

Сравнение методов объектно-ориентированной и нейросетевой классификации данных дистанционного зондирования Земли на основе материалов систем Landsat-5 и Orbview-3

А.А. Романов, К.А. Рубанов

*Сибирский федеральный университет
660041, Красноярск, пр. Свободный, 79
E-mail: arom_work@yahoo.com*

Представлены результаты сравнительного анализа точности методов классификации данных дистанционного зондирования Земли, основанных на объектно-ориентированных и нейросетевых подходах. Сравнение проводилось по данным среднего и высокого пространственного разрешения (Landsat-5 и Orbview-3), характеризующим одну и ту же территорию подстилающей поверхности. Показано, что нейросетевой алгоритм значительно превзошел показатели точности алгоритма объектно-ориентированного (ООП) в случае обработки данных Landsat (92 % против 74 %), и несущественно (всего на 2 %) превзошел результаты ООП для данных Orbview.

Ключевые слова: дистанционное зондирование, управляемая классификация, нейронные сети, статистические алгоритмы, объектно-ориентированный подход, Landsat, Orbview.

Введение

За последние десятилетия в связи с повышением уровня доступности спутниковых данных, появлением новых космических программ и открытых архивов возможности исследователей значительно расширились. Данные дистанционного зондирования Земли (ДЗЗ) сейчас применяются для широкого круга научно-прикладных задач, в частности, для разработки новых и верификации существующих тематических картографических продуктов. При этом также происходит активное развитие методов и технологий обработки данных ДЗЗ, и способов их интерпретации.

В связи с развитием аппаратно-программного обеспечения с конца 1990-х гг. в алгоритмах обработки данных ДЗЗ активно применяются нейросетевые (НС) подходы, поскольку их использование не требует априорного знания о статистическом распределении данных (Decatur, 1989; Keramitsoglou et al., 2005).

Кроме того, широкое распространение получили методы, основанные на объектно-ориентированном подходе (ООП), позволяющие эффективно распознавать данные ДЗЗ не только по спектральным, но и другим, например, структурным и пространственным признакам (Kettig, Landgrebe, 1976; De Kok et al., 1999).

В данной работе приводятся результаты сравнения эффективности представленных выше методов классификации на основе оценки точности распознавания при обработке данных ДЗЗ систем Landsat и Orbview, характеризующих территорию Среднеобской низменности Западно-Сибирской равнины.

Применение объектно-ориентированного подхода

Процедура ООП включает в себя два этапа: сегментацию изображения и классификацию сегментов на основе спектральных, пространственных и других характеристик. Процесс объектно-ориентированной классификации начинается с предварительного шага — разбиения изображения на гомогенные области. В начале процедуры каждый пиксель представляется отдельным объектом, затем смежные пиксели объединяются для формирования больших по размеру сегментов согласно критерию локальной однородности. В качестве такого

критерия могут использоваться спектральные признаки, текстурные характеристики (гладкость, компактность) или их вариации. Процесс останавливается, когда изменение структуры сегментов не превышает заданного пользователем порогового значения. Затем происходит классификация объектов, в качестве алгоритма распознавания часто используется метод ближайших соседних (Nearest Neighbor) и нечеткая логика.

Объектно-ориентированный подход к классификации данных ДЗЗ был предложен в 1970 гг. в работе (Kettig, Landgrebe, 1976), однако его полноценное использование было ограничено производительностью аппаратных средств, программного обеспечения, низким пространственным разрешением данных ДЗЗ и недостатками способов интерпретации (Kettig, Landgrebe, 1976, Flanders et al., 2003). С середины 1990-х гг. в связи с возрастающими возможностями технических средств и доступностью данных высокого пространственного разрешения область использования ООП значительно расширилась. (De Kok et al., 1999).

