

Секция 5

СИСТЕМНЫЙ ПОДХОД В ЗАДАЧАХ ФИЗИКИ И АСТРОНОМИИ

Председатель – Фирсов Андрей Николаевич,
д-р техн. наук, профессор СПбПУ Петра Великого

Ученый секретарь – Сорокина Наталья Владимировна,
ассистент СПбПУ Петра Великого

УДК 004: 629.7

doi:10.18720/SPBPU/2/id20-169

Верба Вера Алексеевна¹,
канд. техн. наук, доцент, доцент кафедры ИСУиА;
Лысов Василий Витальевич²,
магистрант 1-го года обучения

КЛАССИФИКАЦИЯ ВЫСОКОЭНЕРГЕТИЧЕСКИХ ГАММА-ЧАСТИЦ В АТМОСФЕРНОМ ТЕЛЕСКОПЕ ЧЕРЕНКОВА С ПОМОЩЬЮ НЕЙРОСЕТЕВОГО АНАЛИЗА

^{1,2} Московский технический университет связи и информатики,
Москва, Россия,
¹ verba@list.ru, ² 55vasia55@gmail.com

Аннотация. В статье рассматривается проблема классификации высокоэнергетических гамма-частиц. Данные сгенерированы для моделирования регистрации частиц в телескопе Черенкова. Для классификации используется нейронная сеть типа многослойный перцептрон. При обучении нейронной сети используется метод обратного распространения ошибки.

Ключевые слова: гамма-частицы, нейронная сеть, атмосферный телескоп, классификация, прогнозирование, анализ.

Vera A. Verba¹,
Ph.D., Associate Professor, Department of ISUiA;
Vasily V. Lysov²,
1st year Master Student

CLASSIFICATION OF HIGH-ENERGY GAMMA PARTICLES IN THE ATMOSPHERIC TERESCOPE OF CHERENKOV BY USING NEURAL NETWORK ANALYSIS

^{1,2} Moscow Technical University of Communications and Informatics,
Moscow, Russia,
¹ verba@list.ru, ² 55vasia55@gmail.com

Abstract. The article discusses the classification of high-energy gamma particles. Data was generated to simulate particle registration in the Cherenkov telescope. For classification, a neural network such as a multilayer perceptron is used. When training a neural network, the back propagation method is used.

Keywords: gamma particles, neural network, atmospheric telescope, classification, forecasting, analysis.

Введение

На данный момент применение машинного обучения в геоинформационных системах (ГИС) является востребованной задачей [1]. Это связано с тем, что в ГИС хранятся огромные массивы данных, а их ручная обработка занимает огромное количество времени и не удовлетворяет современным потребностям в качестве получаемых результатов. Машинное обучение, а в частности нейронные сети (НС), позволяют существенно снизить время, которое затрачивается на анализ данных. Также НС способны выявлять скрытые и неочевидные взаимосвязи в данных, что значительно влияет на получаемую точность.

В статье рассматривается возможность применения нейронных сетей для классификации высокоэнергетических гамма-частиц. Гамма-телескопы, которые регистрируют такие частицы, являются инструментами в изучении таких объектов, как пульсары, остатки сверхновых звезды, активные ядра галактик и т. д.

1. Описание набора данных

Данные [2] генерируются для моделирования регистрации высокоэнергетических гамма-частиц в наземном атмосферном гамма-телескопе Черенкова с использованием метода визуализации. Гамма-телескоп Черенкова наблюдает высокоэнергетические гамма-лучи, используя в своих интересах излучение заряженных частиц, образующихся внутри электромагнитных ливней, инициируемых гаммами и развивающихся в атмосфере. Это черенковское излучение (видимых до УФ длин волн) просачивается через атмосферу и регистрируется в детекторе, что позволяет реконструировать параметры ливня. Имеющаяся информация состоит из импульсов, оставляемых входящими черенковскими фотонами на фотомножительных трубках, расположенных в плоскости камеры. В зависимости от энергии первичной гаммы, в общей сложности от нескольких сотен до примерно 10000 черенковских фотонов собираются в паттерны (называемые изображением ливня), позволяющие статистически отличать те, которые вызваны первичными гаммами (сигналом) от изображений адронных ливней, инициированных космическими лучами в верхних слоях атмосферы (фоном) [3].

Набор данных был сгенерирован программой Monte Carlo Corsika [4]. Программа была запущена с параметрами, позволяющими наблюдать события с энергиями ниже 50 ГэВ.

