

# Линейные методы классификации I

Виктор Владимирович Китов  
v.v.kitov@yandex.ru

МГУ им.Ломоносова, ф-т ВМиК, кафедра ММП.

I семестр 2015 г.

# Содержание

## 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  $\rho(0, B) = \frac{|w_0|}{\|w\|}$ , 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:  $|y(x)| / \|w\|$ .

# Неоднозначность многоклассовой классификации

Предположим, нужно классифицировать среди 3х классов  $C_1, C_2, C_3$ .

Схема «один против всех»:





Схема «один против одного»:



## Подход «один против всех с весами»

- Классификация среди  $\omega_1, \omega_2, \dots, \omega_C$ .
- Используем  $C$  дискриминантных функций:

$$g_c(x) = w_c^T x + w_{c0}, \quad c = 1, 2, \dots, C.$$

- Решающее правило:

$$\hat{c}(x) = \arg \max_c g_c(x)$$

- Граница между классами  $\omega_i$  и  $\omega_j$  линейна:

$$(w_i - w_j)^T x + (w_{i0} - w_{j0}) = 0$$

## Выпуклость областей прогнозируемых классов

Области прогнозируемых классов выпуклы.

**Доказательство:** Допустим  $\hat{c}(x_A) = \hat{c}(x_B) = c$ ,  $c = 1, 2, \dots, C$ , что по определению означает

$$w_c^T x_A + w_{c0} \geq w_k^T x + w_{k0} \quad \forall k \neq c \quad (1)$$

$$w_c^T x_B + w_{c0} \geq w_k^T x + w_{k0} \quad \forall k \neq c \quad (2)$$

Для  $\lambda x_A + (1 - \lambda)x_B$ ,  $\lambda \in (0, 1)$  суммируя (1) и (2) с весами  $\lambda$  и  $(1 - \lambda)$ , получим:

$$w_c^T (\lambda x_A + (1 - \lambda)x_B) + w_{c0} \geq w_k^T (\lambda x_A + (1 - \lambda)x_B) + w_{k0} \quad \forall k \neq c$$

что означает, что прогноз  $\hat{c}(\lambda x_A + (1 - \lambda)x_B) = c$ , и область каждого класса  $c = 1, 2, \dots, C$  выпукла.

# Содержание

## 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

# 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:

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

# 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.

## Рекомендации к использованию

- Сходимость быстрее для нормализованных признаков
  - нормализация частично решает проблему «вытянутых долин»



- для  $\mathcal{L}$  с левыми горизонтальными асимптотами:  $\langle w, x_i \rangle y_i$  ограничено на начальных итерациях, и метод не «застревает»

## Рекомендации к использованию

- Быстрее сходимость, когда больше совершается ошибок:
  - сэмплировать наблюдения с вероятностями, пропорциональными  $\varepsilon_i = \mathcal{L}(\langle w, x_i \rangle y_i)$ 
    - ускорение вычислений: пересчитывать  $w$  (и связанные  $\mathcal{L}(\langle w, x_i \rangle y_i)$ ) только когда  $\varepsilon_i \geq \delta$  для некоторого порога  $\delta > 0$ .
  - повышать разнообразие сэмплируемых объектов
    - например, за счет целенаправленного сэмплирования из разных классов
- Локальный оптимум совпадает с глобальным для выпуклой  $\mathcal{L}(w|x, y)$ 
  - для невыпуклого случая нужно запускать процедуру для различных начальных приближений и выбрать решение, дающее минимальное значение  $Q_{approx}(w|X, Y)$

## Выбор $\eta$

- Больше  $\eta \Rightarrow$  больше риск, что алгоритм будет расходиться.
- Тест для контроля сходимости: смотреть динамику  $Q_{approx}(w)$  (или  $\hat{Q}_{approx}(w)$ ) от номера итерации  $t$ .
- Тип  $\eta$ :
  - $\eta_t = \eta = const$
  - веса, изменяющиеся по фиксированному правилу:
    - условия сходимости метода:
      - 1  $\eta_t \rightarrow 0$
      - 2  $\sum_{t=1}^{\infty} \eta_t = \infty$
      - 3  $\sum_{t=1}^{\infty} \eta_t^2 < \infty$
  - Пример:  $\eta_t = \frac{1}{t}$

# Выбор

- Шаг, зависимый от данных:

- На каждом шаге  $\eta_t = \arg \min_{\eta} Q_{approx}(\mathbf{w} - \eta \frac{\partial Q_{approx}}{\partial \mathbf{w}})$
- Часто существует аналитическое решение для  $\eta$

# Содержание

# Оценка методом максимального правдоподобия

- $X = \{x_1, x_2, \dots, x_n\}$ ,  $Y = \{y_1, y_2, \dots, y_n\}$  - обучающая выборка,  
 $(x_i, y_i) \sim p(y|x, w)$
- Оценка максимального правдоподобия  $\hat{w} = \arg \max_w p(Y|X, w)$
- Используя предположение о независимости  $y_i|x_i$   $i = 1, 2, \dots, N$ :

$$\prod_{i=1}^N p(y_i|x_i, w) = \sum_{i=1}^N \ln p(y_i|x_i, w) \rightarrow \max_w$$

- Оптимизация цены:

$$\sum_{i=1}^n \mathcal{L}(g(x_i)y_i|w) \rightarrow \min_w$$

- Взаимосвязь двух методов:

$$\mathcal{L}(g(x_i)y_i|w) = -\ln p(y_i|x_i, w)$$

## Максимальная апостериорная вероятность

- $X = \{x_1, x_2, \dots, x_N\}$ ,  $Y = \{y_1, y_2, \dots, y_N\}$  - обучающая выборка из н.о.р.  
 $(x_i, y_i) \sim p(x, y|w)$
- $w$  - не константа, а с.в.  $w \sim p(w)$
- Поскольку

$$p(w|X, Y) = \frac{p(X, Y, w)}{p(X, Y)} = \frac{p(X, Y|w)p(w)}{p(X, Y)} \propto p(X, Y|w)p(w)$$

то справедлива оценка *максимизации апостериорной вероятности*:

$$w = \arg \max_w p(w|X, Y) = \arg \max_w p(X, Y|w)p(w)$$

$$\sum_{i=1}^n \ln p(x_i, y_i|\theta) + \ln p(w) \rightarrow \max_w$$

$\ln p(w)$  соответствует регуляризации.

## Варианты априорных вероятностей

- Нормальное распределение

$$\ln p(\mathbf{w}, \sigma^2) = \ln \left( \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{\|\mathbf{w}\|_2^2}{2\sigma^2}} \right) = -\frac{1}{2\sigma^2} \|\mathbf{w}\|_2^2 + \text{const}$$

- Распределение Лапласа

$$\ln p(\mathbf{w}, C) = \ln \left( \frac{1}{(2C)^n} e^{-\frac{\|\mathbf{w}\|_1}{C}} \right) = -\frac{1}{C} \|\mathbf{w}\|_1 + \text{const}$$

# Содержание

# 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:

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

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

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

- Регрессия, оцениваемая методом наименьших квадратов с регуляризацией:
  - $\tau \|w\|_1$  - LASSO
  - $\tau \|w\|_2$  - 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 зануляются.