

# Машинное обучение (Machine Learning)

## Метрические методы классификации и регрессии

Уткин Л.В.



# Содержание

- ① Наивный байесовский классификатор
- ② Метрические методы классификации и регрессии
  - ① Метод k ближайших соседей
  - ② Метод окна Парзена
  - ③ Метод потенциальных функций

Презентация является компиляцией и заимствованием материалов из замечательных курсов и презентаций по машинному обучению:

*К.В. Воронцова, А.Г. Дьяконова, Н.Ю. Золотых,  
С.И. Николенко, Andrew Moore, Lior Rokach, Rong Jin, Luis F. Teixeira, Alexander Statnikov* и других.

# Наивный байесовский классификатор

# Теорема Байеса



Thomas Bayes  
1702 - 1761

# Теорема Байеса

$$P(y = c|x) = \frac{P(x|y = c)P(y = c)}{P(x)},$$

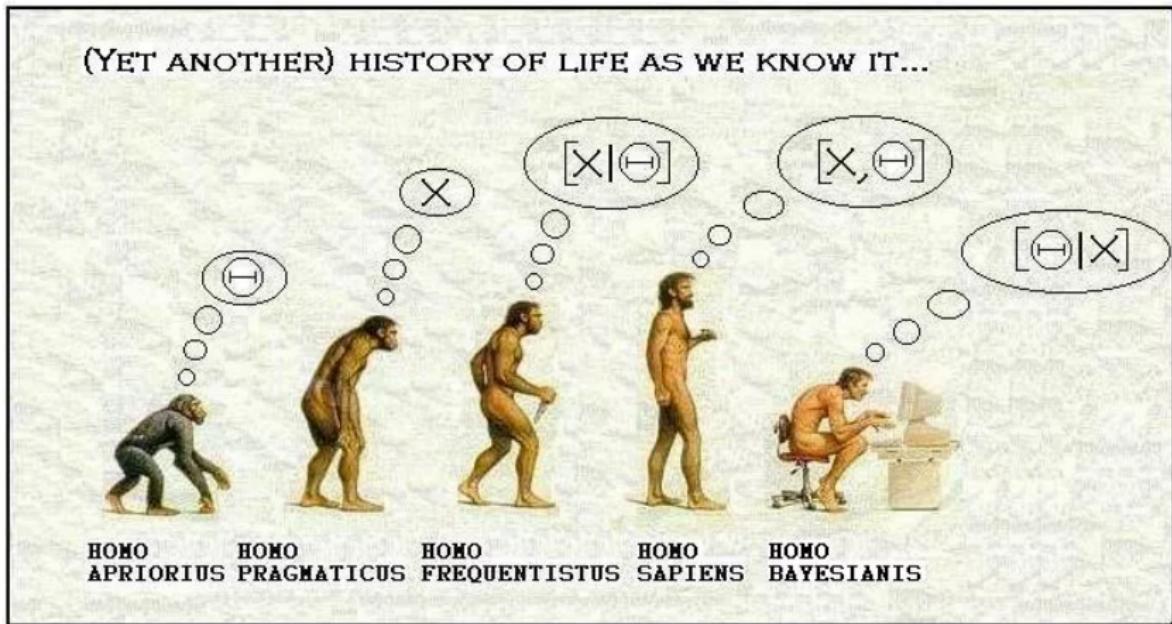
$P(y = c|x)$  - вероятность что объект  $x$  принадлежит классу  $c$  (апостериорная вероятность класса);

$P(x|y = c)$  - вероятность встретить объект  $x$  среди всех объектов класса  $c$ ;

$P(y = c)$  - безусловная вероятность встретить объект класса  $c$  (априорная вероятность класса);

$P(x)$  - безусловная вероятность объекта  $x$ .

# Эволюция по Байесу



# Теорема Байеса и классификация

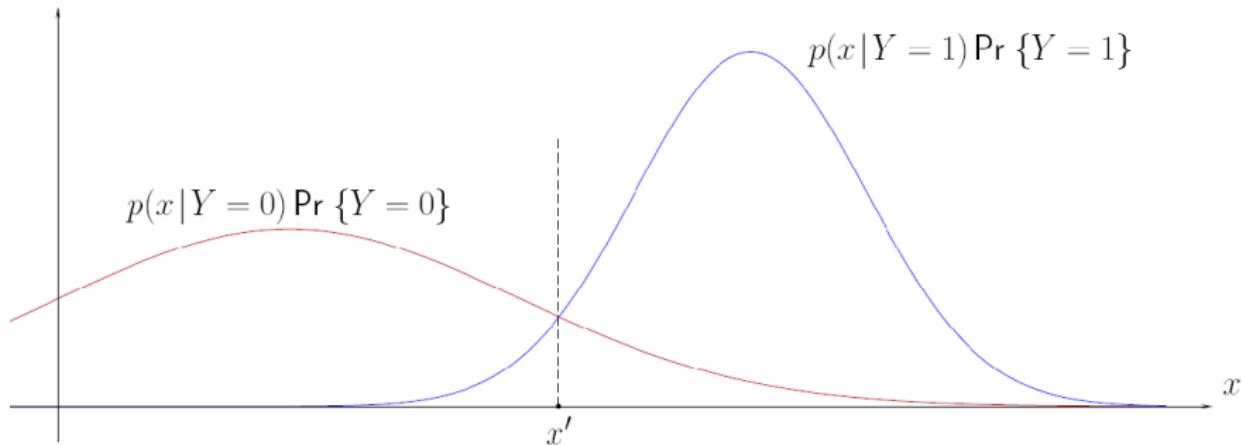
Цель классификации состоит в том чтобы понять к какому классу принадлежит объект  $x$ . Следовательно необходимо найти наиболее вероятный класс объекта  $x$ , т.е., необходимо из всех классов выбрать тот, который дает максимум вероятности  $P(y = c|x)$ :

