

Задание 2 по теме “Деревья решений.”

2.1 Определение типа источника гамма-излучения. 4FGL (LAT 10-year Source Catalog) — каталог источников гамма-излучения, зарегистрированных космической гамма-обсерваторией Fermi LAT. Среди таких источников есть внегалактические и галактические источники. К внегалактическим источникам относятся активные ядра галактик и их подкласс — блазары, среди галактических отдельно отметим пульсары. Часть гамма-пульсаров не излучают в гамма-диапазоне, поэтому их пульсации можно идентифицировать только по данным гамма-телескопов. Поиск подобных пульсаций — вычислительно трудоемкая задача (см., например, [1]). Сложность связана с тем, что частота пульсаций изменяется во времени, а частота регистрации гамма-квантов от источника в миллионы раз ниже частоты пульсаций. Для оптимизации использования ресурсов предлагается провести предварительный отбор объектов на основании данных о спектре объекта 4FGL.

В файле `4fgl_full.dat` [2] содержится информация о 7195 объектах 3FGL, 2577 из которых неидентифицированы. В первой колонке — имя объекта (общий для всех префикс “4FGL” опущен), во 2 и 3 колонках экваториальные координаты (прямое восхождение и склонение) в градусах. В колонках 4-9 — параметры эллипса, описывающего ошибку измерения положения источника, 10-46 параметры спектра и переменности (параметры переменности: 41-43). В колонке 47 содержится код типа источника или `unk` для неидентифицированных источников. Код типа источника принимает значения `bll`, `BLL`, `bcu`, `BCU`, `fsrq`, `FSRQ` для блазаров и значения `psr`, `PSR` для пульсаров. Более полное описание кодов приведено в Таблице 7 в работе [3].

Задача посвящена построению классификатора на основе деревьев решений.

- а) Выделить из каталога набор известных пульсаров и блазаров и случайно разбить его на две равные части: набор для тренировки и набор для тестирования. Построить дерево решений для классификации, используя набор для тренировки. Оценить точность классификации с помощью набора для тестирования.
- б) Реализовать бустинг оригинальным методом Р. Шапире [4]. Оценить точность классификации.
- в) Реализовать метод AdaBoost [5]. Оценить точность классификации.
- г) * Сравнить точность классификации собственной реализации с одной из библиотечных реализаций усиленных деревьев решений (BDT).
- д) Выполнить классификацию неидентифицированных объектов 3FGL.

2.2 Определение красного смещения по фотометрии. SDSS (Sloan Digital Sky Survey) — один из крупнейших современных каталогов звезд и галактик,

построенный с помощью 2.5-метрового широкоугольного телескопа в штате Нью-Мехико в США. Измерения проводятся в пяти спектральных полосах фотометрической системы $u'g'r'i'z$ со средними длинами волн от 355.1, 468.6, 616.5, 748.1 и 893.1 нм. Точное спектроскопическое измерение красного смещения (идентификация спектральных линий поглощения) доступно для нескольких миллионов из 500 миллионов объектов. Красное смещение остальных объектов предлагается оценить приближенно на основе данных SDSS.

В файле `sdss_train.dat` [6] содержится информация о 1999998 объектах с известным красным смещением. Данные о каждом объекте записаны в 37 колонках. В колонке 1 — идентификатор объекта, во 2 и 3 колонках экваториальные координаты (прямое восхождение и склонение) в градусах, в 4-13 колонках — звездные величины в 5 фотометрических полосах и их ошибки, 14-23 — радиусы по Петросяну и их ошибки в 5 фотометрических полосах, 24-33 — отношения полуосей эллипса и их ошибки в 5 фотометрических полосах, 34 — идентификатор в базе данных спектроскопии, 35 — класс объекта. В 36 колонке содержится красное смещение по спектроскопическим данным, а в 37 колонке его ошибка. Описание каждой колонки приведено в файле `sdss_train.colnames` [6], а описание каталога в работе [7]. Информация об 760002 объектах, красное смещение которых предстоит определить — в файле `sdss_test.dat` [6]. Формат последнего файла совпадает с описанным выше форматом файла `sdss_train.dat`, но не содержит последних двух колонок.

Задача посвящена определению красного смещения методом регрессии с помощью деревьев решений.

- а) Разбить каталог объектов с известным красным смещением на две равные части: набор для тренировки и набор для тестирования. Построить дерево решений для регрессии, используя набор для тренировки. Оценить точность регрессии с помощью набора для тестирования.
- б) Задать точность определения z , в пределах которой регрессионная оценка будет условно считаться правильной. Это определение позволяет разбить результаты работы регрессии на два класса и применить к регрессии логику, которая использовалась для классификации. Реализовать бустинг оригинальным методом Р. Шапире [4]. Оценить точность регрессии.
- в) Реализовать метод AdaBoost [5]. Оценить точность регрессии.
- г) * Сравнить точность регрессии собственной реализации с одной из библиотечных реализаций усиленных деревьев решений (BDT).
- д) Определить красное смещение для объектов SDSS, для которых спектроскопические данные не приведены. Предоставить на проверку преподавателю для сравнения с ответом, хранящимся в закрытой части сервера [8].

Список литературы

- [1] H. J. Pletsch *et al.*, “Discovery of Nine Gamma-Ray Pulsars in Fermi-LAT Data Using a New Blind Search Method,” *Astrophys. J.* **744**, 105 (2012) doi:10.1088/0004-637X/744/2/105 [arXiv:1111.0523 [astro-ph.HE]].

- [2] <http://cluster.inr.ac.ru/ML/4FGL/>
- [3] S. Abdollahi *et al.* [Fermi-LAT], “*Fermi* Large Area Telescope Fourth Source Catalog,” *Astrophys. J. Suppl.* **247** (2020) no.1, 33 [arXiv:1902.10045 [astro-ph.HE]].
- [4] R. E. Schapire, “The Strength of Weak Learnability,” *Machine Learning* **5** 197 (1990). <http://www.cs.princeton.edu/~schapire/papers/strengthofweak.pdf>
- [5] Y. Freund, R. E. Schapire, “A Short Introduction to Boosting”, *Journal of Japanese Society for Artificial Intelligence*, 14(5):771 (1999). <http://www.site.uottawa.ca/~stan/csi5387/boost-tut-ppr.pdf>
- [6] <http://cluster.inr.ac.ru/ML/SDSS/>
- [7] C. Stoughton *et al.* [SDSS], *Astron. J.* **123** (2002), 485-548 doi:10.1086/324741
- [8] http://cluster.inr.ac.ru/ML/SDSS/for_teacher/