

Применение нейронной сети для детектирования ледяного покрова Дальневосточных морей по данным прибора VIIRS космического аппарата NOAA-20

М. О. Кучма, З. Н. Лотарева, Л. А. Корнева, Ю. А. Шапилова

Дальневосточный центр НИЦ «Планета», Хабаровск, 680000, Россия
E-mail: m.kuchma@dvrspod.ru

В настоящей работе представлена технология расчёта маски ледяного покрова с использованием свёрточной нейронной сети применительно к данным прибора VIIRS, установленного на космическом аппарате NOAA-20. Специалистами Дальневосточного центра ФГБУ «Научно-исследовательский центр космической гидрометеорологии «Планета» (ДЦ ФГБУ «НИЦ «Планета») была набрана обучающая выборка с использованием данных прибора VIIRS за период с октября 2020 г. по июнь 2021 г., составившая около 22 тыс. текстур. Эмпирическим методом была получена оптимальная для решения поставленной задачи архитектура нейронной сети. В ходе экспериментов были получены оптимальный размер входных текстур, который составил 21×21 пиксель, и входные параметры: зенитный угол Солнца и инфракрасные каналы с центральными длинами волн 0,6; 1,6; 10,7 и 12,0 мкм. Результаты валидации разработанного алгоритма при сравнении с данными программного комплекса Community Satellite Processing Package VIIRS Aerosols, Cryosphere, Clouds and Volcanic Ash Environmental Data Record Products и с эталонными масками ледяного покрова, составленными специалистами ДЦ ФГБУ «НИЦ «Планета» методами интерактивного дешифрирования, показали высокие значения точности и вероятности правильного определения события: 94 и 98 % соответственно.

Ключевые слова: дистанционное зондирование Земли, VIIRS, NOAA-20, свёрточная нейронная сеть, текстура, лёд, маска ледяного покрова

Одобрена к печати: 25.03.2022

DOI: 10.21046/2070-7401-2022-19-2-32-42

Введение

В настоящее время данные дистанционного зондирования Земли из космоса являются важным источником информации и помогают в обеспечении различных сфер деятельности человека. В том числе такие данные активно используются для мониторинга морского ледяного покрова (ЛП) замерзающих акваторий, в которых применение *in situ* измерений затруднено или невозможно.

Акватории дальневосточных (ДВ) морей являются одной из основных транспортных артерий Дальнего Востока. Практически все виды хозяйственной деятельности на морях в регионе во многом зависят от знания ледовой обстановки. Поскольку Дальневосточный центр ФГБУ «Научно-исследовательский центр космической гидрометеорологии «Планета» (ДЦ НИЦ «Планета») — ведущая организация на Дальнем Востоке по предоставлению потребителям спутниковой информационной продукции, то одним из направлений работы центра представляется обеспечение заинтересованных организаций информацией о ЛП ДВ-морей, группу которых составляют воды Берингова, Охотского и Японского морей.

В настоящее время построение карт ледовой обстановки ДВ-морей осуществляется на основе методов визуального (интерактивного) дешифрирования параметров ЛП, поскольку отсутствуют методы автоматического расчёта характеристик морского льда. Расширение группировки метеорологических спутниковых систем ведёт к увеличению объёма обрабатываемой информации, в том числе используемой для интерпретации параметров ЛП. В текущей ситуации это приводит к улучшению качества продукции за счёт использования дополнительных данных, однако при этом необходимо, чтобы время предоставления оперативной

информации конечному потребителю не увеличивалось пропорционально возросшему объёму данных.

Описанные выше проблемы определяют актуальность разработки автоматических алгоритмов определения и картирования параметров ЛП по данным аппаратуры, размещаемой на космических аппаратах (КА). Для автоматизации этого процесса в первую очередь необходимо разработать методику качественного маскирования ЛП, поскольку от этого зависит качество выходной продукции. В настоящей работе авторами предложена новая методика расчёта маски ЛП по данным прибора VIIRS (*англ.* Visible Infrared Imager Radiometer Suite), установленного на КА NOAA-20 (*англ.* National Oceanic and Atmospheric Administration — Национальное управление океанических и атмосферных исследований, США).

Обзор методик

Лёд является сложной структурой и обладает массой характеристик, которые зависят от освещенности, времени года, широты и других параметров. Помимо этого, лёд в зависимости от своего состава имеет разную отражательную способность, влияющую на его обнаружение со спутника. Доля солнечного излучения, отражённого льдом, снегом или водой, имеет резко выраженную спектральную зависимость, изученную во многих исследованиях. В работе (Спутниковые..., 2011) показано, что на длинах волн до 0,9 мкм коэффициент спектральной яркости (КСЯ), характеризующий долю отражённого солнечного излучения, максимален, а на длинах более 0,9 мкм — в ближней инфракрасной области — уменьшается практически до нуля. КСЯ молодого морского льда зависит от его толщины (Jezek et al., 1998), и одновременно для толстого льда наблюдается зависимость КСЯ от сезона измерения. Низкие значения КСЯ характерны для загрязнённого льда, в то время как чистый лёд обладает сравнительно высокой прозрачностью в видимом диапазоне спектра (Паундер, 1967; Dorsey, 1940). Помимо этого, на определение границы льда влияет атмосфера, которая имеет разные характеристики и параметры для различных широт (Minnett, 2007). Например, в полярных районах, где разность температур воздух/вода велика, воздух имеет низкую влажность. Перечисленные факторы накладывают значительные ограничения на достоверность детектирования ЛП, связанные как с состоянием самого льда, так и с его географическим и сезонным распределением.