$$c_{opt} = \arg \max_{c \in C} P(y = c|x) = \arg \max_{c \in C} \frac{P(x|y = c)P(y = c)}{P(x)}.$$

Для каждого класса  $c$  вычисляется  $P(y = c|x)$  и выбирается класс, имеющий максимальную вероятность. Вероятность  $P(x)$  не зависит от  $c$  и является константой:

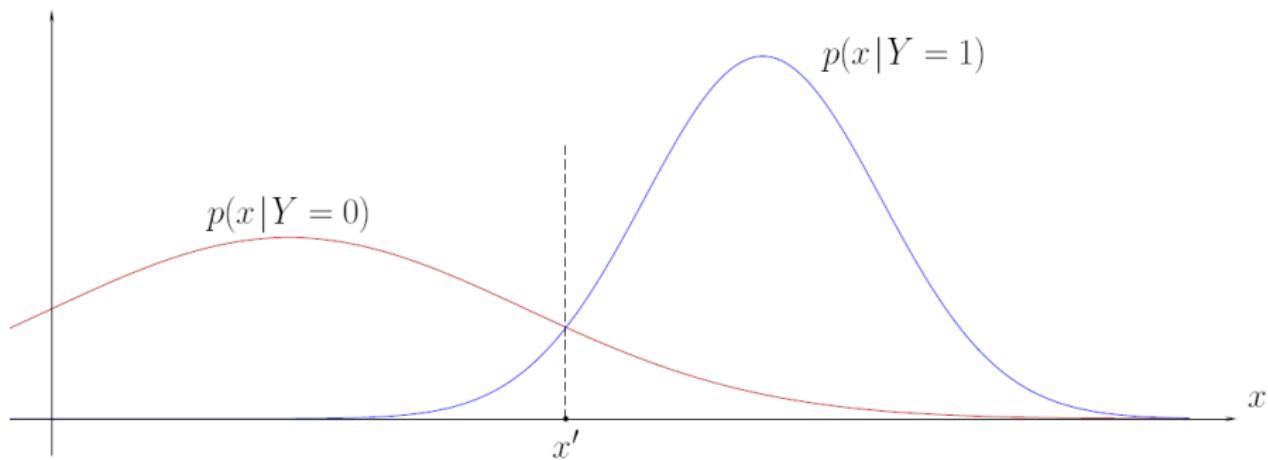
$$c_{opt} = \arg \max_{c \in C} P(x|y = c)P(y = c).$$

# Принцип максимума апостериорной вероятности



При  $x < x'$  считаем  $c_{opt} = 0$  иначе  $c_{opt} = 1$

# Принцип максимального правдоподобия



При  $x < x'$  считаем  $c_{opt} = 0$  иначе  $c_{opt} = 1$

# Теорема Байеса и классификация (2 класса)

*Выбор:*

$$\begin{cases} \text{класс } c_1, & \text{если } P(y = c_1|x) > P(y = c_2|x) \\ \text{класс } c_2, & \text{иначе} \end{cases}$$

*или*

$$\begin{cases} \text{класс } c_1, & \text{если } \frac{P(x|y = c_1)}{P(x|y = c_2)} > \frac{P(y = c_2)}{P(y = c_1)} \\ \text{класс } c_2, & \text{иначе} \end{cases}$$

*Байесовский классификатор минимизирует ошибку принятия решений*

# Наивность классификатора

Байесовский классификатор представляет объект как набор признаков (атрибутов), вероятности которых условно не зависят друг от друга:

$$\begin{aligned} P(x|y = c) &= P(f_1|y = c)P(f_2|y = c) \cdots P(f_m|y = c) \\ &= \prod_{i=1}^m P(f_i|y = c). \end{aligned}$$

Наивный байесовский классификатор:

$$c_{opt} = \arg \max_{c \in C} (P(y = c) \prod_{i=1}^m P(f_i|y = c)).$$

или

$$c_{opt} = \arg \max_{c \in C} (\log P(y = c) + \sum_{i=1}^m \log P(f_i|y = c)).$$

## Оценка априорных вероятностей классов, если признаки категориальные

Вероятность класса  $P(y = c)$  оценивается по обучающей выборке как:

$$P(y = c) = N_c/N$$

$N_c$  – количество объектов, принадлежащих классу ,  
 $N$  – общее количество объектов в обучающей выборке.

