

МАШИННОЕ ОБУЧЕНИЕ

линейные модели классификации и регрессии

Воронцов Константин Вячеславович
ФУПМ МФТИ • ВМК МГУ • Яндекс • FORECSYS

6 июля 2016
Сочи, Сириус • Проектная смена • 1–24 июля 2016

1 Обучение как оптимизация

- Оптимационные постановки задач обучения
- Методы оптимизации
- Линейная регрессия

2 Градиентные методы оптимизации

- Метод стохастического градиента
- Эффект переобучение
- Регуляризация линейных моделей

3 Измерение качества классификации

- Чувствительность и специфичность
- ROC-кривая и площадь под кривой
- Явная максимизация сглаженного AUC

Восстановление зависимости по эмпирическим данным

Задача восстановления зависимости $y = f(x)$
по точкам обучающей выборки (x_i, y_i) , $i = 1, \dots, \ell$.

Дано: векторы $x_i = (x_i^1, \dots, x_i^n)$ — объекты обучающей выборки,
 $y_i = f(x_i)$ — правильные ответы, $i = 1, \dots, \ell$:

$$\begin{pmatrix} x_1^1 & \dots & x_1^n \\ \dots & \dots & \dots \\ x_\ell^1 & \dots & x_\ell^n \end{pmatrix} \xrightarrow{f} \begin{pmatrix} y_1 \\ \dots \\ y_\ell \end{pmatrix}$$

Найти: функцию $a(x)$, способную давать правильные ответы
на тестовых объектах $\tilde{x}_i = (\tilde{x}_i^1, \dots, \tilde{x}_i^n)$, $i = 1, \dots, k$:

$$\begin{pmatrix} \tilde{x}_1^1 & \dots & \tilde{x}_1^n \\ \dots & \dots & \dots \\ \tilde{x}_k^1 & \dots & \tilde{x}_k^n \end{pmatrix} \xrightarrow{a?} \begin{pmatrix} a(\tilde{x}_1) \\ \dots \\ a(\tilde{x}_k) \end{pmatrix}$$

Типы признаков и типы задач

Типы признаков, $x_j^i \in D_j$, в зависимости от множества D_j :

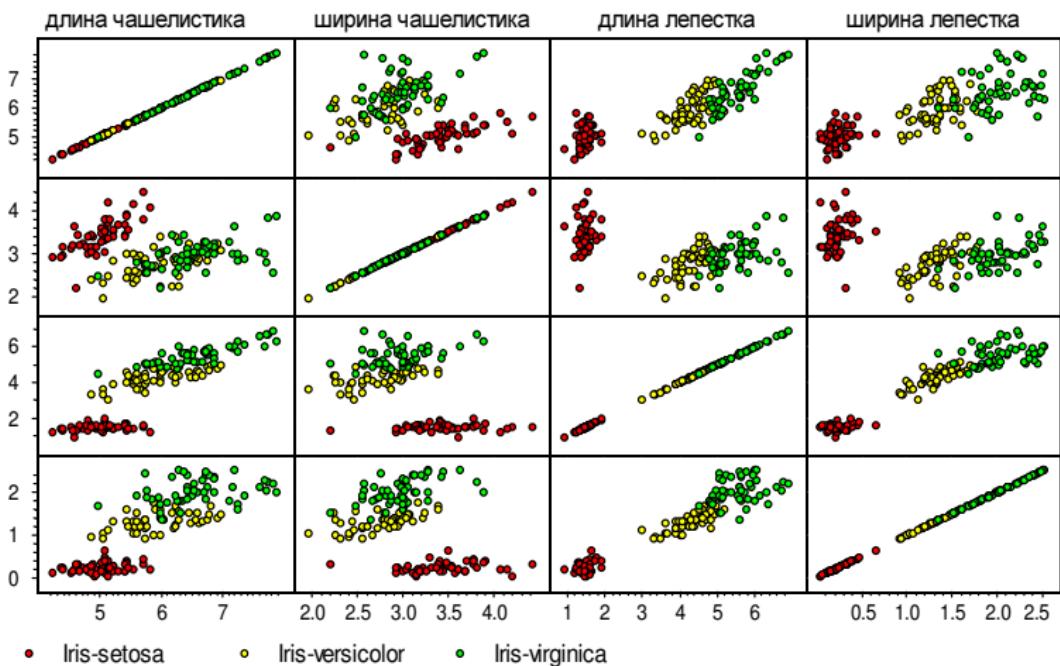
- $D_j = \{0, 1\}$ — бинарный признак;
- $|D_j| < \infty$ — номинальный признак;
- D_j упорядочено — порядковый признак;
- $D_j = \mathbb{R}$ — количественный признак.

