

Классификация многоярусной облачности по данным MODIS с использованием технологии нейронных сетей и методов нечеткой логики

В.Г. Астафуров^{1,2}, А.В. Скороходов¹

¹ *Институт оптики атмосферы им. В.Е. Зуева СО РАН, Томск, 634055, Россия*
E-mail: vazime@yandex.ru

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

В работе предложен метод автоматической послышной классификации многоярусной облачности на основе информации о текстуре спутниковых снимков MODIS с пространственным разрешением 250 м с применением технологии искусственных нейронных сетей и методов нечеткой логики. Приведена классификация облачности, основанная на действующем метеорологическом стандарте и Атласе облаков. Рассматриваются четыре метода статистического подхода к описанию текстуры изображений: Gray-Level Co-occurrence Matrix, Gray-Level Difference Vector, Sum And Difference Histogram и One-Dimensional Signal Histogram. Излагается методика подбора параметров гибридного классификатора, основанная на определении информативности текстурных признаков методом Add. Представлены результаты формирования системы эффективных классификационных характеристик и достигнутые при их использовании показатели классификации однослойной облачности и облаков вертикального развития. Определены наиболее часто повторяющиеся сочетания облаков каждого из трех ярусов, наблюдаемых одновременно над территорией Томска в период с 2008 по 2012 г. (двухслойная и трехслойная облачность). Обсуждаются результаты классификации многоярусной облачности на основе тестовой выборки и перспективы дальнейшего развития работы. Приведены примеры классификации изображений на полноразмерных спутниковых снимках MODIS территории Томской области.

Ключевые слова: информативность, классификация, нейронная сеть, нечеткая логика, облачность, спутниковый снимок, текстурные признаки, ярус

Введение

В настоящее время данные дистанционного зондирования Земли из космоса являются единственным источником получения информации о макросистемах облачности, поскольку сеть наземных и судовых метеостанций не позволяет охватить их в полном объеме. На основе тематических продуктов спутниковой съемки, например MOD06_L2, успешно восстанавливаются такие параметры облаков, как высота и температура их верхней границы, водность, фазовый состав, оптическая толщина, эффективный радиус частиц и другие (<http://modis.gsfc.nasa.gov>). Однако при решении различных задач климатологии и метеорологии необходимой является информация о типе облаков, формирующих глобальное поле облачности. Например, при прогнозировании погоды знание структуры макросистемы облаков помогает определить тип облачного фронта (теплый, холодный, окклюзия) (Облака..., 1989).

В настоящее время подобную информацию можно получить как на основе результатов наблюдений сети наземных и судовых метеостанций, расположенных по всему миру, так и путем использования методов автоматической классификации облачности на спутниковых снимках. При этом результаты классификации на метеостанциях зависят от опыта и знаний техника-метеоролога, поскольку решение о типе наблюдаемой облач-

ности принимается на основе его морфологического описания, приведенного в Атласе облаков (Беспалов и др., 2011). Методы автоматической классификации облачности по спутниковым снимкам (Bankert et al., 2009; Волкова, 2013; Астафуров, Скороходов, 2014) в настоящее время не обладают достаточной полнотой, поскольку позволяют разделять облака только по 10–14 разновидностям из 27 возможных, к которым относятся основные формы облачности (Росгидромет, 2013). На метеостанциях классифицируются облака сразу нескольких ярусов одновременно при наличии полупрозрачной облачности, разрывов между облаками и некоторых других условиях. Существенным недостатком методов автоматической классификации облачности по спутниковым данным является их низкая эффективность при наличии на снимках полупрозрачных облаков верхнего и среднего ярусов, искажающих текстуру изображения нижележащей облачности. В этом случае возникает неопределенность, к какой разновидности облаков отнести исследуемый фрагмент облачности.

При наличии таких неопределенностей (размытость природы искомой классификации) эффективным решением подобных задач является использование методов нечеткой логики (Вятчинин, 2004). Эти методы были успешно апробированы в (Baum et al., 1997) для обнаружения участков изображений на спутниковых снимках AVHRR, принадлежащих многоярусной облачности. При этом в известных нам работах вопрос послойной классификации многоярусной облачности не рассматривался. Целью данной работы является разработка метода автоматической послойной классификации многоярусной облачности на основе информации о текстуре спутниковых снимков MODIS с использованием технологии нейронных сетей и методов нечеткой логики.

Исходные данные

При решении задач автоматической классификации изображений начальным этапом является поиск характерных образцов для них и составление обучающей и тестовой выборки. В работе используются данные MODIS с пространственным разрешением 250 м для спектрального интервала 0,62–0,67 мкм, полученные в дневное время и при отсутствии снежного покрова, когда на метеостанциях фиксировалась только однослойная облачность или облака вертикального развития. Из всех систем космического базирования, позволяющих снимать макросистемы облачности, снимки MODIS обладают одним из лучших пространственных разрешений, благодаря чему получают более детализированные снимки облачного поля. Это, в свою очередь, позволяет выделять больше текстурных особенностей изображений и, как следствие, большее число разновидностей облаков. Путем сопоставления архивных данных наземных и судовых метеостанций (<http://cdiac.ornl.gov>) со спутниковой съемкой MODIS (<http://ladsweb.nascom.nasa.gov>) и применением экспертной оценки были найдены характерные изображения для 25 из 27 возможных разновидностей облаков. В *табл. 1* представлены названия исследуемых

в работе типов облачности в соответствии с ярусом и кодом метеорологической классификации. Из-за низкой повторяемости не были найдены образцы для высококучевых облаков, имеющих несколько слоев (Код 5 в среднем ярусе), и для высококучевой облачности при хаотическом виде неба (Код 9 в среднем ярусе) (Облака..., 1989). Четыре разновидности перисто-слоистых облаков в соответствии со стандартом не имеют названий и просто кодируются цифрами (Росгидромет, 2013).

