

# Разбор летучки

---

# Лекция 7

## Выбор моделей

---

Екатерина Тузова

# Задача выбора метода обучения

$X$  - множество объектов

$Y$  - множество классов

Обучающая выборка:  $X^l = (x_i, y_i)_{i=1}^l$

Целевая функция:  $f : X \rightarrow Y$

Набор моделей алгоритмов  $A_t : X \rightarrow Y, t \in T$

Методы обучения  $\mu : (X \times Y)^l \rightarrow A_t, t \in T$

**Задача:** Найти алгоритм  $a \in A_t$  с наилучшей обобщающей способностью

# Модель

Неизвестная целевая функция

$$f : X \rightarrow Y$$



Обучающая выборка


$$X^l = (x_i, y_i)_{i=1}^l$$




Финальный алгоритм

$$a \in A_t$$

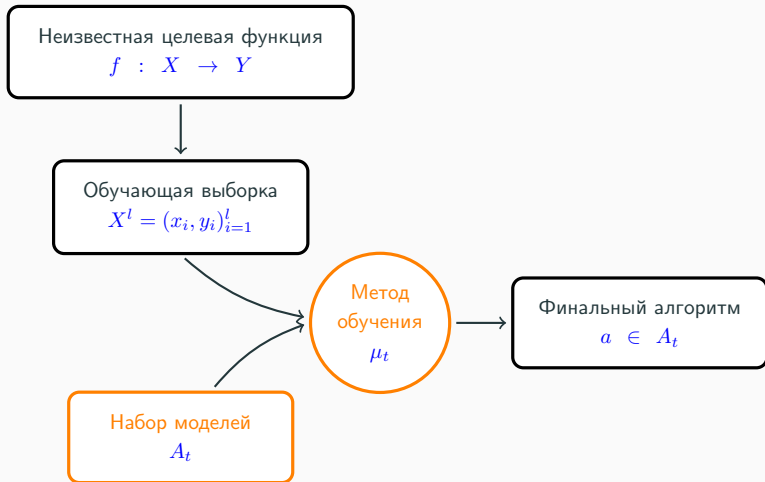
# Модель



# Модель



# Модель



# Пример

---



Набор моделей:

$$a(\mathbf{x}) = \text{sign}\left(\sum_{j=1}^n w_j x^j - w_0\right)$$

Набор моделей:

$$a(\mathbf{x}) = \text{sign}\left(\sum_{j=1}^n w_j x^j - w_0\right)$$

Набор моделей:

$$a(\mathbf{x}) = \text{sign}\left(\sum_{j=1}^n w_j x^j - w_0\right)$$

Метод обучения:


```
1 function PERCEPTRON( $X^l$ )
2   Инициализировать  $w_0, \dots, w_n$ 
3   repeat[пока  $\mathbf{w}$  изменяются]
4     for  $i = 1, \dots, l$  do
5       if  $a(x_i) \neq y_i$  then
6          $\mathbf{w} = \mathbf{w} + y_i \mathbf{x}_i$ 
```

Научиться оценивать метод обучения и обобщающую способность алгоритма

Функция потерь  $\mathcal{L}(a, x_i)$  – характеризует величину ошибки алгоритма  $a$  на объекте  $x_i$ .

Если  $\mathcal{L}(a, x_i) = 0$ , то ответ  $a(x_i)$  называется корректным.

# Примеры $\mathcal{L}$



Функционал качества алгоритма  $a$  на выборке  $X^l$ :

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

Минимизация эмпирического риска:

$$\arg \min_{A_t} Q(a, X^l)$$

$$Q_{\mu}(X^l) = Q(\mu(X^l), X^l)$$

Этот функционал оценивает качество обучения на выборке  $X^l$




$$Q_{\mu}(X^l) = Q(\mu(X^l), X^l)$$

Этот функционал оценивает качество обучения на выборке  $X^l$

Какая с этим может быть проблема?

# Сложность модели



Почему случается  
переобучение?

---

- Слишком мало объектов
- Слишком много признаков
- Линейная зависимость признаков

$$E_{in} = Q_{\mu}(X^l) = Q(\mu(X^l), X^l)$$

Внешний функционал по отложенной выборке:

$$E_{out} = Q_{\mu}(X^t, X^k) = Q(\mu(X^t), X^k)$$

$$E_{in} = Q_{\mu}(X^l) = Q(\mu(X^l), X^l)$$

Внешний функционал по отложенной выборке:

$$E_{out} = Q_{\mu}(X^t, X^k) = Q(\mu(X^t), X^k)$$

Какой здесь недостаток?

$$E_{in} = Q_{\mu}(X^l) = Q(\mu(X^l), X^l)$$

Внешний функционал по отложенной выборке:

$$E_{out} = Q_{\mu}(X^t, X^k) = Q(\mu(X^t), X^k)$$

Сильная зависимость от разбиения  $X^l = X^t \sqcup X^k$

**Идея:** Усреднить по всем  $C_l^t$  выборкам  $X^l = X^t \sqcup X^k$

$$CCV(\mu, X^l) = \frac{1}{C_l^t} \sum_{X^t} Q_\mu(X^t, X^k)$$



**Идея:** Усреднить по всем  $C_l^t$  выборкам  $X^l = X^t \sqcup X^k$

$$CCV(\mu, X^l) = \frac{1}{C_l^t} \sum_{X^t} Q_\mu(X^t, X^k)$$

Во что превратится оценка при  $k = 1$ ?

