

Анализ спутниковых данных для оценки ледовой обстановки на реках Мурманской области с использованием методов машинного обучения (на примере реки Колы)

И. М. Лазарева¹, Е. В. Заболотских², О. И. Ляш¹, Г. С. Шелегов³

¹ Мурманский арктический университет, Мурманск, 183038, Россия
E-mails: lazareva.im@mauniver.ru, lyash.oi@mauniver.ru

² Российский государственный гидрометеорологический университет
Санкт-Петербург, 192007, Россия
E-mail: liza@rshu.ru

³ Главное управление МЧС РФ по Мурманской области, Мурманск, 183053, Россия
E-mail: glebsorta@gmail.com

Сложные климатические условия Арктического региона оказывают влияние на процесс формирования ледяного покрова северных рек. Мониторинг ледовой обстановки представляется важным элементом системы предупреждения опасных явлений на внутренних водоемах: наводнения, половодья, раннего ледостава и т.п. В задаче оценки ледовой обстановки на реках Мурманской области использовались снимки радиолокаторов с синтетической апертурой спутниковой платформы Sentinel-1. Анализировался участок реки Колы в районе гидропоста 1429 км Октябрьской железной дороги, для которого имеются данные натурных наблюдений. Построенная модель логистической регрессии по данным обратного рассеяния на VV- и VH-поляризациях позволила определить вероятность появления льда в каждом пикселе изображения анализируемого участка реки, а также визуализировать картину ледового явления. Задача классификации ледовых явлений решалась с помощью полносвязной нейронной сети MLP (*англ.* multilayer perceptron, многослойный персептрон). Выбор архитектуры обусловлен сравнительно небольшим объемом обучающей выборки и возможностью лёгкой адаптации и расширения модели, например, при добавлении нового слоя или изменении количества нейронов в существующих слоях для улучшения производительности. Было реализовано обучение модели классификации на три класса: ледостав, открытая вода и ледовые явления межсезонья. В рамках проведённого исследования разработаны программные модули, анализирующие спутниковые снимки Sentinel-1A, -1B с целью детектирования ледовых явлений на реках Мурманской области. Дальнейшая работа предполагает адаптацию инструментария к использованию данных с российских спутников.

Ключевые слова: анализ спутниковых данных, Sentinel-1, ледовые явления на реках, методы машинного обучения, Арктический регион

Одобрена к печати: 20.06.2025

DOI: 10.21046/2070-7401-2025-22-4-118-132

Введение

Систематический мониторинг ледовой обстановки на реках Кольского полуострова представляет собой важную задачу, обусловленную необходимостью защиты прибрежной инфраструктуры и населения. Сложные климатические условия Арктического региона, частые изменения температуры и осадков создают потенциально опасные ледовые явления на реках, которые могут приводить к серьёзным наводнениям. На территории Мурманской области можно выделить две реки, ледовые явления на которых несут непосредственную угрозу: Кола и Варзуга. В настоящем исследовании анализировался ледовый режим на реке Коле с целью дальнейшего тиражирования реализованного подхода на другие реки Заполярья.

Речной лёд, образующийся в северных регионах, оказывает влияние на многие аспекты функционирования рек. Например, речной лёд способствует созданию сети сезонных ледяных дорог, которые временно упрощают доступность удалённых поселений (Yang et al., 2020). Также образование речного льда и его таяние оказывают прямое влияние на мест-

ные экосистемы, транспорт и безопасность (Abdelkader et al., 2024; Beaton et al., 2019; Chu, Lindenschmidt, 2016; Gatto, 1990; Newton et al., 2024; Richards et al., 2023; Vuyovich et al., 2009; Yang et al., 2020). Образование ледяного покрова в русле северных рек может иметь негативные последствия, поскольку возникновение ледяных заторов и наводнений может поставить под угрозу энергетическую инфраструктуру (Hicks, 2009). Всё это обуславливает важность наблюдения за состоянием речного льда.

Один из традиционных способов наблюдения за состоянием речного льда — слежение в ключевых местах реки, часто оснащённых оборудованием гидропоста. Этот подход, несмотря на его полезность, имеет такое ограничение, как доступность, особенно в зимних условиях. При этом мониторинг ледовой обстановки с применением погружных инструментов (например, манометров, профилометров течения и гидролокаторов) не всегда результативен, так как эти инструменты могут быть повреждены или смещены льдом. Поэтому для комплексного и непрерывного сбора данных такой подход недостаточен (Chaouch et al., 2014).

Другим традиционным способом оценки ледового режима на реках является дистанционное наблюдение с помощью аэрофотосъёмки, съёмки с беспилотных летательных аппаратов. Однако указанные методы наблюдения сталкиваются с существенными ограничениями, связанными с доступностью, погодными условиями и временными рамками (Шилин, Кузнецов, 2022). Наиболее подходящим инструментом для регулярного мониторинга состояния ледяного покрова рек стало спутниковое дистанционное зондирование (Purnell et al., 2024).

Использование спутниковых данных таких инструментов, как ICESat-2, CryoSat-2, SAR (*англ.* Synthetic Aperture Radar, радиолокационная система с синтетической апертурой — PCA) Sentinel-1, для мониторинга ледовой обстановки предоставляет значительные преимущества, включая широкий охват территории, регулярное обновление данных и, в случае применения микроволновых измерений, независимость от погодных условий (Liu et al., 2023).

Оптические снимки таких спутников, как Landsat-5, Landsat-8, Sentinel-2A и Sentinel-2B, могут быть использованы для классификации пикселей открытой воды, льда и облаков (Moalemi et al., 2024). Измерения радиолокаторов с синтетической апертурой позволяют получать детальную информацию о состоянии ледяного покрова, что критически важно для своевременного принятия мер по предотвращению и ликвидации ледовых заторов (Михайлюкова и др., 2020; Li, Lindenschmidt, 2018; Łoś, Pawłowski, 2017). Подходы, используемые при анализе данных, включают применение пороговых методов, методов классификации и сегментации изображений.

Для обработки спутниковых данных часто применяют метод *k*-средних, эффективность которого сравнима с подходом с фиксированным порогом (Sobiech, Dierking, 2013). Примерами методов, используемых для классификации речного льда, могут выступать нейронные сети, метод опорных векторов SVM (*англ.* support vector machine) и радиочастотные классификаторы (Heinilä et al., 2021; Singh et al., 2020; Sola, Scott, 2022).

