

# Распознавание облаков на гиперспектральных спутниковых изображениях с использованием объяснимой модели машинного обучения

А.С. Минкин✉, О.В. Николаева\*

*Институт прикладной математики им. М.В. Келдыша РАН  
125047, г. Москва, пл. Муусская, 4*

Поступила в редакцию 11.07.2023;  
после доработки 27.10.2023;  
принята к печати 30.10.2023

Рассматривается задача построения алгоритма на основе нейронных сетей и машинного обучения для нахождения облаков на гиперспектральных снимках. Требуется, чтобы сеть позволяла провести анализ причин принятия решений и результатов классификации. Предложенная гибридная модель содержит дерево решений, обученное распознавать сплошную облачность (модель 1) на предварительно выбранных производных признаках исходного снимка в сочетании со сверточной нейронной сетью (модель 2). Модель 2 использует результаты работы модели 1 совместно со значениями яркости в выбранном канале снимка. Модель 1 находит ядра облаков, а модель 2 — их границы. Приведены результаты тестирования гибридной модели на данных сенсора HYPERION, полученных над поверхностями трех типов (океан, растительность, урбанизированная территория). Вычислены общая точность, а также ошибки ложного распознавания и ложного пропускания. Показано, что гибридная модель позволяет находить 85% облачных пикселей, только если нейронная сеть (модель 2) обучена на изображениях, для которых контраст достигает наибольшего значения в том же спектральном канале. Результаты настоящей работы могут быть применены для решения общей задачи анализа и обработки многоспектральных спутниковых изображений и в дальнейшем востребованы для изучения окружающей среды и мониторинга растительности, океана и ледников.

*Ключевые слова:* многоспектральные спутниковые изображения, обнаружение облаков, спектральные индексы, модели машинного обучения, сверточные нейронные сети, объяснимые модели; multispectral satellite image, cloud detection, spectral index, machine learning model, convolutional neural network, explainable model.

## Введение

Выявление облаков и их теней на многоспектральных снимках — первый необходимый шаг в их анализе. Например, восстановление оптической толщины аэрозоля возможно только по данным, полученным в условиях чистого неба. При мониторинге территории необходимо предварительное удаление облаков и их теней со снимков, иначе они будут ошибочно приняты за измененные участки поверхности.

Методы обнаружения облаков могут быть разделены на две большие группы: с использованием только одного снимка или же серии разновременных снимков одной территории. В методах первой группы используются спектральные критерии для выделения облачных и теневых пикселей. С их помощью облака отделяются от других ярких объектов

(снега, искусственных поверхностей, яркой воды), а облачные тени — от темных объектов (влажной почвы, воды). Но не все приборы обладают нужными для вычисления спектральных индексов каналами. Тогда привлекаются индексы формы (предполагается, что облако имеет более сложную форму, чем наземный объект) [1], текстурные признаки [2]. Для повышения точности облачно-теневого маски из нее могут быть исключены все тени, в проекции которых на солнце не находятся облака подходящей формы [2]. Однако в этом случае возможны сложности с нахождением облаков/теней, лежащих вне снимка.

Проблемой также является определение пороговых значений индексов и признаков. Эти значения находятся либо из анализа большого числа снимков [3], либо из результатов математического моделирования взаимодействия излучения с аэрозолем и облаками [4]. Однако результаты тестирования существующих методов показывают, что оцененные таким образом пороговые значения не всегда позволяют с достаточной точностью найти

\* Александр Сергеевич Минкин (amink@mail.ru);  
Ольга Васильевна Николаева (nika@kiam.ru).

границу облака и отделить облако от земных объектов. В частности, пороговые значения зависят от альbedo подстилающей поверхности; при ошибке в определении альbedo можно принять за облако яркий объект.

Поэтому развиваются методы, в которых рассматривается серия разновременных снимков одной территории. Здесь облака и тени идентифицируются как измененные части снимков [5]; такой подход предполагает либо хранение архива чистых снимков каждого участка [6], либо составление чистого мозаичного снимка по всем снимкам серии [7]. Развита специальная алгоритмы, позволяющий надежно находить измененные части на серии снимков [8]. Однако снимки серии, как правило, получены с интервалом по меньшей мере в несколько дней, и за облако или тень могут быть приняты изменения поверхности после пожара, сбора урожая, паводка или сезонного изменения растительности. Поэтому чтобы определить, является ли то или иное изменение облаком или тенью, также используются спектральные критерии [9] или же выполняется статистический анализ временных рядов данных [10].

В настоящем столетии очень популярными стали нейросетевые методы, в которых строится многоуровневая нелинейная аппроксимация [11] зависимости облачно-теневой маски от значений яркости в каналах многоспектрального снимка. Вместо или вместе со значениями яркости в каналах могут использоваться и значения спектральных [12] или текстурных индексов [13]. Подбор числа слоев в нейросетях, сопряжение нескольких сетей и оптимизация гиперпараметров [14] повышают точность классификации. Предполагается, что использование для обучения сети достаточно представительной выборки позволит обеспечить высокую точность распознавания облаков и их теней.

Большую популярность получили ансамблевые алгоритмы, в которых классификация выполняется с помощью параллельного или последовательного применения элементарных классификаторов, обучаемых на всей выборке или ее подмножествах на основе анализа множества признаков или их подгруппы, а итоговый результат определяется путем агрегирования или последовательной коррекции результатов работы элементарных классификаторов. Для реализации последних в составе ансамбля применяется один и тот же алгоритм: например, для решения задачи распознавания облаков в [15] применяется случайный лес, в то время как в [16] — метод опорных векторов в реализации *adaboostSVM*. Если же используются различные методы, то независимо: например, нейронная сеть в сочетании с каскадом деревьев решений [17]. В общий алгоритм могут также включаться пороговые алгоритмы, создающие начальные облачные маски [15], или детерминистические методы, такие как метод разбиения на суперпиксели [17, 18].

