

С.В. ПУШКАРСКИЙ, Е.Ю. КОРНЕЙЧУК, И.И. ВИНОГРАДОВ
**НЕЙРОТЕХНОЛОГИЧЕСКИЙ ПОДХОД
К АВТОМАТИЗИРОВАННОМУ РАСПОЗНАВАНИЮ
НАЗЕМНЫХ ОБЪЕКТОВ ПО ДАННЫМ КОСМИЧЕСКИХ
СИСТЕМ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ**

Пушкарский С.В., Корнейчук Е.Ю., Виноградов И.И. **Нейротехнологический подход к автоматизированному распознаванию наземных объектов по данным космических систем дистанционного зондирования Земли.**

Аннотация. В данной статье определены возможности использования нейромبيوترной технологии для обработки снимков космических систем дистанционного зондирования Земли. Представлено моделирование процесса классификации объектов. Обсуждаются последовательность и содержание основных этапов построения архитектуры нейронной сети. Для классификации и распознавания наземных объектов на космических снимках используются их спектральные характеристики. Проведен сравнительный анализ работы различных типов нейронных сетей при классификации наземных объектов.

Ключевые слова: обработка космических снимков, распознавание, нейронные сети, дистанционное зондирование Земли.

Pushkarskiy S.V., Korneychuk E.J., Vinogradov I.I. **Neural technological approach to automated recognition of ground objects in images of space systems for remote sensing of the Earth.**

Abstract. In this paper the ability to use neurocomputer technology to imaging remote sensing system are considered. The modeling of object classification is reviewed. The sequence and contents of the main stages of the construction of the neural network architecture are discussed. The spectral characteristics of different ground objects are used for classification and recognition of objects in satellite images. Comparative analysis of different types of neural networks in the classification of ground objects is given.

Keywords: processing of satellite images, pattern recognition, neural networks, remote sensing of the Earth.

1. Введение. Одной из актуальных задач, возникающих при обработке изображений, полученных с помощью космических средств наблюдения, является задача распознавания наземных объектов. Правильно выполненная классификация объектов на снимках ДЗЗ значительно упрощает процесс их распознавания, а также позволяет реализовать оперативный мониторинг и предупреждение чрезвычайных происшествий и катастроф природного и техногенного характера. Учитывая важное экологическое и экономическое значение пожаров, морских стихийных бедствий, землетрясений, имеющийся недостаток своевременной, полной и достоверной информации для решения прикладных задач, можно утверждать, что развитие методов классификации объектов и разработка систем автоматизированного распознавания

ния, работающих в реальном масштабе времени, стоят в ряду приоритетных научных задач. Несмотря на то, что этим вопросам посвящено значительное количество работ [1-5], требуется, как показывает анализ, для практических приложений решить целый ряд актуальных задач нестандартного характера.

2. Анализ выполненных работ и постановка задачи. Возможность применения нейронных сетей для обработки данных дистанционного зондирования Земли исследовалась в работах [6, 7]. В данных публикациях рассматриваются и сравниваются классификации объектов с использованием нейронных сетей и Байесовского метода. По результатам исследований наиболее достоверные результаты были получены при использовании многослойного персептрона.

В работе [8] для определения затопленных территорий с высокой точностью использовался подход, основанный на автоматической сегментации и классификации спутниковых изображений.

Во многих работах, посвященных нейросетевой классификации, чаще всего выбирается, как правило, один тип нейронной сети без указания аргументов в пользу выбранного подхода. В представленных и планируемых исследованиях ставится задача проведения сравнительного анализа использования различных нейросетей для обработки снимков ДЗЗ и получения данных об эффективности их применения. При этом оценка качества автоматизированной классификации объектов изображений с использованием нейрокомпьютерной технологии выполнялась по каждому типу объектов в соответствии с выражением:

$$C_{\text{вк}} = \frac{n_{\text{пр}}}{N_{\text{общ}}} * 100\%,$$

где $C_{\text{вк}}$ — процент верно классифицированных образов;

$n_{\text{пр}}$ — количество правильно классифицированных объектов данного типа;

$N_{\text{общ}}$ — общее количество предъявленных для классификации объектов одного типа.