Модель логистической регрессии является полезным инструментом анализа данных PCA для оценки воздействия водохранилищ на плотинах на речной ледяной покров (Fukś, 2024).

Один из широко распространённых подходов для анализа спутниковых снимков — использование методов машинного обучения и искусственных нейронных сетей.

В работе (Temimi et al., 2023) описывается автоматизированная методика, основанная на глубоком обучении, для мониторинга ледовой обстановки на реках в северной части США и Канады в режиме, приближенном к реальному. Основными данными выступают данные высокого разрешения VIIRS (*англ.* Visible Infrared Imaging Radiometer Suite), полученные со спутников NOAA-20 (*англ.* National Oceanic and Atmospheric Administration) и NPP (*англ.* NPOESS (National Polar-orbiting Operational Environmental Satellite System) Preparatory Project). Используется алгоритм глубокого обучения сети U-Net для семантической сегментации изображений в различных условиях облачности и земной поверхности (Temimi et al., 2023). Обнаруживаются такие классы, как вода, земля, растительность, снег, речной лёд, облака и тень облаков.

В работе (Zhang et al., 2023) отмечается важность сегментации речного льда, которая позволяет предоставлять информацию для прогнозирования стихийных бедствий. В этой

публикации предлагается нейронная сеть для семантической сегментации речного льда в режиме реального времени под названием FastICENet.

Основной сложностью применения методов глубокого обучения становится отсутствие достаточного количества данных о ледовой обстановке на внутренних водоёмах для тренировки нейронной сети. Для решения данной проблемы можно использовать съёмку на малых высотах, например, полученных с беспилотных летательных аппаратов с применением алгоритма семантической сегментации RININet. Данное решение позволило создать базу данных изображений льда, которая может быть использована для оценки рисков образования ледяных заторов (Zhao et al., 2024).

Недостаточное количество данных о речном льде в северной части России делает актуальным создание базы данных основных характеристик речного льда. С помощью снимков спектрорадиометра среднего разрешения MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer) были получены данные о суточном колебании характеристик речного льда для улучшения понимания пространственно-временного поведения северных рек на основе анализа данных за 19 лет на примере реки Енисей (Zhang et al., 2024).

Цель данного исследования состоит в разработке подхода для обнаружения ледовых явлений на реке Коле, расположенной в северной части Кольского полуострова. Для анализа используются снимки PCA Sentinel-1, полученные в период 2017–2018 гг. Детектирование ледового явления осуществляется для выбранного участка реки Колы, для которого имеются данные натурных наблюдений. Для каждого пикселя изображения русла реки рассчитывается вероятность обнаружения в нём льда, а ледовое явление определяется как общая картина вероятности всех пикселей изображения. Оценка ледовой обстановки на выбранном участке реки реализуется методом классификации с использованием искусственной нейронной сети.

Река Кола в Мурманской области

Река Кола — одна из рек Кольского полуострова, являющихся потенциальным источником опасных явлений. По данным МЧС наибольшее количество зафиксированных зон затопления присутствуют именно вдоль русла реки Колы.

Протекает Кола через одноимённый город и впадает в Кольский залив Баренцева моря. Длина реки составляет около 83 км, а площадь водосборного бассейна — около 3850 км². Реки Мурманской области питаются преимущественно за счёт талых вод и дождей, что делает их особенно уязвимыми к изменениям погодных условий (Агафонова и др., 2016).

В качестве объекта для анализа был выбран участок русла реки Колы в районе гидропоста (1429 км Октябрьской железной дороги), так как именно на его территории фиксируются данные ежедневных натурных наблюдений высоты воды и типа ледового явления на поверхности реки (*рис. 1*, красной точкой указано местоположение гидропоста).




Рис. 1. Зона наблюдения гидропоста 1429 км (река Кола)

Реки Мурманской области не очень широкие, ширина реки Колы до 150 м, что предъявляет дополнительные требования к пространственному разрешению спутниковых снимков.

Данные для анализа

В настоящем исследовании обнаружение ледовых явлений на реке Коле осуществлялось на основе анализа снимков PCA Sentinel-1. Микроволновый диапазон измерений позволяет интерпретировать снимки PCA независимо от основных ограничений Арктического региона, включающих частую облачность и отсутствие солнечного освещения в периоды полярной ночи. Разрешение PCA Sentinel-1 в режиме широкой полосы обзора EWS (*англ.* Extra Wide Swath) (ширина 400 км) достигает 40 м, в режиме интерферометрический широкозахватный IW (*англ.* Interferometric Wide Swath) (ширина 250 км) — 10 м. Регулярность данных измерений одного инструмента (время повторной съёмки выбранного участка (*англ.* revisiting time)) для отслеживания динамики ледовых процессов составляет четыре-пять дней (Geudtner, Torres, 2012).

В течение 2015 г. данные поступали только с одного спутника Sentinel-1A. С октября 2016 г. добавились данные со спутника Sentinel-1B, что значительно увеличило количество получаемых снимков и сократило revisiting time для наблюдения анализируемого района. В настоящем исследовании использовались спутниковые снимки Sentinel-1A, -1B за 2017–2018 гг. с фрагментом зоны действия гидропоста 1429 км Октябрьской железной дороги.

В анализе применялись данные Sentinel-1, полученные в режиме IW с двойной поляризацией VV + VH (V, *англ.* vertical; H, *англ.* horizontal).

После выбора и скачивания снимков Sentinel-1, доступных на веб-платформе Copernicus Open Access Hub (<https://scihub.copernicus.eu/>), осуществлялась их предобработка с помощью сопроводительного программного обеспечения SNAP (*англ.* Sentinel Application Platform) (<https://step.esa.int/main/download/snap-download/>). Подготовка спутниковых снимков к дальнейшему анализу включала в себя набор последовательно выполняемых операций (Filipponi, 2019):

1. Корректировка информации о точном положении и скорости спутника в момент съёмки на основе применения файла орбиты (*англ.* Apply-Orbit-File), помогающая исправить искажения, вызванные движением спутника во время съёмки.
2. Удаление термического шума (*англ.* Thermal Noise Removal) для улучшения качества изображений и точности анализа.
3. Калибровка (*англ.* Calibration), включающая коррекцию атмосферных и геометрических искажений.
4. Фильтрация шума для улучшения визуального качества изображений (*англ.* Speckle-Filter) с использованием спекл-фильтра Ли с окном размером 3×3 м.

