



КЛАССИФИКАЦИЯ АРЕАЛОВ РАСПРОСТРАНЕНИЯ РЕДКИХ ТИПОВ РАСТИТЕЛЬНОСТИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННОЙ СЕТИ

Е.М. Гамбарова

Научно-исследовательский институт аэрокосмической информатики,
Национальное Аэрокосмическое Агентство, Азербайджан
г.Баку, Азербайджан, проспект Азадлыг 159
e-mail: YLebedik@azuni.net

Резюме: В данной работе были рассмотрены 3 варианта обучения нейронного классификатора Многослойный Перцептрон для решения задачи классификации редких типов растительности и почв, присутствующих на многоспектральных снимках высокого разрешения, полученных со спутника IKONOS. Были определены 12 типов редкой растительности и почв и на их основе построены классификационная схема по 12-ти классам (“Основная”) и две дополнительные – “Модифицированная” (по 7-ми классам) и “Оптимальная” – по 5-ти классам. Используя Геоинформационные технологии детально представлен визуальный анализ картин, представляющих тематические растры результатов классификации и количественные оценки неклассифицированных и нечетко классифицированных элементов сцены.

Ключевые слова: классификация изображений, нейронные сети, IKONOS.

ВВЕДЕНИЕ

Современные технические средства космических исследований природной среды позволяют получать снимки высокого разрешения. Обработка таких космических снимков, включая решение задач распознавания и классификации объектов, требует разработки и применения новейших информационных технологий, включая технологию искусственных нейронных сетей.

Основная задача дистанционного зондирования (ДЗ) – распознавание образов или классификация объектов на сцене, представленной на многоспектральном снимке, полученным методами дистанционного сканирования Земной поверхности. Основной проблемой при решении этой задачи является построение гибкого, самоадаптируемого к конкретным условиям классификатора. Проведенные исследования показали, что наиболее перспективным классификатором с точки зрения гибкости и адаптируемости, для решения задач ДЗ является классификатор, базирующийся на искусственных нейронных сетях (ИНС).

Теоретически ИНС – классификаторы способны решать сколь угодно сложные корректно поставленные задачи классификации,

однако, чем сложнее поставленная задача, тем сложнее архитектура или топология ИНС и, соответственно, требуется больше вычислительных ресурсов для её реализации. Нами исследованы два основных пути оптимизации процессов построения или, точнее говоря, обучения ИНС – классификаторов.

Первый путь – оптимизация выбора тренировочных образцов для обучения и подбор минимального информативного набора признаков или входных нейронов.

Количество нейронов в исходном слое во многом предопределяет сложность архитектуры нейронной сети, а количество образцов и сложность архитектуры ИНС определяют объем вычислений при обучении классификатора. Использование ортогональных базисов для преобразований в пространстве признаков способствует решению задачи нахождения порога генерализации при составлении исходного множества обучающих примеров.

Второй путь оптимизации – это использование теоретико-числовых методов при выполнении линейной части преобразований – так называемой процедуры взвешенного суммирования нейронов. Эти преобразования повторяются при многочисленных итерациях и требуют огромного числа вычислений на числах с плавающей запятой. Замена такого рода

вычислений операциями над целыми числами приводит к значительному ослаблению требований к вычислительным ресурсам.

Среди нестатистических подходов мы рассмотрели классификаторы, построенные на искусственных нейронных сетях (ИНС). Это обусловлено несколькими причинами:

- Этот подход базируется на удачном примере математической формализации чисто человеческого способа анализа и классификации.
- Математический аппарат теории искусственных нейронных сетей позволяет получать решения сколь угодно сложной задачи классификации при условии, что задача поставлена корректно, в том смысле, что тренировочные образцы используемые для обучения должны отличаться друг от друга.
- Несмотря на то, что теория математического аппарата ИНС имеет достаточно длительную историю, возможности её использования в задачах ДЗ сдерживались отсутствием современных средств вычислительной техники и соответствующего программного обеспечения. Вследствие этого, проблема применения ИНС в задачах разработки законченной методики построения классификаторов для обработки многоспектральных космических снимков высокого разрешения не решалась.

В отличие от статистических методов, ИНС подробно и детально исследует информацию, имеющуюся в самих данных, не делая при этом предположения о характере распределения вероятностей или о функциях плотности вероятностей. ИНС раскрывает или находит закономерность, скрытую во входных множествах данных через итеративную процедуру обучения, используя при этом различные нейронные топологии.

В операциях с применением ИНС, как и во всех классификационных процедурах с обучением, есть две главные фазы: фаза обучения и фаза исполнения. В фазе обучения данные повторно – при каждой итерации заново – представляются к сети, меняются только их веса, которые вместе с данными используются в вычислениях для получения ожидаемого результата. В фазе исполнения обученная сеть с установленными весами применяется к данным, которые не участвовали в процессе обучения. Стадия обучения требует большого количества исходных данных и, соответственно, больших вычислительных мощностей, что присуще итеративным методам поиска наилучшего решения. Но как только сеть обучена, фаза

исполнения может быть проведена очень быстро, так как происходит единое математическое преобразование одного множества в другое. ИНС, несомненно, является мощным, а в некоторых случаях единственным средством для проведения классификационной процедуры.

Известно, что основными исходными данными ДЗ являются многоспектральные снимки земной поверхности, получаемые в различных спектральных каналах электромагнитного спектра.

Данные, относящиеся к многоспектральным снимкам и отличающимся датами съемок, относятся к ретроспективным спектральным данным. Существуют также и производные от спектральных данных – различные вегетационные индексы, индексы почвенной яркости, зелености растительной массы и т.д. Все исходные данные могут быть различных численных типов (номинальными, интервальными или относительными), по-разному нормализованы, но они должны быть пространственно привязаны друг к другу.

Отметим, что данные ДЗ, которые можно пространственно привязать к спектральным, но получаемые не из многоспектральных космических снимков, а из других источников мы будем называть дополнительными. Так, к дополнительным данным относятся данные, содержащиеся в картах землепользования и топографических картах, а также данные, полученные из космоснимков, но не связанные с отражательными свойствами поверхности Земли: например, модели рельефа местности и их производные.

