

## Классификация облаков по спутниковым снимкам на основе технологии нейронных сетей

В.Г. Астафуров<sup>1,2</sup>, А.В. Скороходов<sup>1</sup>

*<sup>1</sup>Институт оптики атмосферы им. В.Е. Зуева СО РАН  
634021, Томск, площадь Академика Зуева, 1  
E-mail: astafurov@iao.ru, vazime@yandex.ru;*

*<sup>2</sup>Томский государственный университет систем управления и радиоэлектроники  
634050, Томск, проспект Ленина, 40*

Для сегментации облачных полей на спутниковых снимках и классификации облаков по типам предлагается использовать алгоритмы на основе нейронных сетей. Для описания облаков используется информация об их характерной текстуре изображения. Обсуждается проблема выбора архитектуры нейронной сети и ее влияние на качество обработки изображения. Представлены результаты классификации облаков на спутниковых снимках, полученных по данным спектрорадиометра MODIS. Полученные результаты иллюстрируют эффективность предложенного подхода.

**Ключевые слова:** типы облаков, текстурные признаки, классификация, сегментация, нейронная сеть.

### Введение

Процедура классификации облаков по типам на основе данных дистанционного зондирования Земли из космоса используется для решения таких актуальных задач, как прогнозирование погоды и моделирование климата. Процесс сегментации спутниковых снимков позволяет выполнить предварительный анализ данных, в ходе которого можно определить участки облачности со сходными характеристиками (спектральные признаки, текстура, цвет). По результатам сегментации изображения можно оценить эффективность выбранной системы признаков для её последующего применения при классификации облачности по типам.

Использование спектральных характеристик позволяет определить некоторые физические параметры облачности (температура верхней границы, альбедо), индекс NDSI, который применяется для разделения облаков, снега, льда и тумана. Однако спектральные признаки не позволяют идентифицировать типы облаков согласно принятому в метеорологии стандарту (Хргиан, 1989). Так, в работе (Тишкин, 2007) облачность определяется как «легкая облачность» или «плотная облачность», а в (Bankert et al., 2009) выполнена классификация некоторых основных типов облачности по спектральным характеристикам.

На спутниковых снимках различные типы облаков отличаются по своей текстуре, под которой будем понимать некоторым образом организованный локальный участок изображения облачности, обладающий свойством однородности видеоданных. Поэтому одним из возможных вариантов получения более качественных результатов классификации облаков является использование наборов их текстурных признаков (ТП) и многослойной нейронной сети (НС) в качестве классификатора. НС способна извлекать ключевые характеристики объектов из всего набора используемых признаков. Это свойство является необходимым при дифференцировании схожих текстур различных типов облаков. Другие классификаторы такой способностью не обладают, поэтому используются различные методы определения информативности отдельных признаков или их наборов, например, как в работе (Мицель и др., 2005).

## Система текстурных признаков

Для измерения и описания текстуры можно использовать различные подходы:

- измерение пространственных частот (Прэтт, 1982);
- вычисление статистических характеристик (Потапов, 2005; Харалик, 1979);
- описание структурных элементов (Андреев, 1984).

В (Weszka et al., 1976) показано, что признаки, связанные с пространственными частотами, оценивают текстуру хуже, чем её статистические характеристики. Статистический подход основан на вычислении матриц смежности  $\mathbf{P}$  (Харалик, 1979), которые характеризует пространственное распределение и взаимосвязь значений яркости локальной области изображения. Элементы матрицы  $P_{ij}$  рассчитываются по фрагменту изображения, выделенному скользящим окном с размерами  $n_x, n_y$  пикселей по вертикали и горизонтали, соответственно. Вычисление матриц смежности и ТП подробно рассмотрено в работах (Харалик, 1979; Прэтт, 1982). Эти матрицы зависят от определяемого парой соседних пикселей углового направления и от расстояния между ними. В статье (Харалик, 1979) предлагается вычислять матрицы смежности для угловых направлений  $0^\circ, 45^\circ, 90^\circ$  и  $135^\circ$ , что позволяет учитывать различные ориентации текстуры.

