

Классификация перистой облачности по данным MODIS с помощью нечеткой нейронной сети

В.Г. Астафуров^{1,2}, С.В. Аксёнов³, Т.В. Евсюткин¹

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

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

³*Национальный исследовательский Томский политехнический университет
Томск, 634050, Россия
E-mail: axoenows@tpu.ru*

Рассматривается классификация перистой облачности по подтипам по данным MODIS с пространственным разрешением 250 м. Для анализа изображений облачности на спутниковых снимках используется информация об их текстуре, полученная с помощью четырех методов: Gray-Level Co-occurrences Matrix, Gray-Level Difference Vector, Sum and Difference Histograms и Spectral Features. Приводится методика определения набора информативных текстурных признаков для классификации подтипов перистой облачности на основе сравнительного анализа гистограмм их выборочных значений. В результате проведенных исследований для каждого подтипа перистой облачности сформирован набор ключевых признаков, которые вместе с гистограммами являются моделью изображений подтипов перистой облачности, используемой для их распознавания. Рассматривается архитектура нейронной сети на базе нечеткой логики, позволяющая относить классифицируемое изображение более чем к одному классу с различной степенью уверенности. Сеть сконструирована из нескольких подсетей, каждая из которых сосредоточена на одном из подтипов перистой облачности. Для обучения сети используется генетический алгоритм с различными способами инициализации функции принадлежности. Полученные результаты позволяют сделать вывод о большой неоднородности покрова перистой облачности на спутниковых снимках и переходе одних подтипов облаков в другие. Обсуждается достоверность результатов классификации.

Ключевые слова: перистая облачность, текстурные признаки, нейронная сеть, нечеткая логика, классификация.

Введение

Перистая облачность является наиболее распространенным типом облаков верхнего яруса, образующаяся в районе тропопаузы, но из-за своей малой оптической толщины, несмотря на прогресс в развитии методов обнаружения, существует значительная неопределенность в их мониторинге современными спутниковыми системами. Информацию о наличии перистых облаков, их температуре и высоте верхней границы, коэффициенте отражения, водности и ряд других характеристик можно получить из тематических продуктов MODIS второго уровня: MOD06_L2, MYD06_L2, MOD35_L2 и MYD35_L2. При этом вопросы их классификации по подтипам в известных нам работах не рассмотрены. Согласно действующему метеорологическому стандарту (Государственный комитет СССР по гидрометеорологии и контролю природной среды, 1989) перистая облачность разделяется на когтевидные (*Ci unc*), хребтовидные и перепутанные (*Ci vert & Ci int*), хлопьевидные (*Ci floc*)

и образовавшиеся из наковален кучево-дождевых облаков (*Ci ing*) подтипы. Существуют специфические особенности их влияния на условия образования фронтальных осадков через механизм засева нижней облачности ледяными кристаллами, а также на рост парникового эффекта. Поэтому автоматическая классификация перистой облачности по подтипам на основе данных дистанционного зондирования Земли из космоса является актуальной задачей, которая рассматривается в нашей работе.

Система текстурных признаков

Для описания изображений разновидностей перистой облачности по спутниковым снимкам целесообразно привлекать информацию о текстуре изображений (Гонсалес и др., 2005), что позволяет представить ее как единую целостную структуру. В настоящее время существуют различные подходы к описанию текстуры со своим собственным набором текстурных признаков (ТП). При этом не все ТП являются одинаково информативными для описания различных изображений перистой облачности. В работе используются следующие методы описания и анализа текстуры изображений:

- GLDV, или метод вектора разности уровня яркости (Weszka et al., 1976), основанный на вычислении оценок вероятностей $P_{\delta}(i)$ значений абсолютных разностей уровней яркости $I(x,y)$ пар элементов изображения (пикселей), отстоящих друг от друга на расстоянии $\delta(\Delta x, \Delta y)$, где Δx и Δy – величины смещений по координатам x и y , $i = \overline{1, m}$, m – число уровней квантования яркости изображения;
- GLCM, или метод матрицы смежности уровней яркости (Haralick et al., 1973), элементами которой являются относительные частоты $P_d(i, j)$ наличия на изображении соседних точек с яркостями I_i и I_j , $i = \overline{1, m}$, $j = \overline{1, m}$, расположенных на расстоянии d друг от друга в одном из четырех угловых направлений $\varphi=0^\circ, 45^\circ, 90^\circ, 135^\circ$;
- SADH, или метод гистограмм суммы и разности (Unser, 1986), основанный на вычислении локальных свойств гистограмм суммы (ГС) $P_S(i)$ и разности (ГР) $P_d(j)$ уровней яркости $I(x,y)$ пар элементов изображения, где $i = \overline{2, 2m}$, $j = \overline{-m+1, m-1}$;
- статистические характеристики яркости пикселей изображений (Baum, 1997), такие как вариация, первый начальный момент, мода и другие.

