

## МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ И ИНТЕРПРЕТАЦИИ КОСМИЧЕСКОЙ ИНФОРМАЦИИ

### СРАВНЕНИЕ СТАТИСТИЧЕСКОГО И НЕЙРОСЕТЕВОГО ПОДХОДОВ КЛАССИФИКАЦИИ РАСТИТЕЛЬНОСТИ ПО ДАННЫМ СПУТНИКА LANDSAT 5

© 2012 г. А. А. Романов\*, К. А. Рубанов

*Сибирский федеральный университет, Красноярск*

\*E-mail: arom\_work@yahoo.com

Поступила в редакцию 06.03.2012 г.

Цель данного исследования – изучение эффективности применения нейронных сетей (НС) в задачах классификации данных дистанционного зондирования Земли (ДЗЗ). В работе приводится описание традиционных методов распознавания, дается характеристика нейросетевого подхода. Представляется ретроспектива применения НС для решения различных задач по обработке данных ДЗЗ. Помимо этого, в данной работе приводятся результаты исследования применимости НС на примере классификации реальных данных ДЗЗ, характеризующих территорию высокой степени гетерогенности. Точность распознавания типов растительного покрова, полученная с помощью нейросетевого классификатора, составила 91%, что превосходит показатели других методов: максимального правдоподобия (82%), расстояния Махаланобиса (78%), минимальных расстояний (64%). Результаты исследования показывают, что присущий гетерогенным данным закон нормального распределения не всегда обеспечивает статистическим алгоритмам преимущества в точности классификации. Предложен формат нейросетевого классификатора для обработки данных ДЗЗ, характеризующихся высокой степенью гетерогенности.

**Ключевые слова:** дистанционное зондирование, управляемая классификация, нейронные сети, статистические алгоритмы, Landsat 5, тематическое дешифрирование

#### ВВЕДЕНИЕ

Дистанционное зондирование Земли (ДЗЗ) является одной из наиболее значимых и динамично развивающихся областей современной науки и техники. Достижения последних десятилетий в сфере создания и развития космических систем, технологий обработки, хранения, интерпретации, а также практического использования получаемых данных значительно расширили круг и масштаб задач, решаемых на основе данных ДЗЗ. Постоянно увеличивается число потребителей, а получаемая таким способом информация широко используется как в научных, так и в производственных целях.

Важными этапами использования данных ДЗЗ являются предварительная и тематическая обработка. Первую категорию представляют методы геометрической, радиометрической и атмосферной коррекции, а также процедуры фильтрации и восстановления пропущенных пикселей. Тематическая обработка выполняется после предварительной и направлена на решение определенных задач – извлечение конкретной информации в той или иной области наук о Земле. Основным подходом при тематической обработке является использование аппарата распознавания образов.

Для классификации данных ДЗЗ наиболее часто применяют статистические методы распознавания. Это объясняется тем, что вследствие нерегулярного характера протекания природных явлений результаты ДЗ часто подвержены случайным изменениям, маскирующим характерные различия между классами. Статистический анализ позволяет учесть эти изменения, потенциально уменьшить их отрицательное влияние на точность классификации. Помимо этого, исследуемые классы могут перекрываться в пространстве измерений: некоторые измерения одного класса могут быть неотличимы от измерений других классов. В большинстве этих случаев методы статистического распознавания образов позволяют производить классификацию высокой точности (Кашкин, Сухинин, 2001).

Традиционные методы распознавания образов весьма хороши с точки зрения обеспечения требуемой точности результатов классификации, но при этом требуют достаточно подробной априорной информации о статическом распределении данных. К тому же, широкое распространение данных сверхвысокого пространственного разрешения и гиперспектральных изображений заставляет задумываться о разработке новых методов распознавания.

## МЕТОДЫ НЕУПРАВЛЯЕМОЙ КЛАССИФИКАЦИИ

Методы классификации подразделяются на управляемые и неуправляемые. В первом случае аналитик самостоятельно определяет требуемые классы, во втором — лишь указывает их количество.

Методы неуправляемой классификации основаны на процедуре кластеризации, суть которой состоит в определении местоположения центров векторов признаков внутри однородной выборки пикселей. Эти выборки, называемые кластерами, выполняют функцию представителей классов, содержащихся в изображении. Полученные в результате классификации области необходимо идентифицировать и определить, представляют ли они интерес для аналитика. Этот метод оказывается полезным в случае недостатка априорной обучающей информации о данных ДЗЗ. К примеру, неуправляемая кластеризация часто используется для получения обзорных вегетационных карт (карт растительности) (Memarsadeghi et al., 2003).

Одним из наиболее популярных методов кластеризации является алгоритм К-средних. В начале работы алгоритма произвольным образом задается начальное математическое ожидание вектора для каждого из кластеров. Затем каждый пиксел обучающего набора данных назначается классу, чье математическое ожидание вектора признаков наиболее близко к вектору пиксела. Таким способом формируется первый набор границ решения. Затем вычисляется новый набор векторов математических ожиданий кластера, а пиксели соответствующим образом переназначаются. Итерации продолжаются до тех пор, пока в переопределении пикселей на двух последовательных итерациях не будет наблюдаться существенного изменения, определяемого некоторым абсолютным значением (Шовенгердт, 2010).

Одним из наиболее популярных и широко используемых способов кластеризации в ДЗ является ISODATA (Jain, Dubes, 1988; Jensen, 2004). Этот алгоритм является модификацией метода К-средних, его важное преимущество заключается в том, что аналитику требуется обеспечить только начальную оценку числа классов, а затем, базируясь на широкой эвристике, алгоритм может оптимизировать количество кластеров, удаляя малоразмерные, объединяя ближайшие или разделяя гетерогенные области (Memarsadeghi, 2003).

