

Автоматическая идентификация разрывов в морском ледяном покрове по снимкам спутника *Suomi NPP*

Е. Г. Бойкая, К. Г. Кортикова, Л. Н. Дымент, А. А. Ершова

Арктический и антарктический научно-исследовательский институт
Санкт-Петербург, 199397, Россия
E-mail: ldyment@aari.ru

В дрейфующем ледяном покрове арктических морей под действием динамических факторов образуются разрывы, протяжённость которых может достигать нескольких тысяч километров. Движение судна по попутным разрывам значительно повышает экономическую эффективность и безопасность плавания. В связи с этим информация о разрывах включается в состав гидрометеорологического обеспечения рейсов по Северному морскому пути. Изучение пространственной и временной изменчивости таких характеристик разрывов, как их преобладающая ориентация, протяжённость и плотность расположения на акватории, требует большого количества исходных данных. В настоящее время источником информации о разрывах служат снимки ИСЗ низкого пространственного разрешения. Однако методов автоматического дешифрирования, позволяющих по полученным данным рассчитать все основные характеристики разрывов, не существовало. В статье представлен метод автоматической идентификации разрывов на снимках ИСЗ *Suomi NPP* инфракрасного диапазона с пространственным разрешением 375 м. При разработке метода использовалась свёрточная нейронная сеть U-net. Обучение модели проводилось на данных ручного экспертного дешифрирования разрывов на 187 снимках ледяного покрова морей Лаптевых и Восточно-Сибирского за ледовые сезоны 2021–2024 гг. Коэффициент Жаккара составил 0,64, коэффициент Сёренсена–Дайса — 0,77. После обработки снимка моделью создаётся геопривязанное монохромное изображение идентифицированных разрывов. Затем по разработанному алгоритму проводится выделение отдельных объектов-разрывов. Каждый такой объект представляет собой последовательность отрезков, которые соответствуют относительно прямолинейным участкам разрыва. Географические координаты концов отрезков, заносимые в файл результатов, позволяют рассчитывать протяжённость и ориентацию каждого отдельного разрыва. Верификация разработанного метода проводилась на 30 снимках *Suomi NPP* ледяного покрова морей Лаптевых и Восточно-Сибирского, прошедших экспертное дешифрирование и не использованных при обучении модели. По данным автоматического и ручного дешифрирования были рассчитаны модальная ориентация и удельная длина разрывов, осреднённые по квадратам 100×100 км. Средняя величина различий в полученных значениях модальной ориентации составила 7°, а удельной длины разрывов — 15 м/км².

Ключевые слова: разрывы в ледяном покрове, арктические моря, автоматическое дешифрирование, спутниковые снимки, инфракрасный диапазон, нейросетевые технологии

Одобрена к печати: 18.09.2025
DOI: [10.21046/2070-7401-2025-22-6-43-51](https://doi.org/10.21046/2070-7401-2025-22-6-43-51)

Введение

Дрейфующий ледяной покров в арктических морях неоднороден. В результате динамических процессов в нём образуются протяжённые участки с открытой водой, со временем покрывающиеся молодым льдом. Данные элементы ледяного покрова называются разрывами. Их длина может достигать нескольких тысяч километров, а ширина — нескольких километров. Сформировавшиеся системы разрывов могут сохраняться в течение нескольких суток. Разрывы пронизывают моря в различных направлениях, образуя естественные магистрали для эффективного судоходства в Арктике. Таким образом, изучение разрывов представляет не только научный, но и экономический интерес.

В связи со значительными размерами разрывов наблюдение за ними осуществляется преимущественно по информации с искусственных спутников Земли (ИСЗ). Снимки с низким пространственным разрешением (ПР) позволяют единовременно охватить всё море, что даёт

возможность получить распределение по акватории таких характеристик разрывов, как преобладающая ориентация и плотность расположения. Для расчёта обобщённых характеристик требуются данные об ориентации и протяжённости каждого разрыва на снимке. На одном снимке количество разрывов может достигать 2–3 тыс., из-за чего процесс его обработки экспертом вручную занимает несколько часов. В свою очередь данные с ИСЗ поступают несколько раз за сутки. Таким образом, дешифрирование разрывов экспертом представляется крайне трудоёмким процессом. В связи с этим перед исследователями уже долгое время стояла задача корректной автоматической фиксации разрывов на снимках ИСЗ.

