



ML

НА ПАЛЬЦАХ

Петров Никита

“

ОСНОВЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ТЕХ, КТО
ХОЧЕТ ВКАТИТЬСЯ В ТЕМАТИКУ И ПОНЯТЬ ЧТО К ЧЕМУ

”

ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ

Построение моделей на основе входных данных, способных «обобщать» эти входные данные



Задача регрессии




Задача классификации



Задача кластеризации



Другие



ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ



Линейные модели



Вероятностные модели



Метрические методы




Решающие деревья



Нейронные сети

ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ

CLASSICAL MACHINE LEARNING



ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ

$$x_i = \begin{bmatrix} x_{i1} \\ x_{i2} \\ \dots \\ x_{in} \end{bmatrix} = [x_{i1}, x_{i2}, \dots, x_{in}]^T$$

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_i \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \cdot & \cdot & \cdot & \cdot \\ x_{i1} & x_{i2} & \dots & x_{in} \end{bmatrix}$$


$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_m \end{bmatrix} = [y_1, y_2, \dots, y_m]^T$$

ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ


	v.id	on road old	on road now	years	km	rating	condition	economy	top speed	hp	torque	current price
0	1	535651	798186	3	78945	1	2	14	177	73	123	351318.0
1	2	591911	861056	6	117220	5	9	9	148	74	95	285001.5
2	3	686990	770762	2	132538	2	8	15	181	53	97	215386.0
3	4	573999	722381	4	101065	4	3	11	197	54	116	244295.5
4	5	691388	811335	6	61559	3	9	12	160	53	105	531114.5
...
995	996	633238	743850	5	125092	1	6	11	171	95	97	190744.0
996	997	599626	848195	4	83370	2	9	14	161	101	120	419748.0
997	998	646344	842733	7	86722	1	8	9	196	113	89	405871.0
998	999	535559	732439	2	140478	4	5	9	184	112	128	74398.0
999	1000	590105	779743	5	67295	4	2	8	199	99	96	414938.5

1000 rows × 12 columns

ПРОСТЕЙШАЯ ЗАДАЧА МАШИННОГО ОБУЧЕНИЯ – ЛИНЕЙНАЯ РЕГРЕССИЯ



ФУНКЦИЯ ПОТЕРЬ




- $L(a, x) = |a(x) - y(x)|$ - абсолютная ошибка;
- $L(a, x) = (a(x) - y(x))^2$ - квадратичная ошибка.

$$Q(a, X^l) = \frac{1}{l} \sum_{i=1}^l L(a, x_i)$$

$$Q(a, X^l) = \frac{1}{l} \sum_{i=1}^l (a(x_i) - y(x_i))^2 = \frac{1}{l} \sum_{i=1}^l (kx_i + b - y(x_i))^2$$

ФУНКЦИЯ ПОТЕРЬ



- $L(a, x) = |a(x) - y(x)|$ - абсолютная ошибка;
- $L(a, x) = (a(x) - y(x))^2$ - квадратичная ошибка.


$$Q(a, X^l) = \frac{1}{l} \sum_{i=1}^l L(a, x_i)$$

$$Q(a, X^l) = \frac{1}{l} \sum_{i=1}^l (a(x_i) - y(x_i))^2 = \frac{1}{l} \sum_{i=1}^l (kx_i + b - y(x_i))^2$$

$$\mu(X^l) = \arg \min_{a \in A} Q(a, X^l)$$


НЕМНОГО ПРО ПРИЗНАКИ В ЛИНЕЙНЫХ МОДЕЛЯХ

$$y(x) = \sin(x) + 0,3x + \varepsilon(x), \quad x \in [0; 5]$$




$$\begin{aligned} f_0(x) &= 1 \\ f_1(x) &= x \\ f_2(x) &= x^2 \\ &\dots \\ f_n(x) &= x^n \end{aligned}$$


$$a(x) = 1 \cdot \theta_1 + x \cdot \theta_2 + x^2 \cdot \theta_3 + \dots + x^n \cdot \theta_{n+1}$$




$n = 1$




$n = 2$




$n = 3$




$n = 4$




$n = 5$




$n = 6$



$n = 7$





$n = 8$



$n = 9$



БИНАРНАЯ КЛАССИФИКАЦИЯ



$$x_i = [x_{i1}, x_{i2}]^T, \quad i = 1, 2, \dots$$

$$y_i = \begin{cases} +1, & \text{если } x_i \in C_1 \\ -1, & \text{если } x_i \in C_2 \end{cases}$$

БИНАРНАЯ КЛАССИФИКАЦИЯ



НЕМНОГО О ВЕРОЯТНОСТНОМ ПОДХОДЕ

Доход	Наличие жилья	Наличие работы	Число детей	Возврат кредита
10 000	1	1	2	1
10 000	1	1	2	-1
10 000	1	1	2	-1
10 000	1	1	2	1
10 000	1	1	2	-1
10 000	1	1	2	1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	1

$$a(x, \omega) = \text{sign}(\langle \omega, x \rangle)$$

$$P(y | x, \omega)$$

$$x = [10\ 000, 1, 1, 2]^T$$

$$P(y = +1 | x, \omega) = \frac{3}{6} = 0,5$$

$$P(y = -1 | x, \omega) = 1 - P(y = +1 | x, \omega) = 1 - 0,5 = 0,5$$

$$\omega_* = \arg \max_{\omega} P(y | x, \omega)$$

$$P(y_1, \dots, y_l | x_1, \dots, x_l, \omega_1, \dots, \omega_l) = \prod_{i=1}^l P(y_i | x_i, \omega_i)$$

$$\log L(\omega) = \sum_{i=1}^l \log P(y_i | x_i, \omega) \rightarrow \max_{\omega}$$

$$Q(a, X^l) = \sum_{i=1}^l L_i(x_i, \omega) = - \sum_{i=1}^l \log P(y_i | x_i, \omega) \rightarrow \min_{\omega}$$

