

Использование индекса NDSI для отделения облаков от неснежных поверхностей на многоспектральных снимках

О. В. Николаева

*Институт прикладной математики им. М. В. Келдыша РАН
Москва, 125047, Россия
E-mail: nika@kiam.ru*

Рассматривается возможность использования нормализованного разностного снежного индекса NDSI (*англ.* Normalized Difference Snow Index) для отделения облаков от пустынных областей и урбанизированных территорий на многоспектральных снимках. Отобраны снимки прибора Hyperion, сделанные над поверхностями различного типа (вода, пустынная местность, растительность, урбанизированная территория) в условиях чистого неба и сплошной облачности. Выполнен статистический анализ наборов значений индекса NDSI. Проведён такой же анализ наборов значений индекса песчаной пустыни DSI (*англ.* Desert Sand Index), используемого в стандартном алгоритме построения облачной маски на снимках Hyperion. Получены пороговые значения индексов, позволяющие отделять сплошную облачность от поверхности каждого типа. Оценены доли неправильно классифицированных пикселей. Показано, что индекс NDSI с полученными пороговыми значениями может быть использован для надёжного отделения сплошной облачности от пустынных областей и урбанизированных территорий на снимках Hyperion. Выявлено, что индекс DSI отделяет облака от пустынных областей с большими ошибками и не может быть использован для отделения облаков от урбанизированных территорий. Рассмотрены снимки Hyperion с частичной облачностью. Показано, что анализ гистограмм значений индексов NDSI и DSI для каждого снимка позволяет получить оптимальные для этого снимка пороговые значения индекса, позволяющие отделить освещённую поверхность от облака и облачной тени. Определено, что такое разделение выполняется с помощью индекса NDSI с большей точностью, чем с помощью индекса DSI. Дальнейшее отделение пикселей облака от пикселей облачной тени возможно с помощью других спектральных индексов. Полученные результаты предлагается использовать в алгоритмах обнаружения облаков на снимках приборов, не выполняющих измерений радиационной температуры.

Ключевые слова: обнаружение облаков, многоспектральные снимки, индекс NDSI, индекс DSI

Одобрена к печати: 26.10.2022
DOI: 10.21046/2070-7401-2022-19-5-53-62

Введение

Алгоритмы обнаружения облаков и их теней на многоспектральных снимках активно используются при зондировании земной поверхности. Части снимков, занятые облаками и облачными тенями, могут быть удалены на орбите; это позволит сократить объём передаваемых на Землю данных. Удалённые части снимков могут быть заменены фрагментами других снимков, сделанных над той же территорией в близкий момент времени при безоблачном небе.

В настоящее время существует множество алгоритмов и открытых пакетов для обнаружения облаков и их теней (Li et al., 2022). В открытом доступе находятся полученные с их помощью результаты — облачные и теневые маски. Тем не менее алгоритмы обнаружения постоянно совершенствуются, разрабатываются новые алгоритмы. Это связано с недостатками имеющихся алгоритмов. Прежде всего следует отметить возможность классификации как облаков ярких поверхностей, спектральные характеристики которых подобны облачным (снега, льда, искусственных покрытий) (Li et al., 2022). Кроме того, при тестировании наблюдается низкая (70 %) точность обнаружения облачных теней (Zhu, Woodcock, 2012).

Самые ранние алгоритмы обнаружения облаков основаны на применении к спектру в каждом пространственном пикселе снимка набора спектральных пороговых критериев.

При этом используются условия как на яркость пикселя на какой-либо длине волны, так и на отношения яркостей для некоторых длин волн (Ackerman et al., 2010; Barton et al., 2001; Griffin et al., 2003; Irish et al., 2006). Важным становится определение пороговых значений, которые могут быть выбраны в зависимости от типа подстилающей поверхности, условий освещения и съёмки (Ackerman et al., 2010), высоты и температуры поверхности (Волкова, 2017). В этом случае классификация пикселей выполняется с помощью большого набора спектральных критериев, которые используются в том числе и для определения типа подстилающей поверхности (Zhu, Woodcock, 2012). В других ситуациях пороговые значения находятся отдельно для каждого кадра с помощью статистического анализа данных съёмки. Число используемых критериев в таком случае может быть сокращено до двух-трёх (Thompson et al., 2014; Zhai et al., 2018); это сильно уменьшает время обработки.

Также в алгоритмах обнаружения могут быть использованы и текстурные признаки. В частности, с их помощью находятся границы облаков (Stournara et al., 2013). Чтобы выбрать из затенённых областей именно облачные тени, выполняется оценка их геометрического подобия облакам; при этом итерационно может подбираться подходящая высота облака (Zhu, Woodcock, 2012).

Совместное использование спектральных и текстурных признаков может быть эффективно реализовано в свёрточных нейронных сетях, особенно в активно развиваемых в последние годы сетях глубокого обучения (Li et al., 2022). Однако обучение таких сетей требует больших вычислительных ресурсов и времени. Кроме того, из-за высокой вариабельности земной поверхности и облаков всегда стоит вопрос о полноте использованной обучающей выборки и тем самым об области применимости каждой обученной нейронной сети.

Точность нейросетевого метода может быть повышена, если в архитектуре сети учтены какие-либо физические законы взаимодействия света с атмосферой и поверхностью (Li et al., 2022). Эти законы могут быть заданы, например, в виде ограничений на значения спектральных индексов. Заметим, что в настоящее время значения спектральных индексов уже используются как входная информация для нейросетей (Shendryk et al., 2019).

