

Классификация текстур основных типов облачности по данным MODIS с помощью нечетких систем

В.Г. Астафуров^{1,2}, Т.В. Евсюткин¹, К.В. Курьянович^{1,2}, А.В. Скороходов¹

¹ *Институт оптики атмосферы им. В.Е. Зуева СО РАН, Томск, 634021, Россия*
E-mails: oomphi.iao@gmail.com, ksuyian@mail.ru, vazime@yandex.ru

² *Томский государственный университет систем управления и радиоэлектроники*
Томск, 634050, Россия
E-mail: astafurov@iao.ru

Предложен алгоритм классификации облачности по спутниковым снимкам MODIS с пространственным разрешением 250 м на основе технологии нейронных сетей и методов нечеткой логики, что дает возможность выделять участки изображений со схожей текстурой по отношению к нескольким типам облачности с близкой степенью принадлежности и соответствует реальной динамике облачных образований. Для описания текстуры изображений облачности используются методы на основе матриц смежности (GLCM), векторов разности (GLDV), гистограмм сумм и разностей (SADH) уровней яркости и статистических характеристик яркости отдельных пикселей изображения (ODSH). Наборы эталонных изображений различных типов облачности сформированы путем сопоставления архивных данных наземных метеостанций с результатами спутниковой съемки MODIS. Обсуждается методика получения системы эффективных текстурных признаков изображений облачности на основе сравнительного анализа мер отклонений между гистограммами их выборочных значений. Для описания флуктуаций текстурных признаков различных типов облачности построена статистическая модель, включающая в себя 17 двухпараметрических функций плотностей вероятностей с оценками их параметров. Предложен метод инициализации функций принадлежности нейронной сети с использованием статистической модели текстуры. По результатам численных экспериментов найдена оценка вероятности правильной классификации изображений десяти разновидностей основных типов облачности, равная 0,81.

Ключевые слова: типы облачности, MODIS, классификация изображений, текстурные признаки, статистическая модель текстуры, функции принадлежности, нечеткая система

Одобрена к печати: 07.07.2017
DOI: 10.21046/2070-7401-2017-14-5-9-18

Введение

Информация о типе облаков, формирующих глобальное поле облачности, является необходимой при решении различных задач климатологии и метеорологии. Например, при прогнозировании погоды знание структуры макросистемы облаков способствует определению типа облачного фронта (теплый, холодный, окклюзия) (Облака..., 1989). Единственным источником информации о глобальном поле облачности в реальном масштабе времени являются данные дистанционного зондирования Земли из космоса. При этом существует большое число отечественных и зарубежных работ, отражающих подходы к решению задачи автоматической классификации изображений облачности по спутниковым снимкам. В наиболее результативных из них (Астафуров, Скороходов, 2014; Волкова, 2013; Bankert et al., 2009) на основе технологии нейронных сетей и информации о текстуре изображений облака разделяются только по 10–14 разновидностям с оценкой вероятности правильной классификации 0,8–0,9 из 27 возможных, к которым относятся основные формы облачности (Код..., 2013). Однако эффективность классификации различных типов облачности существенно варьируется, а увеличение числа выделяемых разновидностей приводит к еще большей дифференциации полученных результатов (Астафуров, Курьянович, Скороходов, 2016). Причиной этому

является сходство используемых классификационных характеристик. При этом разновидности облачности считаются сложными классами, для разделения которых успешно применяется аппарат на основе нечеткой логики (Вятчинин, 2004). Классическая методология предполагает использование в качестве функций принадлежности (ФП), определяющих степень принадлежности рассматриваемого объекта к множеству распознаваемых классов, треугольных и гауссовских функций, при которых нечеткая система вместе с рядом дополнительных условий является универсальным аппроксиматором (Круглов, Дли, Голунов, 2000). Однако построенные таким образом ФП не всегда позволяют достаточно точно описать исключительные особенности реальных объектов. С учетом сказанного, целью данной работы явилась разработка алгоритма классификации текстур изображений различных типов облачности по спутниковым данным на основе нейро-нечеткой сети с использованием нового подхода к заданию ФП путем построения статистической модели текстуры изображений.

