

## МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ И ИНТЕРПРЕТАЦИИ КОСМИЧЕСКОЙ ИНФОРМАЦИИ

### ОПРЕДЕЛЕНИЕ МАСКИ ЛЕДЯНОГО ПОКРОВА ДАЛЬНЕВОСТОЧНЫХ МОРЕЙ ПО ДАННЫМ ПРИБОРА МСУ-МР СПУТНИКА “МЕТЕОР-М” № 2

© 2021 г. М. О. Кучма<sup>а</sup>, \*, З. Н. Лотарева<sup>а</sup>, Л. А. Слесаренко<sup>а</sup>

<sup>а</sup>Дальневосточный центр Федерального государственного бюджетного учреждения  
“Научно-исследовательский центр космической гидрометеорологии “Планета”, Хабаровск, Россия

\*E-mail: m.kuchma@dvrpod.ru

Поступила в редакцию 08.09.2020 г.

В настоящей работе рассматривается технология определения маски ледяного покрова с использованием сверточной нейронной сети применительно к данным многозонального сканирующего устройства малого разрешения, установленного на российском космическом аппарате “Метеор-М” № 2. Описаны критерии отбора параметров, участвующих в обучении нейронной сети, а также процесс определения размера текстур. С использованием метрик машинного обучения определена точность классификации разработанной модели. Валидация результатов показала, что полученный алгоритм имеет точность 94.9 и 96.7% по сравнению с масками ледяного покрова по данным продукта MOD10 прибора MODIS и архивными картами-схемами ледовой обстановки, построенными в соответствии с международной номенклатурой ВМО по морскому льду.

*Ключевые слова:* дистанционное зондирование Земли, МСУ-МР, сверточная нейронная сеть, текстуры, лед, маска ледяного покрова

DOI: 10.31857/S0205961421020032

#### ВВЕДЕНИЕ

В настоящее время данные дистанционного зондирования Земли (ДЗЗ) из космоса играют важную роль в обеспечении различных сфер деятельности человека, в том числе на морских акваториях. Оперативный анализ ледовой обстановки замерзающих морей позволяет своевременно оценивать ледовую обстановку на судоходных трассах, планировать ледокольные операции, повышать безопасность навигации, рыболовства и выполнения работ на морском шельфе. Согласно морской доктрине Российской Федерации на период до 2020 г., роль морских перевозок для жизнеобеспечения районов Крайнего Севера и Дальнего Востока продолжает оставаться решающей в обеспечении внутригосударственной и внешнеэкономической деятельности.

Необходимость создания и поддержания отечественной группировки космических аппаратов гидрометеорологического, океанографического, геофизического назначения и мониторинга окружающей среды в соответствии с утвержденной Распоряжением Правительства РФ от 3 сентября 2010 г. № 1458-р “Стратегией деятельности в области гидрометеорологии и смежных с ней областях на период до 2030 года” предусматривает одновременное развитие технологий и методик об-

работки и представления данных российских спутниковых миссий.

Поэтапное увеличение полярно-орбитальной группировки космических аппаратов (КА) серии “Метеор-М” дает специалистам большой дополнительный объем исходной информации о состоянии окружающей среды, в том числе ледовой обстановки на морских акваториях, однако на текущий момент разработанных и внедренных в оперативную практику методик детектирования и картирования льда по данным прибора МСУ-МР КА этой серии нет.

Описанные выше государственные задачи определяют актуальность разработки технологий автоматического построения карт-схем ледовой обстановки с использованием данных российского КА “Метеор-М” № 2, а в дальнейшем и всей группировки КА этой серии. В настоящей статье представлены первые результаты работ по детектированию маски ледяного покрова по данным многозонального сканирующего устройства малого разрешения (МСУ-МР) (Акимов и др., 2015) КА “Метеор-М” № 2.

#### ОБЗОР ИССЛЕДОВАНИЙ

Лед является сложной структурой и обладает массой параметров, которые зависят от освеще-

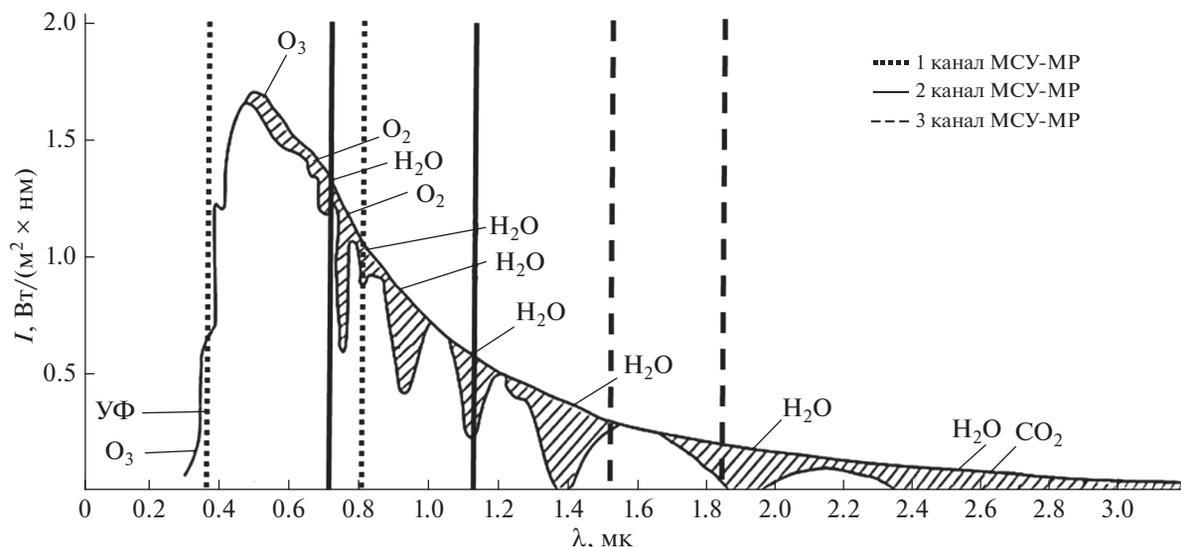


Рис. 1. Спектры солнечного излучения, приходящего на верхнюю границу атмосферы и на поверхность Земли.

ния, времени года, широты и других характеристик. Кроме этого, лед, в зависимости от своего состава, имеет разную отражательную способность, влияющую на его обнаружение со спутника. Доля солнечного излучения, отраженного льдом, снегом или водой, имеет резко выраженную спектральную зависимость, изученную во многих работах. В (Смирнов, 2011) показано, что на длинах волн до 0.9 мкм коэффициент спектральной яркости (КСЯ), характеризующий долю отраженного солнечного излучения (%), максимален, а после 0.9 мкм – в ближней ИК-области, уменьшается почти 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. Пониженные значения КСЯ характерны для загрязненного льда, в то время как чистый лед обладает сравнительно высокой прозрачностью в видимом диапазоне спектра (Dorsey, 1940; Паундер, 1967).

