрешения, а высококачественные данные без надлежащей модели могут привести к недостаточной интерпретации.

Влияние разрешения данных и качества моделей на результаты анализа является критически важным аспектом в области исследования и мониторинга природных и антропогенных процессов. Высокое пространственное и временное разрешение данных в сочетании с качественными моделями глубокого обучения




обеспечивает точность и надежность результатов, что, в свою очередь, способствует более эффективному управлению ресурсами и охране окружающей среды. Понимание этих аспектов позволяет оптимизировать подходы к анализу данных и улучшать результаты в различных приложениях.

Результаты исследования и их обсуждение

Основная цель дешифрирования данных SAR и inSAR заключалась в выявлении рай-

онов повышенной пространственной плотности размещения озер и бугров пучения на территории Ямало-Ненецкого автономного округа. В соответствии с результатами исследований, описанных в работах³ [22–25], некоторые бугры пучения могут иметь эндогенное происхождение и являться индикатором активных глубинных флюидодинамических процессов.

По результатам дешифрирования данных SAR и inSAR построены карты плотности озер (рис. 1) и бугров пучения (рис. 2).



**Рис. 1. Карта плотности озер, выделенных при дешифровке
синтетической апертурной радиолокации:**

1 – гидросеть; 2 – административные границы; 3 – водоемы

Fig. 1. Density map of lakes identified during synthetic aperture radar decryption:

1 – hydro grid; 2 – administrative borders; 3 – reservoirs

³ Нежданов А.А., Смирнов А.С. Флюидодинамическая интерпретация сейсморазведочных данных: учеб. пособие. Тюмень: Изд-во ТИУ, 2021. 286 с. EDN: CHWAYW.




Рис. 2. Карта плотности бугров пучения, выделенных при дешифровке синтетической апертурной радиолокации и интерферометрической синтетической апертурной радиолокации:

1 – гидросеть; 2 – административные границы; 3 – водоемы

Fig. 2. Density map of the heaving mounds identified during synthetic aperture radar and interferometric synthetic aperture radar decryption:

1 – hydro grid; 2 – administrative borders; 3 – reservoirs

Как видно из рис. 1, наибольшая плотность озер характерна для южной и восточной частей полуострова Ямал, а также для Надымского района. Наибольшее же количество бугров пучения сосредоточено в центральной части Ямала и на его восточном побережье, а также в северной части Надымского района. Действительно, именно в пределах выявленных районов глубинные флюидодинамические процессы наиболее явно проявлены, в том числе образованием известного Ямальского кратера [26].

В дальнейшем целесообразно продолжить данное исследование в направлении оценки

динамики роста бугров пучения на основе анализа данных SAR и InSAR, полученных в разные моменты времени, то есть на основе мониторинговых наблюдений.

Закключение

Проведенное исследование подчеркивает значимость применения современных технологий глубокого обучения в сочетании с данными SAR и InSAR для решения задач сегментации и мониторинга природных объектов. Повышение качества данных и моделей, а также использование комплексного подхода к анализу открывают новые горизонты для дальнейших



исследований в области экологии, географии и управления природными ресурсами.

Практическое применение полученных результатов (следование рекомендациям обеспечит их большую точность и надежность) может значительно улучшить процессы мониторинга и анализа природных объектов.

Направления для будущих исследований и улучшения методов открывают новые го-

ризонты применению технологий глубокого обучения и дистанционного зондирования в анализе природных экосистем. Усовершенствование моделей, методов предобработки и интеграции различных подходов позволяет достигать более точных и надежных результатов, что способствует эффективному управлению природными ресурсами и охране окружающей среды.