Типы задач, $y_i \in Y$, в зависимости от множества Y :

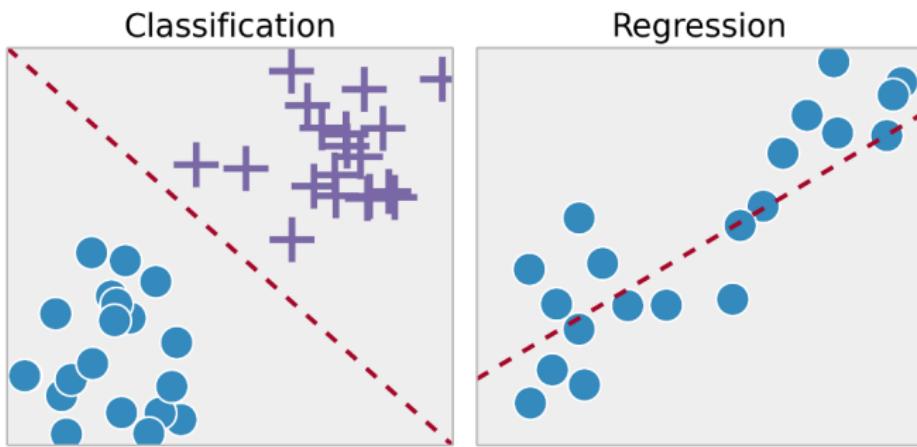
- $Y = \{0, 1\}$ или $Y = \{-1, +1\}$ — классификация на 2 класса;
- $Y = \{1, \dots, M\}$ — на M непересекающихся классов;
- $Y = \{0, 1\}^M$ — на M классов, которые могут пересекаться;
- $Y = \mathbb{R}$ — задача восстановления регрессии;
- Y упорядочено — задача ранжирования (learning to rank).

Пример. Задача классификации цветков ириса [Фишер, 1936]

$n = 4$ признака, $|Y| = 3$ класса, длина выборки $\ell = 150$.



Линейные модели классификации и регрессии



Почему мы так любим линейные модели?
Как обучать параметры линейных моделей?
Как проверять качество предсказательной модели?

Восстановление регрессии — это оптимизация

Задача восстановления регрессионной зависимости, $y_i \in \mathbb{R}$

- 1 Выбираем модель регрессии, например, линейную:

$$a(x, w) = \langle x, w \rangle = \sum_{j=1}^n x^j w_j, \quad x, w \in \mathbb{R}^n$$

- 2 Выбираем функцию потерь, например, квадратичную:

$$\mathcal{L}(a, y) = (a - y)^2$$

- 3 Минимизируем потери методом наименьших квадратов:

$$Q(w) = \frac{1}{\ell} \sum_{i=1}^{\ell} (a(x_i, w) - y_i)^2 \rightarrow \min_w$$

- 4 Проверяем прогностическую (обобщающую) способность:

$$\tilde{Q}(w) = \frac{1}{k} \sum_{i=1}^k (a(\tilde{x}_i, w) - \tilde{y}_i)^2$$

Обучение классификации — тоже оптимизация

Задача классификации, $y_i \in \{-1, +1\}$

- 1 Выбираем модель классификации, например, линейную:

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

- 2 Выбираем функцию потерь, например, бинарную:

$$\mathcal{L}(a, y) = [a(x_i, w)y_i < 0]$$

- 3 Минимизируем частоту ошибок на обучающей выборке:

$$Q(w) = \frac{1}{\ell} \sum_{i=1}^{\ell} [a(x_i, w)y_i < 0] \rightarrow \min_w$$

- 4 Проверяем прогностическую (обобщающую) способность:

$$\tilde{Q}(w) = \frac{1}{k} \sum_{i=1}^k [a(\tilde{x}_i, w)\tilde{y}_i < 0]$$

Обучение классификации — сглаживание функции потерь

Задача классификации, $y_i \in \{-1, +1\}$

- 1 Выбираем модель классификации, например, линейную:

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

- 2 Мажорируем пороговую функцию потерь непрерывной:

$$[M_i < 0] \leq \mathcal{L}(M_i), \quad M_i = \langle x_i, w \rangle y_i \text{ — отступ (margin)}$$

- 3 Минимизируем сглаженную частоту ошибок:

$$Q(w) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(\langle x_i, w \rangle y_i) \rightarrow \min_w$$

- 4 Проверяем прогностическую (обобщающую) способность:

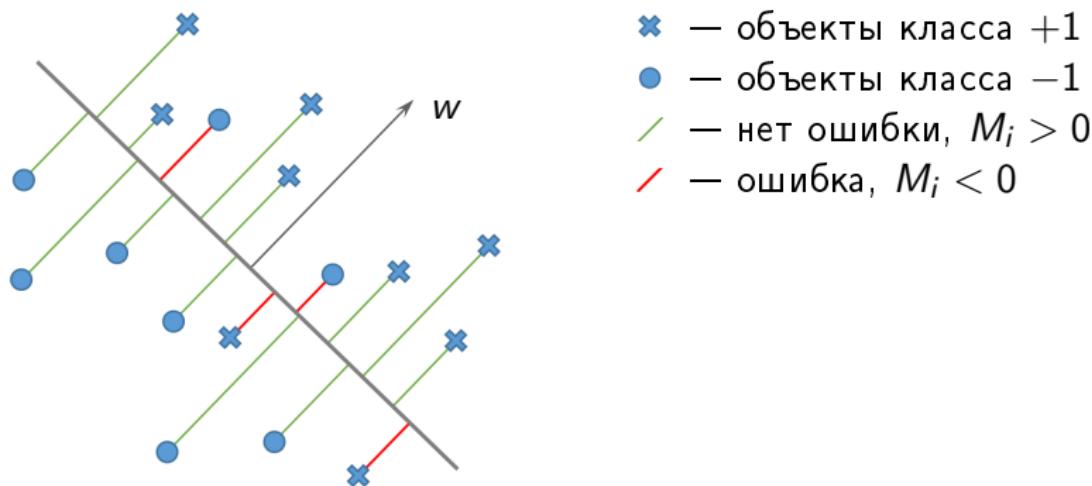
$$\tilde{Q}(w) = \frac{1}{k} \sum_{i=1}^k [\langle \tilde{x}_i, w \rangle \tilde{y}_i < 0]$$

Геометрический смысл отступов объектов

w — нормаль (направляющий вектор) разделяющей гиперплоскости, направлена в сторону класса +1

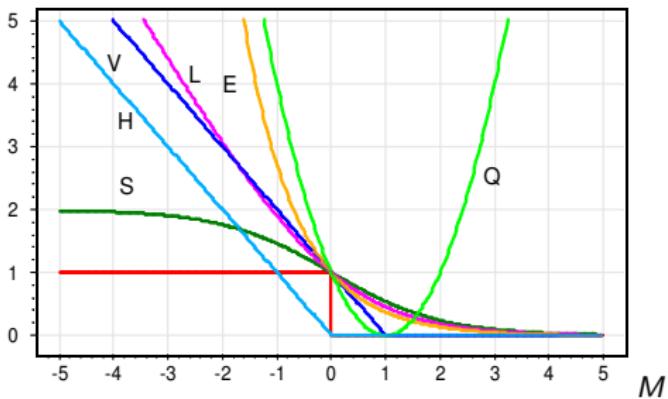
$\langle x_i, w \rangle$ — проекция вектора x_i на вектор нормали w

$\langle x_i, w \rangle y_i = M_i$ — проекция на нормаль в сторону класса y_i



Непрерывные аппроксимации пороговой функции потерь

Часто используемые непрерывные функции потерь $\mathcal{L}(M)$:



- | | |
|-----------------------------|---|
| $V(M) = (1 - M)_+$ | — кусочно-линейная (SVM) |
| $H(M) = (-M)_+$ | — кусочно-линейная (Hebb's rule) |
| $L(M) = \log_2(1 + e^{-M})$ | — логарифмическая (LR, Logistic Regression) |
| $Q(M) = (1 - M)^2$ | — квадратичная (Fisher's Linear Discriminant) |
| $S(M) = 2(1 + e^M)^{-1}$ | — сигмоидная (ANN, Artificial Neural Network) |
| $E(M) = e^{-M}$ | — экспоненциальная (AdaBoost) |
| $[M < 0]$ | — пороговая функция потерь. |

Общие подходы к решению оптимизационных задач

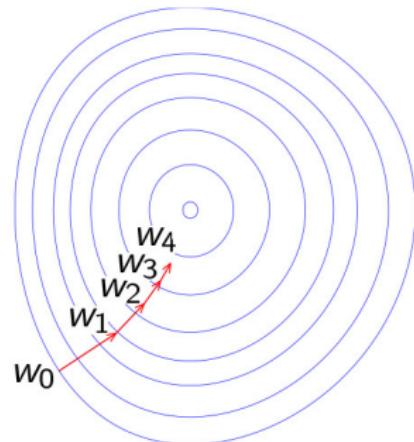
Аналитический подход (напр. метод наименьших квадратов):
Если w — точка минимума гладкой функции $Q(w)$, то

$$\frac{\partial Q(w)}{\partial w_j} = 0, \quad j = 1, \dots, n.$$

Это система n уравнений с n неизвестными.