В ходе проведенных исследований по определению информативности ТП с помощью разработанной нами методики (Астафуров, Скороходов, 2010) и с учетом рекомендаций, приведенных в работе (Ersahin et al., 2004) был сформирован набор из семи ТП. Он включает в себя энергию, энтропию, однородность, контраст, максимальную вероятность, вычисляемые по матрице смежности для четырех угловых направлений (всего двадцать признаков), а также первый начальный момент и вариацию, рассчитываемые по матрице квантованных значений яркости пикселей в скользящем окне. Таким образом фактически используется 22 ТП.




Рис. 1. Архитектура самоорганизующейся нейронной сети Кохонена

### Алгоритмы сегментации спутниковых снимков и классификации облачности по типам на основе нейронных сетей

Для сегментации спутниковых изображений выбрана однослойная НС Кохонена с алгоритмом обучения SWTA (победитель получает всё с механизмом утомления) как наиболее

лее эффективным, обеспечивающим минимум ошибок квантования (Каллан, 2001; Осковский, 2002; Хайкин, 2008). На рис. 1 показана архитектура сети. На ее вход подаются признаки, используемые для сегментации спутникового изображения. Входной нормированный вектор признаков  $\mathbf{x} = \mathbf{X}/\|\mathbf{X}\|$ , где  $\mathbf{X} = (T_1, T_2, \dots, T_{22})^T$  – вектор ТП. Число нейронов равно  $p$ . Отклик  $u_j$  нейрона  $j$  определяется выражением

$$u_j = \sum_{i=1}^{22} w_{ji} x_i, \quad (1)$$

где

$$\mathbf{W}_j = (w_{j1}, w_{j2}, \dots, w_{j22})^T$$

– вектор синаптических весов нейрона  $j$ . По результатам сравнения откликов всех нейронов победителем признается тот нейрон, значение  $u_j/N_j(l)$  у которого будет наибольшим. Здесь  $u_j/N_j(l)$  – число побед нейрона  $j$  на шаге  $l$ . Нейрон-победитель вырабатывает на своем выходе состояние 1, а остальные (проигравшие) нейроны переходят в состояние 0. Такой подход реализует ступенчатую функцию активации нейронов. В процессе обучения для активированного нейрона-победителя происходит уточнение вектора весовых коэффициентов  $\mathbf{W}_j$  на шаге  $l$  по правилу Гроссберга

$$\mathbf{W}_j(l+1) = \mathbf{W}_j(l) + \eta(l)(\mathbf{x} - \mathbf{W}_j(l)),$$

где  $\eta(l)$  – параметр скорости обучения сети, который определяет точность и производительность процесса самоорганизации (Хайкин, 2008).

В процессе обучения НС и при сегментации изображения скользящее окно движется вправо, начиная с левого верхнего угла изображения, смещаясь каждый раз на один пиксель. После достижения правого края изображения осуществляется возврат окна к левой границе изображения со сдвигом вниз на один пиксель и т.д. В процессе обучения на первом этапе сканируется все изображение, а при повторном сканировании обучение прекращается, когда для всех нейронов выполняются условия

$$\sqrt{\sum_{i=1}^{22} (w_{ji}(l) - w_{ji}(l-1))^2} \ll 1, \quad j = \overline{1, p}.$$

Процедура сегментации настроенной НС подобна процессу обучения. Разница заключается в том, что после определения нейрона-победителя происходит не уточнение его весовых коэффициентов, а перекрашивание центрального пикселя скользящего окна в цвет сегмента, который представляет нейрон-победитель.

Для классификации облачности предлагается использовать многослойную НС обратного распространения. Задача разделения облаков по типам на основе информации о текстуре включает предварительное обучение НС по эталонным наборам ТП для характерных изображений различных типов облаков на спутниковых снимках. При этом для каждого типа облака необходимо подобрать несколько эталонных изображений, число которых зависит от ряда факторов (оригинальности текстуры типа облачности, сходства с другими типами облаков и т.д.). В выходном слое число нейронов равно числу определяемых типов облаков. Число скрытых слоев и количество нейронов в каждом слое зависит от решаемой за-

дачи и подбирается эмпирически. Сложность областей в пространстве решений, которые могут быть реализованы с помощью трехслойной НС (два скрытых слоя и выходной слой), в принципе является неограниченной (Гонсалес, Вудс, 2005). Именно такая сеть рассматривается нами. Максимальное количество нейронов в каждом скрытом слое согласно следствию из теоремы Колмогорова-Арнольда равно  $2Q+1$ , где  $Q$  – размерность входного вектора признаков. При этом результаты классификации не всегда будут лучшими, если число нейронов в скрытых слоях будет максимальным. Конкретная топология сети определяется качеством получаемых результатов классификации.