Входные признаки:

1. Непрерывная главная ось эллипса [мм]
2. Непрерывная малая ось эллипса [мм]
3. Десятичный логарифм суммы содержимого всех пикселей
4. Непрерывное отношение суммы двух самых высоких пикселей по размеру
5. Непрерывное соотношение высшего пикселя и параметра z
6. Непрерывное расстояние от самого высокого пикселя до центра, проецируемое на главную ось [мм]
7. Непрерывный 3-й корень третьего момента вдоль главной оси [мм]
8. Непрерывный 3-й корень третьего момента вдоль малой оси [мм]
9. Непрерывный угол главной оси с вектором к началу координат [градусы]
10. Непрерывное расстояние от начала координат до центра эллипса [мм]

Выходной признак:

Класс: гамма (сигнал), Адрон (фон).

Набор данных разделен на обучающий и тестовый.

Для обучающего набора данных:

g = гамма (сигнал): 11007,

h = Адрон (фон): 5788.

Для тестового набора данных:

g = гамма (сигнал): 1325,

h = Адрон (фон): 900.

По техническим причинам число событий h недооценивается. В реальных данных класс h представляет большинство событий.

Простая классификация не имеет смысла для этих данных, так как классифицировать фоновое событие как сигнал хуже, чем классифицировать сигнальное событие как фон. Релевантными результатами являются те, где вероятность принятия фонового события в качестве сигнала ниже одного из следующих порогов: 0.01, 0.02, 0.05, 0.1, 0.2 в зависимости от требуемого качества выборки.

2. Обработка набора данных

Перед тем как начать работать с данными необходимо их обработать. Изначальные данные изображены на рисунке 1.

76.1909	29.7032	3.5078	0.1068	0.0573	-117.196	48.078	-19.0207	1.64	242.437	1
31.0616	11.0944	2.3531	0.5233	0.3215	14.1348	14.9342	7.4413	34.976	123.11	1
41.8044	20.9524	2.7348	0.2468	0.128	72.225	-22.3472	17.6023	22.3263	122.32	1
77.6918	36.8864	3.5261	0.1954	0.1205	-43.3672	65.5969	36.4114	3.9967	297.998	1
28.8362	11.2117	2.4786	0.4552	0.2309	-23.7812	-16.2585	-8.6529	7.4925	159.247	1
37.7771	25.3763	3.3648	0.2236	0.1207	29.8161	-15.9668	-12.1117	0.8021	196.855	1
19.6379	7.3288	2.1538	0.7649	0.4175	3.394	-10.0917	-4.7269	80.2685	129.528	1
45.0186	17.2847	2.8848	0.3325	0.1714	4.0297	45.8469	7.1707	8.59	141.561	1
64.542	29.7453	3.3389	0.1467	0.0758	75.7622	42.5985	17.6999	1.967	241.639	1
25.8414	18.4628	2.5927	0.4138	0.2465	10.0019	19.5856	-13.5796	26.1088	63.177	1
21.5488	6.8176	2.0774	0.7113	0.4142	22.8609	12.9205	6.4543	23.9321	108.52	1
24.9251	10.2825	2.4401	0.4791	0.245	14.6797	-17.1593	5.6988	12.174	119.474	1
47.2337	19.8555	3.2439	0.2144	0.12	17.0072	-33.2638	-13.45	3.5641	213.792	1
75.4045	40.178	3.4087	0.1178	0.0599	68.7596	60.9121	12.1566	13.77	230.517	1
37.1967	26.6725	3.2235	0.2062	0.1121	29.6163	18.7062	13.6322	10.3638	138.16	1
29.9045	15.1933	2.7202	0.4724	0.2848	18.9963	28.622	7.155	2.9967	173.984	1
86.291	26.1931	3.6349	0.1833	0.0928	-64.51	82.9791	19.5049	1.581	296.75	1
23.2204	0.0038	2.1287	0.7807	0.4201	-23.9774	-16.5585	-0.0001	74.3282	188.887	1
49.0724	15.8036	2.9238	0.2872	0.1734	9.35	22.821	9.1958	11.24	197.569	1
19.8537	16.559	2.4298	0.4758	0.2546	2.6021	-11.2684	-10.9321	41.838	211.925	1
18.7977	15.7316	2.4241	0.5198	0.2731	-12.7123	-17.6937	-12.031	38.1018	57.3645	1
34.2512	6.7906	2.3589	0.5821	0.3654	21.3696	21.6899	5.6587	43.554	134.486	1
12.787	11.5763	2.0473	0.7265	0.3722	-15.1619	5.3573	-11.5712	72.426	126.472	1
63.1254	18.643	2.8762	0.3311	0.1749	-69.8622	49.6986	-21.2178	6.9492	293.428	1
58.6792	26.0154	3.2076	0.2709	0.141	33.4313	51.1059	6.8846	14.967	269.606	1