На практике методы неуправляемой классификации часто используются для предварительного распознавания исследуемой территории, что помогает снизить сложность подробной тематической обработки, выполняемой на следующем этапе.

## СТАТИСТИЧЕСКИЕ МЕТОДЫ УПРАВЛЯЕМОЙ КЛАССИФИКАЦИИ

Метод максимального правдоподобия (ММП) является наиболее часто используемым способом управляемой классификации данных ДЗЗ (Richards, Jia, 2006), в задаче определения класса, к которому принадлежит соответствующий пиксел, особый интерес представляют условные вероятности  $p(\omega_i, |x)$ ,  $i = 1, \dots, M$ , где  $\omega_i$  — спектральное представление класса  $\omega_i$ ,  $i = 1, \dots, M$ . Вектор измерений  $x$  — набор яркостных характеристик пиксела. Такое описание представляет пиксел как точку в мультиспектральном пространстве с координатами, определенными яркостью. Вероятность  $p(\omega_i, |x)$  определяет принадлежность конкретного пиксела, характеризуемого вектором  $x$ , к одному из заданных классов. Классификация выполняется по следующему правилу:

$$x \in \omega_i, \text{ если } p(\omega_i, |x) > p(\omega_j, |x) \text{ для всех } j \neq i. \quad (1)$$

Таким образом, пиксел  $x$  принадлежит классу  $\omega_i$ , если вероятность  $p(\omega_i, |x)$  выше. Приведенное решающее правило представляет собой особый случай более общего правила, основанного на статистических закономерностях.

Нужно отметить, что большинство применяемых методов управляемой классификации, основанных на статистических закономерностях, используют в качестве основы Байесовский классификатор (Richards, Jia, 2006).

Несмотря на простоту метода, описываемого в формуле (1), вероятность  $p(\omega_i, |x)$  является неизвестной. Однако предполагается наличие обучающих данных, характеризующих каждый тип распознаваемой поверхности. Эта информация используется для оценки распределения вероятностей каждого вида покрытия, которая описывает возможность принадлежности пиксела  $x$  соответствующего классу  $\omega_i$ . Имеющаяся статистическая информация представляется в виде вероятности  $p(x|\omega_i)$ . Другими словами, для каждого пиксела, занимающего положение  $x$  в спектральном пространстве признаков, рассчитывается набор вероятностей, на основании которых строится гипотеза о принадлежности пиксела к тому или иному классу.

Требуемые вероятности  $p(\omega_i, |x)$  в формуле (1) и имеющиеся  $p(x|\omega_i)$ , получаемые из набора обучающих данных, связаны с теоремой Байеса:

$$p(\omega_i, |x) = p(x|\omega_i) \frac{p(\omega_i)}{p(x)}, \quad (2)$$

где  $p(\omega_i, |x)$  — апостериорная вероятность (вероятность того, что пиксел  $x$  принадлежит классу  $\omega_i$ );  $p(\omega_i)$  — априорная вероятность (вероятность того, что класс  $\omega_i$  встречается на изображении);  $p(x)$  — вероятность принадлежности пиксела  $x$  к любому классу.

Используя (2), можно представить классификационное правило в виде

$x \in \omega_i$ , если  $p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j)$  для всех  $j \neq i$ .

Метод минимальных расстояний (МР) представляет собой значительное упрощение метода максимального правдоподобия, в котором решение о принадлежности пиксела определенному классу принимается на основании сравнения метрики расстояния между яркостью пиксела и средними значениями яркостей классов в мультиспектральном пространстве

$$r_k^2 = \sum_{m=1}^n (f_{ijm} - \mu_{km}^-)^2,$$

где  $f$  и  $\mu$  – векторы признаков;  $m$  – номер спектрального канала;  $n$  – общее число каналов;  $i$  и  $j$  – координаты пиксела;  $k$  – метка класса. Пиксел ставится в соответствие тому классу, для которого значение параметра  $r_k^2$  минимально. Это простой и быстрый метод классификации, он требует минимальных сведений о классах, но проигрывает ММП в точности, так как не учитывает окружения пиксела. Вследствие этого данный алгоритм распознавания, как правило, уступает и методам кластерного анализа, и процедурам сегментации по наращиванию областей и выделению границ. Достоинством классификатора МР является то, что он может рассматриваться безотносительно к нормальному закону распределения (Кашкин, Сухинин, 2001).

Преобразовав одну из дискриминантных функций, используемых в методе максимального правдоподобия, ее можно рассматривать как квадратичную меру расстояния

$$d(x, m_i)^2 = \ln \left| \sum_i^{-1} \right| + (x - m_i)^t \sum_i^{-1} (x - m_i), \quad (3)$$

и классифицировать пикселы, используя в качестве параметра, оценивая его значение подобно евклидовой метрики для метода минимальных расстояний.

В случае тождественности ковариаций рассматриваемых классов формула (3) приводится к упрощенному виду

$$d(x, m_i)^2 = (x - m_i)^t \sum_i^{-1} (x - m_i),$$

где  $m_i$  – вектор средних значений параметров класса  $I$ ;  $x$  – набор яркостных характеристик пиксела. В классификаторе дистанции Махаланобиса (ДМ) обычно используется эта облегченная метрика, хотя иногда данный термин применяется для более общей меры расстояния, представленной в формуле (3).

Достоинством ДМ над процедурой максимального правдоподобия является значительно меньшее время выполнения и, посредством ковариационной матрицы, сохранение высокой степени чувствительности к направлению изменения признаков (Richards, Jia, 2006).