Варианты решения данной проблемы для снимков различных диапазонов представлены, например, в публикациях (Lee et al., 2018; Lindsay, Rothrock, 1995; Röhres, Kaleschke, 2012; Willmes, Heinemann, 2015). Работы (Hoffman et al., 2019, 2021; Reiser et al., 2020) посвящены идентификации разрывов на снимках оптического диапазона, при этом авторы предоставили результаты обработки большого количества снимков ИСЗ, позволяющие провести независимую верификацию их алгоритма.

Алгоритм (Reiser et al., 2020) идентифицирует разрывы на снимках инфракрасного диапазона спектрорадиометра MODIS (*англ. Moderate Resolution Imaging Spectroradiometer*) ИСЗ Terra/Aqua с ПР 1 км. В результате работы данного метода каждому пикселю ставится в соответствие одно из значений: разрыв, лёд, вода, суша, облако или артефакт. Таким образом, все выделенные на снимке разрывы представляют собой совокупность пикселей, а не набор отдельных объектов. Вследствие этого по полученным данным в дальнейшем нельзя рассчитать такую важную характеристику разрывов, как преобладающая ориентация. При определении плотности в пространстве данный алгоритм может давать завышенные результаты (Дымент и др., 2025), так как в качестве разрывов фиксируются также полыни и зоны повышенной раздробленности ледяного покрова. Аналогичные проблемы возникают и при попытке вычислить характеристики разрывов по методу (Hoffman et al., 2021).

В ходе обработки снимка ИСЗ по алгоритму (Hoffman et al., 2019) идентифицируемые разрывы представляют собой отдельные объекты, что позволяет провести расчёт большинства их характеристик. Алгоритм предназначен для дешифрирования разрывов на инфракрасных снимках ИСЗ Terra/Aqua с ПР 1 км. Однако согласно результатам верификации, проведённой авторами (Дымент и др., 2025), этот алгоритм крайне чувствителен к облачности. Полученные данные носят фрагментарный характер, что может привести к некорректным значениям рассчитанных по ним характеристик разрывов.

Таким образом, до настоящего времени не существовало метода, позволяющего так осуществлять автоматическое дешифрирование разрывов в дрейфующем ледяном покрове арктических морей по снимкам ИСЗ, чтобы по полученным данным была возможность расчитывать ориентацию и протяжённость каждого разрыва.

В настоящей статье изложен метод, позволяющий автоматически идентифицировать разрывы на снимках ИСЗ *Suomi NPP* оптического диапазона в отсутствии плотной облачности. Каждый разрыв при этом будет представлен как отдельный объект, определённый последовательностью координат концов прямолинейных отрезков, из которых состоит разрыв. Тем самым алгоритм позволит сформировать результаты в таком же виде, как и при экспертном дешифрировании.

Исходные данные

Разработанный алгоритм предназначен для автоматической идентификации разрывов в ледяном покрове по снимкам радиометра VIIRS (*англ. Visible Infrared Imaging Radiometer Suite*) ИСЗ *Suomi NPP*.

Снимки *Suomi NPP* находятся в свободном доступе, поступают регулярно, имеют ПР 375 м и позволяют охватить акваторию одного моря единовременно. В настоящее время альтернативы данным снимкам нет. Снимки радиометра MODIS спутников Terra и Aqua обладают аналогичными достоинствами в светлое время года, когда съёмка проводится в видимом диапазоне спектра (ПР = 250 м). Однако на протяжении большей части ледового сезона

в арктических морях (октябрь–февраль) снимки этих спутников информативны только в инфракрасном диапазоне с $\text{ПР} = 1 \text{ км}$, что позволяет фиксировать лишь самые крупные разрывы.

В Арктическом и антарктическом научно-исследовательском институте (ААНИИ) имеется собственный архив изображений арктического ледяного покрова, созданный на основе данных VIIRS ИСЗ Suomi NPP, получаемых с помощью спутниковой наземной станции Российской научной экспедиции на архипелаге Шпицберген (РАЭ-Ш) ААНИИ. Для создания изображений архива используются два спектральных канала VIIRS из группы Imagery (I) Bands с пространственным разрешением 375 м: канал I4 (3,55–3,93 мкм), относящийся к средневолновому инфракрасному диапазону, и канал I5 (10,5–12,4 мкм), относящийся к длинноволновому инфракрасному диапазону. Композитные трёхканальные изображения формируются путём объединения спектральных каналов I4 и I5 в комбинацию 554.