Текстурные признаки рассчитывались при смещениях до 5 пикселей по каждой координате, что позволяет учесть различную пространственную ориентацию текстуры изображений подтипов перистой облачности.

Предлагается методика определения набора информативных ТП для классификации подтипов перистой облачности на основе сравнительного анализа гистограмм выборочных значений ТП:

1. Для каждого подтипа перистой облачности (класса) формируется набор из N_k эталонных образцов, значения ТП которых будут использоваться при обучении классификаторов;

2. Для каждого образца k -го класса рассчитывается набор ТП $\{T_j^k\}$, где индекс j определяет вид ТП и соответствующий метод описания и анализа текстур изображений: GLCM, GLDV, SADH и Y(RGB). Так как значения всех ТП изменяются в разных диапазонах, то они приводятся к интервалу $[0,1]$ путем нормировки $\tilde{T} = \frac{T-T_{min}}{T_{max}-T_{min}}$, где T – текущее значение признака, \tilde{T} – нормированное значение ТП, T_{max} и T_{min} – его максимальное и минимальное значения на рассматриваемых фрагментах.

3. Для каждого \tilde{T}_j^k вычисляются гистограммы по набору рассчитанных значений $\{t_{ji}^k\}$ ТП для N_k эталонных образцов с интервалами группировки $\{d_l\}$, где $l=1, \dots, L$, L – число интервалов гистограммы, $i=1, \dots, N_k$. Относительные частоты $\tilde{P}_i^k = v_i^k/N_k$ являются оценками вероятностей $P_i^k = \int_{d_l} f(t_j^k) dt_j^k$ попадания ТП \tilde{T}_j^k в интервал d_l , где v_i^k – число значений ТП, принадлежащих интервалу d_l , $N_k = \sum_{l=1}^L v_l^k$.

4. Для классификации подтипов перистой облачности необходимо выделить для них ТП, гистограммы которых существенно отличаются. Зафиксируем конкретный подтип перистой облачности C_k , который требуется распознать на изображениях, а остальные классы (подтипы перистой облачности и подстилающая поверхность) C_i будем считать «фоновыми», где $i \neq k$. Для классов C_k и C_i вычисляются характеристики $\tau^+(k, i, j) = \sum_{l=1}^L \Delta_l^+(k, i, j)$ и $\tau^-(k, i, j) = \sum_{l=1}^L \Delta_l^-(k, i, j)$ для всех k, i и j , где Δ_l^+ и Δ_l^- обозначают положительные и отрицательные значения разностей $\Delta_l(k, i) = \tilde{P}_l^k - \tilde{P}_l^i$ относительных частот, соответственно. При этом $\tau^+ + \tau^- = 0$. Величина τ^+ характеризует степень отличия между гистограммами ТП различных подтипов перистой облачности

5. Формируется набор информативных ТП для каждого класса. Текстуальный признак \tilde{T}_i считается информативным, если он имеет величину τ^+ больше, чем признаки \tilde{T}_j при $i \neq j$. Найденные ТП являются ключевыми для классифицируемых подтипов перистой облачности.

Исходные данные

Поиск характерных изображений для подтипов перистой облачности осуществлялся на основе сопоставления архивных данных сети метеостанций со спутниковой съемкой спектрорадиометра MODIS. В работе используются результаты измерений 1-го спектрального канала (0,62 – 0,67 мкм), которые согласно спецификации (<http://modis.gsfc.nasa.gov/>) применяются для исследования контуров облачности. Информация о характеристиках облаков извлекалась с сервера «Погода России» (<http://meteo.infospace.ru/>). Для поиска регионов планеты, время фиксации метеоданных на которых совпадает со спутниковой съемкой, использовались расчетные схемы пролетов Terra и Aqua из архива Space Science and Engineering Center (<http://www.ssec.wisc.edu/>). В число интересующих нас метеостанций вошли следующие: Аделаида (Австралия, 34°56'S, 138°31'E), Антофагаста (Чили, 23°26'S, 70°27'W), Балхаш (Казахстан, 46°53'N, 75°00'E), Лансароте (Испания, 28°57'N, 13°36'W), Новотроицкое (Казахстан, 43°42'N, 73°47'E), Томск (Россия, 56°26'N, 84°58'E), Новосибирск (Россия, 55°02'N, 82°54'E), Пиарко (Тринидад и Тобаго, 10°37'N, 61°21'W), Исламабад (Пакистан, 33°37'N 73°06'E), Бетлехем (ЮАР, 28°15'S 28°20'E), Долорес (Аргентина, 36°21'S 57°44'W), Первомайское (Россия, 57°04'N 86°13'E).