В настоящее время известно множество исследований по оценке границ и характеристик ледяного покрова по спутниковым данным (Baker, 2011; Jin et al., 2020; Hall et al., 2017; Key et al., 2013; Meier et al., 2017). Анализ ряда таких исследований показывает, что существующие алгоритмы тематической интерпретации параметров ледяного покрова могут по-разному функционировать в различных географических и климатических условиях. Помимо этого, на детектирование льда влияет атмосферный пограничный слой, который имеет разные характеристики и параметры для различных широт (Minnett, 2007). Например, в полярных районах, где разность температур воздух – вода велика, воздух имеет низкую влажность, что оказывает значительное влияние на ре-

гистрируемые значения КСЯ в каналах спутникового прибора. Покажем это на примере прибора МСУ-МР КА “Метеор-М” № 2. Часть приходящей солнечной энергии рассеивается или поглощается атмосферой. Вследствие различной концентрации газов и аэрозолей искажения электромагнитного излучения неоднородны как в пространстве, так и на разных длинах волн. На рис. 1 показаны спектры солнечного излучения, приходящего на верхнюю границу атмосферы (ВГА) и на поверхность Земли, а также границы чувствительности 1, 2 и 3 каналов МСУ-МР.

Полосы поглощения водяного пара, представленные на рисунке штриховыми линиями, в основном оказывают влияние на 2 и 3 каналы МСУ-МР. Водяной пар напрямую коррелирует с влажностью воздуха, поэтому регистрируемые прибором значения КСЯ в этих каналах подвергаются изменению из-за его влияния. Помимо этого, большое значение имеют функция спектральной чувствительности и ширина каждого из каналов спутникового прибора, или иначе, спектральные характеристики, которые для каждого спутникового прибора уникальны. Для прибора МСУ-МР эти характеристики приведены на рис. 2. Остальные основные параметры прибора представлены в табл. 1.

Перечисленные факторы накладывают значительные ограничения на точность и достоверность глобального детектирования ледяного покрова, связанные как с состоянием самого льда, так и его географическим и сезонным распределением, что зачастую требует определения оптимальных пороговых значений для различных параметров атмосферы и водной поверхности, имеющих существенные пространственные и

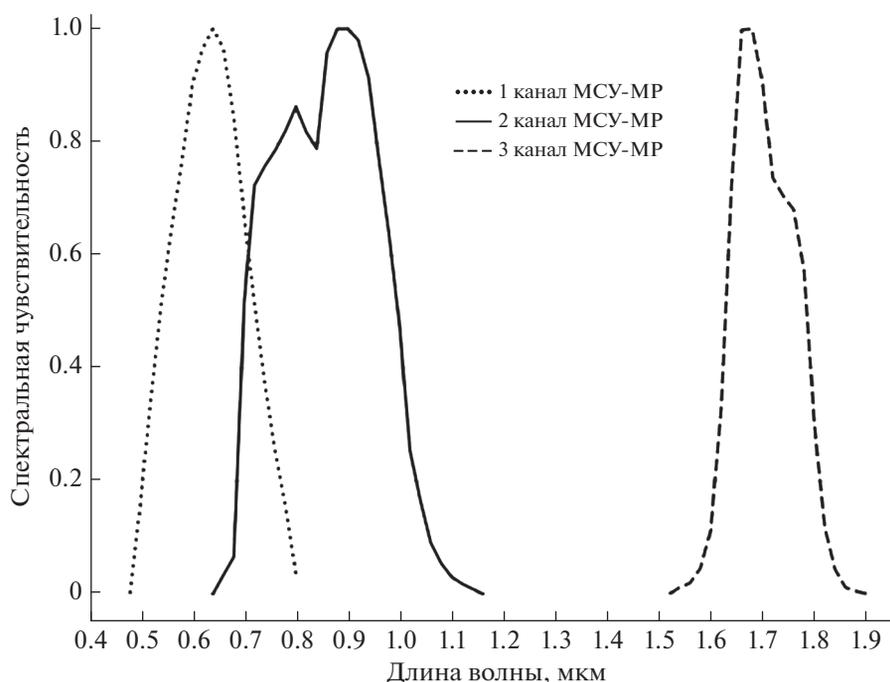


Рис. 2. Функции спектральной чувствительности коротковолновых каналов МСУ-МР.

временные вариации. Помимо этого, как указано выше, пороговые значения подбираются к каждому спутниковому прибору в отдельности, поскольку их спектральные характеристики различаются. Другим подходом к задаче детектирования льда является применение алгоритмов машинного обучения, которые могут работать не только с каждым пикселем в отдельности, но и с текстурами, представляющими собой участки изображения (Бондур, Старченков, 2001). Такой подход наиболее эффективен на начальном этапе детектирования ледяного покрова, а именно построения маски льда.

Маска льда применяется не только для дальнейшего картирования характеристик ледяного покрова, таких как сплоченность, возрастные характеристики и т.д., но также и при вычислении метеорологических параметров облачности. Достоверная информация о наличии льда под тонкой (полупрозрачной) облачностью позволяет учесть влияние подстилающей поверхности на измерения в каналах инфракрасного диапазона и, как следствие, добиться большей точности при расчете параметров такой облачности на верхней границе облачности. Таким образом, маска льда служит не только залогом к возможности создания целого ряда продукции по ледовой обстановке по данным прибора МСУ-МР, но и к качественному улучшению уже имеющихся технологий получения параметров облачности, используемых в прогнозировании.

Основываясь на анализе мирового опыта в области дистанционного зондирования Земли и обработки больших потоков спутниковых данных (Бондур, 2014; Бондур, Старченков, 2001), специалистами Дальневосточного центра НИЦ “Планета” ведутся активные работы по исследованию и реализации алгоритмов машинного обучения, в частности нейронных сетей, которые могут успешно применяться для задач классификации спутниковых изображений при решении различного рода тематических задач (Андреев и др., 2019; Блошинский и др., 2019; Крамарева и др., 2019а, б, в; Bloschchinskiy et al., 2020). В связи с этим для решения обозначенной проблемы будет применена методика контролируемого обучения нейронных сетей.

Таблица 1. Характеристики МСУ-МР

Характеристика	МСУ-МР
Спектральные диапазоны (мкм)	0.52–0.72
	0.7–1.1
	1.62–1.82
	3.5–4.1
	10.5–11.5
Полоса обзора (км)	2900
Разрешение (км)	1

## СОЗДАНИЕ ОБУЧАЮЩЕЙ ВЫБОРКИ

Для решения задачи детектирования ледяного покрова с помощью нейронных сетей по данным прибора МСУ-МР КА “Метеор-М” № 2 в работе рассматривается текстурный метод (Zang et al., 2016), где каждая текстура представляет собой сравнительно небольшой участок подстилающей поверхности и позволяет нейросети с достаточной точностью провести классификацию. Для реализации метода необходимо создать обучающую выборку (ОВ) на основе архивных спутниковых данных. В цифровом виде текстуры представляют собой трехмерные массивы, где третье измерение — это параметры, с использованием которых нейросеть сможет с достаточной точностью провести разделение по классам (Бондур, 2014). Такими параметрами могут быть КСЯ, яркостная температура каналов спутникового прибора, углы Солнца, время, широта или различные вегетационные индексы.