Основная проблема, связанная с нейросетевыми методами, состоит в том, что структура выбранной нейросети может не соответствовать структуре

аппроксимируемого отображения многоспектрального изображения на облачно-теневую маску. Это связано, прежде всего, с очень большими вариациями в свойствах облаков и подстилающих поверхностей. Обычно для обучения нейронной сети выбирается некоторый набор многоспектральных изображений; небольшая часть набора используется для обучения, остальная часть — для тестирования. Однако из того факта, что на тестовой части данной выборки нейронная сеть показывает хорошие результаты, не следует, что она покажет столь же хорошие результаты на другой выборке, состоящей из изображений, полученных в других атмосферных условиях над другой местностью. Кроме того, включение в нейросеть большого числа слоев затрудняет анализ причин принятия решений и возникновения ошибок классификации.

Целью настоящей работы является построение алгоритма распознавания облаков на многоспектральных спутниковых изображениях на основе объяснимой модели машинного обучения [19]. Будем определять «объяснимость модели» как возможность проанализировать взаимосвязи между входными данными и результатом классификации, т.е. объяснить, как и почему принимается некоторое решение. Внутренняя логика работы самой модели может оставаться непрозрачной, но при этом должно быть ясно, как получается некоторый результат при заданных входных данных, каковы значения отдельных признаков [20] и их влияние на работу модели в целом.

Основная проблема, связанная с распознаванием облаков, состоит в том, что пороговые значения в спектральных и текстурных критериях могут быть надежно получены (как путем анализа изображений, так и численного моделирования) только для сплошной облачности и непригодны для распознавания краев облаков. Поэтому развиваются алгоритмы, где спектральные и текстурные критерии используются только для нахождения наиболее плотных и ярких участков (ядер) облаков. Далее выполняется размытие краев облаков с помощью линейного фильтра [1] или метод заливки (*flood filling*) [21]. Аналогичная модель классификатора для распознавания облаков предложена в разд. 1. Подчеркнем, что, в отличие от работ [15–17], классификаторы, реализованные в виде различных алгоритмов, применяются не параллельно, а последовательно, т.е. полученная первым классификатором маска, содержащая ядра облаков, образует входные данные для второго классификатора, находящего края облаков.

## 1. Модель классификатора для распознавания облаков

Предложенный в настоящей работе облачный классификатор представляет собой каскад из двух классификаторов. Первый учитывает исключительно спектральную информацию, а второй анализирует пространственную взаимозависимость между соседними пикселями по выделенному каналу много-

спектрального изображения. Данный подход можно интерпретировать как построение ансамбля зависимых моделей, что позволяет проводить независимый анализ их работы с целью создания объяснимой модели. В нашей статье построение классификатора предполагает обучение на примерах с заранее заданными метками классов, т.е. обучение с учителем.

Первый классификатор (модель 1) распознает пиксели, имеющие спектральные характеристики сплошного облачного слоя. Иначе говоря, модель 1 находит ядра облаков. В обучении модели 1 используются спектры, измеренные в пикселях, отвечающих сплошной облачности и чистому небу. При этом рассматриваются снимки, сделанные над поверхностями разного типа. Таким образом, модель 1 обучается отличать облачность как от темных (вода, растительность), так и от ярких (горная порода) поверхностей.

Для каждого из пикселей, которые используются для обучения, может быть рассмотрен как полный спектр, так и набор производных характеристик. Ограниченность вычислительных возможностей оборудования в сочетании с корреляциями данных по соседним спектральным каналам предполагает выбор значимых признаков. В данной работе используются следующие признаки:

- 1)  $R(559)$ ;
- 2) normalized difference vegetation index

$$NDVI = \frac{R(844) - R(651)}{R(844) + R(651)}$$

- 3) normalized difference snow index

$$NDSI = \frac{R(559) - R(1650)}{R(559) + R(1650)}$$

- 4) normalized difference moisture index

$$NDMI = \frac{R(815) - R(1610)}{R(815) + R(1610)}$$

- 5) normalized difference water index

$$NDWI = \frac{R(651) - R(1436)}{R(651) + R(1436)}$$

где  $R(\lambda)$  – коэффициент яркости пикселя в канале, соответствующем длине волны  $\lambda$ , нм. Отметим, что здесь используются неспецифические признаки, поскольку в модели 1 находятся пиксели, отвечающие сплошной облачности, т.е. нет необходимости в специальных признаках для нахождения края облака.

В качестве модели 1 для распознавания ядер облаков использовано дерево решений, сочетающее преимущества экспертной системы с механизмом обучения на примерах. Обученное дерево решений может быть представлено в виде текстов правил [22]. Особенность данной модели состоит в относительной простоте, объяснимости и нелинейности, так как в ней нет однозначной связи между зависимой (метка класса) и независимыми переменными (признаки 1–5). В связи со склонностью деревьев решений к переобучению, а также сложностью интерпретации больших деревьев рассматриваются деревья с максимальным числом уровней, равным 4. Это означает, что после 4-го уровня дерево должно прекратить дальнейшее расширение. Для обучения дерева решений был использован один из вариантов алгоритма CART [23], реализованный в библиотеке scikit-learn, а для оценки качества разделения классов – энтропия. Полученное дерево решений приведено на рис. 1. После применения модели 1 формируется маска 1: в «облачных» пикселях она содержит 1, в «чистых» – 0.

