Цифровая обработка данных Sentinel-1 для автоматизированного выделения кромки старых льдов

Н. Ю. Захваткина ^{1,2}, И.А. Бычкова ¹, В. Г. Смирнов ¹

¹ Арктический и антарктический научно-исследовательский институт Санкт Петербург, 199397, Россия

Описан алгоритм автоматизированной классификации морского льда Арктики по возрастным стадиям на основе метода нейронных сетей (НС). Входными данными становятся изображения радиолокатора Sentinel-1 с двойной поляризацией. Данные радиолокатора с синтезированной апертурой имеют несколько особенностей, для учёта которых предложен подход к улучшению качества данных. Обучение сети проводилось с использованием алгоритма с обратным распространением ошибки. Обоснован выбор информативных текстурных признаков, обеспечивающих оптимизацию вычислительного алгоритма. На основании анализа ошибок классификации и времени обработки найдена оптимальная топология НС. Для верификации результатов классификации применяются генерализованные карты Арктического и антарктического научно-исследовательского института (ААНИИ) и визуальные оценки ледового эксперта. Показано, что спутниковые радиолокационные данные могут применяться для автоматического определения нескольких градаций морского льда и для картирования границы старого льда. С использованием карт ААНИИ как опорного источника данных рассчитана матрица ошибок и показатели точности классификации льда по методу НС. Точность классификации для однолетнего льда составила 75 %, для старого льда — 90 %.

Ключевые слова: морские льды, кромка старого льда, Арктика, Sentinel-1, радиолокатор с синтезированной апертурой, классификация, текстурные характеристики, нейронные сети

Одобрена к печати: 29.07.2020 DOI: 10.21046/2070-7401-2020-17-5-23-34

Введение

Изменения климата, аномалии ледового режима арктических морей, связанные с потеплением или похолоданием, во многом определяют стратегию использования Северного морского пути. Для обеспечения навигации в Арктике особенно важно иметь оперативную информацию о положении массивов старых льдов, представляющих наибольшую опасность для судов. Такая информация может быть получена по данным спутниковых радиолокаторов с синтезированной апертурой (РСА), позволяющих осуществлять ежесуточный мониторинг арктического региона вне зависимости от погодных условий и уровня естественной освещённости и имеющих достаточное пространственное разрешение (Смирнов и др., 2010).

Первый опыт картирования старых льдов в Арктике по спутниковым радиолокационным данным был получен осенью 1983 г., уже через 2 мес после запуска спутника «Космос-1500». Базируясь на знаниях, полученных ранее при обработке снимков авиационных радиолокационных станций бокового обзора с той же длиной волны (3 см), в Арктическом и антарктическом научно-исследовательском институте (ААНИИ) разработали дешифровочные признаки морских льдов на радиолокационных снимках (Методические..., 1985). В конце 1990-х гг. в разных странах было создано программное обеспечение для анализа спутниковых снимков, предоставляющее интерактивное картирование ледовой обстановки с выделением границ однородных зон. Однако результаты картирования по-прежнему зависели от субъективных факторов: квалификации ледового эксперта и наличия опыта дешифрирования в конкретном регионе Арктики. С запуском спутников ERS-1 (англ. European Remote-Sensing Satellite) и Radarsat-1 с начала 2000-х гг. различными научными организациями мира ведутся

² Международный центр по окружающей среде и дистанционному зондированию им. Нансена, Санкт-Петербург, 199034, Россия E-mail: natalyp@aari.ru

исследования по созданию объективных методов интерпретации спутниковых радиолокационных снимков (Zakhvatkina et al., 2019). Было разработано несколько алгоритмов обработки PCA-изображений для получения карт ледовой обстановки с выделением старых льдов (Котагоv, Buehner, 2019; Kwok, 1998; Soh, Tsatsoulis, 2002), однако в настоящее время в оперативной практике ледовых служб мира на постоянной основе такие методы не применяются. Автоматическое картирование кромки старых льдов выполняется сейчас по данным пассивных микроволновых радиометров — ежедневных карт состояния ледяного покрова, предоставляемых подразделением OSI SAF (англ. Ocean and Sea Ice Satellite Application Facility, http://www.osi-saf.org/?q=content/sea-ice-products) Европейской организации спутниковой метеорологии EUMETSAT (англ. European Organisation for the Exploitation of Meteorological Satellites). Однако применение PCA позволяет существенно улучшить точность картирования старых льдов, так как у них, по сравнению с микроволновыми радиометрами, гораздо выше пространственное разрешение.

В ААНИИ с 2010 г. для определения возрастных характеристик льда успешно используется метод нейронных сетей (НС), позволяющий минимизировать роль субъективного фактора при построении ледовых карт. С введением в эксплуатацию в 2014 и 2016 гг. Европейским космическим агентством (ЕКА, *англ*. European Space Agency — ESA) спутников Sentinel-1A/B с PCA С-диапазона, к данным которых был предоставлен свободный доступ, актуальной стала задача развития технологий автоматизации процесса обработки получаемых с этих спутников снимков для оперативного обеспечения навигации в ледовых условиях Арктики.

Использованные данные и их предварительная обработка

Для выделения основных стадий развития морского льда (старый/однолетний) использованы PCA-данные Sentinel-1A/B, полученные для арктических морей в режиме сверхширокой полосы обзора (ExtraWide — EW) одновременно в двух поляризациях: ГГ (горизонтально передаваемый и горизонтально принимаемый сигналы) и ГВ (горизонтально передаваемый и вертикально принимаемый сигналы). Применялись снимки GRD (англ. Ground Range Detected), прошедшие предварительную обработку в центре управления и на наземных станциях приёма спутниковых данных (уровень обработки L1) с применением различных стандартных алгоритмов, реализованных в программном комплексе Instrument Processing Facility (IPF). В итоге формируемое PCA-изображение GRDM (medium) состоит из пяти полос и соответствует ширине полосы обзора на местности 400 км с размером пикселя 40×40 м (Sentinel-1..., 2019).