На протяжении нескольких лет в ААНИИ по изображениям из архива проводилось ручное экспертное дешифрирование разрывов в ледяном покрове морей Лаптевых и Восточно-Сибирского. В ходе ручного дешифрирования эксперт при помощи геоинформационной системы ArcMap фиксировал географические координаты концов относительно прямолинейных участков каждого разрыва. Полученные данные о разрывах заносились в архив в виде текстовых файлов данных и векторных слоёв (шнейп-файлов).

Информация о разрывах из архива данных ААНИИ использовалась при разработке алгоритма автоматической идентификации разрывов, а также при его верификации.

Разработка метода

Подготовка данных

Для создания метода автоматического дешифрирования разрывов применялись средства машинного обучения (нейросеть).

Для обучения модели использовались композитные изображения из архива данных ААНИИ. В обучающую выборку вошли 66 спутниковых снимков, охватывающих акваторию моря Лаптевых, и 121 снимок по Восточно-Сибирскому морю. Обучающая выборка включает снимки, сделанные в период с ноября по май 2021–2024 гг.

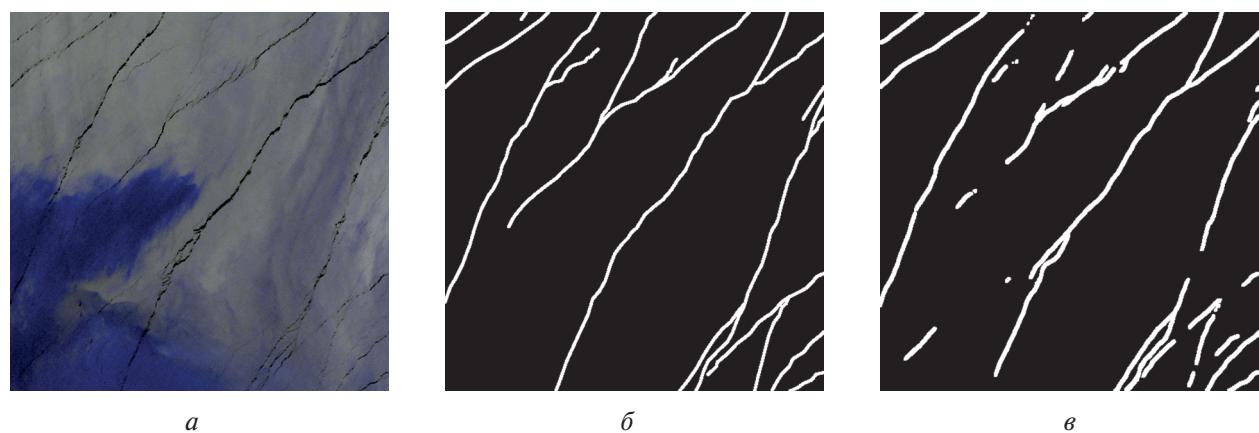


Рис. 1. Пример фрагмента исходного композитного изображения VIIRS размером 512×512 (а), соответствующая ему маска (б) и результаты, полученные моделью (в)

Данные о разрывах со снимков, вошедших в обучающую выборку, были преобразованы из шнейп-файлов в бинарные растровые маски, соответствующие исходным изображениям. Пикселям масок, соответствующим фону (отсутствию разрывов), присваивалось значение 0, а пикселям разрывов — значение 1. Перед подачей данных в свёрточную нейронную

сеть композитные изображения были нормализованы методом Min-Max Scaling, при котором значения пикселей каждого канала масштабировались в диапазон от 0 до 1. Далее изображения и соответствующие им маски были разбиты на фрагменты размером 512×512 пикселей с перекрытием 50 % (шаг 256 пикселей). Такая стратегия формирования фрагментов изображений позволяет увеличить объём обучающей выборки, а также снизить влияние артефактов, возникающих на границах фрагментов. Суша на исходных изображениях не маскировалась. Пример фрагмента композитного изображения и соответствующая ему маска представлены на *рис. 1а* и *б* (см. с. 45).

В процессе предобработки из выборки были удалены фрагменты полностью чёрных масок. Для обучения модели использовалась итоговая тренировочная выборка, состоящая из 22 422 пар изображений и соответствующих им масок, а также тестовая выборка из 5606 пар изображений и масок.