Сравнительный анализ применимости ООП показывает, что он успешно справляется с классификацией ДЗЗ как среднего пространственного разрешения аппаратов Landsat (Matinfar et al., 2007; Qian et al., 2007), так и высокого разрешения спутников Quickbird и IKONOS (Xiaoxia et al., 2005, Kamagata et al., 2006).

В работах по дешифрированию снимков высокого разрешения (Quickbird и IKONOS) отмечается явное превосходство ООП (Xiaoxia et al., 2005; Кух, Araujo, 2006; Kamagata et al., 2006). В исследовании (Xiaoxia et al., 2005) ООП показал достаточно хорошие результаты при обработке данных аппарата Quickbird — средняя точность составила 83 %, против 63 % ММП. В работе (Kamagata et al., 2006) по сравнению различных классификационных алгоритмов предложена собственная конфигурация ООП для картографирования растительности по данным спутника Ikonos. Качество классификации ООП превзошло результаты пикселе-ориентированных методов: ММП выделил на изображении слишком много разрозненных малоразмерных зон, в то время как алгоритм ISODATA часто ошибочно определял принадлежность различных по своим свойствам территорий к одному классу. Точность распознавания ООП составила 64,17 %, ММП — 60,17 %. Результаты приведенных исследований показывают, что ООП является подходящей техникой для анализа изображений высокого пространственного разрешения.

Применение нейронных сетей

Нейронные сети — один из видов искусственного интеллекта, который стал эффективным инструментом для практического применения в различных задачах распознавания образов (Lee et al., 1990; Shafri et al., 2007; Marghany, Hashim, 2011). Структура простейшей НС представлена на рис. 1.

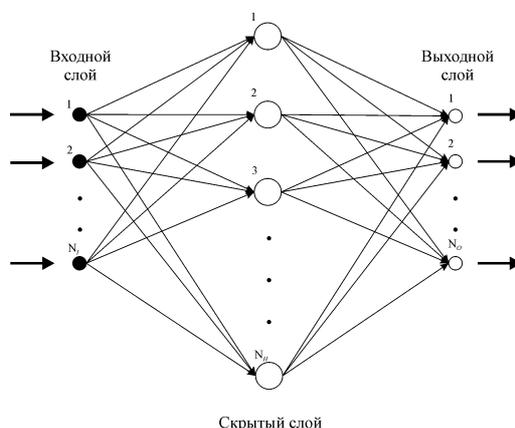


Рис. 1. Структура нейронной сети с одним скрытым слоем

Использование НС для распознавания ДЗЗ стимулируется их важными отличиями от статистических классификаторов: отсутствием необходимости наличия априорной информации относительно входных данных; формированием нелинейных границ решений в пространстве признаков; устойчивостью к ошибкам при обработке неполных или частично некорректных входных образов; хорошими возможностями генерализации входных данных.

Типичная нейронная сеть включает в себя большое число простых обрабатывающих элементов, называемых узлами, соединенных между собой весовыми связями. Простейшая модель ИНС состоит из трех слоев: входного, выходного и скрытого. Общая структура узла представлена на рис. 2. В качестве функции активации, определяющей возможность дальнейшей передачи сигнала, чаще всего используются логистическая или гиперболическая функции.

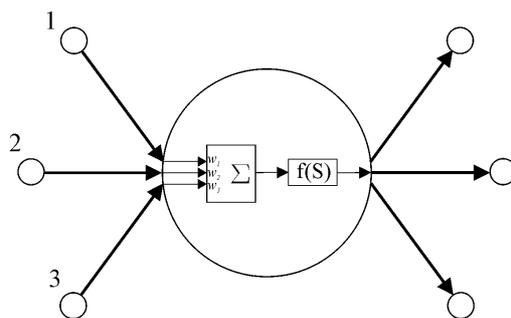


Рис. 2. Структура узла нейронной сети

Один из первых случаев успешного использования НС для классификации данных ДЗЗ описывается в работе Decatur. В ней сравнивается качество классификации НС с архитектурой многоуровневого персептрона (МП) и одного из Байесовских классификаторов. Было установлено, что НС упомянутой структуры позволяет выполнять классификацию более высокой точности, чем статистические методы (Decatur, 1989).