Для выделения на снимке области, соответствующей имеющимся натурным наблюдениям, был создан shape-файл в программе QGIS (*англ.* Quantum Geographic Information System) (<https://qgis.org/>). Область включает только русло реки с отступлением от берега порядка 10–15 м, поэтому такое ледовое явление, как забереги, не включается в анализ. Данное исключение связано со сложностью детектирования территории, близкой к берегу, так как соответствующие пиксели могут содержать как лёд, так и береговой грунт.

После выполнения обработки в SNAP данные экспортировались в txt-файл с учётом наложения shape-файла и сохранялись в указанной пользователем директории. Структура txt-файла каждого анализируемого изображения включает в себя следующие поля: Pixel-X, Pixel-Y, Longitude, Latitude, Sigma0_VH, Sigma0_VV. Для дальнейшего анализа данные Sigma0_VH, Sigma0_VV переводились в децибелы (дБ).

Таким образом, каждый файл содержит данные коэффициентов рассеяния, соответствующие пикселям выделенного фрагмента русла реки. Все пиксели одинаково упорядочены в соответствии с расположением на изображении. Количество пикселей в каждом файле варьируется в диапазоне от 1689 до 2366.

С учётом попадания региона интереса на снимок в течение 2017 г. удалось подготовить и использовать для анализа 181 файл, в 2018 г. — 341 файл (с учётом получения нескольких снимков за одни сутки).

Методы и инструменты

Использование радиолокационных данных лежит в основе многих исследований, позволяющих провести классификацию ледовых явлений на внутренних водоёмах (Łoś, Pawłowski, 2017; Stonevicius et al., 2022).

Спутниковые данные дают возможность получить значения коэффициентов обратного рассеяния с поляризацией VV и VH в каждом пикселе изображения анализируемого участка реки. Отображение значений σ_{0VV} или σ_{0VH} в каждом пикселе, привязанном к географическим координатам, позволяет сформировать общую картину русла реки в различные сезоны, например, в состояниях ледостава (рис. 2а, б) или открытой воды (см. рис. 2в, г). Отдельно стоящей точкой на рисунке изображается местоположение гидропоста в координатах (68,8333° с. ш.; 33,0833° в. д.) (по данным <https://allrivers.info/gauge/kola-1429-km>).




Рис. 2. Визуализация значений σ_{0VV} и σ_{0VH} для состояний ледостава (5 февраля 2018 г.) (а, б) и открытой воды (9 августа 2018 г.) (в, г)

Однако воспользоваться построенной визуализацией (см. *рис. 2*) для определения типа ледового явления затруднительно: масштаб цветовой шкалы разный, диапазоны значений отличаются. Кроме того, поверхность цветного изображения не выглядит однородной, несмотря на то что зимний снимок должен содержать только пиксели льда, а летний — пиксели открытой воды. Это связано с особенностями поляризационных режимов изображений РСА, что если, например, нет ветра, то вода имеет низкие значения обратного рассеяния, а лёд — высокие. Но как только появляется ветер, уровень сигнала для льда и воды может стать одинаковым, особенно на ко-поляризации. Или же вновь образовавшийся лёд имеет такие же значения обратного рассеяния, что и открытая вода (Surdu et al., 2015). Указанные особенности затрудняют идентификацию ледового явления.

В настоящей работе для детектирования льда в пикселе изображения предлагается использовать модель логистической регрессии, которая даёт возможность, учитывая оба коэффициента σ_{0VV} и σ_{0VH} , вычислить вероятность определения льда в отдельном пикселе. Данный подход позволяет обнаруживать ледовый сигнал даже в пикселях, содержащих смесь льда и открытой водной поверхности (Stonevicius et al., 2022).

Логистическая регрессия — это метод машинного обучения, дающий возможность классифицировать бинарную зависимую переменную на основе одной или нескольких независимых переменных.

Построение модели логистической регрессии использует формулу, в которой линейная комбинация входных признаков переводится в вероятность принадлежности объекта к одному из двух классов (лёд или вода):

$$\log\left(\frac{p}{1-p}\right) = \beta_0 + \beta_{VV} \sigma_{0VV} + \beta_{VH} \sigma_{0VH},$$

где β_0 , β_{VV} , β_{VH} — параметры модели; p — вероятность льда; σ_{0VV} — коэффициент рассеяния в поляризации VV; σ_{0VH} — коэффициент рассеяния в поляризации VH.

Для определения параметров модели β_0 , β_{VV} , β_{VH} в качестве обучающего множества были взяты 32 снимка летнего периода (05.07–31.08.2018), когда на поверхности реки гарантирована была вода, и 32 снимка зимнего периода (27.01–30.03.2018), когда можно фиксировать в каждом пикселе изображения лёд. К данным был применён фильтр по выбросам. В результате составлено 32 набора, включающих показатели льда и воды, со средним количеством данных в каждом — 4184.

Используя алгоритм обучения модели логистической регрессии, для каждого подготовленного файла рассчитаны параметры модели β_0 , β_{VV} , β_{VH} (все параметры модели являются значимыми ($p > 0,01$)). Таким образом были получены 32 набора параметров β_0 , β_{VV} , β_{VH} .

Оценивая наборы по критерию Шапиро–Уилка, распределения β_0 ($p = 0,57$), β_{VV} ($p = 0,179$) и β_{VH} ($p = 0,246$) можно отнести к нормальным. Вариативность β_{VH} (среднее значение равно 0,08, стандартное отклонение — 0,159) по сравнению со средним значением является самой большой из всех параметров модели. При этом значение β_{VH} намного меньше, чем β_{VV} , что указывает на то, что его влияние на результат модели менее значительно. Вариативность β_0 (среднее значение составляет 25,773, стандартное отклонение — 8,939) и β_{VV} (среднее значение равно 1,312, стандартное отклонение — 0,427) сравнительно небольшая, что свидетельствует, что параметры модели более стабильны при различных данных обучения.

Учитывая вышесказанное, было решено в качестве параметров модели использовать средние значения полученных наборов: $\beta_0 = 25,773$, $\beta_{VV} = 1,312$, $\beta_{VH} = 0,08$.

В результате применения построенной логистической модели каждый txt-файл спутниковых данных получил новый столбец (Ice_Probability) с рассчитанной вероятностью обнаружения льда в каждом пикселе.