Статистические методы просты в применении, наиболее распространены в современном программном обеспечении для обработки данных ДЗЗ, но в то же время имеют существенные недостатки: необходимость априорной информации о законе распределения и больших объемах обучающих данных для определения статистических закономерностей.

### НЕЙРОСЕТЕВОЙ МЕТОД УПРАВЛЯЕМОЙ КЛАССИФИКАЦИИ

В качестве одной из непараметрических методик классификации данных ДЗЗ используются искусственные нейронные сети (НС). Значительным отличием этого метода распознавания от статических алгоритмов является то, что границы решения не фиксируются детерминированными правилами, применяемыми к характерным признакам прототипа, а определяются в итеративной форме путем минимизации критерия ошибки при обработке обучающих данных (Шовенгердт, 2010). Обычно в качестве меры погрешности берется средняя квадратичная ошибка, определяемая как сумма квадратов разностей между величиной идеального выхода  $d_i$  и реально полученными значениями  $y_i$  для каждого примера  $i$ :

$$E = \sum_{i=1}^M \frac{(d_i - y_i)^2}{M},$$

где  $M$  – количество примеров, обработанных НС. Один из вариантов базовой архитектуры нейронной сети представлен на рис. 1.

Эта сеть имеет три слоя: входной, выходной и скрытый слой. Скрытый слой состоит из узлов, содержащих обрабатывающие элементы. Узлы входного слоя, с другой стороны, просто являются интерфейсом для входных данных и не выполняют никакой обработки. Входные образы являются признаками, используемыми для классификации. В простейшем случае они представляют собой многоспектральные векторы яркости обучающих пикселов, каждый компонент которых характеризует яркость пиксела в одном из каналов. Могут быть также использованы другие признаки, такие как пространственное соседство пикселов или динамические спектральные векторы.

В пределах каждого узла обработки мы имеем дело с суммированием и преобразованием: рис. 2. В каждом  $j$ -м узле скрытого слоя выполняется следующая операция над входным образом  $p_i$ , приводящая к выходному образу  $h_j$ :

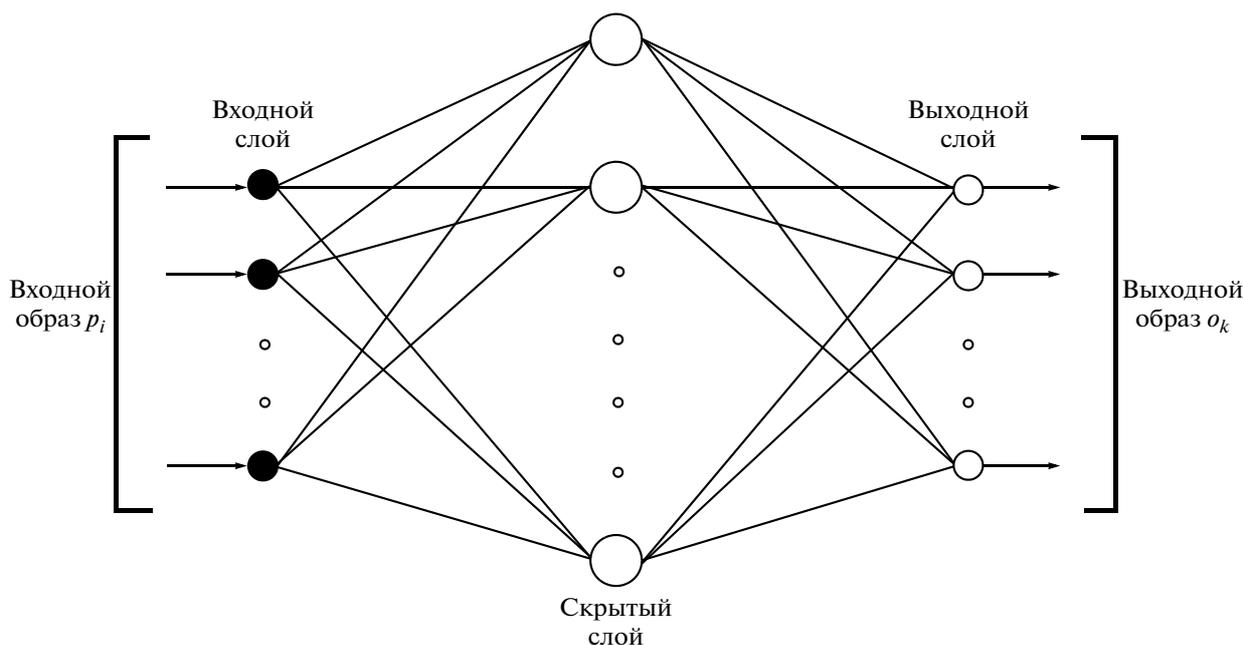


Рис. 1. Архитектура нейронной сети.