На рис. 2 показана архитектура используемой НС. Сеть состоит из двух скрытых и одного выходного слоя. Число нейронов в первом скрытом слое равно  $J$ , а во втором скрытом слое –  $S$ . Число нейронов выходного слоя равно  $M$  и определяется числом классифицируемых ти-

пов облаков. На вход НС подается вектор признаков  $\mathbf{x}^1 = (\hat{T}_1, \hat{T}_2, \dots, \hat{T}_{22})^T$ , где  $\hat{T}_1, \hat{T}_2, \dots, \hat{T}_{22}$  – масштабированные значения ТП,

$$\hat{T}_i = \frac{T_i - T_i^{\min}}{T_i^{\max} - T_i^{\min}}, \quad i = 1, \dots, 22. \quad (2)$$

Здесь  $T$  – текущее значение ТП,  $T_i^{\min}$ ,  $T_i^{\max}$  – его минимальное и максимальное значения, вычисленные для исходного изображения. Необходимость процедуры масштабирования связана с тем, что диапазоны изменения различных ТП существенно отличаются друг от друга. Масштабирование ТП позволяет устранить доминирующее влияние отдельных ТП в процессе обучения сети.

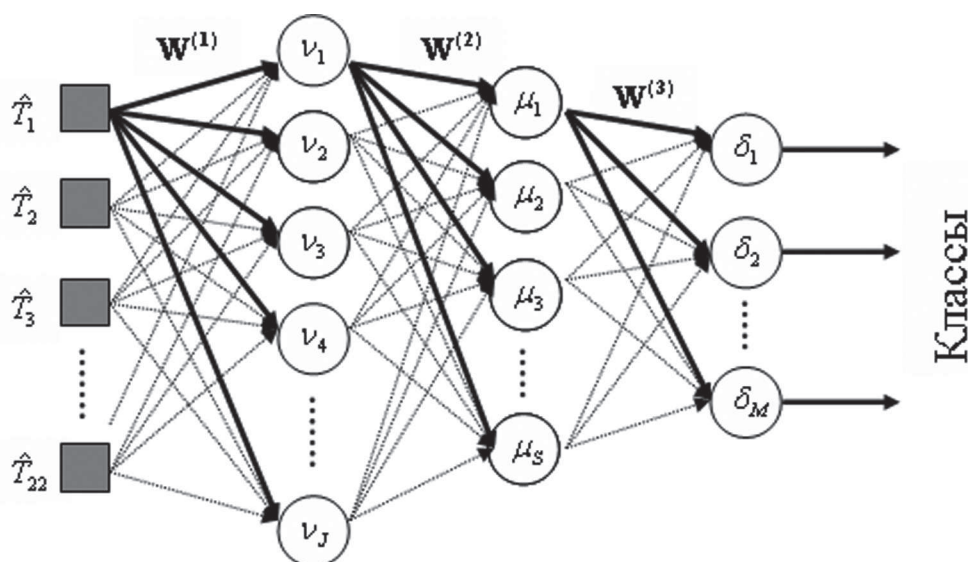


Рис. 2. Архитектура нейронной сети

Для обучения НС использовался модифицированный алгоритм обратного распространения ошибки (Каллан, 2001; Осовский, 2002; Хайкин, 2008). При этом применялась процедура стохастического обучения НС, когда обучающие образцы предъявляются на вход сети в случайном порядке. Также использовалось динамическое изменение параметра  $\eta(l)$  на

каждом шаге (Хайкин, 2008), что позволило существенно увеличить скорость процесса обучения НС. Активационная функция определяет выходной сигнал нейронов и имеет вид

$$f(y) = \tanh(\beta y),$$

где  $y$  – суммарный выходной сигнал нейрона ( $y = v_j$  для нейронов первого скрытого слоя,  $y = \mu_s$  – нейронов второго скрытого слоя,  $y = \delta_m$  – для нейронов выходного слоя),  $\beta$  – параметр, определяемый в процессе настройки сети. Значения  $v_j$ ,  $\mu_s$  и  $\delta_m$ , и вычисляются по формулам, аналогичным (1),  $W^{(i)}$  – матрица весовых коэффициентов  $i$ -го слоя.