Интенсивность обратного рассеяния морским льдом электромагнитных волн, поступающих с PCA, зависит от физико-химических свойств поверхностного слоя льда, состояния его поверхности (шероховатости, торосистости), технических параметров датчика (поляризации сигнала, угла падения) и измеряется величиной удельной эффективной площади рассеяния (УЭПР). Для перехода от яркости PCA-изображения к значениям УЭПР проводится абсолютная калибровка по методике EKA (Sentinel-1..., 2019).

При обработке РСА-изображений с широкой полосой обзора необходимо учитывать угловую зависимость обратного рассеяния морских льдов. На ГВ-поляризации зависимость от угла падения значительно слабее, а на ГГ-поляризации изменения УЭПР морского льда одного возраста с изменением угла падения могут достигать значительных величин (для водной поверхности такие различия ещё больше). Поэтому для данных ГГ-поляризации необходима коррекция значений обратного рассеяния. С этой целью значения УЭПР приводят к некоторому фиксированному углу падения, что позволяет получить приблизительно равноконтрастное по всей полосе обзора изображение (Mäkynen, Karvonen, 2017). Поправка на угол падения рассчитывается путём оценки зависимости коэффициента обратного рассеяния на ГГ-поляризации от угла падения по уравнению регрессии: $\sigma_{j_HH}^{\circ} = 10\log_{10}(\sigma_{j}^{\circ}) - \left[B(\theta_{j} - \theta_{fix})\right]$, где: σ_{j}° — значение УЭПР j-го пикселя изображения; θ_{j} — угол падения, соответствующий j-му пикселю изображения; θ_{fix} — угол падения в градусах, к которому приводится РСА-изображение (обычно центральный угол, определяемый в зависимости от режима съёмки);

B — коэффициент, равный отношению изменения УЭПР (дБ) к изменению углов падения режима съёмки данного РСА.

Диапазон углов падения в режиме EW составляет от \sim 17 до \sim 47°, всё изображение приводится к центральному углу 34°. Коэффициент регрессии был получен из набора более 200 сверхширокозахватных PCA-снимков поверхности, занятой морским льдом по всей ширине полосы обзора, т. е. для всего диапазона углов падения, и составил 0.215 ± 0.007 .

Данные ГВ-поляризации не проходят коррекцию на угол падения, но зато нуждаются в проведении операций по подавлению «термического (теплового)» шума. РСА-данные в режиме широкой полосы обзора формируются из более узких полос, где тепловой шум выражается как флуктуации интенсивности сигнала по дальности как внутри полос, так и на их смежных границах. Для уменьшения шума применяется сглаживание изображения по полосам обзора и их границам с использованием информации из вспомогательных данных архива снимка. Для данных уровня обработки GRD Sentinel-1 используется уравнение EKA

(Thermal..., 2017):
$$\sigma_i^\circ = 10\log_{10}\left|\frac{DN_i^2 - \eta_i}{A_i^2}\right|$$
, где $\sigma_i^\circ -$ УЭПР i -го пикселя в децибелах; $DN_i -$ ам-

плитуда обратного рассеяния исходного сигнала i-го пикселя; η_i — интенсивность теплового шума для i-го пикселя; A_i — коэффициент калибровки для i-го пикселя. Значения η_i и A_i приводятся во вспомогательных метаданных архива изображений PCA Sentinel-1.

Кроме теплового шума у продуктов Sentinel-1 GRD в режиме сверхширокой полосы обзора внутри полос по азимутальному направлению существует ещё так называемый *«гребешковый»* эффект (*англ.* scalloping noise). Эффект гребешкового шума в основном заметен над открытым океаном с низкими значениями УЭПР, соответствующими чаще всего областям чистой водной поверхности при низких скоростях ветра. Для уменьшения этого эффекта применяется та же процедура, что и в случае теплового шума; необходимые вспомогательные данные содержатся в метаданных РСА-снимков начиная с марта 2018 г. Итоговая величина η_i равняется произведению значений теплового и гребешкового шумов для *i*-го пикселя, восстановленных из вспомогательных данных (Thermal..., 2017).

РСА-данные в режиме сверхширокой полосы обзора формируются из пяти более узких полос (EW1–EW5). Первая полоса EW1 после всех коррекций остаётся ярче, чем другие. Таким образом, значения о° морских льдов остаются значительно выше в ближней части полосы обзора относительно дальней. Для получения более равномерных значений яркости для одного и того же типа льда по всей полосе обзора PCA-изображения проводится дополнительная процедура выравнивания полосы EW1 относительно всего изображения. Поскольку полосы EW2–EW5 не имеют значительного перепада яркости относительно друг друга для одного и того же льда, коррекция яркости полосы EW1 проводится по ближайшим полосам EW2 и EW3. После подавления шума на ГВ-поляризации были вычислены значения УЭПР изображения. Значения УЭПР (дБ) с равными промежутками в пикселях извлекаются в направлении по дальности РСА-изображений для полос EW1 и EW2 + EW3. Полученные

таким образом два набора данных УЭПР делятся
$$\left[\frac{\sigma_{EW1}^{\circ}}{\sigma_{EW1+EW2}^{\circ}} \right]$$
 для получения величины *отно*-

шения. Такая процедура проводится несколько раз для одного изображения в разных частях снимка в направлении по азимуту, затем вычисленные отношения усредняются, чтобы в итоге получить среднее для РСА-изображения.