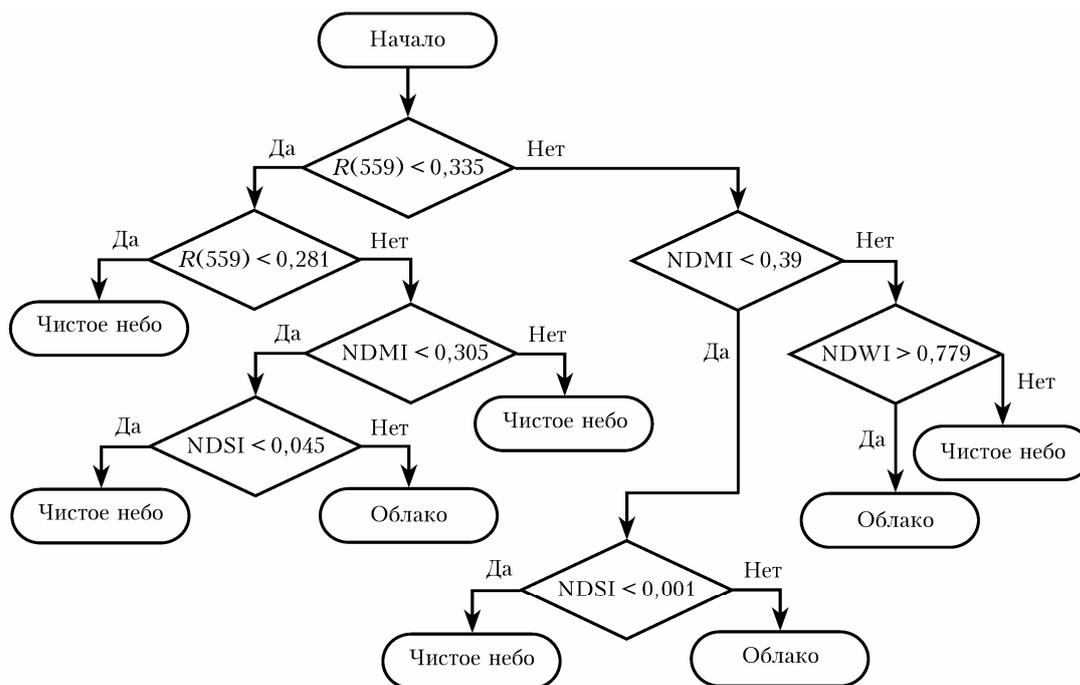


Рис. 1. Модель 1 (дерево решений)

Модель 2 распознает края облаков на основе анализа расположения соседних пикселей. Эта модель требует полной разметки областей снимка, соответствующих облакам и чистому небу. Такая разметка является условной, так как может содержать ошибки и неточности. Разметка одного и того же снимка вручную разными людьми может значительно отличаться.

Для модели 2 применяется сверточная нейронная сеть с небольшим числом слоев. Для получения наиболее компактной модели использованы сверточный, полносвязный и выходной слои. Сверточный слой организован по принципу *deepwise convolution* [24], основанному на независимой обработке каналов разными фильтрами. Данный подход позволяет повысить качество классификации, снизив число параметров нейронной сети в сравнении со стандартной архитектурой сверточного слоя. Модель 2 использует результат классификации, полученной с помощью модели 1, и обучается на множестве подобластей снимка с частичной облачностью размером  $5 \times 5$  пикселей с облачной меткой, соответствующей центральному пикселю. После применения модели 2 формируется маска 2: в «облачных» пикселях она содержит 1, в «чистых» – 0.

Количество входных слоев модели 2 может варьироваться. В простейшем случае она содержит два входных слоя:  $R^{IR}$  инфракрасный (ИК) канал и поле разметки, полученное в результате работы модели 1. ИК-канал выбирается потому, что контраст снимка в ИК-диапазоне больше, чем в видимом. Контраст находим по формуле

$$C_{\lambda}(n, m) = \frac{1}{8} \sum_{i=-1}^1 \sum_{j=-1, (|i|+|j| \neq 0)}^1 |R_{\lambda}(n, m) - R_{\lambda}(n+i, m+j)|, \quad (1)$$

где  $C_{\lambda}(n, m)$  и  $R_{\lambda}(n, m)$  – значения контраста и яркости в пикселе снимка с индексами  $(n, m)$ .

Структура соответствующей сети приведена на рис. 2; использованные обозначения перечислены в табл. 1.

Разность масок 1 и 2 (пункт 21) вычисляется по формуле

$$D = \|D\|, \quad D = \left( (M_1 - M_2)^2 + (M_1 - M_2) \right) \frac{1}{2}, \quad (2)$$

где  $M_i$  –  $i$ -я маска. Сложение двух метрик (пункт 23) выполняется по формуле

$$E = [\text{CrossEntropy} + D\beta]/2, \quad (3)$$

где  $\beta$  – задаваемый параметр; *CrossEntropy* оценивает отклонение маски 2 от точной маски, полученной после ручной разметки:

$$\text{CrossEntropy} = -(y_0 \log(\hat{y}_0) + y_1 \log(\hat{y}_1)), \quad (4)$$

где  $\hat{y}_0$  и  $\hat{y}_1$  – выходные значения со слоя (15) (рис. 2), соответствующие предсказанным вероятностям присутствия ( $\hat{y}_1$ ) и отсутствия ( $\hat{y}_0$ ) облака ( $\hat{y}_0 + \hat{y}_1 = 1$ ), а  $y_0$  и  $y_1$  – ожидаемые выходы, соответствующие облачной метке в центральном пикселе согласно разметке областей снимка для модели 2 (облако соответствует значениям  $y_0 = 0, y_1 = 1$ , чистое небо –  $y_0 = 1, y_1 = 0$ ).

Величина  $D$  в формуле (3) определяет число пикселей, где в маске 1 пиксель является «облачным», а в маске 2 – «чистым». Включение в выражение для погрешности  $E$  величины  $D$  вызвано стремлением предотвратить ситуацию, когда найденное на первом этапе ядро облака не порождает облако в модели 2.