Рассматриваемый в работе прибор VIIRS, установленный на КА NOAA-20, имеет в наличии 5 каналов и 16 каналов в различных диапазонах электромагнитного спектра, имеющих пространственное разрешение 375 и 750 м соответственно (*табл. 1*).

Существующие алгоритмы по определению маски ЛП по данным прибора VIIRS (Key et al., 2013; Riggs et al., 2015), которые используются в свободно распространяемом программном обеспечении (ПО) Community Satellite Processing Package (CSPP) VIIRS Aerosols, Cryosphere, Clouds and Volcanic Ash (ASCI) Environmental Data Record (EDR) Products Version 1.1 (Seaman et al., 2015), хотя и обладают заявленным высоким качеством, но применительно к территории ДВ-морей показывают порой грубые ошибки, как это отражено на *рис. 1* (см. с. 34).

На *рис. 1б* в легенде маски ЛП поле «нет данных/ошибка» означает, что значения в пикселях не восстанавливаются из-за низкой освещённости Солнцем, либо эти пиксели классифицированы как тень от облачности, либо отсутствуют необходимые данные (Riggs et al., 2015). Анализируя *рис. 1*, можно отметить, что большая часть ЛП классифицируется как облачность, а участок воды, свободный ото льда, — как лёд. Всё это является ошибочным результатом и не может применяться для решения поставленной задачи.

К тому же вышеупомянутые алгоритмы основываются на пиксельном анализе. Например, они устанавливают пороговые значения в различных каналах спутникового прибора и температуры поверхности льда. Основная проблема таких методов состоит в том, чтобы найти оптимальные пороговые значения для параметров, поскольку эти значения могут существенно различаться в зависимости от региона и периода года.

Таблица 1. Характеристики каналов VIIRS

Пространственное разрешение 375 м		Пространственное разрешение 750 м	
Наименование канала	Центральная длина волны, мкм	Наименование канала	Центральная длина волны, мкм
I1	0,64	M1	0,415
		M2	0,445
		M3	0,49
		M4	0,555
		M5	0,673
I2	0,865	M6	0,746
		M7	0,865
I3	1,61	M8	1,24
		M9	1,378
		M10	1,61
I4	3,74	M11	2,25
		M12	3,7
I5	11,45	M13	4,05
		M14	8,55
		M15	10,763
		M16	12,013

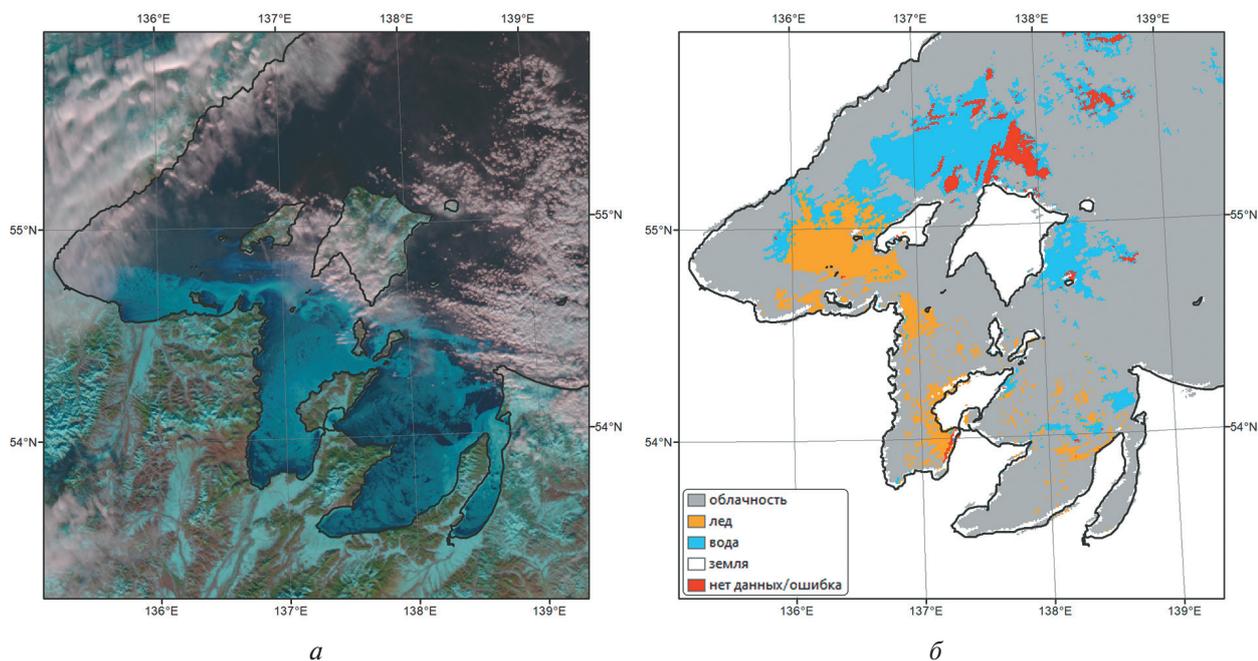


Рис. 1. Снимок от 03.12.2020, 02:33 UTC (англ. Coordinated Universal Time, всемирное координированное время): а — мультиспектральное изображение по данным VIIRS KA NOAA-20; б — маска ЛПИ, полученная с помощью CSPP ASCII EDR

Последние исследования в области дистанционного зондирования Земли показывают, что алгоритмы машинного обучения, в частности нейронные сети (НС), могут успешно применяться для задач классификации пикселей спутникового изображения. Опыт работ ДЦ НИЦ «Планета» в этом направлении (Крамарева и др., 2019; Кучма и др., 2020, 2021; Bloschinskiy et al., 2020) это подтверждает.