В работе использовано более 100 PCA-изображений Sentinel-1A/B, прошедших описанные выше процедуры коррекции. Снимки получены для районов Центральной Арктики, а также северной и центральной частей моря Лаптевых для зимних месяцев 2016—2019 гг. Выбирались изображения с относительно однородными зонами льдов разного возраста (однолетний, старый), наблюдавшимися по всей полосе обзора (EW1—EW5) с разным соотношением их частной сплочённости, границы раздела которых обязательно находились в части снимка EW1—EW3. Изображения также были разбиты на группы согласно спутнику (А или В) и временному периоду версии обработки данных (IPF), т.е. до и после введения

дополнительных данных для подавления различных шумов на ГВ-поляризации. Для каждого изображения было получено среднее значение отношения. Для оценки диапазона изменения этих значений было вычислено усреднённое отношение всех изображений и стандартное отклонение каждой группы, и, таким образом, были получены диапазоны изменения величины отношения (*табличные отношения*).

Для каждого нового PCA-изображения, не участвовавшего в процедуре определения диапазонов изменения отношения, рассчитывается значение среднего отношения. Полученная величина проверяется на попадание в определённый диапазон согласно версии IPF конкретного снимка. Если полученное значение попадает в диапазон, то это среднее отношение применяется для уменьшения значения EW1, если нет, то используется ранее вычисленное среднее диапазона (динамическое отношение). Таким образом, для коррекции сцены PCA используется либо динамическая величина отношения, либо табличная. Следует отметить, что динамические отношения были получены для более чем 350 сцен и только несколько не попали в вычисленные диапазоны. На рис. 1 показан результат обработки ГВ-поляризации.

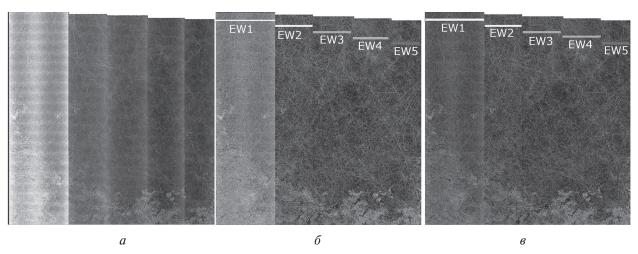


Рис. 1. Пример коррекции снимка Sentinel-1B от 5 февраля 2019 г., Γ В-поляризация: a — УЭПР, полученные без применения какой-либо коррекции шума; δ — результат коррекции шума по методологии, предложенной EKA (Sentinel-1..., 2019); δ — результат дополнительной коррекции полосы снимка EW1

Все процедуры предварительной обработки разновременных снимков Sentinel-1 выполнялись с использованием интегрированного в язык программирования Python модуля *snappy* на базе программного комплекса SNAP (*англ*. Sentinel Application Platform, https://step.esa.int/main/toolboxes/snap).

Признаки РСА-изображений

При дешифрировании РСА-изображений ледовый эксперт должен учитывать географическое положение, синоптические условия и состояние моря в исследуемом районе, сезон, а также диапазон изменения углов падения сигнала в пределах рассматриваемого участка, наличие помех и особенности обработки информации. Разные виды морского льда могут давать одинаковую яркость тона на изображении, поскольку интенсивность сигнала зависит от многих естественных параметров. Это означает, что диапазоны УЭПР некоторых стадий развития морских льдов (например, старый и молодой лёд) могут перекрываться. Поэтому кроме яркости ещё одним дешифровочным признаком при классификации радиолокационных изображений различных видов льда является текстура, по которой определяют стадии развития ледяного покрова, состояние его поверхности и другие особенности.

Текстура выражается с помощью так называемых текстурных признаков или характеристик, которые широко используются для классификации PCA-изображений (Leigh et al.,

2014; Zakhvatkina et al., 2017). Известно несколько методов выделения текстурных признаков. Один из механизмов формирования текстурных характеристик (ТХ) основан на свойствах гистограммы распределения частоты совместных значений яркости пары элементов изображения. Текстурные характеристики вычисляются на основе статистик, полученных с помощью матрицы совместной встречаемости (МСВ, также матрица смежности) уровней яркости (Нагаlіск et al., 1973). Полный набор ТХ для двухполяризационных данных РСА включает 26 характеристик, перечисленных на рис. 2.