НЕМНОГО О ВЕРОЯТНОСТНОМ ПОДХОДЕ

Доход	Наличие жилья	Наличие работы	Число детей	Возврат кредита
10 000	1	1	2	1
10 000	1	1	2	-1
10 000	1	1	2	-1
10 000	1	1	2	1
10 000	1	1	2	-1
10 000	1	1	2	1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	-1
15 000	1	0	3	1

$$a(x, \omega) = \text{sign}(\langle \omega, x \rangle)$$

$$P(y | x, \omega)$$

$$x = [10\ 000, 1, 1, 2]^T$$

$$P(y = +1 | x, \omega) = \frac{3}{6} = 0,5$$

$$P(y = -1 | x, \omega) = 1 - P(y = +1 | x, \omega) = 1 - 0,5 = 0,5$$

$$\omega_* = \arg \max_{\omega} P(y | x, \omega)$$

$$P(y_1, \dots, y_l | x_1, \dots, x_l, \omega_1, \dots, \omega_l) = \prod_{i=1}^l P(y_i | x_i, \omega_i)$$


$$\log L(\omega) = \sum_{i=1}^l \log P(y_i | x_i, \omega) \rightarrow \max_{\omega}$$

$$Q(a, X^l) = \sum_{i=1}^l L_i(x_i, \omega) = - \sum_{i=1}^l \log P(y_i | x_i, \omega) \rightarrow \min_{\omega}$$

О МЕТРИЧЕСКИХ МЕТОДАХ

- ирис щетинистый (*iris setosa*);
- ирис виргинский (*iris virginica*);
- ирис разноцветный (*iris versicolor*).


- длина наружной доли околоцветника (sepal length);
- ширина наружной доли околоцветника (sepal width);
- длина внутренней доли околоцветника (petal length);
- ширина внутренней доли околоцветника (petal width).




О МЕТРИЧЕСКИХ МЕТОДАХ

- ирис щетинистый (*iris setosa*);
 - ирис виргинский (*iris virginica*);
 - ирис разноцветный (*iris versicolor*).
- длина наружной доли околоцветника (sepal length);
 - ширина наружной доли околоцветника (sepal width);
 - длина внутренней доли околоцветника (petal length);
 - ширина внутренней доли околоцветника (petal width).

sepal length (cm)







petal length (cm)




О МЕТРИЧЕСКИХ МЕТОДАХ

Метод ближайших соседей (kNN)



НЕМНОГО ПРО КЛАСТЕРИЗАЦИЮ



Внутриклассовые расстояния, в среднем, меньше, чем межклассовые



Ленточные кластеры



Кластеры с ярко выраженными центрами



Кластеры с перемычками



Кластеры на фоне шумов










Кластеры в виде геометрических фигур



Один кластер

НЕМНОГО ПРО КЛАСТЕРИЗАЦИЮ

K-means





Шаг 4

Шаг 5


Шаг 6

НЕМНОГО ПРО КЛАСТЕРИЗАЦИЮ

K-means



РЕШАЮЩИЕ ДЕРЕВЬЯ




$$f_1(x) = \begin{cases} 0 - \text{не любит Python} \\ 1 - \text{любит Python} \end{cases}$$
$$f_2(x) = \begin{cases} 0 - \text{не любит "Кунг-фу Панда"} \\ 1 - \text{любит "Кунг-фу Панда"} \end{cases}$$
$$f_3(x) = \begin{cases} 0 - \text{не терпит математику} \\ 1 - \text{терпит математику} \end{cases}$$



$$R(x) = f_1(x) \wedge \overline{f_3(x)} \rightarrow \text{просто программист}$$

$$R(x) = \overline{f_1(x)} \wedge f_2(x) \rightarrow \text{свой}$$


РЕШАЮЩИЕ ДЕРЕВЬЯ



РЕШАЮЩИЕ ДЕРЕВЬЯ



РЕШАЮЩИЕ ДЕРЕВЬЯ – БУТСТРЭП И БЭГГИНГ



Обучающая выборка





1
2
3
4
5
6
7
8
9
10

bootstrap


Новая выборка

2
6
4
2
9
6
3


РЕШАЮЩИЕ ДЕРЕВЬЯ – БУТСТРЭП И БЭГГИНГ




РЕШАЮЩИЕ ДЕРЕВЬЯ – БУСТИНГ




Число ошибок: 7.0
Решающих деревьев: 1




Число ошибок: 7
Решающих деревьев: 2




Число ошибок: 0
Решающих деревьев: 3



Число ошибок: 0
Решающих деревьев: 4





НЕЙРОННЫЕ СЕТИ





Нейросеть – нелинейная композиция линейных моделей

НЕМНОГО ПРО PCA



НЕМНОГО ПРО PCA



ХОРОШИЕ ИСТОЧНИКИ ДЛЯ САМОСТОЯТЕЛЬНОГО ИЗУЧЕНИЯ

<https://propoprogs.ru/ml>

<https://stepik.org/course/209247/>

<https://girafe.ai/main>

<https://github.com/girafe-ai/ml-course>

https://www.youtube.com/watch?v=aircAruvnKk&list=PLZHQObOWTQDNU6R1_67000Dx_ZCJB-3pi

Книга Mathematics for machine learning (Marc Peter Deisenroth, A. Aldo Faisal, Cheng Soon Ong)