

Семинары по метрическим методам классификации

Евгений Соколов

5 сентября 2014 г.

1 Метод k ближайших соседей

§1.1 Описание алгоритма

Пусть дана обучающая выборка $X = (x_i, y_i)_{i=1}^{\ell} \subset \mathbb{X}$ и функция расстояния $\rho : \mathbb{X} \times \mathbb{X} \rightarrow [0, \infty)$, и требуется классифицировать новый объект $u \in \mathbb{X}$. Расположим объекты обучающей выборки X в порядке возрастания расстояний до u :

$$\rho(u, x_u^{(1)}) \leq \rho(u, x_u^{(2)}) \leq \dots \leq \rho(u, x_u^{(\ell)}),$$

где через $x_u^{(i)}$ обозначается i -й сосед объекта u . Алгоритм *k ближайших соседей* относит объект u к тому классу, представителей которого окажется больше всего среди k его ближайших соседей:

$$a(u; X^{\ell}, k) = \arg \max_{y \in Y} \sum_{i=1}^k [y_u^{(i)} = y].$$

Параметр k обычно настраивается с помощью кросс-валидации.

§1.2 Случай евклидовой метрики

Разберем особенности и проблемы метода k ближайших соседей, возникающие при использовании евклидовой метрики в качестве функции расстояния:

$$\rho(x, y) = \left(\sum_{i=1}^d |x_i - y_i|^2 \right)^{1/2}.$$

1.2.1 Границы классов

Диаграмма Вороного, соответствующая выборке X^{ℓ} — это такое разбиение пространства на области, что каждая область состоит из точек, для которых одна и та же точка из выборки является ближайшей. Более формально, диаграмма Вороного для выборки X^{ℓ} состоит из ℓ областей R_1, \dots, R_{ℓ} , определяемых как

$$R_i = \{x \in \mathbb{R}^d \mid \rho(x, x_i) < \rho(x, x_j), j \neq i\}.$$

Очевидно, что при использовании классификатора ближайшего соседа ($k = 1$) граница между классами является подмножеством границ между такими областями.

Опр. 1.1. Область $R \subset \mathbb{R}^d$ называется *выпуклым многогранником*, если она является пересечением конечного числа полупространств:

$$R = \bigcap_{i=1}^n \{x \in \mathbb{R}^d \mid \langle w_i, x \rangle < 0\}.$$

Задача 1.1. Показать, что множество точек, для которых ближайшим соседом из выборки является заданный объект x_i , представляет собой выпуклый многогранник.

Решение. Условие того, что x_i является ближайшей точкой выборки к u , записывается как

$$\sum_{p=1}^d (x_{ip} - u_p)^2 < \sum_{p=1}^d (x_{jp} - u_p)^2, \quad j \neq i.$$

Распишем его:

$$\sum_{p=1}^d (x_{ip}^2 - 2x_{ip}u_p + u_p^2) < \sum_{p=1}^d (x_{jp}^2 - 2x_{jp}u_p + u_p^2), \quad j \neq i;$$

$$\sum_{p=1}^d (x_{ip}^2 - 2x_{ip}u_p) < \sum_{p=1}^d (x_{jp}^2 - 2x_{jp}u_p), \quad j \neq i;$$

$$\sum_{p=1}^d (x_{ip}^2 - x_{jp}^2 + 2(x_{jp} - x_{ip})u_p) < 0, \quad j \neq i;$$

$$2 \sum_{p=1}^d (x_{jp} - x_{ip})u_p + \sum_{p=1}^d (x_{ip}^2 - x_{jp}^2) < 0, \quad j \neq i.$$

Мы получили набор линейных относительно u неравенств, каждое из которых задает полупространство. Их пересечение является множеством точек, для которых x_i является ближайшим соседом, и является выпуклым многогранником по определению. ■

Классификатор одного ближайшего соседа является крайне чувствительным к шумовым объектам и выбросам, и граница между классами может оказаться очень сложной. По мере увеличения k граница сглаживается за счет «усреднения» по нескольким объектам.

1.2.2 Нормализация признаков

Умножим один из признаков (например, первый) на константу C . Евклидово расстояние примет следующий вид:

$$\rho_2(x, y) = \sqrt{C(x_1 - y_1)^2 + \sum_{i=2}^d (x_i - y_i)^2}.$$

Таким образом, различие по первому признаку будет считаться в C раз более значимым, чем различия по всем остальным признакам. При этом расположение объектов относительно друг друга не изменилось — изменился лишь масштаб!

