

УДК 004.032.26(045)

Насуро Е.В.

## ПРИМЕНЕНИЕ МОДУЛЬНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ СПУТНИКОВЫХ ДАННЫХ

Национальный авиационный университет

*Приводится сравнительная характеристика результатов применения различных нейросетевых архитектур к задаче классификации ландшафта по спутниковым снимкам. Предложена модульная архитектура нейронной сети. Описаны результаты ее применения для классификации больших объемов данных.*

### Введение

Продукты по классификации объектов земной поверхности по данным дистанционного зондирования Земли являются базой для решения многих задач по мониторингу состояния окружающей среды. Именно спутниковые данные предоставляют оперативную информацию о состоянии больших территорий и позволяют наблюдать последствия и принимать срочные решения в случае чрезвычайных ситуаций, природных и техногенных катастроф. Кроме того, данные по классификации позволяют дистанционно оценивать биоразнообразие исследуемых территорий и проводить мероприятия по сохранению ценных ландшафтных единиц.

Среди существующих программ направленных на создание продуктов по классификации земной поверхности, следует выделить европейский проект *Corine* [1] и американский проект *National Land Cover Data (NLCD)* [2], которые в качестве основы используют данные спутника *Landsat*. Кроме этого есть проект *MODIS Land Cover and Land-Cover Change* [3], который основан на данных прибора *MODIS* спутника *Terra* и использует глобальную систему классификации программы *International Geosphere-Biosphere Program (IGBP)* [4]. Все они отличаются системами классификации, покрытием, используемыми данными, технологиями построения и методами обработки. Для территории Украины доступны лишь данные по глобальной классификации земной поверхности с разрешением не менее 1 км. Они не оперативны и не достаточно информативны в тех случаях, когда необходима более точная ин-

формация по классификации ландшафта на территории Украины. Поэтому актуальной является задача создания более эффективных методов классификации покрытий ландшафта, к которым автор относит применения нейронных сетей с модульной архитектурой.

### Классификация данных дистанционного зондирования Земли при помощи нейронных сетей

В настоящее время при выборе подхода к классификации земного покрова по данным дистанционного зондирования Земли часто отдается предпочтение нейросетевым методам. Существующее разнообразие различных нейросетевых архитектур, а также методов обучения нейронных сетей, позволяют выбрать наиболее оптимальную для поставленной задачи конфигурацию, найти компромисс между скоростью работы сети, размерностью сети и эффективностью работы. В то же время такое разнообразие возможностей приводит к необходимости проводить большое количество экспериментов для получения достоверных и наиболее подходящих к задаче вариантов решения.

Наши исследования, проведенные в работах [5, 6, 7] раскрывают результаты применения различных нейросетевых архитектур, методов обучения нейронных сетей первого и второго порядка, использования сетей на основе радиальных базисных функций и сетей на основе теории адаптивного резонанса для обработки данных спутника *Landsat*. Полученные результаты показывают, что для разных классов наибольшее значение верно классифицированных образов достигалось для

разных методов, что объясняется сложностью топологии исходных данных.

### Сравнение результатов работы различных нейросетевых парадигм

Для сравнительного анализа работы различных нейронных сетей с обучением с учителем было использовано изображение, полученное мультиспектральным прибором *ETM+* (*Enhanced Thematic Mapper Plus*) спутника *Landsat-7* [8]. Прибор предоставляет данные с пространственным разрешением 30м. Для эксперимента были взяты каналы 1-5 и 7. Размерность входных векторов составляла 6 элементов. На выходе был представлен вектор из 8 элементов – по количеству определяемых классов. Для определения эталонных данных использовалась информация проекта *Corine* по классификации земной поверхности. На тестовом снимке были определены следующие 8 классов (в скобках указан код классификации согласно проекту *Corine*): лиственный лес (311), хвойный лес (312), сме-

шанный лес (313), пашня (211), пастбище (231), вода (51), искусственные материалы (1), открытая местность с разреженной растительностью (33) [5,6].