Система классификационных характеристик

Исходный набор классификационных характеристик для описания текстуры облачности состоит из 16-ти наименований признаков метода матриц смежности уровней яркости (GLCM, Gray-Level Co-occurrence Matrix), 8-ми векторов разностей уровней яркости (GLDV, Gray-Level Difference Vector), 15-ти гистограмм суммы и разности (SADH, Sum and Difference Histograms) и 8-ми признаков, учитывающих значения яркости отдельных пикселей изображения (ODSH, One-Dimensional Signal Histogram). Подробное описание методов и рассчитываемых на их основе текстурных признаков (ТП) приведено в работах (Астафуров и др., 2013; Baum et al., 1997; Haralick, Shanmugam, Dinstein, 1973; Weszka, Dyer, Rosenfeld, 1976; Unser, 1986). Значения ТП вычисляются для четырех угловых направлений α ($\alpha=0; 45; 90; 135^\circ$) со сдвигом, равным единице между соседними пикселями изображения.

Исходные данные

Согласно стандарту Всемирной метеорологической организации облачность разделяется на 27 разновидностей, включающих в себя 10 основных типов, подтипы и их сочетания (Код..., 2013). Набор эталонных изображений для каждого типа облачности сформирован с помощью методики сопоставления архивных данных наземных метеостанций (<http://ogimet.com>) со спутниковой съемкой MODIS (<http://ladsweb.nascom.nasa.gov>) (Астафуров, Скороходов, 2011). При этом использовались данные 1-го спектрального канала (0,62–0,67 мкм) с пространственным разрешением 250 м за период 2005–2013 гг. в светлое время суток и при отсутствии снежного покрова для различных регионов планеты, полный список которых приведен в работе (Астафуров, Аксенов, Евсюткин, 2014).

На основе найденных изображений были сформированы обучающая и тестовая выборки, состоящие из 200 и 50 фрагментов соответственно размером 21×21 пиксель для каждой разновидности облаков.

Методика формирования набора информативных текстурных признаков

Формирование наборов информативных ТП осуществляется путем сравнительного анализа гистограмм одноименных ТП, вычисленных по фрагментам обучающих выборок для различных типов облачности. При этом реализуются следующие этапы:

1. Формируется набор из N_k эталонных фрагментов изображений, где $k = 1, \dots, K$; K — число рассматриваемых различных типов облачности (классов).

2. Для каждого фрагмента изображения k -го типа облачности рассчитывается набор значений ТП $\{T_j^k\}$, где $j = 1, \dots, M$, M — число различных ТП с учетом используемых методов анализа текстур изображений. Так как значения ТП изменяются в разных диапазонах, то они приводятся к интервалу $[0,1]$ путем процедуры линейного масштабирования:

$$\tilde{T} = \frac{T - T_{\min}}{T_{\max} - T_{\min}},$$

где T и \tilde{T} — текущее и нормированное значения ТП; T_{\max} и T_{\min} — его максимальное и минимальное значения на рассматриваемых наборах фрагментов изображений различных типов облачности.

3. Для каждого \tilde{T}_j^k формируются гистограммы по набору рассчитанных значений $\{\tilde{T}_j^k\}$ ТП для N_k фрагментов изображений образцов k -го типа облачности, $i = 1, \dots, N_k$. Относительные частоты $\tilde{P}_j^k(l) = v_j^k(l) / N_k$ являются оценками вероятности попадания значений \tilde{T}_j^k в l -й интервал группировки гистограммы d_j , где $l = 1, \dots, L$, L — число интервалов группировки; $v_j^k(l)$ — число значений j -го ТП, принадлежащих интервалу группировки Δ_j , $N_k = \sum_{l=1}^L v_j^k(l)$.