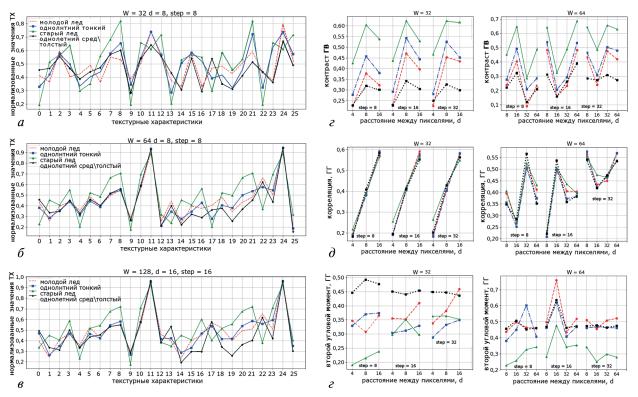


Рис. 2. Набор нормализованных ТХ (Haralick et al., 1973) для 4 классов, выделенных на обучающем наборе предварительно обработанных РСА-изображений Sentinel-1 GRDM, рассчитанных с разными параметрами: $a-W=32\times32,\ d=8,\ step=8;\ \theta-W=64\times64,\ d=8,\ step=8;\ \theta-W=128\times128,\ d=16,\ step=16.$ Текстурные характеристики для ГГ-поляризации: 0- второй угловой момент, 1- контраст, 2- корреляция, 3- дисперсия, 4- момент обратной разности, 5- суммарное среднее, 6- суммарная дисперсия, 7- суммарная энтропия, 8- энтропия, 9- дифференциальная дисперсия, 10- дифференциальная энтропия, 11 и 12- информационная мера корреляции 1 и 2 соответственно. Для ГВ-поляризации - тот же набор (13-25). Контраст ГВ (ϵ), корреляция ГГ (δ) и второй угловой момент ГГ (ϵ), рассчитанные для окон 32×32 и 64×64 с различными межпиксельными расстояниями d для нескольких вариаций шага смещения step

Однако весь набор ТХ в процессе классификации использовать не нужно, так как это приводит к увеличению времени расчётов и очевидному усложнению классификатора. Известно, что некоторые ТХ сильно связаны друг с другом, т.е. имеют высокую корреляцию (Albregtsen, 2008), поэтому нет смысла использовать весь набор извлечённых текстурных признаков. Соответственно, необходимо определить набор значимых или наиболее эффективных ТХ для данной поляризации исходя из выявляемых особенностей того или иного вида морского льда. Одновременно производится выбор параметров расчёта ТХ, который также основывается на проводимых статистических оценках вычисляемых признаков. Другими словами, мы ограничиваем количество текстурных признаков, стремясь к балансу между временем вычислений и надёжным оптимальным разделением классов с учётом деталей РСА-изображения. Для расчёта ТХ можно использовать несколько библиотек языка Python (mahotas, scikit-learn, eo-learn и т.п.) или SNAP.

Методология исследования

Для классификации типов морского льда применялся алгоритм обучения с учителем на основе нейронной сети (Хайкин, 2006). Для контролируемого обучения НС требуются входные наборы данных с правильно идентифицированными примерами классов — разных видов льда (желаемыми выходами). Ледовый эксперт создаёт базу данных примеров различных классов по нескольким РСА-изображениям, выбранным для обучения. Мы используем визуальную оценку ледового эксперта 16 зимних сцен Sentinel-1 2018 и 2019 гг., содержащих возрастные градации морского льда, типичные для данного района Арктики. При формировании наборов данных РСА-изображения летнего периода (с июня по октябрь) не использовались изза неоднозначности интерпретации льдов разного возраста ввиду значительного влияния на сигнал талой воды (снежниц) на поверхности льда. Обучение НС проводилось с использованием алгоритма с обратным распространением ошибки. При расчётах создаются два набора по 13 ТХ (Haralick et al., 1973) для обеих поляризаций РСА-изображения для каждого «тренировочного» участка каждого класса. Как было отмечено выше, прежде чем ТХ можно будет использовать в классификации, необходимо выяснить, какие TX более полезны для разделения классов морского льда. Так как вычисленные значения ТХ зависят не только от свойств ледяного покрова, но и от ряда технических параметров расчёта — от размера скользящего окна W, расстояния между пикселями d и числа квантования уровней яркости исходного изображения K (Clausi, 2002; Shokr, 1991), предварительно были определены оптимальные значения этих параметров. Значение К может варьироваться и было выбрано равным 32 согласно литературным источникам (Clausi, 2002; Soh, Tsatsoulis, 2002). Для определения оптимальных параметров расчёта ТХ были рассчитаны 26 ТХ с размерами окна W = 16, 32, 64 и 128 пикселей с использованием различных расстояний d = 4, 8, 16, 32, 64 и разной степенью детализации PCA-изображения (*шаг смещения* скользящего окна (*step*), равный W/8, W/4, W/2, W).

В более крупном окне отражаются свойства ТХ более крупных однородных объектов (например, большой массив старых льдов), при этом влияние отдельных пикселей окна на величину текстурной оценки снижается, т.е. наличие объектов однолетнего льда или молодого, например образовавшихся в разрывах в массиве старого льда, останется незаметным для текстуры. Таким образом, использование больших окон ведёт к потере точности при обнаружении малоконтрастных текстур и к потере мелких деталей изображения. Маленькое окно не даёт правильного представления о текстуре на снимках, так как наоборот очень мелкие детали РСА-изображения могут дать ошибочное представление при отнесении данной области к тому или иному классу выделяемых льдов. Также при больших окнах заметно ухудшается пространственное разрешение конечной классификации, а слишком малые окна приводят к значительному увеличению объёмов расчётов, поэтому окна менее 32×32 и более 128×128 реально не применялись к имеющимся исходным данным для конкретной задачи классификации.

Набор эффективных характеристик и оптимальные значения для параметров их расчёта выбираются путём анализа изменений распределения средних значений каждой ТХ определённых классов, рассчитанных с использованием различных комбинаций расчётных параметров (см. $puc.\ 2a-e$). Наиболее информативными ТХ считаются характеристики, обеспечивающие больший диапазон изменения средних значений основных видов льда и большее число раз значимо некоррелированных с другими признаками. Так, $puc.\ 2a$ демонстрирует признаки, которые при анализе диапазона изменения значений ТХ показали лучшее разделение всех определяемых видов льда. На $puc.\ 2e-e$ показан пример анализа средних значений нескольких ТХ для определения оптимальной комбинации скользящего окна, шага смещения и расстояния между соседними пикселями, которые обеспечивают в данном случае лучшее разделение классов морского льда по сравнению с другими комбинациями размеров окон с различными параметрами расчёта ТХ. По распределению средних значений отдельных ТХ, рассчитанных для разных шагов смещения и расстояния d, можно сделать предположение, что все типы морского льда наилучшим образом разделяются при step = 8 и d = 8. Также проводится непосредственно анализ изображений ТХ, полученных по РСА-снимкам, использованным для об-

учения и содержащим априори известные проблемные случаи для классификации типов морского льда на PCA-изображениях.