Разработка модели

Для решения задачи идентификации разрывов использовалась свёрточная нейронная сеть U-Net, которая продемонстрировала высокую эффективность при обработке изображений в задачах спутниковой сегментации. Обучение модели реализовано в Python с использованием фреймворка TensorFlow/Keras на GPU.

Модель обучалась с применением оптимизатора Adam с начальной скоростью обучения 0,0001. В качестве функции потерь использовалась функция потерь Дайса, которая хорошо работает с несбалансированными классами.

Для предотвращения переобучения применялась стратегия ранней остановки, при которой обучение прерывается, если семь эпох подряд не наблюдается улучшение функции потерь на тестовой выборке. Дополнительно использовался механизм адаптивного уменьшения скорости обучения, который снижал скорость обучения в пять раз при отсутствии улучшений на тестовой выборке в течение трёх эпох подряд. Минимальное значение скорости обучения ограничивалось величиной $1 \cdot 10^{-6}$. Для сохранения лучшей модели применялся вызов функции, фиксирующей веса модели с минимальным значением функции потерь на тестовых данных. В результате обучение модели было остановлено на 47-й эпохе с использованием стратегии ранней остановки, когда улучшение функции потерь на тестовом наборе перестало наблюдаться.

Для оценки качества сегментации применялись две метрики: коэффициент Жаккара (англ. *Intersection over Union* — IoU) и коэффициент Сёренсена—Дайса (Dice). На момент окончания обучения значения метрик на тестовом наборе показали следующие значения: IoU — 0,64, Dice — 0,77, функция потерь — 0,23 (*рис. 2*).

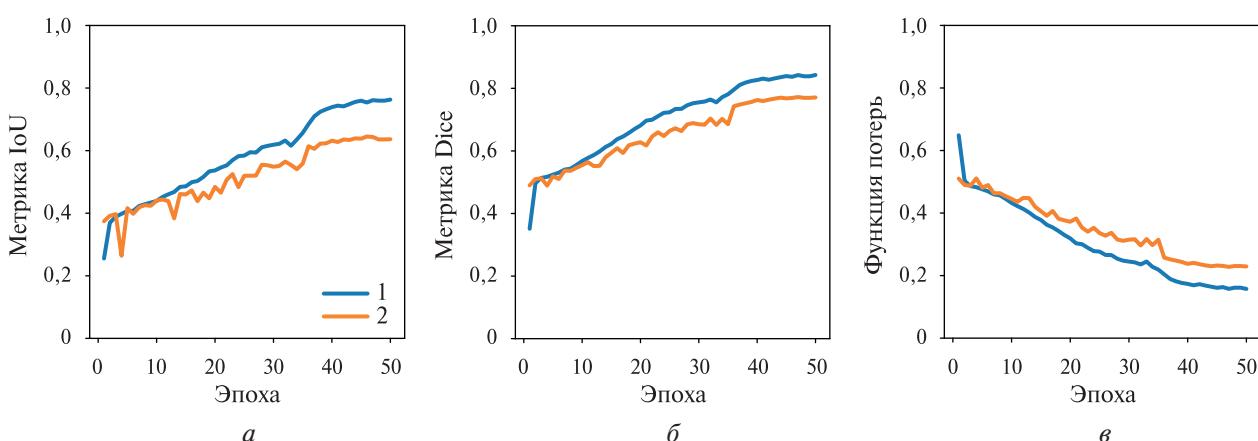


Рис. 2. Изменение метрик качества IoU (а), Dice (б) и функции потерь (в) на обучающей (1) и тестовой (2) выборках в процессе обучения модели

Результат обработки снимка моделью представляет собой геопривязанное бинарное изображение (см. *рис. 1в*). Расположенные рядом белые пиксели формируют полигон, соответствующий одному объекту-разрыву.

Верификация метода

Расчёт характеристик разрывов

Для верификации разработанного метода из архива ААНИИ были отобраны 30 снимков *Suomi NPP* акватории морей Лаптевых и Восточно-Сибирского за ледовые сезоны 2022–2025 гг. Выбранные снимки прошли экспертное дешифрирование и не использовались при обучении модели. По данным ручной обработки каждого снимка были рассчитаны модальная ориентация и удельная длина разрывов по квадратам сетки 100×100 км, охватывающей акватории обоих морей. Удельная длина является мерой плотности разрывов в пространстве и представляет собой отношение суммарной протяжённости разрывов в квадрате к его площади. Общее количество квадратов, обеспеченных данными, составило 1325.