4. Рассчитываются меры отклонения $R_j(k, i)$ между гистограммами k -го и i -го типов облачности для j -го ТП:

$$R_j(k, i) = \sqrt{\sum_l (\tilde{P}_j^k(l) - \tilde{P}_j^i(l))^2},$$

которые являются элементами диагональных матриц:

$$D_j = \begin{pmatrix} 0 & R_j(1,2) & \dots & R_j(1,K) \\ R_j(2,1) & 0 & \dots & R_j(2,K) \\ & & \dots & \\ R_j(K,1) & R_j(K,2) & \dots & 0 \end{pmatrix}, j = 1, \dots, M.$$

Объединив все D_j , получаем матрицу отклонений для всех текстурных признаков:

$$D = \begin{pmatrix} R_1(1,2) & R_2(1,2) & R_M(1,2) \\ R_1(1,3) & R_2(1,3) & R_M(1,3) \\ \dots & \dots & \dots \\ R_1(i,k) & R_2(i,k) & R_M(i,k) \\ \dots & \dots & \dots \\ R_1(K, K-1) & R_2(K, K-1) & R_M(K, K-1) \end{pmatrix},$$

и всех пар различных типов облачности $k, i = 1, \dots, K, k \neq i$.

5. Формируется набор информативных ТП для разделения i -го и k -го типов облачности по следующему критерию: ТП \tilde{T}_j считается информативным, если $R_j(i, k) \geq \alpha \max_l R_l(i, k)$ (максимум по строке в матрице D), $\alpha \in [0,1]$. С увеличением параметра α , который подбирается в процессе настройки классификатора, уменьшается число информативных ТП. При этом для каждого сочетания i -го и k -го типов облачности в набор включается только один из одноименных ТП с различными угловыми направлениями, который превышает величину порога $\alpha \max_l R_l(i, k)$ и имеет наибольшее значение.

Алгоритм классификации

В качестве классификатора используется нечеткая система, основанная на Питтсбургской модели нечеткого вывода (Smith, 1980). Механизм нечетких выводов в своей основе имеет продукционную модель в виде конечной совокупности правил нечетких продукций, которые для Питтсбургского классификатора принимают следующий вид:

$$\text{Правило}_{h_i} : \text{если } \tilde{T}_1 = F_k^{(1)} \text{ и } \tilde{T}_2 = F_k^{(2)} \text{ и } \dots \text{ и } \tilde{T}_M = F_k^{(M)}, \text{ то класс} = c_i, w_{h_i},$$

где h_i — индекс правила h для i -го класса; w_{h_i} — вес правила или уровень доверия h_i -му правилу, $w_{h_i} \in [0,1]$; $j = 1, \dots, M$, M — количество входных переменных (текстурных признаков); $i = 1, \dots, K$, K — количество выходных переменных (распознаваемых классов); $F_k^{(j)}$ — ФП, определенные на j -м ТП. Функции принадлежности выполняют операцию фаззификации для значений ТП путем расчета степени принадлежности к распознаваемым классам. При этом суммарная степень принадлежности образца $x = \{t_j\}$ равна:

$$\sum_i^K F_i^{(j)} = 1.$$

Каждый информативный набор ТП, полученный по описанной выше методике, формирует K правил для i -го типа облачности. В Питтсбургском классификаторе логическим

операциям «И» и «ИЛИ» соответствуют «умножение» и «суммирование». При этом точность нечеткого вывода достигается путем совместной работы этих правил, что выражено степенью принадлежности:

$$Q_i(x^p) = \sum_{\text{Правило}_{h_i}} \prod_{j=1}^M F_i^{(j)}(t_{jp}) \cdot w_{h_i},$$

где x^p — вектор значений ТП для p -го обучающего образца, $p = 1, \dots, N_k$.

Выходом нечеткой системы является вектор $\{Q_1(x^p), n, Q_k(x^p)\}$, определяющий степени принадлежности образца x^p к одному из K рассматриваемых классов. Например, для трех типов облачности — перисто-когтевидных, кучево-дождевых волосатых и слоистых — вектор $\{0,49, 0,48, 0,03\}$ показывает, что исследуемый фрагмент снимка MODIS относится к одному из перечисленных типов с соответствующими степенями принадлежности. Близкие значения $Q_1(x^p)$ и $Q_2(x^p)$ свидетельствуют, что текстура исследуемого фрагмента изображения имеет сходство с текстурой двух типов облачности — перисто-когтевидных и кучево-дождевых волосатых, в результате чего алгоритм классификации относит этот фрагмент к ним одновременно.