Рис. 1. Изначальный набор данных

Класс g объявляется нулем, a класс h единицей. Входные данные масштабируются для ускорения градиентного спуска с помощью формулы 1.

$$x_j^{(i)} = \frac{x_j^{(i)}}{\max(x_j^{(1)}, \dots, x_j^{(m)})}, \quad (1)$$

где $i = 1, 2, \dots, m; j = 1, 2, \dots, n$.

3. Описание выбранных для анализа алгоритмов

В качестве инструмента машинного обучения использовалась нейронная сеть, написанная на языке программирования Python [5], а также использованы библиотеки numpy [6], sys, matplotlib.pyplot [7].

В НС реализован метод прямого распространения для генерации предсказаний, метод обратного распространения ошибки [8] для изменения весов, а также используется сигмоидальная функция активации.

Ошибка вычисляется как $\frac{\sum (y - Y)^2}{n}$, где y – полученное предсказание НС, Y – ожидаемый результат, n – количество примеров.

Вычисление точности:

Процент верного предсказания: $\frac{True}{n} * 100$, где $True$ – правильные предсказания, n – размер выборки.

Процент верного предсказания класса 1: $\frac{True}{n} * 100$, где $True$ – правильные предсказания, n – размер выборки класса 1.

Процент верного предсказания класса 2: $\frac{True}{n} * 100$, где *True* – правильные предсказания, *n* – размер выборки класса 2.

Процент неверного предсказания класса 1: $\frac{False}{n} * 100$, где *False* – неправильные предсказания класса 1, *n* – размер выборки.

Процент неверного предсказания класса 2: $\frac{False}{n} * 100$, где *False* – неправильные предсказания класса 2, *n* – размер выборки.

4. Анализ результатов

Начальная архитектуры НС: 1 входной слой, 1 скрытый слой, 1 выходной слой.

Модель нейронной сети показана на рисунке 2.




Рис. 2. Архитектура нейронной сети [9]

Проведя несколько экспериментов, стало понятно, что коэффициент обучения необходимо брать в диапазоне 0.0001 – 0.00001. Результаты для двух разных архитектур:

A – для обучающей выборки верно.

B – для обучающей выборки верно определен класс 1.

C – для обучающей выборки верно определен класс 2.

D – для обучающей выборки неверно определен класс 1.

E – для обучающей выборки неверно определен класс 2.

F – для тестовой выборки верно.

G – для тестовой выборки верно определен класс 1.

H – для тестовой выборки верно определен класс 2.

I – для тестовой выборки неверно определен класс 1.

J – для тестовой выборки неверно определен класс 2.

Все результаты приведены в процентах (табл. 1).

Таблица 1

Результаты работы программы					
Архитектура 10-5-1					
№	A	B	C	D	E
1	62.4	70.7	46.5	18.4	19.2
2	67.6	83.6	37.1	21.7	10.7
№	F	G	H	I	J
1	61.5	71.9	46.2	21.7	16.7
2	65.3	83.7	38.3	24.9	9.7
Архитектура 10-10-1					
№	A	B	C	D	E
1	63.5	74.6	42.3	19.5	14.7
2	66.5	76.4	47.9	18	15.5
№	F	G	H	I	J
1	61.8	74.5	43.2	23	15.2
2	64	74.8	48	21	15

Добавим 1 скрытый слой, повторим эксперимент:

Таблица 2

Результаты работы программы					
Архитектура 10-10-3-1					
№	A	B	C	D	E
1	65.5	100	0	34.5	0
2	64.6	67.85	58.4	14.3	21
3	69.5	98.7	13.4	29.9	0.7
4	73.5	90.8	40.4	20.5	6
№	F	G	H	I	J
1	59.6	100	0	40.45	0
2	64.7	68.3	59.4	16.4	18.9
3	64.6	98.6	14.6	34.6	0.9
4	70.6	91.3	40	24.3	5.2
Архитектура 10-7-3-1					
№	A	B	C	D	E
1	68.3	92.3	22.7	26.6	5
№	F	G	H	I	J
1	64.8	92.2	24.4	30.6	4.6

Функция стоимости изображена на рисунке 3. Все архитектуры НС показывали схожие графики функции стоимости, сходясь приблизительно к 0.2. Видно, что увеличивать количество итераций необходимости нет.