Результаты некоторых работ показали, что нейросетевой подход позволяет лишь незначительно улучшить процесс классификации (Paola, Schowengerdt, 1995; Herper et al., 1990; Key et al., 1990; Bischof et al., 1992; Kanellopoulos et al., 1991).

Некоторые исследователи, сравнивая подходы, рекомендовали метод максимального правдоподобия вследствие простоты его использования (Skidmore et al., 1997). Результаты нескольких исследований продемонстрировали лучшее качество распознавания методом ММП, нежели НС (Benediktsson et al., 1990; Solaiman, Mouchot, 1994).

Работа Fierens направлена на установление причин таких противоречивых результатов точности классификаторов. Одним из факторов может быть несравнимость экспериментальных настроек алгоритмов. Например, структурные параметры объектов, используемые для обучения НС, не были задействованы стандартными классификаторами (Herper et al., 1990, Bischof et al., 1992, Skidmore et al., 1997). Другой вероятной причиной может быть ограниченность допущений, принимаемых для определенных наборов данных, используемых в процедурах обучения классификаторов (Fierens et al., 1994).

В работе (Benediktsson et al., 1990) для формирования входных образов с нормальным распределением использовался генератор случайных чисел. Результаты его исследования оказались вполне ожидаемы — метод максимального правдоподобия превзошел по точности нейронную сеть, что еще раз подтверждает утверждение о том, что в случае нормального распределения ММП классифицирует данные лучше, чем НС. Нейронная сеть избегает допущений о статистической нормальности и имеет большую гибкость для распознавания нечетких и нелинейных образов (Key et al., 1990).

Нейронные сети демонстрируют высокую точность классификации в задачах анализа гиперспектральных данных ДЗЗ (Shafri et al., 2007). В этой работе по изучению тропических лесов на основе данных спектрометра AISA (высота сенсора 1000 м, 20 спектральных

каналов разрешением 1 м) были получены следующие показатели: наибольшая точность отмечается у ММП — 85,5 6% и НС — 83,61 %, худшая производительность — у метода спектрального угла и дерева решений — 48,83 % и 50,6 7% соответственно. Высокая точность, показанная ММП, объясняется тем, что гиперспектральная информация, полученная с бортового сенсора, достаточно точно соответствовала распределению Гаусса, что способствовало полному описанию распознаваемых классов и выполнению требований для этого параметрического алгоритма. Непараметрические классификаторы демонстрируют более высокую точность в тех случаях, когда пределы решений лежали на границах распределения классов, чем когда границы решений менее разделены в спектральном пространстве.

Широкое применение нейронные сети нашли в области обработки радарных данных. НС успешно использовались для классификации данных радаров с синтезированной апертурой (SAR) (Decatur, 1989; Azimi-Sadjadi et al., 1993; Raghu, Yegnanarayana, 1997).

Эксперимент

Для сравнения качества классификации рассматриваемых алгоритмов были выбраны следующие наборы данных:

- снимок Landsat 5 (5 каналов, VNIR и SWIR-диапазоны, 30 м);
- снимок Orbview 3 (4 канала, 4 м).

Анализируемые материалы характеризуют область Среднеобской низменности Западно-Сибирской равнины, представляющей собой болотно-озерную территорию со средними абсолютными отметками высот равными 35...55 м. Исползованные космические снимки датируются октябрем 2006 г. Исходное изображение исследуемой территории представлено на рис. 3.