## Оценка вероятностей признаков, если они категориальные

Вероятность  $P(f_i|y = c)$  оценивается по обучающей выборке как:

$$P(f_i|y = c) = \frac{M_i(c) + \alpha}{\sum_{j=1}^m (M_j(c) + \alpha)}$$

$M_i(c)$  - общее количество элементов с заданным значением признака  $i$  в классе  $c$ .

$\alpha > 0$  - для избежания нулевых значений вероятности, например,  $\alpha = 1$

# Пример классификации спама (1)

Есть три письма для которых известны их классы (С - спам и Н - не спам):

- [С] предоставляю услуги бухгалтера;
- [С] спешите купить iPhone;
- [Н] надо купить молоко.

Модель классификатора будет выглядеть следующим образом:

	C	H	$P(y = C)$	$P(y = H)$
частота классов	2	1	2/3	1/3

## Пример классификации спама (2)

	C	H	$P(f_i y = C)$	$P(f_i y = H)$
предоставляю	1	0	$(1 + 1)/(6 + 8)$	$(0 + 1)/(3 + 8)$
услуги	1	0	$(1 + 1)/(6 + 8)$	$(0 + 1)/(3 + 8)$
бухгалтера	1	0	$(1 + 1)/(6 + 8)$	$(0 + 1)/(3 + 8)$
спешите	1	0	$(1 + 1)/(6 + 8)$	$(0 + 1)/(3 + 8)$
купить	1	1	$(1 + 1)/(6 + 8)$	$(1 + 1)/(3 + 8)$
iPhone	1	0	$(1 + 1)/(6 + 8)$	$(0 + 1)/(3 + 8)$
надо	0	1	$(0 + 1)/(6 + 8)$	$(1 + 1)/(3 + 8)$
молоко	0	1	$(0 + 1)/(6 + 8)$	$(1 + 1)/(3 + 8)$

## Пример классификации спама (3)

“Надо купить вино” - спам или нет?

- Для класса СПАМ:

$$P(y = \text{СПАМ} \mid \dots \text{ вино}) = \frac{2}{3} \cdot \frac{1}{6+8} \cdot \frac{2}{6+8} \cdot \frac{1}{6+8} = 5 \times 10^{-4}$$

- Для класса НЕ СПАМ:

$$P(y = \text{НЕ СПАМ} \mid \dots \text{ вино}) = \frac{1}{3} \cdot \frac{2}{3+8} \cdot \frac{2}{3+8} \cdot \frac{1}{3+8} = 1 \times 10^{-3}$$

Итог: это не спам!