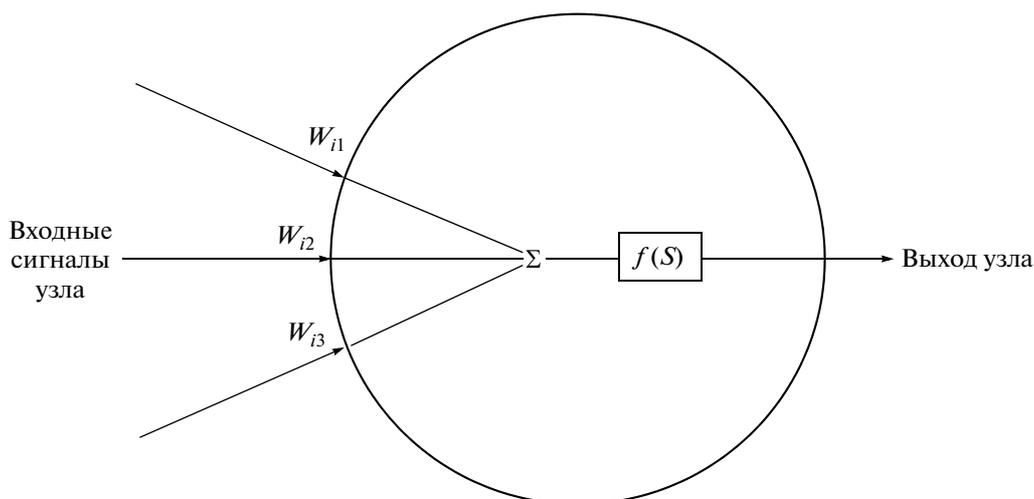


Рис. 2. Узел нейронной сети.

скрытый слой:  $S_j = \sum_i w_{ji} p_i$  и  $h_j = f(S_j)$ ,

который направлен на каждый узел выходного слоя  $k$ , где рассчитывается выходной образ  $o_k$ :

выходной слой:  $S_k = \sum_j w_{kj} h_j$  и  $o_k = f(S_k)$ .

В приведенных выше формулах входной образ  $p_i$  представлен вектором, составленным из значений яркостей пиксела в имеющихся спектральных каналах, выходной образ  $o_k$  характеризует

класс, к которому принадлежит рассматриваемый элемент. Значения  $w_{ji}$  и  $w_{kj}$  – весовые коэффициенты, рассчитываемые при обучении нейронной сети.

Наиболее широко используемой в качестве функции преобразования  $f(S)$  является сигмоидальная функция  $f(S) = \frac{1}{1 + e^{-S}}$ , представленная на рис. 3. Могут быть использованы и другие функции, например, жесткая безградиентная пороговая функция.

Возможность нейронной сети различать те или иные образы обусловлена ее весовыми коэффициентами. В процессе обучения они итеративно корректируются в направлении конфигурации, которая позволяет сети определять представляющие интерес образы прототипа. Алгоритм обратного распространения минимизирует квадратичную ошибку для всех выходных образов сети, и этот алгоритм был первым успешным подходом для обучения сети, представленной на рис. 1–3.

### РЕТРОСПЕКТИВА ПРИМЕНЕНИЯ НЕЙРОННЫХ СЕТЕЙ

Особый интерес специалистов ДЗЗ к использованию НС связан с тем, что этот подход не требует подробного априорного знания о статистическом распределении обрабатываемых данных, что позволяет не ограничиваться законом распределения случайной величины. К тому же, данный метод отличает характерный параллелизм обработки информации и относительно малое время классификации (Bischof et al., 1992).

С другой стороны, сложности при использовании нейронных сетей возникают в связи с выбором сетевой архитектуры, зависимостью результатов классификации от условий обучения и неоднозначностью интерпретации поведения НС. Исследования применимости средств искусственного интеллекта для задач ДЗ ведутся, по меньшей мере, два десятилетия, и за это время получены различные результаты.

Одна из первых попыток применения НС для классификации данных ДЗЗ описывается в публикации Decatur “Applications of neural networks to terrain classification”. В этой работе он сравнивал производительность нейронных сетей с архитектурой многоуровневый перцептрон (МП) и одним из Байесовских классификаторов (Decatur, 1989). Decatur установил, что, применяя НС с архитектурой МП, можно добиться значительного улучшения точности классификации по сравнению со статистическими методами (Roli et al., 1997).

Исследователи Lee, Bischof, Paola и Schowengerdt применяли нейронные сети для классификации изображений, полученных приборами Multispectral Scanner и Thematic Mapper спутников Landsat (Lee et al., 1990; Bischof et al., 1992; Paola, Schowengerdt, 1995). Decatur и Azimi-Sadjadi использовали нейросетевой подход для классификации данных радара с синтезированной апертурой (SAR) (Decatur, 1989; Azimi-Sadjadi et al., 1993). Нернер определил, что НС превосходят метод максимального правдоподобия в случае использования минимальных наборов обучающих данных (Нернер et al., 1990). Kanellopoulos применил нейросетевые методы для анализа временных рядов спутниковых данных и получил точность

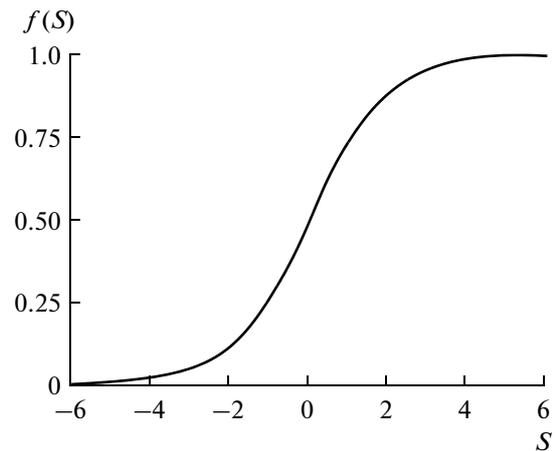


Рис. 3. Функция активации.

классификации равную 80–90% (Kanellopoulos et al., 1990, 1991).

Нейросетевые классификаторы использовались также для совместного распознавания разнотиповых данных ДЗЗ в работах Benediktsson, Ersoy и Hong, Serpico и Roli. (Benediktsson et al., 1990; Ersoy, Hong, 1990; Serpico, Roli, 1995). Позднее Benediktsson использовал нейронные сети для классификации высокоразмерных данных, полученных сканирующей системой Airborne Visible-Infrared Imaging Spectrometer (AVIRIS).