Задача классификации решалась с помощью полносвязной нейронной сети. Для обучающего множества использовались данные 522 снимков анализируемого участка реки Колы в зоне гидропоста 1429 км Октябрьской железной дороги. По каждому снимку рассчитанный с использованием модели логистической регрессии попиксельный набор вероятности обна-

ружения льда образует входной вектор нейронной сети. Выходные данные определяются имеющимися данными натурных наблюдений.

В качестве архитектуры нейронной сети была использована MLP (*англ.* multilayer perceptron, многослойный персептрон). Она имеет входной, выходной слой и два скрытых слоя. Первый скрытый слой представлен 128 нейронами, второй имеет 64. Везде используется функция активации ReLU (*англ.* Rectified Linear Unit), которая помогает избежать проблемы затухающих градиентов и ускоряет обучение модели.

Размер входного слоя определяется размером входного вектора после выравнивания (*англ.* padding). Этот размер соответствует количеству элементов в векторах Ice_Probability (в данном исследовании — 2242).

Выходной слой имеет количество нейронов, равное числу уникальных классов, и функцию активации softmax для многоклассовой классификации. Выходной слой с softmax-активацией обеспечивает нормализованную вероятность для каждого класса, что упрощает задачу классификации.

Так же был использован оптимизатор Adam (*англ.* Adaptive Moment Estimation), который сочетает в себе преимущества методов AdaGrad и RMSProp и обеспечивает быстрое и надёжное обучение.

Выбор архитектуры MLP был сделан в виду небольшого обучающего набора данных и возможности лёгкой адаптации и расширения модели, например, при добавлении нового слоя или изменении количества нейронов в существующих слоях для улучшения производительности.

В табл. 1 представлены полученные значения метрик качества классификации.

Таблица 1. Основные метрики обучения архитектуры MLP

Архитектура	Общая точность	Точность	Полнота	Оценка
MLP	80,95	81,53	80,95	81,18

По окончании обучения происходит сохранение весов модели, что позволяет использовать обученную модель без необходимости повторного обучения.

Результаты и обсуждения

Для анализа ледового режима на реках Мурманской области были разработаны программные модули подготовки спутниковых данных к анализу, реализации методов машинного обучения, анализа спутниковых данных и визуализации полученных результатов.

В процессе анализа использовались данные натурных наблюдений в зоне гидропоста 1429 км Октябрьской железной дороги, а также данные еженедельных отчётов гидрометслужбы о состоянии водных объектов в Мурманской области за 2018 г.

В анализе участвовали данные за 2017 г. — 169 наблюдений (количество дней, когда были получены спутниковые снимки); за 2018 г. — 226 наблюдений; всего — 395 наблюдений, основанных на 522 снимках (с учётом получения нескольких снимков за один день).

На рис. 3 (см. с. 125) представлена визуализация вероятностного представления исследуемой области русла реки Колы в различные календарные сезоны. Рисунок организован так, что каждая цветная точка соответствует пикселю изображения русла реки в конкретных географических координатах и имеет цветовое значение вычисленной вероятности обнаружения льда, определяемое по представленной шкале.

Шкала, используемая для определения вероятности, имеет градацию от голубого — маловероятно — до розового — высокая вероятность. По данным наблюдений 9 февраля 2018 г. фиксировался ледостав (см. рис. 3а), 9 мая 2018 г. — затор выше гидропоста (см. рис. 3б), 29 июля 2018 г. — открытая вода (см. рис. 3в), 20 ноября 2018 г. — неполный ледостав

(см. рис. 3г). Включение в летние данные отдельных пикселей, определённых как лёд, означает некорректные значения коэффициентов рассеивания от фрагментов берега или обмелевшего дна.




Рис. 3. Вероятность обнаружения льда в районе гидропоста 1429 км по данным Sentinel-1: а — 9 февраля 2018 г.; б — 9 мая 2018 г.; в — 29 июля 2018 г.; г — 20 ноября 2018 г.

Для реализации алгоритмов классификации полученным вероятностным векторам необходимо сопоставить тип ледового явления на основе имеющихся натурных наблюдений.

В табл. 2 приведены данные о типах природных явлений и количестве дней, когда они фиксировались в районе гидропоста (1429 км Октябрьской железной дороги) в период с января 2017 г. по декабрь 2018 г.

Анализ данных натурных наблюдений показывает, что наиболее часто встречающимися состояниями реки оказались ледостав и открытая вода. Другие состояния, будучи переходными между указанными, фиксируются значительно реже. И ещё реже попадают на спутниковый снимок.

Такая ситуация осложняет построение модели для автоматической классификации из-за несбалансированности классов.

Таблица 2. Данные по типам природных явлений

Природное явление	2017 г.	2018 г.
Ледостав	199 дней (01.01–16.05, 30.10–31.12)	178 дней (01.01–02.05, 29.10–14.11, 23.11–31.12)
Неполный ледостав	11 дней (17.05–22.05; 25.10–29.10)	15 дней (03.05–07.05; 26.10–28.10; 15.11–17.11; 19.11–22.11)
Затор выше поста	—	2 дня (08.05–09.05)
Затор ниже поста	3 дня (26.10–28.10), совпадает с неполным ледоставом	—
Сало	—	1 день (12.10)
Редкий ледоход	1 день (23.05)	2 дня (10.05–11.05)
Открытая вода	154 дня (24.05–24.10)	167 дней (12.05–25.10; 18.11)
Итого дней в году: межсезонье/лёд/вода	12/199/154	20/178/167

Однако процесс изменения покрова реки не происходит одновременно, и весенние ледовые явления завершают процесс вскрытия рек, а осенние ледовые явления начинают процесс замерзания в течение определённого периода, сроки и длительность которого зависят от текущей температуры воздуха, количества осадков и других гидрологических факторов (Козлов и др., 2015). Выделение указанных периодов особенно важно для предотвращения опасных ситуаций на внутренних водоёмах, когда лёд ещё недостаточно окреп или, наоборот, уже начал подтаивать.




Рис. 4. Среднесуточные значения рассчитанной вероятности обнаружения льда для каждого наблюдения в период с 04.01.2017 по 31.12.2018: голубой цвет — лёд, зелёный — открытая вода, красный — явления межсезонья (по табл. 2)

Анализ данных спутниковых наблюдений позволяет заметить указанные периоды. Для формирования обобщённой характеристики каждого наблюдения определим средние значения вероятности льда по пикселям каждого снимка. На рис. 4 представлена точечная диаграмма среднесуточных значений вероятностной характеристики спутниковых наблюдений по данным 2017 и 2018 гг. Основным признаком периодов межсезонья являются резкие колебания средних значений вероятности в подряд идущих данных наблюдений.