Таблица 1. Используемая в работе классификация облаков

<i>Код</i>	<i>Нижний ярус</i>	<i>Код</i>	<i>Средний ярус</i>	<i>Код</i>	<i>Верхний ярус</i>
1	Кучевые плоские (<i>Cu hum</i>)	1	Высокослоистые (<i>As</i>)	1	Перистые когтевидные (<i>Ci unc</i>)
2	Кучевые средние и мощные (<i>Cu med/cong</i>)	2	Слоисто-дождевые (<i>Ns</i>)	2	Перистые хлопьевидные (<i>Ci floc</i>)
3	Кучево-дождевые лысые (<i>Cb calv</i>)	3	Высококучевые просвечивающие (один слой) (<i>Ac trans</i>)	3	Перистые, образовавшиеся из наковален кучево-дождевых (<i>Ci ing</i>)
4	Слоисто-кучевые кучевообразные (<i>Sc cuf</i>)	4	Высококучевые неоднородные и чечевицеобразные (<i>Ac inh/lent</i>)	4	Перистые перепутанные и хребтовидные (<i>Ci int/vert</i>)
5	Слоисто-кучевые волнистообразные (<i>Sc und</i>)	5	В работе не используется	5	Перисто-слоистые (распространяются по небу и уплотняются) (<i>Cs_5</i>)
6	Слоистые (<i>St</i>)	6	Высококучевые, образовавшиеся из кучевых и кучево-дождевых (<i>Ac cig/vir</i>)	6	Перисто-слоистые (высота сплошной пелены над горизонтом > 45°) (<i>Cs_6</i>)
7	Слоистые разорвано-дождевые (<i>St frnb</i>)	7	Высококучевые непросвечивающие (один слой) (<i>Ac op</i>)	7	Перисто-слоистые (10 баллов) (<i>Cs_7</i>)
8	Кучевые и слоисто-кучевые, наблюдаемые одновременно (<i>Cu & Sc</i>)	8	Высококучевые башенковидные и хлопьевидные (<i>Ac cast/floc</i>)	8	Перисто-слоистые (не распространяются по небу) (<i>Cs_8</i>)
9	Кучево-дождевые волосатые (<i>Cb cap</i>)	9	В работе не используется	9	Перисто-кучевые (<i>Cc</i>)

На основе характерных изображений были сформированы обучающая и тестовая выборки, состоящие из 200 и 50 фрагментов изображений размером 21×21 пиксель для каждой из 25 разновидностей облаков соответственно. Размер изображений был выбран с учетом результатов наших предыдущих исследований (Астафуров, Скороходов, 2011). В классификационную модель добавлены два обобщенных класса подстилающей поверхности, которые носят условные названия Dark (темные оттенки серого на снимках MODIS) и Grey (светлые оттенки серого на снимках MODIS). Для каждого класса подстилающей поверхности также выбрано по 200 обучающих и 50 тестовых образцов. Таким образом, число распознаваемых классов увеличилось до $L = 27$, объем обучающей выборки составил $V_L = 5400$, а тестовой $V_T = 1350$. Примеры эталонных изображений для различных разновидностей облаков показан на *рис. 1*.