Безусловно, самыми важными данными для мониторинга ситуации на исследуемой территории, которые собственно и характеризуют процессы изменений, являются спектральные данные. Выбор процедуры классификации, в первую очередь, ориентируется на эти данные. Исходные данные являются базовыми из которых можно составить другие данные, которые поступают на вход классификатора. Эти данные и называются признаками или исходными признаками.

Определение оптимального числа входных нейронов (исходных признаков) является одним из первых шагов при построении структуры ИНС. Метод, используемый при выборе оптимальных входов (*optimum inputs*), известный как *метод выбора исходных признаков (feature selection techniques)*, был рассмотрен в [1]. В статье исследованы различные варианты комбинаций спектральных каналов (*spectral bands*) и выбраны “как лучшие” для нейронной сети.

В роли исходных признаков могут выступать производные от спектральных данных (вегетативные индексы, индексы почвенной яркости и др.), как это показано в [2]. В этой статье авторы используют модель нейронной сети Многослойный Перцептрон (*MLP*), в которой входными признаками являются значения *нормализованного вегетативного индекса NDVI (Normalized Difference Vegetation Index)*, индекс *EVI (Enhanced Vegetation Index)*, а также данные спектральных каналов: красный (*RED*) и ближний инфракрасный (*NIR*). Авторы предложили несколько моделей *MLP* (с комбинацией исходных признаков *NDVI, EVI*) и провели анализ работ этих классификаторов, которые показали разную степень точности классификации (*level of classification accuracy*).

Метод улучшения работы нейронной сети путем использования многоспектральных данных и дополнительных данных ДЗ, полученных из разных источников и рассматриваемых в качестве исходных признаков, представлен в [3], где исследованы принципы работы классификаторов (ИНС и *Максимального Правдоподобия (Maximut*

Likelihood)) по распознаванию сельскохозяйственных культур.

1. ОБЩАЯ ПОСТАНОВКА ЗАДАЧИ КЛАССИФИКАЦИИ РЕДКИХ ТИПОВ РАСТИТЕЛЬНОСТИ И ПОЧВ

В работе исследованы принципы обучения нейронного классификатора типа Многослойный Перцептрон и дана оценка качества его работы для распознавания и классификации объектов на космических снимках высокого разрешения (*IKONOS*). Для экспериментальных исследований был использован многоспектральный снимок юго-восточной части Азербайджана, полученный со спутника *IKONOS* для участка территории 10×10 км.

Изначально были определены 12 типов редкой растительности и почв, динамика изменения ареалов распространения которых, по мнению экологов, является индикатором, отражающим антропогенное воздействие на природу изучаемой территории. Ниже в таблице 1 приведены названия (в скобках латинские варианты) этих типов растительности и почв.

Таблица 1. Первоначальный набор классов- 12 типов растительности и почв.

Номер класса	Полное название растений
Класс 1	Болотистая тростниковая растительность
Класс 2	Болотистый кустарниковый тамариск (<i>Tamarix</i>)
Класс 3	Прибрежная зона: полупустынная растительность
Класс 4	Тростник ложный австралийский (<i>Phragmites australis</i>)
Класс 5	Солянка древовидная (<i>Salsola ericoides</i>)
Класс 6	Солянка гористая (<i>Salsola nodulosa</i>)
Класс 7	Солянка гористая (<i>Salsola nodulosa</i>) / Польша Лерха (<i>Artemisia lerchiana</i>)
Класс 8	Солянка гористая (<i>Salsola Nodulosa</i>) / Трава
Класс 9	Полупустынная растительность – поташник каспийский, (<i>Kalidium caspicum</i>)
Класс 10	Полупустынная растительность с доминированием Верблюжьей колючки (<i>Alhagi pseudoalhagi</i>)
Класс 11	Голая почва
Класс 12	Солянка гористая (<i>Salsola nodulosa</i>) / голая почва

Выбор оптимального числа тренировочных примеров на стадии обучения нейронного классификатора оказывает влияние на конечный результат работы любого классификатора. Несмотря на то, что в большинстве случаев размер тренировочных примеров ограничен, сам дизайн (структура) нейронной сети частично основана на их оптимальном выборе.

В литературе существует несколько эвристических попыток определения

оптимального числа примеров в связи с размером сети и степенью точности классификации [4], [5], [6].

В таблице 2 приведены количественные данные по множествам извлеченных из снимка примеров по различным классам. В таблицу 2 добавлены статистические характеристики для предварительных оценок по репрезентативности классов.

Таблица 2. Размеры тренинговых и тестовых образцов для 12 типов растительности и почв.

Номер класса	Количество примеров для обучения	Количество примеров для тестирования
Класс 1	1215	1487
Класс 2	3181	2087
Класс 3	97	63
Класс 4	1891	2055
Класс 5	234	279
Класс 6	2393	2867
Класс 7	690	478
Класс 8	200	147
Класс 9	52	49
Класс 10	40	28
Класс 11	474	553
Класс 12	680	579
Общее	11147	10672
Математическое ожидание	928.9167	889.3333
Средне-квадратическое отклонение	1036.354	976.7583

С помощью статистических характеристик обучающие образцы прошли тесты на репрезентативность и разделяемость по четырем спектральным каналам. Эти тесты показали сильную перекрываемость классов и тем самым

подказали нам один из возможных вариантов модификации исходной классификационной схемы. В таблице 3 показан алгоритм этой модификации.

Таблица 3. “Модифицированный набор” из 7-ми классов- типов растительности и почв.

Номер класса	Полное название растений
Класс 7_1	Исх. Класс 1 + Исх. Класс 4 – Болотистая тростниковая растительность + Тростник ложный австралийский (<i>Phragmites australis</i>)
Класс 7_2	Исх. Класс 2 – Болотистый кустарниковый тамариск (<i>Tamarix</i>)
Класс 7_3	Исх. Класс 3 + Исх. Класс 9 + Исх. Класс 10 – Полупустынные растительности: Прибрежной зоны + Поташник каспийский (<i>Kalidium caspicum</i>) + Верблюжья колючка (<i>Alhagi pseudoalhagi</i>)
Класс 7_4	Исх. Класс 5 + Исх. Класс 6 – Солянка древовидная (<i>Salsola ericoides</i>) + Солянка гористая (<i>Salsola nodulosa</i>)
Класс 7_5	Исх. Класс 7 + Исх. Класс 8 – Солянка гористая (<i>Salsola nodulosa</i>) / Полынь Лерха (<i>Artemisia lerchiana</i>) + Солянка гористая (<i>Salsola Nodulosa</i>) / Трава
Класс 7_6	Исх. Класс 11 – Голая почва
Класс 7_7	Исх. Класс 12 – <i>Salsola nodulosa</i> / голая почва

Используя этот алгоритм, мы создали новые классы, извлекая примеры из одного или нескольких классов исходной классификационной схемы. После создания этого набора мы применили по отношению к нему подобный анализ по статистическим

характеристикам по четырем каналам, который показал нам возможность дальнейшей модификации уже 7-ми классовой схемы. Таким образом, мы получили новый набор, состоящий уже из 5-ти классов, показанный в таблице 4.