Ещё одним признаком ледовых явлений межсезонья можно считать возрастающую вариативность рассчитанной вероятности льда в пикселях каждого изображения. На *рис. 5* представлена информация о средней вероятности льда (столбиковая диаграмма голубого цвета), стандартном отклонении вероятности льда (столбиковая диаграмма оранжевого цвета) и среднесуточной температуре (график зелёного цвета) для каждого из имеющихся наблюдений 2017–2018 гг. Все данные приведены после обработки методом скользящего среднего с окном в 8 наблюдений с целью сглаживания случайных выпадов. Размер используемого окна находился экспериментально.




Рис. 5. Результаты обработки с помощью скользящего среднего с окном 8 наблюдений среднесуточных значений вероятности льда (голубые столбики), стандартного отклонения вероятности льда (оранжевые столбики), среднесуточной температуры воздуха (зелёная линия) за период 2017–2018 гг.

Определение на совместной диаграмме (см. *рис. 5*) начала периода резких изменений в значениях как средней вероятности выявления льда, так и рассчитанного для каждого наблюдения стандартного отклонения вероятности льда позволяет спрогнозировать с точностью в два-три дня возникновение ледовых явлений межсезонья. Дополнительную информацию дают и данные о среднесуточной температуре воздуха, а именно переход через нулевую отметку, что соответствует погоде межсезонья. Используя указанные признаки, можно определить периоды межсезонья относительно данных натурных наблюдений явлений межсезонья.

В данном случае период вскрытия реки в 2017 г. можно выявить с 22 апреля по 2 июня (33–49 наблюдения), период замерзания реки в 2017 г. — с 20 октября по 11 декабря (128–139 наблюдения); период вскрытия реки в 2018 г. — с 11 апреля по 15 мая (227–247 наблюдения), период замерзания реки в 2018 г. — с 25 октября по 11 декабря (351–381 наблюдения). Длительность последнего периода объясняется достаточно тёплой погодой в данный сезон 2018 г. Среднее значение температуры воздуха в период с 23.10 по 31.12 составляло $-2,7^{\circ}\text{C}$, имелось только четыре дня, когда температура воздуха опускалась ниже -10°C , зато часто подходила к нулевой отметке и даже поднималась выше нуля. Соответствующая информация отражена в отчётах гидрологической службы. Отмечается, что на плёсах рек, озёрах и большинстве водохранилищ наблюдается ледостав, ледостав с полыньями. На порожистых участках рек и на горных реках — забереги, неполный ледостав. Толщина льда 10 декабря на реках и водоёмах была от 8 до 22 см, что на 5–20 см меньше нормы и прошлого года.

Таким образом, описанный анализ представленных характеристик позволяет провести разметку подготовленных спутниковых данных для создания обучающего множества модели классификации.

Для оценки ледовой обстановки на реке можно поставить задачу классификации на три группы: ледостав, открытая вода и межсезонье, и попытаться решить её с помощью обученной нейронной сети, описанной в предыдущем разделе.

Тестовая выборка, случайным образом выделенная из обучающего множества, включала 105 снимков. Результаты классификации, представленные в *табл. 3*, показывают, что сеть достаточно хорошо определяет классы ледостав и открытая вода, намного хуже определяется межсезонье (ошибка 50 %). Такая ситуация объясняется недостаточной сбалансированностью текущих данных. Расширение базы данных наблюдений в дальнейшем позволит улучшить показатели точности представленной модели.

Таблица 3. Результаты анализа тестовой выборки спутниковых данных

Класс	Всего снимков	Количество классифицированных		Точность, %
		правильно	неправильно	
Ледостав	35	26	9	74,3
Открытая вода	48	39	9	81,2
Межсезонье	22	11	11	50,0

В целом использование модели полносвязной нейронной сети имеет хороший потенциал в решении задач анализа спутниковых данных, так как позволяет в процессе обучения адаптироваться к особенностям получаемых значений характеристик, привязанных к пикселям изображений.

Заключение

В результате проведённого исследования разработана программная реализация методов машинного обучения для анализа спутниковых снимков Sentinel-1. Была оценена эффективность использования данного подхода для обнаружения ледовых явлений на участке русла реки Колы, наиболее подверженной чрезвычайным ситуациям.

Проведённый анализ спутниковых данных позволил выделить признаки ледовых явлений, формируемых на поверхности реки, на основе использования модели логистической регрессии. Разработан механизм разметки подготовленных спутниковых данных для создания обучающего множества модели классификации. Все ледовые явления были разбиты на три класса: ледостав, открытая вода и межсезонье. Проведена апробация автоматической классификации основных ледовых явлений с помощью модели нейронной сети. Повышение точности классификации ледовых явлений возможно при накоплении достаточного количества данных о таких явлениях и обеспечении сбалансированности классов обучающей выборки.

Предлагаемое программное решение может стать основой для создания инструмента мониторинга ледового режима и на других участках рек Мурманской области.

Ближайшим направлением развития данного исследования станет разработка аналогичных решений для данных с отечественных спутников «Кондор-ФКА», обладающих радиолокационной аппаратурой. Обеспечение регулярного покрытия контролируемой территории позволит использовать предлагаемый инструмент в практической деятельности сотрудников МЧС.

Исследования, представленные в настоящей статье, выполнены при финансовой поддержке гранта Российского научного фонда № 24-17-20021 (<https://rscf.ru/project/24-17-20021/>) «Создание регионального портала мониторинга опасных явлений природного и антропогенного происхождения Мурманской области на основе данных спутникового дистанционного зондирования и беспилотных авиационных систем».