Создание ОВ для нейросетевых алгоритмов является одним из важнейших подготовительных этапов, поскольку от ее качества и размера напрямую зависит результат обучения нейронной сети. Проблема создания ОВ заключается в проведении точной классификации объектов на спутниковых изображениях, которая может проводиться двумя способами: вручную и автоматически. Существующие на данный момент средства автоматизации этого процесса уступают в точности ручному способу классификации и вносят погрешность в результат (Топоров и др., 2019). В Дальневосточном центре НИЦ “Планета” имеется положительный опыт решения задач формирования различных ОВ маркированных данных (Андреев и др., 2019; Блощинский и др., 2019; Крамарева и др., 2019а, б, в; Bloschinskiy et al., 2020), текстуры которых относятся к классам: облако, лед, вода и т.д. Необходимо отметить, что для удобства ручного набора ОВ в Дальневосточном центре НИЦ “Планета” была разработана программа “PlanetaMeteorTexMaker” (Андреев и др., 2018), которая предоставляет инструментарий для формирования выборки шаблонов, текстур и точек, выделенных оператором на спутниковых изображениях. С использованием этой программы оператор выбирает текстуру и отмечает класс, к которому она должна относиться.

При маркировке данных для ОВ авторами настоящей работы допускалось присутствие на текстуре объектов другого класса, однако центральный пиксель должен был обязательно соответствовать присваиваемому классу. Каждой отобранной текстуре присваивался один из трех классов: лед, лед под полупрозрачной облачностью или дымкой, вода. Стоит отметить, что классом лед подразумеваются все виды и состояния морского льда. Текстуры набиралась с ис-

пользованием данных прибора МСУ-МР КА “Метеор-М” № 2 с разрешением 1 км на пиксель за период с октября 2017 г. по апрель 2019 г. В рамках решения поставленной задачи было маркировано примерно 130 спутниковых изображений, на которых отмечено около 17 тыс. текстур.

Каждая помеченная текстура принадлежала к определенному классу и характеризовалась 11 параметрами, получаемыми с прибора МСУ-МР: измерения в шести каналах прибора МСУ-МР, зенитный солнечный и спутниковый углы, относительный азимутальный угол, а также индексы Normalized Difference Vegetation Index (NDVI) и Normalized Difference Snow Index (NDSI), которые рассчитывались по следующим формулам:

$$NDVI = (NIR - RED)/(NIR + RED), \quad (1)$$

$$NDSI = (RED - SWIR)/(RED + SWIR), \quad (2)$$

где RED, NIR и SWIR — 1-й, 2-й и 3-й каналы прибора МСУ-МР соответственно.

Такие характеристики необходимы для выбора в дальнейшем оптимального набора параметров при обучении нейросетевого алгоритма.

## ВЫБОР АРХИТЕКТУРЫ И ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ

От выбора архитектуры сети зависит точность классификации, время обучения и время расчета, т.е. получения продукта. Поскольку разрабатываемый алгоритм будет использоваться в оперативной практике, то точность классификации и время расчета являются критичными параметрами ввиду того, что продукт, полученный не оперативно, теряет свою актуальность. В связи с этим была поставлена задача реализовать архитектуру, которая будет иметь минимальное время расчета без снижения точности.

Для создания и использования нейронной сети авторами работы использована библиотека keras, написанная на языке Python. При обучении нейронной сети и проведении всех расчетов использовался персональный компьютер с характеристиками: процессор Intel Core i7-6700K, ОЗУ 32 ГБ, графический процессор NVIDIA GeForce 1060 3GB.

Для создания архитектуры нейронной сети необходимо определить размер входных данных, текстур, от которого зависит глубина нейросети. С учетом опыта разработки нейросетевых алгоритмов (Андреев и др., 2019; Блощинский и др., 2019; Крамарева и др., 2019а, б, в; Bloschinskiy et al., 2020) специалистами Центра был определен предполагаемый размер текстур 11 × 11 пикселей. Далее было реализовано несколько тестовых архитектур (рис. 3). Архитектуры имеют одинаковые входы и выходы, поэтому для упрощения на рисунке пунктиром выделены отличительные элементы каждой модели.

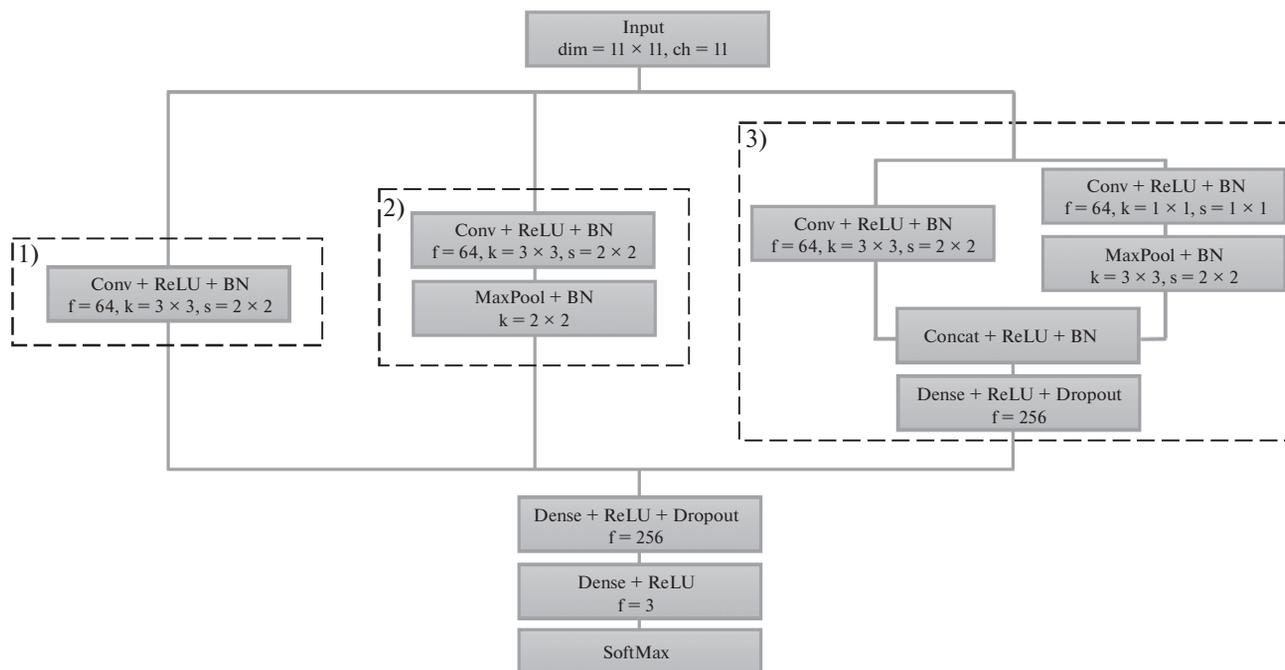


Рис. 3. Варианты архитектур нейронных сетей: 1) архитектура № 1; 2) архитектура № 2; 3) архитектура № 3.