Формирование функций принадлежности

Определение функций принадлежности (фаззификации) является одним из основных этапов построения нечеткой системы, который состоит в том, чтобы установить соответствие между значениями ТП и ФП, ассоциированных с нечеткими множествами распознаваемых классов (типы облачности), на основе исходных данных для каждой предпосылки в базе правил нечеткого вывода. В работе предлагается метод инициализации ФП восстановлением плотностей вероятности (ПВ) и вычисления оценок их параметров по гистограммам значений ТП $\tilde{P}_j^k(l)$ для различных типов облачности. Процедура осуществляется с помощью критерия Колмогорова-Смирнова (Кобзарь, 2006), который основан на мере расхождения

$$D = \sup_{|t^{(j)}| < \infty} |G(t^{(j)}) - \Phi(t^{(j)})|$$

между эмпирической $G(t^{(j)})$ и теоретической $\Phi(t^{(j)})$ функциями распределения. Здесь $\sup_{(\cdot)}$ обозначает точную верхнюю границу рассматриваемой разности. Вид распределения определялся исходя из минимума величины статистики D .

Для описания гистограмм ТП рассматривалось 17 двухпараметрических распределений, среди которых Коши, Эрланга, экспоненциальное, Фрешета, гамма-, максимальное Гамбеля, минимальное Гамбеля, обратное Гаусса, Лапласа, лог-логистическое, логнормальное, Накагами, нормальное, Пирсона типа 5, Рейлея и Вейбула, подробно описанные

в работах (Кобзарь, 2006; EasyFit..., 2015). Примеры найденных ФП для трех типов облачности показаны на *рис. 1*.




Рис. 1. Функции принадлежности текстурных признаков «Момент обратной разности 45°» метода GLCM (а) и «Пространственная когерентность» метода ODSH (б) для кучевых плоских (Cu), слоистых разорванно-слоистых разорванно-дождевых (St) и кучево-дождевых волосатых (Cb) типов облачности, построенные на основе ПВ

Параметры ФП восстанавливаются на основе обучающей выборки, поэтому их адаптация в нечеткой системе к изменениям значений входных переменных не осуществляется.

Основные результаты и их обсуждение

Проведена серия численных экспериментов по апробации алгоритма классификации нейро-нечеткой сетью с инициализацией ФП на основе метода ПВ для распознавания максимального числа различных типов облачности. В качестве базовой системы классификации выбраны три типа облаков с наиболее отличающейся текстурой (Беспалов и др., 2011): кучевые плоские разорванно-кучевые (Cu), слоистые разорванно-слоистые разорванно-дождевые (St) и кучево-дождевые волосатые (Cb). Затем перебором в исходный набор добавляется тип облачности с наибольшим значением вероятности правильной классификации тестовой выборки:

$$E = \sum_{i=1}^K \frac{N_R^{(i)}}{N_T}, \quad (1)$$

где $N_T = \sum_i N_T^{(i)}$; $N_T^{(i)}$ — число тестовых фрагментов i -го типа облачности; $N_R^{(i)}$ — число правильно проклассифицированных фрагментов тестовой выборки, которое рассчитывается исходя из максимальных значений $\max_i Q_i(\mathbf{x}^p)$ степени принадлежности к i -му классу. Набор фиксируется и подбирается следующий тип облачности.

Перечень информативных ТП представлен в *табл. 1*, где цифры в ячейках обозначают количество распознаваемых типов облачности, при котором данный ТП был включен в индивидуальный информативный набор для данной разновидности облаков. В первой строке *табл. 1* приведена последовательность, в которой добавлялись типы облачности, их обозначения приведены в *табл. 2*. Из *табл. 1* видно, что добавление нового типа облачности в систему

классификации приводит к расширению его набора информативных ТП, число которых возрастает от 9 до 12 при увеличении K от 3 до 10.