Ещё одна группа алгоритмов обнаружения облаков опирается на сравнение последовательно сделанных снимков одного участка земной поверхности. В этом случае потенциально «облачные» фрагменты находятся как изменённые части снимка. В таких методах необходимо иметь динамически обновляемый архив «чистых» снимков каждого участка поверхности (Luypustin et al., 2008). Поскольку снимки одного участка сделаны с существенным временным интервалом, часть обнаруженных изменений может быть порождена изменениями земной поверхности. Поэтому для определения, какие из измеренных фрагментов являются облаками, необходимо использовать спектральные критерии (Hagolle et al., 2010).

Для выделения облаков на снимках некоторых приборов могут быть использованы свои спектральные критерии, возникающие благодаря конструктивным особенностям измерительной аппаратуры. Например, детекторы на спутниках Sentinel-2 размещены таким образом, что расположенные над поверхностью Земли объекты (т.е. облака) в каналах NIR-диапазона (*англ.* near infrared, ближний инфракрасный) регистрируются с пространственным сдвигом (Frantz et al., 2018). Это позволяет ввести специальный индекс смещения облаков CDI (*англ.* Cloud Displacement Index), позволяющий эффективно обнаруживать облака.

Таким образом, спектральные критерии выступают необходимой частью различных алгоритмов обнаружения облаков. Перечислим спектральные индексы, обычно используемые в алгоритмах обнаружения облаков на многоспектральных снимках.

Нормализованный разностный вегетационный индекс NDVI (*англ.* Normalized Difference Vegetable Index) позволяет отделять облака от растительности и тёмных водных поверхностей (Ackerman et al., 2010).

Для отделения облаков от пустынных областей используется тот факт, что облака холоднее, чем земная поверхность (Волкова, 2017; Ackerman et al., 2010; Irish et al., 2006). Однако для нахождения температуры необходимо иметь значения яркости отражённого от Земли солнечного излучения в тепловом диапазоне 11–13 мкм. Такие величины присутствуют среди данных, например, прибора MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer).

Но другие приборы, например Hyperion и Sentinel, не выполняют измерений в дальней инфракрасной области. Для отделения облаков от пустынных областей на снимках прибора Hyperion используется индекс песчаной пустыни DSI (*англ.* Desert Sand Index) (Griffin et al., 2003).

Для нахождения облаков как монохромных объектов используется «индекс белизны» (*англ.* whiteness) (Gómez-Chova et al., 2007; Zhu, Woodcock, 2012).

Широкое применение имеет нормализованный разностный снежный индекс NDSI (*англ.* Normalized Difference Snow Index). Он определяет относительную разность значений яркости в видимой (560 нм) и ближней инфракрасной (1650 нм) областях спектра; причём для излучения с длиной волны 1650 нм характерно сильное поглощение в воде. Высокие значения этого индекса ($NDSI > 0,4$) отвечают чистому снегу и льду, поэтому с помощью индекса NDSI водяные облака могут быть отделены ото льда и снега (Белова, Ершов, 2012; Barton et al., 2001; Irish et al., 2006). Присутствие в снеге загрязнений снижает значение NDSI; значения индекса позволяют определить состав загрязняющих примесей (Крутский, Кравченко, 2018) в снеге, хорошо коррелируют с их концентрацией (Амикишиева и др., 2020). Таким образом, индекс NDSI может быть использован и для оценки степени загрязнения снега.

В свою очередь, для сухих почв с редкой растительностью, для искусственных покрытий характерны низкие значения индекса NDSI. При обработке, например, данных Landsat для определения пикселя как облачного, помимо прочих условий, необходимо, чтобы индекс NDSI был больше некоторого порогового значения (Irish et al., 2006).

В настоящей работе исследована возможность отделения облака от пустынной местности и урбанизированной территории по значениям индекса NDSI. Такая возможность актуальна при обработке данных приборов, где не выполняются измерения в дальней инфракрасной области и поэтому неизвестны значения температуры.

Методика определения порогового значения спектрального индекса для разделения чистого неба и сплошной облачности

Составим наборы снимков, сделанных над поверхностями разных типов. Снимки, сделанные над поверхностями одного типа, но в разных условиях: чистого неба и сплошной облачности — поместим в разные наборы. Наборы, полученные при чистом небе, обозначим C_s , где s — тип поверхности. Наборы, полученные в условиях сплошной облачности, обозначим O_s . Для каждого пикселя каждого набора найдём значение спектрального индекса I . Введём равномерное разбиение возможного интервала значений этого индекса на L подынтервалов: $x_0 < \dots < x_{\ell-1} < x_\ell < \dots < x_L$. Для каждого найденного значения индекса I определим два индикатора:

$$U_{i\ell} = \begin{cases} 1, & \text{если } I_i < x_\ell, \\ 0, & \text{если } I_i \geq x_\ell, \end{cases} \quad D_{i\ell} = \begin{cases} 1, & \text{если } I_i > x_{\ell-1}, \\ 0, & \text{если } I_i \leq x_{\ell-1}. \end{cases}$$

Величины $U_{i\ell}$ и $D_{i\ell}$ будем рассматривать как реализации некоторых случайных величин. Найдём выборочные средние \bar{U}_ℓ , \bar{D}_ℓ и дисперсии \bar{u}_ℓ , \bar{d}_ℓ :

$$\bar{U}_\ell = \frac{1}{N} \sum_{i=1}^N U_{i\ell}, \quad \bar{D}_\ell = \frac{1}{N} \sum_{i=1}^N D_{i\ell}, \quad \bar{u}_\ell = \frac{1}{N} \sum_{i=1}^N (U_{i\ell} - \bar{U}_\ell)^2, \quad \bar{d}_\ell = \frac{1}{N} \sum_{i=1}^N (D_{i\ell} - \bar{D}_\ell)^2.$$

Здесь N — число пикселей в наборе.