На рис. 3 введены обозначения, которые будут описаны ниже. Input – входные данные размером  $11 \times 11$  пикселей (dim), имеющие 11 параметров (ch). Для всех слоев:  $f$  – количество выходных блоков,  $k$  – высота и ширина окна двумерной свертки,  $s$  – шаг свертки по высоте и ширине. Conv – сверточный двумерный слой “Conv2d” (Jay, 2016). ReLU – слой активации “Rectified linear unit” (ReLU), который имеет сходство с работой диода: значения меньше нуля принимаются за ноль, а значения больше нуля имеют линейную зависимость. BN – слой “BatchNormalization” (Ioffe, Szegedy, 2015), который нормализует слой активации предыдущего уровня в каждом блоке, то есть преобразовывает среднее значение активации, делая его близким к 0, а стандартное отклонение активации – близким к 1. MaxPool – слой “MaxPool2D” (Vougeau, 2010), который уменьшает входной слой, выбирая максимальное значение пикселя в скользящем окне. Concat – слой “Concatenation”, который объединяет входные слои в один. Dense – полносвязный слой нейронов. Dropout – слой “Dropout” (Srivastava, 2014), который случайным образом устанавливает значения нейронных связей в 0 с заданной частотой на каждом шаге во время обучения нейронной сети, что помогает предотвратить переобучение. SoftMax – функция активации “Softmax”, которая часто используется в качестве активации для последнего слоя нейросети с задачей классификации.

Для обучения нейронной сети в качестве функции потерь (loss) использовалась “categorical crossentropy” – категориальная кросс-энтропия, поскольку она наиболее эффективна, когда на выходе имеется более 2-х классов (Mueller, Guido, 2017). В качестве метрики использовалась “accuracy”, в качестве оптимизатора – “Adam” (Kingma, Ba, 2015), который часто используется в подобных задачах. Результаты тестирования архитектур, представленных на рис. 3, с размером текстур  $11 \times 11$  пикселей и полным набором параметров представлены в табл. 2.

Анализируя результаты тестирования, можно сделать вывод, что архитектура № 3, представленная на рис. 3, имеет наибольшую точность, соответствующую в первом приближении задаче определения маски льда. Эта архитектура была выбрана для дальнейших экспериментов.

После выбора архитектуры необходимо определиться с набором входных параметров. Чем меньше параметров подается на вход, тем быстрее работает в конечном итоге нейросеть. Для обна-

Таблица 2. Результаты тестирования на валидационной выборке

Архитектура	Loss	Accuracy
Архитектура № 1	0.38	0.86
Архитектура № 2	0.21	0.91
Архитектура № 3	0.15	0.95

Таблица 3. Матрица ошибок

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

ружения снежного и ледяного покрова используются коротковолновые инфракрасные каналы в диапазоне длин волн от 1.4 до 1.8 мкм (Crane, Anderson, 1984; Salomonson, Appel, 2004). На приборе МСУ-МР таким является 3 канал (табл. 1), поэтому его использование является необходимым для правильной работы нейронной сети.

Тестирование нейронной сети, при котором в качестве входных параметров подавался 3 канал с одним из других параметров, показало, что комбинация 2 и 3 каналов прибора МСУ-МР дает лучшую точность.

В дальнейшем было решено обучить нейронную сеть на комбинациях 2 и 3 каналов прибора МСУ-МР с различными вариантами комбинаций остальных параметров. Стоит отметить, что просто перестановка местами параметров не является новой комбинацией. В результате был произведен расчет около 500 различных моделей, проведено их сравнение с карт-схемами ледовой обстановки в акваториях морей, составленными в Дальневосточном центре НИЦ “Планета” в соответствии с международной номенклатурой ВМО по морскому льду (далее – эталонные карты).

Такое сопоставление было применено, поскольку оценка метриками машинного обучения иногда показывала высокую точность – более 90%, однако оказывалось, что из-за преобладающего влияния одного из параметров часть льда распознавалась как вода или наоборот. В результате была выбрана модель, которая обеспечивала наибольшее соответствие. Таким образом, был определен набор входных параметров: 2 и 3 каналы прибора МСУ-МР, зенитный угол спутника и Солнца, индекс NDVI.

Следующим шагом необходимо было определить оптимальный размер текстур. С этой целью были обучены нейронные сети с разными размерами текстур:  $17 \times 17$ ,  $15 \times 15$ ,  $13 \times 13$ ,  $11 \times 11$ ,  $9 \times 9$ ,  $7 \times 7$ ,  $5 \times 5$  и  $3 \times 3$  пикселей. Анализ метрик машинного обучения не дал достаточной информации о подходящем размере текстур, поскольку точность у всех тестируемых моделей была практически одинакова. В результате опять был применен метод сопоставления с эталонными картами и определен размер текстур –  $13 \times 13$  пиксе-

лей, с применением которого рассчитанная маска льда имела максимальную точность. Значения loss и accuracy для такого размера текстур и определенного выше набора параметров составили 0.13 и 0.96 соответственно.

### ВАЛИДАЦИЯ

Для валидации работы полученного классификатора использовались данные прибора MODIS – продукта MOD10 (Hall et al., 2001). Для расчета маски льда в этом алгоритме используются эмпирические пороговые значения для параметров температуры поверхности льда и индекса NDSI. Для корректного сравнения были подобраны данные КА Метеор-М № 2 и КА Aqua/Terra, близкие по времени пролета, с разницей не более 15 мин, расхождение по широте и долготе которых составляло не более 5 градусов. Всего было отобрано 11 снимков за 2017–2019 гг., которые удовлетворяли этим условиям. Поскольку в данных MOD10 есть только один класс льда, то класс “лед под дымкой” разработанного классификатора принимался как “лед”.

Для численной оценки рассчитывались коэффициенты, позволяющие оценить точность, вероятность ложного определения и т.д. При их расчете используется матрица ошибок (confusion matrix), представленная в табл. 3.