Таким образом, в качестве первого классификатора используется дерево решений, обучение которого направлено на различение сплошной облачности и чистого неба. Для сокращения времени обучения входные данные для дерева решений содержат только пять признаков изображения – значение яркости в ИК-канале и четыре спектральных индекса. Вторым классификатором служит свер-

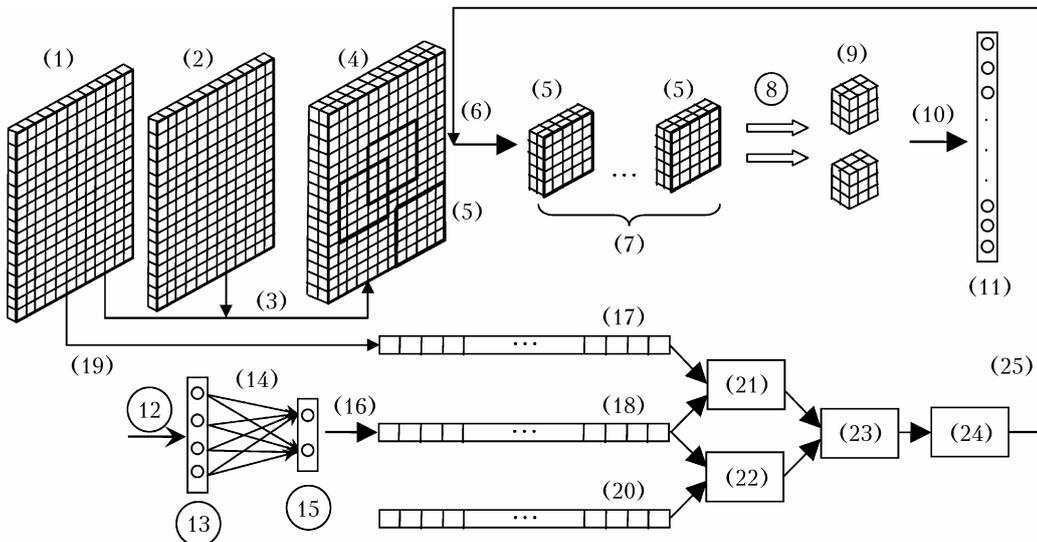


Рис. 2. Модель 2 (сверточная нейронная сеть)

Обозначения, используемые на рис. 2

Номер	Описание
(1)	Маска 1, полученная на первом этапе алгоритма
(2)	ИК-канал исходного снимка
(3)	Перенос величин (1) и (2) в составной снимок
(4)	Составной снимок (1) + (2)
(5)	Фрагменты составного снимка $5 \times 5 \times 2$
(6)	Извлечение фрагментов $5 \times 5 \times 2$
(7)	Поток фрагментов $5 \times 5 \times 2$
(8)	Два фильтра для перевода каждого фрагмента $5 \times 5 \times 2$ в два фрагмента $3 \times 3 \times 2$
(9)	Фрагменты $3 \times 3 \times 2$
(10)	Перенос двух фрагментов $3 \times 3 \times 2$ на 18 входных нейронов
(11)	Входные нейроны
(12)	Адаптивное суммирование с функцией активации Relu
(13)	Скрытые нейроны
(14)	Полносвязный слой с функцией активации Relu
(15)	Выходные нейроны (два значения: облако и чистое небо)
(16)	Перенос выходных значений в вектор результатов классификации фрагментов $5 \times 5 \times 2$
(17)	Вектор результатов классификации фрагментов $5 \times 5 \times 2$ снимка моделью 1 (маска 1)
(18)	Вектор результатов классификации фрагментов $5 \times 5 \times 2$ снимка моделью 2 (маска 2)
(19)	Перенос маски 1 в вектор (17)
(20)	Вектор точных значений признаков облако/чистое небо для фрагментов $5 \times 5 \times 2$
(21)	Вычисление разности маски 1 и маски 2
(22)	Вычисление кросс-энтропии двух векторов
(23)	Сложение двух метрик
(24)	Уточнение весов для фильтров (8), (12) и слоев (13), (15)
(25)	Новая обработка обучающей выборки

точная нейронная сеть; в качестве входных данных используется облачная маска, полученная первым классификатором и значения яркостей снимка в ИК-канале. Обучение нейронной сети направлено на выявление пикселей, спектры которых близки к спектрам найденных первым классификатором облачных ядер.

## 2. Выбор данных для тестирования

Тестирование выполнено на снимках прибора HYPERION с высоким пространственным (30 м) и спектральным (10 нм) разрешением. Выбранные снимки относятся к поверхностям трех типов: океан, растительность и урбанизированная территория. Для каждого типа поверхности отобраны два снимка с умеренной облачностью (табл. 2).

Прибор HYPERION выбран по двум причинам. Во-первых, он обладает достаточно высоким пространственным разрешением, чтобы на его снимках имело смысл искать край облака. Во-вторых, HYPERION проводит съемку в том числе в SWIR-диапазоне, поэтому есть возможность использовать в модели 1 индексы NDSI, NDWI, NDMI, эффективные при отделении облака от воды и сухих яркых поверхностей.

Для каждого снимка найдена длина волны  $\lambda^*$ , для которой данный снимок имеет наибольший контраст (табл. 2). Оказывается, что все  $\lambda^*$  относятся к ИК-диапазону и для снимков, сделанных над одним типом поверхности, наибольший контраст достигается для одной и той же длины волны  $\lambda^*$  (табл. 2).

## 3. Результаты тестирования

Рассматриваются 36 пар снимков. На одном снимке пары выполняется обучение нейронной сети в модели 2, на другом – тестирование. При обучении нейронной сети используются поля яркости  $R(\lambda^*)$  в спектральном канале, соответствующем длине волны  $\lambda^*$ , в сочетании со значением параметра  $\beta = 1$ , согласно формуле (3).

