

**МАШИННОЕ ОБУЧЕНИЕ
И АНАЛИЗ ДАННЫХ
(Machine Learning and Data Mining)**

Н. Ю. Золотых

<http://www.uic.unn.ru/~zny/ml>

Лекция 9

Логистическая регрессия

9.1. Определения

(Дискриминантный метод)

Рассмотрим задачу классификации на 2 класса: $\mathcal{Y} = \{0, 1\}$


Пусть

$$\Pr(Y = 1 | X = x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_d x_d)}} = \sigma(\beta_0 + \beta^\top x),$$

где

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

— логистическая функция (элементарный сигмоид или логит-функция)



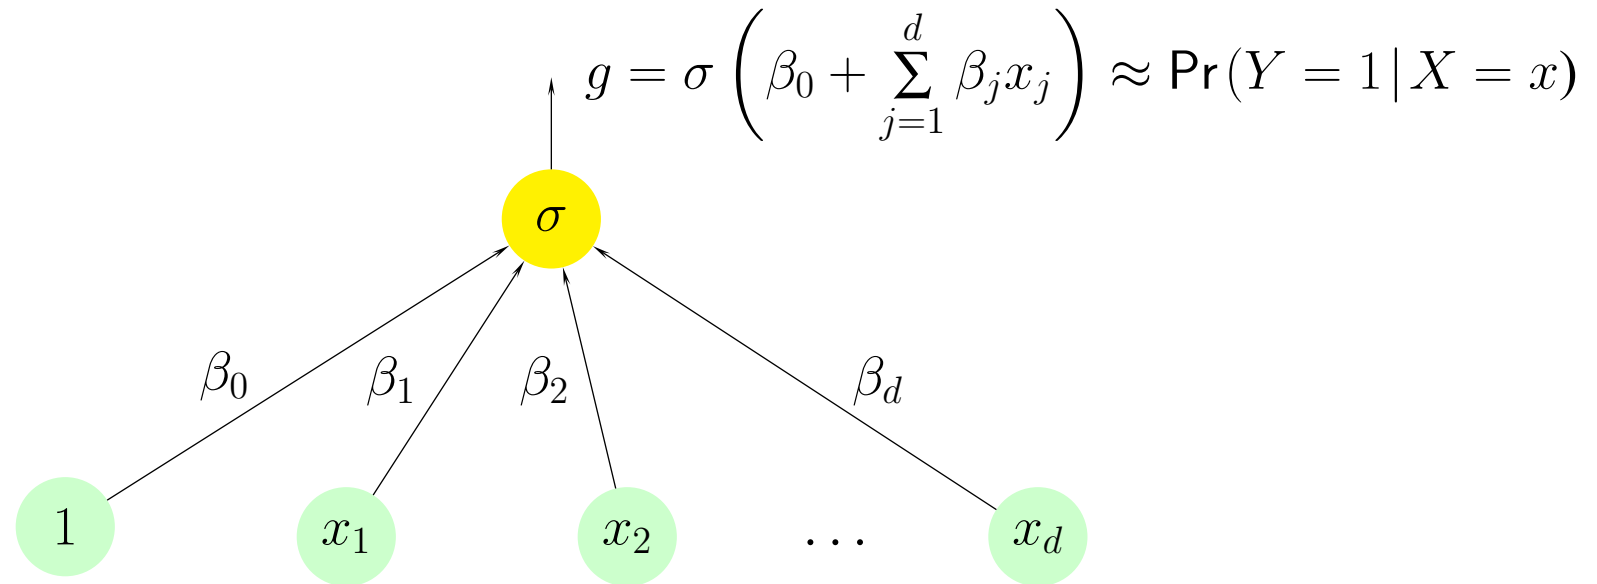
$$\Pr(Y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_d x_d)}} = \sigma(\beta_0 + \beta^\top x),$$

тогда


$$\Pr(Y = 0 | x) = 1 - \Pr(Y = 1 | x) = \frac{1}{1 + e^{\beta_0 + \beta_1 x_1 + \dots + \beta_d x_d}} = \sigma(-\beta_0 - \beta^\top x),$$

Разделяющая поверхность — линейная (гиперплоскость):

$$\Pr(Y = 0 | x) = \Pr(Y = 1 | x) = \frac{1}{2} \quad \Leftrightarrow \quad \beta_0 + \beta_1 x_1 + \dots + \beta_d x_d = 0$$



Случай K классов: $\mathcal{Y} = \{1, 2, \dots, K\}$. Функция softmax:



$$g_k = \frac{\exp\left(\beta_{k0} + \sum_{j=1}^d \beta_{kj}x_j\right)}{\sum_{\ell=1}^K \exp\left(\beta_{\ell 0} + \sum_{j=1}^d \beta_{\ell j}x_j\right)} \approx \Pr(k|x)$$

$(k = 1, 2, \dots, K)$

Разделяющие поверхности (между каждой парой классов) снова линейные:

$$\Pr(Y = k | X = x) = \Pr(Y = k' | X = x) \Leftrightarrow \beta_{k0} + \beta_k^T x = \beta_{k'0} + \beta_{k'}^T x$$

Замечание 9.1 Можно преобразовать и переобозначить:

$$\Pr(Y = k | X = x) = \frac{e^{\beta_{k0} + \beta_k^T x}}{1 + \sum_{\ell=1}^{K-1} e^{\beta_{\ell 0} + \beta_{\ell}^T x}} \quad (k = 1, 2, \dots, K - 1),$$

$$\Pr(Y = K | X = x) = \frac{1}{1 + \sum_{\ell=1}^{K-1} e^{\beta_{\ell 0} + \beta_{\ell}^T x}}$$

9.1.1. Расчет параметров

Как найти $\beta_{10}, \beta_1, \beta_{20}, \beta_2, \dots, \beta_{K0}, \beta_K$?