Автор Lee в работе “A neural network approach to cloud classification” описал применение МП для классификации облаков с помощью данных Landsat MSS. Его результаты показывают высокий уровень точности классификации, полученный благодаря использованию архитектуры четырехслойного перцептрона (Lee et al., 1990).

Другой исследователь — Bischof — использовал трехслойный перцептрон для классификации данных Landsat TM. Результаты его исследований, представленные в статье “Multispectral classification of Landsat images using neural networks”, показывают, что МП выполняет классификацию лучше, чем Байесовский классификатор (Bischof et al., 1992).

Исследователь Azimi-Sadjadi разработал структурированную нейронную сеть для классификации радарных изображений. Сетевая архитектура в его исследовании “Terrain classification in SAR images using principal components analysis and neural networks” содержит четыре подсети (каждая для разной поляризации радарного сигнала) и конечную сеть, которая комбинирует результаты работы подсетей для поиска решения поставленной задачи. Результаты доказывают преимущества “комбинированной поляризационной архитектуры”, использующей специфику радарных данных (Azimi-Sadjadi et al., 1993).

Исследователи Salu и Tilton в рамках работы “Classification of multispectral image data by the Binary Diamond neural network and by nonparametric, pixel-by-pixel methods” представили новую модель нейронной сети, названную “Binary Diamond Neural Network”, предназначенную для классификации данных Landsat 4 TM. Binary Diamond – это многослойная нейронная сеть с прямой связью, которая обучается на примерах в режиме “одного прохода”. Результаты их работы показывают, что НС архитектуры Binary Diamond обрабатывает данные намного лучше, чем НС структуры МП. В качестве единственного недостатка было отмечено значительное использование памяти (Salu, Tilton, 1993).

В работах Chettri предлагается вероятностный нейросетевой классификатор (PNN), предназначенный для анализа данных Landsat-2 MSS, который показал более высокую производительность, чем МП и устойчивость к изменениям весов нейронной сети при очень малом времени обучения (Chettri et al., 1992; Chettri, Cromp, 1993).

Miller, выполняя структурный анализ входных данных, использовал для обучения НС пространственные соотношения между пикселями (Miller et al., 1995).

Нейронные сети успешно использовались для классификации данных, полученных с помощью радаров с синтезированной апертурой (SAR) (Raghu, Yegnanarayana, 1997), а также для обработки многокурсовых мультиспектральных данных, полученных спектрометрическим прибором ASAS (Advanced Solid-State Array Spectroradiometer) для картографирования земной поверхности (Abuelgasim et al., 1996).

Исследователь Tatem использовал НС Хопфилда для распознавания земной поверхности с использованием данных высокого разрешения прибора High Resolution Visible (HRV) аппарата SPOT и полученных с Landsat TM изображений с.-х. территорий. Результаты представлены в публикациях “Multiple-class land cover mapping at the sub-pixel scale using a Hopfield neural network” и “Super-resolution land cover pattern prediction using a Hopfield neural network” (Tatem et al., 2001, 2002).

Исследования, проведенные Keramitsoglou в работе “Radial basis function neural networks classification using very high spatial resolution satellite imagery: an application to the habitat area of Lake Kerkini (Greece)”, были направлены на изучение потенциала применения нейронных сетей с архитектурой радиальных базисных функций (РБФ) для классификации мультиспектральных изображений высокого и сверхвысокого пространственного разрешения (1 м для панхроматического и 4 м для мультиспектрального режимов). Четыре мультиспектральных канала IKONOS-2 были настроены на детектирование спектрального излучения в видимом (0.45–0.53 (голубой), 0.52–0.61 (зеленый) и 0.64–0.72 (красный) нм), а также в ближнем ин-

фракрасном (0.77–0.88 нм) частях электромагнитного спектра. Сравнение производительности НС и метода максимального правдоподобия происходило попиксельным сравнением классифицированных изображений. Производительность классификатора нейронных сетей превзошла ММП примерно на 17%. Характеристики производительности показывают, что эксперименты, в которых для обучения нейронной сети использовались только текстурные параметры, дают меньшую точность среди всех НС-классификаторов. Однако их производительность все еще превосходит стандартный статистический алгоритм примерно на 10%. Сравнение результатов экспериментов, в которых использовалась только спектральная информация, и совокупность спектральной и текстурной информации показывает, что включение структурной информации не дало улучшения точности классификатора (Keramitsoglou et al., 2005).

Исследования, подобные данной работе, направленные на сравнение результатов классификации данных ДЗЗ различными алгоритмами в целях определения границ применимости НС, показывают широкие возможности нейронных сетей для задач распознавания, в частности, для классификации типов растительности. В качестве примера можно привести статью “The Performance of Maximum Likelihood, Spectral Angle Mapper, Neural Network and Decision Tree Classifiers in Hyperspectral Image Analysis”, где сравниваются несколько способов классификации данных ДЗЗ, – такие, как метод максимального правдоподобия (МП), метод спектрального угла (SAM), нейронная сеть и дерево решений. Для оценки производительности этих методов анализируются территорию Малазийских тропических лесов (спектрометр AISA, высота сенсора 1000 м, 20 спектральных каналов разрешением 1 м, ширина полосы обзора 360 м). Наибольшую точность показали ММП – 85.56% и НС – 83.61%, худшая производительность отмечается у SAM и DT – 48.83 и 50.67% 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. Другие классификаторы (использующие непараметрические алгоритмы) демонстрировали более высокую точность в тех случаях, когда границы решений лежали на границах распределения классов, чем когда граница решений менее определена. Это происходит, когда различные классы слабо разделены в спектральном пространстве. Полученные результаты объясняются высоким уровнем гетерогенности материалов ДЗЗ, использованных в эксперименте (Shafri et al., 2007).