Для выбранных метеостанций подбирались соответствующие снимки MODIS из архива на сервере Goddard Space Flight Center (<http://ladsweb.nascom.nasa.gov/index.html>). Интервал времени между фиксацией характеристик облачности на метеостанции и спутниковой съемкой не превышал 20 минут. В результате были сформированы наборы снимков MODIS с пространственным разрешением 250 м при отсутствии снежного покрова, который включают 94 изображения 4 разновидностей перистой облачности. Для каждого подтипа было найдено от 10 до 47 фрагментов размером 250×250 пикселей. Из этих изображений были сформированы обучающая и тестовая выборки объемом 400 и 800 образцов соответственно с размерами 21×21 пиксель.

На основе приведенной выше методики для обучающей выборки каждого подтипа перистой облачности были рассчитаны и проанализированы ТП при числе уровней квантования $m=20$ и максимальном допустимом значении числа интервалов группировки $L=80$. В результате проведенных исследований для каждого подтипа перистой облачности сформирован набор информативных ТП, которые представлены в *табл. 1*. В *таблице* приняты следующие обозначения: $S(x,y)$ – смещения для расчета ТП по ГС метода SADH, в скобках указаны значения параметров угла и расстояния (φ, d) для метода GLCM. Сформированные наборы эффективных ТП и гистограммы их выборочных значений являются моделью изображений подтипов перистой облачности, используемой для их

распознавания. На *рис. 1* показаны примеры огибающих гистограмм выборочных значений ТП: T_2 – «Суммарное среднее ($90^\circ, 2$)», T_6 – «Мода».

Для полученных наборов ТП (*табл. 1*) была проведена проверка соответствия собранных обучающих и тестовых выборок по каждому из подтипов перистой облачности с помощью двухвыборочного критерия Колмогорова-Смирнова (Кобзарь, 2006). По результатам анализа при уровне значимости $\alpha=0,05$ сделан вывод о том, что тестовые и обучающие выборки согласуются между собой.

Таблица 1. Информативные текстурные признаки подтипов перистой облачности

Перистые когтевидные ($Ci unc$)			Перистые хлопьевидные ($Ci floc$)		
Метод	Характеристика		Метод	Характеристика	
GLCM	Дисперсия $45^\circ d = 4$	T_1	GLCM	Момент обратной разности ($135^\circ, 4$)	T_4
GLCM	Суммарное среднее ($90^\circ, 2$)	T_2	SADH	Среднее $S(2, 4)$	T_5
GLCM	Суммарное среднее ($90^\circ, 3$)	T_3	GLCM	Суммарное среднее ($90^\circ, 3$)	T_3
Перистые хребтовидные и перепутанные ($Ci int \& Ci vert$)			Перистые образовавшиеся из наковален кучево-дождевых облаков ($Ci ing$)		
Метод	Характеристика		Метод	Характеристика	
Y(RGB)	Мода	T_6	GLCM	Дисперсия ($45^\circ, 4$)	T_1
SADH	Среднее $S(2, 4)$	T_5	Y(RGB)	Мода	T_6
GLCM	Суммарное среднее ($90^\circ, 2$)	T_2	GLCM	Момент обратной разности ($135^\circ, 4$)	T_4

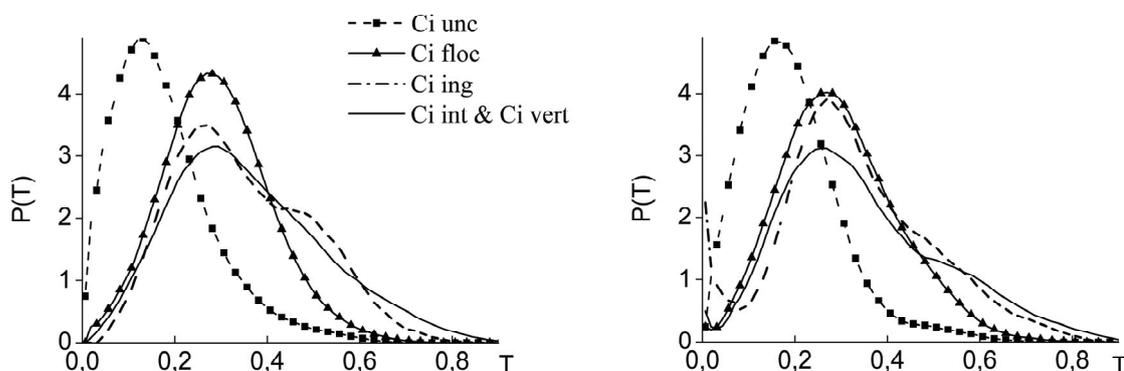


Рис. 1. Огибающие гистограмм выборочных значений ТП «Суммарное среднее ($90^\circ, 2$)» (а), «Мода» (б) при $L = 80$

