

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


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



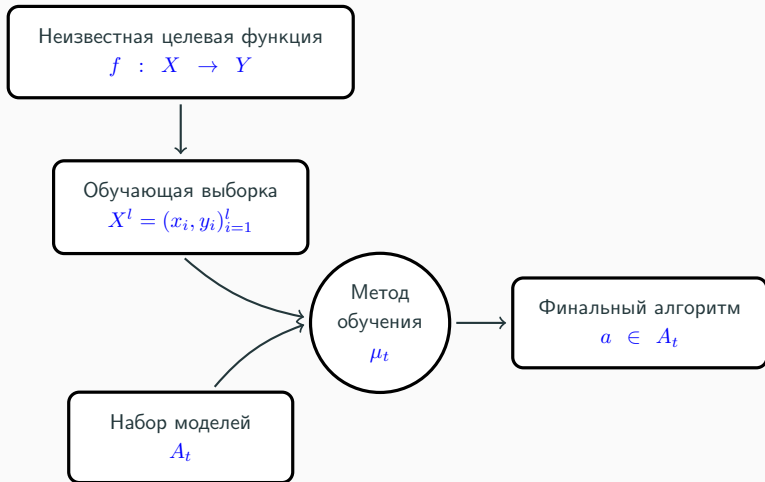
Финальный алгоритм

$$a \in A_t$$

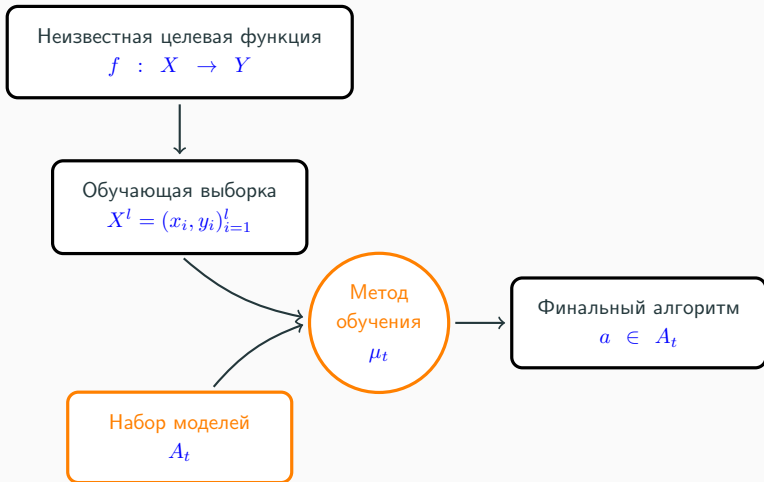
Модель



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



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 ε — 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 ?






ΔE_{out} = площадь жёлтой области

ΔE_{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	α	+1	+1	...	+1	+1
		-1	+1	...	+1	-1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	-1	-1
		-1	+1	...	-1	+1
S_2	β	+1	-1	...	+1	+1
		-1	-1	...	+1	+1
		⋮	⋮	⋮	⋮	⋮
		+1	-1	...	+1	+1
		-1	-1	...	-1	+1
S_2^-	β	+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 .

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

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

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

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

Оценка $\alpha + \beta$

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

Индукционный шаг:

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

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


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

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

Размерность $d_{VC} =$ наибольшее l , для которого $m_A(l) = 2^l$.

$$d_{VC} = k - 1$$

Для линейных классификаторов $d_{VC} = \#$ number of features + 1.



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