Нейронная сеть

Создание обучающей выборки

Качество обучения НС в той или иной степени зависит от качества и количества элементов обучающей выборки (ОВ), а также от того, насколько полно она описывает решаемую задачу.

Для решения маскирования ЛП с помощью НС по данным прибора VIIRS KA NOAA-20 было решено использовать текстурный метод (Zang et al., 2016), который позволяет оценивать параметры как рассматриваемого пикселя, так и соседних, при этом учитывая их возможную связь. Для этого метода необходимо создать ОВ по спутниковым данным в виде изображений. Текстуры в данном случае представляют собой трёхмерные массивы, в которых третье измерение — это параметры, с использованием которых НС сможет с достаточной точностью провести классификацию. Такими параметрами могут быть коэффициент спектральной яркости, яркостная температура каналов спутникового прибора, зенитный угол Солнца, а также другие данные, которые тем или иным образом могут быть представлены в цифровом виде.

Проблема создания такой ОВ состоит в том, что довольно сложно классифицировать объекты на спутниковых изображениях: для этого необходимо обладать соответствующими экспертными знаниями в области дешифрирования определённого типа подстилающей поверхности. Несмотря на то, что в настоящее время проводятся исследования по автоматизированию этого процесса (Топоров и др., 2019), они обладают рядом недостатков и уступают в точности ручному способу классификации. Поэтому авторы формируют ОВ вручную с привлечением специалистов ДЦ НИЦ «Планета», которые имеют необходимую квалификацию и могут с достаточной точностью сказать, к какому классу должны относиться текстуры на спутниковых снимках: облако, лёд, вода и т. д.

Для ОВ данные выбирались таким образом, что к конкретному классу относились текстуры, содержащие пиксели как только данного класса, так и нескольких различных классов одновременно, но при этом центральный пиксель должен принадлежать к указанному. Каждой отобранной текстуре присваивался один из трёх классов: вода, лёд, облачность. ОВ для классификации набиралась с использованием данных прибора VIIRS KA NOAA-20 в период с октября 2020 г. по июнь 2021 г. для региона ДВ-морей. В рамках решения поставленной задачи специалистами вручную из примерно 170 спутниковых снимков было отобрано около 22 тыс. текстур. Каждая текстура изначально имела размер 31×31 пиксель и состояла из зенитных углов Солнца и спутника, широты, а также 16 каналов прибора VIIRS с пространственным разрешением 750 м (см. табл. 1).

Вся ОВ была разбита на три набора данных: обучающий (60 %), проверочный (25 %) и тестовый (15 %). Первый набор используется непосредственно для обучения НС. Проверочный — для оценки функции потерь в конце каждой эпохи, при этом модель напрямую не обучается на этих данных. Этот набор данных нужен для проверки процесса обучения НС и при необходимости — для корректировки архитектуры модели НС. Тестовый набор используется для финальной оценки точности НС.

Для создания, обучения и непосредственного использования НС применяется библиотека “keras”, написанная на языке Python. При обучении НС и проведении всех расчётов использовался персональный компьютер с характеристиками: процессор Intel Core i5-9600K, ОЗУ 32 ГБ, графический процессор NVIDIA GeForce RTX 2080 8 GB.

Архитектура нейронной сети

От архитектуры НС в той или иной степени зависит точность, время обучения и время расчёта. Поскольку разрабатываемый алгоритм будет использоваться в оперативной практике, то время расчёта наравне с точностью является критичным параметром, так как если это время

будет велико, информация потеряет свою актуальность. При оперативном гидрометеорологическом обеспечении морских операций используются либо обзорные ледовые карты, которые составляются на основе комплексирования за 2–3 сут различного рода информации, либо детализированные ледовые карты, создаваемые на основе информативного спутникового снимка не позднее 2–3 ч после его получения. Таким образом, время на расчёт маски должно составлять не более половины времени, допустимого для самого оперативного вида продукции, т. е. не более 1 ч. Такие ограничения вводятся авторами ввиду того, что необходимо предусмотреть время на последующий расчёт параметров и характеристик ЛП, который будет проводиться уже после расчёта маски ЛП.

Эмпирическим путём была получена оптимальная архитектура НС, которая обладала приемлемым быстродействием и хорошей точностью на тестовой выборке для решения поставленной задачи. Такой метод определения оптимальной архитектуры был применён в похожей работе по определению маски ЛП по данным КА «Метеор-М» № 2 (Кучма и др., 2021). Архитектура НС представлена в *табл. 2*.