Список источников

1. Жилина И.Ю. Потепление в Арктике: возможности и риски // Экономические и социальные проблемы России. 2021. № 1. С. 66–87. <https://doi.org/10.31249/espr/2021.01.04>. EDN: GSPTRV.
2. Гудков А.Б., Попова О.Н., Небученных А.А., Богданов М.Ю. Эколого-физиологическая характеристика климатических факторов Арктики. Обзор литературы // Морская медицина. 2017. Т. 3. № 1. С. 7–13. <https://doi.org/10.22328/2413-5747-2017-3-1-7-13>. EDN: YHDEON.
3. Воронина С.А., Порфирьев Б.Н., Семикашев В.В., Терентьев Н.Е., Елисеев Д.О., Наумова Ю.В. Последствия изменений климата для экономического роста и развития отдельных секторов экономики российской Арктики // Арктика: экология и экономика. 2017. № 4. С. 4–17. <https://doi.org/10.25283/2223-4594-2017-4-4-17>. EDN: YMRLRQ.
4. Куделькин Н.С. Арктика и глобальное потепление: адаптация к изменению климата и охрана окружающей среды // Юридические исследования. 2022. № 1. С. 1–16. <https://doi.org/10.25136/2409-7136.2022.1.37049>. EDN: KNUXCH.
5. Эдельгериев Р.С.Х., Романовская А.А. Новые подходы к адаптации к изменениям климата на примере Арктической зоны Российской Федерации // Метеорология и гидрология. 2020. № 5. С. 12–28. EDN: TRDOGS.
6. Васильев А.А., Гравис А.Г., Губарьков А.А., Дроздов Д.С., Коростелев Ю.В., Малкова Г.В. [и др.]. Деградация мерзлоты: результаты многолетнего геофизиологического мониторинга в западном секторе российской Арктики // Криосфера Земли. 2020. Т. 24. № 2. С. 15–30. [https://doi.org/10.21782/KZ1560-7496-2020-2\(15-30\)](https://doi.org/10.21782/KZ1560-7496-2020-2(15-30)). EDN: HROYGC.
7. Павлов А.В., Малкова Г.В. Мелкомасштабное картографирование трендов современных изменений температуры грунтов на севере России // Криосфера Земли. 2009. Т. 13. № 4. С. 32–39. EDN: KYRZGR.
8. Агарков С.А., Козьменко С.Ю., Щеголькова А.А. Эпоха глобального потепления: перспективы экономического взаимодействия в «Новой Арктике» // Север и рынок: формирование экономического порядка. 2019. № 1. С. 26–36. <https://doi.org/10.25702/KSC.2220-802X.1.2019.63.26-36>. EDN: ZQNNOP.
9. Chuang K.-S., Tzeng H.-L., Chen S., Wu J., Chen T.-J. Fuzzy c-means clustering with spatial information for image segmentation // Computerized Medical Imaging and Graphics. 2006. Vol. 30. Iss. 1. P. 9–15. <https://doi.org/10.1016/j.compmedimag.2005.10.001>.
10. Anantrasirichai N., Biggs J., Kelevitz K., Sadeghi Z., Wright T., Thompson J., et al. Detecting ground deformation in the built environment using sparse satellite InSAR data with a convolutional neural network // IEEE Transactions on Geoscience and Remote Sensing. 2021. Vol. 59. Iss. 4. P. 2940–2950. <https://doi.org/10.1109/TGRS.2020.3018315>.
11. Mavrovic A., Sonnentag O., Lemmetyinen J., Baltzer J.L., Kinnard C., Roy A. Reviews and syntheses: recent advances in microwave remote sensing in support of terrestrial carbon cycle science in Arctic-boreal regions // Biogeosciences. 2023. Vol. 20. Iss. 14. P. 2941–2970. <https://doi.org/10.5194/bg-20-2941-2023>.
12. Merchant M., Bourgeau-Chavez L., Mahdianpari M., Brisco B., Obadia M., Devries B., et al. Arctic ice-wedge landscape mapping by CNN using a fusion of Radarsat constellation Mission and ArcticDEM // Remote Sensing of Environment. 2024. Vol. 304. P. 114052. <https://doi.org/10.1016/j.rse.2024.114052>.
13. Li X., Zhang K., Niu J., Liu L. A machine learning-based dynamic ensemble selection algorithm for microwave retrieval of surface soil freeze/thaw: a case study across China // GIScience & Remote Sensing. 2022. Vol. 59. Iss. 1. P. 1550–1569. <https://doi.org/10.1080/15481603.2022.2122117>.
14. Pan J., Zhao R., Xu Z., Cai Z., Yuan Y. Quantitative estimation of sentinel-1A interferometric decorrelation using vegetation index // Frontiers in Earth Science. 2022. Vol. 10. P. 1016491. <https://doi.org/10.3389/feart.2022.1016491>.
15. Byers M., Covey N. Arctic SAR and the “security dilemma” // International Journal. 2019. Vol. 74. Iss. 4. P. 499517. <https://doi.org/10.1177/0020702019890339>.
16. Sydnese A.K., Sydnese M., Antonsen Y. International cooperation on search and rescue in the Arctic // Arctic Review on Law and Politics. 2017. Vol. 8. P. 109–136. <https://doi.org/10.23865/arctic.v8.705>.
17. Morris K., Jeffries M.O., Weeks W.F. Ice processes and growth history on Arctic and sub-Arctic lakes using ERS-1 SAR data // Polar Record. 1995. Vol. 31. Iss. 177. P. 115–128. <https://doi.org/10.1017/S0032247400013619>.
18. Liu X., Zhang Y., Jing H., Wang L., Zhao S. Ore image segmentation method using U-Net and Res_Unet convolutional networks // RSC Advances. 2020. Vol. 10. Iss. 16. P. 9396–9406. <https://doi.org/10.1039/C9RA05877J>.
19. Norouzi A., Rahim M.S.M., Altameem A., Saba T., Rad A.E., Rehman A., et al. Medical image segmentation methods, algorithms, and applications // IETE Technical Review. 2014. Vol. 31. Iss. 3. P. 199–213. <https://doi.org/10.1080/02564602.2014.906861>.
20. Печкин А.Д., Кириллова Т.К. Оценка и перспективы развития глубокого обучения искусственных нейронных сетей // Молодая наука Сибири. 2021. № 1. С. 375–380. EDN: SDQIAU.