Для выбора наиболее информативных ТХ, которые целесообразно использовать в создаваемой НС, был проведён расчёт взаимной корреляции характеристик на примере РСАизображений, использованных для обучения, для многолетнего, однолетнего и молодого льдов (рис. 3). Высокая корреляция между двумя ТХ показывает сходные свойства типа льда, тогда как в случае низкой корреляции обе характеристики будут способствовать повышению точности классификации морского льда (Clausi, 2002). На рис. 3 все коэффициенты корреляции с абсолютным значением менее 0,5 отмечены более тёмно-серыми оттенками, подчёркивая, какие пары характеристик текстуры полезны для классификации. Старый и молодой льды могут лучше различаться по комбинациям ТХ: второй угловой момент (ГГ и ГВ), корреляция (ГГ и ГВ), момент обратной разности ГГ вместе с суммарным средним (ГГ и ГВ) и суммарной дисперсией ГГ, которые характеризуются умеренными и низкими коэффициентами корреляции. Аналогичная комбинация особенностей текстуры была найдена для однолетнего льда. Корреляция (ГГ и ГВ), энтропия (ГГ и ГВ) в сочетании с мерой корреляции 1 и 2 ГВ, а также совместное использование второго углового момента (ГГ и ГВ) и контраста (ГГ и ГВ) являются наиболее важными для выделения однолетнего льда. Хотя корреляция (ГГ и ГВ) показывает потенциал для уверенного разделения всех классов морского льда, рис. 2д иллюстрирует, что данный признак не вносит полезной информации. Таким образом были исследованы все ТХ.

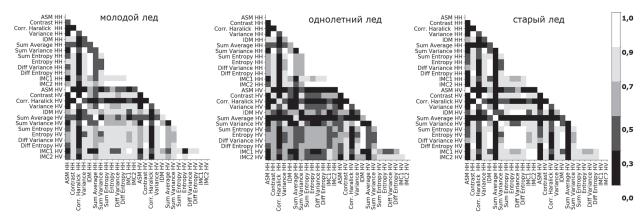


Рис. 3. Значения коэффициентов корреляции (по модулю) между характеристиками набора из 26 ТХ для молодого, однолетнего, старого льдов, участки которых выбраны на предварительно обработанных РСА-изображениях, использованных для обучения. Обозначения, усвоенные из исследования (Нагаlick et al., 1973): поляризации НН и НV (ГГ и ГВ): ASM — второй угловой момент; Contrast — контраст; Corr. Haralick — корреляция; Variance — дисперсия; IDM — момент обратной разности; Sum Average — суммарное среднее; Sum Variance — суммарная дисперсия; Sum Entropy — суммарная энтропия; Entropy — энтропия; Diff Variance — дифференциация дисперсии; Diff Entropy — дифференциация энтропии; IMC1 и IMC2 — информационная мера корреляции 1 и 2 соответственно

В результате такого общего анализа был выбран размер скользящего окна 32×32 пикселя с шагом 8 пикселей и межпиксельным расстоянием 8 как компромисс между сохранением деталей и вычислительными затратами. Совокупность текстурных признаков представляет массив измерений, который можно рассматривать как многомерную матрицу, в которой каждому участку поверхности соответствует набор значений. После расчёта набора ТХ для РСА-изображений, использованных для обучения, определяются их средние и стандартные отклонения. Эти значения используются при работе или тестировании алгоритма на неизвестных РСА-сценах для масштабирования ТХ, т.е. представления в том же диапазоне, что и все сцены, использованные в процессе обучения. Для работы НС обязательным условием становится нормирование входных данных, при котором эти данные приобретают диапазон изменчивости от —1 до 1 (или 0—1). Оптимальный набор текстурных признаков, вычисляемый нами

для обучающей выборки изображений, включает: для ГГ-поляризации — второй угловой момент, контраст, дисперсию, момент обратной разности, суммарное среднее, суммарную дисперсию, энтропию, дифференциальную дисперсию, для ГВ-поляризации — второй угловой момент, момент обратной разности, среднее по суммам, энтропию, информационную меру корреляции 1 и 2.

На входной слой НС подавались признаки РСА-изображения, число нейронов в первом слое соответствует числу нормализованных текстурных признаков, рассчитанных с предварительно заданными параметрами. Набор полученных с участием ледового эксперта данных разбивается на два: для обучения и проверки. Последний используется для определения производительности НС на независимых примерах, не участвующих в процессе обучения. Обучающие примеры последовательно поступают в сеть, и веса каждого нейрона корректируются таким образом, чтобы аппроксимация, создаваемая нейронной сетью, сводила к минимуму ошибку между желаемым выходным сигналом и суммированным (полученным) выходным сигналом, созданным сетью. Во время обучения НС один и тот же набор данных обрабатывается много раз для уточнения весов. Обучение прекращается, когда среднеквадратичная ошибка в течение длительного времени уменьшается незначительно (Хайкин, 2006).