Ошибки классификации облаков в модели 1 (дерево решений) приведены в табл. 3, в полной системе (модель 1 + модель 2) – в табл. 4–6. Отдельно в табл. 4–6 представлены ошибки классификации, ошибки ложного обнаружения (commission error – доли пикселей, ошибочно классифицированных как «облачные», из всех пикселей, классифицированных как «облачные») и ошибки ложного пропуска (omission error – доли пикселей, ошибочно классифицированных как «чистые», среди всех «облачных» пикселей).

Отметим, что часто используемая для оценки точности классификации величина precision (доля правильно найденных «облачных» пикселей среди всех пикселей, классифицированных как «облачные») вычисляется следующим образом  $precision = 1 - commission\ error$ . Доля найденных «облачных» пикселей среди всех имеющихся «облачных» пикселей  $recall = 1 - omission\ error$ .

Маска 1 содержит наиболее яркие части (ядра) облаков, что можно видеть на рис. 3–5; низкие ошибки ложного обнаружения (см. табл. 3) показывают, что найденные ядра действительно принадлежат облакам.

Отметим, что нами также был исследован другой вариант модели 1, где вместо значения  $R(559)$  – яркость в зеленом канале – использовалось значение  $R(650)$  – яркость в красном канале. Такая замена не оказала существенного влияния на результат работы модели 1 и классификатора в целом, так как в качестве облачных ядер выделяются практически те же пиксели. Среднее значение коэффициента Жаккара

$$J(M_{\text{red}}, M_{\text{green}}) = \frac{N(M_{\text{red}} \cap M_{\text{green}})}{N(M_{\text{red}}) + N(M_{\text{green}}) - N(M_{\text{red}} \cap M_{\text{green}})} \quad (5)$$

для оценки сходства облачных масок, полученных с использованием красного ( $M_{\text{red}}$ ) и зеленого ( $M_{\text{green}}$ ) каналов ( $N(X)$  – число элементов множества  $X$ ), составляет 0,976.

Таблица 2

Тип поверхности	ID снимка	Имя снимка	Балл облачности	$\lambda^*$ , нм
Океан	EO1H1360862009134110T0_P2_01	Индийский океан	37,9	915
	EO1H1920882011270110T1_SGS_01	Атлантика	36,3	915
Растительность	EO1H0450162015204110K3_AK3_01	Канада 1	16,6	2375
	EO1H0490132004221110PZ_P2_01	Канада 2	38,5	2375
Урбанизированная территория	EO1H0150332005136110K1_P2_01	Мэриленд	18,8	854
	EO1H0120292011180110P0_SGS_01	Нью-Гэмпшир	26,1	854

Таблица 3

Тип поверхности	Снимок	Ошибка ложного		Полная ошибка
		обнаружения	пропускания	
Океан	Индийский океан	1,7e-5	0,63	0,23
	Атлантика	2,3e-4	0,52	0,20
Растительность	Канада 1	0,0	0,97	0,38
	Канада 2	5,2e-5	0,72	0,12
Урбанизированная территория	Мэриленд	4,8e-3	0,87	0,16
	Нью-Гэмпшир	2,1e-3	0,61	0,16

Таблица 4

Тестовый снимок \ Обучающий снимок	Атлантика	Индийский океан	Канада 2	Канада 1	Мэриленд	Нью-Гэмпшир
Атлантика	<b>0,053</b>	<b>0,105</b>	0,67	0,35	0,79	0,69
Индийский океан	<b>0,056</b>	<b>0,057</b>	0,75	0,46	0,81	0,70
Канада 2	0,105	0,200	<b>0,08</b>	<b>0,15</b>	0,26	0,05
Канада 1	0,240	0,299	<b>0,06</b>	<b>0,07</b>	0,06	0,09
Мэриленд	0,320	0,293	0,12	0,35	<b>0,11</b>	<b>0,15</b>
Нью-Гэмпшир	0,208	0,237	0,1	0,32	<b>0,09</b>	<b>0,15</b>

Таблица 5

Тестовый снимок \ Обучающий снимок	Атлантика	Индийский океан	Канада 2	Канада 1	Мэриленд	Нью-Гэмпшир
Атлантика	<b>0,018</b>	<b>0,005</b>	0,803	0,478	0,810	0,720
Индийский океан	<b>0,110</b>	<b>0,040</b>	0,819	0,546	0,810	0,730
Канада 2	0,007	0,003	<b>0,305</b>	<b>0,274</b>	0,260	0,050
Канада 1	0,002	0,000	<b>0,011</b>	<b>0,027</b>	0,046	0,004
Мэриленд	0,002	0,000	0,008	0,000	<b>0,006</b>	<b>0,113</b>
Нью-Гэмпшир	0,002	0,000	0,000	0,007	<b>0,016</b>	<b>0,270</b>

Таблица 6

Тестовый снимок \ Обучающий снимок	Атлантика	Индийский океан	Канада 2	Канада 1	Мэриленд	Нью-Гэмпшир
Атлантика	<b>0,125</b>	<b>0,28</b>	0,003	0,006	0,00	0,001
Индийский океан	<b>0,028</b>	<b>0,12</b>	0,000	0,001	0,00	0,000
Канада 2	0,270	0,55	<b>0,070</b>	<b>0,024</b>	0,09	0,100
Канада 1	0,630	0,82	<b>0,360</b>	<b>0,160</b>	0,29	0,330
Мэриленд	0,840	0,81	0,730	0,920	<b>0,60</b>	<b>0,520</b>
Нью-Гэмпшир	0,550	0,65	0,590	0,840	<b>0,48</b>	<b>0,340</b>

