

Метрические методы

Виктор Владимирович Китов

МГУ им.Ломоносова, ф-т ВМиК, кафедра ММП.

I семестр 2015 г.

Содержание

- 1 Простейший вариант
- 2 Выбор метрики
- 3 Взвешенный учет ближайших соседей


Метод К-ближайших соседей (K-nearest neighbours)

Классификация методом k ближайших соседей


- ① Найти k ближайших объектов к интересующему объекту x в обучающей выборке.
- ② Сопоставить x самый часто встречающийся класс среди k соседей.

- Случай $k = 1$: алгоритм ближайшего соседа (nearest neighbour)
- Случай $k = N$: константный прогноз наиболее частым классом в выборке.
- В случае регрессии нужно усреднить характеристики k ближайших соседей.
- Основное предположение метода:
 - близкие объекты выдают похожие ответы

Пример: классификация одним ближайшим соседом



Пример: классификация 15 ближайшими соседями



Параметры метода

- Параметры:
 - число соседей k
 - функция близости $\rho(x, y)$
- Вариант метода с адаптивным k по точности ближайших соседей.

Свойства

- Преимущества:
 - нужно знать только ф-цию близости между объектами, сами признаки не нужны.
 - может быть применен к объектам любой сложности, если задана ф-ция близости
 - простая логика работы, легко объяснить и реализовать
 - интерпретируемость (case based reasoning)
 - не требует обучения
 - может применяться в online случаях.
 - K-CV можно заменить на LOO оценивание.
- Недостатки:
 - медленная классификация со сложностью $O(N)$
 - требования по памяти тоже $O(N)$, т.к. нужно хранить всю выборку
 - точность ухудшается с ростом размерности пространства

Проклятие размерности (curse of dimensionality)

- Проклятие размерности - явление, когда с ростом размерности признакового пространства D методу для поддержания точности требуется обучающая выборка, которая растет экспоненциально от D .
- Пример: оценка гистограмм

Проклятие размерности (curse of dimensionality)

- Случай К-ближайших соседей:

- допущение: объекты распределены равномерно в признаковом пространстве
- шар радиуса R имеет объем $V(R) = CR^D$, $C = \frac{\pi^{D/2}}{\Gamma(D/2+1)}$.
- отношение объемов шаров радиуса R и $R - \varepsilon$:

$$\frac{V(R - \varepsilon)}{V(R)} = \left(\frac{R - \varepsilon}{R} \right)^D \xrightarrow{D \rightarrow \infty} 0$$

- основной объем концентрируется на поверхности сферы, значит там лежат ближайшие соседи.
- ближайшие соседи перестают быть близкими по расстоянию.
- В реальных задачах признаки могут быть распределены не равномерно по всему объему, а быть зависимыми и лежать на многообразии меньшей размерности.

Классификация - пограничный случай

Когда несколько классов имеют одинаковый ранг, можно сопоставить класс:

- случайнym образом
- имеющiй большую априорную вероятность
- чей ближайший представитель ближе к x
- для которого среднее значение представителей этого класса среди ближайших соседей ближе
- чей самый дальний представитель среди ближайших соседей ближе (т.е. класс представлен более компактно)

Содержание

- 1 Простейший вариант
- 2 Выбор метрики
- 3 Взвешенный учет ближайших соседей

Нормализация признаков

- Чаще всего используется Евклидова метрика близости:

$$\rho(x, z) = \sqrt{\sum_{d=1}^D (x^d - z^d)^2}$$

- Необходимо нормализовывать признаки.

- Определим μ_j , σ_j , L_j , U_j как среднее значение, стандартное отклонение, минимальное и максимальное значение j -го признака.

Преобразование	Свойства результата
$x'_j = \frac{x_j - \mu_j}{\sigma_j}$	среднее=0, дисперсия=1.
$x'_j = \frac{x_j - L_j}{U_j - L_j}$	принадлежит интервалу [0, 1].

Нормализация признаков

- Нелинейные трансформации для признаков, допускающих редкие большие значения:
 - $\tilde{x}^i = \log(x^i)$
 - $\tilde{x}^i = (x^i)^p$, $0 \leq p < 1$
- Для $F_i(\alpha) = P(x^i \leq \alpha)$ преобразование $\tilde{x}^i \rightarrow F_i(x^i)$ даст признак, равномерно распределенный на $[0, 1]$.

Выбор функции расстояния

Metric	$d(x, z)$
Евклидова	$\sqrt{\sum_{i=1}^D (x^i - z^i)^2}$
L_p	$\sqrt[p]{\sum_{i=1}^D (x^i - z^i)^p}$
L_∞	$\max_{i=1,2,\dots,D} x^i - z^i $
L_1	$\sum_{i=1}^D x^i - z^i $
Canberra	$\frac{1}{D} \sum_{i=1}^D \frac{ x^i - z^i }{x^i + z^i}$
Ланса-Уильямса	$\frac{\sum_{i=1}^D x^i - z^i }{\sum_{i=1}^D x^i + z^i}$
косинусная мера	$1 - \frac{\sum_{i=1}^D x^i z^i}{\sqrt{\sum_{i=1}^D (x^i)^2} \sqrt{\sum_{i=1}^D (z^i)^2}}$