Архитектура нечеткого нейросетевого классификатора

В качестве классификатора выбрана нейронная сеть на базе нечеткой логики (Круглов и др., 2000; Леоненков, 2005; Осовский, 2002). Основной идеей нечетких систем является то, что классифицируемый образец может принадлежать более чем к одному классу с различной степенью доверия (уверенности). Предложенная архитектура

четырёхслойной нейронной сети (рис. 2) сконструирована из нескольких подсетей, каждая из которых сосредоточена на одном из подтипов перистой облачности (слои 1 и 2), нейронов-сумматоров (слой 3) и интерпретатора. Полученные наборы информативных ТП для различных подтипов перистой облачности, представленные в табл. 1, использовались для формирования входных векторов подсетей: Сеть $Ci unc [T_1, T_2, T_3]$, Сеть $Ci floc [T_4, T_5, T_3]$, Сеть $Ci ing [T_6, T_5, T_2]$, Сеть $Ci int \& Ci vert [T_1, T_6, T_4]$. Для обучения сети применялся генетический алгоритм обучения (Рутковская и др., 2006).

На этапе обучения используется набор эталонных изображений подтипов перистой облачности, с помощью которого настраиваются значения параметров функций принадлежности (ФП), чтобы при предъявлении схожих по текстуре образцов она относила их с большей степенью принадлежности к конкретному подтипу. Критерием останова обучения является достаточная малая величина относительного изменения на соседних эпохах целевой функции $E_j = \frac{1}{2} \sum_{l=1}^N (Y(x^l) - d^l)^2$, принятая равной 0,01 (Осовский, 2002). Здесь j – номер эпохи, x^l – вектор ТП для l -го обучающего образца, $Y(x^l) = \max_i(A_i^l)$ – отклик сети, d^l – эталонный выходной сигнал сети на этот образец, N – объем обучающей выборки. Эталонные выходные сигналы определялись по степени достоверности выделенных экземпляров подтипов перистой облачности обучающей выборки. Например, для сети $Ci unc$ выходные отклики должны стремиться к 1 при предъявлении образцов когтевидных перистых облаков, а для остальных образцов других классов – к 0.