Таблица 2. Архитектура нейронной сети

№ слоя	Входной слой	Параметр	Характеристики параметра
1	Input	Conv2D	filters = 80, kernel_size = 3×3, strides = 2×2
2	1	Activation	ReLU
3	2	BatchNormalization	–
4	Input	Conv2D	filters = 80, kernel = 1×1, strides = 1×1
5	4	Activation	ReLU
6	5	BatchNormalization	–
7	3,5	Concatenate	–
8	7	Activation	ReLU
9	8	BatchNormalization	–
10	9	Dense	units = 256, activation = ReLU
11	10	Dropout	rate = 0,5
12	11	Dense	unit = 256, activation = ReLU
13	12	Dropout	rate = 0,5
14	13	Dense	units = 3, activation = ReLU
15	14	Activation	Softmax

В *табл. 2* введены следующие обозначения. Input — входные данные. Conv2d — свёрточный двумерный слой, для которого задаётся количество карт признаков (filters), высота и ширина окна двумерной свёртки (kernel_size), шаг этой свёртки по высоте и ширине (strides) (Куо, 2016). ReLU — слой активации “Rectified linear unit”, в котором отрицательные значения принимаются за ноль, а остальные значения имеют линейную зависимость (Mueller, Guido, 2017). BatchNormalization — слой, который нормализует слои активации предыдущего уровня в каждом блоке, т. е. преобразовывает среднее значение активации, делая его близким к нулю, а стандартное отклонение активации — близким к единице (Ioffe, Szegedy, 2015). Concatenation — слой, который объединяет входные слои в один. Dense — полносвязный слой нейронов, которому задаётся количество выходных нейронов (units), а также указывается функция активации (activation) (Mueller, Guido, 2017). Dropout — слой, который случайным образом устанавливает значения нейронных связей в нуль с заданной частотой (rate) на каждом шаге во время обучения НС, что помогает предотвратить переобучение (Srivastava et al., 2014). SoftMax — функция активации, которая часто используется в качестве активации для последнего слоя НС с задачей классификации (Mueller, Guido, 2017) и рассчитывается по формуле:

$$f_{\text{softmax}}(s) = \frac{e^s}{\sum_{k=1}^N e^{s_k}},$$

где s — значение на выходе нейрона до активации; N — общее количество нейронов в слое.

Для обучения НС в качестве функции потерь использовалась “categorical crossentropy” — категориальная кросс-энтропия, поскольку она наиболее эффективна, когда на выходе имеется более двух классов (Mueller, Guido, 2017). В качестве метрики использовалась “Accurasy” (Mueller, Guido, 2017), в качестве оптимизатора — “Adam” (Kingma, Ba, 2015), который часто используется в подобных задачах.

Обучение нейронной сети и выбор оптимальных параметров

Процесс обучения НС состоит в итерационном пересчёте весовых коэффициентов нейронов в слоях по заданному алгоритму оптимизации. Обучение выполняется с помощью алгоритма обратного распространения ошибки. Обучение НС продолжается до достижения минимальных изменений в показателях метрик машинного обучения на проверочном наборе данных на протяжении последних нескольких итераций.

В процессе обучения НС были проведены эксперименты по поиску оптимального размера текстур. Так, были выбраны 10 спутниковых пролётов в разные месяцы с различной ледовой обстановкой, и для этих случаев с использованием всех входных параметров НС обучалась для различных размеров текстур: от 31×31 до 3×3 пикселя с шагом в 2 пикселя. Результаты расчётов метрик после обучения показали, что все варианты моделей имеют схожие значения “Accurasy” (более 90 %), различающиеся на 0,5–5 %. После обучения были построены маски ЛП и специалисты ДЦ НИЦ «Планета» оценивали их точность. В результате было определено, что оптимальный размер текстур составляет 21×21 пиксель.

Следующим шагом были эксперименты по определению оптимального набора входных параметров, поскольку некоторые из них могли вносить незначительный вклад в работу алгоритма и не оказывать существенного влияния на итоговую маску. В качестве основы были взяты каналы, которые используются в алгоритме по расчёту маски ЛП по данным VIIRS в Центре космических полётов НАСА имени Годдарда (*англ.* NASA’s Goddard Space Flight Center — GSFC; НАСА — Национальное управление по аэронавтике и исследованию космического пространства, *англ.* NASA — National Aeronautics and Space Administration) (Riggs et al., 2015). Это каналы I1, I2, I3, I5, M4 (см. табл. 1). Однако для экономии времени расчёта вместо каналов с пространственным разрешением 375 м были взяты близкие по спектральным характеристикам каналы, имеющие пространственное разрешение 750 м, а именно: M5, M7, M10, M16 вместо I1, I2, I3, I5 соответственно. После обучения НС с этим набором параметров была получена точность немного ниже, чем на полном наборе данных. Дальнейшие эксперименты показали, что оптимальным набором параметров представляется следующий: каналы M5, M10, M15, M16 и зенитный угол Солнца.

Выбор каналов M5 и M10 обосновывается тем, что для обнаружения снежного покрова используются коротковолновые инфракрасные каналы в диапазоне длин волн от 1,4 до 1,8 мкм (Crane, Anderson, 1984; Salomonson, Appel, 2004), поскольку альbedo снежного покрова в этом спектральном диапазоне отличается от альbedo облачности (*рис. 2*, см. с. 38) (Crane, Anderson, 1984).

Таким образом, альbedo снега и облачности в канале M10 различается, а в канале M5 — практически нет. В частности, именно такая зависимость этих каналов используется в расчёте снежного индекса NDSI (*англ.* Normalized Difference Snow Index — нормализованный разностный снежный индекс) согласно формуле: $NDSI = (M5 - M10)/(M5 + M10)$. Таким образом, совокупность двух каналов позволяет отделить снежный и облачный покровы друг от друга. Лёд на данном диапазоне волн обладает близкими к снегу характеристиками, поэтому вышеописанные доводы применимы и к нему. Стоит отметить, что в данной работе не стоит задачи разделять классы «снег» и «лёд», поскольку на морском льду также может присутствовать снег, что в целом делает их равными с точки зрения классификации.