Рис. 4. Исходное изображение.

Приведенные выше работы свидетельствуют об интересе исследователей к применению НС для различных задач по классификации данных ДЗ. Результаты предыдущих исследований показывают, что метод нейросетевого подхода имеет потенциал для создания классификационных алгоритмов с подобной, или даже лучшей, точностью, чем у статистических методов.

#### ОПИСАНИЕ ЭКСПЕРИМЕНТА

Целью эксперимента было сравнение точности результатов, полученных традиционными методами классификации и нейросетевого подхода на примере территории, обладающей высокой степенью гетерогенности (исследуемый район содержит смешанные типы растительности).

Для классификации был выбран космический снимок, полученный прибором ТМ спутника Landsat 5 (пять каналов, разрешение 30 м, территория Красноярского края  $59^{\circ}$ – $61^{\circ}$  с.ш. и  $87^{\circ}$ – $92^{\circ}$  в.д.). Изображение исследуемой территории представлено на рис. 4.

Для процедуры распознавания использовались алгоритмы, описанные выше: метод минимальных расстояний, расстояние Махаланобиса, классификатор максимального правдоподобия и нейронные сети.

На первом этапе была выполнена классификация исходного изображения каждым из представленных методов. Рисунок 5 характеризует зависимость между величиной средней квадратической ошибки (СКО) и количеством итераций процесса обучения нейронной сети: после 50-ти итераций процесса обучения НС величина СКО снижается до приемлемого значения, что позволяет проводить классификацию достаточного уровня точности.



Рис. 5. Зависимость СКО от количества итераций НС.

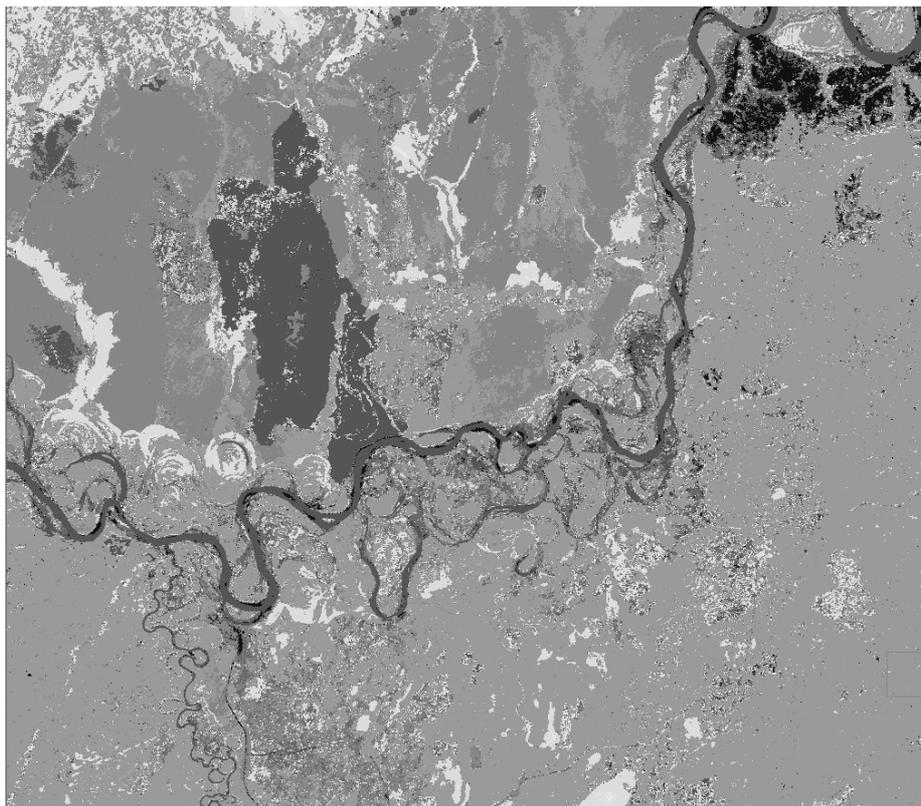


Рис. 6. Результат классификации методом максимального правдоподобия.