Поскольку каждый полигон, охватывающий разрыв, является отдельным объектом, вокруг него можно описать прямоугольник. Большинство разрывов имеют вытянутую форму, приближённую к прямой линии. Вследствие этого их ориентация и протяжённость будут совпадать с соответствующими параметрами отрезка, соединяющего середины меньших сторон описанного прямоугольника (ОП) (*рис. 3а*). При наличии генерального направления разрыва и небольшого числа ответвлений метод ОП верно передаёт модальную ориентацию, но даёт значительные потери в протяжённости (см. *рис. 3б*). В случаях, когда форма разрыва далека от линейной и стороны ОП получаются приблизительно равными, ошибка возникает при определении обоих параметров (см. *рис. 3в*).

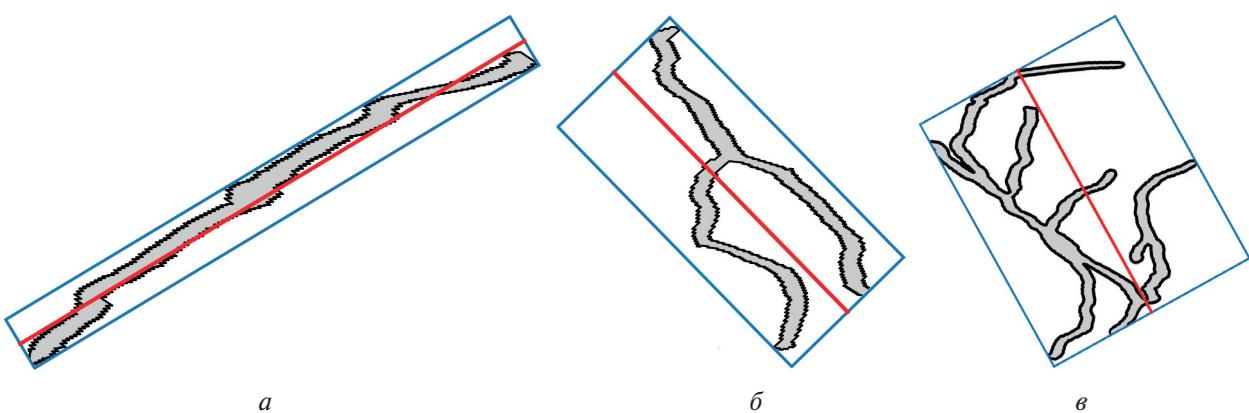


Рис. 3. Примеры представления длины и ориентации разрыва методом ОП

Результаты сравнения модальной ориентации и удельной длины разрывов, рассчитанных по методу ОП и по данным экспертного дешифрирования, которое принято за эталонное, приведены в *таблице*.

Как можно заметить, среднее значение отличия модальной ориентации по методу ОП от эталонной составило 9° , случаи существенных различий, превышающих 30° , составляют менее 3 %. Среднее отличие значений удельной длины, рассчитанных по данным ручного дешифрирования, от полученных по методу ОП составило $20 \text{ м}/\text{км}^2$. Это свидетельствует о том, что определение протяжённости разрывов по методу ОП в среднем занижает истинные значения. Решением данной проблемы является выделение отдельных ветвей разрывов как самостоятельных объектов с представлением их в виде ломаных линий.

Различия значений модальной ориентации и удельной длины разрывов, рассчитанных по данным автоматического и ручного дешифрирования (в %)

Различия ориентации, град	Расчёт по методу описанного прямоугольника	Расчёт по алгоритму «ветвления» (AB)
<i>Модальная ориентация</i>		
0–10	69,9	79,2
10–20	22,5	15,9
20–30	4,9	3,7
30–40	1,9	0,8
40–50	0,2	0,2
50–60	0,4	0,2
60–70	0,1	0
70–80	0	0
80–90	0,1	0
Среднее значение, град	9,0	7,0
Среднеквадратичное отклонение, град	8,4	6,9
<i>Удельная длина</i>		
Среднее значение, м/км ²	20	15
Среднеквадратичное отклонение, м/км ²	19,8	16,0