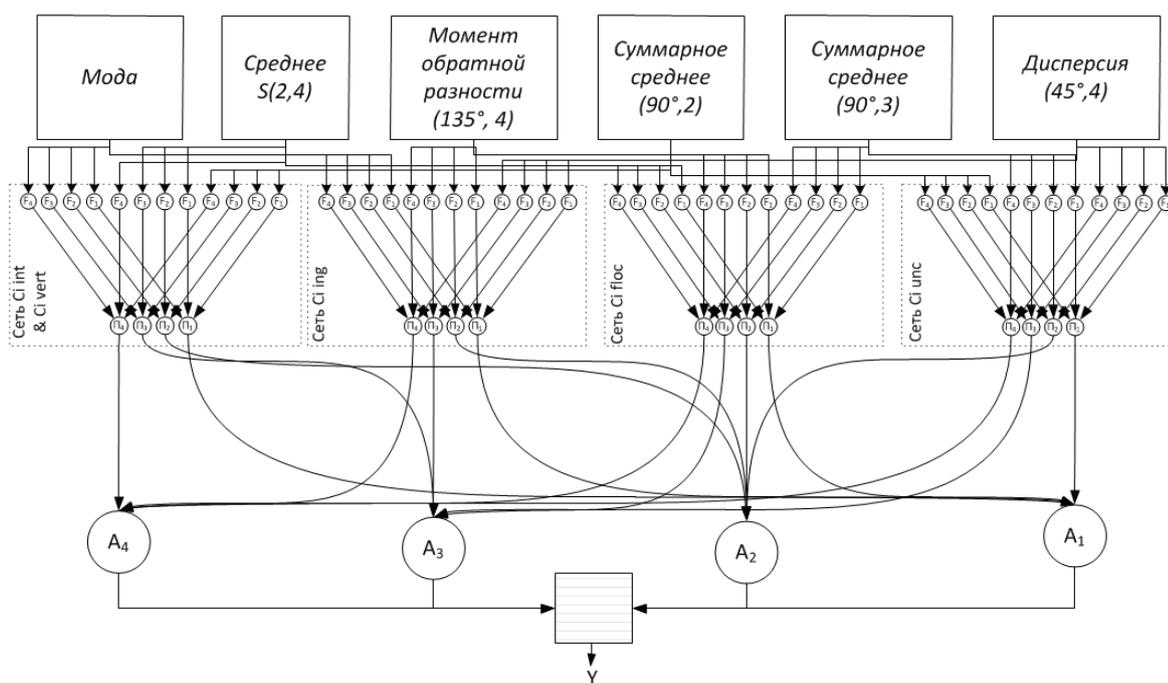


Рис. 2. Архитектура нечеткого нейросетевого классификатора

Инициализация нечеткой нейронной сети

В работе рассматривались три способа инициализации ФП:

1. Классический способ задания ФП в виде гауссовской или треугольной функций на всей области изменения текстурного признака (Леоненков, 2005);

2. Кусочно-линейная интерполяция функциями

$$F_k(t) = (\widehat{P}_k(t_1) - \widehat{P}_k(t_0)) \times (t - t_0) / (t_1 - t_0),$$

где $F_k(t)$ – значение ФП k -го класса при значении текстурного признака t , $\widehat{P}_k(t_1)$ и $\widehat{P}_k(t_0)$ – известные значения относительных частот при значениях текстурного признака t_1 и t_0 соответственно. В данном случае обучение нейронной сети не требуется, и можно приступать непосредственно к классификации;

3. Кусочная аппроксимация ФП набором функций $\{f_i(t)\}$, область значений которых находится в интервале $[0,1]$. Выбор числа функций $\theta_{k,i}^j$, которые характеризуют компактность представления ФП k -го типа облачности, и областей их определения осуществлялся на основе анализа вида характеристики Δ_l^+ . Считается, что ТП T_i является более компактным для k -го типа облачности тогда, когда значение $\theta_{k,i}^j$ меньше. В связи с этим в пункте 5 предложенной выше методики выбор ТП осуществляется следующим образом: текстурный признак \tilde{T}_i считается информативным, если он более компактный и имеет величину τ^+ больше, чем признаки \tilde{T}_j при $i \neq j$.

Результаты классификации и их обсуждение

После предъявления классифицируемого фрагмента изображения определяется его принадлежность к каждому подтипу перистой облачности в соответствии с полученными значениями A_i^l на нейронах-сумматорах третьего слоя сети. В результате центральный пиксель классифицируемого фрагмента изображения перекрашивается в определенный цвет в соответствии с выбранной легендой, или смешением цветов в случае отнесения фрагмента сразу к нескольким подтипам перистой облачности, когда значения степеней принадлежности образца отличаются на величину не более 0,1. Если нейронная сеть не может определить принадлежность классифицируемого фрагмента к какому-либо подтипу перистых облаков, то это обозначается пикселем белого цвета (класс NC).

Достоверность результатов классификации на основе тестовой выборки определялась по оценке вероятности правильной классификации: $E_i = N_R^{(i)} / N_T^{(i)}$, где $N_T^{(i)}$ – число тестовых образцов для i -го типа облачности при $i = \overline{1,4}$, $N_R^{(i)}$ – количество совпадений результатов классификации с данными метеостанции для i -го типа

облачности. В табл. 3 приведены оценки E_i и усредненная вероятность правильной классификации E_A .

На рис. 4 приведены результаты классификации снимков, представленных на рис. 3, где слева направо наблюдались: когтевидные над Исламабадом от 17.11.2005, хлопьевидные в районе Первомайского от 20.08.2010 и хребтовидные над Балхашем от 21.09.2010.