# Пример распознавания рукописных цифр

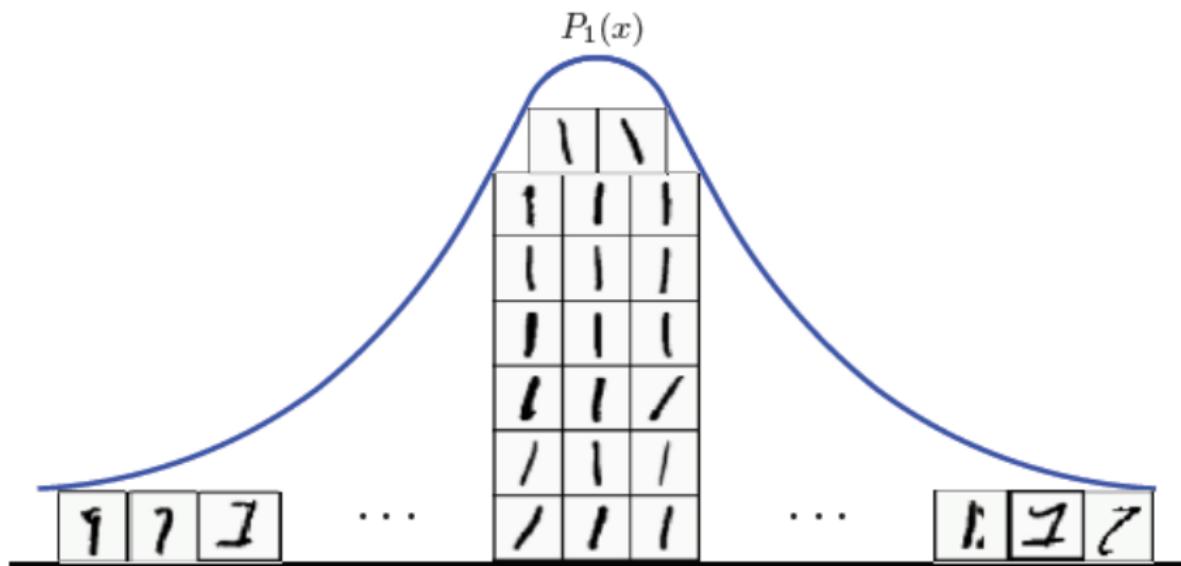
Обучающая выборка

0	1	2	3	4	5	6	7	8	9
0	1	2	3	4	5	6	7	8	9
0	1	2	3	4	5	6	7	8	9
0	1	2	3	4	5	6	7	8	9

Что это?

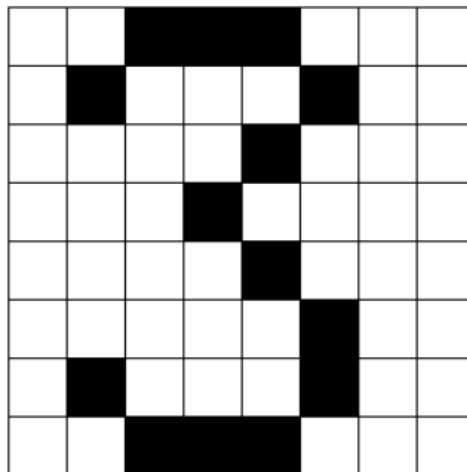
0 1 2 1 0 0

# Пример распознавания рукописных цифр



# Пример распознавания рукописных цифр

- 64 клетки - 64 бинарных признака (более белая/более черная-0/1):  $f_{i,j}$
- Вектор признаков для 3:  $(0, 0, 1, 1, \dots, 1, 0, 0, 0)$

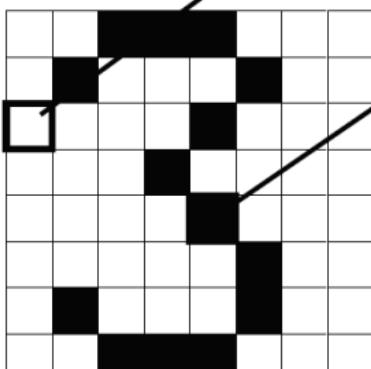


# Пример распознавания рукописных цифр

$P(Y)$

1	0.1
2	0.1
3	0.1
4	0.1
5	0.1
6	0.1
7	0.1
8	0.1
9	0.1
0	0.1

$Y=3$



$P(f_{3,1} = 1 | Y)$

1	0.01
2	0.05
3	0.05
4	0.30
5	0.80
6	0.90
7	0.05
8	0.60
9	0.50
0	0.80

$P(f_{5,5} = 1 | Y)$

1	0.05
2	0.01
3	0.90
4	0.80
5	0.90
6	0.90
7	0.25
8	0.85
9	0.60
0	0.80

# Пример распознавания рукописных цифр

$P(f_{i,j} = 1|y = 3)$  - доля всех троек с черной клеткой  $i,j$

$P(f_{i,j} = 0|y = 3)$  - доля всех троек с белой клеткой  $i,j$

Сравним

$$P(y = 3|f) = P(y = 3) \cdot P(f_{1,1} = 0|y = 3)P(f_{1,2} = 0|y = 3) \times \\ \times P(f_{1,3} = 1|y = 3) \cdots P(f_{8,8} = 0|y = 3)$$

с другими цифрами, например, с цифрой 8:

$$P(y = 8|f) = P(y = 8) \cdot P(f_{1,1} = 0|y = 8)P(f_{1,2} = 0|y = 8) \times \\ \times P(f_{1,3} = 1|y = 8) \cdots P(f_{8,8} = 0|y = 8)$$

# Случай количественных признаков

Одномерный непрерывный случай: эмпирическая оценка плотности

$$p_h(x) = \frac{1}{2nh} \sum_{i=1}^n [|x - x_i| < h]$$

$h$  - неотрицательный параметр, называемый шириной окна.  
Локальная непараметрическая оценка  
Парзена-Розенблатта:

$$p_h(x) = \frac{1}{2nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

# Случай количественных признаков

Многомерный непрерывный случай ( $m$  признаков объекта): оценка плотности в точке  $x = (\xi_1, \dots, \xi_m)$ :

$$p_h(x) = \frac{1}{2n} \sum_{i=1}^n \prod_{j=1}^m \frac{1}{h_j} K\left(\frac{\xi_j - f_j(x_i)}{h_j}\right)$$

В каждой точке  $x_i$  многомерная плотность представляется в виде произведения одномерных плотностей

# Программная реализация в R

- <https://cran.r-project.org/web/views/MachineLearning.html>
- Package **e1071**, функция **naiveBayes**
- Package **klaR**, функция **NaiveBayes**
- Package **BayesTree**, функция **bart**

