

# Линейные методы классификации

Виктор Китов  
v.v.kitov@yandex.ru

# Содержание

- 1 Геометрические основы линейной классификации
- 2 Оценка числа ошибок сверху
- 3 Метод стохастического градиента
- 4 Регуляризация
- 5 Логистическая регрессия

## Линейная дискриминантная функция

- Классификация среди двух классов  $\omega_1$  и  $\omega_2$ .
- Линейная дискриминантная функция:

$$y(x) = w^T x + w_0$$

- Решающее правило:

$$x \rightarrow \begin{cases} \omega_1, & y(x) \geq 0 \\ \omega_2, & y(x) < 0 \end{cases}$$

- Граница классов  $B = \{x : y(x) = 0\}$

## Свойства

- $x_A, x_B \in B \Rightarrow \begin{cases} y(x_A) = w^T x_A + w_0 = 0 \\ y(x_B) = w^T x_B + w_0 = 0 \end{cases} \Rightarrow$   
 $w^T(x_A - x_B) = 0$ , поэтому  $w \perp B$ .
- Расстояние от начала координат до  $B$  равно абсолютной величине проекции  $x \in B$  на  $\frac{w}{\|w\|}$ :

$$\left\langle x, \frac{w}{\|w\|} \right\rangle = \frac{\langle x, w \rangle}{\|w\|} = \{w^T x + w_0 = 0\} = -\frac{w_0}{\|w\|}$$

- Поэтому  $\rho(0, B) = \left| \frac{w_0}{\|w\|} \right|$ , и  $w_0$  определяет смещение.

## Расстояние от $x$ до $B$

Обозначим через  $x_{\perp}$  вектор проекции  $x$  на  $B$ , а  $r = \langle \frac{w}{\|w\|}, x - x_{\perp} \rangle$  - проекцию  $x$  на  $B$ :

$$x = x_{\perp} + r \frac{w}{\|w\|}$$

Умножим на  $w$  и прибавим  $w_0$ :


$$w^T x + w_0 = w^T x_{\perp} + w_0 + r \frac{\langle w, w \rangle}{\|w\|}$$

Используя  $w^T x + w_0 = y(x)$  и  $w^T x_{\perp} + w_0 = 0$ , получим:

$$r = \frac{y(x)}{\|w\|}$$

Следовательно, с одной стороны гиперплоскости  $r > 0 \Leftrightarrow y(x) > 0$ , а с другой  $r < 0 \Leftrightarrow y(x) < 0$ .

## Демонстрация



Линейное решающее правило:

$$\hat{c}(x) = \begin{cases} \omega_1, & y(x) > 0 \\ \omega_2, & y(x) < 0 \end{cases}$$

Граница классов:  $y(x) = 0$ ,

степень уверенности в классификации:  $|y(x)| / \|w\|$ .

# Содержание

- 1 Геометрические основы линейной классификации
- 2 Оценка числа ошибок сверху**
- 3 Метод стохастического градиента
- 4 Регуляризация
- 5 Логистическая регрессия

## Линейные дискриминантные функции

- Линейная дискриминантная функция:  $g(x) = w^T x + w_0$ ,

$$\hat{\omega} = \begin{cases} \omega_1, & g(x) \geq 0 \\ \omega_2, & g(x) < 0 \end{cases}$$

- Обозначим классы  $\omega_1$  и  $\omega_2$  через  $y = +1$  и  $y = -1$ .  
Решающее правило:  $y = \text{sign } g(x)$ .
- Определим дополнительный признак  $x_0 \equiv 1$ , тогда  $g(x) = w^T x = \langle w, x \rangle$  для  $w = [w_0, w_1, \dots, w_D]^T$ .
- Определим отступ  $M(x) = g(x)y$ 
  - $M(x) \geq 0 \iff$  объект  $x$  правильно классифицирован
  - $|M(x)|$  - уверенность классификатора в прогнозе

## Выбор весов

- Цель - оптимизация функции потерь:

$$Q_{\text{accurate}}(w|X) = \sum_i \mathbb{I}[M(x_i|w) < 0] \rightarrow \min_w$$


