

Обучение нейронного классификатора для распознавания объектов на снимках, полученных со спутника IKONOS

Гамбарова Е.М.

Научно-исследовательский институт аэрокосмической информатики, г. Баку,
Азербайджан
E-mail: YLebedik@azuni.net

Аннотация. Рассмотрены 3 варианта обучения нейронного классификатора. Определены 12 типов растительности и почв и построены основная классификационная схема (по 12-ти классам) и две дополнительные – «Модифицированная» (по 7-ми классам) и «Оптимальная» – по 5-ти классам. Работы проведены для решения задачи определения ареалов распространения редких типов растительности, присутствующих на многоспектральных снимках высокого разрешения, полученного со спутника IKONOS.

1. Общая постановка классификации типов растительности и почв

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

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

Номер класса	Почва или название растения
1	Болотистая тростниковая растительность
2	Болотистый кустарниковый тамариск (Tamarix)
3	Прибрежная зона: полупустынная растительность
4	Тростник ложный австралийский (Phragmites australis)
5	Солянка древовидная (Salsola ericoides)
6	Солянка гористая (Salsola nodulosa)
7	Солянка гористая (Salsola nodulosa) / Полынь Лерха (Artemisia lerchiana)
8	Солянка гористая (Salsola Nodulosa) / Трава
9	Полупустынная растительность – поташник каспийский (Kalidium capsicum)
10	Полупустынная растительность с доминированием верблюжьей колючки (Alhagi pseudoalhagi)
11	Голая почва
12	Солянка гористая (Salsola nodulosa) / голая почва

Для процесса обучения классификатора были выбраны и определены размеры тренировочных и тестовых образцов для 12-ти классовой классификационной схемы. С помощью общих статистических характеристик обучающие образцы прошли тесты на репрезентативность и разделяемость по четырем спектральным каналам. В таблице 2 приведены статистические характеристики обучающих примеров по 4-м спектральным каналам.

Таблица 2. Статистические характеристики обучающих классов по четырем каналам

Номер класса	Красный канал		Зеленый канал		Голубой канал		Инфракрасный канал	
	Минимум-Максимум	Среднее±Стан.Откл	Минимум-Максимум	Среднее±Стан.Откл	Минимум-Максимум	Среднее±Стан.Откл	Минимум-Максимум	Среднее±Стан.Откл
1	241 - 655	363.5 ± 40.5	398 - 725	497.9 ± 31.4	356 - 553	418.0 ± 20.0	466 - 1132	820.5 ± 115.8
2	264 - 738	497.8 ± 65.9	391 - 779	574.4 ± 53.2	354 - 605	468.6 ± 33.9	396 - 821	631.8 ± 52.6
3	555 - 826	704.7 ± 60.4	648 - 878	772.5 ± 56.5	511 - 655	586.1 ± 36.7	481 - 759	649.4 ± 57.4
4	216 - 697	380.7 ± 44.5	362 - 737	498.7 ± 38.0	329 - 553	424.7 ± 22.4	416 - 1394	806 ± 289.4
5	544 - 981	769.6 ± 95.3	653 - 1008	839.7 ± 77.2	493 - 724	619 ± 50.1	481 - 941	713.7 ± 100.8
6	395 - 1058	743.2 ± 89.7	523 - 1051	799.2 ± 75.9	409 - 760	609.3 ± 42.8	362 - 1000	698.1 ± 87.8
7	554 - 930	729 ± 55.5	631 - 973	780.1 ± 50.7	493 - 691	583.7 ± 30.1	534 - 896	700.4 ± 50.2
8	597 - 972	784.1 ± 63.5	694 - 994	835.8 ± 51.2	517 - 715	618.6 ± 33.2	541 - 928	738.3 ± 65.7
9	639 - 761	689.0 ± 30.6	684 - 781	722.4 ± 24.4	528 - 598	553 ± 16.1	642 - 783	698 ± 30.2
10	389 - 870	657.1 ± 139.6	520 - 914	742.8 ± 115.7	424 - 672	561.4 ± 70.2	432 - 909	696.8 ± 137.9
11	760 - 1104	941.4 ± 64.6	841 - 1141	1001.8 ± 60.2	607 - 800	709.8 ± 38.0	673 - 1001	851.5 ± 61.1
12	613 - 1047	854.0 ± 75.9	715 - 1078	912 ± 63.3	530 - 768	660.6 ± 40.7	523 - 975	780.0 ± 76.4

Из таблицы 2 видно, что:

- классы 1 и 4 сильно перекрываются;
- класс 6 включает в себя класс 5;
- классы 7 и 8 сильно перекрываются;
- класс 10 включает в себя классы 9 и 3.

Данные, приведенные в таблице 2, показывают сильную перекрываемость классов и тем самым указывают на один из возможных вариантов модификации исходной классификационной схемы (таблица 3).