Алгоритм ветвления

Как было описано ранее, после обработки снимка моделью получаются бинарные изображения, содержащие только разрывы. С помощью встроенной функции пакета skimage для Python производится выделение отдельных объектов и их последующая скелетизация. Затем на каждой линии фиксируются координаты всех точек смены направления. Поиск прямолинейных участков, поворотов и ветвления осуществляется путём анализа ближайших соседей по вертикали, горизонтали и диагонали для каждого пикселя. Выявленные и обработанные непрерывные линии, соответствующие одной ветви разрыва, удаляются с изображения, что обеспечивает корректность работы и конечность процесса. Также алгоритм предусматривает сглаживание небольших углов, чтобы сократить количество точек в одном объекте при дальнейшем расчёте характеристик разрывов. Эта операция проводится на основе аппроксимации при помощи парной линейной регрессии. Таким образом, все идентифицированные моделью разрывы разбиваются на наборы вершин начала, конца и смены направления каждой из их ветвей, аналогично результатам экспертного дешифрирования.

Пример визуализации результатов работы АВ представлен на *рис. 4*.

Снимки, отобранные в верификационную выборку, после автоматического дешифрирования разработанной моделью были дополнительно обработаны АВ. По полученным данным рассчитаны значения характеристик разрывов и сопоставлены с данными ручного дешифрирования (см. таблицу).

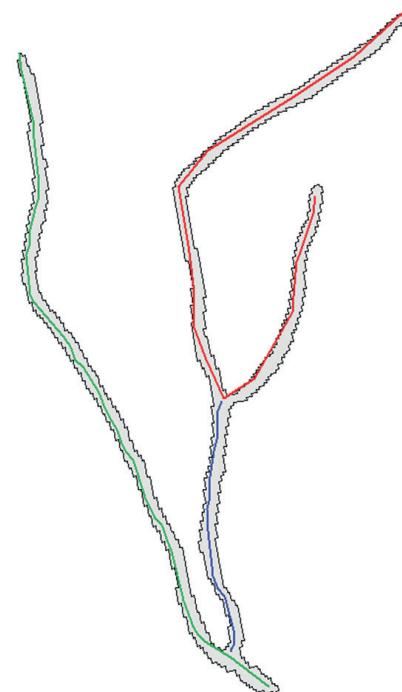


Рис. 4. Пример представления разрыва по алгоритму ветвления

Как можно заметить, среднее значение отклонений в модальной ориентации несколько уменьшилось относительно метода ОП и составило 7° , число случаев с незначительной ошибкой в определении модальной ориентации (менее 10°) возросло почти на 10 %. Также произошло снижение различий с данными ручного дешифрирования в значениях удельной длины разрывов. По гистограмме, приведённой на рис. 5, видно, что применение АВ существенно снижает количество сильных занижений протяжённости разрывов (более чем на $20 \text{ м}/\text{км}^2$) и почти на 10 % повышает долю случаев с близкими к эталонным значениям удельной длины (различия от -20 до $20 \text{ м}/\text{км}^2$). Средняя величина занижения составила $15 \text{ м}/\text{км}^2$. По отношению к среднему значению удельной длины разрывов, рассчитанному по верификационной выборке, это приблизительно соответствует занижению на 25 %. Анализ случаев с отрицательными значениями различий, т. е. когда удельная длина разрывов по данным ручного дешифрирования оказалась меньше, чем рассчитанная по данным автоматической идентификации, выявил ошибки в работе эксперта (пропуски разрывов на снимке при дешифрировании). Таким образом, можно сделать вывод о целесообразности использования АВ после идентификации разрывов на снимке с помощью построенной модели.