- Проблема: стандартные методы оптимизации неприменимы, т.к  $Q(w, X)$  разрывна.
- **Идея решения: аппроксимировать функцию цены сверху гладкой функцией  $\mathcal{L}$ :**

$$\mathbb{I}[M(x_i|w) < 0] \leq \mathcal{L}(M(x_i|w))$$

# Аппроксимация целевого критерия

Получаем аппроксимацию эмпирического риска сверху:

$$\begin{aligned}
 Q_{\text{accurate}}(w|X) &= \sum_i \mathbb{I}[M(x_i|w) < 0] \\
 &\leq \sum_i \mathcal{L}(M(x_i|w)) = Q_{\text{approx}}(w|X)
 \end{aligned}$$



$$\begin{aligned}
 Q(M) &= (1 - M)_+^2 \\
 V(M) &= (1 - M)_+ \\
 S(M) &= 2(1 + e^M)^{-1} \\
 L(M) &= \log_2(1 + e^{-M}) \\
 E(M) &= e^{-M}
 \end{aligned}$$

# Содержание

- 1 Геометрические основы линейной классификации
- 2 Оценка числа ошибок сверху
- 3 Метод стохастического градиента**
- 4 Регуляризация
- 5 Логистическая регрессия

# Оптимизация

- Оптимизационная задача для получения весов:

$$\begin{aligned}
 F(\mathbf{w}) &= Q_{approx}(\mathbf{w}|X, Y) = \sum_{i=1}^n \mathcal{L}(M(x_i, y_i|\mathbf{w})) \\
 &= \sum_{i=1}^n \mathcal{L}(\langle \mathbf{w}, \mathbf{x}_i \rangle y_i) \rightarrow \min_{\mathbf{w}}
 \end{aligned}$$

## Алгоритм градиентного спуска

### **ВХОД:**

$\eta$  – параметр, контролирующий скорость сходимости  
критерий остановки

### **АЛГОРИТМ:**


инициализировать  $w_0$  случайным образом

**пока** не выполнен критерий остановки:

$$\begin{aligned}
 w_{n+1} &\leftarrow w_n - \eta \frac{\partial F(w_n)}{\partial w} \\
 n &\leftarrow n + 1
 \end{aligned}$$

# Алгоритм градиентного спуска

- Критерии остановки:
  - $|w_{n+1} - w_n| < \varepsilon$
  - $|F(w_{n+1}) - F(w_n)| < \varepsilon$
  - $n > n_{max}$
- Субоптимальный метод минимизации в направлении наибольшего уменьшения  $F(w)$ :



## Ускорение сходимости

### Метод стохастического градиента

задать начальное приближение  $w_0$

рассчитать  $\hat{Q}_{approx} = \sum_{i=1}^n \mathcal{L}(M(x_i|w_0))$

итеративно, до сходимости  $\hat{Q}_{approx}$ :

- 1 выбрать случайное наблюдение  $(x_i, y_i)$
- 2 пересчитать веса:  $w_{n+1} \leftarrow w_n - \eta_n \mathcal{L}'(\langle w_n, x_i \rangle y_i) x_i y_i$
- 3 оценить ошибку:  $\varepsilon_i = \mathcal{L}(\langle w_{n+1}, x_i \rangle y_i)$
- 4 пересчитать оценку  $\hat{Q}_{approx} = (1 - \alpha) \hat{Q}_{approx} + \alpha \varepsilon_i$
- 5  $n \leftarrow n + 1$

## Выбор начальных весов

- $w_0 = w_1 = \dots = w_D = 0$
- Для логистической ф-ции  $\mathcal{L}$  (из-за асимптоты слева):
  - случайно на интервале  $[-\frac{1}{2D}, \frac{1}{2D}]$
- Для др. ф-ции:
  - случайно на произвольном интервале
- $w_i = \frac{\langle x^i, y \rangle}{\langle x^i, x^i \rangle}$

## Обсуждение метода

### Преимущества

- Легко реализовать
- Работает в online-режиме
- Небольшого подмножества обучающих объектов может быть достаточно для точной оценки

# Обсуждение метода

## Преимущества

- Легко реализовать
- Работает в online-режиме
- Небольшого подмножества обучающих объектов может быть достаточно для точной оценки

## Недостатки

- Субоптимальность - сходимость к локальному оптимуму
- Необходимость выбора  $\eta_n$ :
  - при слишком больших - расходимость
  - при слишком маленьких - медленная сходимость
- Возможно переобучение для больших  $D$  и малых  $N$
- для логистической аппроксимации (и всегда, когда  $\mathcal{L}(u)$  имеет горизонтальные асимптоты), алгоритм может «застрять» для больших значений  $\langle w, x_j \rangle$ .