Таблица 3. «Модифицированный набор» из 7-ми классов – типов растительности и почв

Номер класса	Почва или название растения
1	Исх.Класс 1 + Исх.Класс 4 – Болотистая тростниковая растительность + Тростник ложный австралийский (<i>Phragmites australis</i>)
2	Исх.Класс 2 – Болотистый кустарниковый тамариск (<i>Tamarix</i>)
3	Исх.Класс 3 + Исх.Класс 9 + Исх.Класс 10 – Полупустынные растительности: Прибрежной зоны + Поташник каспийский (<i>Kalidium capsicum</i>) + Верблюжья колючка (<i>Alhagi pseudoalhagi</i>)
4	Исх.Класс 5 + Исх.Класс 6 – Солянка древовидная (<i>Salsola ericoides</i>) + Солянка гористая (<i>Salsola nodulosa</i>)
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
6	Исх.Класс 11 – Голая почва
7	Исх.Класс 12 – <i>Salsola nodulosa</i> / голая почва

После создания этого набора из 7-ми классов к нему был применен подобный же анализ по статистическим характеристикам по четырем спектральным каналам, который показал нам возможность дальнейшей модификации 7-ми классовой схемы. Таким образом мы получили новый набор, состоящий из 5-ти классов (таблица 4).

Таблица 4. «Оптимальный набор» обучающих примеров по 5-ти классовой схеме

Номер класса	Почва или название растения
1	Исх.Класс 1 + Исх.Класс 4 – Chal Meadow/Камышовые болота + Камышовые <i>Phragmites australis</i>
2	Исх.Класс 2 – Chal Meadow/ <i>Tamarix Scrub</i>
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
4	Исх.Класс 11 – Голая почва
5	Исх.Класс 12 – <i>Salsola nodulosa</i> / голая почва

2. Результаты обучения классификатора

Архитектура использованного нейронного классификатора представлена на рис. 1. Входной слой состоит из 4-х нейронов, соответствующим 4-м спектральным каналам; скрытый – из 25 или 50 нейронов; выходной – из 12 нейронов для «первоначального набора классов», из 7 нейронов для «модифицированного набора» и из 5 нейронов для «оптимального набора», соответственно. Активационная функция нейронов – гиперболический тангенс. Для обучения нейронной сети использовался алгоритм обратного распространения ошибок.




Рис. 1. Архитектура нейронной сети

Для всех 3-х проведенных нами экспериментов набор параметров обучения для классификатора был одним и тем же. Этот набор представлен ниже вместе с параметрами качества.

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

- MSE – среднеквадратическая ошибка, при достижении двойной кратности порога ошибки (0.02), обучение останавливалось.
- r – коэффициент корреляции между реальным выходом сети и ожидаемым.
- err – погрешность на единицу элемента нейронной сети, по которому вычисляются ошибки.

Коэффициент корреляции между выходом сети $\mathbf{x}$ и ожидаемым выходом $\mathbf{d}$ равен:

$$r = \frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}}$$

Коэффициент корреляции ограничен интервалом $[-1, 1]$. При $r = 1$ мы имеем точное предсказание, при $r = -1$ ошибка предсказания велика. Промежуточные значения описывают частичные корреляции выхода и ожидания. Например, $r = 0.88$ означает, что соответствие результата предсказанию является достаточно хорошим.

Погрешность err (в процентах) определяется выражением:

$$err = \frac{100}{N P} \sum_{j=0}^P \sum_{i=0}^N \frac{|dy_{ij} - dd_{ij}|}{dd_{ij}}$$

где: P – число элементов обработки на выходе сети, N – число примеров в наборе обучающих данных, dy_{ij} – денормализованный выход сети для примера i на элементе обработки j , dd_{ij} – денормализованный заданный (ожидаемый) выход сети для примера i на элементе обработки j .

2.1. Первоначальная классификационная схема (12 классов)

В результате обучения нейронного классификатора на тренинговых образцах по 12-ти классам после проведения максимального количества итераций мы составили перекрестную таблицу с результатами распознавания примеров из тех же тренинговых образцов (так называемое самотестирование). По этой таблице 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, во-первых, классов 1, 2 и 4, во-вторых, классов 5, 6, 7 и 8.

В таблице 5 приведены параметры обучения, при которых получены данные результаты, а также параметры качества, зафиксированные при максимальном количестве итераций.

Таблица 5. Параметры обучения

Название	Значение
Исходные веса	Случайные числа из интервала [0, 0.05]
Количество входных 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
Момент между входным и скрытым слоями	0.7
Скорость обучения между скрытым и выходным слоями	0.25
Момент между скрытым и выходным слоями	0.7
Вид и тип передаточной функции	гиперболический тангенс
Порог ошибки er_{thresh}	0.01

Результаты приведены в таблице 6.

