

```
In [2]: import IPython.display  
        IPython.display.display_latex(IPython.display.Latex(filename="macros.tex"))
```

# Регрессия

*Имеем:*

$(X, Y)$  тренировочную выборку размера  $N$ , количество фич  $M$

$$|\hat{Y}| = \mathbb{R}$$

**knn**

решение принимается как среднее от ответов соседей

**decision trees** критерий качества:

$$D = \frac{1}{l} \sum_{i=1}^l \left( y_i - \frac{1}{l} \sum_{i=1}^l y_i \right)^2$$

- $l$  - число объектов в листе Минимизируем дисперсию вокруг среднего, ищем признаки, разбивающие выборку таким образом, что значения целевого признака в каждом листе примерно равны.

Как будем предсказывать? -> Среднее по всем объектам в листе.

## Линейная регрессия

Имеем:

$$\begin{bmatrix} X & | & \text{Ones} \end{bmatrix} * \theta = Y_{predict}$$


Аналитическое решение

$$\theta = (X^T * X)^{-1} * X^T * Y$$

используя градиентный спуск

$$\theta^{(j+1)} := \theta^{(j)} - \gamma * (X^T * (X * \theta^{(j)} - Y))$$

Линейная регрессия



**метрики**



MAE (Mean absolute error):

$$MAE = \frac{1}{N} \sum_{i=1}^N |\alpha(x_i) - y_i|$$

RMSE (Root mean squared error):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\alpha(x_i) - y_i)^2}$$

RMSE – будет меньше для модели с большим количеством малых ошибок, чем для модели с одной большой ошибкой, в то время как для этой же модели MAE может быть одинаковым.

MSE (mean squared error):

$$MSE = \frac{1}{N} \sum_{i=1}^N (\alpha(x_i) - y_i)^2$$

Relative absolute error (RAE) Относительная абсолютная ошибка

$$RAE = \frac{\sum_{i=1}^N |\alpha(x_i) - y_i|}{\sum_{i=1}^N |\overline{\alpha(x_i)} - y_i|}$$

Relative squared error (RSE) Относительная квадратичная ошибка

$$RSE = \frac{\sum_{i=1}^N (\alpha(x_i) - y_i)^2}{\sum_{i=1}^N (\overline{\alpha(x_i)} - y_i)^2}$$

Коэффициент детерминации, часто называемый  $R^2$ , представляет прогностическую силу модели как значение между 0 и 1. Ноль означает, что модель случайна (ничего не объясняет); 1 означает, что есть идеальная подгонка.

$$R^2 = 1 - \frac{\sum_{i=1}^N (\alpha(x_i) - y_i)^2}{\sum_{i=1}^N (\bar{y} - y_i)^2}$$

## МЕТОД МАКСИМАЛЬНОГО ПРАВДОПОДОБИЯ

$$p(y_1, y_2, \dots, y_N \mid x_1, x_2, \dots, x_N, \theta) \rightarrow \max_{\theta}$$

$$W = \prod_i p(y_i \mid x_i, \theta) \rightarrow \max_{\theta}$$

Гипотеза:  $y(x_i) = \alpha(x_i, \theta) + \xi_i$ , где  $\xi_i$  из  $N(0, \sigma_i)$

$$W = \prod_i p(\alpha(x_i, \theta) + \xi_i) \rightarrow \max_{\theta}$$

Плотность нормального распределения:

$$p_{N(\mu, \sigma)}(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

Итого:

$$-\log(W) = \text{const} + \frac{1}{2} \sum_i \frac{1}{\sigma_i^2} (\xi)^2 = \text{const} + \frac{1}{2} \sum_i \frac{1}{\sigma^2} (\alpha(x, \theta) - y(x_i))^2$$

$\rightarrow \min$

**Получили метод наименьших квадратов Ordinary Least Squares(OLS)!**

## backfitting algorithm

$$\alpha(x) = \sum_i \phi_i(x_i)$$

$\phi_i$  - не линейные функции.

1) зафиксировать стартовые  $\phi_i$

2) Пока ER  $Q(\alpha, X) = \sum_i (\alpha(x_i) - y_i)^2$  не стабилизировался повторяем:

for  $j$ :

$$z_i = y_i - \sum_{k=1, k \neq i}^N (\phi_k(x_k^i)), \text{ for } i \in [1, N]$$

$$\phi_j := \operatorname{argmin}_{\phi_j} \sum_{i=1}^N (\phi_j(x_i) - z_i)^2$$

$$Q_j := \sum_{i=1}^N (\phi_j(x_i) - z_i)^2$$

## algorithms with regularisation

Ordinary Least Squares:


$$MSE \rightarrow \min$$

LASSO(least absolute shrinkage and selection operator):

$$MSE + \lambda * \|\theta\| \rightarrow \min$$

Ridge:

$$MSE + \lambda * \|\theta\|^2 \rightarrow \min$$





## L2 регуляризация как помощник в борьбе со скоррелированными признаками

С прошлых семинаров и лекций (либо можно прям явно вывести):

$$\nabla_{\theta} L(X, Y, \theta) = 0 = X^T X \theta - X^T Y$$

$$L_{reg} = L + 0.5(\lambda \theta)^T \lambda \theta$$

$$\begin{aligned} \nabla_{\theta} L_{reg}(X, Y, \theta) &= \nabla_{\theta} ((X\theta - Y)^T (X\theta - Y) + (\lambda \theta)^T \lambda \theta) = \\ X^T X \theta - X^T Y + 0.5 \nabla_{\theta} (\lambda \theta)^T \lambda \theta &= (X^T X + \lambda^T \lambda) \theta - X^T Y = 0 \end{aligned}$$

$$\theta = (X^T X + \lambda^T \lambda)^{-1} X^T Y$$

## Bias - Variance TradeOff (Разложение ошибки на разброс и смещение)

$$Y = f(X) + \epsilon, E[\epsilon] = 0, Var[\epsilon] = \sigma$$

Истинная зависимость:  $f$ , наш алгоритм:  $\hat{f}$ . Давайте найдем среднее значение ошибки на задаче регрессии.

$$E[(Y - \hat{f})^2] = E[Y^2 - 2Y\hat{f} + \hat{f}^2] = E[Y^2] - 2E[Y\hat{f}] + E[\hat{f}^2]$$

$$E[Y^2] = E[(f + \epsilon)^2] = f^2 + 2E[\epsilon]f + E[\epsilon^2] = f^2 + \sigma^2$$

$$E[Y\hat{f}] = E[(f + \epsilon)\hat{f}] = E[f\hat{f}] + E[\epsilon\hat{f}] = fE[\hat{f}]$$

$$E[\hat{f}^2] = Var[\hat{f}] + E[\hat{f}]^2$$

$$E[(Y - \hat{f})^2] = f^2 + \sigma^2 - 2fE[\hat{f}] + Var[\hat{f}] + E[\hat{f}]^2 = \sigma^2 + Var[\hat{f}]$$



$$+ (f - E[\hat{f}])^2$$

$$E[(Y - \hat{f})^2] = \sigma^2 + Var[\hat{f}] + Bias[\hat{f}]^2$$



Low Variance


High Variance

Low Bias




High Bias






**overfitting**



**underfitting**



**Good balance**

