

Курс «Введение в машинное обучение»

Метрические методы машиинного обучения

Воронцов Константин Вячеславович

k.v.vorontsov@phystech.edu

<http://www.MachineLearning.ru/wiki?title=User:Vokov>

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Введение в машинное обучение (курс лекций, К.В.Воронцов)»

- ❶ СИМВОЛИЗМ – поиск логических закономерностей
 - Decision Tree, Rule Induction
- ❷ КОННЕКЦИОНИЗМ – обучаемые нейронные сети
 - BackPropagation, Deep Belief Nets, Deep Learning
CNN, ResNet, LSTM, GRU, Attention, Transformer
- ❸ ЭВОЛЮЦИОНИЗМ – саморазвитие сложных моделей
 - Genetic Algorithms, Genetic Programming, Symbolic Regression
- ❹ БАЙЕСИОНИЗМ и вероятностно-статистические методы
 - MLE, EM, GLM, LR, OBC, Naive Bayes, QD, LDF
Bayesian Networks, Bayesian Learning, Graphical Models
- ❺ АНАЛОГИЗМ – «близким объектам близкие ответы»
 - kNN, RBF, SVM, KDE, Kernel Smoothing
- ⊕ КОМПОЗИЦИОНИЗМ – коопeração моделей
 - Weighted Voting, Boosting, Bagging, Stacking,
Random Forest, Яндекс.CatBoost



1 Введение расстояний между объектами

- Гипотезы компактности или непрерывности
- Функции расстояния между векторами признаков
- Беспризнаковые способы вычисления расстояний

2 Метрические методы обучения с учителем

- Классификация
- Непараметрическая регрессия
- Задача отбора эталонов

3 Метрические методы обучения без учителя

- Непараметрическое оценивание плотности
- Кластеризация
- Многомерное шкалирование

Гипотезы непрерывности и компактности

Задачи классификации и регрессии:

X — объекты, Y — ответы;

$X^\ell = (x_i, y_i)_{i=1}^\ell$ — обучающая выборка;

Гипотеза непрерывности (для регрессии):

близким объектам соответствуют близкие ответы.

выполнена:




не выполнена:




Гипотеза «компактности» (для классификации):

близкие объекты, как правило, лежат в одном классе.

выполнена:




не выполнена:



Пример: задача классификации цветков ириса [Фишер, 1936]

Классы — компактные сгустки точек (3 класса по 50 объектов)



Формализация понятия «расстояние» (*distance*)

Евклидова метрика и обобщённая метрика Минковского:

$$\rho(x, x_i) = \left(\sum_{j=1}^n |x^j - x_i^j|^2 \right)^{1/2} \quad \rho(x, x_i) = \left(\sum_{j=1}^n w_j |x^j - x_i^j|^p \right)^{1/p}$$


$x = (x^1, \dots, x^n)$ — вектор признаков объекта x

$x_i = (x_i^1, \dots, x_i^n)$ — вектор признаков объекта x_i

w_j — веса признаков (возможно, обучаемые) играют две роли:

- нормировка, приведение к общему масштабу
- подавление неинформативных (мешающих) признаков

Линии уровня (эквидистантные поверхности) при различных p :




Расстояния между строками / сигналами

Для строк — редакторское расстояние Левенштейна:




CTGGG**CT**AAAAG**GTC**CCTTAGCC..TTTAGAAAAA.GGGCCATTAGG**AA**TTGC
CTGGG**ACT**AAA....CCTTAGC**CT**ATTTACAAAAA**T**GGGCCATTAGG...TTGC

Для сигналов — энергия сжатий и растяжений:



Расстояния между изображениями

Расстояние между изображениями на основе выравнивания:



Оценивается энергия растяжения прямоугольной сетки

Общая формула метрического классификатора

Для произвольного $x \in X$ отранжируем объекты x_1, \dots, x_ℓ :

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

$x^{(i)}$ — i -й сосед объекта x среди x_1, \dots, x_ℓ ;

$y^{(i)}$ — ответ на i -м соседе объекта x .