Прежде чем получить натренированную HC, была проведена серия экспериментов: менялось количество скрытых слоёв и количество нейронов в этих слоях, каждая сеть обучалась несколько раз. Оптимальная топология HC выбиралась на основе анализа ошибок классификации и времени обработки, а также анализа данных для обучения, классифицированных ледовым экспертом, в результате чего однолетний лёд был разделён на две градации. Так определены следующие параметры HC: 14 нейронов на входном слое, соответствующих выбранному набору TX для двух поляризаций, один скрытый слой с 9 нейронами и выходной слой с 4 нейронами, соответствующими определяемым классам: молодой лёд, однолетний тонкий, однолетний средний или толстый, старый лёд.

Результаты

Для тестирования алгоритма использовалось 100 сцен Sentinel-1, не участвовавших в обучении. Для оценки результатов классификации (рис. 4a, см. с. 31) взяты ледовые карты ААНИИ (рис. 46), составляемые ледовыми экспертами с использованием различных данных со спутников (видимый диапазон, ИК-диапазоны, радарные снимки), судов и полярных станций, собранных и осреднённых в течение 2—5 дней. Продукт автоматизированной классификации подготовлен по РСА-данным, собранным в течение двух дней (1—2 дня требуется для охвата спутниковыми изображениями территории Центральной Арктики, менее 1 дня необходимо для выполнения всех расчётов). Сравнение результата классификации НС с ледовой картой ААНИИ показывает разницу в положении границы старого льда от 1 до 10 км.

Детальное изучение РСА-изображений показывает, что они содержат, по существу, несколько типов поверхности: многолетний лёд с включениями однолетнего льда, зоны однолетнего льда, содержащие сморози однолетнего тонкого или ровного льда со смесью торосов и разрывов, заполненных молодым льдом. Визуальный анализ продуктов классификации РСА-изображений, как участвовавших, так и не участвовавших в процессе обучения, показал ошибку в разграничении старых и молодых льдов в высоких широтах Арктического бассейна. Разрывы с открытой водой могут казаться яркими на ГГ-поляризации при высоких углах падения при значительной скорости приводного ветра, тогда как на ГВ-поляризации такие каналы кажутся тёмными при тех же условиях. Тонкий морской лёд — молодой, образовавшийся в результате замерзания воды в разрывах, может иметь высокие значения обратного рассеяния как на ГГ-, так и на ГВ-поляризации и поэтому может быть похож на гряды торосов на РСА-изображениях С-диапазона (Dierking, 2013). Для Центральной Арктики класс «молодой лёд» был отнесён к классу «однолетний тонкий», в результате чего предложенная классификация для выделения кромки старых льдов ограничена тремя градациями (см. рис. 4б). Две возрастные градации однолетнего льда, полученные в процессе применения автомати-

зированного алгоритма, объединены в один класс «однолетний лёд» для того, чтобы соответствовать обзорным картам ААНИИ. Для количественной оценки результатов классификации были рассчитаны матрицы ошибок для сравнения с картами ААНИИ и экспертными оценками, полученными по 16 РСА-изображениям, использованным для обучения. Точность классификации по сравнению с оценками ледового эксперта составила 97 и 89 %, 75 и 90 %—с картами ААНИИ для однолетнего и старого льдов соответственно (*табл. 1 и 2*).

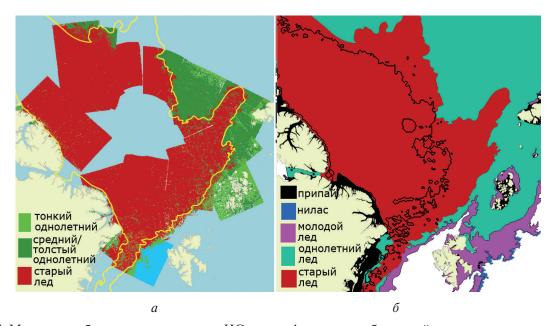


Рис. 4. Мозаика, собранная из результата НС-классификации изображений, полученных со спутника Sentinel-1: a — классификация 25 PCA-изображений, 12—13 февраля 2019 г.; жёлтая линия — граница распространения старого льда по данным обзорной карты ААНИИ на рис. 46; δ — обзорная ледовая карта ААНИИ, 12—15 февраля 2019 г.; чёрная линия — граница распространения старого льда по данным OSI SAF, 12.02.2019

Таблица 1. Матрица ошибок для 16 снимков, использованных для обучения: визуальная оценка (зоны, выделенные для обучения) (ось Y), результат классификации HC (ось X)

	Старый лёд	Однолетний лёд
Старый лёд	0,97	0,003
Однолетний лёд	0,06	0,891
Общая точность	0,916	

Таблица 2. Матрица ошибок: карта ААНИИ (ось Y), результат классификации HC (ось X) (100 снимков)

	Старый лёд	Однолетний лёд
Старый лёд	0,907	0,093
Однолетний лёд	0,245	0,755
Общая точность	0,854	

Значительный процент ошибки классификации однолетнего льда вносит молодой лёд. Этот тип льда в Центральной Арктике наблюдается в основном в замёрзших разрывах и хорошо выделяется НС-классификацией в массиве старого льда, что в целом соответствует реальному его наличию на снимках. Также визуальный анализ результатов показал, что процент ошибок однолетнего льда в зонах старого льда не соответствует фактическому и является завышенным. При сравнении границы старых льдов, полученной по данным микроволновых радиометров специалистами OSI SAF, с ледовой картой ААНИИ расхождение положения границ довольно значительно (см. рис. 4а). Таким образом, по данным РСА обеспечивается более точное картирование границы старого льда. При валидации результатов классификации с помощью карт ААНИИ или данных OSI SAF, имеющих разрешение 12,5 км (чёрная линия на рис. 4б соответствует границе старого льда), важно иметь в виду, что достаточно

подробный продукт классификации очень трудно сравнить с генерализованными ледовыми картами, поскольку карты ААНИИ содержат общие границы зон того или иного типа льда, внутри которых другие возрастные градации не выделяются, а даётся указание на их наличие и приводится балл их частной сплочённости. Таким образом, процесс валидации, а также разработка методологии валидации более подробных продуктов классификации РСА-изображений нуждается в дальнейшем исследовании.

