

Хеширование признаков

Илья Трофимов

22.09.2016

Машинное обучение и большие данные
ФИВТ, осень 2016

Машинное обучение с учителем:

Дана выборка $(\mathbf{x}_i, y_i)_{i=1}^n$, $\mathbf{x}_i \in X = \mathbb{R}^p, y_i \in Y$

построить функцию $f : X \rightarrow Y$

На самом деле:

Машинное обучение с учителем:

по выборке $(o_i, y_i)_{i=1}^n$, $o_i \in O$ (множество объектов), $y_i \in Y$
сгенерировать p признаков с помощью функций $f_1, \dots, f_p$

$$f_j : O \rightarrow \mathbb{R}$$

$$x_i = [f_1(o_i), \dots, f_p(o_i)]$$

построить функцию $f : X \rightarrow Y$

Пространства признаков высокой размерности

Пример 1. Классификация текстов. Представление в виде мешка слов.

Признаки - N-граммы.

Признаки - N-граммы с пропусками. (K-skip-N-grams)

Пространства признаков высокой размерности

Пример 1. Классификация текстов. Представление в виде мешка слов.

Признаки - N-граммы.

Признаки - N-граммы с пропусками. (K-skip-N-grams)

Текст: ABCDE

2-граммы: AB, BC, CD, DE

1-скип-2-граммы: A?C, B?D, C?E

Пространства признаков высокой размерности

Пример 1. Классификация текстов. Представление в виде мешка слов.

Признаки - N-граммы.

Признаки - N-граммы с пропусками. (K-skip-N-grams)

Текст: ABCDE

2-граммы: AB, BC, CD, DE

1-скип-2-граммы: A?C, B?D, C?E

Размерность быстро растет с ростом N

Пространства признаков высокой размерности

Пример 1. Классификация текстов. Представление в виде мешка слов.

Признаки - N-граммы.

Признаки - N-граммы с пропусками. (K-skip-N-grams)

Текст: ABCDE

2-граммы: AB, BC, CD, DE

1-скип-2-граммы: A?C, B?D, C?E

Размерность быстро растет с ростом N

Пример 2. Предсказание вероятности клика. Комбинации категориальных признаков.

UserID $\sim 10^6$, AdID $\sim 10^6$

Пространства признаков высокой размерности

Пример 1. Классификация текстов. Представление в виде мешка слов.

Признаки - N-граммы.

Признаки - N-граммы с пропусками. (K-skip-N-grams)

Текст: ABCDE

2-граммы: AB, BC, CD, DE

1-скип-2-граммы: A?C, B?D, C?E

Размерность быстро растет с ростом N

Пример 2. Предсказание вероятности клика. Комбинации категориальных признаков.

$\text{UserID} \sim 10^6, \text{AdID} \sim 10^6$

$\text{UserID} \times \text{AdID} \sim 10^{12}$

$$\mathbf{x}_i = [f_1(o_i), \dots, f_p(o_i)]$$

Методы машинного обучения принимают на вход вектор признаков $\mathbf{x} \in \mathbb{R}^p$

$$\mathbf{x}_i = [f_1(o_i), \dots, f_p(o_i)]$$

Методы машинного обучения принимают на вход вектор признаков $\mathbf{x} \in \mathbb{R}^p$

Подход 1. Пронумеровать признаки, проставить $f_j(o_i)$ в обучении и тесте.

$$\mathbf{x}_i = [f_1(o_i), \dots, f_p(o_i)]$$

Методы машинного обучения принимают на вход вектор признаков $\mathbf{x} \in \mathbb{R}^p$

Подход 1. Пронумеровать признаки, проставить $f_j(o_i)$ в обучении и тесте.

- 1 Нумерация может идти дальше, чем онлайн обучение
- 2 Увеличение размера датасета
- 3 Получается пространство большой размерности
- 4 Не онлайн
- 5 Необходимо использовать словарь <признак, индекс> при прогнозе

Генерация признаков

Хранить параметры модели в ассоциативном массиве (хеш-таблица, дерево): `map<признак, вес>`

$$\mathbf{x}_i = [f_1(o_i), \dots, f_p(o_i)]$$

Методы машинного обучения принимают на вход вектор признаков $\mathbf{x} \in \mathbb{R}^p$

Генерация признаков

Хранить параметры модели в ассоциативном массиве (хеш-таблица, дерево): `map<признак, вес>`

$$\mathbf{x}_i = [f_1(o_i), \dots, f_p(o_i)]$$

Методы машинного обучения принимают на вход вектор признаков $\mathbf{x} \in \mathbb{R}^p$

Объект: $o = \text{ABCDE}$

Метка: y

Признаки: $\mathbf{x} = \text{AB, BC, CD, DE}$

Шаг стохастического градиента:

- 1 for key in $\{ \text{AB, BC, CD, DE} \}$:
- 2 $w[key] = w[key] - \eta \frac{\partial L(f_w(\mathbf{x}), y)}{\partial w[key]}$

Подход 2. Генерировать признаки «на лету», использовать ассоциативный массив.

- 1 Нумерация не используется
- 2 Размера датасета не увеличивается
- 3 Получается пространство большой размерности
- 4 Онлайн
- 5 Необходимо использовать словарь <признак, вес> при прогнозе

Хеш-таблица

Хеш-функция: признак (строка) $\rightarrow \{1, \dots, 2^b\}$


Отображение должно быть достаточно «равномерным».