Формулы, по которым рассчитываются коэффициенты, представлены ниже:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}), \quad (3)$$

$$\begin{aligned} \text{Probability of detection (POD)} &= \\ &= \text{TP} / (\text{TP} + \text{FN}), \end{aligned} \quad (4)$$

$$\begin{aligned} \text{Probability of false detection (POFD)} &= \\ &= \text{FP} / (\text{FP} + \text{TN}), \end{aligned} \quad (5)$$

$$\begin{aligned} \text{F-measure} &= \\ &= 2(\text{Precision} \times \text{POD}) / (\text{Precision} + \text{POD}), \end{aligned} \quad (6)$$

здесь Precision – точность, POD – вероятность правильного определения события, POFD – вероятность неправильного определения события,

F-measure – f-мера, или параметр, отражающий соотношение рассчитанных и эталонных данных.

Необходимо отметить, что для построения карт с использованием обученного нейросетевого классификатора по данным МСУ-МР используется маска облачного покрова (Андреев и др., 2014), разработанная ранее в Дальневосточном центре НИЦ “Планета”, а в продукте MOD10 используется свой алгоритм по детектированию облачности. Поэтому сравнение полученных карт проводилось по двум вариантам: в первом использовались пиксели, в которых нет облачности как на MODIS, так и на МСУ-МР, во втором – в которых нет облачности только на МСУ-МР. Второй вариант использовался для оценки точности детектирования ледяного покрова по данным МСУ-МР на границах льда с водой и с облачностью, поскольку маски облачности MODIS и МСУ-МР отличаются. Результаты отражены в табл. 4.

Проводя анализ результатов из табл. 4, можно отметить, что если брать безоблачные пиксели на обоих приборах, то имеет место высокая точность 94.8%, а также низкая вероятность ложного детектирования 13.1%. Однако, если учитывать безоблачные пиксели только по МСУ-МР, то точность становится ниже, а вероятность ошибки выше. Для выяснения причин этого было проведено сравнение и подробный анализ валидации с эталонными картами.

Валидация с эталоном проводилась как для карт по данным МСУ-МР, так и для карт по данным MODIS. Результат показан в табл. 5.

Примеры эталонных карт и карт по данным МСУ-МР, MODIS показаны на рис. 4.

Анализируя информацию, полученную из табл. 5 и рис. 4, можно сделать вывод, что разработанный классификатор обладает высокой точностью – 96.7%, имеет вероятность определения 97.1% и с вероятностью 11.1% классифицирует пиксели маски ледяного покрова ошибочно. Это означает, что из всех дешифрованных пикселей эталонных карт только 2.9% не были обнаружены, а 11.1% всех пикселей были ложно классифицированы. Карты MODIS хоть и имеют большую точность – 97.9%, но только 69.4% всех эталонных пикселей ледяного покрова было обнаружено, то есть продукт MOD10 имеет недобор в детектировании льда.

Анализируя информацию фрагмента 3 на рис. 4, видно, что маска льда по данным MODIS в некоторых местах имеет прямоугольную форму. В описании алгоритма MOD10 указано, что по краям ледяного покрова пиксели часто идентифицируются как облачные. Эти проблемные пиксели иногда занимают большие площади, в границах которых находится редкий или тонкий лед на краю ледяного массива. Эта проблема связана

**Таблица 4.** Валидация рассчитанных карт МСУ-МР по данным MODIS

Параметр	Первый вариант	Второй вариант
Precision	94.89	69.09
POD	98.78	98.82
F-measure	96.79	81.32
POFD	13.11	38.84

**Таблица 5.** Валидация карт МСУ-МР и MODIS по эталонным данным

Параметр	Сравнение с МСУ-МР	Сравнение с MODIS
Precision	96.71	97.99
POD	97.13	69.47
F-measure	96.92	81.30
POFD	11.10	3.60

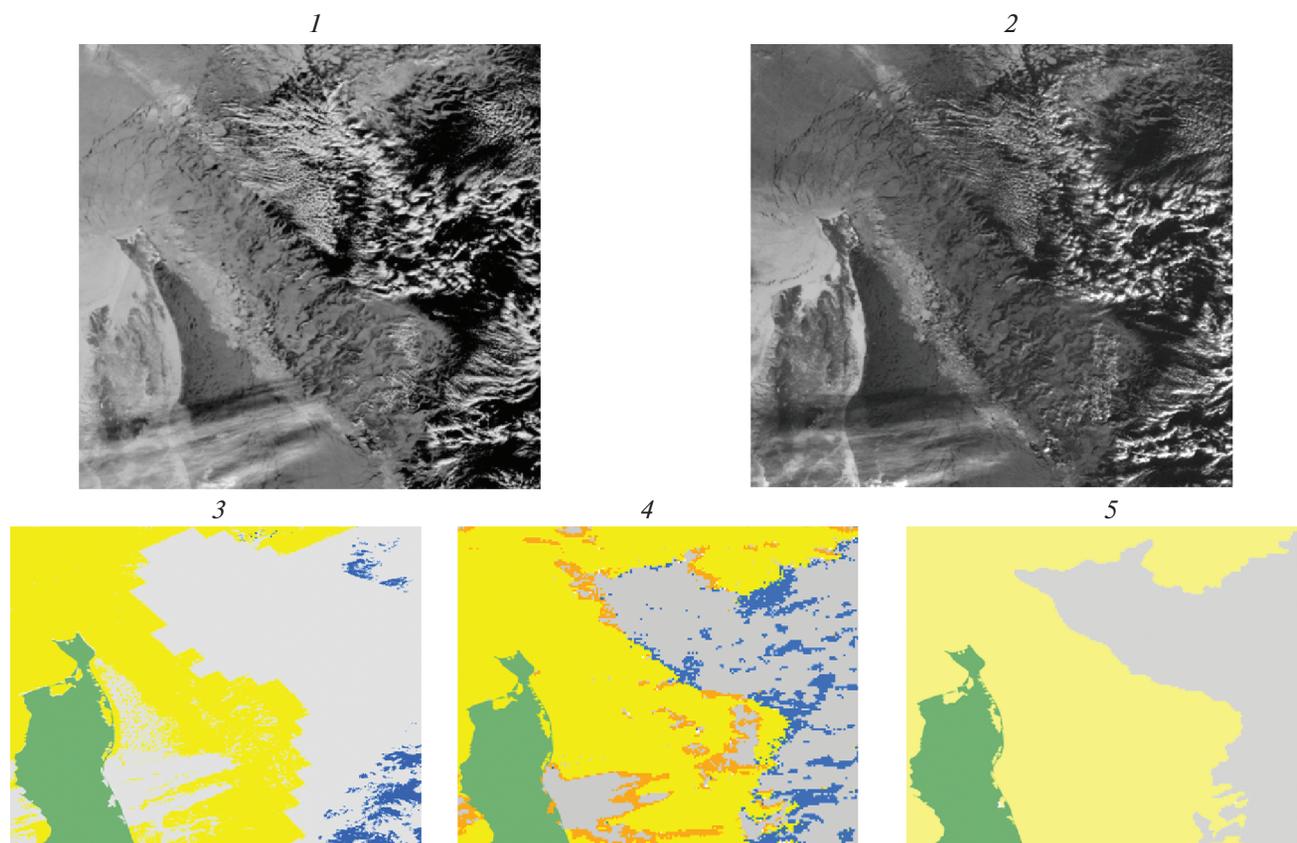
с пороговой методикой детектирования облачности по MODIS.