Таблица 3. Результаты оценки достоверности результатов классификации

Способ инициализации ФП		Тип облачности				E_A
		$Ci unc$	$Ci floc$	$Ci ing$	$Ci int \& Ci vert$	
Классический с гауссовскими функциями	E_i	0,77	0,46	0,45	0,23	0,46
Классический с треугольными функциями	E_i	0,74	0,48	0,26	0,36	0,48
Нелинейно-кусочная аппроксимация треугольными функциями	E_i	0,7	0,46	0,32	0,38	0,48
Линейная интерполяция	E_i	0,7	0,45	0,21	0,56	0,51
Нелинейно-кусочная аппроксимация гауссовскими функциями	E_i	0,72	0,5	0,49	0,55	0,56

Распределение интерпретации распознавания выборочных данных N_T подтипов перистой облачности по типам и их сочетаниям, на основе анализа значений, полученных с нейронов-сумматоров, при инициализации ФП кусочной аппроксимацией гауссовскими функциями приведено на рис. 5. На данном рисунке используются следующие обозначения: $A - Ci unc$, $B - Ci floc$, $C - Ci ing$, $D - Ci int \& Ci vert$, а также их сочетания, когда образцы отнесены сразу к нескольким подтипам перистой облачности, например, AB – когтевидные или хлопьевидные.

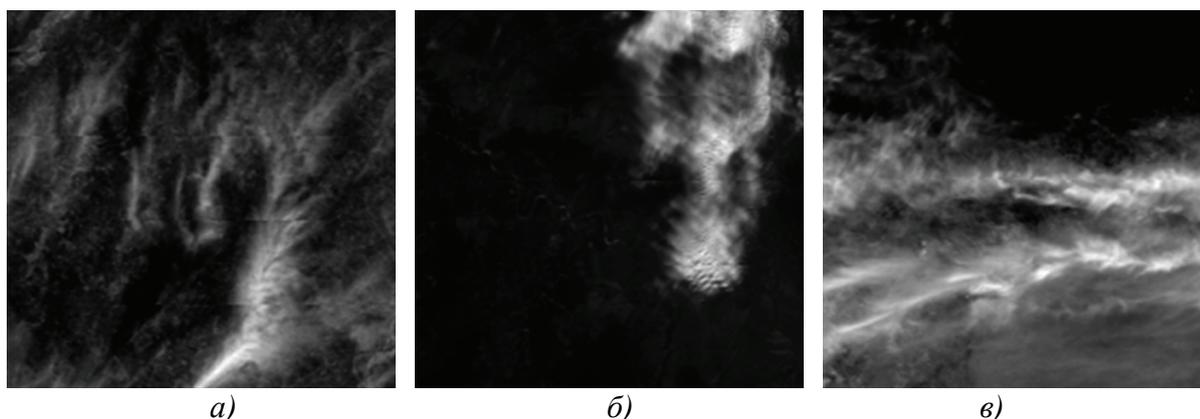


Рис. 3. Исходные фрагменты снимков MODIS территорий Пакистана (а), России (б) и Казахстана (в) с разрешением 250 м

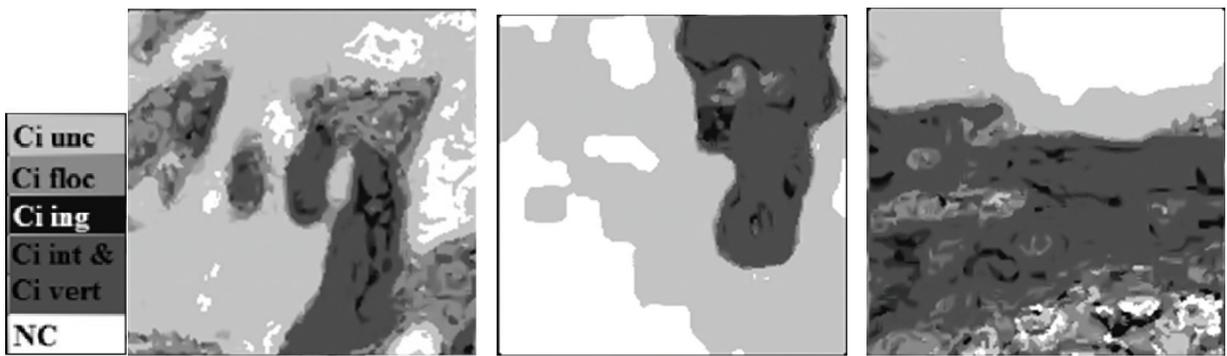


Рис. 4. Результаты классификации изображений рис. 2 территорий Пакистана (а), России (б) и Казахстана (в)