# Метрические методы классификации и регрессии

# Гипотезы компактности или непрерывности

Задачи классификации и регрессии:

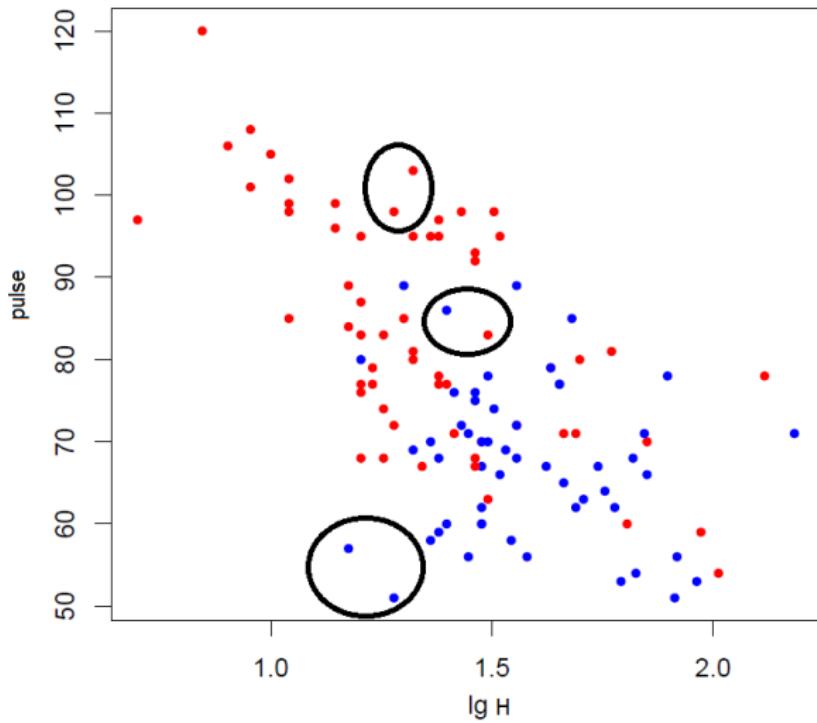
$X$  - объекты,  $Y$  - ответы;  $X^n = (x_i, y_i)_{i=1}^n$  - обучающая выборка.

**Гипотеза компактности (для классификации):**

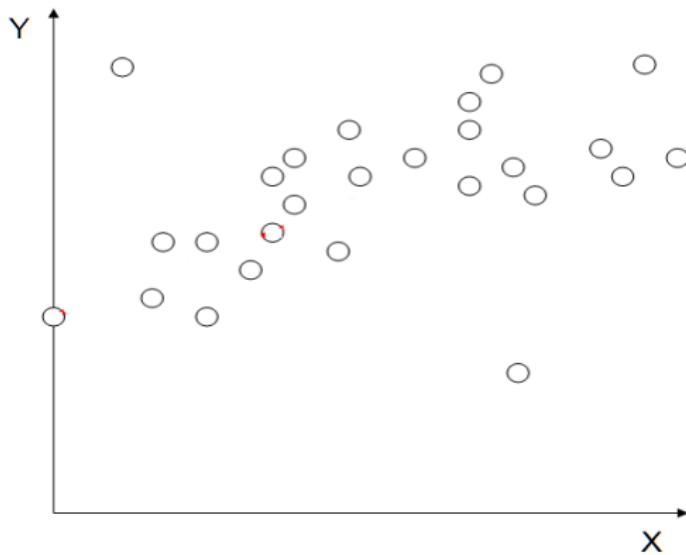
Близкие объекты, как правило, лежат в одном классе.

**Гипотеза непрерывности (для регрессии):** Близким объектам соответствуют близкие ответы.

# Гипотеза компактности



# Гипотеза непрерывности (нарушение)



# Метод k ближайших соседей

Метод  $k$  ближайших соседей ( $k$ NN —  $k$  nearest neighbours) метрический алгоритм для классификации объектов, основанный на оценивании сходства объектов.

Классифицируемый объект относится к тому классу, которому принадлежат ближайшие к нему объекты обучающей выборки.

**Алгоритм:**

- ➊ Вычислить расстояние до каждого из объектов обучающей выборки
- ➋ Отобрать  $k$  объектов обучающей выборки, расстояние до которых минимально
- ➌ Класс классифицируемого объекта — это класс, наиболее часто встречающийся среди  $k$  ближайших соседей

# Мера близости

Что такое близкие объекты? Задана функция расстояния  $\rho : X \times X \rightarrow [0, \infty)$ .