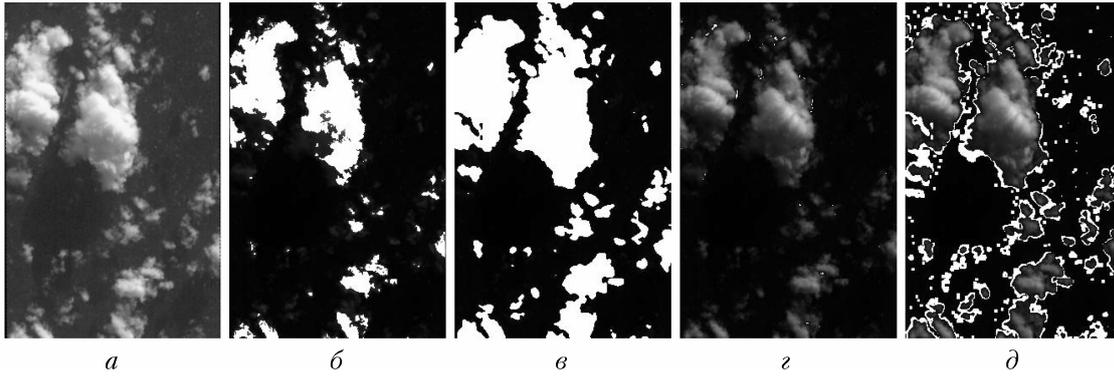


Рис. 3. Фрагмент снимка «Индийский океан»: ИК-канал (а) с наложенными маской 1 (б), маской 2 (в) и отмеченными пикселями с ложными (г) и пропущенными облаками (д)

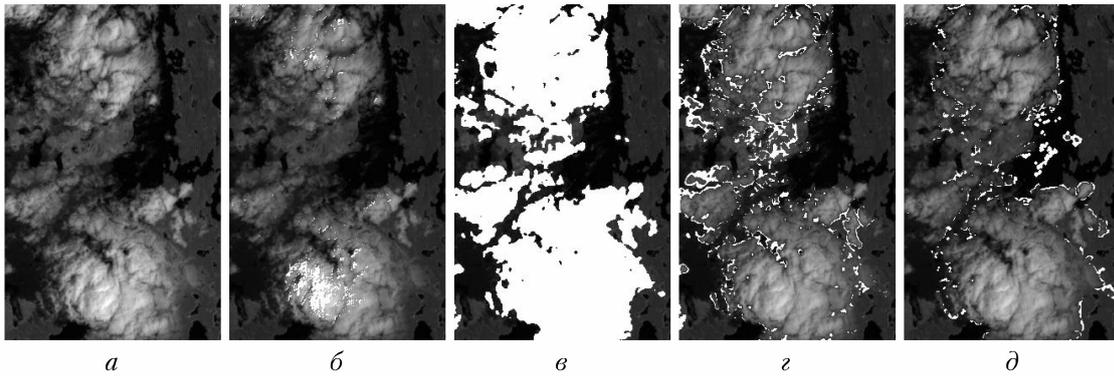


Рис. 4. То же, что и на рис. 3, только для снимка «Канада 1»

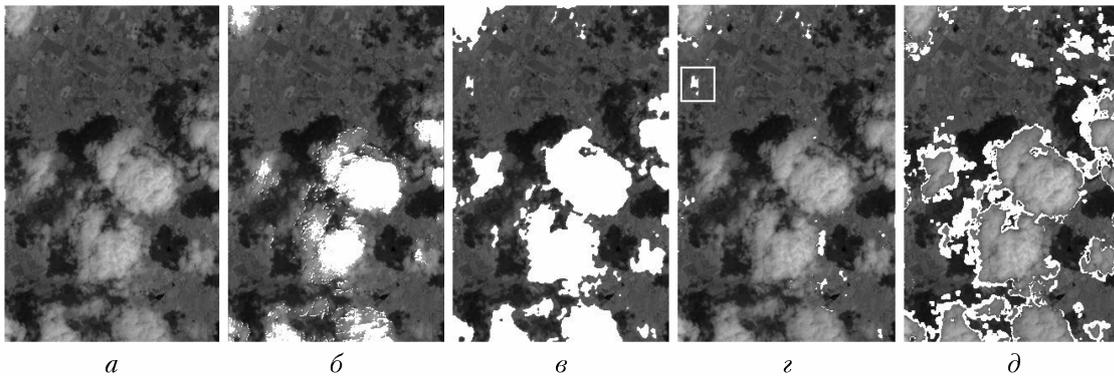


Рис. 5. То же, что и на рис. 3, только для снимка «Мэриленд»

Сравнивая рис. 3, б и в, рис. 4, б и в, рис. 5, б и в, можно убедиться, что маска 2 является расширением маски 1. При этом для маски 2 характерны низкие ошибки классификации (не более 0,15; см. табл. 4), только если для обоих снимков (обучающего и тестового) максимум контраста достигается на одной и той же длине волны  $\lambda^*$ . Ошибки классификации, полученные в таких условиях, выделены в табл. 4–6 полужирным. Если максимальный контраст достигается на разных длинах волн, маска 2 может быть построена с большими ошибками (например, при обучении на снимке «Индийский океан» ошибка при тестировании на снимке «Мэриленд» равна 0,81). Отметим, что максимальное значение контраста на одной длине волны  $\lambda^*$  для пары снимков достигается в том случае, если оба снимка (обу-

чающий и тестовый) сделаны над поверхностью одного типа (см. табл. 2).