Обучение сети выполняется по эпохам. В течение одной эпохи на вход сети в случайном порядке предъявляются вектора признаков для всех имеющихся образцов заданных классов. После предъявления каждого образца происходит подстройка весовых коэффициентов для всех слоев по формуле

$$W^{(i)}(l+1) = W^{(i)}(l) + \eta(l)\Delta W^{(i)}(l), \quad i = 1, 2, 3,$$

где  $\Delta W^{(i)}(l)$  – величина коррекции весовых коэффициентов или направление градиентного спуска в многомерном пространстве  $W^{(i)}$ .

Обучение будет считаться завершенным, если в пределах одной эпохи для всех образцов будет выполняться следующее условие: если образец относится к  $i$ -му классу, то на соответствующем ему выходе НС значение  $\delta_i \in (0,9; 1)$ , в противном случае  $\delta_j \in (0,0; 0,1)$ .

### Результаты обработки изображений и их обсуждение

В качестве исходных данных использовались снимки спектрорадиометра MODIS с пространственным разрешением 1000 метров, синтезированные с помощью программы ENVI по 1, 3 и 4-му спектральным каналам. Данные каналы используются для исследования контуров облаков и земных объектов, а также их свойств. На рис. 3а показано исходное изображение размером 610×816 км облачных образований над поверхностью океана в районе побережья Аргентины. На основании архивных данных метеостанции аэродрома Долорес (<http://meteo.infospace.ru>), которая отмечена на рис. 3а символом  $\Delta$ , в данном регионе в момент съемки находилась облачность двух ярусов: нижний ярус – кучевые облака, средний ярус – высокослоистые облака. Исходя из этого, при классификации изображения рассматривалось три класса: облачность первого типа (кучевые облака нижнего яруса), облачность второго типа (слоистые облака среднего яруса) и поверхность океана. Визуальная оценка снимка не позволяет увидеть различий в текстуре различных типов облаков. На рис. 3б представлены результаты сегментации облачного поля. На рис. 3г приведен результат классификации изображения трехслойной НС, для которой число нейронов первого скрытого слоя  $J=22$ , число нейронов второго скрытого слоя  $S=11$  и выходного слоя  $M=3$ . На рис. 3в представлен результат классификации двухслойной НС, для которой  $J=22$ ,  $M=3$ . Для обучения НС использовалось по 20 образцов для каждого класса облаков, которые выделены на рис. 3а различными символами в форме квадрата. Образцы различных типов облачности выбирались вручную оператором интуитивно на основе результатов сегментации изображения. На рис. 3в и 3г для обозначения одного и того же типа облаков используются одинаковые оттенки серого тона.



