

# Теория обучения

3 апреля 2013 г.

## Определение (Условное м.о.)

Совсем неформальное определение  $E(Y|X)$ : случайная величина, усредняющая значения  $Y$  относительно значений  $X$ .

Свойства:

- 1) Для независимых величин  $E(Y|X) = E(Y)$
- 2)  $E(E(Y|X)) = E(Y)$
- 3)  $E(f(X)Y|X) = f(X)E(Y|X)$

## Теорема

Пусть есть совместное распределение  $P(x, y)$  и некоторая выборка  $(X, Y)$ . Рассмотрим математическое ожидание ошибки  $E(y - f(x))^2$ . Лучшая оценка в смысле  $E(y - f(x)) \rightarrow \min$  будет  $E(Y|X)$ .

## Определение

$$E(y - f(x))^2 = E(y - E(y|x))^2 + E(E(y|x) - f(x))^2$$

$E(y - E(y|x))^2$  - шум


$E(E(y|x) - f(x))^2$  - bias-variance

## Определение


Теперь представим, что есть много датасетов  $D$  и оценка зависит от  $D$ :  $f(x, D)$ .

$$\begin{aligned} E_D(E(y|x) - f(x, D))^2 &= \\ &= (E(y|x) - E_D(f(x, D)))^2 + E_D(f(x, D) - E_D(f(x, D)))^2 \\ &(E(y|x) - E_D(f(x, D)))^2 - \text{bias}^2 \\ &E_D(f(x, D) - E_D(f(x, D)))^2 - \text{variance} \end{aligned}$$

# Bias-variance



# Bias-variance



## Пример



Рассмотрим функцию  $h(x) = \sin(2\pi x)$ . И возьмем  $L = 100$  датасетов по  $N = 25$  точек. Построим регрессию с регуляризацией  $L^2$  и гауссовскими базисными функциями.

$$\bar{y}(x) = \sum_{l=1}^L y^{(l)}(x)$$

$$\text{bias}^2 = \frac{1}{N} \sum_{n=1}^N (\bar{y}(x_n) - h(x_n))^2$$



$$\frac{1}{N} \sum_{n=1}^N \frac{1}{L} \sum_{l=1}^L (y^{(l)}(x_n) - \bar{y}(x_n))^2$$

# Bias-variance








# Bias-variance



# Bias-variance



# Bias-variance



## Определение

- 1) Датасет  $S$  разделим на  $S_{train}$  и  $S_{cv}$
- 2) Тренируем модели на  $S_{train}$
- 3) Выберем модель с наименьшей ошибкой на  $S_{cv}$
- 4) (опционально) Тренируем выбранную модель на всем  $S$

## Определение

- 1) Датасет  $S$  разделим на  $k$  равных частей:  $S = S_1 \cup \dots \cup S_k$
- 2) Для каждого  $j = 1 \dots k$  тренируем модель  $M_j$  на  $S_1 \cup \dots \cup S_{j-1} \cup S_{j+1} \cup \dots \cup S_k$ , проверяем на  $S_j$ , считаем ошибки
- 3) Выбираем модель с наименьшим средним по  $j$  ошибок
- 4) (опционально) Тренируем выбранную модель на всем  $S$