3. Выбор исходных данных. Для проведения исследований использовались библиотеки спектральных характеристик объектов, которые состоят из наборов графиков-кривых спектральной отражательной способности объектов [9]. График спектральной кривой представляет собой графическое отображение связи между длиной волны и значениями коэффициентов отражения у анализируемого объекта (рис. 1). По оси абсцисс отложены значения длин волн, для которых проводились измерения коэффициентов отражения, как правило, ука-

зываются в микрометрах или нанометрах, по оси ординат - значения коэффициентов отражения в рассматриваемых зонах спектра, измеряемых, как правило, в относительных долях.

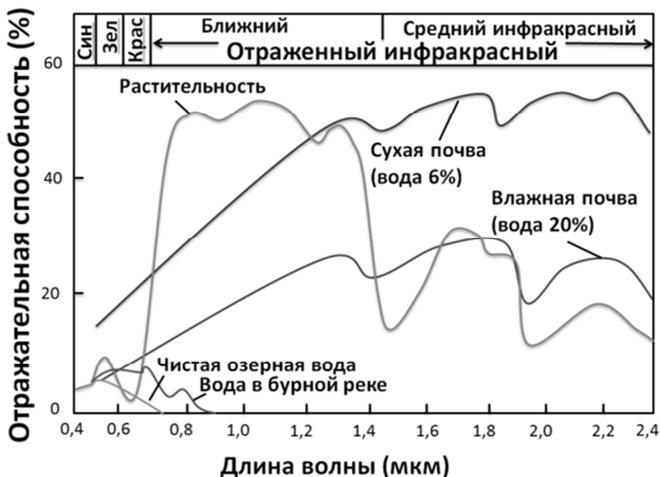


Рис. 1. Графики спектральных отражательных способностей.

Основное назначение спектральных библиотек — сравнение кривых спектральной отражательной способности различных объектов для выявления характерных зон поглощения/отражения энергии и использование полученной информации при проведении спектрального анализа. Такое сравнение может производиться между спектральными кривыми различных объектов. На основе спектральных библиотек возможно сформировать набор эталонов и после сравнения их со спектральными кривыми со снимков реализовать классификацию объектов. Например, из рис. 1 видно, что растительность имеет высокую отражательную способность в ближнем инфракрасном диапазоне и низкую отражательную способность в среднем инфракрасном спектре по сравнению с почвами.

На спектральные характеристики воды большое влияние оказывает мутность, вызываемая взвешенными осадками, и содержание хлорофилла. Мутная вода имеет более высокую отражательную способность, чем прозрачная вода, и для мутной воды в отличие от прозрачной воды она самая высокая в диапазоне более длинных волн. Как по-

казано на рис. 1, при увеличении содержания хлорофилла происходит значительное уменьшение количества отраженной энергии в синей области спектра и ее увеличение в зеленой области.

Особый интерес представляет рассмотрение спектров сухой и влажной почвы. Благодаря хорошей разделимости данных объектов практически во всей области видимого и ближнего инфракрасного излучения, спектральные характеристики сухой и влажной почвы можно использовать при прогнозировании пожаров. Именно влажность является основным погодным фактором, оказывающим влияние на возникновение лесных пожаров, для возникновения которого достаточно, чтобы высох поверхностный слой. Если влажность поверхностного слоя составляет 25–30 %, то он может легко воспламениться.

Можно видеть также хорошую разделимость травянистой и лесной растительности. Спектры травы имеют значительно меньший разброс, чем для леса. Это объясняется отсутствием кроны, ибо попадая во внутрикороновые просветы, свет претерпевает многократное рассеяние, что может существенно изменять форму спектра.