21. Грицков И.О., Говоров А.В., Васильев А.О., Ходырева Л.А., Ширяев А.А., Пушкарь Д.Ю. Data Science – глубокое обучение нейросетей и их применение в здравоохранении // Здоровье мегаполиса. 2021. Т. 2. № 2. С. 109–115. <https://doi.org/10.47619/2713-2617.zm.2021.v2i2;109-115>. EDN: SGWBPD.
22. Buddo I.V., Sharlov M., Shelokhov I., Misyurkeeva, N., Seminsky I., Selyaev V., et al. Applicability of transient electromagnetic surveys to permafrost imaging in Arctic West Siberia // *Energies* 2022. Vol. 15. Iss. 5. P. 1816. <https://doi.org/10.3390/en15051816>.
23. Buddo I., Misyurkeeva N., Shelokhov I., Shein A., Sankov V., Rybchenko A., et al. Modeling of explosive Pingo-like structures and fluid-dynamic processes in the Arctic permafrost: workflow based on integrated geophysical, geocryological, and analytical data // *Remote Sensing*. 2024. Vol. 16. Iss. 16. P. 2948. <https://doi.org/10.3390/rs16162948>.
24. Misyurkeeva N., Buddo I., Kraev G., Smirnov A., Nezhdanov A., Shelokhov I., et al. Periglacial landforms and fluid dynamics in the permafrost domain: a case from the Taz Peninsula, West Siberia // *Energies*. 2022. 15. Iss. 8. P. 2794. <https://doi.org/10.3390/en15082794>.
25. Misyurkeeva N., Buddo I., Shelokhov I., Smirnov A., Nezhdanov A., Agafonov Y. The structure of permafrost in northern West Siberia: geophysical evidence // *Energies*. 2022. Vol. 15. Iss. 8. P. 2847. <https://doi.org/10.3390/en15082847>.
26. Bogoyavlensky V., Bogoyavlensky I., Nikonov R., Kargina T., Chuvin E., Bukhanov B., et al. New catastrophic gas blowout and giant crater on the Yamal Peninsula in 2020: results of the expedition and data processing // *Geosciences*. 2021. Vol. 11. Iss. 2. P. 71. <https://doi.org/10.3390/geosciences11020071>.