Метрический алгоритм классификации относит объект x к тому классу, которому принадлежат его ближайшие соседи:

$$a(x; X^\ell) = \arg \max_{y \in Y} \underbrace{\sum_{i=1}^{\ell} [y^{(i)} = y] w(i, x)}_{\Gamma_y(x)},$$

$w(i, x)$ — функция близости к объекту x его i -го соседа,
неотрицательная, не возрастает по i ,

$\Gamma_y(x)$ — оценка близости объекта x к классу y .

Эвристические варианты метрического классификатора

$w(i, x) = [i \leq 1]$ — метод ближайшего соседа (1NN)

$w(i, x) = [i \leq k]$ — метод k ближайших соседей (k NN)

$w(i, x) = [i \leq k]w_i$ — метод k взвешенных ближайших соседей

$w(i, x) = K\left(\frac{1}{h}\rho(x, x^{(i)})\right)$ — метод окна Парзена, где

h — фиксированная ширина окна (bandwidth),

$K(r)$ — ядро (kernel), не возрастает и положительно на $[0, 1]$

$w(i, x) = K\left(\frac{1}{h(x)}\rho(x, x^{(i)})\right)$ — метод окна Парзена, где

$h(x) = \rho(x, x^{(k+1)})$ — переменная ширина окна по k соседям

$w(i, x) = \alpha^{(i)}K\left(\frac{1}{h^{(i)}}\rho(x, x^{(i)})\right)$ — метод потенциальных функций,

$\alpha^{(i)}$ — обучаемый параметр «заряд потенциала»,

$h^{(i)}$ — «радиус действия потенциала» с центром в точке $x^{(i)}$

Метод потенциальных функций

$$w(i, x) = \alpha^{(i)} K\left(\frac{\rho(x, x^{(i)})}{h^{(i)}}\right)$$

Более простая запись (ведь можно не ранжировать объекты):

$$a_h(x; X^\ell) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_i = y] \alpha_i K\left(\frac{\rho(x, x_i)}{h_i}\right),$$

Физическая аналогия из электростатики:

$\alpha_i \geq 0$ — веса объектов, величина «заряда» в точке x_i ;

$h_i > 0$ — «радиус действия» потенциала с центром в точке x_i ;

α_i, h_i — обучаемые параметры (однородный потенциал, $h_i = h$)

y_i — знак «заряда» (в случае двух классов $Y = \{-1, +1\}$)

$K(r) = \frac{1}{r^2}$ или $\frac{1}{r}$ или $\frac{1}{r+a}$ — вид потенциальной функции

В задачах классификации нет ограничений на вид K и на $|Y|$

М.А.Айзерман, Э.М.Браверман, Л.И.Розоноэр. Метод потенциальных функций в теории обучения машин. М.: Наука, 1970.

Научная школа М. А. Айзermana

- Гипотеза компактности: схожие объекты, как правило, находятся в одном классе
- Идея метода потенциальных функций заимствуется из физики
- Линейная модель классификации: взвешенное голосование функций сходства $f_i(x) = K(x, x_i)$ между x и x_i :

$$a(x) = \arg \max_{y \in Y} \sum_{i: y_i=y} \alpha_{yi} K(x, x_i)$$



Марк Аронович
Айзerman
(1913–1992)

Айзerman М. А., Браверман Э. М., Розеноэр Л. И. Теоретические основы метода потенциальных функций в задаче об обучении автоматов разделению входных ситуаций на классы. 1964.

Айзerman М. А., Браверман Э. М., Розеноэр Л. И. Метод потенциальных функций в теории обучения машин. 1970.

Аркадьев А. Г., Браверман Э. М. Обучение машин распознаванию образов. 1964.

Метод потенциальных функций = линейный классификатор

Два класса: $Y = \{-1, +1\}$.

$$\begin{aligned} a(x; X^\ell) &= \arg \max_{y \in Y} \Gamma_y(x) = \text{sign}(\Gamma_{+1}(x) - \Gamma_{-1}(x)) = \\ &= \text{sign} \sum_{i=1}^{\ell} \alpha_i y_i K\left(\frac{\rho(x, x_i)}{h_i}\right). \end{aligned}$$