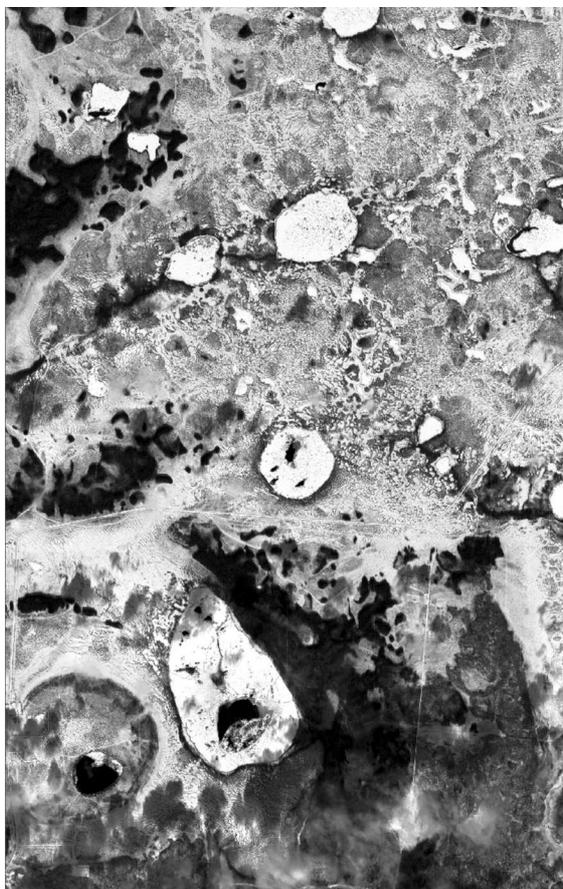


Рис. 3. Снимок Orbview 3 части территории Среднеобской низменности Западно-Сибирской равнины, использованный в качестве одного из исходных изображений

Путем подбора были выбраны следующие параметры сегментации в процессе объектно-ориентированного анализа, наилучшим образом подходящие для каждого изображения:

- для снимка Landsat 5: степень разбиения — 64 % (scale level), степень объединения сегментов (merge level) — 42 %;
- для снимка Orbview 3: степень разбиения — 18 %, степень объединения сегментов — 26 %.

Для выделения объектов в обоих случаях использовалась совокупность спектральных, пространственных и текстурных атрибутов.

При использовании нейросетевого подхода наилучшее качество распознавания показали НС следующих конфигураций:

- для Landsat 5: 1 скрытый слой, логистическая функция активации, 100 итераций процесса обучения, значение порога воздействия 0,04, коэффициент обучения 0,05, тренировочный шаг 0,25, критерий ошибки 0,1.
- для Orbview 3: 1 скрытый слой, логистическая функция активации, 200 итераций процесса обучения, значение порога воздействия 0,1, коэффициент обучения 0,25, тренировочный шаг 0,5, критерий ошибки 0,1.

Значение порога воздействия определяет степень влияния весовых коэффициентов на уровень активации узлов нейронной сети. Коэффициент обучения устанавливает величину настройки весовых коэффициентов, высокие значения ускоряют процедуру обучения, однако могут приводить к неточной настройке НС и, как следствие, неправильной классификации. Тренировочный шаг характеризует шаг изменения весовых коэффициентов. Критерий ошибки определяет минимальное значение среднеквадратической ошибки, при достижении которого процесс обучения НС прекращается.

Помимо сравниваемых в данной статье методов классификации — ООП и НС, был выполнен анализ материалов ДЗЗ с помощью метода максимального правдоподобия (наиболее распространенного статистического метода, реализованного в большинстве программных пакетов обработки данных ДЗЗ). Выбор параметров используемых алгоритмов осуществлялся произвольно, до достижения необходимого уровня точности классификации и качества интерпретации. Путем визуального экспертного анализа были отобраны лучшие результаты классификации, которые затем сравнивались между собой по качеству распознавания. Средние показатели точности и представлены в таблице.