Таблица 4. “Оптимальный набор” обучающих примеров по 5-ти классовой схеме.

Номер класса	Полное название растений
Класс 1	Исх. Класс 1 + Исх.Класс 4 – Chal Meadow/Камышовые болота + Камышовые <i>Phragmites australis</i>
Класс 2	Исх. Класс 2 – Chal Meadow/ <i>Tamarix Scrub</i>
Класс 3	Исх.Класс 5 + Исх. Класс 6 + Исх. Класс 7 + Исх. Класс 8 – Солянка древовидная (<i>Salsola ericoides</i>) + Солянка гористая (<i>Salsola nodulosa</i>) + Солянка гористая (<i>Salsola nodulosa</i>) / Полынь Лерха (<i>Artemisia lerchiana</i>) + Солянка гористая (<i>Salsola Nodulosa</i>) / Трава
Класс 4	Исх. Класс 11 – Голая почва
Класс 5	Исх. Класс 12 – <i>Salsola nodulosa</i> / голая почва

Все это было сделано до начала процедуры обучения нейронного классификатора с целью определения границ возможных изменений классификационной схемы. Так как одновременное определение хода развития обучения нейронных классификаторов является невозможным, желательно заранее задавать возможные направления изменений множеств обучающих примеров. В нашем случае возможными направлениями изменений являются два дополнительных набора множеств обучающих примеров – две дополнительные классификационные схемы.

2. РЕЗУЛЬТАТЫ ОБУЧЕНИЯ КЛАССИФИКАТОРА

Архитектура нейронного классификатора МСП представлена на рис. 1.

Входной слой состоит из 4-х нейронов, соответствующих 4-м спектральным каналам (red, green, blue and near infrared (NIR)); скрытый – из 25 нейронов; выходной – из 12 нейронов, соответствующий 12 классам для распознавания. Активационная функция нейронов – гиперболический тангенс. Для обучения нейронной сети использовался алгоритм обратного распространения ошибок.

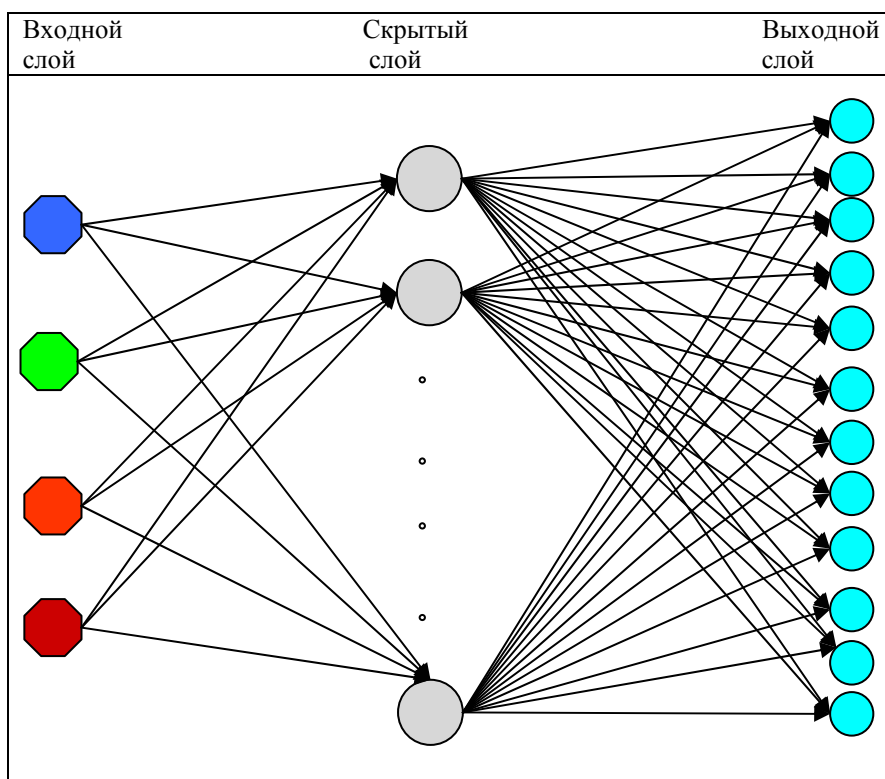


Рис. 1 – Архитектура нейронной сети.

Результаты показали, что использование нейронной сети с установкой оптимальных значений параметров сети (число нейронов скрытого слоя, количество весовых коэффициентов сети) обеспечивает более высокую точность классификации при решении проблем распознавания объектов с космических снимков высокого разрешения [4].

Во всех 3-х проведенных нами экспериментах у нас был набор постоянных параметров обучения для классификатора МСП, который представлен ниже вместе с параметрами качества.

Качество классификатора мы определяли через каждые 2500 итераций вплоть до достижения порога ошибки (0.01). При этом мы использовали следующие параметры качества:

- MSE – среднеквадратическая ошибка при достижении двойной кратности порога ошибки (0.01), обучение останавливалось.
- r – коэффициент корреляции между реальным выходом сети и ожидаемым.
- %err – процент погрешности, определяющий погрешность на единицу элемента, по которому вычисляются ошибки.

2.1. Результаты обучения – Вариант 1.
Первоначальная классификационная
схема (12 классов)

В результате обучения нейронного классификатора МСП на тренировочных образцах по 12-ти классам после проведения максимального количества итераций, мы составили матрицу неточностей (*confusion matrix*) [7] с результатами распознавания примеров из тех же тренировочных образцов (т.н. самотестирование). Из этой таблицы мы произвели оценку общего уровня корректности (ОУК) по формуле:

$$\text{ОУК} = 100\% * (\text{КПКП} / \text{ОКП}),$$

где КПКП – количество правильно отклассифицированных примеров;

ОКП – общее количество примеров.