Виды функций расстояния:

- Евклидово:  $\rho(x_i, x_j) = \sqrt{\sum_{k=1}^m w_k (x_i^{(k)} - x_j^{(k)})^2}$
- $L_p$ -метрика:  $\rho(x_i, x_j) = \left( \sum_{k=1}^m w_k |x_i^{(k)} - x_j^{(k)}|^p \right)^{1/p}$
- $L_\infty$ -метрика:  $\rho(x_i, x_j) = \max_{k=1, \dots, m} |x_i^{(k)} - x_j^{(k)}|$
- $L_1$ -метрика:  $\rho(x_i, x_j) = \sum_{k=1}^m |x_i^{(k)} - x_j^{(k)}|$

$x_i = (x_i^{(1)}, \dots, x_i^{(m)})$  - вектор  $m$  признаков  $i$ -го объекта;

$x_j = (x_j^{(1)}, \dots, x_j^{(m)})$  - вектор  $m$  признаков  $j$ -го объекта.

# Мера близости

Что такое близкие объекты? Задана функция расстояния  
 $\rho : X \times X \rightarrow [0, \infty)$ .

Виды функций расстояния:

- Ланса-Уильямса:  $\rho(x_i, x_j) = \frac{\sum_{k=1}^m |x_i^{(k)} - x_j^{(k)}|}{\sum_{k=1}^m (x_i^{(k)} + x_j^{(k)})}$
- косинусная мера:  $\rho(x_i, x_j) = \frac{\sum_{k=1}^m x_i^{(k)} x_j^{(k)}}{\sqrt{\sum_{k=1}^m (x_i^{(k)})^2} \sqrt{\sum_{k=1}^m (x_j^{(k)})^2}}$

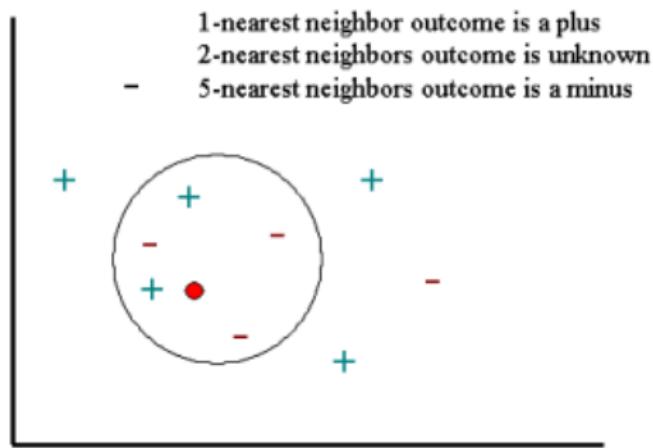
$x_i = (x_i^{(1)}, \dots, x_i^{(m)})$  - вектор  $m$  признаков  $i$ -го объекта;

$x_j = (x_j^{(1)}, \dots, x_j^{(m)})$  - вектор  $m$  признаков  $j$ -го объекта.