Средние показатели точности и каппа-коэффициенты результатов классификации

| Метод классификации | Метод оценки | Набор данных | |
|---------------------|-------------------|--------------|-----------|
| | | Landsat 5 | Orbview 3 |
| ММП | Точность, % | 85 | 81 |
| | Каппа-коэффициент | 0,82 | 0,78 |
| ООП | Точность, % | 74 | 94 |
| | Каппа-коэффициент | 0,69 | 0,91 |
| НС | Точность, % | 92 | 96 |
| | Каппа-коэффициент | 0,9 | 0,95 |

Как видно из таблицы, в случае распознавания материалов Landsat 5, лучшая точность была достигнута нейросетевым алгоритмом — 92 % (каппа-коэффициент 0,9). ООП не смог превзойти традиционный метод максимального правдоподобия: 74 % (каппа-коэффициент 0,69) против 85 % (каппа-коэффициент 0,82). При классификации снимка высокого пространственного разрешения НС также показала наилучшие результаты — 96 % (каппа-коэффициент 0,95), против 94 % (каппа-коэффициент 0,91) у ООП. Результаты классификации снимков Orbview 3 объектно-ориентированным и нейросетевым методами представлены на рис. 4, 5.

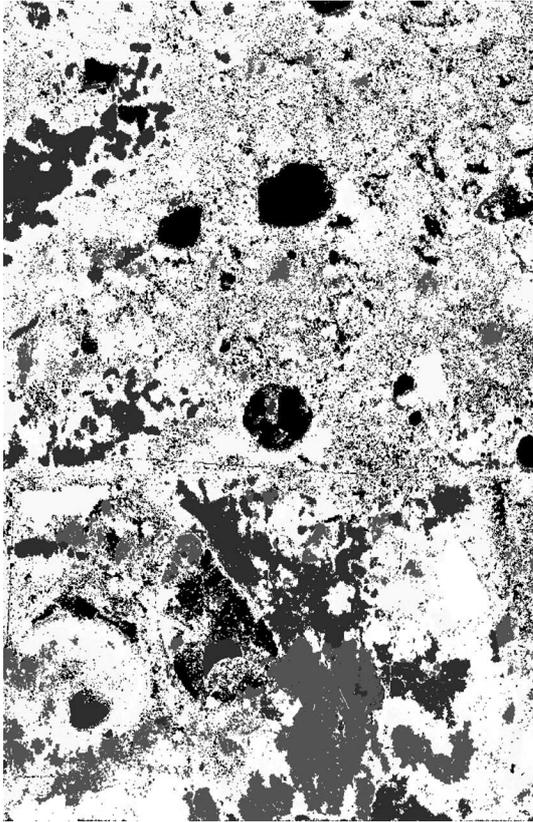


Рис. 4. Результат классификации снимка Orbview 3 методом объектно-ориентированной классификации

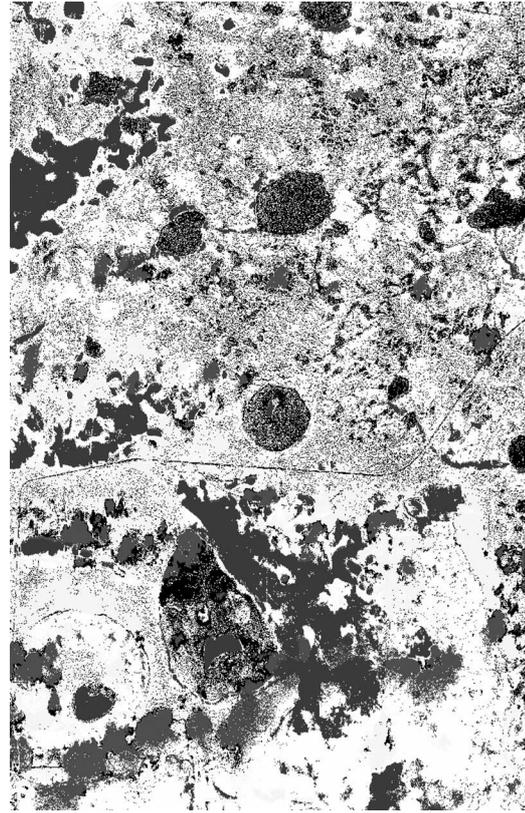


Рис. 5. Результат классификации снимка Orbview3 нейросетевым методом классификации

Следует отметить, что точность ООП в случае анализа снимка Landsat 5, оказалась неприемлемой для качественной классификации. Нейронная сеть, напротив, показала хорошие результаты в случае использования данных как высокого, так и среднего пространственного разрешения, что показывает возможность создания универсальной архитектуры, подходящей для материалов различных характеристик.