Заключение

Алгоритм метода нейронных сетей показал хорошие результаты при автоматизированном выделении кромки старых льдов. Разница в положении границ старых льдов, обнаруженных методом НС и проведённых ледовыми экспертами, не превышала 10 км.

Анализ показал, что классификация ледяного покрова по методу НС должна иметь региональный характер, т.е. для обеспечения статистической достоверности результатов необходимо выделять в разных районах характерные для конкретных морей типы льда для достижения оптимальной конфигурации НС.

Выполненное сравнение результатов классификации старых и однолетних льдов на серии из ~100 PCA и квазисинхронных ледовых карт ААНИИ позволило оценить общую точность классификации по методу HC, составившую ~85,4 %. Расчёт точности проводился путём вычисления матрицы ошибок для каждого изображения.

Метод классификации морского льда по спутниковым данным может быть использован для выделения границы старого льда в Арктике в целом с периодичностью 1—2 раза в неделю. Такие данные могут быть применены для мониторинга и автоматической оценки изменений кромки старого льда в Арктике и для сравнения состояния льда в течение года со средними климатическими данными.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проект № 18-05-60124).

Литература

- 1. Методические указания по вопросам приема, обработки и использования спутниковой ледовой информации. Вып. 1: Определение характеристик ледяного покрова по радиолокационным сним-кам ИСЗ «Космос-1500». Л.: ААНИИ, 1985. 75 с.
- 2. *Смирнов В. Г.*, *Бушуев А. В.*, *Захваткина Н. Ю.*, *Лощилов В. С.* Спутниковый мониторинг морских льдов // Проблемы Арктики и Антарктики. 2010. Т. 85. № 2. С. 62—76.
- 3. *Хайкин С.* Нейронные сети: полный курс. 2-е изд. / пер. с англ. М.: Вильямс, 2006. 1104 с.
- 4. *Albregtsen F.* Statistical Texture Measures Computed from Gray Level Coocurrence Matrices / Image Processing Laboratory Department of Informatics. University of Oslo. 2008. 14 p.
- 5. *Clausi D*. A. An analysis of co-occurrence texture statistics as a function of grey level quantization // Canadian J. Remote Sensing. 2002. V. 28. P. 45–62.
- 6. *Dierking W*. Sea ice monitoring by synthetic aperture radar // Oceanography. 2013. V. 26. P. 100–111.
- 7. *Haralick R. M.*, *Shanmugam K. S.*, *Dinstein I.* Textural features for image classification // IEEE Trans. Systems, Man, and Cybernetics. 1973. V. 3. P. 610–621.
- 8. *Komarov A. S.*, *Buehner M.* Detection of First-Year and Multi-Year Sea Ice from Dual-Polarization SAR Images Under Cold Conditions // IEEE Trans. Geoscience and Remote Sensing. 2019. V. 57. No. 11. P. 9109–9123.
- 9. *Kwok R*. The Radarsat Geophysical Processor System // Analysis of SAR Data of the Polar Oceans. Berlin; Heidelberg: Springer, 1998. P. 235–257.
- 10. *Leigh S., Zhijie W., Clausi D. A.* Automated Ice—Water Classification Using Dual Polarization SAR Satellite Imagery // IEEE Trans. Geoscience and Remote Sensing. 2014. V. 52. P. 5529–5539.
- 11. *Mäkynen M.*, *Karvonen J.* Incidence Angle Dependence of First-Year Sea Ice Backscattering Coefficient in Sentinel-1 SAR Imagery Over the Kara Sea // IEEE Trans. Geoscience and Remote Sensing. 2017. V. 55. No. 11. P. 6170–6181.
- 12. Sentinel-1 Level 1 Detailed Algorithm Definition. Technical Document. Iss. 2/2. ESA, 2019. 158 p.

- 13. *Shokr M. E.* Evaluation of Second-Order Texture Parameters for Sea Ice Classification from Radar Images // J. Geophysical Research. 1991. V. 96. P. 10625–10640.
- 14. *Soh L. K.*, *Tsatsoulis C.* ARCTOS: A Knowledge Engineering Software Tool for Images // Intern. J. Human-Computer Studies. 2002. V. 57. No. 6. P. 469–496.
- 15. Thermal denoising of products generated by the Sentinel-1 IPF: Technical Document. Iss. 1.1. ESA, 2017. 25 p.
- 16. Zakhvatkina N., Korosov A., Muckenhuber S., Sandven S., Babiker M. Operational algorithm for ice water classification on dual-polarized Radarsat-2 images // The Cryosphere. 2017. V. 11. No. 1. P. 33–46.
- 17. Zakhvatkina N., Smirnov V., Bychkova I. Satellite SAR Data-based Sea Ice Classification: An Overview // Geosciences. 2019. V. 9(4). P. 152. DOI: 10.3390/geosciences9040152.