Рассмотрим простой пример чувствительности метода ближайшего соседа к масштабу признаков. Допустим, решается задача определения пола человека по двум признакам: росту (в сантиметрах, принимает значения примерно от 150 до 200) и уровню экспрессии гена SRY (безразмерная величина от нуля до единицы; у мужчин ближе к единице, у женщин ближе к нулю). Обучающая выборка состоит из двух объектов: $x_1 = (180, 0.2)$, девочка и $x_2 = (173, 0.9)$, мальчик. Требуется классифицировать новый объект $u = (178, 0.85)$. Воспользуемся классификатором одного ближайшего соседа. Расстояния от u до объектов обучения равны $\rho(u, x_1) \approx 2.1$ и $\rho(u, x_2) \approx 5$. Мы признаем новый объект девочкой, хотя это не так — высокий уровень экспрессии гена SRY позволяет с уверенностью сказать, что это мальчик. Из-за сильных различий в масштабе признаков уровень экспрессии практически не учитывается при классификации, что совершенно неправильно.

Чтобы избежать подобных проблем, признаки следует нормировать. Это можно делать, например, следующими способами:

- Нормировка на единичную дисперсию:

$$\tilde{x}^j = \frac{x^j - \bar{x}^j}{\sigma(x^j)}.$$

- Нормировка на отрезок $[0, 1]$:

$$\tilde{x}^j = \frac{x^j - \min(x^j)}{\max(x^j) - \min(x^j)}.$$

Здесь x^j — это вектор, составленный из j -х признаков всех объектов. Иными словами, это j -й столбец матрицы «объекты-признаки».

1.2.3 Шумовые признаки

Задача 1.2. Рассмотрим задачу с одним признаком и двумя объектами обучающей выборки: $x_1 = 0.1$, $x_2 = 0.5$. Первый объект относится к первому классу, второй — ко второму. Добавим к объектам шумовой признак, распределенный равномерно на отрезке $[0, 1]$. Пусть требуется классифицировать новый объект $u = (0, 0)$. Какова вероятность, что после добавления шума второй объект окажется к нему ближе, чем первый?

Решение. Задача сводится к вычислению вероятности $\mathbb{P}(0.5^2 + \xi_2^2 \leq 0.1^2 + \xi_1^2)$, где ξ_1 и ξ_2 — независимые случайные величины, распределенные равномерно на $[0, 1]$. Вычислим ее:

$$\begin{aligned} \mathbb{P}(0.5^2 + \xi_2^2 \leq 0.1^2 + \xi_1^2) &= \mathbb{P}(\xi_1^2 \geq 0.24 + \xi_2^2) = \\ &= \int_0^{\sqrt{0.76}} \int_{\sqrt{x_2^2 + 0.24}}^1 dx_1 dx_2 = \int_0^{\sqrt{0.76}} \left(1 - \sqrt{x_2^2 + 0.24}\right) dx_2 \approx 0.275. \end{aligned}$$

■

Таким образом, шумовые признаки могут оказать сильное влияние на метрику. Обнаружить шумовые признаки можно, удаляя поочередно все признаки и смотря на ошибку на тестовой выборке или ошибку кросс-валидации. Более сложные методы отбора информативных признаков будут разобраны позже на лекциях.

1.2.4 «Проклятие размерности»

Пусть объекты выборки — это точки, равномерно распределенные в d -мерном кубе $[0, 1]^d$. Рассмотрим выборку, состоящую из 5000 объектов, и применим алгоритм пяти ближайших соседей для классификации объекта u , находящегося в начале координат. Выясним, на сколько нужно отступить от этого объекта, чтобы с большой вероятностью встретить пять объектов выборки. Для этого построим подкуб единичного куба, включающий в себя начало координат и имеющий объем δ , и найдем такое значение δ , при котором в этот подкуб попадет как минимум пять объектов выборки с вероятностью 0.95.

Задача 1.3. Запишите выражение для δ .

Решение.

$$\min \left\{ \delta \mid \sum_{k=5}^{5000} \binom{5000}{k} \delta^k (1 - \delta)^{5000-k} \geq 0.95 \right\}.$$

■

Минимальное значение δ , удовлетворяющее этому уравнению, приблизительно равно приблизительно 0.0018. Отсюда находим, что для того, чтобы найти пять соседей объекта u , нужно по каждой координате отступить на $0.0018^{1/d}$. Уже при $d = 10$ получаем, что нужно отступить на 0.53, при $d = 100$ — на 0.94. Таким образом, при больших размерностях объекты становятся сильно удалены друг от друга, из-за чего классификация на основе сходства объектов может потерять смысл. В то же время отметим, что в рассмотренном примере признаки объектов представляли собой равномерный шум, тогда как в реальных задачах объекты могут иметь осмысленные распределения, позволяющие построение модели классификации даже при больших размерностях.

Настоящая же проблема, связанная с «проклятием размерности», заключается в невозможности эффективного поиска ближайших соседей для заданной точки. Было показано, что сложность всех популярных методов решения этой задачи становится линейной по размеру выборки по мере роста размерности [1]. В то же время можно добиться эффективного поиска, если решать задачу поиска ближайших соседей приближенно. Ниже этот вопрос будет разобран более подробно.