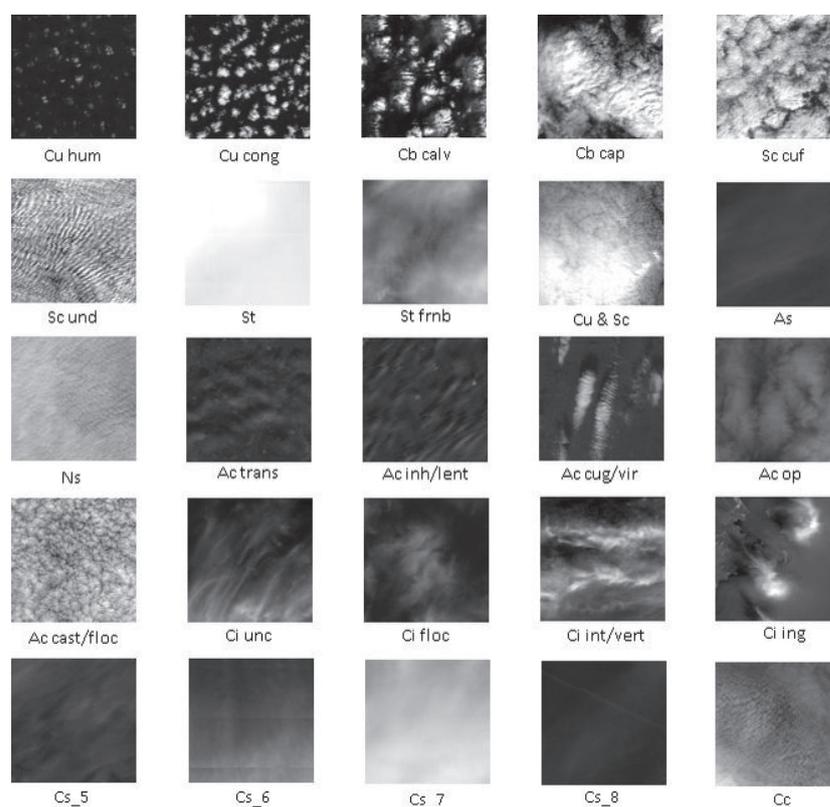


Рис. 1. Эталонные фрагменты изображений различных типов облачности

Классификационные характеристики

Выбор классификационных характеристик для различных разновидностей облачности основан на 4-х методах статистического подхода к описанию текстуры: Gray-Level Co-occurrence Matrix (GLCM) (Haralick et al., 1973), Gray-Level Difference Vector (GLDV) (Weszka, 1976), Sum And Difference Histogram (SADH) (Unser, 1986) и One-Dimensional Signal Histogram (ODSH) (Колодникова, 2004). Все эти методы базируются на вычислении статистических характеристик пространственной взаимозависимости значений яркости соседних пикселей изображения, называемых текстурными признаками. Основная суть метода GLCM заключается в формировании матриц пространственной смежности пар пикселей, удаленных друг от друга на расстояние d (уровень соседства), при различных угловых направлениях α . Согласно методу GLDV, строятся векторы абсолютных значений разностей яркости смежных пар пикселей. В основе метода SADH лежит построение гистограмм простых значений разностей и сумм яркости. Текстурные признаки по методу ODSH вычисляются по матрице яркости исходного изображения. При этом угловое направление в методе ODSH не учитывается. Подробное описание методов и рассчитываемых на их основе текстурных признаков приведено в (Haralick et al., 1973; Weszka et al., 1976; Unser, 1986; Колодникова, 2004). В нашей работе рассматривалось 132 различных текстурных признака для четырех методов и угловых направлений $\alpha = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ при $d = 1$, названия которых приведены в *табл. 2*.

Таблица 2. Текстурные признаки, используемые для описания изображений облачности

<i>GLCM</i>	<i>GLDV</i>	<i>SADH</i>	<i>ODSH</i>
Энтропия			
Второй угловой момент			Первый начальный момент
Локальная однородность			Энергия
Контраст			Вариация
Инверсия	Математическое ожидание		
Дисперсия	Стандартное отклонение		
Суммарное среднее	Кластерное затенение		
Суммарная дисперсия	Кластерная рельефность		
Суммарная энтропия		Корреляция	
Максимальная вероятность			
Дифференциальная дисперсия			
Дифференциальная энтропия			
Информационная мера корреляции – 1			
Информационная мера корреляции – 2			
Корреляция			

Очевидно, что текстурные признаки будут иметь различную информативность при описании разных типов облаков. Можно предположить, что признаки «контраст» и «дисперсия» будут малоэффективны для описания текстуры малоконтрастных изображений перистой, перисто-слоистой и слоистой облачности. Поэтому необходимо сформировать систему классификационных характеристик, которая бы позволила эффективно классифицировать различные типы облаков. Оптимальным можно считать набор текстурных признаков, полученный в результате проведения полного перебора всех существующих комбинаций этих признаков с оценкой качества классификации, например, тестовой выборки. Однако, учитывая большое число текстурных признаков, этот метод является самым трудоемким в вычислительном плане. Существуют методы, которые оперируют корреляционными (Астафуров, Скороходов, 2011), энтропийными (Bankert, 1994) и другими мерами информативности, позволяющие достаточно быстро сформировать систему классификационных характеристик, не прибегая непосредственно к процедуре классификации. Однако полученные наборы признаков информативны только относительно используемой меры, а не качества классификации. Еще одним подходом к определению эффективности признаков являются методы усеченного перебора, которые могут позволить сформировать систему классификационных характеристик, близкую к оптимальной при значительно меньшей продолжительности расчетов по сравнению с полным перебором. В работе использовался один из самых эффективных методов усеченного перебора Add (Загоруйко, 1999).

Основная идея этого метода заключается в последовательном переборе текстурных признаков с выбором наиболее информативного из них по результатам оценки вероятности правильной классификации тестовой выборки. Признак, увеличивающий качество классификации, добавляется в информативный набор и на последующих итерациях алгоритма Add не рассматривается. Процедура перебора заканчивается, если на очередном шаге не определен признак, улучшающий достоверность классификации тестовой выборки, либо когда в информативном наборе представлены все рассматриваемые классификационные

характеристики. Достоинством методики Add является возможность ее использования практически с любым алгоритмом классификации. Ее применение совместно с гибридным классификатором, описание которого представлено в следующем разделе, позволило сформировать систему из 8 информативных текстурных признаков: суммарная энтропия для углового направления – 0° , вычисляемая по методу GLCM, дифференциальная энтропия – 135° (GLCM), информационная мера корреляции – $1 - 90^\circ$ (GLCM), математическое ожидание – 45° (GLDV), второй угловой момент – 90° (GLDV), второй угловой момент – 135° (GLDV), кластерная рельефность – 45° (GLDV) и математическое ожидание – 0° (SADH). При этом вероятность правильной классификации тестовой выборки составила около 0,7.