Стоит отметить, что кроме более высокой вероятности детектирования льда, разработанный классификатор с достаточной точностью выделяет границы ниласовых форм льда, которые не выделяются в продукте MOD10 (рис. 4). Также, сравнивая фрагменты 3 и 4 на рис. 4, можно заметить, что область у правого берега о. Сахалин, где находится лед, имеющий более темные тона, на картах MODIS детектируется как облачность, а на картах МСУ-МР – как лед, что соответствует факту. Таким образом, разработанный нейросетевой классификатор оказался более чувствительным к распознаванию льда с наличием на нем подтаявшего снега, перемешанного с соленой морской водой, что является весомым фактором в пользу его применения в оперативной практике.

## ЗАКЛЮЧЕНИЕ

В работе описан процесс получения рабочей методики определения маски льда по данным прибора МСУ-МР с использованием технологии сверточных нейронных сетей. Для обучения нейросети была создана выборка из 17 тысяч текстур, в которую входили данные МСУ-МР за период с 2017 по 2019 гг. Эмпирическим путем были выбраны оптимальные: архитектура сети, размер текстур и входные параметры.

Валидация по картам, полученным по данным прибора MODIS, показала точность 94.9% и вероятность ложного обнаружения 13.1%. Валидация по эталонным картам показала точность 96.7% и вероятность ложного обнаружения 11.1%.



**Рис. 4.** Участок Охотского моря: 1 – исходное изображение по данным MODIS; 2) исходное изображение по данным MCSU-MP; 3 – маска ледяного покрова по данным прибора MODIS (желтый – лед, синий – вода, зеленый – земля, серый – облачность); 4 – маска ледяного покрова по данным прибора MCSU-MP (желтый – лед, оранжевый – лед под дымкой, синий – вода, зеленый – земля, серый – облачность); 5 – эталонная маска ледяного покрова (желтый – лед, зеленый – земля, синий – вода и облачность).

Полученный нейросетевой классификатор может быть внедрен в оперативную работу специалистов для автоматизации начального этапа детектирования ледяного покрова, связанного с выделением кромки льда.

Проведенная работа является заделом для дальнейших работ по созданию тематических продуктов: возрастные характеристики, сплоченность и толщина льда.

#### СПИСОК ЛИТЕРАТУРЫ

Андреев А.И., Лотарева З.Н., Бородицкая А.В. Свидетельство о государственной регистрации программы для ЭВМ “PlanetaMeteorTexMaker” № 2018665185 // Зарегистрировано в Реестре программ для ЭВМ 3 декабря 2018 г.

Андреев А.И., Шамилова Ю.А., Холодов Е.И. Применение сверточной нейронной сети для детектирования облачности по данным прибора MCSU-MP спутника “Метеор-М” № 2 // Метеорология и гидрология. 2019. № 7. С. 44–53.

Акимов Н.П., Бадаев К.В., Гектин Ю.М., Рыжаков А.В., Смелянский М.Б., Фролов А.Г. Многозональное сканирующее устройство малого разрешения MCSU-MP для космического информационного комплекса “Метеор-М”. Принцип работы, эволюция, перспективы // Ракетно-космическое приборостроение и информационные системы. 2015. Т. 2. Вып. 4. С. 30–39. <https://doi.org/10.17238/issn2409-0239.2015.4.30>

Бондур В.Г. Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исслед. Земли из космоса. 2014. № 1. С. 4–16. <https://doi.org/10.7868/S0205961414010035>

Бондур В.Г., Старченков С.А. Методы и программы обработки и классификации аэрокосмических изображений // Изв. вузов. Геодезия и аэрофотосъемка. 2001. № 3. С. 118–143.

Блощинский В.Д., Кучма М.О., Андреев А.И. Применение сверточных нейронных сетей в задачах детектирования облачности и снежного покрова по данным прибора MCSU-ГС КА Электро-Л № 2 // Материалы 17-й Всероссийской открытой конференции “Современ-