На основе спектральных библиотек были сформированы наборы эталонов, принадлежащие 7 классам: сухая почва (содержание влаги в почве 6%), влажная почва (содержание влаги в почве 20%), чистая вода, вода в бурной реке, трава, лиственный лес, хвойный лес.

В проводимых исследованиях были использованы несколько общедоступных спектральных библиотек природных и искусственных объектов: USGS Digital Spectral Library [10], JPL (Jet Propulsion Lab) spectral library [11], Johns Hopkins University Spectral Library [12], ASTER spectral library [13], IGCP264 Spectral Library. Сравнение спектральных характеристик производилось не только между спектральными кривыми различных объектов, но и между кривыми, снятыми спектрометром со снимка. Использование данных спектральных библиотек в качестве эталонов при проведении спектрального анализа для выявления объектов на конкретном снимке требует соблюдения ряда обязательных требований: одинаковые единицы измерения, одинаковый спектральный диапазон и разрешение данных.

4. Построение нейронной сети. Для определения возможностей использования нейрокомпьютерной технологии для обработки снимков ДЗЗ была построена нейронная сети. Основными этапами ее построения являются:

- 1) выбор типа (архитектуры) сети;
- 2) обучение сети.

При выборе архитектуры сети была проведена серия экспериментов в программном пакете Statistica Neural Networks [14] с использованием трех основных моделей нейронной сети:

- сети прямого распространения (backpropagation): одна из наиболее распространенных архитектур, в основном используется в таких областях, как прогнозирование и распознавание образов;
- сети с обратной связью: такие, как дискретная модель Хопфилда, в основном используется для оптимизации вычислений;
- самоорганизующиеся сети: модели Кохонена, в основном используется для кластерного анализа.

В ходе определения архитектуры сети наиболее удачным оказалось использование многослойного персептрона. Архитектура сети многослойного персептрона с одним скрытым слоем представлена на рис. 2. На вход подаются значения коэффициентов отражения, а на выходе — тип объекта. Таким образом, размерность входного слоя нейронной сети — 124, размер выходного слоя — 7 нейронов (в соответствии с количеством классов). В обучающей выборке было использовано порядка 30 спектральных кривых для каждого класса. Функция активации нейронов была выбрана сигмоидального типа:

$$f(u) = \frac{1}{1 + \exp(-u)}.$$

Обычно, в первом приближении при построении модели на скрытом слое выбирается число элементов, равное полусумме числа входных и выходных элементов, но в данной задаче рассматривалось различное количество нейронов в скрытом слое: 5, 10, 20, 40.

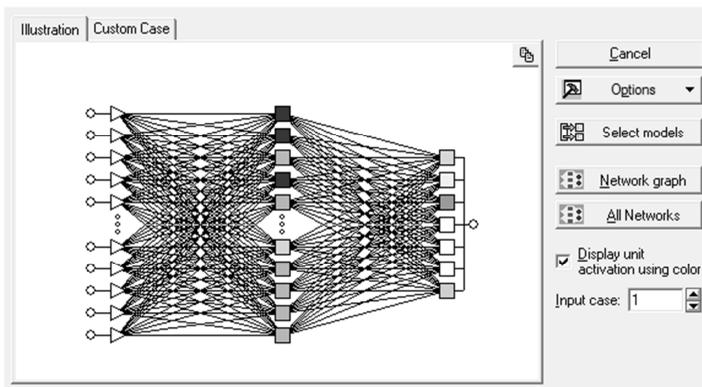


Рис. 2. Многослойный персептрон.

На втором этапе построения сети проводится ее обучение (подбор весов). На рис. 3 представлен процесс обучения сети. При предъявлении значений спектральных кривых на входе сеть выдает некоторый ответ, не обязательно верный. Известен и верный ответ — тип объекта, которому принадлежит данная кривая. После многократного предъявления примеров веса сети стабилизируются, причем сеть дает правильные ответы на все (или почти все) примеры из базы данных. Когда величина ошибок достигает нуля или приемлемо малого уровня, обучение останавливается, и сеть готова к классификации.