Алгоритм классификации

В работе использовался гибридный классификатор, основанный на совместном применении технологии искусственных нейронных сетей и методов нечеткой логики. Его архитектура показана на *рис. 2*. Модель нечеткого вывода может быть представлена в виде упорядоченного набора модулей в виде нейронов-термов с единичными синаптическими коэффициентами. Подобные классификаторы принято называть нечеткими нейронными сетями или гибридными классификаторами (Круглов и др., 2001; Осовский, 2002). На вход сети, показанной на *рис. 2*, предъявляется вектор значений информативных текстурных признаков $\mathbf{X} = (x_1, x_2, \dots, x_N)$ исследуемого фрагмента изображения облачности (N – число информативных текстурных признаков). Первый слой состоит из наборов нейронов-термов, выполняющих приведение к нечеткости (фазсификации) значений текстурных признаков. В качестве функций фазсификации используется стандартная функция Гаусса:

$$\mu_i(x_j) = e^{-\left(\frac{x_j - c_j^{(i)}}{\sigma_j^{(i)}}\right)^2},$$

при которой нечеткая система является универсальным аппроксиматором (Круглов и др., 2001). Второй слой включает в себя 27 нейронов-антецедентов, реализующих треугольную норму и моделирующих логическую операцию «И». При этом число нейронов определяется числом распознаваемых классов. Третий слой состоит из трех нейронов-консеквентов (постусловий), реализующих произвольную треугольную конорму, моделирующую логическую операцию «ИЛИ». В этом слое происходит интерпретация результатов классификации многоярусной облачности. Каждый из трех нейронов 3-го слоя соответствует одному из ярусов облачности. Таким образом, в нейроне S_{Low} аккумулируется сигнал, приходящий от нейронов предыдущего слоя, отвечающих за облака только нижнего яруса и подстилающей поверхности, в S_{Mid} – среднего яруса и S_{Hi} – верхнего яруса. Выходом сети является трехкомпонентный вектор, состоящий из кодов разновидностей облаков в каждом ярусе. Например, выход сети $\mathbf{y} = (1, 9, 0)$ свидетельствует о том, что исследуемый фрагмент снимка MODIS с определенной степенью принадлежности (в данной работе использовалось значе-

ние 0,9) относится как к перистым когтевидным облакам, так и к кучево-дождевым волосатым. Иными словами, текстура исследуемого фрагмента изображения имеет сходство с текстурой как подтипа перистой облачности, так и разновидности кучево-дождевых облаков. Таким образом, алгоритм классификации позволяет относить один и тот же фрагмент снимка облачности к нескольким разновидностям облаков одновременно на основе сходства их текстур. Следует отметить, что алгоритмом не производится определение числа ярусов облачности по наличию разрывов между облаками или другим факторам, позволяющим определить их многослойность. Алгоритм позволяет решать только задачу классификации облачности по спутниковым снимкам в условиях неопределенностей, когда на изображении наблюдается смесь текстур различных типов облаков, образующаяся в результате «наложения» полупрозрачной облачности на облака нижележащих ярусов.