Нормализующее преобразование

- x распределен согласно некоторому распределению со средним μ и невырожденной матрицей ковариации Σ ($\mu \in \mathbb{R}^D$, $\Sigma \in \mathbb{R}^{D \times D}$)
- Тогда нормализующее преобразование (whitening) $z = \Sigma^{-1/2}(x - \mu)$ даст новый вектор признаков со средним 0 и ковариацией $I \in \mathbb{R}^{D \times D}$, где I - это единичная матрица.
- Доказательство:

$$\mathbb{E}z = \mathbb{E}\left\{\Sigma^{-1/2}(x - \mu)\right\} = \Sigma^{-1/2}\mathbb{E}\{x - \mu\} = \mathbf{0} \in \mathbb{R}^D$$

$$\begin{aligned} \text{cov}[z] &= \mathbb{E}(z - \mathbb{E}z)(z - \mathbb{E}z)^T = \mathbb{E}zz^T \\ &= \mathbb{E}\left\{\Sigma^{-1/2}(x - \mu)(x - \mu)^T(\Sigma^{-1/2})^T\right\} = \\ &= \Sigma^{-1/2}\mathbb{E}\left\{(x - \mu)(x - \mu)^T\right\}(\Sigma^{-1/2})^T = \\ &= \Sigma^{-1/2}\Sigma\Sigma^{-1/2} = I \end{aligned}$$

Расстояние между нормализациями

- Расстояние между x и x' можно считать в нормализованном пространстве как Евклидово расстояние между $z = \Sigma^{-1/2}(x - \mu)$ и $z' = \Sigma^{-1/2}(x' - \mu)$:


$$\begin{aligned}\rho_M(x, x') &= \rho_E(z, z') = \sqrt{(z - z')^T (z - z')} = \\ &= \sqrt{(x - x')^T \Sigma^{-1/2} \Sigma^{-1/2} (x - x')} \\ &= \sqrt{(x - x')^T \Sigma^{-1} (x - x')}\end{aligned}$$

- Это называется *расстоянием Махаланобиса*.
- Частный случай: если признаки некоррелированы и $\text{Var } x^i = \sigma_i^2$, то $\rho(x, \tilde{x}) = \sqrt{\sum_i \frac{(x^i - \tilde{x}^i)^2}{\sigma_i^2}}$


Расстояние Махalanобиса - иллюстрация

(A): объекты в исходном признаковом пространстве и множество точек $G_\alpha = \{x : \rho_M(x, \mu) = \alpha\}$. (B): объекты в нормализованном признаковом пространстве и образ G_α - множество точек $\{z : \rho_E(z, 0) = \alpha\}$.

(A)



(B)



Содержание

- 1 Простейший вариант
- 2 Выбор метрики
- 3 Взвешенный учет ближайших соседей

Взвешенный учет

Определим $x_{i_1}, x_{i_2}, \dots, x_{i_N}$ как переупорядочивание x_1, x_2, \dots, x_N по расстоянию до x : $\rho(x, x_{i_1}) \leq \rho(x, x_{i_2}) \leq \dots \leq \rho(x, x_{i_N})$.

Определим $z_1 = x_{i_1}, z_2 = x_{i_2}, \dots, z_K = x_{i_K}$.

Метод ближайших соседей можно определить через C дискриминантных функций:

$$g_c(x) = \sum_{k=1}^K \mathbb{I}[z_k \in \omega_c], \quad c = 1, 2, \dots, C.$$

Взвешенный учет ближайших соседей:

$$g_c(x) = \sum_{k=1}^K w(k, \rho(x, z_k)) \mathbb{I}[z_k \in \omega_c], \quad c = 1, 2, \dots, C.$$

Часто выбираемые веса

Независимые от x :

$$w_k = \alpha^k, \quad \alpha \in (0, 1)$$

$$w_k = \frac{K + 1 - k}{K}$$

Зависимые от x :

$$w_k = \begin{cases} \frac{\rho(z_K, x) - \rho(z_k, x)}{\rho(z_K, x) - \rho(z_1, x)}, & \rho(z_K, x) \neq \rho(z_1, x) \\ 1 & \rho(z_K, x) = \rho(z_1, x) \end{cases}$$

$$w_k = \frac{1}{\rho(z_k, x)}$$

Понятие отступа

- Рассмотрим обучающую выборку:
 $(x_1, c_1), (x_2, c_2), \dots (x_N, c_N)$, где c_i - правильный класс для объекта x_i , а $\mathbf{C} = \{1, 2, \dots, C\}$ - множество допустимых классов.
- Определим понятие отступа:


$$M(x_i, c_i) = g_{c_i}(x_i) - \max_{c \in \mathbf{C} \setminus \{c_i\}} g_c(x_i)$$

- отступ отрицательный \Leftrightarrow объект x_i был неправильно классифицирован
- величина отступа показывает, насколько классификатор уверен, что объект x_i может быть отнесен к истинному классу c_i

Классификация объектов по отступам

По величине отступа объекты делятся на следующие категории:

- ① Объекты, классифицированные верно с высокой степенью уверенности
- ② Правильно классифицированные объекты
- ③ Пограничные объекты (их классификация неустойчива)
- ④ Неправильно классифицированные объекты
- ⑤ Объекты, сильно выбивающиеся из закономерности, определенной классификатором



Критерии качества по отступу

Хороший классификатор:

- минимизирует область отрицательных отступов
- классифицирует правильно с высокой степенью уверенности (высоким $M(x_i, c_i)$)