Особого внимания заслуживают следующие моменты, связанные с классификацией снимков высокого пространственного разрешения аппарата Orbview 3:

- нейронная сеть, в отличие от ООП, смогла распознать подстилающую поверхность, закрытую облаками;
- объектно-ориентированный алгоритм проигнорировал большое количество мало-размерных областей, маркировав их как соответствующие классу соседних с ними более крупных зон, хотя вариация спектральных характеристик в этих областях была существенной. Это легко объясняется несовершенством сегментации, правильный подбор параметров которой является важнейшим аспектом использования ООП, существенно влияющим на точность распознавания. Однако следует отметить, что такая генерализация, может быть как критичной в решении некоторых задач, так и полезной: все зависит от размеров интересующих объектов.

Заключение

Данные ДЗЗ высокого и сверхвысокого разрешения характеризуются широкой вариацией спектральных характеристик единообразных природных явлений. Большие спектральные колебания существенно снижают точность стандартных классификационных алгоритмов

пиксельного анализа, в качестве метода, способного обойти эти ограничения, может быть использован объектно-ориентированный подход. Наряду с полезными достоинствами, ООП имеет серьезный недостаток — точность классификации напрямую зависит от качества сегментации изображения: если объекты выделены неаккуратно, результирующая ошибка распознавания будет включать в себя как дефекты сегментации, так и классификации, что приведет к низкому качеству итоговой классификации.

Неправильное задание и неточная оценка функции распределения играет решающую роль в точности распознавания статистических алгоритмов. С другой стороны, сложности при использовании НС возникают в связи с выбором сетевой архитектуры, зависимостью результатов классификации от условий обучения и неоднозначностью интерпретации поведения НС.

В случае данных среднего пространственного разрешения нейронная сеть значительно превзошла результаты ООП: 92 % против 74 %, метод максимального правдоподобия показал точность распознавания равную 85 %. При обработке многоспектральных материалов высокого пространственного разрешения, ООП незначительно уступил НС — 96 % против 94 %.

Результаты работы показывают, что нейронные сети имеют большой потенциал для использования в качестве метода классификации данных ДЗЗ, однако требуется отметить, что процесс обучения нейронной сети сложной архитектуры занимает значительное время, что показывает необходимость разработки и применения специализированных архитектур для решения конкретных задач. Более тонкая настройка процесса обучения и конфигурирования структуры нейронной сети должна обеспечить сокращение временных затрат на классификацию.

Работа выполнена при поддержке РФФИ (проекты № 11-05-98056, 12-04-10098), Правительства РФ в рамках: договора 11.G34.31.0014 между Министерством образования и науки РФ, ФГАОУ ВПО СФУ и проф. Эрнстом-Детлефом Шульце; тематического плана СФУ, выполняемого по аналитической ведомственной целевой программе Министерства образования и науки РФ «Развитие научного потенциала высшей школы» (мероприятие 1).