- ные проблемы дистанционного зондирования Земли из космоса”. Москва: ИКИ РАН, 2019. С. 18.
- 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 // Вычислительные технологии. 2019а. Т. 24. № 6. С. 50–59. <https://doi.org/10.25743/ICT.2019.24.6.007>
- Крамарева Л.С., Андреев А.И., Симоненко Е.В., Сорокин А.А.* Применение сверточной нейронной сети для детектирования снега по данным многоканального спутникового устройства космического аппарата “Метеор-М” № 2 // Procedia Computer Science. 2019б. V. 150. P. 368–375.
- Крамарева Л.С., Пустынский И.С., Филей А.А., Андреев А.И., Кучма М.О., Блощинский В.Д.* Современные возможности и подходы Дальневосточного центра НИЦ “Планета” к решению научных и прикладных задач с использованием данных дистанционного зондирования (50 лет в области ДЗЗ) // Материалы 17-й Всероссийской открытой конференции “Современные проблемы дистанционного зондирования Земли из космоса”. Москва: ИКИ РАН, 2019в. С. 5.
- Паундер. Э.* Физика льда / Пер. с англ. М.: Мир, 1967. 190 с.
- Смирнов В.Г.* Спутниковые методы определения характеристик ледяного покрова морей / Под ред. В.Г. Смирнова. С.-П. ААНИИ, 2011. 240 с.
- 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 конференции “Современные проблемы дистанционного зондирования Земли из космоса”. Москва: ИКИ РАН, 2019. С. 67.
- Тренина И.С.* Космический мониторинг ледяного покрова для оперативного картирования и долгосрочных исследований // Соврем. пробл. дист. зондир. Земли из космоса. 2004. Т. 1. № 1. С. 303–316.
- Baker N.* Joint Polar Satellite System (JPSS) VIIRS Sea Ice Characterization Algorithm Theoretical Basis Document (ATBD) // NASA Goddard Space Flight Center: Greenbelt. MD. USA. 2011.
- Bloshchinskiy 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. Appl. Remote Sens. 2020. V. 14. № 3. 034506. <https://doi.org/10.1117/1.JRS.14.034506>
- Boureau Y., Ponce J., LeCun Y.* A theoretical analysis of feature pooling in visual recognition // 27th Int. Conf. Mach. Learn. (ICML'10). Madison: Omnipress, 2010. P. 111–118.
- Crane R. G., Anderson M. R.* Satellite discrimination of snow/cloud surfaces // International J. Remote Sensing. 1984. № 5. P. 213–223. <https://doi.org/10.1080/01431168408948799>
- Dorsey N.E.* Properties of ordinary water-substance // Amer. Chem. Soc. Monogr. Ser. 1940. № 81. P. 673. <https://doi.org/10.1002/qj.49708134736>
- Ioffe S., Szegedy C.* Batch normalization: accelerating deep network training by reducing internal covariate shift. 2015. Arxiv:1502.03167.
- Hall D.K., Riggs G.A., Salomonson V.V., Barton J.S., Casey K., Chien J.Y.L., DiGirolamo N.E., Klein A.G., Powell H.W., Tait A.B.* Algorithm Theoretical Basis Document (ATBD) for the MODIS Snow and Sea Ice-Mapping Algorithms // NASA Goddard Space Flight Center: Greenbelt. MD. USA. 2001. V. 45.
- Jay Kuo C.C.* Understanding convolutional neural networks with a mathematical model // J. Vis. Commun. Image Represent. 2016. Vol. 41. P. 406–413. arXiv:1609.04112.
- Jezeq K.C., Perovich D., Golden K.M., Luther C., Barber D., Gogineni P., Grenfell T., Jordan A., Mobley C., Nghiem S.V., Onstott R.* A broad spectral, interdisciplinary investigation of the electromagnetic properties of sea ice // IEEE Trans. Geosci. Remote Sens. 1998. V. 36. № 5. P. 1633–1641. <https://doi.org/10.1109/36.718635>
- Jin D., Chung S.R., Lee K.S., Seo M., Choi S., Seong N.H., Jung D., Sim S., Kim J., Han K.S.* Development of Geo-KOMPSAT-2A Algorithm for Sea-Ice Detection Using Himawari-8/AHI Data // Remote Sens. 2020. V. 12. P. 2262. <https://doi.org/10.3390/rs12142262>
- 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. Geophys. Res.: Atmos. 2013. P. 118. <https://doi.org/10.1002/2013JD020459>
- Kingma D.P., Ba J.L.* Adam: a method for stochastic optimization. 2015. Arxiv:1412.6980.
- Meier W.N., Markus T., Comiso J., Ivano A., Miller J.* AMSR2 Sea Ice Algorithm Theoretical Basis Document // NASA Goddard Space Flight Center: Greenbelt. MD. USA. 2017.
- Minnett P.J.* GHRSSST-PP Sea Ice Working Group (SI-WG) report // 8th GHRSSST-PP Science Team Meeting. 14–18 May 2007. Melbourne, Australia, 2007. Vol. 1. P. 36–39.
- Mueller A., Guido S.* An Introduction to Machine Learning with Python. O'Reilly Media, Inc., 2017. P. 402.
- Salomonson V. V., Appel I.* Estimating fractional snow cover from MODIS using the normalized difference snow index // Remote Sensing of Environment. 2004. № 89. P. 351–360. <https://doi.org/10.1016/j.rse.2003.10.016>
- Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R.* Dropout: a simple way to prevent neural networks from overfitting // J. Mach. Learn. Res. 2014. V. 15. P. 1929–1958.
- Zang L., Zang L., Du B.* Deep learning for remote sensing data: a technical tutorial on the state of the art // IEEE Geosci. Remote Sens. Mag. 2016. V. 4. № 2. P. 22–40. <https://doi.org/10.1109/MGRS.2016.2540798>

## Ice Cover Detection of the Far Eastern Seas Using the MSU-MR Instrument of the Meteor-M No. 2 Satellite

M. O. Kuchma<sup>1</sup>, Z. N. Lotareva<sup>1</sup>, and L. A. Slesarenko<sup>1</sup>

<sup>1</sup>Far-Eastern Center of State Research Center for Space Hydrometeorology "Planeta", Khabarovsk, Russia

In this paper the technology for determining the boundaries of the sea ice cover using a convolutional neural network in relation to the data of a low-resolution multispectral scanning device installed on the Russian satellite "Meteor-M" No. 2 is considered. The paper describes the selection criteria for the parameters involved in training the neural network, as well as the process of texture size determination. The classification score of the developed model was determined using machine learning metrics. The validation results showed that the obtained algorithm has a probability of detection 94.9 and 96.7% in comparison with the maps of the ice cover boundaries from MOD10 product of the MODIS instrument and archived maps of ice conditions, built in accordance with the WMO international nomenclature for sea ice.

*Keywords:* remote sensing, MSU-MR, convolutional neural network, texture, ice, sea ice cover