Выборочное среднее \bar{U}_ℓ определяет долю пикселей, для которых индекс I не превышает величину x_ℓ . Отклонение выборочного среднего \bar{U}_ℓ от точного значения этой доли \tilde{U}_ℓ оценивается неравенством:

$$|\bar{U}_\ell - \tilde{U}_\ell| < \Phi_{1-\varepsilon_\ell} / 2 \sqrt{\bar{u}_\ell / (N-1)}, \quad (1)$$

где $\Phi_{1-\varepsilon_\ell^U/2}$ — квантиль стандартного нормального распределения. Условие (1) выполнено с вероятностью $1-\varepsilon_\ell^U$. Найдём величину ε_ℓ^U из уравнения (Орлов, Федоров, 2016):

$$\Phi_{1-\varepsilon_\ell^U/2} \sqrt{\bar{u}_\ell / (N-1)} = \varepsilon_\ell^U. \quad (2)$$

Введём функцию $\psi(\varepsilon) = \Phi_{1-\varepsilon} / \varepsilon$ и запишем равенство (2) в форме (Орлов, Федоров, 2016):

$$\psi(\varepsilon_\ell^U / 2) = 2\sqrt{(N-1)/\bar{u}_\ell}.$$

Поскольку функция $\psi(\varepsilon)$ строго монотонна, это уравнение имеет единственное решение:

$$\varepsilon_\ell^U = 2\psi^{-1}\left(2\sqrt{(N-1)/\bar{u}_\ell}\right). \quad (3)$$

Аналогичным образом найдём величину

$$\varepsilon_\ell^D = 2\psi^{-1}\left(2\sqrt{(N-1)/\bar{d}_\ell}\right). \quad (4)$$

Величины ε_ℓ^U и ε_ℓ^D , определяемые уравнениями (3) и (4), оценивают погрешности выборочных средних \bar{U}_ℓ и \bar{D}_ℓ соответственно:

$$|\bar{U}_\ell - \tilde{U}_\ell| < \varepsilon_\ell^U, \quad |\bar{D}_\ell - \tilde{D}_\ell| < \varepsilon_\ell^D,$$

причём оценки выполнены с вероятностями $1-\varepsilon_\ell^U$ и $1-\varepsilon_\ell^D$.

Найдём величины $\bar{D}_{\ell,s}$ и $\varepsilon_{\ell,s}^D$ для всех наборов C_s , полученных при чистом небе. Также вычислим величины $\bar{U}_{\ell,s}$ и $\varepsilon_{\ell,s}^U$ для всех наборов O_s , сделанных в условиях сплошной облачности. Выберем тип поверхности s . Найдём такой номер $\ell(s)$, при котором достигается минимум величины E_s , определяемой выражением:

$$E_s = \max\left[\bar{D}_{\ell(s),s} + \varepsilon_{\ell(s),s}^D, \max_{s'}\left(\bar{U}_{\ell(s),s'} + \varepsilon_{\ell(s),s'}^U\right)\right]. \quad (5)$$

Здесь сумма $\bar{D}_{\ell(s),s} + \varepsilon_{\ell(s),s}^D$ — оценка доли пикселей в снимках, сделанных при чистом небе над поверхностью типа s , где индекс $I > x_{\ell(s)-1}$. Сумма $\bar{U}_{\ell(s),s'} + \varepsilon_{\ell(s),s'}^U$ — оценка доли пикселей в снимках, сделанных в условиях облачности над поверхностью типа s' , где индекс $I < x_{\ell(s)}$. Фактически согласно условию (5) ищется такой номер интервала разбиения $\ell(s)$, при котором минимальна доля «чистых» пикселей с $I > x_{\ell(s)-1}$, а также минимальна доля «облачных» пикселей с $I < x_{\ell(s)}$. Далее для поверхности типа s можно определить оптимальное пороговое значение по формуле:

$$I_s^* = \frac{x_{\ell(s)} + x_{\ell(s)-1}}{2}.$$

Тогда можно полагать, что пиксели, для которых индекс I меньше, чем пороговое значение I_s^* , являются «чистыми», а пиксели, для которых индекс I больше, чем величина I_s^* , являются «облачными». Погрешность (доля ошибочно классифицированных с помощью порогового значения I_s^* пикселей) оценивается величиной E_s (см. формулу (5)).

Данные для экспериментов

Составим наборы снимков, сделанных прибором Nupregion над поверхностями разных типов: открытая вода, зелёная растительность, пустынная местность и урбанизированная территория. Под открытой водой понимаются участки океана и озёр, расположенные вдали от береговой линии. Пустынная местность может включать отдельные участки редкой растительности. Урбанизированная территория может включать участки открытого грунта, редкой растительности и искусственных покрытий. Снимки, сделанные над поверхностями одного типа, но в разных условиях: чистого неба и сплошной облачности, — поместим в разные наборы. Выбранные снимки, сделанные при чистом небе, содержат 6,2 млн пикселей, а в условиях облачности — 4,6 млн пикселей.