Digital processing of Sentinel-1 data for automated detection of old ice edge

N. Yu. Zakhvatkina ^{1,2}, I. A. Bychkova ¹, V. G. Smirnov ¹

¹ Arctic and Antarctic Research Institute, Saint Petersburg 199397, Russia
² Nansen International Environmental Remote Sensing Center
Saint Petersburg 199034, Russia
E-mail: natalyp@aari.ru

An automated technique for old ice edge detection based on the neural networks (NN) method is described. NN classification algorithm is based on Sentinel-1 extra wide mode dual polarized synthetic aperture radar (SAR) imagery acquired over the Arctic under winter conditions. This SAR data has several features and an approach to improve data quality has been proposed. NN training was conducted using a backpropagation algorithm. Since various sea ice types can have the same backscattering coefficients, the texture features have been used as accompanying data. Selection of the most informative texture features is justified. The optimal NN topology was found based on the analysis of classification errors and processing time. The ice charts provided by the Arctic and Antarctic Research Institute (AARI) and visual ice expert's estimation were used for verification of the NN classification results. It is shown that SAR data can be used for automatic identification of several sea ice stages of development and old ice boundary mapping. The error matrices were calculated with the classification accuracies for each class using AARI ice charts as a source of reference data. The classification accuracy of the first-year and old ice was 75 and 90 % respectively.

Keywords: sea ice, old ice edge, Arctic, Sentinel-1, synthetic aperture radar, classification, texture, neural networks

Accepted: 29.07.2020 DOI: 10.21046/2070-7401-2020-17-5-23-34

References

- 1. Metodicheskie ukazaniya po voprosam priema, obrabotki i ispol'zovaniya sputnikovoi ledovoi informatsii. Vypusk 1: Opredelenie kharakteristik ledyanogo pokrova po radiolokatsionnym snimkam ISZ "Kosmos-1500" (Guidelines for reception, processing and use of satellite ice information, Issue 1: Determination of the ice cover characteristics from Cosmos-1500 satellite radar images), Leningrad: AARI, 1985, 75 p.
- 2. Smirnov V. G., Bushuev A. V., Zakhvatkina N. Yu., Loshchilov V. S., Sputnikovyi monitoring morskikh l'dov (Satellite Monitoring of the Sea Ice), *Problemy Arktiki i Antarktiki*, 2010, Vol. 85, No. 2, pp. 62–76.
- 3. Haykin S., Neural Networks: A Comprehensive Foundation, Second Edition, Moscow: Williams, 2006, 1104 p.
- 4. Albregtsen F., *Statistical Texture Measures Computed from Gray Level Coocurrence Matrices*, Image Processing Laboratory Department of Informatics, University of Oslo, 2008, pp. 1–14.
- 5. Clausi D.A., An analysis of co-occurrence texture statistics as a function of grey level quantization, *Canadian J. Remote Sensing*, 2002, Vol. 28, pp. 45–62.

- 6. Dierking W., Sea ice monitoring by synthetic aperture radar, *Oceanography*, 2013, Vol. 26, pp. 100–111.
- 7. Haralick R.M., Shanmugam K.S., Dinstein I., Textural features for image classification, *IEEE Trans. Systems, Man, and Cybernetics*, 1973, Vol. 3, pp. 610–621.
- 8. Komarov A. S., Buehner M., Detection of First-Year and Multi-Year Sea Ice from Dual-Polarization SAR Images Under Cold Conditions, *IEEE Trans. Geoscience and Remote Sensing*, 2019, Vol. 57, No. 11, pp. 9109–9123.
- 9. Kwok R., The Radarsat Geophysical Processor System, In: *Analysis of SAR Data of the Polar Oceans*, Berlin-Heidelberg: Springer, 1998, pp. 235–257.
- 10. Leigh S., Zhijie W., Clausi D.A., Automated Ice–Water Classification Using Dual Polarization SAR Satellite Imagery, *IEEE Trans. Geoscience and Remote Sensing*, 2014, Vol. 52, pp. 5529–5539.
- 11. Mäkynen M., Karvonen J., Incidence Angle Dependence of First-Year Sea Ice Backscattering Coefficient in Sentinel-1 SAR Imagery Over the Kara Sea, *IEEE Trans. Geoscience and Remote Sensing*, 2017, Vol. 55, No. 11, pp. 6170–6181.
- 12. Sentinel-1 Level 1 Detailed Algorithm Definition, Technical Document, Issue 2/2, ESA, 2019, 158 p.
- 13. Shokr M. E., Evaluation of Second-Order Texture Parameters for Sea Ice Classification from Radar Images, *J. Geophysical Research*, 1991, Vol. 96, pp. 10625–10640.
- 14. Soh L. K., Tsatsoulis C., ARCTOS: A Knowledge Engineering Software Tool for Images, *Intern. J. Human-Computer Studies*, 2002, Vol. 57, No. 6, pp. 469–496.
- 15. Thermal denoising of products generated by the Sentinel-1 IPF, Technical Document, Issue 1.1, ESA, 2017, 25 p.
- 16. Zakhvatkina N., Korosov A., Muckenhuber S., Sandven S., Babiker M., Operational algorithm for ice water classification on dual-polarized Radarsat-2 images, *The Cryosphere*, 2017, Vol. 11, No. 1, pp. 33–46.
- 17. Zakhvatkina N., Smirnov V., Bychkova I., Satellite SAR Data-based Sea Ice Classification: An Overview, *Geosciences*, 2019, Vol. 9(4), pp. 152, DOI: 10.3390/geosciences9040152.