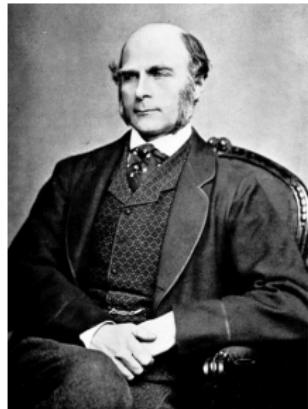
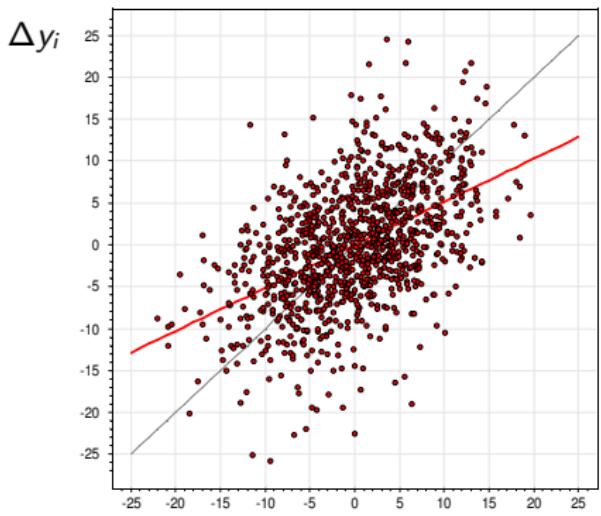
Численный метод — градиентный спуск:

- 1 начальное приближение w^0 , $t := 0$;
- 2 **повторять**
- 3 $w_j^{t+1} := w_j^t - h^t \cdot \frac{\partial Q(w^t)}{\partial w_j}$, $j = 1, \dots, n$;
- 4 $t := t + 1$;
- 5 **пока** процесс не сойдётся;



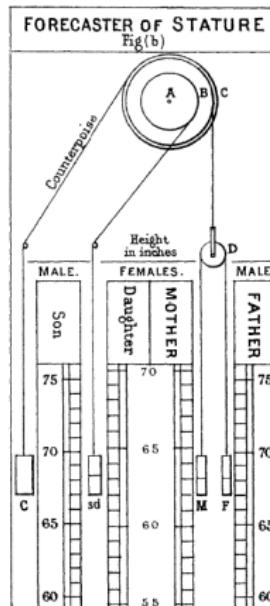
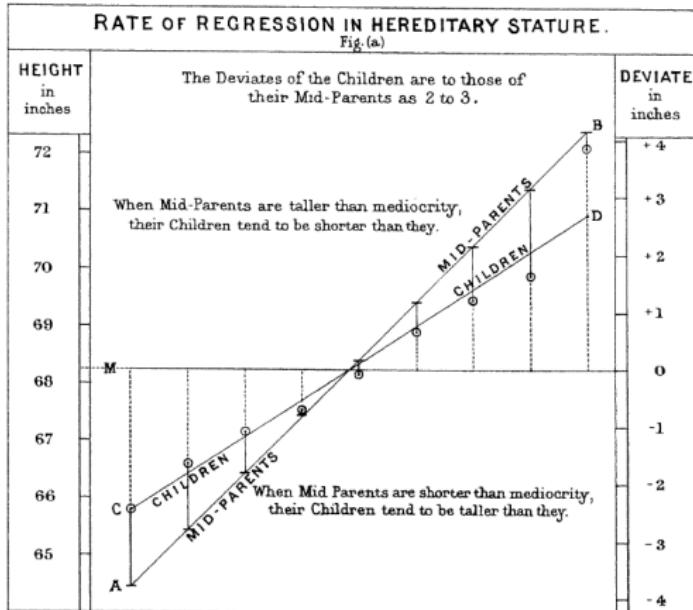
Откуда пошло название «регрессия» (Гальтон, 1886)

Исследование наследственности роста.
отклонение роста от среднего в популяции:
 Δx_i — отклонение роста отца
 Δy_i — отклонение роста взрослого сына



Фрэнсис Гальтон
(1822–1911)

Скрытый смысл: «регрессия» — сначала данные, потом модель



Galton F. Regression Towards Mediocrity in Hereditary Stature. 1886.

Задача проведения прямой через заданные точки

Дано: $x_i, y_i \in \mathbb{R}$, $i = 1, \dots, \ell$

Найти: параметры $w = (\alpha, \beta)$ линейной модели $y = \alpha x + \beta$

Критерий: $Q(\alpha, \beta) = \sum_{i=1}^{\ell} (\alpha x_i + \beta - y_i)^2 \rightarrow \min$

Аналитический метод решения:

$$\frac{\partial Q}{\partial \alpha} = 0 \quad \Rightarrow \quad \alpha \sum_{i=1}^{\ell} x_i^2 + \beta \sum_{i=1}^{\ell} x_i - \sum_{i=1}^{\ell} x_i y_i = 0$$

$$\frac{\partial Q}{\partial \beta} = 0 \quad \Rightarrow \quad \alpha \sum_{i=1}^{\ell} x_i + \beta \sum_{i=1}^{\ell} 1 - \sum_{i=1}^{\ell} y_i = 0$$

Это система линейных уравнений 2×2 :

$$\begin{cases} \alpha S_{xx} + \beta S_x = S_{xy} \\ \alpha S_x + \beta S_1 = S_y \end{cases} \Rightarrow \begin{cases} \alpha = \frac{S_{xy} S_1 - S_x S_y}{S_{xx} S_1 - S_x S_x} \\ \beta = \frac{S_{xx} S_y - S_{xy} S_x}{S_{xx} S_1 - S_x S_x} \end{cases}$$

Метод стохастического градиента (SG, Stochastic Gradient)

Задача классификации: $y_i \in \{-1, +1\}$, $a(x, w) = \text{sign}\langle w, x \rangle$.