Это значение оказалось равным 91.63%. На первый взгляд, (ОУК) достаточно высок, однако это было связано с высокими процентами корректного распознавания примеров из таких многозаселенных классов, как 1-й, 2-й и 6-й классы. По отдельным классам, таким как 3-й и 10-й, результаты классификации оказались непредсказуемыми. А 8-ой класс серьезным образом заслонился 7-м классом. По классам 11 и 12 результаты оказались такими же высокими, как для классов 1, 2 и 6. Также была обнаружена взаимная перекрываемость классов 1, 2 и 4, с одной стороны, и классов 5, 6, 7 и 8 – с другой.

Ниже приведены параметры обучения, при которых получены данные результаты, а также параметры качества, зафиксированные при максимальном количестве итераций (Таблица 5,6).

Хоть и достигнут максимальный порог итераций, средне-квадратическая ошибка *MSE* далека от достижения своего порога – 0.01, значение *r* достаточно далеко от оптимальных значений (около единицы), а погрешность на единицу элемента *%err* велика (таблица 7).

Все приведенные факторы указывают на то, что процесс обучения по данной классификационной схеме не является успешным.

Далее мы осуществили тестирование этого же классификатора по тестовым образцам, составленные из примеров, которые в обучении классификатора никаким образом не участвовали. Результаты, как и ожидалось, существенно ухудшились. Так, значение (ОУК) стало равным 81.39%, а картина недостатков существенно не изменилась.

Таблица 5. Параметры обучения

Название	Значение
Исходные веса	[0, 0.05]
Количество исходных нейронов	4
Количество скрытых слоев	1
Количество нейронов в скрытом слое	25 – для “основного набора” 50 – для “расширенного набора”
Скорость обучения между входным и скрытым слоями	0.5
Моментум между входным и скрытым слоями	0.7
Скорость обучения между скрытым и выходным слоями	0.25
Моментум между скрытым и выходным слоями	0.7
Вид и тип передаточной функции	гиперболический тангенс
Порог ошибки ϵ_{thresh}	0.01

Таблица 6. Количество итераций и параметры качества для тренировочных образцов (по 12-ти классам)

Название	Значение
Количество итераций – N_{iter}	25000
Средне-квадратическая ошибка – <i>MSE</i>	0.0382
Коэффициент корреляции – <i>r</i>	0.7822
Погрешность на единицу элемента – <i>%err</i>	1.2823

Хоть и достигнут максимальный порог итераций, средне-квадратическая ошибка *MSE* далека от достижения своего порога – 0.01, значение *r* достаточно далеко от оптимальных значений (около единицы), а погрешность на единицу элемента *%err* велика (таблица 7).

Все приведенные факторы указывают на то, что процесс обучения по данной классификационной схеме не является успешным.

Далее мы осуществили тестирование этого же классификатора по тестовым образцам, составленные из примеров, которые в обучении классификатора никаким образом не участвовали. Результаты, как и ожидалось, существенно ухудшились. Так, значение (ОУК) стало равным 81.39%, а картина недостатков существенно не изменилась.

Таблица 7. Количество итераций и параметры качества для тестовых образцов (по 12-ти классам)

Название	Значение
Количество итераций – N_{iter}	25000
Средне-квадратическая ошибка – MSE	0.0795
Коэффициент корреляции – r	0.6960
Погрешность на единицу элемента – %err	1.9938

Эти результаты подтвердили сделанные на основе предварительных тестов выводы о неадекватности исходной 12-ти классовой классификационной схемы.

2.2. Результаты обучения. Вариант 2. Процедура обучения по 7-ми классовой схеме

Для этого варианта показано, что: ОУК = 94.61% для тренировочных образцов и ОУК = 85.8% для тестовых образцов. Более детально результаты расчетов суммированы в Таблицах 8 и 9.

Таблица 8. Количество итераций и параметры качества для тренировочных образцов (по 7-классам)

Название	Значение
Количество итераций – N_{iter}	25000
Средне-квадратическая ошибка – MSE	0.0417
Коэффициент корреляции – r	0.8898
Погрешность на единицу элемента %err	1.4983

Таблица 9. Количество итераций и параметры качества для тестовых образцов (по 7-классам)

Название	Значение
Количество итераций – N_{iter}	25000
Средне-квадратическая ошибка – MSE	0.0983
Коэффициент корреляции – r	0.7734
Погрешность на единицу элемента %err	2.5686

Процесс обучения для этого варианта был достаточно эффективным: имелись лишь небольшие перекрытия пар классов 1 и 2, 4 и 5, что было ожидаемо. С другой стороны, рассмотрение значений параметров качества выявило более усложненную картину событий. Так, средне-квадратическая ошибка *MSE* увеличилась по сравнению с аналогичным самотестированием работы классификатора,

обученного по 12-ти классовой схеме. И хотя коэффициент корреляции *r* увеличился, что указывает на большую устойчивость в процедуре обучения, однако в целом погрешность на единицу элемента %err также увеличилась, а это указывает на то, что скорость улучшения качества обучения отстает от скорости уменьшения неопределенности работы классификатора.

Процесс тестирования подтвердил эту неоднозначность. Как и ожидалось, (ОУК) заметно снизился и упал на существенно более низкий уровень, чем желаемый 90%-ный порог. Кроме того, выявились большое значение *MSE* и низкая устойчивость процедуры обучения, на что указывает достаточно низкое значение *r* и еще более высокая погрешность на единицу элемента %err.

Выводы, сделанные по результатам тестирования работы нейронного классификатора, обученного по 7-ми классовой классификационной схеме, в основном подтвердили результаты предварительных статистических тестов о целесообразности рассмотрения 5-ти классовой схемы.

2.3. Результаты обучения – Вариант 3. Процедура обучения по 5-ти классовой схеме

Для этого варианта обучения максимальный порог количества итераций был снижен до 15000 шагов, т.к. задолго до этого процесс приобретал устойчивый характер и характер распределения тестовых примеров по классам, а также параметры качества практически не менялись для нейронного классификатора на тренировочных примерах.