Сравнивая рис. 3, а и д, рис. 4, а и д, рис. 5, а и д, видно, что пропущенные облака расположены главным образом вдоль краев реальных облаков. В некоторых случаях пропущены тонкие облака (правый верхний угол снимка «Мэриленд»). Соответствующие пиксели не были отмечены в маске 1, не входят они и в маску 2. Если на снимке присутствует много небольших облаков, ошибки ложного пропуска могут быть велики (см. табл. 6).

Ложно обнаруженные облака также часто расположены около границ реальных облаков (см. рис. 4, г), где они могут возникать вследствие неточности построенной вручную облачной маски. Кроме того, за облака могут быть приняты яркие

элементы поверхности. Такое ложное облако присутствует на рис. 5,  $z$  (обведено белой рамкой). Это также приводит к повышению ошибок ложного распознавания (см. рис. 5 и табл. 4).

Представленная нами модель состоит из двух классификаторов, применяемых последовательно. Дерево решений (модель 1) и нейросетевой классификатор (модель 2) реализованы в упрощенном варианте для ускорения процесса обучения, а также с целью проведения анализа причин принятия решений.

Например, если облако пропущено, значит, согласно модели 1, спектр ни одного его пикселя не обладает свойствами сплошной облачности. Если найдено ложное облако, расположенное вокруг ложного облачного ядра, значит, согласно модели 1, спектры пикселей этого ядра обладают свойствами сплошной облачности. Заметим, что в обоих случаях можно, используя рис. 1, найти то правило, при применении которого возникала ошибка.

Если пропущены края облака, значит, ошибка возникла в модели 2. Если края облака пропущены даже при обучении и тестировании на одном и том же снимке, значит, спектры пикселей края облака слишком далеки по своим спектральным свойствам от спектров его ядра и используемая простая модель с одним полносвязным слоем распознает их как пиксели поверхности под чистым небом. В этом случае можно рассмотреть вопрос об усложнении представленной модели, например, увеличении числа слоев нейронной сети.

## Заключение

Представлена гибридная модель машинного обучения, позволяющая находить облака на гиперспектральных снимках. Модель состоит из двух обучаемых классификаторов: первый находит на снимке пиксели, чьи спектры удовлетворяют условию сплошной облачности, — они соответствуют ядрам облаков; второй предназначен для выявления тел облаков, сформированных вокруг ядер. Классификаторы применяются последовательно. Предложенная модель является объяснимой, т.е. позволяет проводить анализ причин принятия решений.

Выполнено тестирование модели на данных гиперспектрального прибора HYPERION. Найдены ошибки классификации, ложного распознавания и пропуска при обучении и тестировании на снимках в зависимости от типа поверхности (океан, растительность, урбанизированная территория). Показано, что главным фактором, влияющим на точность построенной облачной маски, является выбор ИК-канала при обучении нейронной сети. Для каждого снимка ищется спектральный канал, в котором снимок имеет наибольший контраст. Предложенный алгоритм находит только те облака, которые содержат фрагменты сплошной облачности. Он может быть применен для другого снимка с наибольшим контрастом в том же спектральном канале. Таким образом, удовлетворительная облачная маска может быть получена, только если снимки, используемые для обучения и тестирования, имеют

наибольший контраст в одном и том же спектральном канале, т.е. соответствуют одинаковым типам поверхностей. Тем не менее представленный алгоритм может применяться для нахождения облаков на снимках, не входящих в обучающую выборку.

Отметим, что в настоящей работе для обучения и тестирования применяются разные снимки, поэтому обучение и тестирование выполняется на действительно независимых выборках данных. Подчеркнем, что эти снимки сделаны в разное время над различными участками земной поверхности, а не над одним, как, например, в [16], поэтому оценки точности, полученные нами при тестировании, более надежны. Они также надежнее, чем оценки из других работ, где обучение выполнялось на разных частях одной и той же выборки, что позволяет естественным образом получить классификацию с более высокой точностью.

## Список литературы

1. Li Z., Shen H., Li H., Xid G., Gamba P., Zhang L. Multi-feature combined cloud and cloud-shadow detection in Gaofen-1 widefield of view imagery // *Remote Sens. Environ.* 2017. V. 191. P. 342–358. DOI: 10.1016/j.rse.2017.01.026.
2. Bo P., Fenzhen S., Yunshan M. A cloud and cloud shadow detection methods based on fuzzy c-Means algorithm // *IEEE J. Sel. Top. Appl. Earth. Obs. Remote Sens.* 2020. V. 13. P. 1714–1727. DOI: 10.1109/JSTARS.2020.2987844.
3. Sun L., Mi X., Wei J., Wang J., Tian X., Yu H., Gan P. A cloud detection algorithm generating method for remote sensing data at visible to short-wave infrared wavelengths // *ISPRS J. Photogramm.* 2017. V. 125, N D24. P. 70–88. DOI: 10.1016/j.isprsjprs.2016.12.005.
4. Sun L., Wei J., Wang J., Mi X., Guo Y., Lv Y., Yang Y., Gan P., Zhou X., Jio C., Jiawei C., Tian X. A universal dynamic threshold cloud detection algorithm (UNSADA) supported by a prior surface // *J. Geophys. Res.: Atmos.* 2016. V. 121, N. 12. P. 7172–7196. DOI: 10.1002/2015JD024722.
5. Mateo-Garcia G., Gomez-Chova L., Amoros-Lopez J., Munoz-Mari J., Camps-Valls G. Multitemporal cloud masking in the Google Earth Engine // *Remote Sens.* 2018. V. 10, N 7. P.1079. DOI: 10.3390/rs10071079.
6. Lyapustin A., Wang Y., Frey R. An automatic cloud mask algorithm based on time series of MODIS measurements // *J. Geophys. Res.* 2008. V. 113. P. D16207. DOI: 10.1029/2007JD009641.
7. Bian J., Li A., Liu Q., Huang C. Cloud and snow discrimination for CCD images of HJ-1A/B constellation based on spectral signature and spatio-temporal context // *Remote Sens.* 2016. V. 8, N 31. DOI: 10.3390/rs8010031.
8. Белов А.М., Денисова А.Ю. Алгоритм выявления случайных искажений в составе сцены на серии разновременных изображений ДЗЗ одной и той же территории // *Компьютерная оптика.* 2019. Т. 43, № 5. С. 869–885. DOI: 10.18287/2412-6179-2019-43-5-869-885.
9. Hagolle O., Huo M., Villa Pascual D., Dedieu G. A multi-temporal method for cloud detection, applied to Formosat-2, VeNµS, Landsat, and Sentinel-2 images // *Remote Sens. Environ.* 2010. V. 114, N 8. P. 1747–1755. DOI: 10.1016/j.rse.2010.03.002.
10. Zhu X., Helmer E.H. An automatic method for screening clouds and cloud shadows in optical satellite image