References

1. Zhilina I.Yu. Warming in the arctic: opportunities and risks. *Economic and Social Problems of Russia*. 2021;1:66-87. (In Russ.). <https://doi.org/10.31249/espr/2021.01.04>. EDN: GSPTRV.
2. Gudkov A.B., Popova O.N., Nebuchennyh A.A., Bogdanov M.Yu. Ecological and physiological characteristic of the Arctic climatic factors. Review. *Marine Medicine*. 2017;3(1):7-13. (In Russ.). <https://doi.org/10.22328/2413-5747-2017-3-1-7-13>. EDN: YHDEOH.
3. Voronina S.A., Porfiriev B.N., Semikashv V.V., Terentiev N.E., Eliseev D.O., Naumova Yu.V. Climate change impact on economic growth and specific sectors' development of the Russian Arctic. *Arctic: Ecology and Economy*. 2017;4:4-17. (In Russ.). <https://doi.org/10.25283/2223-4594-2017-4-4-17>. EDN: YMRLRQ.
4. Kudelkin N. The Arctic and global warming: adaptation to climate change and environmental protection. *Legal Studies*. 2022;1:1-16. (In Russ.). <https://doi.org/10.25136/2409-7136.2022.1.37049>. EDN: KNUXCH.
5. Edel'geriev R.S.K., Romanovskaya A.A. New approaches to the adaptation to climate change: the Arctic zone of Russia. *Meteorologiya i gidrologiya*. 2020;5:12-28. (In Russ.). EDN: TRDOGS.
6. Vasiliev A.A., Gravis A.G., Gubarkov A.A., Drozdov D.S., Korostelev Yu.V., Malkova G.V., et al. Permafrost degradation: results of the long-term geocryological monitoring in the western sector of Russian Arctic. *Earth's Cryosphere*. 2020;24(2):15-30. (In Russ.). [https://doi.org/10.21782/KZ1560-7496-2020-2\(15-30\)](https://doi.org/10.21782/KZ1560-7496-2020-2(15-30)). EDN: HROYGC.
7. Pavlov A.V., Malkova G.V. Small-scale mapping of trends of the contemporary ground temperature changes in the Russian north. *Earth's Cryosphere*. 2009;13(4):32-39. (In Russ.). EDN: KYRZGR.
8. Agarkov S.A., Koz'menko S.Yu., Shchegol'kova A.A. The era of global warming: prospects of economic interaction in the "New Arctic". *North and market: formation of economic order*. 2019;1:26-36. (In Russ.). <https://doi.org/10.25702/KSC.2220-802X.1.2019.63.26-36>. EDN: ZQNNOP.
9. Chuang K.-S., Tzeng H.-L., Chen S., Wu J., Chen T.-J. Fuzzy c-means clustering with spatial information for image segmentation. *Computerized Medical Imaging and Graphics*. 2006;30(1):9-15. <https://doi.org/10.1016/j.compmedimag.2005.10.001>.
10. Anantrasirichai N., Biggs J., Kelevitz K., Sadeghi Z., Wright T., Thompson J., et al. Detecting ground deformation in the built environment using sparse satellite InSAR data with a convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*. 2021;59(4):2940-2950. <https://doi.org/10.1109/TGRS.2020.3018315>.
11. Mavrovic A., Sonnentag O., Lemmetyinen J., Baltzer J.L., Kinnard C., Roy A. Reviews and syntheses: recent advances in microwave remote sensing in support of terrestrial carbon cycle science in Arctic-boreal regions. *Biogeosciences*. 2023;20(14):2941-2970. <https://doi.org/10.5194/bg-20-2941-2023>.
12. Merchant M., Bourgeau-Chavez L., Mahdianpari M., Brisco B., Obadia M., Devries B., et al. Arctic ice-wedge landscape mapping by CNN using a fusion of Radarsat constellation Mission and ArcticDEM. *Remote Sensing of Environment*. 2024;304:114052. <https://doi.org/10.1016/j.rse.2024.114052>.
13. Li X., Zhang K., Niu J., Liu L. A machine learning-based dynamic ensemble selection algorithm for microwave retrieval of surface soil freeze/thaw: a case study across China. *GIScience & Remote Sensing*. 2022;59(1):1550-1569. <https://doi.org/10.1080/15481603.2022.2122117>.
14. Pan J., Zhao R., Xu Z., Cai Z., Yuan Y. Quantitative estimation of sentinel-1A interferometric decorrelation using vegetation index. *Frontiers in Earth Science*. 2022;10:1016491. <https://doi.org/10.3389/feart.2022.1016491>.
15. Byers M., Covey N. Arctic SAR and the "security dilemma". *International Journal*. 2019;74(4):499-517. <https://doi.org/10.1177/0020702019890339>.
16. Sydnes A.K., Sydnes M., Antonsen Y. International cooperation on search and rescue in the Arctic. *Arctic Review on Law and Politics*. 2017;8:109-136. <https://doi.org/10.23865/arctic.v8.705>.
17. Morris K., Jeffries M.O., Weeks W.F. Ice processes and growth history on Arctic and sub-Arctic lakes using ERS-1 SAR data. *Polar Record*. 1995;31(177):115-128. <https://doi.org/10.1017/S0032247400013619>.