## Примеры

Дельта-правило  $\mathcal{L}(M) = (M - 1)^2$

$$w \leftarrow w - \eta(\langle w, x_i \rangle - y_i)x_i$$

Это также подходит для регрессии и  $f(x) = \langle w, x \rangle$  для ф-ции цены  $(\langle w, x \rangle - y)^2$ ,  $y \in \mathbb{R}$

$\mathcal{L}(M) = [-M]_+$

Персептрон Розенблатта

$$w \leftarrow w + \begin{cases} 0, & \langle w, x_i \rangle y_i \geq 0 \\ \eta x_i y_i & \langle w, x_i \rangle y_i < 0 \end{cases}$$

Логичное правило, но не пытается расширить полосу разделения между классами.

# Содержание

- 1 Геометрические основы линейной классификации
- 2 Оценка числа ошибок сверху
- 3 Метод стохастического градиента
- 4 Регуляризация**
- 5 Логистическая регрессия

# Переобучение

- Ранняя остановка
  - остановка, когда качество перестает улучшаться
- Регуляризация
  - Штраф за большие веса:

$$Q_{approx}^{regularized}(w) = Q_{approx}(w) + \frac{\tau}{2}|w|^2$$

- Шаг градиентного спуска:  $w \leftarrow w(1 - \eta\tau) - \eta Q'_{approx}(w)$

## Регуляризация

- Удобный прием для контроля сложности модели:

$$Q^{regularized}(w) = Q(w) + \tau \|w\|_2^2$$

$$Q^{regularized}(w) = Q(w) + \tau \|w\|_1$$

$$\|w\|_1 = \sum_{d=1}^D |w^d|, \quad \|w\|_2 = \sqrt{\sum_{d=1}^D (w^d)^2}$$

- Регрессия, оцениваемая методом наименьших квадратов с регуляризацией:
  - $\tau \|w\|_1$  - LASSO
  - $\tau \|w\|_2^2$  - Ridge
  - $\alpha \|w\|_1 + \beta \|w\|_2$  - elastic net:

## $L_1$ норма

- $\|w\|_1$  регуляризация производит отбор признаков.
- Рассмотрим

$$Q(w) = \sum_{i=1}^N \mathcal{L}_i(w) + \lambda \sum_{d=1}^D |w_d|$$

- При  $\lambda > \sup_w \left| \frac{\partial \mathcal{L}(w)}{\partial w_i} \right|$  становится заведомо лучше положить  $w_i = 0$
- Для более высоких  $\lambda$  больше коэффициентов становятся равными нулю.

# Содержание

- 1 Геометрические основы линейной классификации
- 2 Оценка числа ошибок сверху
- 3 Метод стохастического градиента
- 4 Регуляризация
- 5 Логистическая регрессия**

## Логистическая регрессия

- Добавим в  $x$  константный признак и  $w_0$  к  $w$ .
- Сигмоидная функция активации  $\sigma(z) = \frac{1}{1+e^{-z}}$ .
- Двухклассовая классификация:

$$\text{score}(\omega_1|x) = w^T x$$

$$p(\omega_1|x) = \sigma(w^T x)$$

- Многоклассовая классификация:

$$\begin{cases} \text{score}(\omega_1|x) = w_1^T x \\ \text{score}(\omega_2|x) = w_2^T x \\ \dots \\ \text{score}(\omega_C|x) = w_C^T x \end{cases}$$

## Логистическая регрессия

Вероятности классов аппроксимируются через soft-max функцию:

$$p(\omega_c|x) = \frac{\exp(w_c^T x)}{\sum_i \exp(w_i^T x)}$$

$w_c$ ,  $c = 1, 2, \dots$  определены с точностью до сдвига на произвольный вектор  $v$ :

$$\frac{\exp((w_c - v)^T x)}{\sum_i \exp((w_i - v)^T x)} = \frac{\exp(-v^T x) \exp(w_c^T x)}{\sum_i \exp(-v^T x) \exp(w_i^T x)} = \frac{\exp(w_c^T x)}{\sum_i \exp(w_i^T x)}$$

Обычно сдвигают все  $w_c$  на  $v = w_C$ .