Литература

1. Агафонова С. А., Фролова Н. Л., Василенко А. Н., Широкова В. А. Ледовый режим и опасные гидрологические явления на реках арктической зоны европейской территории России // Вестн. Московского ун-та. Сер. 5. География. 2016. № 6. С. 41–49.
2. Козлов Д. В., Бузин В. А., Фролова Н. Л., Агафонова С. А., Бабурин В. Л., Банищикова Л. С., Горошкова Н. И., Завадский А. С., Крыленко И. Н., Савельев К. Л., Козлов К. Д., Бузина Л. Ф. Опасные ледовые явления на реках и водохранилищах России: моногр. / под общ. ред. Д. В. Козлова. М.: Изд-во РГАУ-МСХА имени К. А. Тимирязева, 2015. 348 с.
3. Михайлюкова П. Г., Агафонова С. А., Фролова Н. Л. Анализ ледовой обстановки на реке Сухона (у г. Великий Устюг) по радиолокационным снимкам // Современные проблемы дистанционного зондирования Земли из космоса. 2020. Т. 17. № 2. С. 162–175. DOI: 10.21046/2070-7401-2020-17-2-162-175.
4. Шилин Б. В., Кузнецов А. Ю. Место видеоспектральной съёмки среди методов дистанционного зондирования // Современные проблемы дистанционного зондирования Земли из космоса. 2022. Т. 19. № 1. С. 9–24. DOI: 10.21046/2070-7401-2022-19-1-9-24.
5. Abdelkader M., Bravo Mendez J. H., Temimi M. et al. Google Earth Engine platform to integrate multi-satellite and citizen science data for the monitoring of river ice dynamics // Remote Sensing. 2024. V. 16. No. 8. Article 1368. DOI: 10.3390/rs16081368.
6. Beaton A., Whaley R., Corston K., Kenny F. Identifying historic river ice breakup timing using MODIS and Google Earth Engine in support of operational flood monitoring in Northern Ontario // Remote Sensing of Environment. 2019. V. 224. P. 352–364. DOI: 10.1016/j.rse.2019.02.011.
7. Chaouch N., Temimi M., Romanov P. et al. An automated algorithm for river ice monitoring over the Susquehanna River using the MODIS data // Hydrological Processes. 2014. V. 28. Iss. 1. P. 62–73. DOI: 10.1002/hyp.9548.
8. Chu T., Lindenschmidt K.-E. Integration of space-borne and air-borne data in monitoring river ice processes in the Slave River, Canada // Remote Sensing of Environment. 2016. V. 181. P. 65–81. DOI: 10.1016/j.rse.2016.03.041.
9. Filipponi F. Sentinel-1 GRD preprocessing workflow // Proceedings. 2019. V. 18. No. 1. Article 11. 4 p. DOI: 10.3390/ECRS-3-06201.
10. Fuks M. Assessment of the impact of dam reservoirs on river ice cover — an example from the Carpathians (central Europe) // The Cryosphere. 2024. V. 18. Iss. 5. P. 2509–2529. DOI: 10.5194/tc-18-2509-2024.
11. Gatto L. W. Monitoring river ice with Landsat images // Remote Sensing of Environment. 1990. V. 32. No. 1. P. 1–16. DOI: 10.1016/0034-4257(90)90094-3.
12. Geudtner D., Torres R. Sentinel-1 system overview and performance // IEEE Intern. Geoscience and Remote Sensing Symp. 2012. P. 1719–1721. DOI: 10.1109/IGARSS.2012.6351191.
13. Heinilä K., Mattila O.-P., Metsämäki S. et al. A novel method for detecting lake ice cover using optical satellite data // Intern. J. Applied Earth Observation and Geoinformation. 2021. V. 104. Article 102566. DOI: 10.1016/j.jag.2021.102566.
14. Hicks F. An overview of river ice problems: CRIPE07 guest editorial // Cold Regions Science and Technology. 2009. V. 55. No. 2. P. 175–185. DOI: 10.1016/j.coldregions.2008.09.006.
15. Li Z., Lindenschmidt K.-E. Coherence of Radarsat-2, Sentinel-1, and ALOS-1 PALSAR for monitoring spatiotemporal variations of river ice covers // Canadian J. Remote Sensing. 2018. V. 44. No. 1. P. 11–25. DOI: 10.1080/07038992.2018.1419424.
16. Liu B., Ji H., Zhai Y., Luo H. Estimation of River Ice Thickness in the Shisifenzi reach of the Yellow River with remote sensing and air temperature data // IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing. 2023. V. 16. P. 5645–5659. DOI: 10.1109/JSTARS.2023.3285229.
17. Łoś H., Pawłowski B. The use of Sentinel-1 imagery in the analysis of river ice phenomena on the lower Vistula in the 2015–2016 winter season // 2017 Signal Processing Symp. (SPSymo). 2017. P. 1–5. DOI: 10.1109/SPS.2017.8053663.
18. Moalemi I., Kheyrollah Pour H., Scott K. A. Assessing ice break-up trends in Slave River Delta through satellite observations and random forest modeling // Remote Sensing. 2024. V. 16. No. 12. Article 2244. DOI: 10.3390/rs16122244.
19. Newton B., Beltaos S., Burrell B. C. Ice regimes, ice jams, and a changing hydroclimate, Saint John (Wolastoq) River, New Brunswick, Canada // Natural Hazards. 2024. V. 120. P. 12613–12642. DOI: 10.1007/s11069-024-06736-5.
20. Purnell D., Dabboor M., Matte P. et al. Observations of river ice breakup using GNSS-IR, SAR, and machine learning // IEEE Trans. Geoscience and Remote Sensing. 2024. V. 62. P. 1–13. DOI: 10.1109/TGRS.2024.3380554.