Таблица 1. Информативные ТП для различных типов облачности

Метод	Наименование ТП	Типы облачности									
		<i>Cu</i>	<i>St</i>	<i>Cb</i>	<i>Ac</i>	<i>Sc</i>	<i>As</i>	<i>Cs</i>	<i>Cc</i>	<i>Ns</i>	<i>Ci</i>
GLCM	Дисперсия	3	3	3	4	5	6	7	8	9	10
	Информационная мера корреляции — 1	6	4	6	4	5	6	7	8	9	10
	Момент обратной разности	3	3	4	4	5	6	–	8	9	10
	Суммарная энтропия	5	5	5	5	5	6	–	8	9	10
	Суммарное среднее	3	3	3	4	5	6	7	8	9	10
	Энтропия	5	5	5	5	5	6	7	–	9	10
OSDH	Низкое значение	3	3	3	4	5	–	10	8	9	10
	Перекрытие (overlay)	3	3	3	4	5	6	7	8	9	10
	Пространственная когерентность	3	3	8	4	5	6	7	8	9	10
	Среднее	–	–	3	–	–	–	–	8	–	–
SADH	Среднее	3	3	–	4	5	6	7	–	9	10
	Энтропия гистограммы суммы	–	–	–	–	–	–	–	8	–	–
GLDV	Второй угловой момент	3	3	3	4	5	6	7	8	9	10
	Среднеквадратическое отклонение	9	–	–	–	–	–	–	–	9	10

Таблица 2. Обозначения типов облачности

Тип облачности	Обозначения
Кучевые плоские	<i>Cu</i>
Слоистые разорванно-слоистые разорванно-дождевые	<i>St</i>
Кучево-дождевые волосатые	<i>Cb</i>
Высококучевые волнистообразные, чечевицеобразные и неоднородные	<i>Ac</i>
Слоисто-кучевые кучево-образные	<i>Sc</i>
Высокослоистые	<i>As</i>
Перисто-слоистые	<i>Cs</i>
Перисто-кучевые	<i>Cc</i>
Слоисто-дождевые	<i>Ns</i>
Перисто-когтевидные	<i>Ci</i>

Результаты классификации текстур различных типов облачности на основе тестовых выборок предложенного алгоритма Питтсбургского классификатора и сформированных информативных наборов ТП представлены в *табл. 3*. Оценка вероятности правильной классификации i -го типа облачности определяется выражением:

$$E_i = \frac{N_R^{(i)}}{N_T^{(i)}}.$$

Таблица 3. Результаты классификации различных типов облачности

K	Оценка вероятности правильной классификации										E
	E_i										
	Тип облачности										
	Cu	St	Cb	Ac	Sc	As	Cs	Cc	Ns	Ci	
3	0,98	0,8	1	–	–	–	–	–	–	–	0,93
4	1	0,88	1	1	–	–	–	–	–	–	0,97
5	1	0,84	0,94	1	0,98	–	–	–	–	–	0,95
6	1	0,82	0,94	1	0,98	0,76	–	–	–	–	0,92
7	1	0,72	0,96	1	0,96	0,66	0,88	–	–	–	0,88
8	0,94	0,74	0,96	0,98	0,96	0,7	0,88	0,94	–	–	0,89
9	0,94	0,74	0,96	0,98	0,96	0,72	0,86	0,84	0,8	–	0,87
10	0,92	0,76	0,94	0,8	0,96	0,62	0,72	0,84	0,8	0,8	0,81

Приведенные в *табл. 3* результаты показывают, что оценка усредненной вероятности правильной классификации (1) уменьшается с увеличением числа распознаваемых классов, что связано со снижением эффективности индивидуальной классификации отдельных типов облачности, поэтому дальнейшее добавление различных разновидностей облачных образований в систему без модификации алгоритма было признано нецелесообразным.