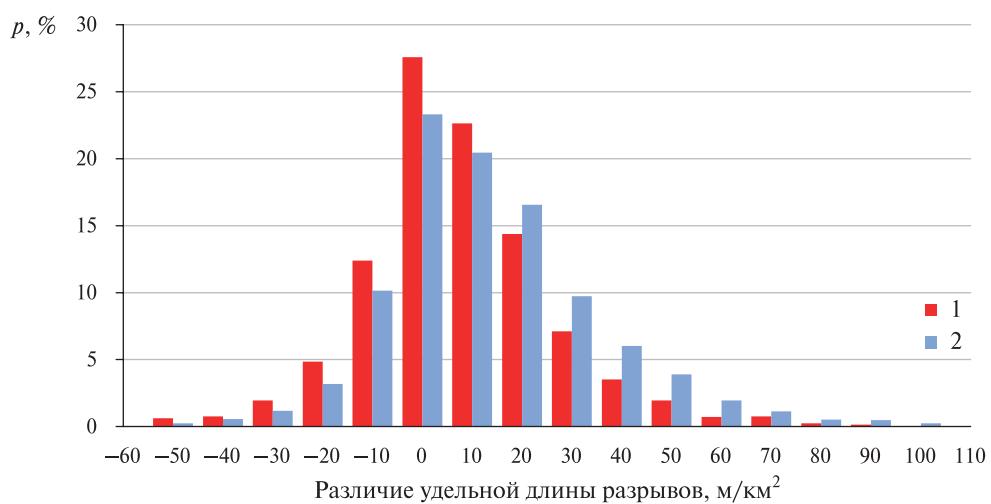


Рис. 5. Разность между значениями удельной длины разрывов, рассчитанными по данным ручного дешифрирования и автоматического по методу АВ (1) и ОП (2)

Заключение

Согласно результатам верификации разработанного метода отличия получаемых результатов от экспертной ручной сколки в среднем невелики. Из этого следует, что использование данных, полученных при автоматической идентификации разрывов на снимках ИСЗ, не внесёт существенных ошибок при последующем определении их обобщённых характеристик. Кроме того, применение автоматического дешифрирования исключает элемент субъективности, который присутствует при ручной обработке снимков различными экспертами.

Таким образом, созданное программное обеспечение даёт возможность значительно пополнить электронный архив данных о разрывах в кратчайшие сроки. Сформированный архив будет использоваться для исследования пространственной и временной изменчивости характеристик разрывов в арктических морях. Данные о разрывах также будут востребованы в ААНИИ при составлении краткосрочных прогнозов преобладающей ориентации разрывов на трассе Северного морского пути, которые входят в состав гидрометеорологического обеспечения судоходства.

Как было сказано ранее, из доступных источников оптимальными для изучения разрывов являются снимки с ИСЗ Suomi NPP, однако пополнение базы данных возможно и с использованием информации от других спутников. В связи с этим планами по развитию метода является его распространение на снимки спутников Terra и Aqua.

Исследование выполнено за счёт гранта Российского научного фонда № 25-27-00008, <https://rscf.ru/project/25-27-00008/>.

Литература

1. *Дымент Л. Н., Ершова А. А., Бойкая Е. Г., Кортикова К. Г.* Проблема автоматического дешифрирования разрывов в морском ледяном покрове по спутниковым снимкам // Исслед. Земли из космоса. 2025. № 4. С. 52–61. DOI: 10.7868/S3034540525040046.
2. *Hoffman J. P., Ackerman S. A., Liu Y., Key J. R.* The detection and characterization of Arctic sea ice leads with satellite images // Remote Sensing. 2019. V. 11. No. 5. Article 521. DOI: 10.3390/rs11050521.
3. *Hoffman J. P., Ackerman S. A., Liu Y. et al.* Application of a convolutional neural network for the detection of sea ice leads // Remote Sensing. 2021. V. 13. No. 22. Article 4571. DOI: 10.3390/rs13224571.
4. *Lee S., Kim H.-C., Im J.* Arctic lead detection using a waveform mixture algorithm from CryoSat-2 data // The Cryosphere. 2018. V. 12. No. 5. P. 1665–1679. DOI: 10.5194/tc-12-1665-2018.
5. *Lindsay R. W., Rothrock D. A.* Arctic sea ice leads from advanced very high resolution radiometer images // J. Geophysical Research: Oceans. 1995. V. 100. No. C3. P. 4533–4544. DOI: 10.1029/94JC02393.
6. *Reiser F., Willmes S., Heinemann G.* A new algorithm for daily sea ice lead identification in the Arctic and Antarctic winter from thermal-infrared satellite imagery // Remote Sensing. 2020. V. 12. No. 12. Article 1957. DOI: 10.3390/rs12121957.
7. *Röhrs J., Kaleschke L.* An algorithm to detect sea ice leads by using AMSR-E passive microwave imagery // The Cryosphere. 2012. V. 6. No. 2. P. 343–352. DOI: 10.5194/tc-6-343-2012.
8. *Willmes S., Heinemann G.* Pan-Arctic lead detection from MODIS thermal infrared imagery // Annals of Glaciology. 2015. V. 56. No. 69. P. 29–37. DOI: 10.3189/2015AoG69A615.