§1.3 Примеры функций расстояния

1.3.1 Метрика Минковского

Метрика Минковского определяется как:

$$\rho_p(x, y) = \left(\sum_{i=1}^d |x_i - y_i|^p \right)^{1/p}$$

для $p \geq 1$. При $p \in (0, 1)$ данная функция метрикой не является, но все равно может использоваться как мера расстояния.

Частными случаями данной метрики являются:

- Евклидова метрика ($p = 2$). Задаёт расстояние как длину прямой, соединяющей заданные точки.
- Манхэттенское расстояние ($p = 1$). Минимальная длина пути из x в y при условии, что можно двигаться только параллельно осям координат.
- Метрика Чебышева ($p = \infty$), выбирающая наибольшее из расстояний между векторами по каждой координате:

$$\rho_{\infty}(x, y) = \max_{i=1, \dots, d} |x_i - y_i|.$$

- «Считающее» расстояние ($p = 0$), равное числу координат, по которым векторы x и y различаются:

$$\rho_0(x, y) = \sum_{i=1}^d [x_i \neq y_i].$$

Отметим, что считающее расстояние не является нормой.

Отметим, что по мере увеличения параметра p метрика слабее штрафует небольшие различия между векторами и сильнее штрафует значительные различия.

В случае, если признаки неравнозначны, используют взвешенное расстояние:

$$\rho_p(x, y; w) = \left(\sum_{i=1}^d w_i |x_i - y_i|^p \right)^{1/p}, \quad w_i \geq 0.$$

Задача 1.4. Рассмотрим функцию $f(x) = \rho_2(x, 0; w)$. Что представляют из себя линии уровня такой функции?

Решение. Распишем квадрат функции $f(x)$ (форма линий уровня от этого не изменится):

$$f^2(x) = \sum_{i=1}^d w_i x_i^2.$$

Сделаем замену $x_i = \frac{x'_i}{\sqrt{w_i}}$:

$$f^2(x') = \sum_{i=1}^d x_i'^2.$$

В новых координатах линии уровня функции расстояния представляют собой окружности с центром в нуле. Сама же замена представляет собой растяжение вдоль каждой из координат, поэтому в исходных координатах линии уровня являются эллипсами, длины полуосей которых пропорциональны $\sqrt{w_i}$. ■

Вывод: благодаря весам линии уровня можно сделать эллипсами с осями, параллельными осям координат. Это может быть полезно, если признаки имеют разные масштабы — благодаря весам автоматически будет сделана нормировка.

Весы можно либо настраивать, минимизируя ошибку кросс-валидации, либо выбирать из эвристических соображений. Например, можно брать веса равными корреляции между признаком и целевым вектором:

$$w_i = \left| \frac{\sum_{j=1}^{\ell} x_{ji} y_j}{\left(\sum_{j=1}^{\ell} x_{ji}^2\right)^{1/2} \left(\sum_{j=1}^{\ell} y_j^2\right)^{1/2}} \right|.$$

1.3.2 Расстояние Махалонбиса

Расстояние Махалонбиса определяется следующим образом:

$$\rho(x, y) = \sqrt{(x - y)^T S^{-1} (x - y)},$$

где S — симметричная положительно определенная матрица.

Напомним, что собственным вектором матрицы S называется такой вектор x , что $Sx = \lambda x$ для некоторого λ . Если матрица S симметричная, то из ее собственных векторов можно составить ортонормированный базис. Сформировав матрицу Q из таких собственных векторов (один столбец — один вектор), получим следующие два соотношения:

$$SQ = Q\Lambda \Rightarrow S = Q\Lambda Q^{-1},$$

где Λ — диагональная матрица, в которой записаны собственные значения матрицы S . При этом матрица Q является ортогональной: $Q^T Q = I$, $Q^T = Q^{-1}$.

Изучим, как ведет себя расстояние Махалонбиса, если с его помощью сравнивать начало координат с произвольной точкой x . Сделаем для этого замену $x' = Q^T x$. Она соответствует такому повороту осей координат, что координатные оси совпадают со столбцами матрицы Q (то есть с собственными векторами).

Выясним теперь, как выглядят линии уровня метрики в новых координатах:

$$\begin{aligned} \rho^2(x, 0) &= x^T S^{-1} x = x'^T Q^T S^{-1} Q x' = x'^T (Q^{-1} S Q)^{-1} x' = \\ &= x'^T \Lambda^{-1} x' = \sum_{i=1}^d \frac{x_i'^2}{\lambda_i}. \end{aligned}$$

Получаем, что линии уровня представляют собой эллипсы с осями, параллельными осям координат, причем длины полуосей равны корням из собственных значений $\sqrt{\lambda_i}$. Таким образом, расстояние Махалонбиса позволяет получить линии уровня в виде произвольно ориентированных эллипсов.