# Метод k ближайших соседей (классификация)

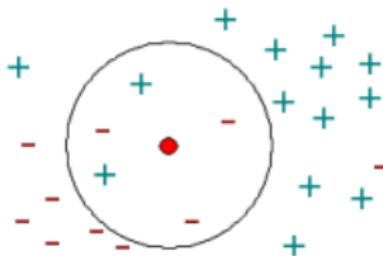


# Метод k ближайших соседей (классификация)

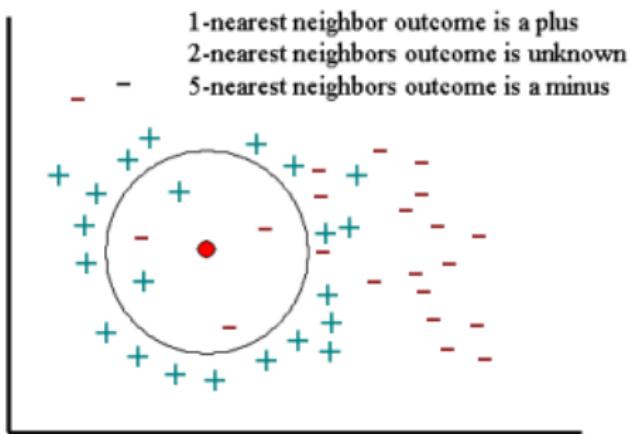


# Метод k ближайших соседей: пример “правильной” классификации

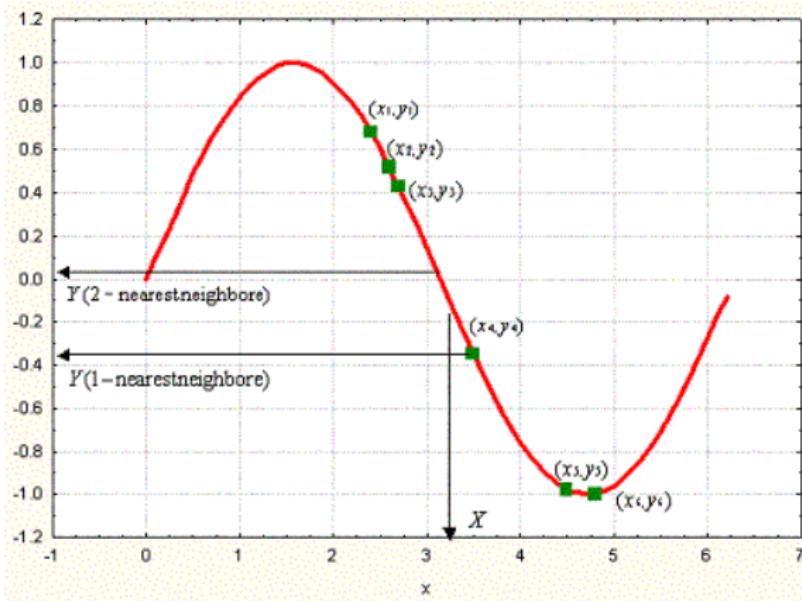
- 1-nearest neighbor outcome is a plus
- 2-nearest neighbors outcome is unknown
- 5-nearest neighbors outcome is a minus



# Метод k ближайших соседей: пример ошибочной классификации



# Метод k ближайших соседей (регрессия)



# Метод k ближайших соседей

## Достоинства:

- Простота реализации.
- Классификацию, проведенную алгоритмом, легко интерпретировать путем предъявления пользователю нескольких ближайших объектов.

## Недостатки:

- Необходимость хранения обучающей выборки целиком.
- Поиск ближайшего соседа предполагает сравнение классифицируемого объекта со всеми объектами выборки.

# Выбор $k$

- Малые значения  $k$  приведут к тому, что “шум” (выбросы) будет существенно влиять на результаты.
- Большие значения усложняют вычисления и искажают логику ближайших соседей, в соответствии с которой ближайшие точки могут принадлежать одному классу (гипотеза компактности).
- Эвристика:  $k = \sqrt{n}$

# Метод k ближайших соседей (пример)

Анализ брака древесины: по признакам средняя длина трещины и средний диаметр сучка

длина трещины	диаметр сучка	класс
7	7	брак
7	4	брак
3	4	не брак
1	4	не брак

Новый объект (длина трещины=3, диаметр сучка=7),  $k = 3$

# Метод k ближайших соседей (пример)

длина трещины	диаметр сучка	$\rho$
7	7	$(7 - 3)^2 + (7 - 7)^2 = 16$
7	4	$(7 - 3)^2 + (4 - 7)^2 = 25$
3	4	$(3 - 3)^2 + (4 - 7)^2 = 9$
1	4	$(1 - 3)^2 + (4 - 7)^2 = 13$

# Метод k ближайших соседей (пример)

длина трещины	диаметр сучка	$\rho$	ранк	входит в 3 соседа?
7	7	16	3	да
7	4	25	4	нет
3	4	9	1	да
1	4	13	2	да

# Метод k ближайших соседей (пример)

длина трещины	диаметр сучка	$\rho$	ранк	класс объекта
7	7	16	3	брак
7	4	25	4	-
3	4	9	1	не брак
1	4	13	2	не брак

Объект  $(3, 7)$  принадлежит классу “не брак”

# Вероятностная интерпретация метода ближайших соседей

- Метод ближайших соседей пытается аппроксимировать байесовское решающее правило на множестве обучающих данных
- Для этого необходимо вычислить условную вероятность  $P(x|y)$  данных  $x$  при условии их принадлежности классу  $y$ , априорную вероятность каждого класса  $P(y)$  и маргинальную вероятность данных  $P(x)$ .
- Эти вероятности вычисляются для некоторой малой области вокруг нового примера, размер области будет зависеть от распределения вероятностей на тестовых примерах

# Вычисление вероятностей для kNN

- Пусть “шар” размерности  $m$  ( $m$  - число признаков) вокруг нового примера  $z$  содержит  $k$  ближайших соседей для  $z$
- Тогда

$$P(z) = \frac{k}{n}, \quad P(z|y = 1) = \frac{k_1}{n_1}, \quad P(y = 1) = \frac{n_1}{n}$$

- $P(z)$  - вероятность того, что случайная точка находится в “шаре”
- $P(z|y = 1)$  - вероятность того, что случайная точка из класса 1 находится в “шаре”
- $n_1, k_1$  - число примеров из класса 1 и из класса 1 в  $k$

# Вычисление вероятностей для kNN



$$P(z) = \frac{k}{n}, \quad P(z|y=1) = \frac{k_1}{n_1}, \quad P(y=1) = \frac{n_1}{n}$$

- Используем правило Байеса

$$P(y=1|z) = \frac{P(z|y=1)P(y=1)}{P(z)} =$$

$$= \frac{\frac{k_1}{n_1} \cdot \frac{n_1}{n}}{\frac{k}{n}} = \frac{k_1}{k}$$

# Вычисление вероятностей для kNN

- Правило Байеса

$$P(y = 1|z) = \frac{k_1}{k}, \quad P(y = -1|z) = \frac{k_{-1}}{k}$$

Используя решающее правило Байеса, мы выбираем класс с наибольшей вероятностью, т.е. сравниваем  $P(y = 1|z)$  и  $P(y = -1|z)$ . А это тоже самое, что сравнение  $k_1/k$  и  $k_{-1}/k$ .