Рис. 2. Альбедо снежного покрова в спектральном диапазоне от 1,4 до 1,8 мкм

Каналы M15 и M16 используются в расчёте температуры поверхности моря (Godin, Vicente, 2017) и температуры поверхности льда (Key et al., 2013), что косвенно позволяет учесть температуру поверхности и более точно разделить классы льда и воды. Использование информации о зенитном угле Солнца позволяет НС учесть зависимость регистрируемого спутником излучения от освещённости подстилающей поверхности.

Стоит также отметить, что время расчёта одного спутникового снимка с использованием разработанной НС с таким входным набором параметров занимает до 40 мин в зависимости от размера самого снимка. Количество эпох для обучения составило 144, при этом “ассурасу” равен 95,8 %.

Валидация

Валидацию маски ЛП по данным VIIRS было решено провести в два этапа. Первый заключался в оценке рассчитанных меток классов для текстур на тестовом наборе данных. Второй этап состоял в сравнении масок ЛП, полученных с помощью ПО CSPP ASCII EDR и рассчитанных посредством представленного алгоритма, с эталонными, которые были составлены специалистами ДЦ НИЦ «Планета» методом интерактивного дешифрирования.

Таблица 3. Матрица ошибок

		Наблюдаемое событие	
		Наличие явления — Positive (P)	Отсутствие явления — Negative (N)
Рассчитанное событие	Наличие явления — True (T)	Истинно положительный — True positive (TP)	Ложный положительный — False positive (FP)
	Отсутствие явления — False (F)	Ложный отрицательный — False negative (FN)	Истинно отрицательный — True negative (TN)

В качестве метрик согласно матрице ошибок (табл. 3) для оценки результатов были рассмотрены: Precision = TP/(TP + FP) × 100 % — точность; Recall = TP/(TP + FN) × 100 % — вероятность правильного определения события; F-мера = 2 · (Precision · Recall) / (Precision + Recall) × 100 % — гармоническое среднее между Precision и Recall.

Результаты первого этапа валидации представлены в табл. 4. Всего в тестовом наборе данных присутствует 6700 текстур.

Таблица 4. Валидация на тестовом наборе данных

Класс	Метрики, %		
	Precision	Recall	F-мера
Лёд	96,1	92,0	94,0
Вода	94,3	96,3	95,3
Облачность	96,4	97,3	96,8

Анализируя информацию из *табл. 4*, можно отметить высокую точность по всем метрикам (>92 %) для каждого класса. Однако анализ только тестового набора данных не всегда может показать действительную картину, именно поэтому валидация в настоящей работе проводится в два этапа.

На втором этапе валидации полученные с помощью программного комплекса CSPP ASCI EDR и рассчитанные с помощью предлагаемого алгоритма маски ЛП сравнивались с эталонными. Для этого были отобраны 9 спутниковых снимков в период с октября 2020 г. по июнь 2021 г., которые не принимали участия при обучении НС. Для этих случаев специалистами ДЦ НИЦ «Планета» были получены маски ЛП посредством интерактивного дешифрирования. Сравнение проводилось только для класса «лёд», при этом все остальные классы использовались как отдельный класс. Всего было проанализировано около 18 млн пикселей. Результаты второго этапа валидации представлены в *табл. 5*. Визуальное представление маски по данным CSPP ASCI EDR показано на *рис. 1*, визуальное представление эталонной и рассчитанной маски — на *рис. 3*.

Таблица 5. Валидация на основе данных CSPP ASCI EDR

Валидация данных	Класс	Метрики, %		
		Precision	Recall	F-мера
CSPP ASCI EDR	Лёд	98,7	64,3	77,8
	Не лёд	99,3	99,9	99,6
Рассчитанные маски	Лёд	94,5	98,3	96,3
	Не лёд	99,9	99,9	99,9