Рис. 3. Функция стоимости

Увеличение скрытых слоев и количества нейронов не дали существенного улучшения результатов.

Лучший результат в простой классификации (на обучающей выборке) – 73.5, но при этом вероятность принятия фонового события в качестве сигнала – 20.5, что является не лучшим результатом. Минимальная вероятность принятия фонового события в качестве сигнала (обучающая выборка) – 14.3, что достаточно хорошо относительно остальных результатов, но недостаточно для решения поставленной задачи. Исходя из полученных результатов можно сделать следующий вывод: для решения конкретной задачи нейронная сеть типа многослойный персептрон не подходит, необходимо использовать другие типы нейронных сетей.

Выводы

В статье проанализирована проблема классификации высокоэнергетических гамма-частиц в атмосферном телескопе Черенкова методами машинного обучения; обозначены основные понятия. Описан программный код для реализации метода обратного распространения ошибки и построен график функций стоимости. Спроектированы и реализованы нейронные сети с различными архитектурами и параметрами для сравнения, сделан вывод о наилучшем варианте использования архитектуры и параметров нейронной сети для решения задачи классификации высокоэнергетических гамма-частиц в атмосферном телескопе Черенкова.

Список литературы

1. Морозов Д.А. Применение нейронных сетей для прогнозирования в геоинформационных системах // Вопросы науки и образования, 2018. URL: <https://cyberleninka.ru/article/n/primenenie-neyronnyh-setey-dlya-prognozirovaniya-v-geoinformatsionnyh-sistemah/viewer> (дата обращения: 02.04.2020).

2. MAGIC Gamma Telescope Data Set [Электронный ресурс]. URL: <https://archive.ics.uci.edu/ml/datasets/MAGIC+Gamma+Telescope> (дата обращения: 11.01.2020).

3. Васильев Г.И., Холупенко Е.Е., Байко Д.А., Быков А.М., Красильщиков А.М., Павлов Г.Г. Влияние оптического фона ночного неба на наземные наблюдения гамма-всплесков в диапазоне 1-10 ГэВ.

4. Heck D., Knapp J., Capdevielle J.N., Schatz G., Thouw T. CORSIKA: A Monte Carlo Code to Simulate Extensive Air Showers // Tech. Rep. 1998. FZKA. P. 6019.

5. Python // Python. URL: <https://www.python.org/> (дата обращения: 11.01.2020).

6. NumPy // NumPy. URL: <https://numpy.org/> (дата обращения: 11.01.2020).

7. Matplotlib // Matplotlib. URL: <https://matplotlib.org/> (дата обращения: 11.01.2020).

8. Воронова Л.И., Воронов В.И. MachineLearning: регрессионные методы интеллектуального анализа данных: Учебное пособие. М.: МТУСИ, 2018. 83 с.

9. Шалтынова З.С., Тутова Н.В. Классификация спама с применением методов машинного обучения // XI Международная студенческая научная конференция «Студенческий научный форум – 2019». Российская академия естествознания. URL: <https://scienceforum.ru/2019/article/2018013813>(дата обращения: 11.01.2020).

УДК 004.93

doi:10.18720/SPBPU/2/id20-170

Виноградов Андрей Николаевич¹,

канд. физ.-мат. наук, доцент кафедры ИТ;

Куршев Евгений Петрович²,

канд. техн. наук, ведущий научный сотрудник ИЦИИ;

Тищенко Игорь Петрович³,

канд. техн. наук, заведующий лабораторией;

Иванов Егор Сергеевич⁴,

младший научный сотрудник

ПРИМЕНЕНИЕ КОМБИНИРОВАННОЙ СЕГМЕНТАЦИИ ДЛЯ РАСПОЗНАВАНИЯ МУЛЬТИСПЕКТРАЛЬНЫХ СНИМКОВ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

¹ ФГАОУ ВО «Российский университет дружбы народов»,

Москва, Россия,

¹ vinogradov-an@rudn.ru

^{2,3,4} ФГБУН «Институт программных систем им. А.К. Айламазяна

Российской академии наук», Переславль-Залесский, Россия,

² epk@epk.botik.ru, ³ igor.p.tishchenko@gmail.com, ⁴ penguin90@yandex.ru

Аннотация. Работа посвящена технологии сегментации мультиспектральных аэрокосмических снимков, полученных при дистанционном зондировании Земли. Спектральные отражательные свойства растительности и водных поверхностей