В логистической регрессии параметры обычно подбираются с помощью метода максимального правдоподобия.

Максимизации подвергается логарифмическая функция правдоподобия

$$\ell(\beta) = \sum_{i=1}^N \ln \Pr \left\{ Y = y^{(i)} \mid X = x^{(i)}, \beta \right\} \rightarrow \max,$$

где

$$\beta = (\beta_{10}, \beta_1, \beta_{20}, \beta_2, \dots, \beta_{K-1,0}, \beta_{K-1}), \quad \Pr(Y = k \mid X = x, \beta) = \Pr(Y = k \mid X = x).$$

Возможна регуляризация:

$$\sum_{i=1}^N \ln \Pr \left\{ Y = y^{(i)} \mid X = x^{(i)}, \beta \right\} - \lambda \|\beta\|^2 \rightarrow \max$$

где вместо квадрата евклидовой нормы можно рассматривать 1-норму $\|\beta\|_1$

Вначале рассмотрим случай $K = 2$: $\mathcal{Y} = \{0, 1\}$.

$$g(x, \beta) = \Pr \{Y = 1 | X = x, \beta\} = \frac{1}{1 + e^{-\beta_0 - \beta^\top x}}.$$

Требуется максимизировать логарифмическую функцию правдоподобия

$$\ell(\beta) = \sum_{i=1}^N \left(y^{(i)} \ln g(x^{(i)}, \beta) + (1 - y^{(i)}) \ln(1 - g(x^{(i)}, \beta)) \right).$$

Упражнение 9.2 Докажите, что

$$\frac{\partial \ell(\beta)}{\partial \beta_0} = \sum_{i=1}^N \left(y^{(i)} - g(x^{(i)}, \beta) \right), \quad \frac{\partial \ell(\beta)}{\partial \beta_j} = \sum_{i=1}^N \left(y^{(i)} - g(x^{(i)}, \beta) \right) x_j^{(i)}.$$

Теперь можем воспользоваться методом градиентного спуска или более продвинутым методом оптимизации (сопряженных градиентов, BFGS, L-BFGS и др.).

Теперь рассмотрим случай $\mathcal{Y} = \{1, 2, \dots, K\}$.

$$g(x, \beta) = \Pr \{Y = k | X = x, \beta\} = \frac{e^{\beta_{k0} + \beta_k^\top x}}{\sum_{\ell=1}^K e^{\beta_{\ell 0} + \beta_\ell^\top x}}.$$

Требуется максимизировать логарифмическую функцию правдоподобия

$$\ell(\beta) = \sum_{i=1}^N \sum_{k=1}^K I(y^{(i)} = k) \ln g_k(x^{(i)}, \beta) = \sum_{i=1}^N \sum_{k=1}^K I(y^{(i)} = k) \left(\beta_{k0} + \beta_k^\top x^{(i)} - \ln \sum_{\ell=1}^K e^{\beta_{\ell 0} + \beta_\ell^\top x^{(i)}} \right).$$

Упражнение 9.3 Докажите, что

$$\frac{\partial \ell(\beta)}{\partial \beta_{k0}} = \sum_{i=1}^N \left(I(y^{(i)} = k) - g(x^{(i)}, \beta) \right), \quad \frac{\partial \ell(\beta)}{\partial \beta_k} = \sum_{i=1}^N x^{(i)} \left(I(y^{(i)} = k) - g(x^{(i)}, \beta) \right).$$

Замечание 9.4 Легко видеть, что максимизация логарифмической функции правдоподобия эквивалентна минимизации эмпирического риска

$$\widehat{R}(\beta) = -\frac{1}{N}\ell(\beta) = -\frac{1}{N}\sum_{i=1}^N \left(y^{(i)} \ln g(x^{(i)}, \beta) + (1 - y^{(i)}) \ln(1 - g(x^{(i)}, \beta)) \right),$$

если в качестве штрафной функции рассмотреть *кросс-энтропию* (или *logloss-функцию*):

$$L(g(x, \beta), y) = -y \ln g(x, \beta) - (1 - y) \ln(1 - g(x, \beta)).$$

Аналогично для случая K классов:

$$\widehat{R}(\beta) = -\frac{1}{N}\ell(\beta) = -\frac{1}{N}\sum_{i=1}^N \sum_{k=1}^K I(y^{(i)} = k) \ln g_k(x^{(i)}, \beta),$$

если в качестве штрафной функции рассмотреть *кросс-энтропию* (или *logloss-функцию*):

$$L(g(x, \beta), y) = -\sum_{k=1}^K I(y = k) \ln g_k(x, \beta).$$

9.1.2. Регуляризация


В L_2 норме:

$$-\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K I(y^{(i)} = k) \ln g(x^{(i)}, \beta) + \lambda \|\beta\|_2 \rightarrow \min,$$


В L_1 норме:

$$-\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K I(y^{(i)} = k) \ln g(x^{(i)}, \beta) + \lambda \|\beta\|_1 \rightarrow \min,$$

Без регуляризации, если классы линейно отделимы: $\beta \rightarrow -\infty$



Логистическая регрессия



Логистическая регрессия с признаками x_1 , x_2 , x_1^2 , x_1x_2 , x_2^2