- time series in cloudy region // RSE. 2018. V. 214. P. 135–153. DOI: 10.1016/j.rse.2018.05.024.
11. Визильтер Ю.В., Горбацевич В.С., Желтов С.Ю. Структурно-функциональный анализ и синтез глубоких конволюционных нейронных сетей // Компьютерная оптика. 2019. Т. 43, № 5. С. 886–900. DOI: 10.18287/2412-6179-2019-43-5-886-900.
  12. Shendryk Y., Rist Y., Ticehurst C., Thorburn P. Deep learning for multi-modal classification of cloud, shadow and land cover scenes in PlanetScope and Sentinel-2 imagery // ISPRS J. Photogramm. 2019. V. 157. P. 124–136. DOI: 10.1016/j.isprsjprs.2019.08.018.
  13. Андреев А.И., Шамилова Ю.А. Детектирование облачности по данным КА HIMAWARI-8 с применением сверточной нейронной сети // Исслед. Земли из космоса. 2021. № 2. С. 42–52. DOI: 10.31857/S0205961421010036.
  14. Zheng M, Tang W., Zhao X. Hyperparameter optimization of neural network-driven spatial models accelerated using cyber-enabled high-performance computing // Int. J. Geogr. Inf. Sci. 2019. V. 33. P. 314–345. DOI: 10.1080/13658816.2018.1530355.
  15. Fu H., Shen Y., Liu J., He G., Chen J., Liu P., Qian J., Li J. Cloud detection for FY meteorology satellite based on ensemble thresholds and random forests approach // Remote Sens. 2019. V. 11, N 1. P. 44. DOI: 10.3390/rs11010044.
  16. Ghasemian N., Akhoondzadeh M. Integration of VIR and thermal bands for cloud, snow/ice and thin cirrus detection in MODIS satellite images // Proc. of the Third International Conference on Intelligent Decision Science, Tehran, Iran, May 16–18. 2018. P. 1–37.
  17. Liu H., Zeng D., Tian Q. Super-pixel cloud detection using hierarchical fusion CNN // Proc. of the 2018 IEEE Fourth International Conference on Multimedia Big Data. 2018. P. 1–6. DOI: 10.1109/BigMM.2018.8499091.
  18. Wang L., Chen Y., Tang L., Fan R., Yao Y. Object-based convolutional neural networks for cloud and snow detection in high-resolution multispectral imagers // Water. 2018. V. 10, N 11. P. 1666. DOI: 10.3390/w10111666.
  19. Gilpin L., Bau D., Yuan B., Bajwa A., Specter M., Kagal L. Explaining explanations: An overview of interpretability of machine learning // IEEE 5th International Conference on Data Science and Advanced Analytics (DSAA) 2018, Turin, Italy. P. 80–89. DOI: 10.1109/DSAA.2018.00018.
  20. Štrumbelj E., Kononenko I. Explaining prediction models and individual predictions with feature contributions // Knowl. Inf. Syst. 2014. V. 41. P. 647–665.
  21. Goodwin N.R., Collet L.J., Denham R.J., Flood N., Tindall D. Cloud and cloud shadow screening across Queensland, Australia: An automated method for LandsatTM/ETA + time-series // Remote Sens. Environ. 2013. V. 134. P. 50–65. DOI: 10.1016/j.rse.2013.02.019.
  22. Муурпа П. Объяснимые модели искусственного интеллекта на Python. М.: ДМК-Пресс, 2022. 298 с.
  23. Hastie T., Tibshirani R., Friedman J. Additive models, trees, and related methods // The Elements of Statistical Learning. Springer, 2009. P. 295–336.
  24. Chollet F. Xception: Deep learning with depthwise separable convolutions // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA, 2017. P. 1800–1807. DOI: 10.1109/CVPR.2017.195.

**A.S. Minkin, O.V. Nikolaeva. Cloud recognition in hyperspectral satellite images using an explainable machine learning model.**

Problem of developing algorithm based upon neural networks and machine learning to find clouds on hyperspectral images are under consideration. It is required that the network is not a "black box," but allows an analysis of the reasons for decision making and classification results. Presented hybrid model includes decision tree trained to overcast recognition (model 1) on pre-selected features of an image in combination with convolutional neural network (model 2). Model 2 uses the result of model 1 and brightness in a selected band of an image. Model 1 finds cloud cores, and model 2 finds cloud edges. Results of testing the hybrid model on data of HYPERION sensor are presented. Data obtained over three surface types (ocean, plant, and urban region) are considered. Overall accuracy, as well as commission and omission errors are assessed. It is shown that the hybrid model can find 85% cloud pixels, only if the neural network is trained on an image where the contrast attains a maximum in the same spectral band. The results of this work can be applied to solve the general problem of analyzing and processing multispectral satellite images and further in environmental science and monitoring of changes in vegetation, ocean and glaciers.