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

Название	Значение
Количество итераций, N_{iter}	25000
Средне-квадратическая ошибка, MSE	0.0382
Коэффициент корреляции, r	0.7822
Погрешность на единицу элемента сети, err (%)	1.2823

Номер класса определялся по максимальному совпадению выходного вектора $\mathbf{x}$ с ожидаемым $\mathbf{d}$. Ожидаемый вектор $\mathbf{d}$ имеет бинарные компоненты 0 и 1: компонента для ожидаемого класса равна 1, для всех остальных – 0. Для возможности сравнения реального и ожидаемого выходов, значения выходных нейронов нормализуются в интервале $[0,1]$

Из таблицы 6 видно, что хотя 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.

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, составленным из примеров, которые в обучении классификатора не участвовали (таблица 7). Результаты, как и ожидалось, существенно ухудшились. Так, значение ОУК существенно понизилось и стало равным 81.39%. Эти результаты подтвердили сделанные на основе анализа спектров выводы о неадекватности исходной 12-ти классовой классификационной схемы.

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 сети, err (%)	1.9938

2.2. Процедура обучения по 7-ми классовой схеме

Для этого варианта показано, что: а) ОУК = 94.61% для тренировочных образцов и б) ОУК = 85.8% при тестовых образцах. Более детально результаты расчетов суммированы в таблицах 8, 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 сети, 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 сети, 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 сети 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 ниже 90%-ного порога. Кроме того, выявились большое значение для MSE и низкая устойчивость процедуры обучения, на что указывает достаточно низкое значение r и еще более высокая погрешность на единицу элемента сети 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. Процедура обучения по 5-ти классовой схеме

Для этого варианта при обучении максимальный порог количества итераций был снижен до 15000 шагов, так как задолго до этого процесс обучения приобретал устойчивый характер и характер распределения тестовых примеров по классам, а также параметры качества практически не менялись для нейронного классификатора на тренинговых 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 тренинговых 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 сети, err (%)	1.503

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

Название	Значение
Количество итераций, N_{iter}	15000
Средне-квадратическая ошибка, MSE	0.0745
Коэффициент корреляции, r	0.9107
Погрешность на единицу элемента сети, 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. Анализ результатов классификации

Для экспериментальных исследований был использован многоспектральный снимок юго-восточной части Азербайджана, полученный со спутника IKONOS.

После проведения процедуры обучения по двум классификационным схемам (12 классовой и 5 классовой) по ним были проведены автоматические классификации по всей сцене, охватываемой космоснимком (многоспектральный снимок со спутника IKONOS, охватывающий территорию площадью 110 км²) для распознавания объектов из соответствующих классов.

Был сделан визуальный анализ картин, представляющих тематические растры результатов классификации и количественные оценки неклассифицированных и нечетко классифицированных элементов сцены с активным использованием возможностей геоинформационных систем.

На рис. 2 – 4 показаны тематические растровые изображения, отображающие результаты классификации данных по всей сцене, охватываемой космоснимком. Условные обозначения классов в изображениях различными градациями серого цвета хотя и неидентичны, 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 светлыми оттенками серого.




Рис. 2. Результаты классификации (неклассифицированные пиксели представлены черным цветом).

Рис. 2б показывает, что тематический растр, отображающий классификацию по 12-ти классовой схеме, визуально очень сильно искажен представлением неидентифицированных пикселей черным цветом. Также видно, что в правом изображении темносерые цвета более значимы, чем в левом. Для лучшего представления рассмотрим эти изображения в более близком ракурсе. Для этого увеличим масштаб и выберем участки, где наиболее ясно заметны различия между изображениями (рис. 3).




Рис. 3. Результаты классификации (неклассифицированные пиксели представлены черным цветом). Фрагмент 1.

На этом фрагменте сцены наиболее ярко видно различие качества работы двух классификаторов: количество неклассифицированных пикселей на правом снимке так велико, что приходится полностью отказаться от принятия результатов для этого фрагмента. Фрагмент на левом снимке, отражающий результаты классификации по 5-ти классовой схеме, показывает распределения различных типов растительности на данном участке.

Рассмотрим другой фрагмент (рис. 4), где, хотя и присутствует заметное количество пикселей, для которых классификатор достаточно ясно показывает *высокую вариативность* участков растительности, определенных по 12-ти классовой схеме, но не обеспечивает четкое распознавание классов, имеется другая характерная особенность – тонкие переходы между типами высоковегетирующей растительности. На рисунке, который находится слева, заметны различия между различными типами болотной растительности, тогда как на правом снимке мы видим сплошной темновато-серый, указывающий на единственный тип растительности.

Анализ классификации выявил следующие особенности пространственного распространения исследуемых объектов, которые наиболее сильно влияют на интерпретацию результатов работы классификатора:

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




Рис. 4. Результаты классификации (неклассифицированные пиксели представлены черным цветом). Фрагмент 2.

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.

Статья поступила 25 октября 2007 г.
После доработки 07 декабря 2007 г.