# Метод ближайшего соседа (общий вид)

Для произвольного  $x^* \in X$  отсортируем объекты  $x_1, \dots, x_n$ :

$$\rho(x^*, x_1) \leq \rho(x^*, x_2) \leq \dots \leq \rho(x^*, x_n)$$

$x_i$  -  $i$ -ый сосед объекта  $x^*$ ;  $y_i$  - ответ на  $i$ -ом соседе объекта  $x^*$ .

**Метрический алгоритм классификации:**

$$a(x^*) = \arg \max_{y \in Y} \underbrace{\sum_{i=1}^n [y_i = y] \cdot w(i, x^*)}_{\Gamma_y(x^*)}$$

$w(i, x^*)$  - вес (степень важности)  $i$ -го соседа объекта  $x^*$ , неотрицателен, не возрастает по  $i$ .

$\Gamma_y(x^*)$  - оценка близости объекта  $x^*$  к классу  $y$ .

# Метод ближайшего соседа (частный случай)

$$w(i, x^*) = [i = 1] = \begin{cases} 1, & i = 1, \\ 0, & i > 1. \end{cases}$$

т.е. решение принимается только по одному первому ближайшему соседу.

## Преимущества:

- простота реализации;
- интерпретируемость решений,
- вывод на основе прецедентов (case-based reasoning)

## Недостатки:

- неустойчивость к погрешностям (шуму, выбросам);
- отсутствие настраиваемых параметров;
- низкое качество классификации;
- приходится хранить всю выборку целиком.

# Метод k ближайших соседей (частный случай общего вида)

$$w(i, x^*) = [i \leq k] = \begin{cases} 1, & i \leq k, \\ 0, & i > k. \end{cases}$$

т.е. решение принимается только по  $k$  ближайшим соседям.

**Преимущества:**

- менее чувствителен к шуму;
- появился параметр  $k$ .

# Как найти оптимальное значение k в различных ситуациях

**Оптимизация** числа соседей k: функционал скользящего контроля leave-one-out:

$$LOO(k, X) = \sum_{i=1}^n [a(x_i) \neq y_i] \rightarrow \min_k$$

# Метод окна Парзена

**Усложнение:** определить  $w(i, x^*)$  как функцию от расстояния  $\rho(x^*, x_i)$ , а не от ранга соседа  $i$ :

$$w(i, x^*) = K\left(\frac{1}{h}\rho(x^*, x_i)\right)$$

**Алгоритм:**

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

Параметр  $h$  - ширина окна (так же роль, что и число соседей  $k$ ).  
Окно - сферическая окрестность объекта  $x^*$  радиуса  $h$ , при попадании в которую обучающий объект  $x_i$  "голосует" за отнесение объекта  $x^*$  к классу  $y_i$ .

# Метод окна Парзена

Параметр  $h$  можно задавать априори или определять по скользящему контролю.

- Слишком узкие окна приводят к неустойчивой классификации,
- Слишком широкие окна приводят к вырождению алгоритма в константу.

# Метод потенциальных функций

В методе парзеновского окна центр радиального ядра  $K\left(\frac{1}{h}\rho(x^*, x_i)\right)$  помещается в классифицируемый объект  $x^*$ .

**Двойственный взгляд:** ядро помещается в каждый обучающий объект  $x_i$  и “притягивает” объект  $x^*$  к классу  $y_i$ , если он попадает в его окрестность радиуса  $h_i$ :

$$a(x^*, X, h) = \arg \max_{y \in Y} \sum_{i=1}^n [y_i = y] \gamma_i K\left(\frac{\rho(x^*, x_i)}{h_i}\right).$$

$\gamma_i$  - величина “заряда” в точке  $x_i$ ;

$h_i$  - “радиус действия” потенциала с центром в точке  $x_i$ ;

$y_i$  - знак “заряда”.

# Метод потенциальных функций

- Идея метода потенциальных функций имеет прямую физическую аналогию с электрическим потенциалом
- При  $Y = \{-1, +1\}$  обучающие объекты - это положительные и отрицательные электрические заряды
- коэффициенты  $\gamma_i$  - абсолютные величины этих зарядов
- ядро  $K(z)$  - зависимость потенциала от расстояния до заряда
- сама задача классификации - ответ на вопрос: какой знак имеет электростатический потенциал в заданной точке пространства  $x^*$ .

# Программная реализация в R

- Package **kknn**, функция **kknn**

# Вопросы

?