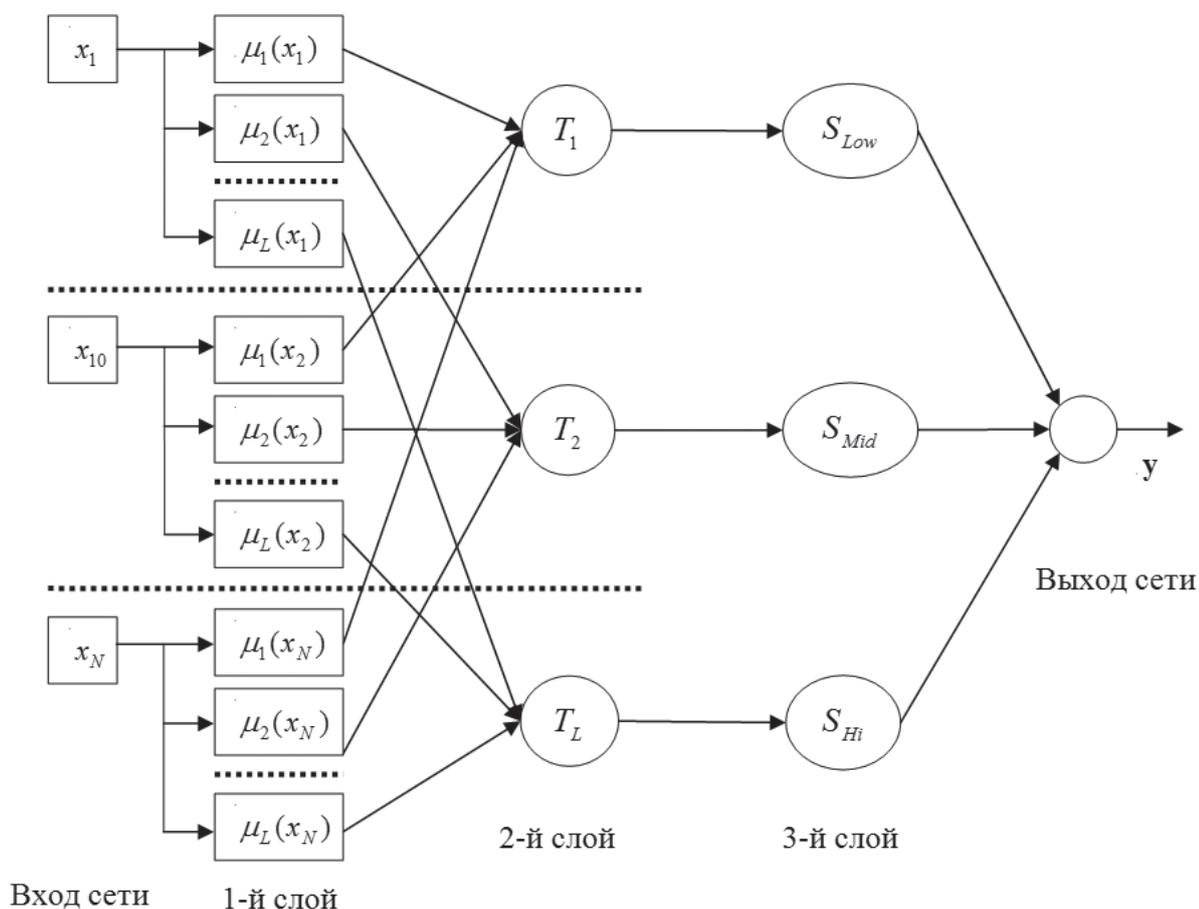


Рис. 2. Архитектура гибридного классификатора

Нейронные сети такого типа обучаются «с учителем». В работе для обучения гибридного классификатора использовался алгоритм обратного распространения ошибки (Осовский, 2002). В процессе настройки сети происходит коррекция параметров функции принадлежности $\mu_i(x_j)$ таким образом, чтобы при предъявлении схожих по текстуре образцов классификатор относил бы их к одному из 27 рассматриваемых классов.

Результаты классификации

Для оценки достоверности результатов послышной классификации многоярусной облачности сформирована тестовая выборка изображений по данным MODIS и результатам наблюдений на метеостанции города Томска за период с 2008 по 2013 гг. При этом были отобраны только те снимки, на которых метеостанциями фиксировалось наличие облаков в двух или трех ярусах одновременно. Тестовая выборка состоит из 152 фрагментов спутниковых снимков многоярусной облачности размером 250×250 пикселей, центр которых соответствует местоположению метеостанции. При этом размер тестовых образцов обусловлен возможностью оценить мезосистему облачности вокруг метеостанции в целом, а не только в районе метеостанции. На *рис. 3* показано распределение тестовой выборки по различным сочетаниям облаков по ярусам, представленным в закодированном виде в соответствии с *табл. 1*. Первая цифра кода обозначает тип наблюдаемой облачности верхнего яруса, вторая – нижнего яруса и третья – среднего яруса.

Из *рис. 3* видно, что в наиболее часто встречающихся сочетаниях облачности присутствуют перистые когтевидные облака, что связано с их высокой повторяемостью по всему миру, в том числе и над территорией Западной Сибири (Облака..., 1989). При этом больше всего образцов было найдено для следующих сочетаний облачности: перистых с кучевыми плоскими (36 фрагментов), перистых с кучевыми средними и мощными (27) и перистых с кучево-дождевыми волосатыми (15). Это связано с легкостью их фиксации на метеостанциях из-за наличия разрывов в облаках нижнего яруса.