Перекрестные таблицы неточностей (матрицы вероятностей перепутывания), полученные в ходе обучения и тестирования классификатора из “Оптимального набора” (5 классов) показали, что ОУК= 96.37% для тренировочных образцов и ОУК = 91.45% при тестировании. Результаты расчетов для этого варианта суммированы в таблицах 10, 11.

Таблица 10. Количество итераций и параметры качества для тренировочных образцов (по 5-ти классам)

Название	Значение
Количество итераций – N_{iter}	15000
Средне-квадратическая ошибка – MSE	0.0361
Коэффициент корреляции – r	0.9632
Погрешность на единицу элемента %err	1.503

Таблица 11. Количество итераций и параметры качества для тестовых образцов (по 5-ти классам)

Название	Значение
Количество итераций – $N_{итер}$	15000
Средне-квадратическая ошибка – MSE	0.0745
Коэффициент корреляции – r	0.9107
Погрешность на единицу элемента %err	2.0283

Есть небольшое перекрытие между 1-м и 2-м классами (однако это в рамках допустимых границ). Что касается параметров качества, то здесь заметны определенные недостатки. Речь касается среднеквадратической ошибки, значение которой заметно выше установленного минимального порога 0.01. Однако высокое значение коэффициента корреляции r отражает факт, что на данном этапе процесс обучения приобрел очень устойчивый характер. Этот факт, в свою очередь, указывает на то, что в ходе обучения обнаружены определенные закономерности и процесс адаптации классификатора к этим закономерностям происходит успешным образом.

Подытоживая результаты тестирования классификатора, обученного на примерах 5-ти классов классификационной схемы, можно сказать, что, несмотря на обнаруженные неоднозначности при классификации и не идеальные значения параметров качества, можно надеяться, что эти недостатки могут быть преодолены с помощью привлечения в процедуру классификации дополнительных пространственных данных (цифровые модели рельефа, карты землепользования и т.д.).

3. ОЦЕНКА РАБОТЫ КЛАССИФИКАТОРОВ ПОСЛЕ ПРОВЕДЕНИЯ АВТОМАТИЧЕСКОЙ КЛАССИФИКАЦИИ. ВИЗУАЛЬНЫЙ АНАЛИЗ РЕЗУЛЬТАТОВ КЛАССИФИКАЦИИ

Для проведения сравнительного анализа работы классификаторов, обученных по различным классификационным схемам на реальных примерах, когда заранее не известна их настоящая принадлежность, методы оценки, применяемые при оценке качества обучения классификаторов не являются пригодными. В обычной практике, при приеме/сдачи результатов классификации используются различного рода верификации. Они заключаются

в том, что принимающая работу сторона определяет верификационные примеры, количество и способ отбора которых на сцене заранее обговаривается с исполнителем работы. На этих примерах производятся тестирование, аналогично проведенным тестам во время обучения и по которым можно сделать точные количественные оценки качества работы классификаторов. В исследовательской же практике, тестирование верификационных примеров ни чем не отличается от тестирования тестовых тех же примеров.

Имеются другие, менее строгие способы оценки качества работы классификаторов. Этими способами являются визуальный анализ картин, представляющих тематические растры результатов классификации, и количественные оценки неклассифицированных и нечетко классифицированных элементов сцены. В своем анализе мы, наряду с тестированием верификационных примеров, использовали и эти способы.

После проведения процедуры обучения по двум классификационным схемам, по ним были проведены автоматические классификации по всей сцене, охватываемой космоснимком (многоспектральный снимок со спутника IKONOS, 110 км²) для распознавания объектов из соответствующих классов. Для проведения сравнительного анализа работы классификаторов, обученных по различным классификационным схемам на реальных примерах, когда заранее не известна их настоящая принадлежность, методы оценки, применяемые при оценке качества обучения классификаторов, не являются пригодными. Однако имеются другие, менее строгие способы оценки качества работы классификаторов, но которые являются достаточно продуктивными для решения ряда задач по данному анализу. Этими способами являются визуальный анализ картин, представляющих тематические растры результатов классификации и количественные оценки неклассифицированных и нечетко классифицированных элементов сцены с активным использованием возможностей геоинформационных систем.

Ниже на Рис. 2 приведены тематические растровые изображения, отображающие результаты классификации данных по всей сцене, охватываемой космоснимком.

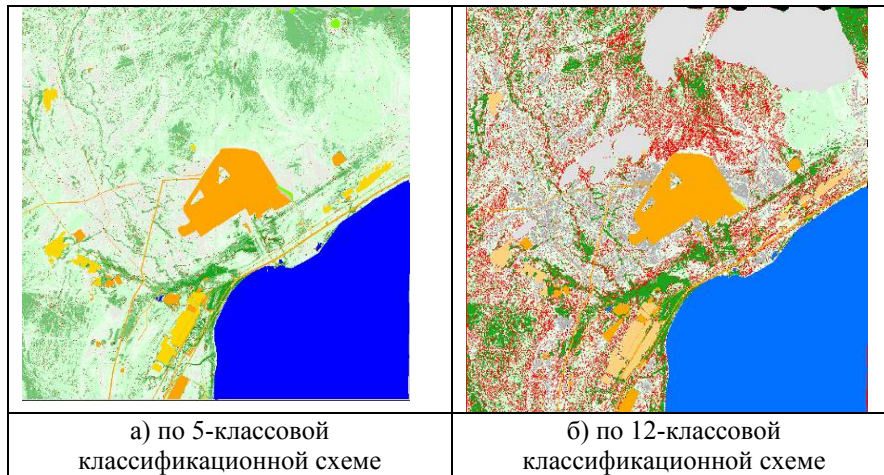


Рис. 2 – Результаты классификации – неклассифицированные пиксели представлены красным цветом.

Классы можно сгруппировать в три группы:

1. Классы, соответствующие однозначно отклассифицированным пикселям. Соответствующие таким классам тексты в таблице представлены в отчетливо черном цвете;
2. Классы, соответствующие неоднозначно отклассифицированным пикселям. Соответствующие таким классам тексты в таблице представлены в сером цвете;
3. Классы, соответствующие пикселям, которые отклассифицированы не из космоснимка, а находятся внутри областей охватываемой сцены, соответствующим различным типам землепользования или покрытия земель, определенным экспертным путем. Соответствующие таким классам названия имеют префикс “Доп.”.