18. Liu X., Zhang Y., Jing H., Wang L., Zhao S. Ore image segmentation method using U-Net and Res_Unet convolutional networks. *RSC Advances*. 2020;10(16):9396-9406. <https://doi.org/10.1039/C9RA05877J>.
19. Norouzi A., Rahim M.S.M., Altameem A., Saba T., Rad A.E., Rehman A., et al. Medical image segmentation methods, algorithms, and applications. *IETE Technical Review*. 2014;31(3):199-213. <https://doi.org/10.1080/02564602.2014.906861>.
20. Pechkin A.D., Kirillova T.K. Assessment and prospects for the development of artificial neural network deep learning. *Young science of Siberia*. 2021;1:375-380. (In Russ.). EDN: SDQIAU.
21. Gritskov I.O., Govorov A.V., Vasiliev A.O., Khodyreva L.A., Shiryaev A.A., Pushkar D.Yu. Data science – deep learning of neural networks and their application in healthcare. *City Healthcare*. 2021;2(2):109-115. (In Russ.). <https://doi.org/10.47619/2713-2617.zm.2021.v2i2;109-115>. EDN: SGWBPD.
22. Buddo I.V., Sharlov M., Shelokhov I., Misyurkeeva N., Seminsky I., Selyaev V., et al. Applicability of transient electromagnetic surveys to permafrost imaging in Arctic West Siberia. *Energies*. 2022;15(5):1816. <https://doi.org/10.3390/en15051816>.
23. Buddo I., Misyurkeeva N., Shelokhov I., Shein A., Sankov V., Rybchenko A., et al. Modeling of explosive Pingo-like structures and fluid-dynamic processes in the Arctic permafrost: workflow based on integrated geophysical, geocryological, and analytical data. *Remote Sensing*. 2024;16(16):2948. <https://doi.org/10.3390/rs16162948>.
24. Misyurkeeva N., Buddo I., Kraev G., Smirnov A., Nezhdanov A., Shelokhov I., et al. Periglacial landforms and fluid dynamics in the permafrost domain: a case from the Taz Peninsula, West Siberia. *Energies*. 2022;15(8):2794. <https://doi.org/10.3390/en15082794>.
25. Misyurkeeva N., Buddo I., Shelokhov I., Smirnov A., Nezhdanov A., Agafonov Y. The structure of permafrost in northern West Siberia: geophysical evidence. *Energies*. 2022;15(8):2847. <https://doi.org/10.3390/en15082847>.
26. Bogoyavlensky V., Bogoyavlensky I., Nikonov R., Kargina T., Chuvilin E., Bukhanov B., et al. New catastrophic gas blowout and giant crater on the Yamal Peninsula in 2020: results of the expedition and data processing. *Geosciences*. 2021;11(2):71. <https://doi.org/10.3390/geosciences11020071>.