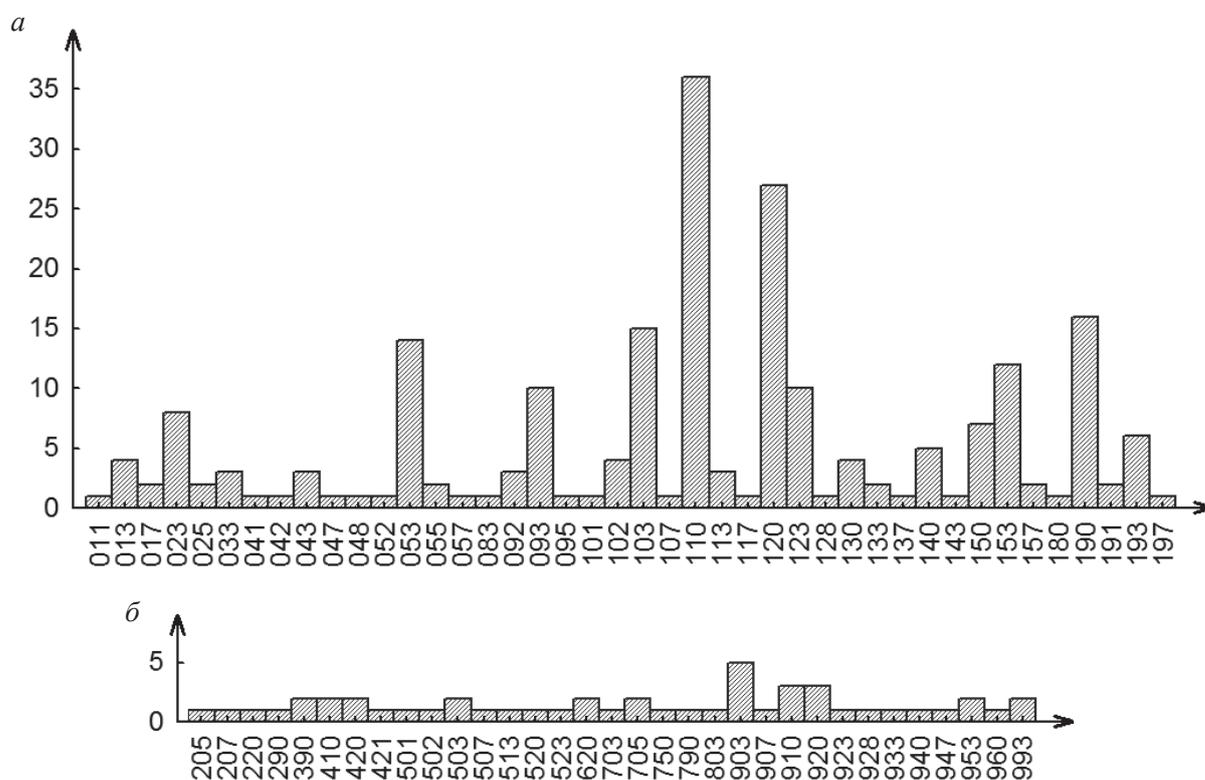


Рис. 3. Распределение тестовых образцов по сочетаниям типов облачности для кодов КН-01 SYNOP 011-197 (а) и 205-993 (б)

Установлено, что для Томской области повторяемость сочетаний облаков, в которых встречаются другие разновидности облачности верхнего яруса, крайне низкая (рис. 3б). По результатам применения разработанного гибридного классификатора определено, что вероятность правильной классификации тестовой выборки составила 0,83. При этом правильно проклассифицированным считался тестовый образец, для которого «мнение классификатора» о типе наблюдаемой облачности в каждом ярусе совпало с данными метеостанции.

На рис. 4а показан фрагмент снимка территории Томской области от 03.05.2008 (UTC 05:50) размером 305×243 км. Цифровыми метками на снимке обозначены местоположения метеостанций региона: 1 – Колпашево, 2 – Бакчар, 3 – Первомайское и 4 – Томск. В момент спутниковой съемки на метеостанциях была зафиксирована облачность следующих разновидностей: Cb calv – в Колпашево, Sc und – в Бакчаре, Cu med/cong и Ac trans – в Первомайском и Sc cuf – в Томске. Как видно из результатов послойной классификации облачности, показанной на рис. 3б, 3в и 3г, «мнение классификатора» совпало с метеоданными, за исключением района Бакчара, для которого наша визуальная оценка подтверждает правильность классификации о наличии в этом районе двухъярусной облачности из-за заметной на снимке пелены облаков среднего или верхнего ярусов.