- Оценка вычислительно слишком сложна
- Не учитывает дисперсию  $X^k$

**Идея:** Возьмём случайное разбиение  $X^l = X_1 \sqcup \dots \sqcup X_k$  на  $k$  блоков равной длины.

$$CV_k(\mu, X^l) = \frac{1}{k} \sum_{i=1}^k Q_\mu(X^l \setminus X_i, X_i)$$

**Идея:** Возьмём случайное разбиение  $X^l = X_1 \sqcup \dots \sqcup X_k$  на  $k$  блоков равной длины.

$$CV_k(\mu, X^l) = \frac{1}{k} \sum_{i=1}^k Q_\mu(X^l \setminus X_i, X_i)$$

Недостатки:

- Оценка зависит от разбиения на блоки
- Каждый объект только один раз участвует в контроле

**Идея:** Выборка разбивается  $t$  раз случайным образом на  $k$  блоков


$$CV_{tk}(\mu, X^l) = \frac{1}{t} \sum_{j=1}^t \frac{1}{k} \sum_{i=1}^k Q_{\mu}(X^l \setminus X_{ji}, X_{ji})$$

**Идея:** Выборка разбивается  $t$  раз случайным образом на  $k$  блоков

$$CV_{tk}(\mu, X^l) = \frac{1}{t} \sum_{j=1}^t \frac{1}{k} \sum_{i=1}^k Q_{\mu}(X^l \setminus X_{ji}, X_{ji})$$

- + Выбором  $t$  можно улучшать точность оценки
- + Каждый объект участвует в контроле  $t$  раз

# Кривая обучения



# Критерий непротиворечивости моделей

**Идея:** Если модель верна, то алгоритмы, настроенные по разным частям данных, не должны противоречить друг другу.



# Аналитический подход

---

1. Получить верхнюю оценку вероятности переобучения

$$P[E_{out} - E_{in} > \varepsilon] \leq \eta(\varepsilon)$$

2. Тогда с вероятностью не менее  $1 - \eta$  справедливо

$$E_{out} < E_{in} + \varepsilon(\eta)$$


3. Будем оптимизировать

$$E_{in} + \varepsilon(\eta) \rightarrow \min_{\mu}$$

Регуляризатор  $\varepsilon$  — аддитивная добавка к внутреннему критерию, штраф за сложность модели  $A$ .

# Неравенство Бернштейна-Хёфдинга

$$P[|a - b| > \varepsilon] \leq 2e^{-2\varepsilon^2 l}$$



$a$  – доля оранжевых шаров в выборке размера  $l$

$b$  – истинная доля оранжевых шаров

Какое отношение это имеет к нашим моделям?

---

Каждый шар это объект  $x$  из пространства  $X$ .  
Неизвестная целевая функция  $f$ .

Зелёный шар – модель  $h$  верна ( $h(x) = f(x)$ )

Оранжевый шар – модель  $h$  не верна ( $h(x) \neq f(x)$ )

По выборке  $X^l$  можем оценить долю объектов, на которых модель ошибается.

$E_{in}(h) = a$  - доля объектов в выборке  $X^l$ , на которых  $h$  ошибается  
 $E_{out}(h) = b$  - доля объектов во всём множестве  $X$ , на которых  $h$  ошибается

$$P[|E_{in}(h) - E_{out}(h)| > \varepsilon] \leq 2e^{-2\varepsilon^2 l}$$

Неравенство выполняется для каждой модели.

Какова вероятность, что модель  $a \in A$ , наилучшим образом приближающая  $f$  по выборке, наилучшим образом приближает  $f$  на всём множестве?



С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз?

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз?


0.001

С какой вероятностью одна из 1000 монет, каждая из которых подброшена 10 раз, выпадет одной и той же стороной все 10 раз?

С какой вероятностью одна из 1000 монет, каждая из которых подброшена 10 раз, выпадет одной и той же стороной все 10 раз?

0.63

## К нашей задаче




На  $h_t$  модели наблюдаем переобучение.


$$\begin{aligned} P[|E_{in}(a) - E_{out}(a)| > \varepsilon] &\leq \sum_{t=1}^T P[|E_{in}(h) - E_{out}(h)| > \varepsilon] \\ &\leq 2Te^{-2\varepsilon^2 l} \end{aligned}$$

Какое количество моделей в  
нашем пространстве  $A$ ?

---








$\Delta E_{out}$  = площадь жёлтой области

$\Delta E_{in}$  = изменение меток объектов жёлтой области в выборке

$$|E_{in}(h_1) - E_{out}(h_1)| \approx |E_{in}(h_2) - E_{out}(h_2)|$$

Обучающая выборка  $x_1, \dots, x_l$  и набор бинарных значений меток  $y_1, \dots, y_l$ .