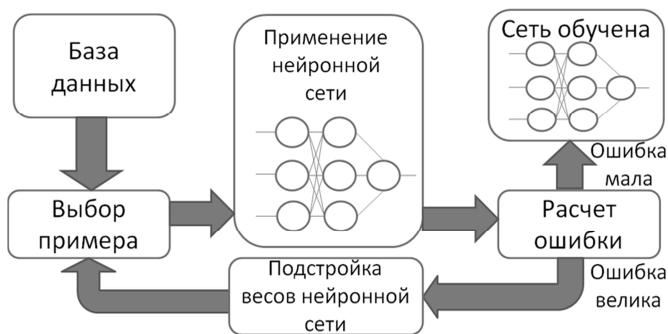


Рис. 3. Структурная схема процесса обучения.

Для моделирования нейронной сети использовались алгоритмы обратного распространения ошибки, квазиньютоновский, и спуск по сопряженным градиентам [14].

В многослойных нейронных сетях оптимальные выходные значения нейронов всех слоёв, кроме последнего, как правило, неизвестны. Одним из наиболее удачных вариантов решения данной проблемы является распространение сигналов ошибки от выходов нейронной сети к ее входам, в направлении, обратном прямому распространению сигналов в обычном режиме работы. Этот алгоритм обучения получил название процедуры обратного распространения ошибки и используется с целью минимизации среднеквадратического отклонения текущих от требуемых выходов многослойных нейронных сетей с последовательными связями. При использовании алгоритма обратного распространения ошибки были проведены серии экспериментов с разным количеством эпох (50, 100, 200, 500) и скоростью обучения (от 0.01 до

0.3). При увеличении скорости обучения алгоритм работает быстрее, но это может привести к неустойчивости.

5. Результаты решения задачи классификации. Максимальное значение верно классифицированных данных было получено при использовании алгоритма обратного распространения ошибки в многослойном персептроне. В таблице приведены статистики, отражающие результаты работы данного алгоритма и качество классификации спектральных кривых: процент верно классифицированных кривых, процент ошибочно классифицированных кривых и количество спектральных кривых, которые сеть не смогла классифицировать.

Таблица 1. Статистика классификации

Классы	сухая почва	влажная почва	чистая озерная вода	вода в бурной реке	трава	лиственный лес	хвойный лес
$C_{\text{БК}}, \%$	98,36	95,92	96,38	92,59	89,94	96,20	84,29
$C_{\text{ОШ}}, \%$	1,64	4,08	3,62	7,41	10,06	3,8	15,71
$C_{\text{НЕИЗВ}}, \%$	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Чтобы достичь 90–99% правильности классификации с использованием различных нейронных сетей, был проведен поиск оптимальных параметров обучения выбранных сетей: коэффициентов обучения, коэффициентов принятия — отвержения, количества эпох обучения. Таким образом, были определены архитектуры нейронных сетей, при использовании которых спектральные кривые, полученные из библиотек, были успешно разделены на 7 классов.

6. Выводы. Сравнение результатов классификации спектральных характеристик различными типами сетей показало сопоставимость результатов при небольшом превосходстве по времени обучения многослойного персептрона с использованием метода обратного распространения. Вместе с тем, необходимы дополнительные исследования для анализа применимости нейронных сетей при мониторинге пожаров, морских стихийных бедствий, определении состояния лесных и сельскохозяйственных угодий и детектировании атмосферного загрязнения.

Литература

1. *Кашкин В.Б., Сухинин А.И.* Дистанционное зондирование Земли из космоса//Цифровая обработка изображений: учеб. пособие. – М.: Логос, 2001. 264 с.
2. *Гонсалес Р.* Цифровая обработка изображений / Р.Гонсалес, Р. Вудс. – М.: Техносфера, 2005. 1072 с.