Минимизация сглаженной частоты ошибок:

$$Q(w) = \sum_{i=1}^{\ell} \mathcal{L}(\langle w, x_i \rangle y_i) \rightarrow \min_w .$$

Один шаг градиентного спуска:

$$w^{t+1} := w^t - h^t \sum_{i=1}^{\ell} \mathcal{L}'(\langle w^t, x_i \rangle y_i) x_i y_i.$$

Идея ускорения сходимости: брать (x_i, y_i) по одному в случайном порядке и сразу обновлять вектор весов,

$$w^{t+1} := w^t - h^t \mathcal{L}'(\langle w^t, x_i \rangle y_i) x_i y_i.$$

Алгоритм SG (Stochastic Gradient)

Вход: выборка $(x_i, y_i)_{i=1}^{\ell}$;

Выход: веса w_1, \dots, w_n ;

- 1 инициализировать веса $w_j, j = 1, \dots, n$;
- 2 **повторять**
- 3 | выбрать случайный объект (x_i, y_i) из обучающей выборки;
- 4 | выбрать величину градиентного шага h ;
- 5 | выполнить градиентный шаг:
 $w_j := w_j - h \mathcal{L}'(\langle w, x_i \rangle y_i) x_i^j$ для всех $j = 1, \dots, n$;
- 6 **пока** процесс не сойдётся куда-нибудь;

Преимущества и недостатки:

- ⊕ можно брать какие угодно модели и функции потерь \mathcal{L}
- ⊕ хорошо работает на больших выборках
- ⊖ возможно застревание в локальных экстремумах

Эвристики

- Выбор начального приближения, например, так:

$$w_j^0 := \frac{\langle y, f_j \rangle}{\langle f_j, f_j \rangle} \quad (\text{из одномерной линейной регрессии})$$

$f_j = (x_i^j)_{i=1}^\ell$ — вектор значений j -го признака,
 $y = (y_i)_{i=1}^\ell$ — вектор ответов.

- Выбор темпа обучения (градиентного шага) h^t :
сходимость гарантируется для выпуклых $Q(w)$ при

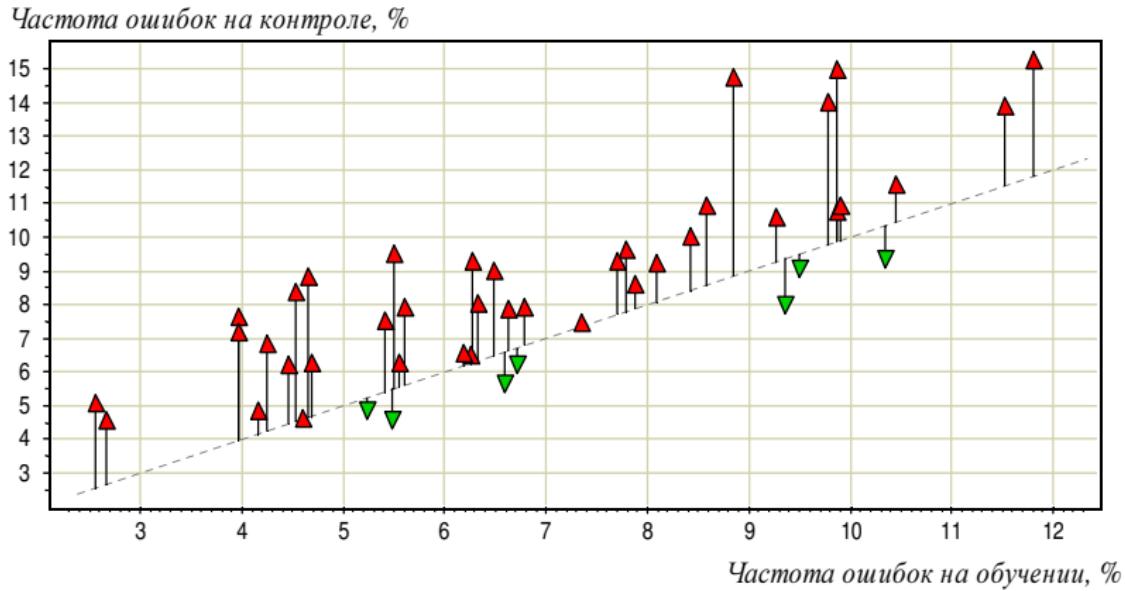
$$h^t \rightarrow 0, \quad \sum_{t=1}^{\infty} h^t = \infty, \quad \sum_{t=1}^{\infty} (h^t)^2 < \infty,$$

в частности можно положить $h^t = \frac{1}{t}$;

- Выбор порядка предъявления объектов:
 - случайно, но попеременно из разных классов;
 - чаще брать пограничные объекты с малым $|M_i|$;

Пример. Переобучение в задаче медицинской диагностики

Задача предсказания отдалённого результата хирургического лечения атеросклероза. Точки — различные алгоритмы.