Automatic identification of sea ice leads from Suomi NPP satellite images

E. G. Boikaya, K. G. Kortikova, L. N. Dyment, A. A. Ershova

Arctic and Antarctic Research Institute, Saint Petersburg 199397, Russia

E-mail: ldyment@yandex.ru

The impact of dynamic factors on drifting ice cover in the Arctic seas causes formation of sea ice leads that can elongate up to several thousand kilometers. Ship movement along the favorable lead improves significantly the economic efficiency and safety of navigation. In this regard, information on sea ice leads is included as part of hydrometeorological support of voyages along the Northern Sea Route. The study of spatial and temporal variability of such characteristics of sea ice leads as prevailing orientation, length and spatial density in the water area requires a large amount of initial data. At present, low-resolution satellite images serve as a source of information on sea ice leads. However, so far there has been no automatic interpretation method to calculate all principal sea ice lead characteristics. The paper presents a method for automatic identification of leads from Suomi NPP infrared images with a spatial resolution of 375 m. The method is developed on the basis of a U-net convolutional neural network. The model is trained on data of manual expert interpretation of sea ice leads in 187 images of ice cover of the Laptev and East Siberian seas of 2021–2024 ice seasons. Jaccard coefficient is 0.64, and Dice coefficient is 0.77. After processing the image, the model creates a georeferenced monochrome image of the identified leads. Then individual lead objects are detected using the developed algorithm. Each lead object is a sequence of segments that correspond to relatively straight segments of the lead. The geographic coordinates of the segments ends are entered into the results file and are used to calculate the length and orientation of each individual lead. The developed method is verified using 30 Suomi NPP images of ice cover of the Laptev and East Siberian seas, preliminary interpreted by expert and excluded from model training. Based on the data from automatic and manual interpretation, the modal orientation and normalized length of leads are calculated, averaged over 100×100 km squares. The mean difference is 7° for the values of modal orientation and 15 m/km^2 for normalized length.

Keywords: leads in ice cover, Arctic seas, automatic interpretation, satellite images, infrared range, neural networks

Accepted: 18.09.2025
DOI: 10.21046/2070-7401-2025-22-6-43-51

References

1. Dyment L. N., Ershova A. A., Bojkaya E. G., Kortikova K. G., The problem of automatic identification of leads in the sea ice cover from satellite images, *Issledovanie Zemli iz kosmosa*, 2025, No. 4, pp. 52–61 (in Russian), DOI: 10.7868/S3034540525040046.
2. Hoffman J. P., Ackerman S. A., Liu Y., Key J. R., The detection and characterization of Arctic sea ice leads with satellite images, *Remote Sensing*, 2019, V. 11, No. 5, Article 521, DOI: 10.3390/rs11050521.
3. Hoffman J. P., Ackerman S. A., Liu Y. et al., Application of a convolutional neural network for the detection of sea ice leads, *Remote Sensing*, 2021, V. 13, No. 22, Article 4571, DOI: 10.3390/rs13224571.
4. Lee S., Kim H.-C., Im J., Arctic lead detection using a waveform mixture algorithm from CryoSat-2 data, *The Cryosphere*, 2018, V. 12, No. 5, pp. 1665–1679, DOI: 10.5194/tc-12-1665-2018.
5. Lindsay R. W., Rothrock D. A., Arctic sea ice leads from advanced very high resolution radiometer images, *J. Geophysical Research: Oceans*, 1995, V. 100, No. C3, pp. 4533–4544, DOI: 10.1029/94JC02393.
6. Reiser F., Willmes S., Heinemann G., A new algorithm for daily sea ice lead identification in the Arctic and Antarctic winter from thermal-infrared satellite imagery, *Remote Sensing*, 2020, V. 12, No. 12, Article 1957, DOI: 10.3390/rs12121957.
7. Röhrs J., Kaleschke L., An algorithm to detect sea ice leads by using AMSR-E passive microwave imagery, *The Cryosphere*, 2012, V. 6, No. 2, pp. 343–352, DOI: 10.5194/tc-6-343-2012.
8. Willmes S., Heinemann G., Pan-Arctic lead detection from MODIS thermal infrared imagery, *Annals of Glaciology*, 2015, V. 56, No. 69, pp. 29–37, DOI: 10.3189/2015AoG69A615.