Хеш-таблица

Хеш-функция: признак (строка) $\rightarrow \{1, \dots, 2^b\}$

Отображение должно быть достаточно «равномерным».


Хеш-таблица, $v1$ = Хеш-функция + таблица размера 2^b , в ячейках таблицы храним списки (ключ, значение), если коллизии разрешаются методом цепочек




Как по признаку найти значение веса

Хеш-таблица, v2 - с коллизиями.


Сравнение методов хранения весов



Сравнение методов хранения весов



Сравнение методов хранения весов



Чем больше храним весов - тем лучше!

Основным возражением против хеширования являются коллизии.

Основным возражением против хеширования являются коллизии.

- 1 Актуально только на датасетах с небольшим числом признаков. Если признаков много, то среди них, как правило, есть сильно коррелированные (избыточность). Часть из них избежит коллизий.
- 2 На практике можно подобрать число бит в хеш-таблице b , так что при его увеличении качество предсказания не улучшается. Значит при данном значении b коллизии не вредят.

Пусть o - исходный объект обучающей выборки.

Пусть o - исходный объект обучающей выборки.

Обозначим $\phi(o) \in \mathbb{R}^{2^b}$ - вектор признаков после хеширования.

Пусть o - исходный объект обучающей выборки.
Обозначим $\phi(o) \in \mathbb{R}^{2^b}$ - вектор признаков после хеширования.

$$K(o, w) = (\phi(o), w) \text{ — хеш-ядро}$$

Решающее правило

$$K(o, w) > a$$

в новом признаковом пространстве будет линейным:

$$(\phi(o), w) > a$$

Пусть o - исходный объект обучающей выборки.
Обозначим $\phi(o) \in \mathbb{R}^{2^b}$ - вектор признаков после хеширования.

$$K(o, w) = (\phi(o), w) \text{ — хеш-ядро}$$

Решающее правило

$$K(o, w) > a$$

в новом признаковом пространстве будет линейным:

$$(\phi(o), w) > a$$

Представление объекта o в признаковом пространстве не нужно хранить явно, можно вычислять «на лету».

Hashing trick

Дано: $\mathbf{x} \in \mathbb{R}^n$ (n - большое),
хеш-функции $h: \mathbb{N} \rightarrow \{1, \dots, 2^b\}$, $\xi: \mathbb{N} \rightarrow \{-1, +1\}$

$$\phi_i^{h,\xi}(\mathbf{x}) = \sum_{j:h(j)=i} \xi(j)x_j$$

$$(\mathbf{x}, \mathbf{x}')_\phi \stackrel{\text{def}}{=} \sum_{i=1}^{2^b} \phi_i^{h,\xi}(\mathbf{x}) \phi_i^{h,\xi}(\mathbf{x}')$$

Утверждение 1. Хеш-ядро не смещено:

$$\mathbb{E}[(\mathbf{x}, \mathbf{x}')_\phi] = (\mathbf{x}, \mathbf{x}')$$

Утверждение 2. Оценка на дисперсию если $\|\mathbf{x}\|_2 = \|\mathbf{x}'\|_2 = 1$:

$$\mathbb{D}[(\mathbf{x}, \mathbf{x}')_\phi] = O\left(\frac{1}{2^b}\right)$$

Можно использовать как способ понижения размерности для разреженных $\mathbf{x}$.

Подход 3. Генерировать признаки «на лету», использовать хеш-таблицу с коллизиями.

- 1 Нумерация не используется
- 2 Размера датасета не увеличивается
- 3 Размер пространства признаков фиксирован
- 4 Онлайн
- 5 Для прогноза нужен только вектор размера 2^b

Пример: персонализированная фильтрация спама

- ❶ $3.2 * 10^6$ размеченных писем.
- ❷ 433167 пользователей.
- ❸ $\sim 40 * 10^6$ уникальных слов.

Как обучить персонализированный спам-фильтр, который был бы лучше неперсонализированного?

Пример: персонализированная фильтрация спама


- ❶ $3.2 * 10^6$ размеченных писем.
- ❷ 433167 пользователей.
- ❸ $\sim 40 * 10^6$ уникальных слов.

Как обучить персонализированный спам-фильтр, который был бы лучше неперсонализированного?


Плохое решение: Обучить общий фильтр (для всех пользователей) + 433167 персональных фильтров, использующих hashtable для хранения весов признаков. Это потребует $433167 * 40 * 10^6 * 4 \sim 70$ Терабайт.

Используем хеширование

Используем хеширование для прогноза: $\langle w, \phi(x) \rangle + \langle w, \phi_u(x) \rangle$



Результаты



2^{26} параметров = 64M весов = 256MB RAM.

В **x270K** более эффективное использование RAM.

- hash** Shi, Q., Petterson, J., Dror, G., Langford, J., Smola, A., Vishwanathan, S. V. N. (2009). Hash kernels for structured data. The Journal of Machine Learning Research, 10, 2615-2637.
- spam** Kilian Weinberger, Anirban Dasgupta, Josh Attenberg, John Langford, A. S. (2009). Feature Hashing for Large Scale Multitask Learning. In ICML.
- dna** Sonnenburg, S. (2010). COFFIN : A Computational Framework for Linear SVMs, in ICML.
- ad** Chapelle O., Manavoglu, E., Rosales R. Simple and scalable response prediction for display advertising