Условные обозначения классов в изображениях различными цветами хотя и не идентичны, но достаточно близки, что позволяет проводить наглядное сравнение. При совместном визуальном анализе обоих растров будут возникать одинаковые восприятия классов объектов, являющимися одинаковыми или очень близкими по своему составу. Так, те пиксели, которые классификаторы смогли идентифицировать, представлены цветами

оттенков зеленого и серого. Общая логика здесь такова: чем больше вегетации, тем более темнозеленым является цвет соответствующего пикселя, и соответственно, чем меньше вегетации, тем больше чисто серым является цвет пикселя. Обратите внимание, что те пиксели, которых классификаторы не смогли идентифицировать, представлены ярко красным цветом, когда как в представлении идентифицированных пикселей полностью отсутствуют оттенки красного цвета. Это значительно усиливает наглядность представления одной из важных характеристик визуального анализа работы классификатора, а именно количество и особенности распределения неклассифицированных пикселей.

Общий осмотр изображений на Рис. 2, показывает, что тематический растр, отображающий классификацию по 12-ти классовой схеме, визуальное очень сильно искажен представлением в красном цвете неидентифицированных пикселей. Если мы использовали бы для их представления не красный, а другой отличный от цветов, примененных для идентифицированных цветов, например, более нейтральный белый, то визуальное представление могло бы быть совершенно иным (см. Рис. 3).

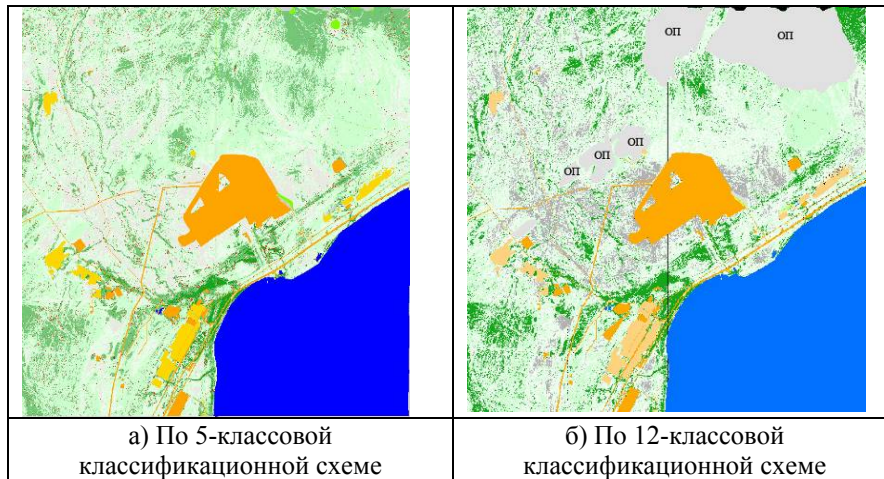


Рис. 3 – Результаты классификации типов растительности–неклассифицированные пиксели – представлены белым цветом по всему снимку.

Видно, что с исчезновением красного цвета, эти тематические растры – исключая области с надписями “ОП” – гораздо более сопоставимы, нежели аналогичные на Рис. 1. Области с надписями “ОП”, соответствует участкам территории, которые экспертным путем были оценены как сложные для распознавания: им были назначены условные классы землепользования – “Открытая площадь”, и они были исключены для автоматической

классификации, проводимой по 12-ти классовой схеме. Однако для 5-ти классовой схемы решено было включить их в процедуру автоматической классификации. Также видно, что в правом изображении темнозеленые цвета более значимы, чем в левом. Чтобы лучше понять все эти аспекты, рассмотрим эти изображения в более близком ракурсе. Для этого увеличим масштаб, и выберем участки, где наиболее ясно заметны различия между изображениями.

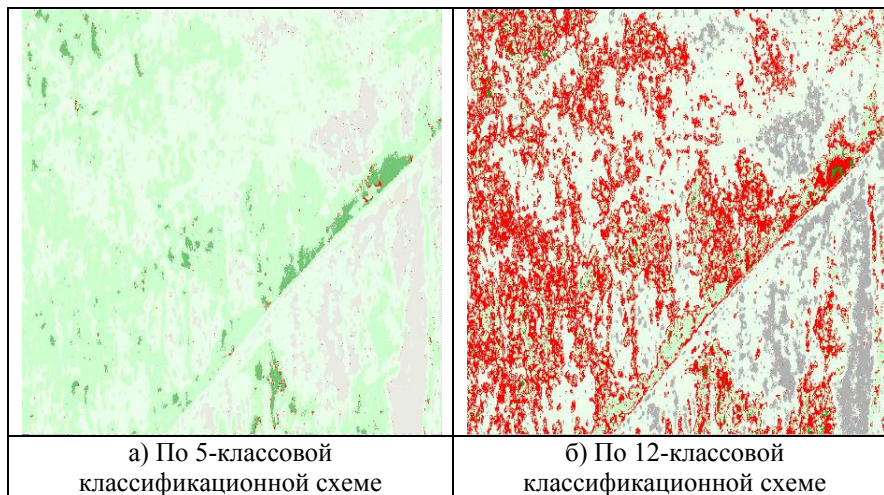


Рис. 4 – Результаты классификации – неклассифицированные пиксели – представлены красным цветом. Фрагмент 1.

На этом фрагменте сцены наиболее характерно различие качества работы двух классификаторов: количество неклассифицированных пикселей на правом снимке так велико, что приходится отказываться полностью от принятия результатов на этом фрагменте. Фрагмент на левом снимке,

отражающий результаты классификации по 5-ти классовой схеме, достаточно ясно показывает **высокую вариативность** характера распределения различных типов на данном участке, что и является камнем преткновения для классификатора по 12-ти классовой схеме.