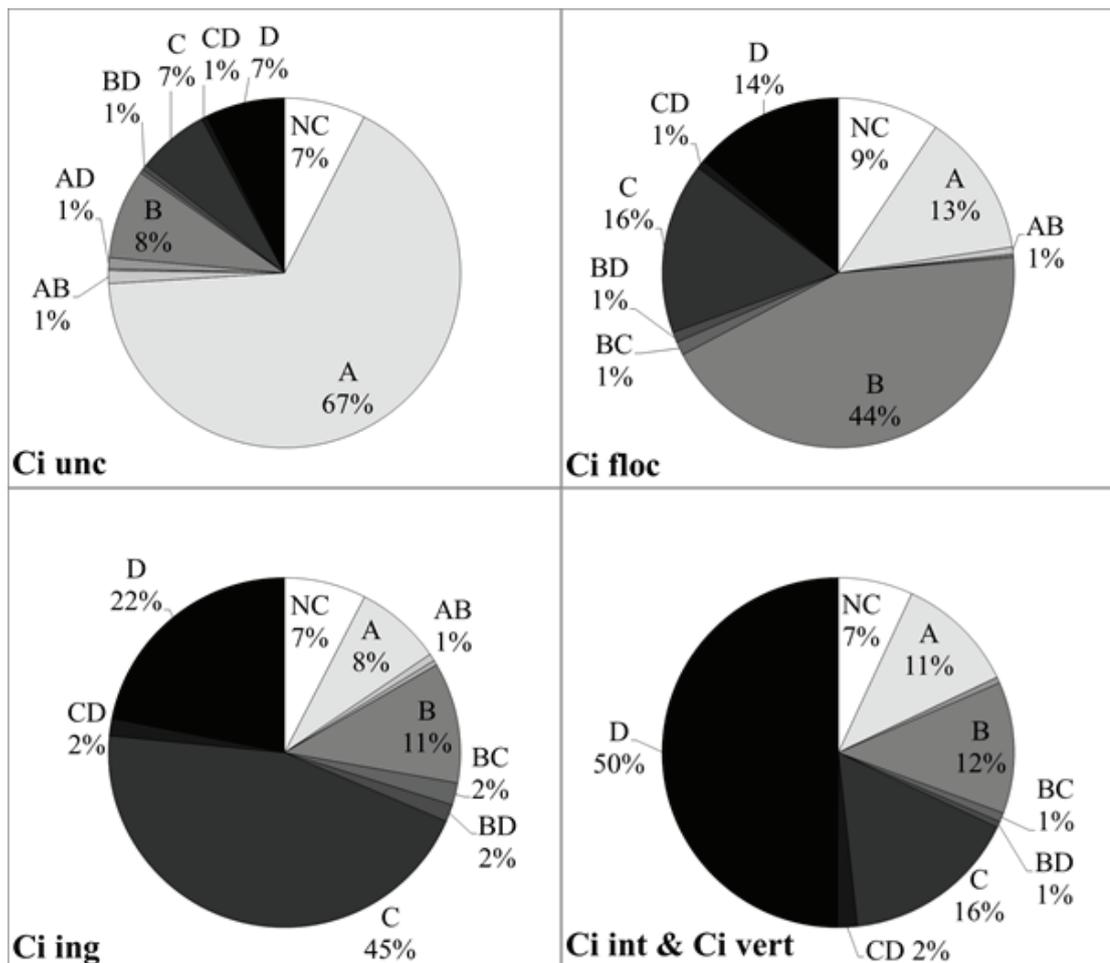


Рис. 5. Результаты распознавания перистой облачности по типам: А – Ci unc, В – Ci floc, С – Ci ing, D – Ci int&Ci vert, - и их сочетаниям

Заключение

Сформированные наборы информативных текстурных признаков для подтипов перистой облачности на основе четырех методов анализа и описания текстур изображений являются достаточными для их классификации. Для классификации перистой облачности по ее изображению на спутниковых снимках предложена архитектура нейросетевого

классификатора на основе нечеткой логики, которая обладает хорошей обобщающей способностью, что подтверждается результатами её тестирования. При этом оценка вероятности правильной классификации достигает 0,6. По результатам классификации фрагментов изображений перистой облачности (рис. 5) можно говорить об их большой неоднородности на спутниковых снимках и переходе одних подтипов в другие и разновидностей облаков в другие, что является типичным для перистой облачности, так как они часто наблюдаются в зонах турбулентности (Зуев, Титов, 1996). Результаты классификации спутниковых снимков (рис. 4) показывают совпадение с данными метеостанции для Балхаша и Исламабада, в районе Первомайского нейронная сеть ошибочно проклассифицировала хлопьевидный подтип перистой облачности как хребтовидный. Применение предложенной нейронной сети для автоматической классификации перистой облачности по подтипам предполагает использование информации о наличии перистой облачности (маска перистой облачности), которую можно извлечь из продукта MOD06_L2 (MYD06_L2). Повышение эффективности классификации может быть достигнута привлечением дополнительной информации о параметрах облачности (высота и температура верхней границы облаков, их фазовый состав и оптическая толщина), содержащейся в указанных продуктах MODIS.