Литература

1. *Azimi-Sadjadi M.R., Ghaloum S., Zoughi R.* Terrain classification in SAR images using principal components analysis and neural networks // *IEEE Trans. Geoscience and Remote Sensing*. 1993. V. 31. P. 511–515.
2. *Benediktsson J.A., Swain P.H., Ersoy O.K.* Neural network approaches versus statistical methods in classification of multisource remote sensing data // *IEEE Trans. Geoscience and Remote Sensing*. 1990. V. 28. N. 4. P. 540–552.
3. *Bischof H., Schneider W., Pinz A.J.* Multispectral classification of Landsat images using neural networks // *IEEE Trans. Geoscience and Remote Sensing*. 1992. V. 30. P. 482–490.
4. *De Kok R., Schneider T., Ammer U.* Object-based classification and applications in the alpine forest environment // *Intern. Archives of Photogrammetry and Remote Sensing*. Valladolid. Spain. 1999. V. 32.
5. *Decatur S.E.* Applications of neural networks to terrain classification // *Proc. Intern. Joint Conf. Neural Networks*. Washington DC, USA. 1989. P. 283–288.
6. *Kamagata N., Hara K., Mori M., Akamatsu Y., Li Y., Hoshino Y.* A new method of vegetation mapping by object-based classification using high resolution satellite data // *Proc. 1st Intern. Conf. Object-Based Image Analysis*. 2006. V. 36-4/C42.
7. *Keramitsoglou I., Sarimveis H., Kiranoudis C.T., Sifakis N.* Radial basis function neural networks classification using very high spatial resolution satellite imagery: an application to the habitat area of Lake Kerkini (Greece) // *Intern. J. Remote Sensing*. 2005. V. 26. N. 9. P. 1861–1880.
8. *Kettig R.L., Landgrebe D.A.* Classification of multispectral image data by extraction and classification of homogeneous objects // *IEEE Trans. Geoscience Electronics*. 1976. V. GE-14, N. 1. P. 19–26.

9. Lee J., Weger R.C., Sengupta S.K., Welch R.M. A neural network approach to cloud classification // IEEE Trans. Geoscience and Remote Sensing. 1990. V. 28. P. 846–855.
10. Marghany M., Hashim M. Comparison between Mahalanobis classification and neural network for oil spill detection using RADARSAT-1 SAR data // Intern. J. Physical Sciences. 2011. V. 6. N. 3. P. 566–576.
11. Qian J., Zhou Q.M., Hou Q. Comparison of pixel-based and object-oriented classification methods for extracting built-up areas in aridzone // ISPRS Workshop on Updating Geo-spatial Databases with Imagery and The 5th ISPRS Workshop on DMGISs. 2007. P. 163–171.
12. Raghu P.P., Yegnanarayana B. Multispectral image classification using Gabor filters and stochastic relaxation neural network // Neural Networks. 1997. V. 10. P. 561–572.
13. Shafri H.Z.M., Suhaili A., Mansor S. The performance of Maximum Likelihood, Spectral Angle Mapper, Neural Network and Decision Tree classifiers in hyperspectral image analysis // J. Computer Science. 2007. V. 3. N. 6. P. 419–423.
14. Xiaoxia S., Jixian Z., Zhengjun L. A comparison of object-oriented and pixel-based classification approaches using Quickbird imagery // Intern. Symp. Spatio-Temporal Modelling, Spatial Reasoning, Analysis, Data Mining and Data Fusion. Beijing, China. 2005.

Comparison of methods for object-oriented and neural network classification of remote sensing data based on Landsat-5 and Orbview-3 materials

A.A. Romanov, K.A. Rubanov

*Siberian Federal University
660041 Krasnoyarsk, Svobodniy prospect, 79
E-mail: arom_work@yahoo.com*

Comparative analysis of the accuracy of classification methods of remote sensing data based on object-oriented and neural network approaches is presented. Process was carried out according to the datasets of middle and high spatial resolution (Landsat 5 и Orbview 3) characterizing the same land surface area. It was shown that neural network algorithm performance significantly exceeded the accuracy of the algorithm based on object-oriented approach (OOA) in the case of Landsat datasets (92 % vs. 74 %), and insignificantly (just for 2 %) surpassed the results of the OOA for Orbview datasets.

Keywords: remote sensing, supervised classification, neural networks, statistical algorithms, object-oriented approach, Landsat, Orbview.