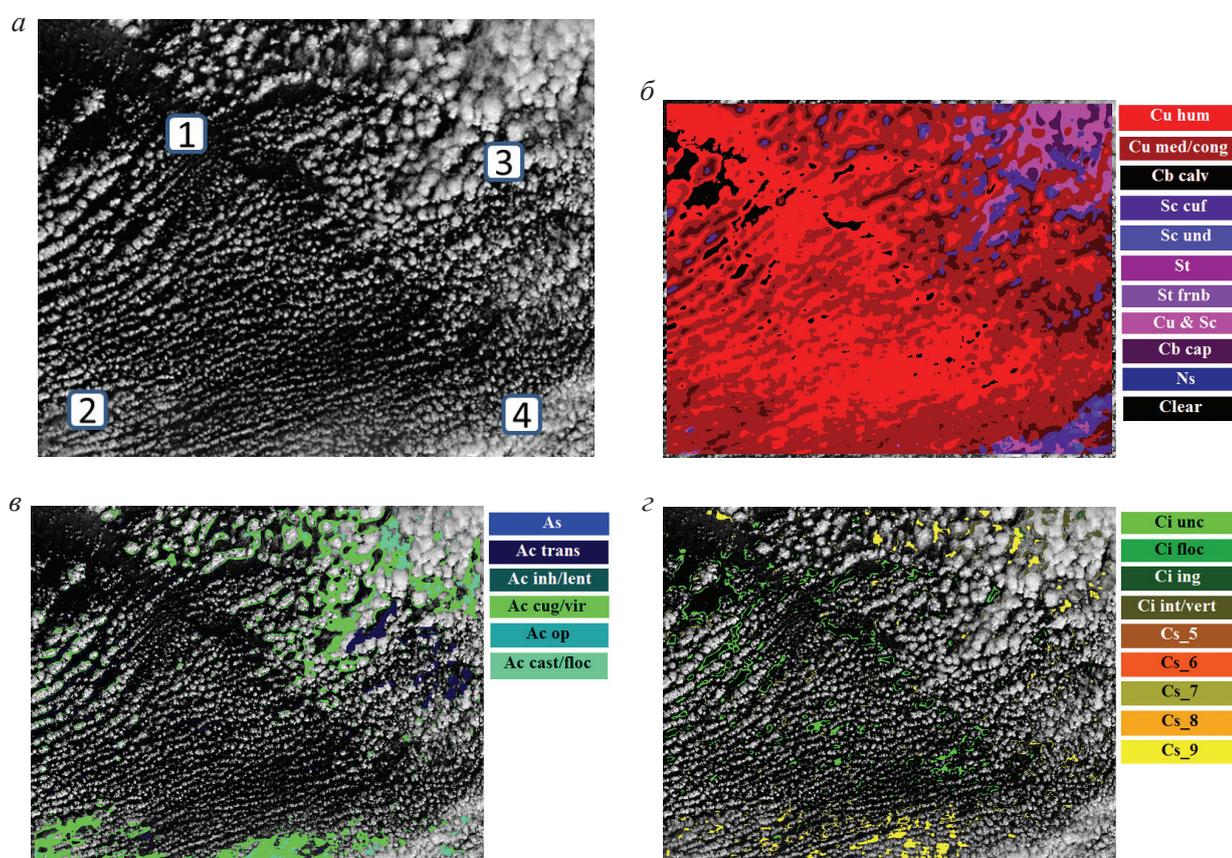


Рис. 4. Результат классификации облаков вертикального развития и нижнего яруса (а), среднего яруса (в) и верхнего яруса (z) по фрагменту снимка территории Томской области от 03.05.2008 (UTC 05:50)

Заключение

Основным результатом работы является предложенный алгоритм послышной классификации многоярусной облачности на спутниковых снимках MODIS, позволяющий выделять 25 разновидностей облаков с усредненной вероятностью правильной классификации тестовой выборки 0,83. Применение методики Add позволило сформировать систему из 8 информативных текстурных признаков для классификации многоярусной облачности (табл. 2). Определены наиболее повторяющиеся сочетания разновидностей облаков над территорией Томской области (рис. 3).

Перспективным направлением развития исследований может быть совместное использование результатов послышной классификации облачности с тематическими продуктами MODIS (MOD06_L2) для уточнения сезонно-широтных особенностей различных разновидностей облаков и их сочетаний.

Работа выполнена при частичной финансовой поддержке РФФИ в рамках научного проекта № 14-07-31018 мол_а.

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., Скороходов А.В. Применение нейросетевых технологий для классификации облачности по текстуре снимков MODIS высокого разрешения // Исследование Земли из космоса. 2014. № 5. С. 39–49.
3. Беспалов Д.П., Девяткин А.М., Довгальюк 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.
4. Вятчин Д.А. Нечеткие методы автоматической классификации. Мн.: УП «Технопринт», 2004. 219 с.
5. Волкова Е.В. Оценка 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.
6. Федеральная служба по гидрометеорологии и мониторингу окружающей среды (Росгидромет). Код для оперативной передачи данных приземных метеорологических наблюдений с сети станций Росгидромета. М.: «Триада. лтд», 2013. 79 с.
7. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. Новосибирск: ИМ СО РАН, 1999. 270 с.
8. Колодников Н.В. Обзор текстурных признаков для задач распознавания образов // Доклады Томского государственного университета систем управления и радиоэлектроники. 2004. Т. 9. № 1. С. 113–124.
9. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2001. 224 с.
10. Облака и облачная атмосфера. Справочник / Под ред. Мазина И.П., Хргиана А.Х. Л.: Гидрометеиздат, 1989. 647 с.
11. Осовский С. Нейронные сети для обработки информации / Пер. с польск. Рудинского И.Д. М.: Финансы и статистика, 2002. 344 с.
12. Bankert R.L., Rabindra P., Sengupta S.K. A probabilistic neural network approach to cloud classification // Miss: Tech. Note of the Naval Oceanographic and Atmospheric Research Laboratory 39529–5004, 1994. 35 p.
13. Bankert R.L., Mitrescu C., Miller S.W., Wade R.H. Comparison of GOES cloud classification algorithms employing explicit and implicit physics // J. Appl. Meteor. Climatol. 2009. V. 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. Appl. Meteor. 1997. V. 36. P. 1519–1540.
15. Haralick R.M., Shanmugam K., Dinstein I. Textural features for image classification // IEEE Transactions on Systems, Man and Cybernetics. 1973. V. SMC–3. No. 6. P. 610–621.
16. Weszka J.S., Dyer C.R., Rosenfeld A. A comparative study of texture measures for terrain classification // IEEE Transaction on Systems, Man and Cybernetics. V. SMC–6. No. 4. P. 269–285.
17. Unser M. Sum and difference histograms for texture classification // IEEE Transaction on Systems, Pattern Analysis and Machine Intelligence. V. PAMI–8/ No. 1. P. 118–125.