Заключение

Предложенный метод инициализации функций принадлежности нейро-нечеткой сети с использованием статистической модели текстурных признаков позволил получить результат систематизации основных типов облачности с вероятностью правильной классификации 0,81, что сравнимо с лучшими результатами, приведенными в работах (Астафуров, Курьянович, Скороходов, 2016; Bankert et al., 2009, Tag, Bankert, Brody, 2000). При этом данный метод имеет ряд преимуществ, основным из которых является выделение участков изображений со схожей текстурой по отношению к нескольким типам облачности с близкой степенью принадлежности, что соответствует реальной динамике облачных образований. Так же следует отметить, что данный подход формально исключает процедуру обучения, которая фактически переходит в процесс формирования статистической модели текстурных признаков.

Перспективным направлением развития исследований может быть использование многопараметрической плотности вероятности текстурных признаков различных типов облачности с привлечением дополнительной информации о физических параметрах облачных образований, а также совершенствование методов конструирования нечетких систем.

Литература

1. Астафуров В.Г., Скороходов А.В. Сегментация спутниковых снимков облачности по текстурным признакам на основе нейросетевых технологий // Исследование Земли из космоса. 2011. № 6. С. 10–20.
2. Астафуров В.Г., Евсюткин Т.В., Курьянович К.В., Скороходов А.В. Статистическая модель текстуры изображений различных типов облачности по данным MODIS // Современные проблемы дистанционного зондирования Земли из космоса. 2013. Т. 10. № 4. С. 188–197.
3. Астафуров В.Г., Скороходов А.В. Применение нейросетевых технологий для классификации облачности по текстуре снимков MODIS высокого разрешения // Исследование Земли из космоса. 2014. № 5. С. 39–49.
4. Астафуров В.Г., Аксенов С.В., Евсюткин Т.В. Классификация перистой облачности по данным MODIS с помощью нечеткой нейронной сети // Современные проблемы дистанционного зондирования Земли из космоса. 2014. Т. 11. № 4. С. 265–275.
5. Астафуров В.Г., Курьянович К.В., Скороходов А.В. Методы автоматической классификации облачности по спутниковым снимкам MODIS // Исследование Земли из космоса. 2016. № 4. С. 35–45.
6. Беспалов Д.П., Девяткин А.М., Довгалюк Ю.А., Кондратюк В.И., Кулешов Ю.В., Светлова Т.П., Суворов С.С., Тимофеев В.И. Атлас облаков. СПб: Д'АРТ, 2011. 248 с.
7. Волкова Е.В. Оценки параметров облачного покрова, осадков и опасных явлений погоды по данным радиометра AVHRR с МИСЗ серии NOAA круглосуточно в автоматическом режиме // Современные проблемы дистанционного зондирования Земли из космоса. 2013. Т. 10. № 3. С. 66–74.
8. Вятчинин Д.А. Нечеткие методы автоматической классификации. Минск: УП «Технопринт», 2004. 219 с.
9. Кобзарь А.И. Прикладная математическая статистика: для инженеров и научных работников. М.: Физматлит, 2006. 816 с.
10. Код для оперативной передачи данных приземных метеорологических наблюдений с сети станций Росгидромета / Федеральная служба по гидрометеорологии и мониторингу окружающей среды (Росгидромет). М.: Триада. Лтд, 2013. 79 с.
11. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2000. 224 с.
12. Облака и облачная атмосфера: Справочник / под ред. Мазина И.П., Хргиана А.Х. Л.: Гидрометеоиздат, 1989. 647 с.
13. Bankert R.L., Mitrescu C., Miller S.W., Wade R.H. Comparison of GOES cloud classification algorithms employing explicit and implicit physics // J. Applied Meteorology and Climatology. 2009. Vol. 48. P. 1411–1421.
14. Baum B.A., Tovinkere V., Titlow J., Welch R.M. Automated cloud classification of global AVHRR data using a fuzzy logic approach // J. Applied Meteorology. 1997. Vol. 36. P. 1519–1540.
15. Haralick R.M., Shanmugam K., Dinstein I. Textural features for image classification // IEEE Trans. Systems, Man and Cybernetics. Nov. 1973. Vol. SMC-3. No. 6. P. 610–621.
16. EasyFit — Easily Fit Distributions to Your Data! Electronic data. URL: <http://www.mathwave.com/help/easyfit/index.html> (access data 28.11.2016).
17. Smith S.F. A learning system based on genetic adaptive algorithms: Doctoral Dissertation. University of Pittsburgh, PA, 1980.
18. Tag P.M., Bankert R.L., Brody L.R. An AVHRR multiple cloud-type classification package // J. Applied Meteorology. 2000. Vol. 39. P. 125–134.
19. Weszka J.S., Dyer C.R., Rosenfeld A. A comparative study of texture measures for terrain classification // IEEE Trans. Systems, Man and Cybernetics. Apr. 1976. Vol. SMC-6. No. 4. P. 269–285.
20. Unser M. Sum and difference histograms for texture classification // IEEE Trans. Systems, Pattern Analysis and Machine Intelligence. Jan. 1986. Vol. PAMI-8. No. 1. P. 118–125.