Сравним с линейной моделью классификации:

$$a(x) = \text{sign} \sum_{j=1}^n \alpha_j f_j(x).$$

- $f_j(x) = y_j K\left(\frac{1}{h_j} \rho(x, x_j)\right)$ — новые признаки объекта x ,
близость (сходство) объекта x и обучающего объекта x_j
- α_j — обучаемые веса линейного классификатора
- $n = \ell$ — число признаков равно числу объектов обучения

Выбор ядра K и ширины окна h

- Ядро $K(r)$
 - влияет на гладкость разделяющей поверхности
 - почти не влияет на качество классификации
- Ширина окна h
 - существенно влияет на качество классификации
- Переменная ширина окна по k ближайшим соседям:


$$w_i(x) = K\left(\frac{\rho(x, x_i)}{h(x)}\right), \quad h(x) = \rho(x, x^{(k+1)})$$

где $x^{(k)}$ — k -й сосед объекта x .

- Оптимизация ширины окна (h или k) по leave-one-out:

$$\text{LOO}(h, X^\ell) = \sum_{i=1}^{\ell} [a_h(x_i; X^\ell \setminus \{x_i\}) \neq y_i] \rightarrow \min_h$$

Часто используемые ядра $K(r)$



$\Pi(r) = [|r| \leq 1]$ — прямоугольное

$T(r) = (1 - |r|)[|r| \leq 1]$ — треугольное

$E(r) = (1 - r^2)[|r| \leq 1]$ — квадратичное (Епанечникова)

$Q(r) = (1 - r^2)^2[|r| \leq 1]$ — квартическое

$G(r) = \exp(-2r^2)$ — гауссовское


Влияние ширины окна h на качество классификации

Пример: $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$, $K(r) = \exp(-2r^2)$

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} \underbrace{\left(\Gamma_{+1}(x) - \Gamma_{-1}(x) \right)}_{}$$

ядро:
гауссовское

ширина
окна:
 $h = 0.05$




Влияние ширины окна h на качество классификации

Пример: $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$, $K(r) = \exp(-2r^2)$

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} \underbrace{\left(\Gamma_{+1}(x) - \Gamma_{-1}(x) \right)}_{}$$

ядро:
гауссовское

ширина
окна:
 $h = 0.2$




Влияние ширины окна h на качество классификации

Пример: $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$, $K(r) = \exp(-2r^2)$

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} \underbrace{\left(\Gamma_{+1}(x) - \Gamma_{-1}(x) \right)}_{}$$

ядро:
гауссовское

ширина
окна:
 $h = 0.3$




Влияние ширины окна h на качество классификации

Пример: $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$, $K(r) = \exp(-2r^2)$

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} \underbrace{\left(\Gamma_{+1}(x) - \Gamma_{-1}(x) \right)}_{}$$

ядро:
гауссовское

ширина
окна:
 $h = 0.5$




Влияние ширины окна h на качество классификации

Пример: $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$, $K(r) = \exp(-2r^2)$

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} \underbrace{\left(\Gamma_{+1}(x) - \Gamma_{-1}(x) \right)}_{}$$

ядро:
гауссовское

ширина
окна:
 $h = 1.0$




Влияние ширины окна h на качество классификации

Пример: $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$, $K(r) = \exp(-2r^2)$

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} \left(\underbrace{\Gamma_{+1}(x) - \Gamma_{-1}(x)}_{\text{ }} \right)$$

ядро:
гауссовское

ширина
окна:
 $h = 5.0$




Зависимость LOO от числа соседей

Пример.
Задача UCI: Iris.

$$\text{LOO}(h) = \sum_{i=1}^{\ell} [a_h(x_i; X^{\ell} \setminus \{x_i\}) \neq y_i] \rightarrow \min_h$$

частота ошибок



- смещённое число ошибок, когда объект учитывается как сосед самого себя
- несмещённое число ошибок LOO

Задачи регрессии и метод наименьших квадратов

Дано: $X^\ell = (x_i, y_i)_{i=1}^\ell$ — обучающая выборка, $y_i \in \mathbb{R}$

Найти регрессионную модель для аппроксимации $y(x)$:

$$a(x) = f(x, \theta)$$

где θ — вектор параметров, f — фиксированная функция

Критерий — метод наименьших квадратов:

$$Q(\theta, X^\ell) = \sum_{i=1}^{\ell} w_i (f(x_i, \theta) - y_i)^2 \rightarrow \min_{\theta},$$