Пороговые значения индексов NDSI и DSI для разделения чистого неба и сплошной облачности

Рассмотрим два спектральных индекса:

- NDSI, определяющий относительную разность значений яркости в видимой (560 нм) и ближней инфракрасной (1650 нм) областях спектра;
- DSI, определяющий относительную разность двух значений яркости (869 и 1650 нм) в ближней инфракрасной области спектра.

Индекс DSI используется для отделения облаков от пустынных областей на снимках прибора Hyperion (Griffin et al., 2003). Исследование возможности использования индекса NDSI для отделения облаков от неснежных поверхностей составляет цель данной работы. Возможные значения каждого индекса лежат в интервале $[-1, 1]$.

Зададим число $L = 200$ подынтервалов разбиения интервала $[-1, 1]$. Пороговые значения индексов $NDSI^*$, DSI^* и соответствующие погрешности E^{NDSI^*} , E^{DSI^*} , полученные по представленной выше методике для поверхности каждого типа, представлены в *табл. 1*.

Таблица 1. Пороговые значения и погрешность

Тип поверхности	Пороговые значения		Погрешность	
	$NDSI^*$	DSI^*	E^{NDSI^*}	E^{DSI^*}
Урбанизированная территория	-0,02	0,13	0,013	0,240
Пустынная местность	-0,02	0,07	0,012	0,042
Растительность	0,01	0,28	0,029	0,880
Вода	0,31	0,27	0,880	0,780

Можно видеть, что индекс NDSI позволяет отделить облако от пустынной местности и урбанизированной территории с высокой точностью, а с чуть меньшей точностью — от растительности. Индекс DSI позволяет отделить облако от пустынной местности, но с меньшей точностью, чем индекс NDSI, тогда как отделить облако от урбанизированной местности и от растительности индекс DSI не позволяет. В то же время оба индекса не могут отделить облако от воды (что и следовало ожидать). Важное преимущество индекса NDSI состоит в том, что и для пустынной местности, и для урбанизированной территории для него получены одинаковые пороговые значения.

Результаты экспериментов для снимков с частичной облачностью

Рассмотрим сделанные над пустынной местностью или урбанизированной территорией снимки Hyperion (*табл. 2*), где только часть пикселей занята облаком. Выбранные снимки расположим в порядке уменьшения размера облака. На каждом снимке выберем фрагмент, содержащий границу облака.

Таблица 2. Снимки Hyperion с частичной облачностью

Номер снимка	Индекс снимка	Место съёмки	Дата
1	EO1H0440342002196110PF_AGS_01	Сан-Франциско	15.07.2002
2	EO1H1710822016068110KF_TR2_01	Южная Африка	08.03.2016
3	EO1H0290382016078110K2_AK3_01	Техас	18.03.2016
4	EO1H0360382007272110K3_AGS_01	Аризона	29.09.2007

Для каждого фрагмента построим гистограммы индексов NDSI и DSI. Для этого найдём средние значения индикаторов $T_{i\ell}^I = 1$ при $x_{\ell-1} \leq I_i < x_\ell$, $T_{i\ell}^I = 0$ в противном случае, $I = \text{NDSI}, \text{DSI}$. На рис. 1–4 (см. с. 59) представлены RGB-изображения (R — *англ.* red, красный; G — *англ.* green, зелёный; B — *англ.* blue, синий) выбранных фрагментов снимков и полученные гистограммы. Приведены как полные гистограммы (4), так и гистограммы для освещённой поверхности (1), облака (2), затенённой облаком поверхности (3). Можно видеть, что для снимков 1, 2, сделанных вблизи границы обширного облака, гистограмма каждого индекса имеет два пика: левый пик в целом отвечает освещённой поверхности, правый пик — облаку (см. рис. 1б, в, 2б, в). При уменьшении размера облака это свойство сохраняется только для индекса NDSI (см. рис. 3б, 4б); для индекса DSI пики оказываются совмещёнными (см. рис. 3в, 4в). При этом для снимков 3, 4 с обширными тенями от облаков в значениях индекса NDSI выделяется третий пик для затенённых областей (см. рис. 3б, 4б). Таким образом, индекс NDSI является более информативным, чем индекс DSI.

Также на рис. 1–4 отмечены (цифрой 6) общие пороговые значения индексов NDSI*, DSI* из табл. 1. Там же отмечены (цифрой 5) оптимальные для данных фрагментов значения индексов NDSI** и DSI**; оптимальными полагаются значения, отделяющие левый пик гистограммы (если в гистограмме для DSI только один пик, в соответствующей ячейке таблицы стоит прочерк). С помощью пороговых значений NDSI** и DSI** пиксели освещённой поверхности могут быть отделены от пикселей облаков и облачных теней.