В процессе работы были рассмотрены и протестированы следующие нейросетевые парадигмы: многослойный персептрон, обученный методом обратного распространения ошибки, *EDBD*, квази-Ньютоновским методом и методом сопряженных градиентов; нейронная сеть на основе радиальных базисных функций; нейронная сеть, основанная на теории адаптивного резонанса.

Выполненные эксперименты были направлены на определение оптимальной архитектуры нейронной сети, предназначенной для классификации мультиспектральных спутниковых снимков; анализ методов обучения нейронных сетей и их влияние на результаты работы сети, анализ применимости нейронных сетей для решения задач такого класса. Сравнение результатов работы различных нейросетевых архитектур приведено в таблице 3.

Таблица 1. Сравнение результатов работы различных нейросетевых архитектур

Классы		Архитектура сети					
		Многослойный персептрон				Радиальная базисная функция	Нейронные сети, на основе адаптивной резонансной теории
		Обратного распространения ошибки	<i>EDBD</i>	Квази-Ньютоновский	Сопряженных градиентов		
лиственный лес	1	99,6%	98,9%	100,0%	99,9%	99,9%	99,3%
хвойный лес	2	94,6%	85,7%	98,3%	96,3%	88,8%	80,2%
смешанный лес	3	53,4%	67,4%	0,5%	35,2%	57,7%	68,7%
пашня	4	91,2%	89,6%	87,2%	92,7%	97,1%	82,0%
пастбище	5	90,5%	91,4%	0,0%	0,0%	77,8%	75,8%
вода	6	97,8%	97,7%	0,0%	0,0%	92,6%	96,2%
искусственные материалы	7	81,4%	83,6%	58,8%	67,2%	70,8%	77,8%
открытая местность	8	89,6%	96,5%	0,0%	0,0%	79,4%	97,3%
Всего		87,9%	88,9%	58,5%	64,35%	85,6%	83,7%

Анализируя результаты проведенных экспериментов видно, что для разных классов наилучший результат достигался разными методами. Это можно объяснить

сложностью входных данных и сложными свойствами разделимости. В среднем по всей выборке данных наилучшие результаты дает многослойный персептрон,

обученный методом *EDBD*. Кроме того, обучение этим методом занимает значительно меньше времени, по сравнению с другими методами [7].

### Применение модульных нейронных сетей для классификации данных ДЗЗ

Сложное разбиение поверхности земли на классы и подклассы влечет за собой значительное усложнение архитектуры нейронной сети. Это приводит к замедлению процесса обучения и снижению точности классификации.

Для улучшения классификации спутниковых снимков можно использо-

вать модульные нейронные сети со сложной архитектурой. Модульная нейронная сеть – это несколько нейронных сетей, объединенных общим входом, через который подаются входные данные и выходным блоком с решающим правилом, который собирает результаты работы всех сегментов и принимает окончательное решение. Каждая нейронная сеть модульной сети обладает своими характеристиками (архитектура сети, метод обучения) и направлена на решение простейшей задачи, на которые разбивается сложное задание (рис.1).




Рис. 1. Концепция модульной нейронной сети

В нашем случае количество элементов модульной сети соответствует количеству классов, на которые требуется разбить данные. Каждый модуль нашей сети обучен и отлажен для определения принадлежности образца к одному из классов. Это обеспечивает получение более точных результатов классификации.

Так как в среднем метод обучения многослойного персептрона *EDBD* дал наилучшие результаты с наименьшими временными затратами, то в качестве элементов модульной сети будут выступать нейронные сети, обученные этим методом. На рисунке 2 изображена модуль-

ная нейронная сеть, которая была использована для проведения экспериментов. Каждый модуль нейронной сети обучен таким образом, чтобы из всех предложенных вариантов данных выбирать только те, которые относятся к соответствующему классу (модули *B1-B8*). Модуль *IN* проводит предобработку всех входных данных, модуль *PAT* подает в нейронные сети сигнал проверки точности классификации – признак принадлежности образца данных к классу, модуль *OUT* комбинирует все данные и выдает общий ответ.