Матрицу S можно настраивать либо по кросс-валидации, либо брать равной выборочной ковариационной матрице: $\hat{S} = \frac{1}{n-1} X^T X$.

Задача 1.5. *Покажите, что выборочная ковариационная матрица является неотрицательно определенной.*

Решение. Напомним, что матрица A называется неотрицательно определенной, если $\langle Az, z \rangle \geq 0$ для всех z .

Покажем неотрицательную определенность выборочной ковариационной матрицы:

$$\langle X^T X z, z \rangle = (X^T X z)^T z = z^T X^T X z = (X z)^T (X z) = \|X z\|^2 \geq 0.$$

■

1.3.3 Косинусная мера

Пусть заданы векторы x и y . Известно, что их скалярное произведение и косинус угла θ между ними связаны следующим соотношением:

$$\langle x, y \rangle = \|x\| \|y\| \cos(\theta).$$

Соответственно, косинусное расстояние определяется как

$$\rho_{\cos}(x, y) = \arccos \left(\frac{\langle x, y \rangle}{\|x\| \|y\|} \right) = \arccos \left(\frac{\sum_{i=1}^d x_i y_i}{\left(\sum_{i=1}^d x_i^2 \right)^{1/2} \left(\sum_{i=1}^d y_i^2 \right)^{1/2}} \right).$$

Косинусная мера часто используется для измерения схожести между текстами. Каждый документ описывается вектором, каждая компонента которого соответствует слову из словаря. Компонента равна единице, если соответствующее слово встречается в тексте, и нулю в противном случае. Тогда косинус между двумя векторами будет тем больше, чем больше слов встречаются в этих двух документах одновременно.

1.3.4 Расстояние Джаккарда

Выше мы рассматривали различные функции расстояния для случая, когда объекты обучающей выборки являются вещественными векторами. Если же объектами являются множества (например, каждый объект — это текст, представленный множеством слов), то их сходство можно измерять с помощью *расстояния Джаккарда*:

$$\rho_J(A, B) = 1 - \frac{|A \cap B|}{|A \cup B|}.$$

Задача 1.6. Пусть все множества являются подмножествами некоторого конечного упорядоченного множества $U = \{u_1, \dots, u_N\}$. Тогда любое множество A можно представить в виде бинарного вектора длины N , в котором единица в i -й позиции стоит тогда и только тогда, когда $u_i \in A$. Запишите формулу для расстояния Джаккарда, исходя из таких обозначений, и сравните ее с формулой для косинусной меры.

Решение. Пусть X и Y — два множества, $(x_i)_{i=1}^N$ и $(y_i)_{i=1}^N$ — их векторные представления. Тогда мощность их пересечения можно записать следующим образом:

$$|X \cap Y| = \sum_{i=1}^N x_i y_i = \langle X, Y \rangle,$$

а мощность их объединения как

$$\begin{aligned} |X \cup Y| &= \sum_{i=1}^N x_i + \sum_{i=1}^N y_i - \sum_{i=1}^N x_i y_i = \\ &= \sum_{i=1}^N x_i^2 + \sum_{i=1}^N y_i^2 - \sum_{i=1}^N x_i y_i = \\ &= \|X\|^2 + \|Y\|^2 - \langle X, Y \rangle. \end{aligned}$$

Тогда:

$$\rho_J(X, Y) = 1 - \frac{\langle X, Y \rangle}{\|X\|^2 + \|Y\|^2 - \langle X, Y \rangle}.$$

■

1.3.5 Редакторское расстояние

Для измерения сходства между двумя строками (например, последовательностями ДНК) можно использовать *редакторское расстояние*, которое равно минимальному числу вставок и удалений символов, с помощью которых можно преобразовать первую строку ко второй. В зависимости от специфики задачи можно также разрешать замены, перестановки соседних символов и прочие операции.

§1.4 Заключение

Основной проблемой метода ближайших соседей является то, что его обучение заключается лишь в запоминании выборки (и, возможно, построении структуры данных для эффективного поиска в ней). При этом не происходит никакой настройки параметров с целью максимизации качества, из-за чего метод не может приспособиться к ненормированным или шумовым признакам. В то же время метод работает с объектами лишь через функцию расстояния, что позволяет использовать его для работы с самыми разнообразными данными (векторами, множествами, строками, распределениями и т.д.).

Список литературы

- [1] Weber, R., Schek, H. J., Blott, S. (1998). A Quantitative Analysis and Performance Study for Similarity-Search Methods in High-Dimensional Spaces. // Proceedings of the 24th VLDB Conference, New York C, 194–205.