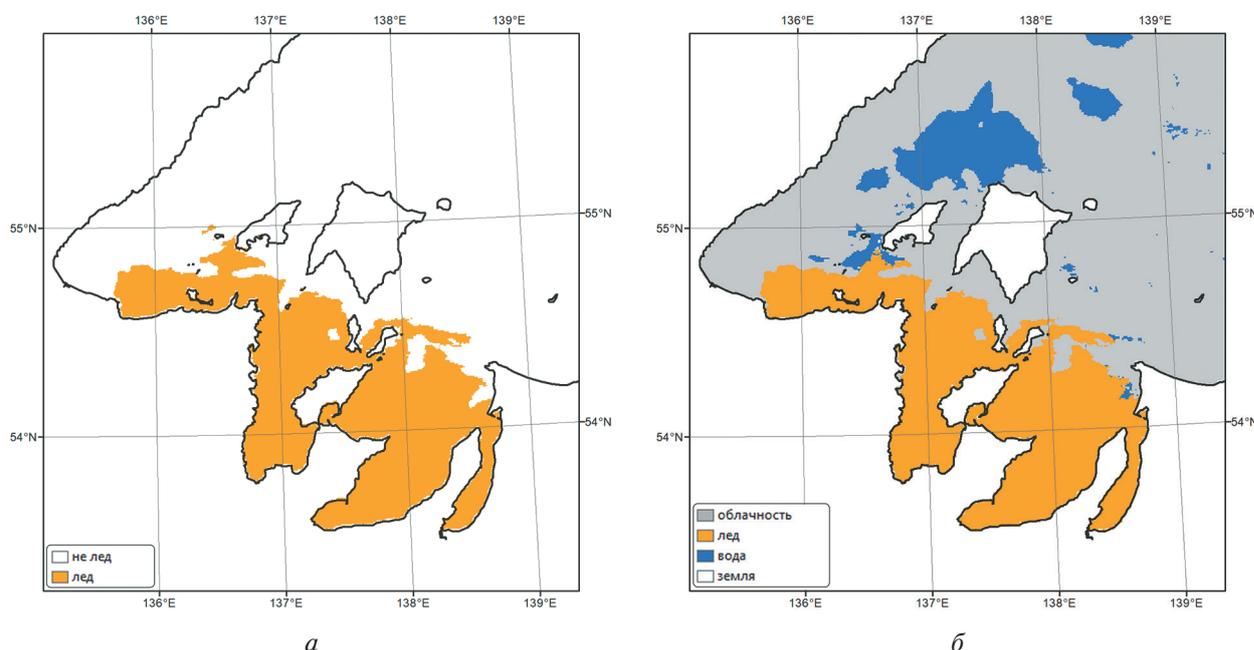


Рис. 3. Снимок от 03.12.2020, 02:33 UTC: *а* — эталонная маска ЛП; *б* — маска ЛП, полученная с помощью описанной в работе методики

Анализируя данные из *табл. 5*, можно сделать вывод, что рассчитанные с помощью разработанного алгоритма маски ЛП показали меньшую точность, чем маски по данным CSPP ASCI EDR. Дополнительный интерактивный анализ информации из *рис. 3*, а также других случаев, участвующих в валидации, показал, что уверенный морской ЛП детектируется разработанным алгоритмом без ошибок. Основные погрешности возникают на стыке воды

и льда, где температура в каналах М15 и М16 для воды и льда различается в обоих случаях не более чем на 0,1 К. Вероятность правильного определения для разработанного алгоритма оказалась на 34 % выше, чем по данным CSPP ASCI EDR.

Заключение

В ходе работы был проведён анализ существующих подходов к детектированию ЛП по данным прибора VIIRS, в ходе которого была выбрана методика на основе НС. Для обучения НС специалистами ДЦ НИЦ «Планета» была набрана ОБ в количестве 22 тыс. текстур. Эмпирическим методом были определены: архитектура НС; размер текстур, который составил 21×21 пиксель; входные параметры для обучения НС, а именно зенитный угол Солнца, каналы VIIRS М5, М10, М15, М16. Проведённая валидация по эталонным маскам ЛП, составленным специалистами ДЦ НИЦ «Планета» методами интерактивного дешифрирования, показала высокие значения метрик Precision, Recall и F-мера для класса «лёд»: 94, 98 и 96 % соответственно. Разработанная методика является законченным техническим решением и внедрена в оперативную практику ДЦ НИЦ «Планета».

Литература

1. Крамарева Л. С., Андреев А. И., Блощинский В. Д., Кучма М. О., Давиденко А. Н., Пустатинцев И. Н., Шамилова Ю. А., Холодов Е. И., Королев С. П. Использование нейронных сетей в задачах гидрометеорологии // Вычисл. технологии. 2019. Т. 24. № 6. С. 50–59. DOI: 10.25743/ICT.2019.24.6.007.
2. Кучма М. О., Лотарева З. Н., Слесаренко Л. А. Определение кромки ледового покрова Дальневосточных морей с использованием сверточных нейронных сетей по данным прибора МСУ-МР спутника «Метеор-М» № 2 // Материалы 18-й Всероссийской открытой конф. «Современные проблемы дистанционного зондирования Земли из космоса». 16–20 нояб. 2020. М.: ИКИ РАН, 2020. С. 217. DOI: 10.21046/18DZZconf-2020a.
3. Кучма М. О., Лотарева З. Н., Слесаренко Л. А. Определение маски ледяного покрова Дальневосточных морей по данным прибора МСУ-МР спутника «Метеор-М» № 2 // Исслед. Земли из космоса. 2021. № 2. С. 31–41. DOI: 10.31857/S0205961421020032.
4. Паундер Э. Физика льда: пер. с англ. М.: Мир, 1967. 190 с.
5. Спутниковые методы определения характеристик ледяного покрова морей / под ред. В. Г. Смирнова. СПб.: ААНИИ, 2011. 240 с.
6. Топоров А. И., Мясоедов А. Г., Гусев В. В. Использование нейросетевых подходов для мультиспектрального анализа спутниковых данных при проектировании объектов капитального строительства // Материалы 17-й Всероссийской открытой конф. «Современные проблемы дистанционного зондирования Земли из космоса». 11–15 нояб. 2019. М.: ИКИ РАН, 2019. С. 67.
7. Bloschinskiy V. D., Kuchma M. O., Andreev A. I., Sorokin A. A. Snow and cloud detection using a convolutional neural network and low-resolution data from the Electro-L No. 2 Satellite // J. Applied Remote Sensing. 2020. V. 14. No. 3. P. 034506. DOI: 10.1117/1.JRS.14.034506.
8. Crane R. G., Anderson M. R. Satellite discrimination of snow/cloud surfaces // Intern. J. Remote Sensing. 1984. No. 5. P. 213–223. DOI: 10.1080/01431168408948799.
9. Dorsey N. E. Properties of Ordinary Water-Substance in All Its Phases. Reinhold Publishing Corporation, 1940. 673 p. DOI: 10.1038/146145a0.
10. Godin R., Vicente G. Joint Polar Satellite System (JPSS) Operational Algorithm Description (OAD) Document for VIIRS Sea Surface Temperature (SST) Environmental Data Record (EDR) Software. USA: NASA Goddard Space Flight Center, 2017. 17 p.
11. Ioffe S., Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift // Proc. 32nd Intern. Conf. Machine Learning (ICML 15). 2015. V. 37. P. 448–456. DOI: 10.48550/arXiv.1502.03167.
12. Jezek K., Perovich D., Golden K., Luther C., Barber D., Gogineni P., Grenfell T., Jordan A., Mobley C., Nghiem S., Onstott R. Broad spectral, interdisciplinary investigation of the electromagnetic properties of sea ice // IEEE Trans. Geoscience and Remote Sensing. 1998. V. 36. P. 1633–1641. DOI: 10.1109/36.718635.
13. Key J. R., Mahoney R., Liu Y., Romanov P., Tschudi M., Appel I., Maslanik J., Baldwin D., Wang X., Meade P. Snow and ice products from Suomi NPP VIIRS // J. Geophysical Research: Atmospheres. 2013. V. 118. P. 12816–12830. DOI: 10.1002/2013JD020459.
14. Kingma D. P., Ba J. L. Adam: a method for stochastic optimization // Intern. Conf. Learning Representations. 2015. 13 p. DOI: 10.48550/arXiv.1412.6980.