Пример: переобучение полиномиальной регрессии

Зависимость $y(x) = \frac{1}{1 + 25x^2}$ на отрезке $x \in [-2, 2]$.

Признаковое описание $x \mapsto (1, x^1, x^2, \dots, x^n)$.

Модель полиномиальной регрессии

$$a(x, \theta) = \theta_0 + \theta_1 x + \cdots + \theta_n x^n \text{ — полином степени } n.$$

Обучение методом наименьших квадратов:

$$Q(a, X^\ell) = \sum_{i=1}^{\ell} (\theta_0 + \theta_1 x_i + \cdots + \theta_n x_i^n - y_i)^2 \rightarrow \min_{\theta_0, \dots, \theta_n}.$$

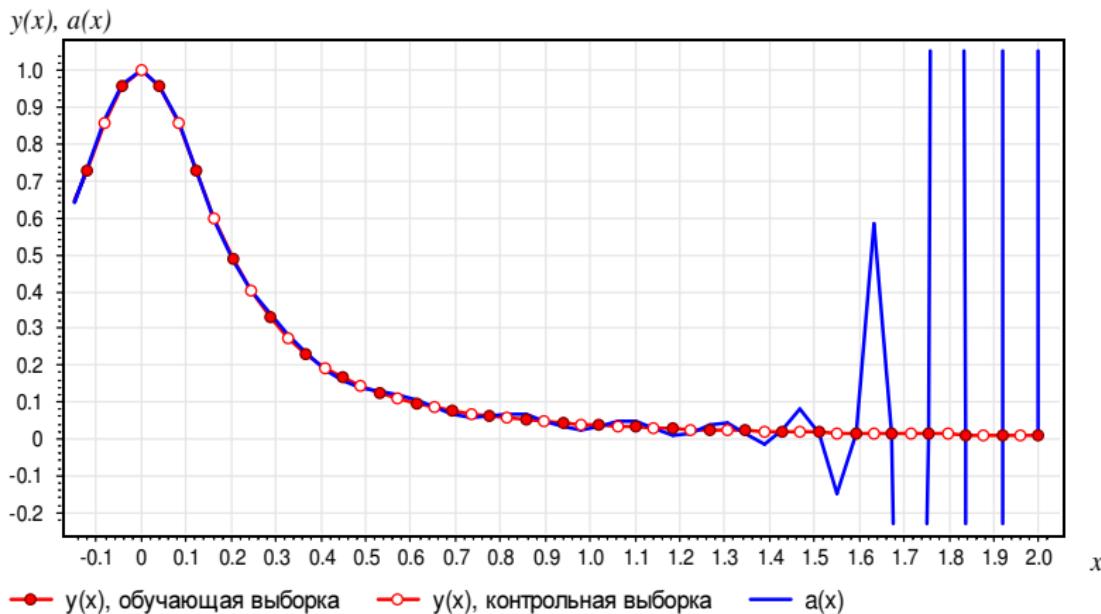
Обучающая выборка: $X^\ell = \{x_i = 4 \frac{i-1}{\ell-1} - 2 \mid i = 1, \dots, \ell\}$.

Контрольная выборка: $X^k = \{x_i = 4 \frac{i-0.5}{\ell-1} - 2 \mid i = 1, \dots, \ell-1\}$.

Что происходит с $Q(a, X^\ell)$ и $Q(a, X^k)$ при увеличении n ?