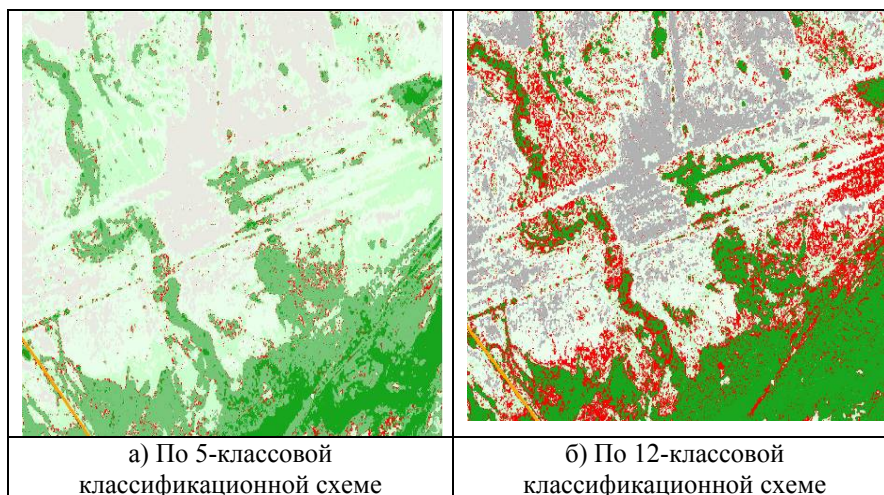


Рис. 5 – Результаты классификации – неклассифицированные пиксели – представлены красным цветом. Фрагмент 2.

Рассмотрим другой фрагмент (Рис. 5), где, хотя и присутствует заметное количество пикселей, которых классификатор по 12-ти классовой схеме не смог распознать, имеется другая характерная особенность – тонкие переходы между типами высоковегетирующей

растительности. На левом снимке (рис. 5а) заметны различия между различными типами болотной растительности, тогда как на правом снимке (5б) мы видим сплошной темнозеленый цвет, указывающий на один единственный тип растительности.

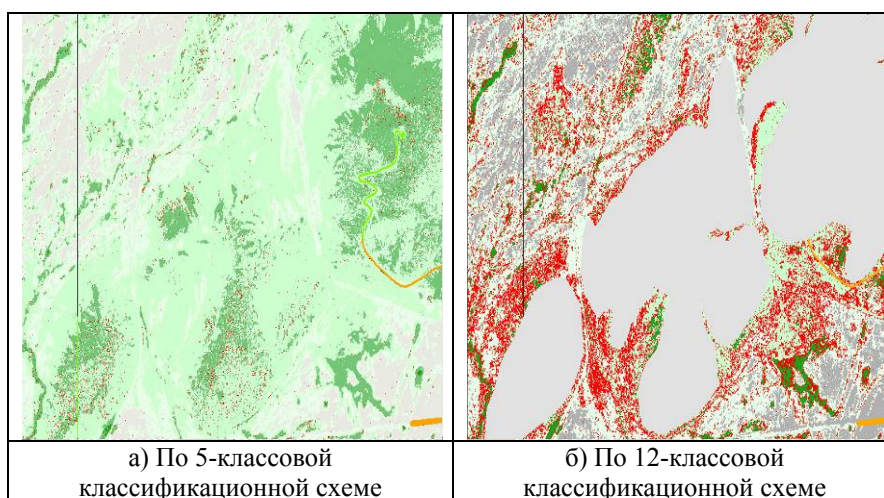


Рис. 6 – Результаты классификации – неклассифицированные пиксели представлены красным цветом. Фрагмент 3.

На Рис. 6 отражен фрагмент, большая часть которого изначально экспертным путем была оценена как “Открытая или пустая площадь” (сплошные серые пятна), где находится неиспользуемая земля, и на которой не имеется какая либо ценная растительность. И так как предварительное тестирование классификатора по 12-ти классовой схеме на данном участке также показало невразумительные результаты, как таковые, эти площади были исключены из подлежащей классификации по 12-ти классовой схеме сцены. Однако результаты классификации по 5-ти классовой схеме указывали на наличие

на этих площадях интересующие нас типы растительности, что было подтверждено при инспектировании или верификации.

Использование возможностей ГИС по визуализации и управлению над пространственно совмещенными слоями данных позволяют проводить эвристически полезный анализ качества работы автоматических классификаторов. В данной работе мы исследовали два совмещенных тематических растра – результаты автоматической классификации одного и того снимка по двум классификационным темам. Сначала мы

использовали возможности символизации ГИС для акцентирования различий при показе всей сцены. Это указало нам направления возможного поиска источников этих различий и локализацию наиболее значимых из них. По этим локализациям мы выделили 3 фрагмента, где были выявлены и определены следующие особенности пространственного распространения исследуемых объектов, которые наиболее сильно влияют на интерпретацию результатов работы классификатора:

- **Высокая пространственная вариативность** характера распределения различных типов на данном участке.
- **Тонкие переходы** между типами распознаваемых объектов.

ВЫВОДЫ

Развитый подход позволил найти оптимальную структуру нейросетевого классификатора для определения ареалов распространения типов растительности на основе многоспектральных снимков юго-восточной части Азербайджана, полученных со спутника IKONOS. Была составлена классификационная схема, состоящая из 5-ти классов и являющаяся комбинацией исходных 12-ти классов, которые изначально были предложены специалистами из предметной области. Качество работы классификатора, обученного по этой схеме, оказалось выше 90%. Результаты анализа также позволили определить, какие особенности исследуемых объектов на космических снимках высокого разрешения наиболее сильно влияют на качество работы классификаторов. Была проведена классификация, позволяющая определить ареалы распространения 12 типов редкой растительности.

ЛИТЕРАТУРА

- [1] T. Kavzoglu and P. Mather. The role of feature selection in artificial neural network applications, *INT. J. Remote Sensing*, 2002, vol. 23, №15, pp. 2919–2937.
- [2] M. Bocco, G. Ovando, S. Sayago and E. Willington. Neural network models for land cover classification from satellite images. *AGRICULTURA TECNICA, Argentina*, 2007, vol. 67, № 4.
- [3] C. Oliveira, P. Mather and P. Aplin. Improving artificial neural network performance by temporal-spectral features for agricultural crop classification". *17th European Simulation multiconference*, 9-11 June 2003, Nottingham Trent University, Nottingham, England.

- [4] T. Kavzoglu and P. Mather. The use of backpropagating artificial neural networks in land cover classification, *INT. J. Remote Sensing*, 2003, 24, pp. 4907–4938.
- [5] C. Klimasauskas. Applying neural networks, *In Neural Networks in Finance and Investing*, edited by R. Trippi and E. Turban (Cambridge: Probus), 1993, pp. 47–72.
- [6] T. Kavzoglu. An investigation of the design and use of feed-forward artificial neural networks in the classification of remotely sensed images, *PhD thesis, School of Geography*, The University of Nottingham, 2001.
- [7] R. Congalton and K. Green. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Lewis Publishers, New York, 1999.