**Замечание:** нелинейное преобразование score в вероятность могло быть определено и по-другому - получили бы другой метод.

## Логистическая регрессия

- Пусть  $\gamma_1, \gamma_2$  - цены неправильной классификации классов  $\omega_1$  и  $\omega_2$ .
- Предположим

$$\ln \left( \frac{\gamma_1 p(\omega_1 | \mathbf{x})}{\gamma_2 p(\omega_2 | \mathbf{x})} \right) = \beta_0 + \beta^T \mathbf{x}$$

- это эквивалентно

$$p(\omega_2 | \mathbf{x}) = \frac{1}{1 + \exp(\beta'_0 + \beta^T \mathbf{x})}$$

$$p(\omega_1 | \mathbf{x}) = \frac{\exp(\beta'_0 + \beta^T \mathbf{x})}{1 + \exp(\beta'_0 + \beta^T \mathbf{x})}$$

- где  $\beta'_0 = \beta_0 - \ln(\gamma_1/\gamma_2)$

## Логистическая регрессия

Решающее правило (следуя Байесовскому правилу минимальной цены):

$$x = \begin{cases} \omega_1, & \beta'_0 + \beta^T \mathbf{x} > 0 \\ \omega_2, & \beta'_0 + \beta^T \mathbf{x} < 0 \end{cases}$$

Оценка  $\beta'_0, \beta$  методом максимального правдоподобия:

$$\prod_{i=1}^N p(c_i | x_i) \rightarrow \max_{\beta'_0, \beta}$$

где  $c_i$  - класс объекта  $x_i$ .

## Многоклассовая логистическая регрессия

- Предположение:

$$\ln \left( \frac{\gamma_s p(\omega_s | \mathbf{x})}{\gamma_C p(\omega_C | \mathbf{x})} \right) = \beta_{s0} + \beta_s^T \mathbf{x}, \quad s = 1, 2, \dots, C-1$$

- Вероятности классов (дающие эквивалентное определение):

$$p(\omega_s | \mathbf{x}) = \frac{\exp(\beta'_{s0} + \beta_s^T \mathbf{x})}{1 + \sum_{s=1}^{C-1} \exp(\beta'_{s0} + \beta_s^T \mathbf{x})}, \quad s = 1, 2, \dots, C-1$$

$$p(\omega_C | \mathbf{x}) = \frac{1}{1 + \sum_{s=1}^{C-1} \exp(\beta'_{s0} + \beta_s^T \mathbf{x})}$$

$$\beta'_{s0} = \beta_{s0} - \ln(\gamma_s / \gamma_C)$$

- Интерпретация: soft-max от дискриминатных функций (для классов  $\omega_1, \omega_2, \dots, \omega_{C-1}$ ) и константы (для класса  $\omega_C$ ).

## Многоклассовая логистическая регрессия

- Решающее правило (Байесовское правило минимальной ожидаемой цены):
- $c = \arg \max_c \beta_{c0} + \beta_c^T x$ , если  $\beta_{c0} + \beta_c^T x > 0$  иначе сопоставить  $x$  классу  $C$ .
- Оценивание методом максимального правдоподобия:

$$\prod_{i=1}^N p(c_i | x_i) \rightarrow \max_{\beta'_0, \beta}$$

## Функция цены


Для 2-х классов  $p(y|x) = \sigma(\langle w, x \rangle y)$ , где  $\sigma = \frac{1}{1+e^{-z}}$ ,  
 $w = [\beta'_0, \beta]$ ,  $x = [1, x_1, x_2, \dots, x_D]$ .

Оценка методом  
 максимального правдоподобия:

$$\prod_{i=1}^N \sigma(\langle w, x_i \rangle y_i) \rightarrow \max_w$$

эквивалентна

$$\sum_{i=1}^N \ln(1 + e^{-\langle w, x_i \rangle y_i}) \rightarrow \min_w$$



Следовательно, мажорирующая ф-ция для логистической регрессии  $\mathcal{L}(M) = \ln(1 + e^{-M})$ .