Classification of the main cloud type textures from MODIS data using fuzzy systems

V.G. Astafurov^{1,2}, T.V. Evsyutkin¹, K.V. Kuryanovich², A.V. Skorokhodov¹

¹ V.E. Zuev Institute of Atmospheric Optics SB RAS, Tomsk 634021, Russia
E-mails: oomphi.iao@gmail.com, ksuyian@mail.ru, vazime@yandex.ru

² Tomsk State University of Control Systems and Radioelectronics, Tomsk 634050, Russia
E-mail: astafurov@iao.ru

The paper presents an algorithm of cloud classification on MODIS satellite images with 250-meter spatial resolution based on fuzzy logic methods and neural network technologies, which makes it possible to allocate image areas with a similar texture in relation to several cloud types with a close membership degree, and corresponds to the real dynamics of cloud formations. To describe cloud images texture, the methods are used based on gray level

co-occurrence matrices (GLCM), vectors of difference (GLDV), sum and difference histograms (SADH) and statistical features of intensity for individual pixels on images (ODSH). Reference image sets for different cloud types have been formed by comparing the archival data of terrestrial weather stations with MODIS satellite images. The technique is discussed for building a set of effective texture features of cloud images based on comparative analysis of sampling histogram deviations. To characterize fluctuations of texture feature values for different cloud type images, a statistical model was developed that includes 17 two-parameter probability density functions with estimation of the features' parameters. A method was proposed of neural network membership functions initialization using statistical model of image textures. In the course of numerical experiments an assessment was obtained of probability of correct image classification for ten basic cloud types which reached 0.81.

Keywords: cloud types, MODIS, image classification, texture features, texture statistical model, membership functions, fuzzy system