где w_i — весовой коэффициент, степень важности объекта x_i

Мотивация перехода к непараметрическим моделям:
нет теории для создания «физической» модели $f(x, \theta)$

Непараметрическая регрессия, формула Надаля–Ватсона

Приближение константой $f(x, \theta) = \theta$ в окрестности точки x :

$$Q(\theta; X^\ell) = \sum_{i=1}^{\ell} w_i(x) (\theta - y_i)^2 \rightarrow \min_{\theta \in \mathbb{R}};$$

где $w_i(x) = K\left(\frac{\rho(x, x_i)}{h}\right)$ — веса объектов x_i относительно x ;

$K(r)$ — ядро (kernel), невозрастающее, ограниченное, гладкое;
 h — ширина окна сглаживания (bandwidth).

Формула ядерного сглаживания Надаля–Ватсона:

$$a_h(x; X^\ell) = \frac{\sum_{i=1}^{\ell} y_i w_i(x)}{\sum_{i=1}^{\ell} w_i(x)} = \frac{\sum_{i=1}^{\ell} y_i K\left(\frac{\rho(x, x_i)}{h}\right)}{\sum_{i=1}^{\ell} K\left(\frac{\rho(x, x_i)}{h}\right)}.$$

Обоснование формулы Надаля–Ватсона (одномерный случай)

Теорема

Пусть выполнены следующие условия:

- 1) выборка $X^\ell = (x_i, y_i)_{i=1}^\ell$ простая, из распределения $p(x, y)$;
- 2) ядро $K(r)$ ограничено: $\int_0^\infty K(r) dr < \infty$, $\lim_{r \rightarrow \infty} rK(r) = 0$;
- 3) зависимость $E(y|x)$ не имеет вертикальных асимптот:
$$E(y^2|x) = \int_Y y^2 p(y|x) dy < \infty \text{ при любом } x \in X;$$
- 4) последовательность h_ℓ убывает, но не слишком быстро:
$$\lim_{\ell \rightarrow \infty} h_\ell = 0, \quad \lim_{\ell \rightarrow \infty} \ell h_\ell = \infty.$$


Тогда имеет место сходимость по вероятности:

$$a_{h_\ell}(x; X^\ell) \xrightarrow{P} E(y|x) \text{ в любой точке } x \in X,$$

в которой $E(y|x)$, $p(x)$ и $D(y|x)$ непрерывны и $p(x) > 0$.

Выбор ядра K и ширины окна h

$h \in \{0.1, 1.0, 3.0\}$, гауссовское ядро $K(r) = \exp(-2r^2)$




Гауссовское ядро \Rightarrow гладкая аппроксимация

Ширина окна существенно влияет на точность аппроксимации

Выбор ядра K и ширины окна h


$h \in \{0.1, 1.0, 3.0\}$, треугольное ядро $K(r) = (1 - |r|)[|r| \leq 1]$



Треугольное ядро \Rightarrow кусочно-линейная аппроксимация
Аппроксимация не определена, если в окне нет точек выборки

Выбор ядра K и ширины окна h

$h \in \{0.1, 1.0, 3.0\}$, прямоугольное ядро $K(r) = [|r| \leq 1]$



Прямоугольное ядро \Rightarrow кусочно-постоянная аппроксимация
Выбор ядра слабо влияет на точность аппроксимации

Выбор ядра K и ширины окна h

- Ядро $K(r)$
 - влияет на гладкость аппроксимирующей функции $a_h(x)$
 - почти не влияет на качество аппроксимации
- Ширина окна h
 - существенно влияет на качество аппроксимации
- Переменная ширина окна по k ближайшим соседям:

$$w_i(x) = K\left(\frac{\rho(x, x_i)}{h(x)}\right), \quad h(x) = \rho(x, x^{(k+1)})$$

где $x^{(k)}$ — k -й сосед объекта x

- Оптимизация ширины окна (h или k) по leave-one-out:

$$\text{LOO}(h, X^\ell) = \sum_{i=1}^{\ell} \left(a_h(x_i; X^\ell \setminus \{x_i\}) - y_i \right)^2 \rightarrow \min_h$$

Задача отбора эталонов (prototype selection)