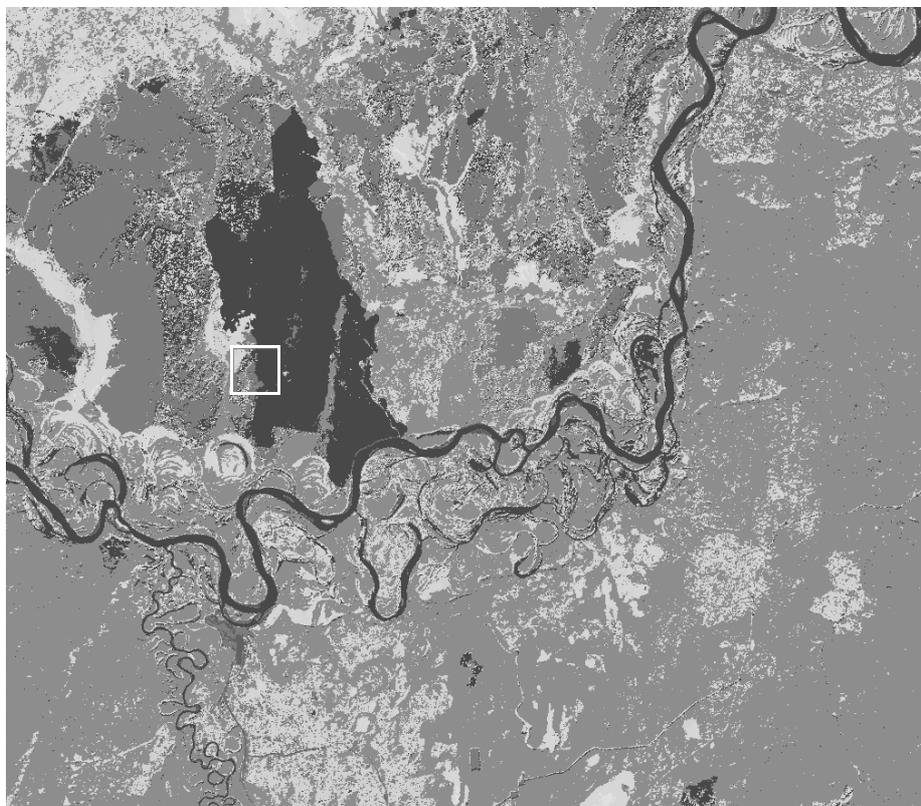


Рис. 7. Результат классификации нейросетевым методом.

Путем изменения параметров используемых алгоритмов классификации для каждого способа распознавания было получено 20 классифицированных изображений изучаемой территории. Обучение проводилось с использованием данных полевых исследований, полученных в 2011 г. На исходном изображении выделялось семь различных типов подстилающей поверхности. Использование информации пяти спектральных каналов спутника Landsat видимого, ближнего ИК- и коротковолнового ИК-диапазонов оказалось достаточно для корректного распознавания подстилающей поверхности.

Затем из этого набора путем экспертного анализа и сравнения были выбраны изображения, характеризующие классы с наивысшей точностью.

Далее проводилось сравнение результатов классификации, полученных разными методами, достигнутая точность распознавания методов представлена в таблице.

На рис. 6 представлено изображение, отклассифицированное методом максимального правдоподобия, на рис. 7 – нейронной сетью.

### ЗАКЛЮЧЕНИЕ

В рамках данной работы было проведено исследование применимости нейронных сетей для классификации данных ДЗЗ. Для этой цели были изучены публикации, посвященные применению нейросетевого подхода к дешифрированию космических снимков и данных аэрофотосъемки. Эти исследования, проводимые на протяжении почти четверти века, свидетельствуют о значительном интересе специалистов в области ДЗЗ к использованию нейронных сетей, а их результаты показывают большой потенциал этого метода и широкие границы применимости.

Помимо исследования ретроспективы применения нейронных сетей и оценки их результатов, был выполнен практическое сравнение статистических способов управляемой классификации и нейросетевого метода путем оценки точности классификации данных ДЗЗ высокой гетерогенности, характеризующих территорию Центрально-Сибирской тайги.

Проведенный анализ подтвердил широкие возможности нейронных сетей по распознаванию данных ДЗЗ. Точность этого метода составила 91%. Метод максимального правдоподобия показал меньшую точность, равную 82%, незначительно превзойдя классификатор дистанции Махаланобиса, – 78%. Самый простой алгоритм классификации – метод минимальных расстояний, как и ожидалось, продемонстрировал худшую производительность – 64%.

Как видно из показателей точности распознавания, закон нормального распределения, чаще всего присущий гетерогенным данным, не обеспечил ста-

Точность результатов классификации

Классификатор	Средняя точность классификации, %
Метод минимальных расстояний	64
Дистанция Махаланобиса	78
Метод максимального правдоподобия	82
Нейронная сеть	91

тистическим алгоритмам преимущества перед нейросетевым подходом. Нейросетевой алгоритм может обеспечить высокий уровень распознавания в случаях неприменимости нормального закона распределения к исследуемой информации, что актуально, к примеру, для материалов ДЗЗ приборов с синтезируемой апертурой (SAR). Неправильное задание и неточная оценка функции распределения играет решающую роль в точности распознавания статистических алгоритмов (Roli et al., 1997).

Наилучшее качество распознавания показала нейронная сеть следующей конфигурации: один скрытый слой, логистическая функция активации, 100 итераций процесса обучения, значение порога воздействия 0.05, коэффициент обучения 0.05, тренировочный шаг 0.05.

Результаты данной работы показывают, что нейронные сети имеют большой потенциал для использования в качестве методов классификации данных ДЗЗ. Однако следует отметить, что процесс распознавания с помощью нейронной сети занял гораздо больше времени, чем использование статистических алгоритмов, 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.

### СПИСОК ЛИТЕРАТУРЫ

- Кашкин В.Б., Сухинин А.И.* Дистанционное зондирование Земли из космоса. Цифровая обработка изображений: Уч. пос. М.: Логос, 2001. С. 264.
- Шовенгердт Р.А.* Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера, 2010. С. 560.
- Abuelgasim A.A., Gopal S., Irons J.R., Strahler A.H.* Classification of ASAS multiangle and multispectral measurements using artificial neural networks // *Rem. Sens. Env.* 1996. V. 57. P. 79–87.
- Azimi-Sadjadi M.R., Ghaloum S., Zoughi R.* Terrain classification in SAR images using principal components analysis and neural networks // *IEEE Trans. Geosc. Rem. Sens.* 1993. V. 31. P. 511–515.
- Benediktsson J.A., Swain P.H., Ersoy O.K.* Neural network approaches versus statistical methods in classification of multisource remote sensing data // *IEEE Trans. Geosc. Rem. Sens.* 1990. V. 28. № 4. P. 540–552.