Accepted: 07.07.2017

DOI: 10.21046/2070-7401-2017-14-5-9-18

References

1. Astafurov V.G., Skorokhodov A.V., Segmentatsiya sputnikovykh snimkov oblachnosti po teksturnym priznakam na osnove neirosetevykh tekhnologii (Segmentation of satellite cloud images based on texture features and neural network technologies), *Issledovanie Zemli iz kosmosa*, 2011, No. 6, pp. 10–20.
2. Astafurov V.G., Evsyutkin T.V., Kur'yanovich K.V., Skorokhodov A.V., Statisticheskaya model' tekstury izobrazhenii razlichnykh tipov oblachnosti po dannym MODIS (Statistical model of the texture images of different types of clouds on MODIS data), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2013, Vol. 10, No. 4, pp. 188–197.
3. Astafurov V.G., Skorokhodov A.V., Primenenie neirosetevykh tekhnologii dlya klassifikatsii oblachnosti po teksture snimkov MODIS vysokogo razresheniya (Application of neural network technologies for classification of clouds according to the texture of high resolution MODIS images), *Issledovanie Zemli iz kosmosa*, 2014, No. 5, pp. 39–49.
4. Astafurov V.G., Aksenov S.V., Evsyutkin T.V., Klassifikatsiya peristoi oblachnosti po dannym MODIS s pomoshch'yu nechetkoi neironnoi seti (Classification of cirrus clouds on MODIS data using a fuzzy neural network), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2014, Vol. 11, No. 4, pp. 265–275.
5. Astafurov V.G., Kur'yanovich K.V., Skorokhodov A.V., Metody avtomaticheskoi klassifikatsii oblachnosti po sputnikovym snimkam MODIS (Methods of automatic classification of clouds on MODIS), *Issledovanie Zemli iz kosmosa*, 2016, No. 4, pp. 35–45.
6. Bepalov D.P., Devyatkin A.M., Dovgalyuk Yu.A., Kondratyuk V.I., Kuleshov Yu.V., Svetlova T.P., Suvorov S.S., Timofeev V.I., *Atlas oblakov* (Cloud Atlas), Saint Petersburg: D'ART, 2011, 248 p.
7. Volkova E.V., Otsenki parametrov oblachnogo pokrova, osadkov i opasnykh yavlenii pogody po dannym radiometra AVHRR s MISZ serii NOAA kruglosutochno v avtomaticheskom rezhime (Estimates of the parameters of the cloud cover, precipitation and dangerous weather phenomena according to the AVHRR radiometer with MISZ of the NOAA series around the clock in automatic mode), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2013, Vol. 10, No. 3, pp. 66–74.
8. Vyatchenin D.A., *Nechetkie metody avtomaticheskoi klassifikatsii* (Fuzzy methods of automatic classification), Minsk: UP "Tekhnoprint", 2004, 219 p.
9. Kobzar' A.I., *Prikladnaya matematicheskaya statistika* (Applied mathematical statistics), Moscow: Fizmatlit, 2006, 816 p.
10. *Kod dlya operativnoi peredachi dannykh prizemnykh meteorologicheskikh nablyudenii s seti stantsii Rosgidrometa* (The code for the operational data transfer of surface meteorological observations from the Roshydromet network (SYNOP)), Moscow, Triada. Ltd, 2013, 79 p.
11. Kruglov V.V., Dli M.I., Golunov R.Yu., *Nechetkaya logika i iskusstvennye neironnye seti* (Fuzzy logic and artificial neural networks), Moscow: Fizmatlit, 2000, 224 p.
12. *Oblaka i oblachnaya atmosfera* (Clouds and a cloudy atmosphere), Leningrad: Gidrometeoizdat, 1989, 647 p.
13. Bankert R.L., Mitrescu C., Miller S.W., Wade R.H., Comparison of GOES cloud classification algorithms employing explicit and implicit physics, *Journal of Applied Meteorology and Climatology*, 2009, Vol. 48, pp. 1411–1421.
14. Baum B.A., Tovinkere V., Titlow J., Welch R.M., Automated cloud classification of global AVHRR data using a fuzzy logic approach, *Journal of Applied Meteorology*, 1997, Vol. 36, pp. 1519–1540.
15. Haralick R.M., Shanmugam K., Dinstein I., Textural features for image classification, *IEEE Transactions on Systems, Man and Cybernetics*, November 1973, Vol. SMC-3, No. 6, pp. 610–621.
16. <http://www.mathwave.com/help/easyfit/index.html>.
17. Smith S.F., *A learning system based on genetic adaptive algorithms: Doctoral Dissertation*, University of Pittsburgh, PA, 1980.
18. Tag P.M., Bankert R.L., Brody L.R., An AVHRR multiple cloud-type classification package, *J. Appl. Meteor.*, 2000, Vol. 39, pp. 125–134.
19. Weszka J.S., Dyer C.R., Rosenfeld A., A comparative study of texture measures for terrain classification, *IEEE Transaction on Systems, Man and Cybernetics*, April 1976, Vol. SMC-6, No. 4, pp. 269–285.
20. Unser M., Sum and difference histograms for texture classification, *IEEE Transaction on Systems, Pattern Analysis and Machine Intelligence*, January 1986, Vol. PAMI-8, No. 1, pp. 118–125.