Сколько вариантов  $y_1, \dots, y_l$ ?


$$P(|E_{in}(a) - E_{out}(a)| > \varepsilon) \leq 2Te^{-2\varepsilon^2 l}$$

Наш набор моделей  $A$  может породить  $|A(x_1, \dots, x_l)|$  дихотомий.


$$|A(x_1, \dots, x_l)| \leq 2^l$$

При этом сам набор моделей может быть бесконечным.


# Функция роста $m_A(l)$



$l = 3$



$l = 3$



$l = 4$

$$m_A(l) = \max_{x_1, \dots, x_l} |A(x_1, \dots, x_l)| \leq 2^l$$

Если для некоторого  $k$  выполняется  $m_A(k) < 2^k$ , то  $k$  называется точкой разрыва.

Наличие точки разрыва означает наличие полиномиального ограничения на функцию роста  $m_A(l)$

# Пример

	# of rows	$x_1$	$x_2$	...	$x_{l-1}$	$x_l$
$S_1$	$\alpha$	+1	+1	...	+1	+1
		-1	+1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	-1	-1
		-1	+1	...	-1	+1
$S_2$	$\beta$	+1	-1	...	+1	+1
		-1	-1	...	+1	+1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	+1
		-1	-1	...	-1	+1
$S_2^-$	$\beta$	+1	-1	...	+1	-1
		-1	-1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	-1
		-1	-1	...	-1	-1

Разделим на 2 ситуации относительно  $x_l$ :  
 либо есть только один вариант (+1 или -1), либо оба (+1 и -1)



$B(l, k)$  – максимальное число дихотомий для выборки размера  $l$  при наличии точки разрыва  $k$ .

- $B(l, k) = \alpha + 2\beta$

- $\alpha + \beta \leq B(l - 1, k)$

- $\beta \leq B(l - 1, k - 1)$

$$\implies B(l, k) \leq B(l - 1, k) + B(l - 1, k - 1)$$

# Оценка $\alpha + \beta$

	# of rows	$\mathbf{x}_1$	$\mathbf{x}_2$	...	$\mathbf{x}_{l-1}$	$\mathbf{x}_l$
$S_1$	$\alpha$	+1	+1	...	+1	+1
		-1	+1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	-1	-1
		-1	+1	...	-1	+1
$S_2$	$\beta$	+1	-1	...	+1	+1
		-1	-1	...	+1	+1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	+1
		-1	-1	...	-1	+1
$S_2^-$	$\beta$	+1	-1	...	+1	-1
		-1	-1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	-1
		-1	-1	...	-1	-1

	# of rows	$x_1$	$x_2$	...	$x_{l-1}$	$x_l$
$S_1$	$\alpha$	+1	+1	...	+1	+1
		-1	+1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	-1	-1
		-1	+1	...	-1	+1
$S_2$	$\beta$	+1	-1	...	+1	+1
		-1	-1	...	+1	+1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	+1
		-1	-1	...	-1	+1
$S_2^-$	$\beta$	+1	-1	...	+1	-1
		-1	-1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	-1
		-1	-1	...	-1	-1

$$B(l, k) \leq \sum_{i=0}^{k-1} C_l^i$$

Доказывается по индукции:

$$B(l, 1) = 1, \quad B(1, k) = 2$$

Индукционный шаг: 
$$\sum_{i=0}^{k-1} C_l^i = \sum_{i=0}^{k-1} C_{l-1}^i + \sum_{i=0}^{k-2} C_l^i$$

$$m_A(l) \leq B(l, k) \leq \sum_{i=0}^{k-1} C_l^i \leq l^{k-1}$$

$$P(E_{in}(a) - E_{out}(a) > \varepsilon) \leq 2l^{k-1} e^{-2\varepsilon^2 l}$$

$$P(E_{in}(a) - E_{out}(a) > \varepsilon) \leq 4m_A(2l)e^{-\frac{1}{8}\varepsilon^2 l}$$

## Пример регуляризации в градиентном спуске

Функционал с регуляризацией:

$$Q_\tau = Q + \frac{\tau}{2} \|\mathbf{w}\|^2 \rightarrow \min_{\mathbf{w}}$$

Градиент:

$$\nabla Q_\tau = \nabla Q + \tau \mathbf{w}$$

Градиентный шаг:

$$\mathbf{w} = \mathbf{w}(1 - \alpha\tau) - \alpha \nabla Q(\mathbf{w})$$



Вопросы?

## Что почитать по этой лекции

- Professor Yaser Abu-Mostafa MOOC
- Tom Mitchell "Machine Learning" Chapter 4
- Hastie, T., Tibshirani R. "The Elements of Statistical Learning"  
Chapter 7.9

## На следующей лекции

- Многослойная нейронная сеть
- Нелинейное преобразование
- Быстрое вычисление градиента
- Алгоритм обратного распространения ошибки
- Оптимизация структуры сети
- Сверточные нейросети