Рис. 2. Архитектура модульной нейронной сети

Анализируя результаты работы модульной нейронной сети видно, что результаты классификации стали более стабильными: все классы распознаются с достаточной точностью – более 80%, при этом значительно улучшилась точность распознавания тех классов, для которых мало данных (табл. 2).

Важно также отметить, что времени на обучение и настройку модульной нейронной сети требуется значительно меньше, так как разбиение данных на два класса не требует сложной архитектуры

сети, кроме того, модульная архитектура позволяет настраивать только один элемент системы, не меняя уже настроенные модули.

Дальнейшее увеличение количества классов влечет за собой добавление дополнительных модулей. Применение модульной нейронной сети для разделения данных на большое количество классов позволяет не терять точность классификации и настраивать каждый модуль сети непосредственно в соотношении с характером данных отдельного класса.

Таблица 2. Сравнение результатов работы модульной нейронной сети и нейронной сети с простой архитектурой

Классы		Архитектура сети	
		Многослойный перцептрон, обученный методом <i>EDBD</i>	Модульная нейронная сеть
лиственный лес	1	98,9%	98,7%
хвойный лес	2	85,7%	82,1%
смешанный лес	3	67,4%	83,9%
пашня	4	89,6%	81,5%
пастбище	5	91,4%	89,9%
вода	6	97,7%	95,8%
искусственные материалы	7	83,6%	84,9%
открытая местность	8	96,5%	96,7%
Всего		88,9%	89,2%

### Выводы

В статье предложен метод классификации земной поверхности на основании спутниковых данных. В процессе классификации принимают участие нейронные сети. Сложное разбиение поверхности земли на классы и подклассы влечет за собой значительное усложнение исходных данных. Для улучшения классификации спутниковых снимков применяются модульные нейронные сети со сложной архитектурой. Каждый из модулей такой нейронной сети определяет принадлежность образца к определенному классу, что позволяет проводить классификацию с меньшей погрешностью.

Наряду с повышением эффективности решения задачи в модульных инфраструктурах следует отметить существенное увеличение вычислительной сложности таких систем. Поэтому вопросы их программной реализации представляют отдельный интерес и будут рассмотрены дополнительно.

### Список литературы

1. NASA Landsat 7, <http://landsat.gsfc.nasa.gov>
2. National Land Cover Data (NLCD) [<http://www.epa.gov/mrlc/nlcd.html>]
3. Strahler Alan, et al. MODIS Land Cover and Land-Cover Change, Algorithm Theoretical Basis Document (ATBD), Version 5.0, 1999. – 72 p.
4. Belward A.S., Estes J.E., Kline K.D. The IGBP-DIS Global 1-km Land-Cover

Data Set DISCover: A Project Overview// Photogram. Eng. Remote Sens. — 1999. — 65. — P. 1013-1020.

5. N. Kussul, S. Skakun, O. Kussul. Comparative Analysis of Neural Networks and Statistical Approaches to Remote Sensing Image Classification // International Scientific Journal of "Computing". – 2006. – Vol. 5, Issue 2. – P. 93–99.

6. Насуро Е.В. Нейросетевая модификация метода оценки биоразнообразия // Кибернетика и вычислительная техника, – 2006. – выпуск 152. С. 61-69.

7. Скакун С.В., Насуро Е.В., Лавренко А.Н., КуССуль О.М. Анализ применимости нейронных сетей для классификации спутниковых данных // Проблемы управления и информатики, – 2007. – №2. – С.105-117

8. Landsat-7 Science Data User's Handbook. – [http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook\\_toc.html](http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_toc.html)