21. Richards E., Stuefer S., Correa Rangel R. et al. An evaluation of GPR monitoring methods on varying river ice conditions: A case study in Alaska // *Cold Regions Science and Technology*. 2023. V. 210. Article 103819. DOI: 10.1016/j.coldregions.2023.103819.
22. Singh A., Ray N., Loewen M., Ray N. River ice segmentation with deep learning // *IEEE Trans. Geoscience and Remote Sensing*. 2020. V. 58. No. 11. P. 7570–7579. DOI: 10.1109/TGRS.2020.2981082.
23. Sobiech J., Dierking W. Observing lake- and river-ice decay with SAR: advantages and limitations of the unsupervised k-means classification approach // *Annals of Glaciology*. 2013. V. 54. No. 62. P. 65–72. DOI: 10.3189/2013AoG62A037.
24. Sola D., Scott K.A. Efficient shallow network for river ice segmentation // *Remote Sensing*. 2022. V. 14. No. 10. Article 2378. DOI: 10.3390/rs14102378.
25. Stonevicius E., Uselis G., Grendaite D. Ice detection with Sentinel-1 SAR backscatter threshold in long sections of temperate climate rivers // *Remote Sensing*. 2022. V. 14. No. 7. Article 1627. DOI: 10.3390/rs14071627.
26. Surdu C.M., Duguay C.R., Kheyrollah Pour H., Brown L. C. Ice freeze-up and break-up detection of shallow lakes in Northern Alaska with spaceborne SAR // *Remote Sensing*. 2015. V. 7. No. 5. P. 6133–6159. DOI: 10.3390/rs70506133.
27. Temimi M., Abdelkader M., Tounsi A. et al. An automated system to monitor river ice conditions using Visible Infrared Imaging Radiometer Suite imagery // *Remote Sensing*. 2023. V. 15. No. 20. Article 4896. DOI: 10.3390/rs15204896.
28. Vuyovich C.M., Daly S.F., Gagnon J.J. et al. Monitoring river ice conditions using web-based cameras // *J. Cold Regions Engineering*. 2009. V. 23. No. 1. P. 1–17. DOI: 10.1061/(ASCE)0887-381X(2009)23:1(1).
29. Yang X., Pavelsky T.M., Allen G.H. The past and future of global river ice // *Nature*. 2020. V. 577. No. 7788. P. 69–73. DOI: 10.1038/s41586-019-1848-1.
30. Zhang X., Zhao Z., Ran L. et al. FastICENet: A real-time and accurate semantic segmentation model for aerial remote sensing river ice image // *Signal Processing*. 2023. V. 212. Article 109150. DOI: 10.1016/j.sigpro.2023.109150.
31. Zhang Y., Qiu Y., Li Y. et al. Spatial-temporal variation of river ice coverage in the Yenisei river from 2002 to 2021 // *J. Hydrology*. 2024. V. 637. Article 131440. DOI: 10.1016/j.jhydrol.2024.131440.
32. Zhao W., Xue Y., Han F. et al. Research on semantic segmentation algorithm of high latitude urban river ice based on deep transfer learning // *Intern. J. Remote Sensing*. 2024. V. 45. No. 13. P. 4278–4299. DOI: 10.1080/01431161.2024.2360695.

Analysis of satellite data on ice conditions on rivers in Murmansk Region using machine learning: The case of the Kola River

I. M. Lazareva¹, E. V. Zabolotskikh², O. I. Lyash¹, G. S. Shelegov³

¹ *Murmansk Arctic University, Murmansk 183038, Russia*
E-mails: lazareva.im@mauniver.ru, lyash.oi@mauniver.ru

² *Russian State Hydrometeorological University, Saint Petersburg 192007, Russia*
E-mail: liza@rshu.ru

³ *EMERCOM Main Office for Murmansk Region, Murmansk 183053, Russia*
E-mail: glebsorta@gmail.com

Complex climatic conditions in the Arctic region influence the process of ice cover formation in northern rivers. Monitoring ice conditions is an important component of systems designed to prevent dangerous phenomena on inland water bodies, such as floods, high water levels and early ice formation. Synthetic aperture radar images from the Sentinel-1 satellite platform were used to assess ice conditions on rivers in Murmansk Region. The section of the Kola River near the gauging station at 1429 km of the Oktyabrskaya Railway, for which field observation data are available, was analyzed. A logistic regression model built using backscatter data from VV and VH polarizations made it possible to determine the probability of ice appearance in each pixel of the image of the analyzed river section, as well as to visualize the patterns of ice formation. The task of classifying ice phenomena was addressed using a fully connected multilayer perceptron (MLP) neural network. The choice of this architecture was due to the relatively small size of the training sample and the flexibility it offers in terms of adapta-

tion and extension, for instance, by adding new layers or adjusting the number of neurons in existing layers to improve performance. The model was trained to classify three categories: ice drift, open water, and off-season ice events. As part of the research, software modules were developed to analyze Sentinel-1A, -1B satellite images for detecting ice phenomena on rivers in Murmansk Region. Future work will focus on adapting the toolkit to utilize data from Russian satellites.

Keywords: satellite data analysis, Sentinel-1, river ice phenomena, machine learning methods, Arctic region

Accepted: 20.06.2025

DOI: 10.21046/2070-7401-2025-22-4-118-132

References

1. Agafonova S.A., Frolova N.L., Vasilenko A.N., Shirocova V.A., Ice regime and dangerous hydrological phenomena on rivers of the arctic zone of European Russia, *Vestnik Moskovskogo universiteta. Ser. 5. Geografiya*, 2016, No. 6, pp. 41–49 (in Russian).
2. Kozlov D.V., Buzin V.A., Frolova N.L., Agafonova S.A., Baburin V.L., Banshchikova L.S., Goroshkova N.I., Zavadskij A.S., Krylenko I.N., Savel'ev K.L., Kozlov K.D., Buzina L.F., *Opasnye ledovye yavleniya na rekakh i vodokhranilishchakh Rossii: Monografiya* (Dangerous ice phenomena on rivers and reservoirs of Russia: Monograph), D.V. Kozlov (ed.), Moscow: Izd. RGAU-MSKHA imeni K.A. Timiryazeva, 2015, 348 p. (in Russian).
3. Mikhaylyukova P.G., Agafonova S.A., Frolova N.L., Analysis of ice situation on the Sukhona River (near the town of Veliky Ustyug) based on SAR imagery, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2020, V. 17, No. 2, pp. 162–175 (in Russian), DOI: 10.21046/2070-7401-2020-17-2-162-175.
4. Shilin B.V., Kuznetsov A.Y., Place of video spectral imaging among remote sensing methods, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, V. 19, No. 1, pp. 9–24 (in Russian), DOI: 10.21046/2070-7401-2022-19-1-9-24.
5. Abdelkader M., Bravo Mendez J.H., Temimi M. et al., Google Earth Engine platform to integrate multi-satellite and citizen science data for the monitoring of river ice dynamics, *Remote Sensing*, 2024, V. 16, No. 8, Article 1368, DOI: 10.3390/rs16081368.
6. Beaton A., Whaley R., Corston K., Kenny F., Identifying historic river ice breakup timing using MODIS and Google Earth Engine in support of operational flood monitoring in Northern Ontario, *Remote Sensing of Environment*, 2019, V. 224, pp. 352–364, DOI: 10.1016/j.rse.2019.02.011.
7. Chaouch N., Temimi M., Romanov P. et al., An automated algorithm for river ice monitoring over the Susquehanna River using the MODIS data, *Hydrological Processes*, 2014, V. 28, Iss. 1, pp. 62–73, DOI: 10.1002/hyp.9548.
8. Chu T., Lindenschmidt K.-E., Integration of space-borne and air-borne data in monitoring river ice processes in the Slave River, Canada, *Remote Sensing of Environment*, 2016, V. 181, pp. 65–81, DOI: 10.1016/j.rse.2016.03.041.
9. Fukuš M., Assessment of the impact of dam reservoirs on river ice cover — an example from the Carpathians (central Europe), *The Cryosphere*, 2024, V. 18, Iss. 5, pp. 2509–2529, DOI: 10.5194/tc-18-2509-2024.
10. Gatto L.W., Monitoring river ice with Landsat images, *Remote Sensing of Environment*, 1990, V. 32, No. 1, pp. 1–16, DOI: 10.1016/0034-4257(90)90094-3.
11. Geudtner D., Torres R., Sentinel-1 system overview and performance, *IEEE Intern. Geoscience and Remote Sensing Symp.*, 2012, pp. 1719–1721, DOI: 10.1109/IGARSS.2012.6351191.
12. Heinilä K., Mattila O.-P., Metsämäki S. et al., A novel method for detecting lake ice cover using optical satellite data, *Intern. J. Applied Earth Observation and Geoinformation*, 2021, V. 104, Article 102566, DOI: 10.1016/j.jag.2021.102566.
13. Hicks F., An overview of river ice problems: CRIPE07 guest editorial, *Cold Regions Science and Technology*, 2009, V. 55, No. 2, pp. 175–185, DOI: 10.1016/j.coldregions.2008.09.006.
14. Li Z., Lindenschmidt K.-E., Coherence of Radarsat-2, Sentinel-1, and ALOS-1 PALSAR for monitoring spatiotemporal variations of river ice covers, *Canadian J. Remote Sensing*, 2018, V. 44, No. 1, pp. 11–25, DOI: 10.1080/07038992.2018.1419424.
15. Liu B., Ji H., Zhai Y., Luo H., Estimation of river ice thickness in the Shisifenzi reach of the Yellow River with remote sensing and air temperature data, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, V. 16, pp. 5645–5659, DOI: 10.1109/JSTARS.2023.3285229.
16. Łoś H., Pawłowski B., The use of Sentinel-1 imagery in the analysis of river ice phenomena on the lower Vistula in the 2015–2016 winter season, *2017 Signal Processing Symp. (SPSymposium)*, 2017, pp. 1–5, DOI: 10.1109/SPS.2017.8053663.