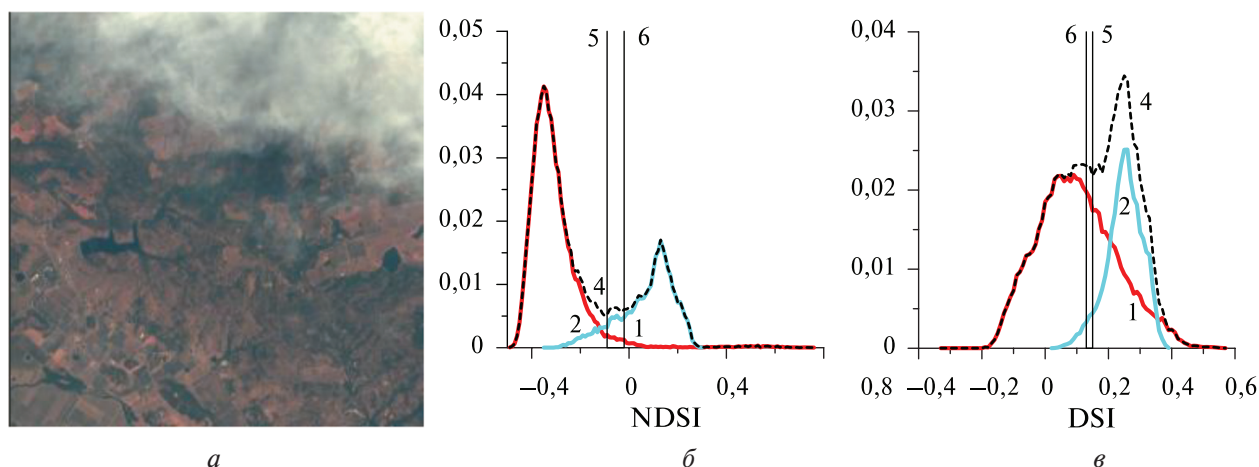


Рис. 1. Фрагмент снимка 1: а — RGB-изображение; б — NDSI; в — DSI

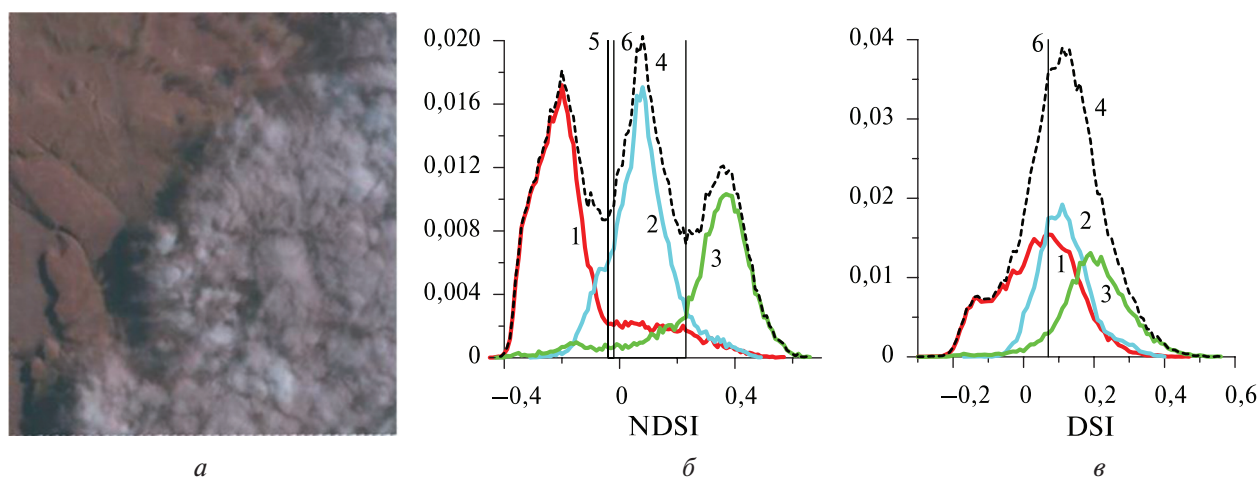


Рис. 2. Фрагмент снимка 2: а — RGB-изображение; б — NDSI; в — DSI




Рис. 3. Фрагмент снимка 3: *a* — RGB-изображение; *b* — NDSI; *v* — DSI

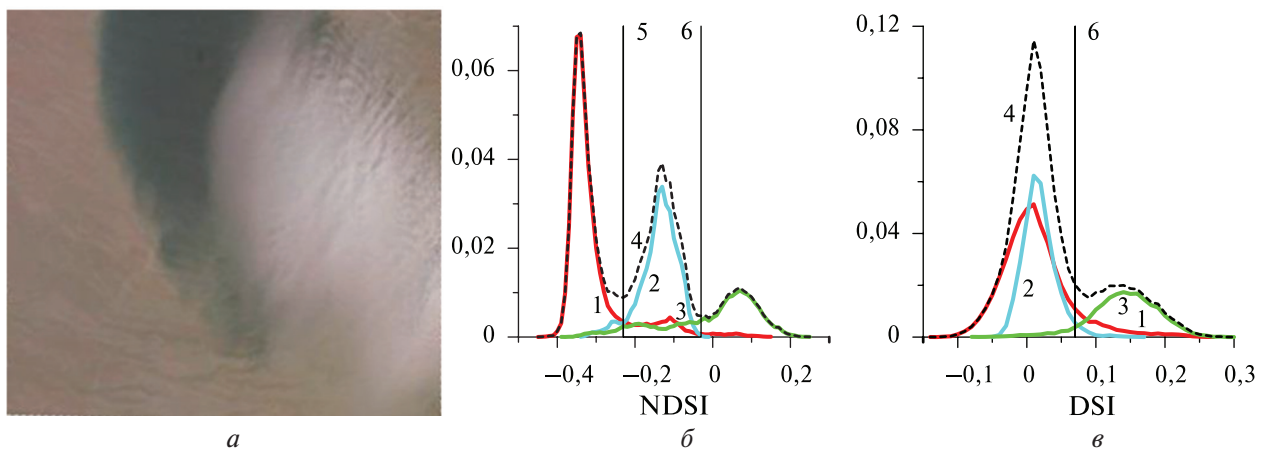


Рис. 4. Фрагмент снимка 4: *a* — RGB-изображение; *b* — NDSI; *v* — DSI

В табл. 3 представлены точности классификации пикселей с помощью общих пороговых значений NDSI*, DSI* и частных NDSI**, DSI**. Точность определяется как доля правильно классифицированных пикселей (освещённая поверхность/облако и облачная тень). Можно видеть, что переход к частному пороговому значению повышает точность классификации, причём повышает тем сильнее, чем больше частное пороговое значение отличается от общего. Заметим также, что точность классификации с помощью индекса NDSI выше точности классификации с помощью индекса DSI.

Таблица 3. Точность классификации пикселей на снимках с частичной облачностью

Номер снимка	NDSI*	NDSI**	DSI*	DSI**
1	0,92	0,94	0,72	0,75
2	0,83	0,90	0,63	0,83
3	0,85	0,86	0,67	—
4	0,60	0,91	0,62	—

Важно отметить, что для части «облачных» пикселей значения индекса NDSI меньше, чем общее пороговое значение NDSI* (см. рис. 1б, 2б, 3б и 4б). Поэтому при использовании порогового значения NDSI* часть облака будет признана освещённой поверхностью. Например, для снимка 4 (см. рис. 4а) в этом случае почти все облако будет признано освещённой поверхностью (см. рис. 4б).

Отметим, что индекс NDSI не может быть использован для разделения облака и облачной тени, поскольку области значений этого индекса для облака и тени существенно пересекаются (см., например, рис. 2б, 3б, 4б).

Заключение

Рассмотрена возможность использования спектрального индекса NDSI (англ. Normalized Difference Snow Index) для отделения облаков от неснежных поверхностей на многоспектральных снимках. Выполнен статистический анализ данных прибора Hyperion, полученных в условиях чистого неба и сплошной облачности над поверхностями разных типов. Получены пороговые значения индекса, позволяющие отделить сплошную облачность от пустынной местности и урбанизированной территории. Показано, что доля неправильно классифицированных пикселей при использовании индекса NDSI оказывается меньше, чем при применении индекса DSI (англ. Desert Sand Index), используемого в этих целях в стандартном алгоритме Hyperion.