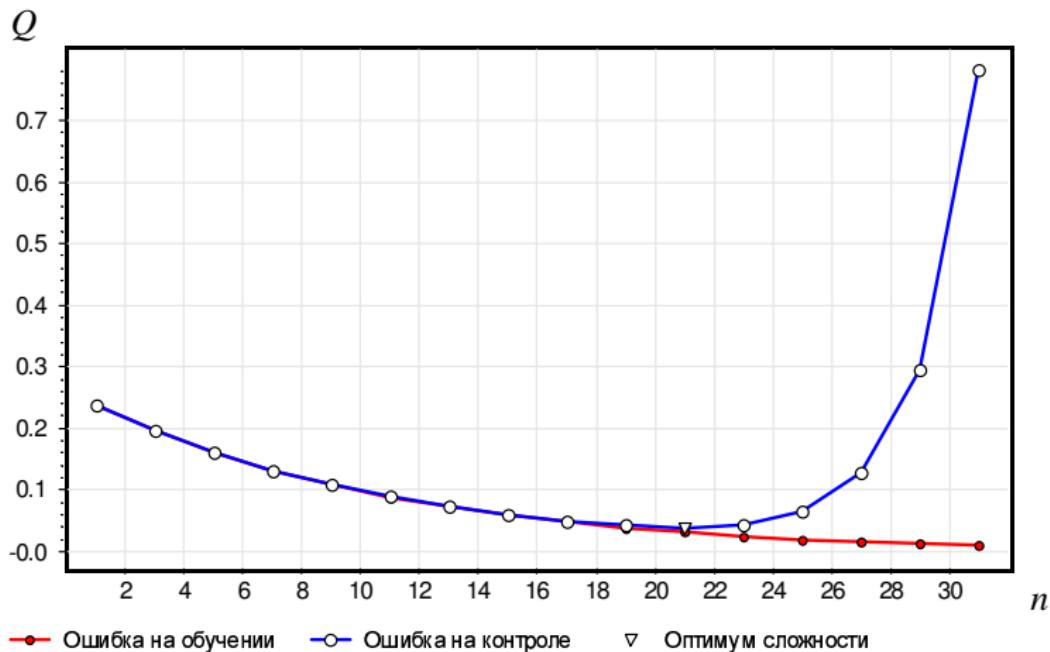
Пример переобучения: эксперимент при $\ell = 50$, $n = 38$

$$y(x) = \frac{1}{1 + 25x^2}; \quad a(x) — \text{полином степени } n = 38$$



Пример переобучения: эксперимент при $\ell = 50$, $n = 1, \dots, 31$

Переобучение — это когда $Q(\mu(X^\ell), X^k) \gg Q(\mu(X^\ell), X^\ell)$:



Эмпирические оценки обобщающей способности

Метод обучения μ по выборке $(x_i, y_i)_{i=1}^\ell$ строит алгоритм a .

- Среднее значение потерь на тестовых данных (hold-out):

$$\text{HO}(\mu, X^\ell, X^k) = Q(\mu(X^\ell), X^k) \rightarrow \min$$

- Скользящий контроль (leave-one-out), $L = \ell + 1$:

$$\text{LOO}(\mu, X^L) = \frac{1}{L} \sum_{i=1}^L \mathcal{L}(\mu(X^L \setminus \{x_i\}), x_i) \rightarrow \min$$

- Кросс-проверка (cross-validation) по N разбиениям, $X^L = X_n^\ell \sqcup X_n^k$, $L = \ell + k$:

$$\text{CV}(\mu, X^L) = \frac{1}{N} \sum_{n=1}^N Q(\mu(X_n^\ell), X_n^k) \rightarrow \min$$

Причины переобучения линейных моделей

- ➊ слишком мало объектов; слишком много признаков;
- ➋ линейная зависимость (мультиколлинеарность) признаков:
пусть построен классификатор: $a(x, w) = \text{sign}\langle x, w \rangle$;
мультиколлинеарность: $\exists v \in \mathbb{R}^n: \forall x \quad \langle x, v \rangle \approx 0$;
тогда $\forall \gamma \in \mathbb{R} \quad a(x, w) \approx \text{sign}\langle x, w + \gamma v \rangle$

Последствия:

- ➌ решение неединственно и неустойчиво;
- ➍ появляются слишком большие веса $+w_j$ или $-w_j$;
- ➎ $Q(w)$ на обучении много меньше, чем на контроле;

Спасает регуляризация — введение дополнительного критерия:

$$\|w\|^2 = \sum_{j=1}^n w_j^2 \rightarrow \min.$$

Метод сокращения весов (weight decay)

Штраф за увеличение нормы вектора весов:

$$Q_\tau(w) = Q(w) + \frac{\tau}{2} \sum_{j=1}^n w_j^2 \rightarrow \min_w .$$

Компоненты вектора градиента:

$$\frac{\partial}{\partial w_j} Q_\tau(w) = \frac{\partial}{\partial w_j} Q(w) + \tau w_j, \quad j = 1, \dots, n.$$

Модификация градиентного шага:

$$w_j^{t+1} := w_j^t (1 - h^t \tau) - h^t \frac{\partial}{\partial w_j} Q(w^t), \quad j = 1, \dots, n.$$

Параметр регуляризации τ подбирается экспериментально, по качеству на контрольной выборке.

Терминология, пришедшая из медицинской диагностики

Положительный диагноз — алгоритм предсказывает болезнь (хотя, казалось бы, что тут положительного...)

Доля больных с верным положительным диагнозом:

$$\text{чувствительность} = \frac{\sum_{i=1}^{\ell} [y_i = +1][a(x_i) = +1]}{\sum_{i=1}^{\ell} [y_i = +1]}$$

Доля здоровых с верным отрицательным диагнозом:

$$\text{специфичность} = \frac{\sum_{i=1}^{\ell} [y_i = -1][a(x_i) = -1]}{\sum_{i=1}^{\ell} [y_i = -1]}$$

Чувствительность и специфичность хотим максимизировать.