Елена Гамбарова родилась (20 марта, 1963) в Баку, Азербайджанская республика. Она окончила среднюю школу (Баку, Азербайджан, 1980), и затем окончила Азербайджанский государственный университет (1985), физический факультет, специальность – физик. Е. Гамбарова работает старшим научным работником Азербайджанского национального аэрокосмического агентства.

Научные интересы – использование искусственных нейронных сетей (ИНС) в классификации данных изображений удаленных датчиков. Обучение нейронных сетей требует от пользователя спецификации структуры сети и набора обучающих параметров. В этой отрасли науки исследуются оптимизация ИНС для проблем классификации.



THE USE OF NEURAL NETWORKS IN RARE VEGETATION COMMUNITIES CLASSIFICATION

E.M. Gambarova

Institute for Aerospace Informatics, National Aerospace Agency,
 Baku, Azerbaijan
 YLebedik@azuni.net

Abstract: *This paper describes training of Multilayer Perceptron Neural classifier to extract rare vegetation objects from high spatial resolution IKONOS satellite imagery. There have been considered three options of training of the Multilayer Perceptron Neural according to three different classification schemes. At first 12 type of rare vegetation community types were defined, a main classification scheme (“Initial classification scheme”) was designed on that base. After prelim statistical tests on training samples two modification algorithms of the classification scheme were defined: the first one led to creating of scheme consisting of 7 classes (“Modified classification scheme”) and second one led us to creating of 5-classes scheme (“Optimized classification scheme”). The learning procedures of these classifiers are described as well as analysis and post processing of extraction results of objects of interest using Geoinformation Technologies in details.*

Keywords: *image classification, neural networks, IKONOS.*

Two IKONOS images acquired in July 2005 and June 2006 were used for the delineation of 12 rare vegetation communities and soil types. The study area was about a 110 km² region of flat land located in the south-east of the Azerbaijan Republic. The images being used were pan-sharpened multi-spectral images with resolution of 1m.

Initially 12 types of rare vegetation communities

and soil were defined that – according to ecologists’ opinion – are indicator of antropogenous impact on environment in the region being studied. Below the names of them including their Latin analogs (in parenthesis) are presented (Table 1).

Table 1. The “Initial classification scheme” – 12 types of vegetation communities and soil

Class number	Full name of vegetation communities and soil types
Class 1	Chal meadow / reedbed wetland
Class 2	Chal meadow / tamarix scrub (Tamarix)
Class 3	Coastal zone semi desert
Class 4	Phragmites australis reedbed wetland (Phragmaties australis)
Class 5	Salsola ericoides
Class 6	Salsola nodulosa
Class 7	Salsola nodulosa / Artemesia lerchiana
Class 8	Salsola Nodulosa /Grasses
Class 9	Semi desert vegetation, kalidium caspicum (Kalidium caspicum)
Class 10	Semi desert scrub alhagi dominated (Alhagi pseudoalhagi)
Class 11	Bare ground
Class 12	Salsola nodulosa / Bare ground

Using GIS procedures the areas of location of these vegetation communities were determined for extraction of samples for the classifier training and testing.

The training and test sets of samples were tested of representativeness and separability basing on their calculated statistical parameters. These tests pointed in a direction of possible modification of “Initial classification scheme” (of 12 classes). Using this algorithm we created a new training and test sets which were combination of one or more classes from the Initial sets of samples. Having received the new sets, we performed the same statistical tests of representativeness and separability. Finally the “Optimized classification scheme” (5 classes) has been created for learning procedure. It was a combination of classes from initial set (12 classes) of rare vegetation communities and soil types which were chosen by the ecologists as sensible indicators of antropogenous impact.

We used a topological structure of the back-propagation neural network in which neurons are arranged into three layers, (i.e., input layer, hidden layer and output layer).

The input layer consisted of 4 neurons, corresponding to four spectral channels of IKONOS satellite scanner: we used the red, green, blue, and near infrared (NIR) channel. The hidden layer had 25 neurons and the output layer had 12 neurons for the “initial set” of classes, 7 – for “modified set” and 5 – for “optimized set”.

An activation function was hyperbolic tangent.

The back-propagation algorithm was used for neural network training.

A network structure of 4-25-12 was trained with the parameters listed in Table 2.

Table 2. Optimum setting of network structure and learning parameters

Parameters	Choice
Initial weight range	[0, 0.05]
Number of input nodes	4
Number of hidden layers	1
Number of hidden nodes	25
Learning rate between input and hidden layers	0.5
Momentum term between input and hidden layers	0.7
Learning rate between hidden and output layers	0.25
Momentum term between hidden and output layers	0.7
Type of activation function	hyperbolic tangent
Error threshold er_{thresh}	0.01

For evaluation of training process we used the following quality parameters:

- The Mean Square Error (*MSE*); Having reached *threshold* set for the *MSE* level of 0.01 the training process was stopped;
- The Correlation coefficient (*r*), which reflects the degree of correlation between directions of changing of real and desired outputs of the neural network;
- $\%Error$ – Error per element of the neural network.

During the training process, all learning parameters were kept constant. Training networks were saved and their performances evaluated using a test dataset.

When we reached the maximal number of iterations and the training process was stopped, we compiled a contingency matrix with the results of recognition of samples from training sets.

We estimated the common degree of correctness (*CDC*) by the following formula:

$$CDC = 100\% \times (N_{CCS} / N_{total})$$

N_{CCS} – the number of correctly classified samples;

N_{total} – the total number of samples

After completion of training procedures, a dataset covering this scene were classified by neural network according to all three classification schemes described above. The resulting images representing themselves as thematic rasters were analyzed.

Using of Geoinformation Technologies the number of non-classified and not exactly classified pixels was estimated.

The quality of learning of the classifier on “Optimized classification scheme” was higher than 90%. The on-site analysis has approved the quality of the classifier. The analysis using spatial overlapping method with help of visualization tools have revealed those characteristics of the objects on high resolution multispectral satellite images that have the most influence on the quality of classification products. The classification results provide information for solving the real task of defining areas of rare vegetation communities.