Рассмотрены снимки, сделанные в условиях частичной облачности. Показано, что анализ гистограмм значений индексов NDSI и DSI выбранного фрагмента снимка позволяет получить оптимальные для этого снимка пороговые значения, позволяющие отделить пиксели освещенной поверхности от пикселей облака и облачной тени. Точность такой классификации пикселей с помощью индекса NDSI оказывается выше, чем точность классификации с помощью индекса DSI. Дальнейшее разделение пикселей облаков и облачных теней возможно с использованием других критериев (например, с помощью ограничения на минимальную яркость «облачного» пикселя в видимом диапазоне и условия минимума яркости тени в NIR-диапазоне).

Полученные результаты могут быть использованы в алгоритмах обнаружения облаков на многоспектральных снимках при отсутствии данных о радиационной температуре.

Литература

1. Амикишиева Р.А., Распута В.Ф., Ярославцева Т.В. Технология анализа процессов атмосферного загрязнения на базе наземных и спутниковых измерений // Интерэкспо. Гео-Сибирь. 2020. Т. 4. № 1. С. 36–41. DOI: 10.33764/2618-981X-2020-4-1-36-41.
2. Белова Е.И., Ершов Д.В. Метод предварительной обработки сцен Landsat-5/7 с изображением снежного покрова // Современные проблемы дистанционного зондирования Земли из космоса. 2012. Т. 9. № 4. С. 9–14.
3. Волкова Е.В. Оценки параметров облачного покрова и осадков по данным радиометра МСУ-МР полярно-орбитального спутника «Метеор-М» № 2 для европейской территории России // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14. № 5. С. 300–320. DOI: 10.21046/2070-7401-2017-14-5-300-320.
4. Крутский Н.В., Кравченко И.Ю. Использование снимков Landsat для геоэкологического мониторинга урбанизированных территорий // Современные проблемы дистанционного зондирования Земли из космоса. 2018. Т. 15. № 2. С. 159–168. DOI: 10.21046/2070-7401-2018-15-2-159-168.
5. Орлов Ю.Н., Федоров С.Л. Методы численного моделирования процессов нестационарного случайного блуждания. М.: МФТИ, 2016. 108 с.
6. Ackerman S., Frey R., Strabala K., Liu Y., Gumley L., Baum B., Menzel P. Discriminating clear-sky from cloud with Modis. Algorithm Theoretical Basis Document (MOD35). Madison: Univ. Wisconsin, 2010. 121 p.
7. Barton J.S., Casey K., Chien J.Y.L., Digirolamo N.E., Klein A.G., Powell H.W., Tait A.B., Hall D.K., Riggs G.A., Solomonson V.V. Algorithm Theoretical Basis Document for the Modis snow and sea ice-mapping algorithms. Madison: Univ. Wisconsin, 2001. 45 p.
8. Frantz D., Haß E., Uhl A., Stoffels J., Hill J. Improvement of the Fmask algorithm for Sentinel-2 images: Separating clouds from bright surfaces based on parallax effects // Remote Sensing of Environment. 2018. V. 215. P. 471–481. DOI: 10.1016/j.rse.2018.04.046.
9. Gómez-Chova L., Camps-Valls G., Calpe-Maravilla J., Guanter L., Moreno J. Cloud-Screening Algorithm for ENVISAT/MERIS Multispectral Images // IEEE Trans. Geoscience and Remote Sensing. 2007. V. 45. No. 12. P. 4105–4118. DOI: 10.1109/TGRS.2007.905312.