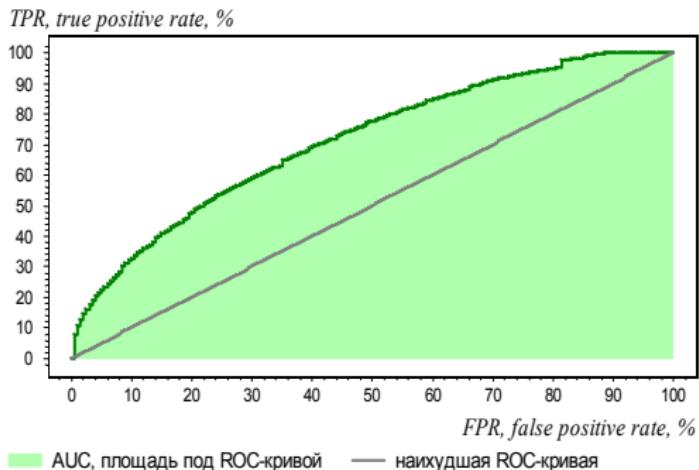
- ⊕ Они не зависят от соотношения мощностей классов.
- ⊕ Хорошо подходят для несбалансированных выборок.

Определение ROC-кривой

Модель классификации: $a(x) = \text{sign}(\langle x, w \rangle - w_0)$

по оси X: 1 – специфичность = FPR, false positive rate,
по оси Y: чувствительность = TPR, true positive rate

Каждая точка ROC-кривой соответствует значению порога w_0
(ROC – «receiver operating characteristic»),



AUC (area under curve) — площадь под ROC-кривой

Модель классификации: $a(x) = \text{sign}(\langle x, w \rangle - w_0)$

Доля правильно упорядоченных пар объектов (x_i, x_s) из разных классов, $y_i = -1$, $y_s = +1$ (докажите!):

$$\text{AUC} = \frac{\sum_{i=1}^{\ell} \sum_{s=1}^{\ell} [y_i < y_s] [\langle x_i, w \rangle < \langle x_s, w \rangle]}{\sum_{i=1}^{\ell} \sum_{s=1}^{\ell} [y_i < y_s]}$$

Преимущества AUC:

- ⊕ не зависит от порога w_0 , оценивает только качество w ;
- ⊕ не зависит от численности классов;
- ⊕ это общепринятая мера качества классификации;

Чтобы измерить предсказательную способность метода обучения μ , надо вычислять AUC на контрольной выборке.

Явная максимизация сглаженного AUC

Максимизация доли правильно упорядоченных пар (x_i, x_s) :

$$\text{AUC} = \sum_{i,s: y_i < y_s} [\langle x_i, w \rangle < \langle x_s, w \rangle] \rightarrow \max_w$$

Максимизация сглаженного AUC:

$$Q(w) = \sum_{i,s: y_i < y_s} \mathcal{L}(\underbrace{\langle x_s, w \rangle - \langle x_i, w \rangle}_{M_{is}}) \rightarrow \min_w$$

$\mathcal{L}(M)$ — гладкая убывающая функция отступа,

M_{is} — новое понятие отступа, теперь для пар объектов.

Метод стохастического градиента по парам (x_i, x_s) : $y_i < y_s$

$$w^{t+1} := w^t - h^t \mathcal{L}'(\langle x_s - x_i, w^t \rangle)(x_s - x_i)$$

Метод стохастического градиента для максимизации AUC

Вход: выборка $(x_i, y_i)_{i=1}^{\ell}$, $y_i \in \{-1, +1\}$, параметры h, τ ;

Выход: веса w_1, \dots, w_n ;

1 инициализировать веса $w_j = \frac{\langle y, f_j \rangle}{\langle f_j, f_j \rangle}$, $j = 1, \dots, n$;

2 **повторять**

3 выбрать случайную пару обучающих объектов x_i, x_s
 из разных классов: $y_i = -1$, $y_s = 1$;

4 выбрать величину градиентного шага h ;

5 выполнить градиентный шаг:

$$M_{is} := \langle x_s - x_i, w \rangle;$$

для всех $j = 1, \dots, n$

$$w_j := w_j(1 - \tau h) + h \mathcal{L}'(M_{is})(x_s^j - x_i^j);$$

6 **пока** процесс не сойдётся куда-нибудь;

Резюме

- Обучение — это оптимизация (почти во всех методах)
- Лучшие методы классификации основаны на сглаживании пороговой функции потерь
- Метод наименьших квадратов для линейной регрессии сводится к решению системы линейных уравнений $n \times n$
- Метод стохастического градиента позволяет единообразно решать самые разные задачи, в том числе для Big Data
- Регуляризация помогает против переобучения
- Можно максимизировать непосредственно AUC

Воронцов Константин Вячеславович

voron@forecsys.ru

www.MachineLearning.ru • Участник:Vokov

Если что-то было не понятно,
не стесняйтесь подходить и спрашивать :)