3. *Анисимов В.Б., Курганов В.Д., Злобин В.К.* Распознавание и цифровая обработка изображений: Учеб. Пособие для студентов вузов. – М.: Высш. шк., 1983. 295 с.
4. *Бондур В.Г., Крапивиных В.Ф., Савиных В.П.* Мониторинг и прогнозирование природных катастроф. – М.: Научный мир, 2009. 696с.
5. *Давыдов В.Ф.* *Землетрясения.* Телеметрия предвестников: Монография – М.: МГУЛ, 2001. 73 с.
6. *Decatur S.E.* Applications of Neural Networks to Terrain Classification. Proceedings of the International Joint Conference on Neural Networks, vol. 1, 1989. pp. 283–288.
7. *Bischof H., Schneider W., Pinz A.J.* Multispectral Classification of Landsat Images Using Neural Networks, IEEE Trans. on Geoscience and Remote Sensing, Vol. 30 no. 3 (1992) pp. 482–490.
8. Нейросетевой метод мониторинга затопленных территорий с использованием радиолокационных спутниковых данных / Н.Н. Кукуль [и др.] // Исследование Земли из космоса. 2008. № 4, с. 29–35.
9. *Кринов, Е.Л.* Спектральная отражательная способность природных образований. М.-Л. Изд-во АН СССР. 1947. — 272 с.
10. <http://speclab.cr.usgs.gov/spectral-lib.html>
11. http://speclib.jpl.nasa.gov/documents/jpl_desc
12. http://speclib.jpl.nasa.gov/documents/jhu_desc
13. <http://speclib.jpl.nasa.gov/search-1>
14. Электронный учебник по статистике StatSoft: <http://www.statsoft.ru/home/textbook/default.htm>

Пушкарский Сергей Васильевич — к.т.н., академик Российской академии космонавтики им. К.Э. Циолковского, вице-президент Российской академии космонавтики. Член Президиума Федерации космонавтики России; заместитель генерального директора по науке, региональному развитию и качеству ОАО «НПК «РЕКОД». Область научных интересов: теория полета космических аппаратов, маркетинговые исследования рынка космических технологий и услуг, технико-экономическое обоснование создания и применения космической техники. Число научных публикаций — 200. ommo53@mail.ru; ОАО «НПК «РЕКОД», 3-й проезд Марьиной Рощи, дом 40, корпус 6, строение 1, Москва, 127018, РФ; р.т. +7(985)928-9851.

Pushkarskiy Sergey Vasilevich — Cand.Tech.Sci; Deputy Director of Research Institute of Open Joint Stock Company "Scientific and Production Corporation "REKOD" (JSC "SPC" REKOD)". Fields of research: space flights theory and market research of space applications and services. Publications: more than 200 scientific paper. ommo53@mail.ru; JSC "SPC" REKOD", 3 p. Marina Grove, Building 40, Building 6, Moscow, 127018, Russia; office phone +7(985)928-9851.

Корнейчук Евгения Юрьевна — аспирант; ведущий научный сотрудник «НИИ КС имени А.А. Максимова» - филиал ФГУП «ГКНПЦ им. М.В. Хруничева». Область научных интересов: теория распознавания образов, экспертные системы, нейрокомпьютерные технологии, системы ДЗЗ. Число научных публикаций — 4. jardine@mail.ru; «НИИ КС имени А.А.Максимова» - филиал ФГУП «ГКНПЦ им. М.В. Хруничева», ул. Тихонравова, д. 27, г. Юбилейный МО, 141091, РФ; р.т. +7(495)543-38-68.

Korneychuk Evgeniya Yurievna — postgraduate; leading researcher, Space Systems named after A.A. Maksimov – branch of KHRUNICHEV State Research and Production Space Center. Fields of research: the theory of pattern recognition, expert systems, neurocomputing tech-

nology, remote sensing system. The number of scientific publications - 4. jardine@mail.ru; Space Systems named after A.A. Maksimov – branch of KHRUNICHEV State Research and Production Space Center, st. Tikhonravova, 27, the Yubileyniy, Moscow region, 141091, Russia; office phone +7 (495) 543-38-68.