Дано: $X^\ell = (x_i, y_i)_{i=1}^\ell$ — обучающая выборка
 $a(x; X^\ell)$ — модель, хранящая выборку (lazy learning)

Найти подмножество эталонных объектов $U \subseteq X^\ell$

Критерий — неухудшение качества модели:

$$Q(a, U) = \sum_{i=1}^{\ell} \mathcal{L}(a(x_i; U), y_i) \rightarrow \min_{U \subseteq X^\ell}$$

Цели отбора эталонов в метрических алгоритмах:

- уменьшить объём хранимых данных
- избавиться от объектов-выбросов
- улучшить качество (обобщающую способность) модели

Отбор эталонов в линейных метрических моделях

$$z_j(x) = K\left(\frac{1}{h_j}\rho(x, x_j)\right), j = 1, \dots, \ell \text{ — признаки объекта } x$$

Линейная модель классификации, $Y = \{-1, +1\}$, обучение с убывающей функцией отступа $L(M)$ и L_1 -регуляризацией:

$$a(x, w) = \operatorname{sign} \sum_{i=1}^{\ell} w_i y_i K\left(\frac{1}{h_i} \rho(x, x_i)\right) = \operatorname{sign} \langle w, y \otimes z(x) \rangle;$$

$$\sum_{i=1}^{\ell} L(y_i \langle w, y \otimes z(x_i) \rangle) + \tau \sum_{i=1}^{\ell} |w_i| \rightarrow \min_w;$$


Линейная модель регрессии, $Y = \mathbb{R}$, обучение методом НК:

$$a(x, w) = \sum_{i=1}^{\ell} w_i y_i K\left(\frac{1}{h_i} \rho(x, x_i)\right) = \langle w, y \otimes z(x) \rangle$$

$$\sum_{i=1}^{\ell} (a(x_i, w) - y_i)^2 + \tau \sum_{i=1}^{\ell} |w_i| \rightarrow \min_w;$$


Чем больше τ , тем меньше остаётся эталонов

Пример. Отбор эталонов в задаче бинарной классификации



Синтетическая задача классификации:
2 класса по 500 объектов, добавлено 30 шумовых объектов

Пример. Отбор эталонов в задаче бинарной классификации



Задача непараметрического восстановления плотности

Задача: по выборке $X^\ell = (x_i)_{i=1}^\ell$ оценить плотность $\hat{p}(x)$,
без введения параметрической модели плотности

Дискретный случай: $x_i \in X$, $|X| \ll \ell$. Частотная оценка:

$$\hat{p}(x) = \frac{1}{\ell} \sum_{i=1}^{\ell} [x_i = x]$$

Одномерный непрерывный случай: $x_i \in \mathbb{R}$. По определению плотности, если $P[a, b]$ — вероятностная мера отрезка $[a, b]$:

$$p(x) = \lim_{h \rightarrow 0} \frac{1}{2h} P[x - h, x + h]$$

Эмпирическая частотная оценка плотности по окну ширины h (заменяем вероятность долей объектов выборки):

$$\hat{p}_h(x) = \frac{1}{2h} \frac{1}{\ell} \sum_{i=1}^{\ell} [|x - x_i| < h]$$

Локальная непараметрическая оценка Парзена-Розенблатта

Эмпирическая оценка плотности по окну ширины h :

$$\hat{p}_h(x) = \frac{1}{\ell h} \sum_{i=1}^{\ell} \frac{1}{2} \left[\frac{|x - x_i|}{h} < 1 \right]$$

Обобщение: оценка Парзена-Розенблатта по окну ширины h :

$$\hat{p}_h(x) = \frac{1}{\ell h} \sum_{i=1}^{\ell} K\left(\frac{x - x_i}{h}\right)$$

где $K(r)$ — ядро, удовлетворяющее требованиям:

- чётная функция;
- нормированная функция: $\int K(r) dr = 1$;
- невозрастающая при $r > 0$, неотрицательная функция.

В частности, при $K(r) = \frac{1}{2}[|r| < 1]$ имеем эмпирическую оценку.