10. Griffin M., Burke H., Mandle D., Miller J. Cloud cover detection algorithm for EO-1 Hyperion imagery // Proc. IEEE Intern. Geoscience and Remote Sensing Symp. 2003. No. 03CH37477. DOI: 10.1109/IGARSS.2003.1293687.
11. Hagolle O., Huc M., Villa Pascual D., Dedieu G. A multi-temporal method for cloud detection, applied to FORMOSAT-2, VEN μ S, LANDSAT and SENTINEL-2 images // Remote Sensing of Environment. 2010. V. 114. P. 1747–1755. DOI: 10.1016/j.rse.2010.03.002.
12. Irish R. R., Barker J. L., Goward S. N., Arvidson T. Characterization of the Landsat-7 ETM+ Automated Cloud-Cover Assessment (ACCA) algorithm // Photogrammetric Engineering and Remote Sensing. 2006. V. 72. No. 10. P. 1179–1188. DOI: 10.14358/PERS.72.10.1179.
13. Li Z., Shen H., Weng Q., Zhang Y., Dou P., Zhang L. Cloud and cloud shadow detection for optical satellite imagery: Features, algorithms, validation, and prospects // ISPRS J. Photogrammetry and Remote Sensing. 2022. V. 188. P. 89–108. DOI: 10.1016/j.isprsjprs.2022.03.020.
14. Lyapustin A., Wang Y., Frey R. An automatic cloud mask algorithm based on time series of MODIS measurements // J. Geophysical Research. 2008. V. 113. D16207. DOI: 10.1029/2007JD009641.
15. 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. Photogrammetry and Remote Sensing. 2019. V. 157. P. 124–136. DOI: 10.1016/j.isprsjprs.2019.08.018.
16. Stournara P., Tsakiri-Strati M., Patias P. Detection and removal of cloud and cloud shadow contamination from hyperspectral images of Hyperion sensor // South-Eastern European J. Earth Observation and Geomatics. 2013. V. 2. No. 1. P. 33–44.
17. Thompson D. R., Green R. O., Keymeulen D., Lundeen S. K., Mouradi Y., Nunes D., Castano R., Chien S. A. Rapid spectral cloud screening onboard aircraft and spacecraft // IEEE Trans. Geoscience and Remote Sensing. 2014. V. 52. No. 11. P. 6779–6792. DOI: 10.1109/TGRS.2014.2302587.
18. Zhai H., Zhang H., Zhang L., Li P. Cloud/shadow detection based on spectral indices for multi/hyperspectral optical remote sensing imagery // ISPRS J. Photogrammetry and Remote Sensing. 2018. V. 114. P. 235–253. DOI: 10.1016/j.isprsjprs.2018.07.006.
19. Zhu Z., Woodcock C. E. Object-based cloud and cloud shadow detection in Landsat imagery // Remote Sensing of Environment. 2012. V. 118. P. 83–94. DOI: 10.1016/j.rse.2011.10.028.

Using NDSI index to distinguish clouds and non-snow surfaces in multispectral images

O. V. Nikolaeva

*Keldysh Institute of Applied Mathematics RAS, Moscow 125047, Russia
E-mail: nika@kiam.ru*

Using the NDSI (Normalized Difference Snow Index) to distinguish clouds from desert areas and urbanized ones in multi-spectral images of the Hyperion spectrometer is under consideration. Hyperion images taken over surfaces of various types (water, desert, green vegetation, urbanized areas) in both clear sky and overcast conditions were selected. Statistical analysis of NDSI index value samples was performed. The same analysis of the DSI (Desert Sand Index) value samples being used in the standard cloud mask Hyperion algorithm was performed. Thresholds to distinguish clouds from the surface of each type are obtained. The percentages of misclassified pixels are estimated. It is shown that the NDSI index with the obtained thresholds can be used to reliably distinguish clouds from desert areas and urbanized areas in Hyperion images. The DSI index is shown to distinguish clouds from desert areas by larger errors, and cannot be used to distinguish clouds from urbanized areas. Hyperion images with broken clouds are considered. Bar chart analysis is shown to give optimal thresholds for an image. It is shown that the separation of pixels into “lighted surface” and “cloud and cloud shadow” is performed via the NDSI index with greater accuracy than via the DSI index. Further separation of cloudy pixels and shadow pixels should be performed via other spectral indexes. The presented results are proposed to be used in algorithms of detecting clouds in images of spectrometers with no radiation temperature measurements.