### REFERENCES

- Andreev A.I., Lotareva Z.N., Boroditskaya A.V.* Svidetel'stvo o gosudarstvennoy registratsii programmy dlya EVM "PlanetaMeteorTexMaker" № 2018665185 [Certificate of state registration of the computer program "PlanetaMeteorTexMaker" No. 2018665185] // Zaregistrirvano v Reestre programm dlya EVM 3 December 2018 (In Russian).
- Andreev A.I., Shamilova Yu.A., Holodov E.I.* Primenenie svertochnoy neyronnoy seti dlya detektirovaniya oblachnosti po dannym pribora MSU-MR sputnik "Meteor-M" № 2 [Application of a convolutional neural network for cloud detection according to the MSU-MR device of the Meteor-M satellite No. 2] // Meteorologiya i gidrologiya. 2019. № 7. P. 44–53 (In Russian).
- Akimov N.P., Badaev K.V., Gektin YU.M., Ryzhakov A.V., Smelyanskiy M.B., Frolov A.G.* Mnogozonal'noe skaniruyushee ustroystvo malogo razresheniya MSU-MR dlya kosmicheskogo informatsionnogo kompleksa "Meteor-M". Printsip raboty, evolyutsiya, perspektivy [Multiband scanner of low spatial resolution MSU-MR for space-based informational system "Meter-M". The principle of operation and development prospects] // Raketno-Kosmicheskoe priborostroenie i informatsionnye sistemy. 2015. T. 2. V. 4. P. 30–39. DOI: 10.17238/issn2409-0239.2015.4.30
- Baker N.* Joint Polar Satellite System (JPSS) VIIRS Sea Ice Characterization Algorithm Theoretical Basis Document (ATBD) // NASA Goddard Space Flight Center: Greenbelt. MD. USA. 2011.
- Bloschinskiy V.D., Kuchma M.O., Andreev A.I.* Primenenie svertochnykh neyronnykh setey v zadachah detektirovaniya oblachnosti i snezhnogo pokrova po dannym pribora MSU-GS KA Elektro-L № 2 [Application of convolutional neural networks in the problems of detecting clouds and snow cover according to the data of the MSU-GS device of the Electro-L № 2 satellite] // Materialy 17-y Vserossiyskoy otkrytoy konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa". Moskva: IKI RAN, 2019. P. 18 (In Russian).
- 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. Appl. Remote Sens. 2020. V. 14. № 3. 034506. DOI: 10.1117/1.JRS.14.034506
- Bondur V.G.* Modern Approaches to Processing Large Hyperspectral and Multispectral Aerospace Data Flows // Izv., Atmos. Oceanic Phys.. 2014. V. 50. № 9. P. 840–852. DOI: 10.1134/S0001433814090060
- Bondur V.G., Starchenkov S.A.* Metody i programmy obrabotki i klassifikatsii aerokosmicheskikh izobrazheniy (Methods and programs for aerospace imagery processing and classification) // Izvestia Vuzov. Geodesy and Aerophotography. 2001. № 3. P. 118–143 (In Russian).
- Boureau Y., Ponce J., LeCun Y.* A theoretical analysis of feature pooling in visual recognition // 27th Int. Conf. Mach. Learn. (ICML'10). Madison: Omnipress, 2010. P. 111–118.
- Crane R.G., Anderson M.R.* Satellite discrimination of snow/cloud surfaces // International J. of Remote Sensing. 1984. № 5. P. 213–223. DOI: 10.1080/01431168408948799
- Dorsey N.E.* Properties of ordinary water-substance // Amer. Chem. Soc. Monogr. Ser. 1940. № 81. P. 673. DOI: 10.1002/qj.49708134736
- Ioffe S., Szegedy C.* Batch normalization: accelerating deep network training by reducing internal covariate shift. 2015. Arxiv:1502.03167.
- Hall D.K., Riggs G.A., Salomonson V.V., Barton J.S., Casey K., Chien J.Y.L., DiGirolamo N.E., Klein A.G., Powell H.W., Tait A.B.* Algorithm Theoretical Basis Document (ATBD) for the MODIS Snow and Sea Ice-Mapping Algorithms // NASA Goddard Space Flight Center: Greenbelt. MD. USA. 2001. V. 45.
- Jay Kuo C.C.* Understanding convolutional neural networks with a mathematical model // J. Vis. Commun. Image Represent. 2016. V. 41. P. 406–413. arXiv:1609.04112.
- Jezeq K.C., Perovich D., Golden K.M., Luther C., Barber D., Gogineni P., Grenfell T., Jordan A., Mobley C., Nghiem S.V., Onstott R.* A broad spectral, interdisciplinary investigation of the electromagnetic properties of sea ice // IEEE Trans. Geosci. Remote Sens. 1998. V. 36. № 5. P. 1633–1641. DOI: 10.1109/36.718635
- Jin D., Chung S.R., Lee K.S., Seo M., Choi S., Seong N.H., Jung D., Sim S., Kim J., Han K.S.* Development of Geo-KOMPSAT-2A Algorithm for Sea-Ice Detection Using Himawari-8/AHI Data // Remote Sens. 2020. V. 12. P. 2262. DOI: 10.3390/rs12142262
- 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. Geophys. Res. Atmos.* 2013. 118. DOI: 10.1002/2013JD020459
- Kingma D.P., Ba J.L.* Adam: a method for stochastic optimization. 2015. Arxiv:1412.6980.
- Meier W.N., Markus T., Comiso J., Ivano A., Miller J.* AMSR2 Sea Ice Algorithm Theoretical Basis Document // NASA Goddard Space Flight Center: Greenbelt. MD. USA. 2017.
- Kramareva L.S., Andreev A.I., Bloshinskiy V.D., Kuchma M.O., Davidenko A.N., Pustatintsev I.N., Shamilova Yu.A., Holodov E.I., Korolev S.P.* Ispol'zovanie neyronnyh setey v zadachah gidrometeorologii [The use of neural networks in hydrometeorology problems] // *Computational Technologies.* 2019a. V. 24. № 6. P. 50–59 (In Russian). DOI: 10.25743/ICT.2019.24.6.007
- Kramareva L.S., Andreev A.I., Simonenko E.V., Sorokin A.A.* Primenenie svertochnoy neyronnoy seti dlya detektirovaniya snega po dannym mnogokanal'nogo sputnikovogo ustroystva kosmicheskogo apparata "Meteor-M" № 2 [Application of a convolutional neural network for snow detection based on data from a multichannel device of the Meteor-M No. 2 satellite] // *Procedia Computer Science.* 2019b. V. 150. P. 368–375 (In Russian).
- Kramareva L.S., Pustynskiy I.S., Filey A.A., Andreev A.I., Kuchma M.O., Bloshinskiy V.D.* Sovremennye vozmozhnosti i podhody Dal'nevostochnogo tsentra NITS "Planeta" k resheniyu nauchnyh i prikladnyh zadach s ispol'zovaniem dannyh distantsionnogo zondirovaniya (50 let v oblasti DZZ) [Modern possibilities and approaches of the Far Eastern Center of State Research Center "Planeta" to solving scientific and applied problems using remote sensing data (50 years in the field of remote sensing)] // *Materialy 17-y Vserossiyskoy otkrytoy konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa"*. Moskva: IKI RAN, 2019c. P. 5 (In Russian).
- Minnett P.J.* GHRSSST-PP Sea Ice Working Group (SI-WG) report // 8th GHRSSST-PP Science Team Meeting. 14–18 May 2007. Melbourne, Australia, 2007. V. 1. P. 36–39.
- Mueller A., Guido S.* An Introduction to Machine Learning with Python. O'Reilly Media, Inc., 2017. P. 402.
- Paunder E.* Fizika l'da [Physics of Ice] / Per. s angl. M.: Mir, 1967. P. 190 (In Russian).
- Salomonson V.V., Appel I.* Estimating fractional snow cover from MODIS using the normalized difference snow index // *Remote Sensing of Environment.* 2004. № 89. P. 351–360. DOI: 10.1016/j.rse.2003.10.016.
- Smirnov V.G.* Sputnikovye metody opredeleniya harakteristik ledyanogo pokrova morey [Satellite Methods for Determining the Characteristics of the Ice Cover of the Seas] / Ed. V.G. Smirnova. SPb.: AANII, 2011. 240 p. (In Russian).
- Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R.* Dropout: a simple way to prevent neural networks from overfitting // *J. Mach. Learn. Res.* 2014. V. 15. P. 1929–1958.
- Toporov A.I., Myasoedov A.G., Gusev V.V.* Ispol'zovanie neyrosetyevykh podhodov dlya mul'tispektral'nogo analiza sputnikovyyh dannyh pri proektirovanii ob'ektov kapital'nogo stroitel'stva [The use of neural network approaches for multispectral analysis of satellite data in the design of capital construction facilities] // *Materialy 17-y Vserossiyskoy otkrytoy konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa"*. Moskva: IKI RAN, 2019. P. 67 (In Russian).
- Trenina I.S.* Kosmicheskii monitoring ledyanogo pokrova dlya operativnogo kartirovaniya i dolgovremennyh issledovaniy [Space monitoring of ice cover for operational mapping and long-term research] // *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa.* 2004. T. 1. № 1. P. 303–316 (In Russian).
- Zang L., Zang L., Du B.* Deep learning for remote sensing data: a technical tutorial on the state of the art // *IEEE Geosci. Remote Sens. Mag.* 2016. V. 4. № 2. P. 22–40. DOI: 10.1109/MGRS.2016.2540798