Обоснование оценки Парзена-Розенблатта

Другое название — Kernel Density Estimate (KDE)

Теорема (одномерный случай, $x_i \in \mathbb{R}$)

Пусть выполнены следующие условия:

- 1) X^ℓ — простая выборка из распределения $p(x)$;
- 2) ядро $K(z)$ непрерывно и ограничено: $\int_X K^2(z) dz < \infty$;
- 3) последовательность h_ℓ : $\lim_{\ell \rightarrow \infty} h_\ell = 0$ и $\lim_{\ell \rightarrow \infty} \ell h_\ell = \infty$.

Тогда:

- 1) $\hat{p}_{h_\ell}(x) \rightarrow p(x)$ при $\ell \rightarrow \infty$ для почти всех $x \in X$;
- 2) скорость сходимости имеет порядок $O(\ell^{-2/5})$.

А как быть в многомерном случае, когда $x_i \in \mathbb{R}^n$?

Два варианта обобщения на многомерный случай

- ① Если объекты описываются n признаками $f_j: X \rightarrow \mathbb{R}$:

$$\hat{p}_{h_1 \dots h_n}(x) = \frac{1}{\ell} \sum_{i=1}^{\ell} \prod_{j=1}^n \frac{1}{h_j} K\left(\frac{f_j(x) - f_j(x_i)}{h_j}\right)$$

- ② Если на X задана функция расстояния $\rho(x, x')$:

$$\hat{p}_h(x) = \frac{1}{\ell V(h)} \sum_{i=1}^{\ell} K\left(\frac{\rho(x, x_i)}{h}\right)$$

где $V(h) = \int_X K\left(\frac{\rho(x, x_i)}{h}\right) dx$ — нормировочный множитель

Сферическое гауссовское ядро — частный случай обоих:

$$\hat{p}_h(x) = \frac{1}{\ell} \sum_{i=1}^{\ell} \prod_{j=1}^n \frac{1}{\sqrt{2\pi}h} \exp\left(-\frac{(f_j(x) - f_j(x_i))^2}{2h^2}\right)$$

Выбор ядра почти не влияет на качество восстановления

Функционал качества восстановления плотности:


$$J(K) = \int_{-\infty}^{+\infty} E(\hat{p}_h(x) - p(x))^2 dx.$$

Асимптотические значения отношения $J(K^*)/J(K)$ при $\ell \rightarrow \infty$ не зависят от вида распределения $p(x)$.

| ядро $K(r)$ | степень гладкости | $J(K^*)/J(K)$ |
|-----------------------|--------------------------|---------------|
| Епанечникова $K^*(r)$ | \hat{p}'_h разрывна | 1.000 |
| Квартическое | \hat{p}''_h разрывна | 0.995 |
| Треугольное | \hat{p}'_h разрывна | 0.989 |
| Гауссовское | ∞ дифференцируема | 0.961 |
| Прямоугольное | \hat{p}_h разрывна | 0.943 |

Зависимость оценки плотности от ширины окна

Оценка $\hat{p}_h(x)$ при различных значениях ширины окна h :



- Качество восстановления плотности существенно зависит от ширины окна h , но слабо зависит от вида ядра K
- При неоднородности локальных сгущений плотности можно задавать $h_k(x) = \rho(x, x^{(k+1)})$, где k — число соседей

Выбор ширины окна

Скользящий контроль *Leave One Out* для оценки плотности:

$$\text{LOO}(h) = - \sum_{i=1}^{\ell} \ln \hat{p}_h(x_i; X^{\ell} \setminus \color{red}{x_i}) \rightarrow \min_h,$$

Типичный вид зависимости $\text{LOO}(h)$ или $\text{LOO}(k)$:



Ретроспектива: (непара)метрические методы анализа данных

Классификация. Метод парзеновского окна:

$$a_h(x; X^\ell, Y^\ell) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_i = y] K\left(\frac{\rho(x, x_i)}{h}\right)$$

Регрессия. Метод ядерного сглаживания Надаля–Ватсона:

$$a_h(x; X^\ell, Y^\ell) = \frac{\sum_{i=1}^{\ell} y_i K\left(\frac{\rho(x, x_i)}{h}\right)}{\sum_{i=1}^{\ell} K\left(\frac{\rho(x, x_i)}{h}\right)}$$

Восстановление плотности. Метод Парзена–Розенблatta:

$$\hat{p}_h(x; X^\ell) = \frac{1}{\ell V(h)} \sum_{i=1}^{\ell} K\left(\frac{\rho(x, x_i)}{h}\right)$$

Постановка задачи кластеризации

Дано:

X — пространство объектов;

$X^\ell = \{x_1, \dots, x_\ell\}$ — обучающая выборка;

$\rho: X \times X \rightarrow [0, \infty)$ — функция расстояния между объектами.