Keywords: cloud detection, multispectral images, NDSI, DSI

Accepted: 26.10.2022

DOI: 10.21046/2070-7401-2022-19-5-53-62

References

1. Amikishieva R. A., Raputa V. F., Yaroslavtseva T. V., Analysis technologies of atmospheric pollution processes based on ground and satellite observations, *InterExpo, Geo-Siberia*, 2020, Vol. 4, No. 1, pp. 36–41 (in Russian), DOI: 10.33764/2618-981X-2020-4-1-36-41.
2. Belova E. I., Ershov D. C., Preprocessing LandSat TM-/ETM+ Data Sets for Creating Cloud-Free Spring, Autumn and Winter Imagery, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2012, Vol. 9, No. 4, pp. 9–14 (in Russian).
3. Volkova E. V., Automatic estimation of cloud cover and precipitation parameters obtained by AVHRR NOAA for day and night conditions, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2017, Vol. 14, No. 5, pp. 300–320 (in Russian), DOI: 10.21046/2070-7401-2017-14-5-300-320.
4. Krutskikh N. V., Kravchenko I. Yu., The use of Landsat satellite images for geoecological monitoring of urbanized areas, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2018, Vol. 15, No. 2, pp. 159–168 (in Russian), DOI: 10.21046/2070-7401-2018-15-2-159-168.
5. Orlov Yu. N., Fedorov S. L., Methods of numerical modeling of transient random wandering processes, Moscow: MIPT, 2016, 108 p. (in Russian).
6. Ackerman S., Frey R., Strabala K., Liu Y., Gumley L., Baum B., Menzel P., *Discriminating Clear-Sky from Cloud with MODIS. Algorithm Theoretical Basis Document (MOD35)*, Madison: Univ. Wisconsin, 2010, 121 p.
7. Barton J. S., Casey K., Chien J. Y. L., Digirolamo N. E., Klein A. G., Powell H. W., Tait A. B., Hall D. K., Riggs G. A., Solomonson V. V., *Algorithm Theoretical Basis Document for the MODIS Snow and Sea Ice-Mapping Algorithms*, Madison: Univ. Wisconsin, 2001, 45 p.
8. Frantz D., Haß E., Uhl A., Stoffels J., Hill J., Improvement of the Fmask algorithm for Sentinel-2 images: Separating clouds from bright surfaces based on parallax effects, *Remote Sensing of Environment*, 2018, Vol. 215, pp. 471–481, DOI: 10.1016/j.rse.2018.04.046.
9. Gómez-Chova L., Camps-Valls G., Calpe-Maravilla J., Guanter L., Moreno J., Cloud-Screening Algorithm for ENVISAT/MERIS Multispectral Images, *IEEE Trans. Geoscience and Remote Sensing*, 2007, Vol. 45, No. 12, pp. 4105–4118, DOI: 10.1109/TGRS.2007.905312.
10. Griffin M., Burke H., Mandle D., Miller J., Cloud cover detection algorithm for EO-1 Hyperion imagery, *Proc. IEEE Intern. Geoscience and Remote Sensing Symp.*, Toulouse, France, 2003, No. 03CH37477, DOI: 10.1109/IGARSS.2003.1293687.
11. Hagolle O., Huc M., Villa Pascual D., Dedieu G., A multi-temporal method for cloud detection, applied to FORMOSAT-2, VENUS, LANDSAT and SENTINEL-2 images, *Remote Sensing of Environment*, 2010, Vol. 114, pp. 1747–1755, DOI: 10.1016/j.rse.2010.03.002.
12. Irish R. R., Barker J. L., Goward S. N., Arvidson T., Characterization of the Landsat-7 ETM+ Automated Cloud-Cover Assessment (ACCA) algorithm, *Photogrammetric Engineering and Remote Sensing*, 2006, Vol. 72, No. 10, pp. 1179–1188, DOI: 10.14358/PERS.72.10.1179.
13. Li Z., Shen H., Weng Q., Zhang Y., Dou P., Zhang L., Cloud and cloud shadow detection for optical satellite imagery: Features, algorithms, validation, and prospects, *ISPRS J. Photogrammetry and Remote Sensing*, 2022, Vol. 188, pp. 89–108, DOI: 10.1016/j.isprsjprs.2022.03.020.
14. Lyapustin A., Wang Y., Frey R., An automatic cloud mask algorithm based on time series of MODIS measurements, *J. Geophysical Research*, 2008, Vol. 113, D16207, DOI: 10.1029/2007JD009641.
15. 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. Photogrammetry and Remote Sensing*, 2019, Vol. 157, pp. 124–136, DOI: 10.1016/j.isprsjprs.2019.08.018.
16. Stournara P., Tsakiri-Strati M., Patias P., Detection and removal of cloud and cloud shadow contamination from hyperspectral images of Hyperion sensor, *South-Eastern European J. Earth Observation and Geomatics*, 2013, Vol. 2, No. 1, pp. 33–44.
17. Thompson D. R., Green R. O., Keymeulen D., Lundeen S. K., Mouradi Y., Nunes D., Castano R., Chien S. A., Rapid spectral cloud screening onboard aircraft and spacecraft, *IEEE Trans. Geoscience and Remote Sensing*, 2014, Vol. 52, No. 11, pp. 6779–6792, DOI: 10.1109/TGRS.2014.2302587.
18. Zhai H., Zhang H., Zhang L., Li P., Cloud/shadow detection based on spectral indices for multi/hyperspectral optical remote sensing imagery, *ISPRS J. Photogrammetry and Remote Sensing*, 2018, Vol. 114, pp. 235–253, DOI: 10.1016/j.isprsjprs.2018.07.006.
19. Zhu Z., Woodcock C. E., Object-based cloud and cloud shadow detection in Landsat imagery, *Remote Sensing of Environment*, 2012, Vol. 118, pp. 83–94, DOI: 10.1016/j.rse.2011.10.028.