Работа выполнена при частичной финансовой поддержке РФФИ в рамках проекта № 14-07-31090 мол_a.

Литература

1. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2005. 1072 с.
2. Государственный комитет СССР по гидрометеорологии и контролю природной среды. Код для оперативной передачи данных приземных гидрометеорологических наблюдений с сети станций Госкомгидромета СССР, расположенных на суше (включая береговые станции) КН-01, национальный вариант международного кода FM-12-IX SYNOP. Ленинград: Гидрометеиздат, 1989. 64 с.
3. Зуев В.Е., Титов Г.А. Оптика атмосферы и климат. Томск: Спектр, 1996. 272 с.
4. Кобзарь А.И. Прикладная математическая статистика: для инженеров и научных работников. М.: Физматлит, 2006. 816 с.
5. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2000. 224 с.
6. Леоненков А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH. СПб: БХВ Петербург, 2005. 736 с.
7. Осовский С. Нейронные сети для обработки информации: Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 2002. 344 с.
8. Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. Пер. с польск. И.Д. Рудинского. М.: Горячая линия – Телеком, 2006. 452 с.
9. Baum B.A., Tovinkere V., Titlow J., Welch R.M. Automated cloud classification of global AVHRR data using a fuzzy logic approach // J. Appl. Meteor. 1997. Vol. 36. P. 1519-1540.
10. 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. P. 610-621.
11. 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. P. 118-125.
12. 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. P. 269-285.

Classification of cirrus clouds according to MODIS data by fuzzy neural network

V.G. Astafurov^{1,2}, S.V. Axyonov³, T.V. Evsyutkin¹

¹*V.E. Zuev Institute of Atmospheric Optics SB RAS, Tomsk 634021, Russia
E-mail: oomphi.iao@gmail.com*

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

³*National Research Tomsk Polytechnic University, Tomsk 634050, Russia
E-mail: axoenows@tpu.ru*

A classification of cirrus clouds by subtypes according to MODIS data with the spatial resolution of 250 m is considered. Cloud patterns in satellite data are analyzed using information on their texture, obtained with the help of four methods: Gray-Level Co-occurrence Matrix, Gray-Level Difference Vector, Sum and Difference Histograms, and Spectral Features. We present a method capable of determining the set of informative texture features for classifying the cirrus cloud subtypes on the basis of comparative analysis of histograms of their sampling values. Based on studies performed, for each cirrus cloud subtype we created a set of key features which, together with histograms, represent the model of patterns of cirrus cloud subtypes, used for their recognition. We consider the architecture of neural network on the basis of fuzzy logic, which makes it possible to refer the classified pattern to more than one class with different confidence degrees. The network is constructed on a few sub-networks, each focused on one of the cirrus cloud subtypes. The network is learned using a genetic algorithm with different methods for initializing the membership function. The results obtained allow us to state large inhomogeneity of cirrus cloud cover on satellite data and possibility of transitions between cloud subtypes. The validity of classification results is discussed.

Keywords: cirrus clouds, texture features, neural network, fuzzy logic, classification.

References

1. Gonsales R., Vuds R., *Tsifrovaya obrabotka izobrazhenii* (Digital image processing), Moscow: Tekhnosfera, 2005, 1072 p.
2. FM-12-IX SYNOP, Leningrad: Gidrometeoizdat, 1989, 64 p.
3. Zuev V.E., Titov G.A., *Optika atmosfery i klimat* (Optics of the atmosphere and climate), Tomsk: Spektr, 1996, 272 p.
4. Kobzar' A.I., *Prikladnaya matematicheskaya statistika* (Applied mathematical statistics), Moscow: Fizmatlit, 2006, 816 p.
5. 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.
6. Leonenkov A.V., *Nechetkoe modelirovanie v srede MATLAB i fuzzyTECH* (Fuzzy modeling in MATLAB and fuzzyTECH), St. Petersburg: BHV Peterburg, 2005, 736 p.
7. Osovskii S., *Neironnye seti dlya obrabotki informatsii* (Neural network for information processing), Moscow: Finansy i statistika, 2002, 344 p.
8. Rutkovskaya D., Pilin'skii M., Rutkovskii L. *Neironnye seti, geneticheskie algoritmy i nechetkie sistemy* (Neural networks, genetic algorithms and fuzzy systems), Moscow: "Goryachaya liniya – Telekom", 2006, 452 p.
9. 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*, November 1997, Vol. 36, pp. 1519-1540.
10. 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.
11. 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.
12. 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.