Виноградов Игорь Игоревич — аспирант; заместитель начальника отдела 908 подразделения «НИИ КС им. А.А. Максимова» - филиала ФГУП «ГКНПЦ им. М.В. Хруничева». Область научных интересов: защита информации, системы дистанционного зондирования Земли, нейрокомпьютерные технологии. Число научных публикаций — 5. «НИИ КС имени А.А. Максимова» - филиал ФГУП «ГКНПЦ им. М.В. Хруничева», ул. Тихонравова, д. 27, г. Юбилейный МО, 141091, РФ; р.т. +7(495)780-07-81.

Vinogradov Igor Igorevich — postgraduate; Deputy Head of Unit 908 of Space Systems named after A.A. Maksimov – branch of KHRUNICHEV State Research and Production Space Center. Fields of research: protection of information, expert systems, neurocomputing technology, remote sensing system. The number of scientific publications — 5. Space Systems named after A.A. Maksimov – branch of KHRUNICHEV State Research and Production Space Center, st. Tikhonravova, 27, the Yubileyniy, Moscow region, 141091, Russia, office phone +7(495)780-07-81.

Рекомендовано «НИИ КС им. А.А. Максимова» — филиал ФГУП «ГКНПЦ им. М.В. Хруничева», начальник отделения Вокин Г.Г., д.т.н., проф.
Статья поступила в редакцию 08.05.2013.

РЕФЕРАТ

Пушкарский С.В., Корнейчук Е.Ю., Виноградов И.И. **Нейротехнологический подход к автоматизированному распознаванию наземных объектов по данным космических систем дистанционного зондирования Земли.**

Проведен обзор работ, посвященных классификации наземных объектов и их состояний по данным космических снимков с использованием нейронных сетей. В настоящее время нейротехнологический подход находит все более широкое применение в задачах распознавания образов и комплексной обработки информации. В обзоре отмечено, что в анализируемых публикациях чаще всего выбирается, как правило, один тип нейронной сети без указания аргументов в пользу выбранного подхода. В данной работе ставится задача проведения сравнительного анализа использования нейросетей для обработки снимков ДЗЗ и получения данных об эффективности их применения. Для оценки качества нейронной сети используется процент верно классифицированных образов.

Для классификации наземных объектов используются методы, основанные на сравнении их спектральных характеристик. При этом необходимым инструментом обработки многоспектральных данных являются спектральные библиотеки - базы данных, содержащие информацию об отражательной способности наземных объектов на различных длинах волн.

В статье представлено моделирование процесса классификации объектов с использованием разнообразных нейронных сетей. Обсуждаются последовательность и содержание основных этапов построения архитектуры нейронной сети. Результаты работы различных типов нейронных сетей при классификации наземных объектов и их состояний показали, что данные объекты выделяются почти безошибочно при использовании многослойного перцептрона, обученного методом обратного распространения ошибки.

Выполненная классификация объектов на снимках дистанционного зондирования Земли может быть полезна для решения таких задач, как оперативный мониторинг и предупреждение чрезвычайных происшествий и катастроф природного или техногенного характера.

SUMMARY

Pushkarskiy S.V., Korneychuk E.J., Vinogradov I.I. **Neural technological approach to automated recognition of ground objects in images of space systems for remote sensing of the Earth.**

A review of papers on the classification of ground objects and their states according to satellite images using neural networks has shown. Neural network approach is becoming more widely used in pattern recognition problems and complex information processing. One type of neural network is selected in the analyzed publications without an argument.

The article gives us the information concerning the results of aerial image processing on the base different neural network algorithm. The modeling of object classification is reviewed. The sequence and contents of the main stages of the construction of the neural network architecture are discussed. The spectral characteristics of different ground objects are used for classification and recognition of objects in satellite images. Comparative analysis of different types of neural networks in the classification of ground objects is given. The classification of objects in images of remote sensing can be useful for tasks such as real-time monitoring and prevention of accidents and disasters of natural or man-made disasters.