15. Kuo J. C. Understanding convolutional neural networks with a mathematical model // J. Visual Communication and Image Representation. 2016. V. 41. P. 406–413. DOI: 10.48550/arXiv.1609.04112.
16. Minnett P. J. GHRSSST-PP Sea Ice Working Group (SI-WG) report // Report 8th GHRSSST-PP Science Team Meeting. 14–18 May 2007. Melbourne, Australia. 2007. V. 1. P. 57–60.
17. Mueller A., Guido S. An Introduction to Machine Learning with Python. O'Reilly Media, 2017. 188 p.
18. Riggs G., Hall D., Roman M. O. VIIRS Snow Cover Algorithm Theoretical Basis Document (ATBD). USA: NASA Goddard Space Flight Center, 2015. 38 p.
19. Salomonson V. V., Appel I. Estimating fractional snow cover from MODIS using the normalized difference snow index // Remote Sensing of Environment. 2004. V. 89. No. 3. P. 351–360. DOI: 10.1016/j.rse.2003.10.016.
20. Seaman C., Hillger D., Kopp T., Williams R., Miller S., Lindsey D. Visible Infrared Imaging Radiometer Suite (VIIRS) Imagery Environmental Data Record (EDR) User's Guide: NOAA Technical Report NESDIS 150. 2015. 35 p.
21. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // J. Machine Learning Research. 2014. V. 15. P. 1929–1958.
22. Zang L., Zang L., Du B. Deep learning for remote sensing data: a technical tutorial on the state of the art // IEEE Geoscience and Remote Sensing Magazine. 2016. V. 4. No. 2. P. 22–40. DOI: 10.1109/MGRS.2016.2540798.

Sea ice cover detection in the Russian Far Eastern seas using NOAA-20 VIIRS measurements and a neural network

M. O. Kuchma, Z. N. Lotareva, L. A. Korneva, Yu. A. Shamilova

*Far-Eastern Center of SRC Planeta, Khabarovsk 680000, Russia
E-mail: m.kuchma@dvrepod.ru*

In this paper, we consider the technology for calculating the ice cover mask using a convolutional neural network on the data of VIIRS measurements from the NOAA-20 satellite. Specialists of the Far-Eastern Center of State Research Center for Space Hydrometeorology “Planeta” (FEC SRC Planeta) collected a training dataset using data from October 2020 to June 2021 that amounted to about 22 thousand textures. The optimal neural network architecture for solving the problem was obtained by the empirical method. During the experiments, the optimal size of input textures was obtained, which was 21×21 pixels. In the same way, the input parameters were obtained, which were the solar zenith angle and infrared channels with central wavelengths of 0.6, 1.6, 10.7, and 12.0 μm. As reference data, ice cover masks were used, manually created by experienced decoders of FEC SRC Planeta. When compared with the data of the Community Satellite Processing Package VIIRS Aerosols, Cryosphere, Clouds and Volcanic Ash Environmental Data Record Products, the validation results of the developed algorithm showed high accuracy and probability of correct event identification — 94 and 98 %, respectively.

Keywords: remote sensing, VIIRS, NOAA-20, convolutional neural network, texture, ice, ice cover mask

Accepted: 25.03.2022

DOI: 10.21046/2070-7401-2022-19-2-32-42

References

1. Kramareva L. S., Andreev A. I., Bloshchinskiy V. D., Kuchma M. O., Davidenko A. N., Pustatintsev I. N., Shamilova Yu. A., Kholodov E. I., Korolev S. P., The use of neural networks in hydrometeorological problems, *Vychislitel'nye tekhnologii*, 2019, Vol. 24, No. 6, pp. 50–59 (in Russian), DOI: 10.25743/ICT.2019.24.6.007.
2. Kuchma M. O., Lotareva Z. N., Slesarenko L. A., Determination of the ice edge of the Far Eastern seas using convolutional neural networks according to the MSU-MR device of the Meteor-M satellite No. 2, *Materialy*