Найти:

Y — множество кластеров,

$a: X \rightarrow Y$ — алгоритм кластеризации,

такие, что:

— каждый кластер состоит из близких объектов;

— объекты разных кластеров существенно различны.



Это задача обучения без учителя (*unsupervised learning*).

Некорректность задачи кластеризации

Решение задачи кластеризации принципиально неоднозначно:

- точной постановки задачи кластеризации нет;
- существует много критериев качества кластеризации;
- существует много эвристических методов кластеризации;
- число кластеров $|Y|$, как правило, заранее не известно;
- результат кластеризации сильно зависит от метрики ρ , выбор которой также является эвристикой.


Пример: сколько здесь кластеров?




Цели кластеризации

- Упростить дальнейшую обработку данных, разбить выборку X^ℓ на подвыборки схожих объектов, далее работать с ними по принципу «разделяй и властвуй»
- Сократить объём хранимых данных, оставив по одному представителю от каждого кластера, получить максимально представительную подвыборку
- Выделить нетипичные объекты, которые не подходят ни к одному из кластеров (выделение аномалий, одноклассовая классификация)
- Построить иерархию множества объектов, пример — классификация животных и растений К.Линнея (задачи таксономии, иерархической кластеризации)

Типы кластерных структур



кластеры с центрами



внутрикластерные расстояния
меньше межкластерных



ленточные кластеры

Типы кластерных структур



перемычки между кластерами



разреженный фон
из нетипичных объектов



перекрывающиеся кластеры

Типы кластерных структур



кластеры могут вообще отсутствовать




а это вообще не кластеры
и на практике такое не встречается


- Каждый метод кластеризации имеет свои ограничения и выделяет кластеры лишь некоторых типов.
- Понятие «тип кластерной структуры» зависит от метода и также не имеет формального определения.

Проблема чувствительности к выбору метрики

Результат зависит от нормировок признаков:



A — студентки,
B — студенты



после перенормировки
(сжали ось «вес» вдвое)

Задача кластеризации (clustering)

Дано: $X^\ell = \{x_1, \dots, x_\ell\}$ — обучающая выборка, $x_i \in \mathbb{R}^n$

Найти:


- центры кластеров — параметры $\mu_j \in \mathbb{R}^n$, $j = 1, \dots, K$
- какому кластеру принадлежит каждый объект $a_i \in \{1, \dots, K\}$

Критерий: минимум суммы
внутрикластерных расстояний

$$\sum_{i=1}^{\ell} \|x_i - \mu_{a_i}\|^2 \rightarrow \min_{\{a_i\}, \{\mu_j\}}$$

Метрика, как правило, евклидова
(но может быть и другая):

$$\|x - \mu_j\|^2 = \sum_{d=1}^n (f_d(x) - \mu_{jd})^2$$



Метод K -средних (K -means) для кластеризации

Минимизация суммы квадратов внутрикластерных расстояний:

$$\sum_{i=1}^{\ell} \|x_i - \mu_{a_i}\|^2 \rightarrow \min_{\{a_i\}, \{\mu_a\}}, \quad \|x_i - \mu_a\|^2 = \sum_{j=1}^n (f_j(x_i) - \mu_{aj})^2$$

Алгоритм Ллойда

вход: X^ℓ , $K = |Y|$; **выход:** центры кластеров μ_a , $a \in Y$;

$\mu_a :=$ начальное приближение центров, для всех $a \in Y$;

повторять

отнести каждый x_i к ближайшему центру:

$$a_i := \arg \min_{a \in Y} \|x_i - \mu_a\|, \quad i = 1, \dots, \ell;$$


вычислить новые положения центров:

$$\mu_a := \frac{\sum_{i=1}^{\ell} [a_i = a] x_i}{\sum_{i=1}^{\ell} [a_i = a]}, \quad a \in Y;$$

