

КЛАССИФИКАЦИЯ ДАННЫХ КАК ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ

Фрузорова В. А., Попок Р.В., Метельский А. В.
Белорусский национальный технический университет, Минск

Машинное обучение — класс методов искусственного интеллекта, одной из задач которых является не прямое выполнение задачи, а обучение решению множества сходных задач. В основе этих методов лежат такие разделы математики, как комбинаторика, дискретная математика, математический анализ, линейная алгебра, статистика, теория вероятности.

Другая цель машинного обучения — предсказать результат по входным данным. Чем более разнообразными они будут, тем сложнее программе выявить закономерности и дать точный результат. Примером может служить распознавание букв в тексте (однообразные данные) и распознавание изображения на фотографии (разнообразные данные).

Еще одной важной задачей машинного обучения является классификация объектов. Для классификации всегда нужен Учитель — заранее размеченные данные с признаками и категориями, по которым программа будет учиться разделять объекты на классы. Такой подход позволяет создавать различные классификаторы для различных целей. Например, новостные ленты в социальных сетях, предлагающие новости исходя из интересов пользователей, или классификация текстов по тематике и языкам, что необходимо для поисковых систем.

Не менее востребованная задача, которую решают с помощью машинного обучения – выбор наилучшего варианта из числа доступных. По такому принципу работают автомобили с автопилотом: программа выбирает наилучший вариант развития событий.

Раньше все спам-фильтры использовали наивный байесовский классификатор, основанный на теореме Байеса:

$$P(H_i / A) = \frac{P(H_i) \cdot P(A / H_i)}{P(A)}, \quad i = \overline{1, n},$$

Рисунок 1. Формула Байеса

$P(H_i / A)$ - вероятность события H_i , если наступит событие A

$P(H_i)$ – априорная вероятность события H_i

$P(A / H_i)$ – вероятность события A при истинности H_i ,

$P(A)$ – полная вероятность события A .

В спам-фильтрах определяют вероятность того, что письмо спам, при условии, что в нем встречаются определенные слова.

Популярным методом классификации в машинном обучении является метод опорных векторов. Он использует гиперплоскость, чтобы классифицировать данные на 2 класса. Для простой задачи с 2 параметрами гиперплоскость может быть линией, однако, если параметров больше – уже нет.

Метод опорных векторов позволяет спроецировать ваши данные в пространство большей размерности, используя для этого новые признаки объектов, а когда данные спроецированы, метод определяет гиперплоскость, которая делит данные на 2 класса наилучшим образом.




Рисунок 2. Визуализация разделения данных на два класса.

Суть метода в том, что он максимизирует отступ так, чтобы гиперплоскость находилась примерно на одинаковом расстоянии от 2 типов данных – это снижает шанс ошибок классификации.

У данного метода есть хорошее качество – поиск аномалий. Когда какой-либо признак объекта сильно отличается от среднего значения, программа выделяет этот участок как аномальный. Данная особенность нашла применение в медицине (компьютер подсвечивает врачу все подозрительные области МРТ или выделяет отклонения в анализах) и не только.

Литература

1. (2010) Классификация данных методом опорных векторов//Сайт <https://habr.com>. 29 сентября. (<https://habr.com/ru/post/105220/>) Просмотрено: 15.04.2019.

2. (2016) Метод опорных векторов (SVM)//Сайт <http://datascientist.one>. 15мая. (<http://datascientist.one/support-vector-machines/>) Просмотрено: 15.04.2019.

3. Udiproduct (2007) SVMwithpolynomialkernelvisualizationвекторов//YouTube. 5 февраля. (<https://www.youtube.com/watch?v=3liCbRZPrZA>) Просмотрено: 16.04.2019.

4. (2018) Машинное обучение для людей//Сайт <https://vas3k.ru>. 22июля. (https://vas3k.ru/blog/machine_learning/) Просмотрено: 14.04.2019.
5. (2015)6 простых шагов для освоения наивного байесовского алгоритма//Сайт <http://datareview.info>. 23 сентября. (<http://datareview.info/article/6-prostyih-shagov-dlya-osvoeniya-naivnogo-bayesovskogo-algoritma-s-primerom-koda-na-python/>) Просмотрено: 15.04.2019.
6. Veritasium(2017) The Bayesian Trap//YouTube. 5апреля. (<https://www.youtube.com/watch?v=R13BD8qKeTg>) Просмотрено: 16.04.2019.
7. (2017) Теорема Байеса: из-за чего весь сыр-бор?//Сайт <https://habr.com>. 16июня. (<https://habr.com/ru/post/404633/>) Просмотрено: 16.04.2019.