Multi-layer cloud classification from MODIS data using neural network technology and fuzzy logic approach

V.G. Astafurov^{1,2}, A.V. Skorokhodov¹

¹ V.E. Zuev Institute of Atmospheric Optics SB RAS, Tomsk, 634055, Russia
E-mail: vazime@yandex.ru

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

This paper proposes an automatic layered classification method for multi-layer cloudiness. This method is based on using textural information of MODIS satellite data with a spatial resolution of 250 m and application of artificial neural network technology and fuzzy logic approach. Cloud classification is presented which is based on current meteorological standard and Cloud Atlas. Four methods of statistical approach to texture image description are considered: Gray-Level Co-occurrence Matrix, Gray-Level Difference Vector, Sum and Difference Histogram and One-Dimensional Signal Histogram. We describe the technique for adjusting parameters of a hybrid classifier based on definition of information content of textural features by the Add method. We present results of formation of effective classification features and classification rating achieved in classifying single-layer cloudiness and vertical development clouds. The most frequently occurring combinations were identified of either of the three cloud layers observed simultaneously over Tomsk territory in the period from 2008 to 2012 (two- and three-layer cloudiness). The multi-layer cloud classification results based on test samples and prospects for further work are discussed. Image classification examples based on full-size MODIS satellite imagery of Tomsk region are demonstrated.

Keywords: information value, classification, neural networks, fuzzy logic, cloudiness, satellite image, textural features, layer

References

1. Astafurov V.G., Skorokhodov A.V., Segmentatsiya sputnikovykh snimkov oblachnosti po teksturnym priznakam na osnove neirosetevykh tekhnologii (Segmentation of cloudiness satellite images by textural parameters based on neural network technologies), *Issledovanie Zemli iz kosmosa*, 2011, No. 6, pp. 10–20.
2. Astafurov V.G., Skorokhodov A.V. Primenenie nejrosetevykh tekhnologiy dlja klassifikatsii oblachnosti po teksture snimkov MODIS vysokogo razresheniya (The application of neural network technology for the classification of clouds high-resolution MODIS texture images), *Issledovanie Zemli iz kosmosa*, 2014, No. 5, pp. 39–49.
3. 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.
4. Vyatchenin D.A., *Nechetkie metody avtomaticheskoi klassifikatsii* (Fuzzy methods of automatic classification), Minsk: UP "Tekhnoprint", 2004, 219 p.
5. Volkova E.V. Ocenki parametrov oblachnogo pokrova, osadkov i opasnykh javlenij pogody po dannym radiometra AVHRR s MISZ serii NOAA kruglosutochno v avtomaticheskom rezhime (Automatic estimation of cloud cover and precipitation parameters obtained by AVHRR NOAA for day and night conditions), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2013, Vol. 10, No. 3, pp. 66–74.
6. Federal'naya sluzhba po gidrometeorologii i monitoringu okruzhayushchei sredy (Rosgidromet), *Kod dlya operativnoi peredachi dannykh prizemnykh meteorologicheskikh nablyudenii s seti stantsii Rosgidrometa* (Code for rapid data transfer of surface meteorological observations from a network of Hydromet stations), Moscow: "Triada. Ltd", 2013, 79 p.
7. Zagoruiko N.G., *Prikladnye metody analiza dannykh i znanii* (Applied methods of data analysis and knowledge), Novosibirsk: IM SO RAN, 1999, 270 p.
8. Kolodnikova N.V., Obzor teksturnykh priznakov dlya zadach raspoznavaniya obrazov (Overview of textural features for pattern recognition problems), *Doklady Tomskogo gosudarstvennogo universiteta sistem upravleniya i radioelektroniki*, 2004, Vol. 9, No. 1, pp. 113–124.
9. Kruglov V.V., Dli M.I., Golunov R.Yu., *Nechetkaya logika i iskusstvennyye neironnyye seti* (Fuzzy logic and artificial neural networks), Moscow: Fizmatlit, 2001, 224 p.
10. *Oblaka i oblachnaya atmosfera. Spravochnik* (Clouds and cloudy atmosphere. Directory), Leningrad: Gidrometeoizdat, 1989, 647 p.
11. Osovskii S., *Neironnyye seti dlya obrabotki informatsii* (Neural network for processing information), Moscow: Finansy i statistika, 2002, 344 p.
12. Bankert R.L., Cloud classification of AVHRR imagery in maritime regions using a probabilistic neural network, *Journal of Applied Meteorology*, 1994, Vol. 33, No. 8, pp. 909–918.
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, *J. Appl. Meteor.*, 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. Weszka J.S., Dyer C.R., Rosenfeld A., A comparative study of texture measures for terrain classification, *IEEE Transaction on Systems, Man and Cybernetics*, 1976, Vol. SMC – 6, No. 4, pp. 269–285.
17. Unser M, Sum and difference histograms for texture classification, *IEEE Transaction on Systems, Pattern Analysis and Machine Intelligence*, 1986, Vol. PAMI – 8, No. 1, pp. 118–125.