Информация об авторах / Information about the authors



Юрьев Антон Александрович,

аспирант,
ведущий инженер лаборатории инженерной геологии и геоэкологии,
лаборатории комплексных исследований Арктики,
Институт земной коры СО РАН,
г. Иркутск, Россия,
✉ antonyrevgeo@mail.ru
<https://orcid.org/0000-0002-2452-4840>

Anton A. Yuriev,

Postgraduate Student,
Lead Engineer of the Laboratory of Engineering Geology and Geoecology,
Laboratory of Integrated Arctic Research,
Institute of the Earth's Crust SB RAS,
Irkutsk, Russia,
✉ antonyrevgeo@mail.ru
<https://orcid.org/0000-0002-2452-4840>



Шелухов Иван Антонович,

кандидат геолого-минералогических наук,
младший научный сотрудник лаборатории комплексной геофизики,
лаборатории комплексных исследований Арктики,
Институт земной коры СО РАН,
г. Иркутск, Россия,
ведущий научный сотрудник,
Научный центр изучения Арктики,
г. Салехард, Россия,
sia@crust.irk.ru
<https://orcid.org/0000-0003-3523-4440>

Ivan A. Shelokhov,

Cand. Sci. (Geol. & Mineral.),
Junior Researcher of the Laboratory of Integrated Geophysics,
Laboratory of Integrated Arctic Research,
Institute of the Earth's Crust SB RAS,
Irkutsk, Russia,
Leading Researcher,
Scientific Center for the Study of the Arctic,
Salekhard, Russia,
sia@crust.irk.ru
<https://orcid.org/0000-0003-3523-4440>



Буддо Игорь Владимирович,

кандидат геолого-минералогических наук,
заведующий лабораторией комплексной геофизики,
лабораторией комплексных исследований Арктики,
Институт земной коры СО РАН,
г. Иркутск, Россия,
доцент кафедры прикладной геологии,
геофизики и геоинформационных систем,
институт «Сибирская школа геонаук»,
Иркутский национальный исследовательский технический университет,
г. Иркутск, Россия,
biv@crust.irk.ru
<https://orcid.org/0000-0002-5204-9530>

Igor V. Buddo,

Cand. Sci. (Geol. & Mineral.),
Head of the Laboratory of Integrated Geophysics,
Laboratory of Integrated Arctic Research,
Institute of the Earth's Crust SB RAS,
Irkutsk, Russia
Associate Professor of the Department of Applied Geology,
Geophysics and Geoinformation Systems,
Siberian School of Geosciences,
Irkutsk National Research Technical University,
Irkutsk, Russia,
biv@crust.irk.ru
<https://orcid.org/0000-0002-5204-9530>



Рыбченко Артем Александрович,

кандидат геолого-минералогических наук,
заведующий лабораторией инженерной геологии и геоэкологии,
Институт земной коры СО РАН,
г. Иркутск, Россия,
rybchenk@crust.irk.ru
<https://orcid.org/0000-0003-2615-8423>

Artem A. Rybchenko,

Cand. Sci. (Geol. & Mineral.),
Head of the Laboratory of Engineering Geology and Geoecology,
Institute of the Earth's Crust SB RAS,
Irkutsk, Russia,
rybchenk@crust.irk.ru
<https://orcid.org/0000-0003-2615-8423>

Вклад авторов / Contribution of the authors

А.А. Юрьев – разработка концепции, разработка методологии, написание черновика рукописи.

И.А. Шелохов – визуализация, написание рукописи – рецензирование и редактирование.

И.В. Буддо – разработка концепции, написание черновика рукописи, написание рукописи – рецензирование и редактирование.

А.А. Рыбченко – написание рукописи – рецензирование и редактирование.

Anton A. Yuriev – conceptualization, methodology, writing – original draft.

Ivan A. Shelokhov – visualization, writing – review & editing.

Igor V. Buddo – conceptualization, writing – original draft, writing – review & editing.

Artem A. Rybchenko – writing – review & editing.

Конфликт интересов / Conflict of interests

Авторы заявляют об отсутствии конфликта интересов.

The authors declare no conflicts of interests.

Все авторы прочитали и одобрили окончательный вариант рукописи.

The final manuscript has been read and approved by all the co-authors.

Информация о статье / Information about the article

Статья поступила в редакцию 15.11.2024; одобрена после рецензирования 28.11.2024; принята к публикации 11.12.2024.

The article was submitted 15.11.2024; approved after reviewing 28.11.2024; accepted for publication 11.12.2024.