- Bischof H., Schneider W., Pinz A.J.* Multispectral classification of Landsat images using neural networks // IEEE Trans. Geosci. Rem. Sens. 1992. V. 30. P. 482–490.
- Chettri S.R., Cromp R.F.* Probabilistic neural network architecture for high-speed classification of remotely sensed imagery // Telemat. Inform. 1993. V. 10. P. 187–198.
- Chettri S.R., Cromp R.F., Birmingham M.* Design of neural networks for classification of remotely sensed imagery // Telemat. and Inform. 1992. V. 9. P. 145–156.
- Decatur S.E.* Applications of neural networks to terrain classification // Proc. Intern. Joint Conf. Neural Networks. 18–22 Jun 1989. Washington DC, USA, 1989. P. 283–288.
- Ersoy O.K., Hong D.* Parallel, self-organizing, hierarchical neural networks // IEEE Trans. Neur. Net. 1990. V. 1. P. 167–178.
- Hepner G.F., Logan T., Ritter N., Bryant N.* Artificial neural network classification using a minimal training set: comparison to conventional supervised classification // Photogram. Eng. and Rem. Sens. 1990. V. 56. № 4. P. 469–473.
- Jain A.K., Dubes R.C.* Algorithms for Clustering Data // NJ: Prentice Hall, 1988. P. 320.
- Jensen J.R.* Introductory Digital Image Processing. Third Edition // NJ: Prentice Hall, 2004. P. 544.
- Kanellopoulos I., Varfis A., Wilkinson G.G., Megier J.* Land-cover discrimination in SPOT–HRV imagery using artificial neural network: a 20-class experiment // Intern. J. Rem. Sens. 1990. V. 13. P. 917–924.
- Kanellopoulos I., Varfis A., Wilkinson G.G., Megier J.* Neural network classification of multi-date satellite imagery // Proc. Intern. Geosci. Rem. Sens. Symp. (IGARSS'91). 3–6 Jun 1991. Espoo, Finland, 1991. V. 4. P. 2215–2218.
- 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. Rem. Sens. 2005. V. 26. № 9. P. 1861–1880.
- Lee J., Weger R.C., Sengupta S.K., Welch R.M.* A neural network approach to cloud classification // IEEE Trans. Geosci. Rem. Sens. 1990. V. 28. P. 846–855.
- Memarsadeghi N., Mount D.M., Netanyahu N.S., Le Moigne J.* A fast implementation of the ISOCLUS algorithm. // Proc. Intl. Geosci. Rem. Sens. Symp. (IGARSS'03). 21–25 July 2003. Toulouse, France, 2003. V. 3. P. 2057–2059.
- Miller D.M., Kaminsky E.J., Rana S.* Neural network classification of remote-sensing data // Comput. and Geosci. 1995. V. 21. P. 377–386.
- Paola J.D., Schowengerdt R.A.* A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification // IEEE Trans. Geosci. Rem. Sens. 1995. V. 33. P. 981–996.
- Raghu P.P., Yegnanarayana B.* Multispectral image classification using Gabor filters and stochastic relaxation neural network // Neural Networks. 1997. V. 10. P. 561–572.
- Richards J.A., Jia X.* Remote Sensing Digital Image Analysis. An Introduction. Fourth Edition. Heidelberg: Springer, 2006. P. 454.
- Roli F., Giacinto G., Vernazza G.* Comparison and combination of statistical and neural network algorithms for remote-sensing image classification // Neurocomputation in remote sensing data analysis: processing of concerted action COMPARES (connectionist methods for pre-processing and analysis of remote sensing data) / Eds. I. Kanellopoulos, G.G. Wilkinson, F. Roli, J. Austin. Heidelberg: Springer, 1997. P. 117–125.
- Salu Y., Tilton J.* Classification of multispectral image data by the binary diamond neural network and by nonparametric, pixel-by-pixel methods // IEEE Trans. Geosci. Rem. Sens. 1993. V. 31. P. 606–617.
- Serpico S.B., Roli F.* Classification of multisensory remote-sensing images by structured neural networks // IEEE Trans. Geosci. Rem. Sens. 1995. V. 33. P. 562–578.
- 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. Comp. Sci. 2007. V. 3. № 6. P. 419–423.
- Tatem A.J., Lewis H.G., Atkinson P.M., Nixon M.S.* Multiple-class land cover mapping at the sub-pixel scale using a Hopfield neural network // Intern. J. App. Earth Obs. Geoinf. 2001. V. 3. P. 184–190.
- Tatem A.J., Lewis H.G., Atkinson P.M., Nixon M.S.* Super-resolution land cover pattern prediction using a Hopfield neural network // Rem. Sens. Env. 2002. V. 79. P. 1–1.

## A Comparison of Statistical and Neural Network Approaches for Classification of remote Sensing Data Using Landsat 5 Images Characterized Territory of High Heterogeneity

A. A. Romanov, K. A. Rubanov

*Institute of Space and Information Technology Siberian Federal University, Krasnoyarsk*

The aim of this study is analysis the efficiency of using neural networks (NN) for the classification of remote sensing data (RSD). This paper contains the definition of conventional classification methods and presents the description of neural network approach. Also it presents the retrospective review of using this approach for RSD processing tasks. In addition the results of practical research applicability of NN method for territory of high heterogeneity are presented in this study. The accuracy of recognition of land cover types was obtained by NN is 91%. This value better than results of other methods: maximum likelihood classifier (82%), Mahalanobis distance (78%), minimum distance (64%). The results show that the normal distribution is usually character for high heterogeneity data doesn't always provide with better accuracy for statistical algorithms. The architecture of NN is suitable for classification of high heterogeneity RSD is proposed.

**Keywords:** remote sensing, supervised classification, neural networks, statistical algorithms, Landsat 5, thematic decoding