17. Moalemi I., Kheyrollah Pour H., Scott K. A., Assessing ice break-up trends in Slave River Delta through satellite observations and random forest modeling, *Remote Sensing*, 2024, V. 16, No. 12, Article 2244, DOI: 10.3390/rs16122244.
18. Newton B., Beltaos S., Burrell B. C., Ice regimes, ice jams, and a changing hydroclimate, Saint John (Wolastoq) River, New Brunswick, Canada, *Natural Hazards*, 2024, V. 120, pp. 12613–12642, DOI: 10.1007/s11069-024-06736-5.
19. Purnell D., Dabboor M., Matte P. et al., Observations of river ice breakup using GNSS-IR, SAR, and machine learning, *IEEE Trans. Geoscience and Remote Sensing*, 2024, V. 62, pp. 1–13, DOI: 10.1109/TGRS.2024.3380554.
20. Richards E., Stuefer S., Correa Rangel R. et al., An evaluation of GPR monitoring methods on varying river ice conditions: A case study in Alaska, *Cold Regions Science and Technology*, 2023, V. 210, Article 103819, DOI: 10.1016/j.coldregions.2023.103819.
21. Singh A., Ray N., Loewen M., Ray N., River ice segmentation with deep learning, *IEEE Trans. Geoscience and Remote Sensing*, 2020, V. 58, No. 11, pp. 7570–7579, DOI: 10.1109/TGRS.2020.2981082.
22. Sobiech J., Dierking W., Observing lake- and river-ice decay with SAR: advantages and limitations of the unsupervised k-means classification approach, *Annals of Glaciology*, 2013, V. 54, No. 62, pp. 65–72, DOI: 10.3189/2013AoG62A037.
23. Sola D., Scott K. A., Efficient shallow network for river ice segmentation, *Remote Sensing*, 2022, V. 14, No. 10, Article 2378, DOI: 10.3390/rs14102378.
24. Stonevicius E., Uselis G., Grendaite D., Ice detection with Sentinel-1 SAR backscatter threshold in long sections of temperate climate rivers, *Remote Sensing*, 2022, V. 14, No. 7, Article 1627, DOI: 10.3390/rs14071627.
25. Surdu C. M., Duguay C. R., Kheyrollah Pour H., Brown L. C., Ice freeze-up and break-up detection of shallow lakes in Northern Alaska with spaceborne SAR, *Remote Sensing*, 2015, V. 7, No. 5, pp. 6133–6159, DOI: 10.3390/rs70506133.
26. Temimi M., Abdelkader M., Tounsi A. et al., An automated system to monitor river ice conditions using Visible Infrared Imaging Radiometer Suite imagery, *Remote Sensing*, 2023, V. 15, No. 20, Article 4896, DOI: 10.3390/rs15204896.
27. Vuyovich C. M., Daly S. F., Gagnon J. J. et al., Monitoring river ice conditions using web-based cameras, *J. Cold Regions Engineering*, 2009, V. 23, No. 1, pp. 1–17, DOI: 10.1061/(ASCE)0887-381X(2009)23:1(1).
28. Yang X., Pavelsky T. M., Allen G. H., The past and future of global river ice, *Nature*, 2020, V. 577, No. 7788, pp. 69–73, DOI: 10.1038/s41586-019-1848-1.
29. Zhang X., Zhao Z., Ran L. et al., FastICENet: A real-time and accurate semantic segmentation model for aerial remote sensing river ice image, *Signal Processing*, 2023, V. 212, Article 109150, DOI: 10.1016/j.sigpro.2023.109150.
30. Zhang Y., Qiu Y., Li Y. et al., Spatial-temporal variation of river ice coverage in the Yenisei river from 2002 to 2021, *J. Hydrology*, 2024, V. 637, Article 131440, DOI: 10.1016/j.jhydrol.2024.131440.
31. Zhao W., Xue Y., Han F. et al., Research on semantic segmentation algorithm of high latitude urban river ice based on deep transfer learning, *Intern. J. Remote Sensing*, 2024, V. 45, No. 13, pp. 4278–4299, DOI: 10.1080/01431161.2024.2360695.