пока a_i не перестанут изменяться;

Примеры неудачной кластеризации k -means

Причина — неудачное начальное приближение или форма кластеров, существенно отличная от сферической




Алгоритм кластеризации DBSCAN

(Density-Based Spatial Clustering of Applications with Noise)

Объект $x \in U$, его ε -окрестность $U_\varepsilon(x) = \{u \in U : \rho(x, u) \leq \varepsilon\}$

Каждый объект может быть одного из трёх типов:

- корневой: имеющий плотную окрестность, $|U_\varepsilon(x)| \geq m$
- граничный: не корневой, но в окрестности корневого
- шумовой (выброс): не корневой и не граничный



Ester, Kriegel, Sander, Xu. A density-based algorithm for discovering clusters in large spatial databases with noise. KDD-1996.

Алгоритм кластеризации DBSCAN

Вход: выборка $X^\ell = \{x_1, \dots, x_\ell\}$; параметры ε и m ;

Выход: разбиение выборки на кластеры и шумовые выбросы;

$U := X^\ell$ — непомеченные; $a := 0$;

пока в выборке есть непомеченные точки, $U \neq \emptyset$:

 взять случайную точку $x \in U$;

если $|U_\varepsilon(x)| < m$ **то**

 пометить x как, возможно, шумовой;

иначе

 создать новый кластер: $K := U_\varepsilon(x)$; $a := a + 1$;

для всех $x' \in K$, не помеченных или шумовых

если $|U_\varepsilon(x')| \geq m$ **то** $K := K \cup U_\varepsilon(x')$;


иначе пометить x' как граничный кластера K ;

$a_i := a$ для всех $x_i \in K$;

$U := U \setminus K$;

Преимущества алгоритма DBSCAN

- быстрая кластеризация больших данных:
 $O(\ell^2)$ в худшем случае,
 $O(\ell \ln \ell)$ при эффективной реализации $U_\varepsilon(x)$;
- кластеры произвольной формы (долой центры!);
- деление объектов на корневые, граничные, шумовые.



Многомерное шкалирование (multidimensional scaling, MDS)

Дано: $(i, j) \in E$ — выборка рёбер графа $\langle V, E \rangle$,

R_{ij} — расстояния между вершинами ребра (i, j) .

Например, в IsoMAP R_{ij} — длина кратчайшего пути по графу.

Найти: векторные представления вершин $z_i \in \mathbb{R}^d$, так, чтобы близкие (по графу) вершины имели близкие векторы.

Критерий стресса (stress):

$$\sum_{(i,j) \in E} w(R_{ij}) (\rho(z_i, z_j) - R_{ij})^2 \rightarrow \min_Z, \quad Z \in \mathbb{R}^{V \times d},$$

где $\rho(z_i, z_j) = \|z_i - z_j\|$ — обычно евклидово расстояние,


Обычно решается методом стохастического градиента (SG).

Вопрос: как лучше задавать веса $w(R_{ij}) = 1? R_{ij}? \frac{1}{R_{ij}}?$

I. Chami et al. Machine learning on graphs: a model and comprehensive taxonomy. 2020.

Многомерное шкалирование для визуализации данных

При $d = 2$ осуществляется проекция выборки на плоскость



- Используется для визуализации кластерных структур
- Форму облака точек можно настраивать весами и метрикой
- Недостаток — искажения неизбежны
- Наиболее популярная разновидность метода — t-SNE

Laurens van der Maaten, Geoffrey Hinton. Visualizing data using t-SNE. 2008

- Метрические методы — простейшие в машинном обучении, обучение сводится к запоминанию выборки (lazy learning)
- Усложняя метрические методы, можно обучать:
 - число ближайших соседей k или ширину окна h
 - веса (значимости, информативности) объектов
 - набор эталонов (prototype learning)
 - метрику (*distance learning, similarity learning*),
в частности, веса признаков в метрике Минковского
- Метод потенциальных функций = линейный классификатор
расстояние до опорного объекта = новый признак
- Качество обучения зависит от метрики и ширины окна,
слабо зависит от вида ядра сглаживания
- Непараметрические методы обходятся без модели?
Нет, модельные предположения закладываются в метрику