- 18-i Vserossiiskoi otkrytoi konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa" (Proc. 18th All-Russia Open Conf. "Current Problems in Remote Sensing of the Earth from Space"), 16–20 Nov. 2020, Moscow: IKI RAN, 2020, p. 217 (in Russian), DOI: 10.21046/18DZZconf-2020a.
3. Kuchma M. O., Lotareva Z. N., Slesarenko L. A., Ice cover detection of the Far Eastern Seas using the MSU-MR instrument of the Meteor-M No. 2 satellite, *Issledovanie Zemli iz Kosmosa*, 2021, No. 2, pp. 31–41 (in Russian), DOI: 10.31857/S0205961421020032.
 4. Paunder E., *Physics of Ice*, Oxford: Pergamon Press, 1967, 160 p.
 5. Smirnov V. G., *Sputnikovye metody opredeleniya kharakteristik ledyanogo pokrova morei* (Satellite methods for determining the characteristics of the sea ice cover), Saint Petersburg: AANII, 2011, 240 p. (in Russian).
 6. Toporov A. I., Myasoedov A. G., Gusev V. V., The use of neural network approaches for multispectral analysis of satellite data in the design of capital construction facilities, *Materialy 17-i Vserossiiskoi otkrytoi konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa"* (Proc. 17th All-Russia Open Conf. "Current Problems in Remote Sensing of the Earth from Space"), 11–15 Nov. 2019, Moscow: IKI RAN, 2019, p. 67 (in Russian).
 7. Bloschinskiy V. D., Kuchma M. O., Andreev A. I., Sorokin A. A., Snow and cloud detection using a convolutional neural network and low-resolution data from the Electro-L No. 2 Satellite, *J. Applied Remote Sensing*, 2020, Vol. 14, No. 3, p. 034506, DOI: 10.1117/1.JRS.14.034506.
 8. Crane R. G., Anderson M. R., Satellite discrimination of snow/cloud surfaces, *Intern. J. Remote Sensing*, 1984, No. 5, pp. 213–223, DOI: 10.1080/01431168408948799.
 9. Dorsey N. E., *Properties of Ordinary Water-Substance in All Its Phases*, Reinhold Publishing Corporation, 1940, 673 p., DOI: 10.1038/146145a0.
 10. Godin R., Vicente G., *Joint Polar Satellite System (JPSS) Operational Algorithm Description (OAD) Document for VIIRS Sea Surface Temperature (SST) Environmental Data Record (EDR) Software*, USA: NASA Goddard Space Flight Center, 2017, 17 p.
 11. Ioffe S., Szegedy C., Batch normalization: accelerating deep network training by reducing internal covariate shift, *Proc. 32nd Intern. Conf. Machine Learning (ICML 15)*, 2015, Vol. 37, pp. 448–456, DOI: 10.48550/arXiv.1502.03167.
 12. Jezek K., Perovich D., Golden K., Luther C., Barber D., Gogineni P., Grenfell T., Jordan A., Mobley C., Nghiem S., Onstott R., Broad spectral, interdisciplinary investigation of the electromagnetic properties of sea ice, *IEEE Trans. Geoscience and Remote Sensing*, 1998, Vol. 36, pp. 1633–1641, DOI: 10.1109/36.718635.
 13. Key J. R., Mahoney R., Liu Y., Romanov P., Tschudi M., Appel I., Maslanik J., Baldwin D., Wang X., Meade P., Snow and ice products from Suomi NPP VIIRS, *J. Geophysical Research: Atmospheres*, 2013, Vol. 118, pp. 12816–12830, DOI: 10.1002/2013JD020459.
 14. Kingma D. P., Ba J. L., Adam: a method for stochastic optimization, *Intern. Conf. Learning Representations*, 2015, 13 p., DOI: 10.48550/arXiv.1412.6980.
 15. Kuo J. C., Understanding convolutional neural networks with a mathematical model, *J. Visual Communication and Image Representation*, 2016, Vol. 41, pp. 406–413, DOI: 10.48550/arXiv.1609.04112.
 16. Minnett P. J., GHRSSST-PP Sea Ice Working Group (SI-WG) report, *Report 8th GHRSSST-PP Science Team Meeting*, 2007, Vol. 1, pp. 57–60.
 17. Mueller A., Guido S., *An Introduction to Machine Learning with Python*, O'Reilly Media, 2017, 188 p.
 18. Riggs G., Hall D., Roman M. O., *VIIRS Snow Cover Algorithm Theoretical Basis Document (ATBD)*, USA: NASA Goddard Space Flight Center, 2015, 38 p.
 19. Salomonson V. V., Appel I., Estimating fractional snow cover from MODIS using the normalized difference snow index, *Remote Sensing of Environment*, 2004, Vol. 89, No. 3, pp. 351–360, DOI: 10.1016/j.rse.2003.10.016.
 20. Seaman C., Hillger D., Kopp T., Williams R., Miller S., Lindsey D., *Visible Infrared Imaging Radiometer Suite (VIIRS) Imagery Environmental Data Record (EDR) User's Guide: NOAA Technical Report NESDIS 150*, 2015, 35 p.
 21. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *J. Machine Learning Research*, 2014, Vol. 15, pp. 1929–1958.
 22. Zang L., Zang L., Du B., Deep learning for remote sensing data: a technical tutorial on the state of the art, *IEEE Geoscience and Remote Sensing Magazine*, 2016, Vol. 4, No. 2, pp. 22–40, DOI: 10.1109/MGRS.2016.2540798.