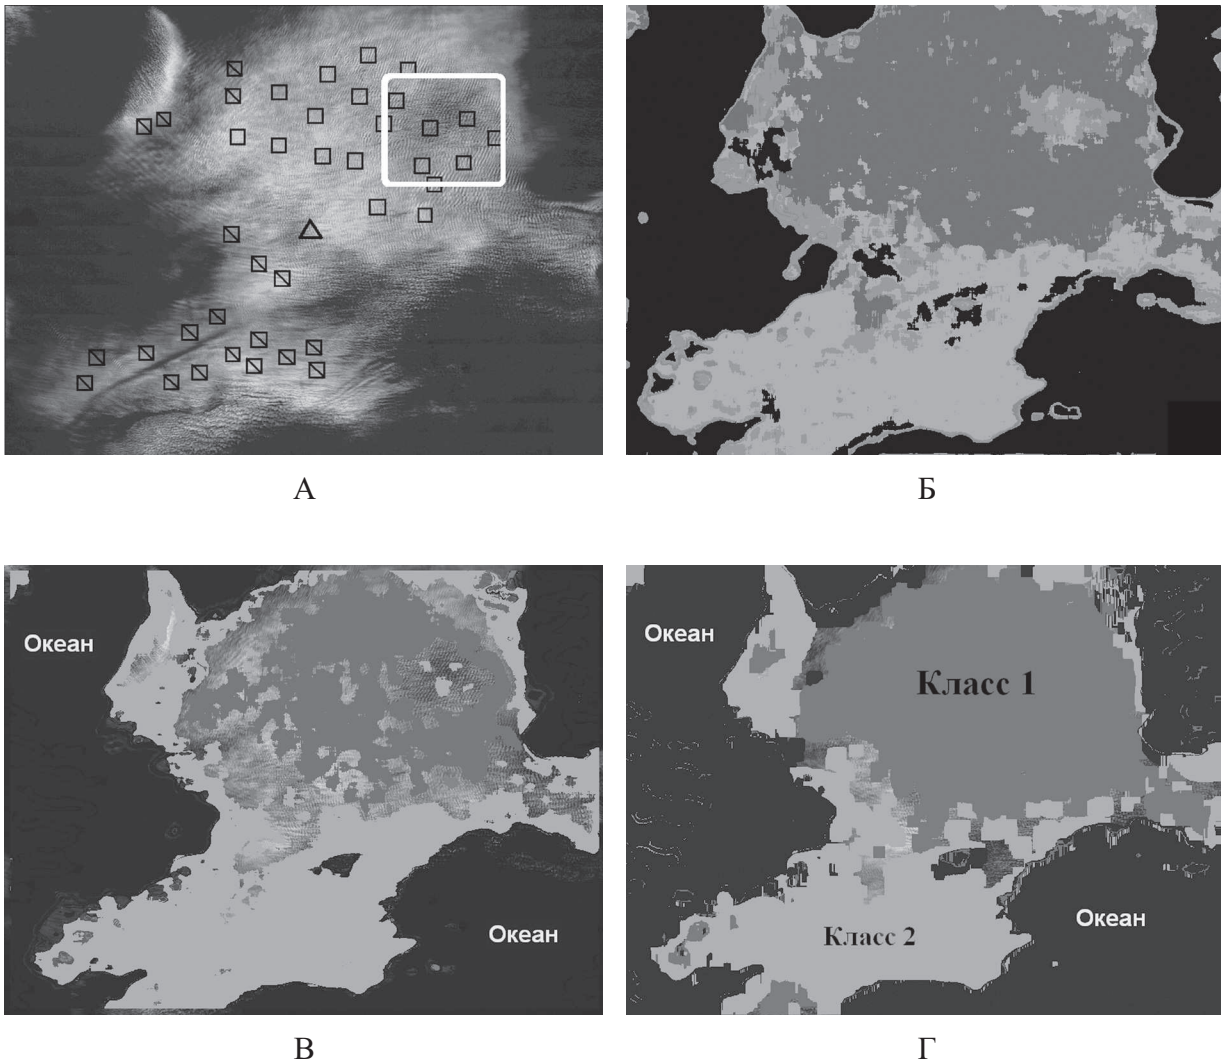


Рис. 3. Исходное изображение (а); результат сегментации самоорганизующейся нейронной сетью (б); результат классификации облаков двухслойной нейронной сетью (в); результат классификации облаков трехслойной нейронной сетью (г)

Анализируя результат сегментации на рис. 3б, можно заметить, что края сегментов не всегда совпадают с реальными границами облачных образований. Такие ошибки объясняются однослойной топологией НС Кохонена и автоматическим процессом обучения. С помощью сегментации выполнен предварительный анализ изображения, результаты которого использовались для формирования обучающих выборок многослойной НС.

Из сравнения результатов классификации на рис. 3в и 3г видно, что добавление второго скрытого слоя (рис. 3г) привело к увеличению обобщающей способности НС. Это позволило выполнить классификацию визуально схожих по текстуре участков облачного поля. На рис. 3а в правом верхнем углу выделен участок изображения белой рамкой, в пределах которого сквозь облака просвечивается водная поверхность океана. Трехслойная НС позволила проклассифицировать этот участок снимка как облачность, принадлежащая к первому классу (рис. 3г), в то время как на рис.3в этот участок изображения не классифицирован. Трехслойная НС позволила также выделить и проклассифицировать небольшие облачные образования на фоне океана, находящиеся вдали от крупных облачных масс (рис. 3г). Следует также отметить, что области изображения на рис. 3г, относящиеся к одному классу облаков, более однородны по сравнению с соответствующими областями на рис. 3в.

## Заключение

Полученные результаты применения технологии искусственных НС и информации о текстуре для сегментации спутниковых снимков и классификации облачности по типам свидетельствуют об эффективности предложенного подхода. Целью дальнейших исследований является формирование базы эталонных значений ТП для различных типов облачности согласно принятым в метеорологии стандартам. Такую задачу можно решить путем сопоставления данных спектрорадиометра MODIS и наземных метеостанций. Полученный таким образом набор эталонных текстур можно использовать на стадии обучения НС, предназначенной для классификации облаков на спутниковых снимках.

Работа выполнена при частичной финансовой поддержке Минобрнауки РФ (госконтракт № 02.740.11.0674).

## Литература

1. Облака и облачная атмосфера. Справочник // Под ред. Мазина И.П., Хргиана А.Х. Л.: Гидрометеоиздат, 1989. 647 с.
2. Тишкин Р.В. Нейросетевые алгоритмы идентификации облачности по спутниковым изображениям // Научно-техническая конференция ФГУП «РНИИ КП». Тезисы докладов, 2007. С. 323.
3. Bankert R.L., Mitrescu C., Miller S.D., Wade R.H. Comparison of GOES cloud classification algorithms employing explicit and implicit physics // Journal of applied meteorology and climatology. 2009. V. 48 P. 1411–1421.
4. Прэтт У. Цифровая обработка изображений // Пер. с англ. М.: Мир, 1982. 480 с.
5. Потапов А.А. Фракталы в радиофизике и радиолокации: Топология выборки // М.: Университетская книга, 2005. 848 с.
6. Харалик Р.М. Статистический и структурный подходы к описанию текстур // ТИИЭР, 1979. Т. 67. № 5. С. 98–120.
7. Андреев Г.А. Анализ и синтез случайных пространственных текстур // Зарубежная радиоэлектроника, 1984. №2. С. 3–33.
8. Weszka J., Dyer C., Rosenfeld A. A comparative study of texture measures for terrain classification // IEEE Trans. Syst., Man, and Cybern. 1976. V. SMC-6 №4 P 269–285
9. Астафуров В.Г., Скороходов А.В. Эффективные текстурные признаки различных типов облачности и подстилающей поверхности по данным спектрорадиометра MODIS // Контроль окружающей среды и климата “КОСК-2010”: Материалы симпозиума. Томск. 2010. С. 292-294.
10. Ersahin K., Scheuchl B., Cumming I. Incorporating texture information into polarimetric radar classification using neural networks // Proceedings of IGARSS'04.
11. Осовский С. Нейронные сети для обработки информации // Пер. с польского Рудинского И.Д. М.: Финансы и статистика, 2002. 344 с.
12. Хайкин С. Нейронные сети: Полный курс // Пер. с англ. КуССуль Н. Н., Шелестовой А.Ю. М.: Издательский дом Вильямс, 2008. 1103 с.
13. Калан Р. Основные концепции нейронных сетей // Пер. с англ. М.: Издательский дом Вильямс, 2001. 287 с.
14. Мицель А.А., Колодникова Н.В., Протасов К.Т. Непараметрический алгоритм текстурного анализа // Известия Томского политехнического университета. 2005. Т. 308. №1. С. 65–70.
15. Гонсалес Р., Вудс Р. Цифровая обработка изображений // М.: Техносфера, 2005. 1072 с.

# Classification of clouds in satellite images based on the technology of neural networks

V.G. Astafurov<sup>1,2</sup>, A.V. Skorokhodov<sup>1</sup>

*<sup>1</sup>V. E. Zuev Institute of Atmospheric Optics SB RAS*

*1, Academician Zuev Sq., Tomsk 634021*

*E-mail: astafurov@iao.ru, vazime@yandex.ru;*

*<sup>2</sup>Tomsk State University of Control Systems and Radioelectronics*

*40, Lenin Ave., Tomsk 634050*

For segmentation of cloud fields in satellite images and classification of clouds by types, it is suggested to use algorithms based on neural networks. For a description of clouds, information on their characteristic texture parameters is used. Problems of choice of the neural network architecture and its influence on the quality of image processing are discussed. Results of classification of clouds in satellite images recorded by the MODIS spectral radiometer are presented. The results obtained illustrate the efficiency of the suggested approach.

**Keywords:** cloud types, texture parameters, classification, segmentation, neural network.