

Логаритмична регресия

Доц. д-р Ивайло Пенев

Кат. „Компютърни науки и технологии“

Функция на хипотезата


$$h_{\theta}(x) = g(\theta^T x) = \frac{1}{1 + e^{-\theta^T x}}$$

Функция на цената


- $J(\theta) = \frac{1}{m} \sum_{i=1}^m \text{Cost}(h_{\theta}(x^{(i)}, y^{(i)}))$, където
- $\text{Cost}(h_{\theta}(x^{(i)}, y^{(i)})) = -\log(h_{\theta}(x))$ за $y = 1$
- $\text{Cost}(h_{\theta}(x^{(i)}, y^{(i)})) = -\log(1 - h_{\theta}(x))$ за $y = 0$

Графично представяне на $J(\theta)$

При $y=1$



При $y=0$



Обяснение

- $Cost(h_\theta(x), y) = 0$, ако $h_\theta(x) = y$
- $Cost(h_\theta(x), y) \rightarrow \infty$, ако $y = 0$ и $h_\theta(x) \rightarrow 1$
- $Cost(h_\theta(x), y) \rightarrow \infty$, ако $y = 1$ и $h_\theta(x) \rightarrow 0$
- Ако при обучението коректният резултат е $y = 0$, то цената ще бъде 0 при $h_\theta(x)=0$ (т.е. при прогноза 0). Ако прогнозата е по-голяма от 0, то цената ще се увеличава ($Cost(h_\theta(x), y) \rightarrow \infty$)
- Ако при обучението коректният резултат е $y = 1$, то цената ще бъде 0 при $h_\theta(x)=1$ (т.е. при прогноза 1). Ако прогнозата е по-малка от 1, то цената ще се увеличава ($Cost(h_\theta(x), y) \rightarrow \infty$)

Контролен въпрос

В логаритмичната регресия функцията на цената има следният вид:

- $Cost(h_\theta(x), y) = -\log(h_\theta(x))$ за $y = 1$
- $Cost(h_\theta(x), y) = -\log(1 - h_\theta(x))$ за $y = 0$

Отбележете **ВСИЧКИ** верни отговори:

- а) Ако $h_\theta(x) = y$, то $cost(h_\theta(x), y) = 0$ за $y=0$ и $y=1$
- б) Ако $y=0$, то $cost(h_\theta(x), y) \rightarrow \infty$ при $h_\theta(x) \rightarrow 1$
- в) Ако $y=0$, то $cost(h_\theta(x), y) \rightarrow \infty$ при $h_\theta(x) \rightarrow 0$
- г) Ако $h_\theta(x) = 0.5$, то $cost(h_\theta(x), y) > 0$ за $y=0$ и $y=1$

Опростена функция на цената

- Двамата случая на ф-та на цената (за $y=0$ и $y=1$) могат да бъдат обединени:

$$Cost(h_{\theta}(x), y) = -y \log(h_{\theta}(x)) - (1 - y) \log(1 - h_{\theta}(x))$$

- При $y=1 \Rightarrow Cost(h_{\theta}(x), y) = -y \log(h_{\theta}(x))$
- При $y=0 \Rightarrow Cost(h_{\theta}(x), y) = (1 - y) \log(1 - h_{\theta}(x))$
- Следователно ф-та на цената може да се представи:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m [y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)}))]]$$

Векторна форма на функцията на цената

Ако ϕ -та на цената за всички обучителни примери е:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m [y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)}))]$$

, то във векторна форма ϕ -та може да се запише така:

$$h = g(X\theta)$$

$$J(\theta) = \frac{1}{m} \cdot (-y^T \log(h) - (1 - y)^T \log(1 - h))$$

Градиентно спускане

- Общ вид:

Повтаряй:

{

$$\theta_j = \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta)$$

}

- След диференцирането на $J(\theta)$ се получава:

Повтаряй:

{

$$\theta_j = \theta_j - \frac{\alpha}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) x_j^{(i)}$$

}

Контролен въпрос

Прилагаме градиентно спускане в логаритмична регресия за намиране на стойностите на параметрите θ . Как ще проверим дали сме избрали подходяща стойност на скоростта на обучение α и дали градиентното спускане работи правилно?

а) Чертаем графиката на ф-та $J(\theta) = \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$, като по абсцисната ос нанасяме броя на итерациите. Проверяваме дали стойността на $J(\theta)$ намалява на всяка следваща итерация

б) Чертаем графиката на ф-та $J(\theta) = -\frac{1}{m} \sum_{i=1}^m [y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 -$

Контролен въпрос

При градиентно спускане на всяка итерация се изпълняват следните операции:

$$\theta_0 = \theta_0 - \frac{\alpha}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})x_0^{(i)}$$

$$\theta_1 = \theta_1 - \frac{\alpha}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})x_1^{(i)}$$

.

.

.

$$\theta_n = \theta_n - \frac{\alpha}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})x_n^{(i)}$$

Искаме да направим векторна реализация на алгоритъма във вида $\theta = \theta - \alpha\beta$, където β е вектор. Изберете правилния вариант на векторната имплементация:

а) $\theta = \theta - \alpha \frac{1}{m} \sum_{i=1}^m [(h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x^{(i)}]$

б) $\theta = \theta - \alpha \frac{1}{m} [\sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})] \cdot x^{(i)}$

в) $\theta = \theta - \alpha \frac{1}{m} x^{(i)} [\sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})]$

г) Всички изброени

Векторна форма на градиентното спускане

$$\theta := \theta - \frac{\alpha}{m} X^T (g(X\theta) - \vec{y})$$

Класификация за множество класове

- Обобщаваме класификационната задача за случаи, в които имаме повече от две възможности за y , т.е. вместо $y = \{0,1\}$ възможните изходи са $y = \{0,1, \dots, n\}$
- Можем да разделим задачата на $n + 1$ бинарни класификационни задачи, във всяка от които предсказваме вероятността y да принадлежи на всеки от n класа, т.е.:

$$y = \{0,1, \dots, n\}$$

$$h_{\theta}^{(0)}(x) = P(y = 0 | x; \theta)$$

$$h_{\theta}^{(1)}(x) = P(y = 1 | x; \theta)$$

...

$$h_{\theta}^{(n)}(x) = P(y = n | x; \theta)$$


$$\text{Резултат} = \max_i (h_{\theta}^{(i)}(x))$$

Алгоритъм

- Първоначална избираме един клас, а всички останали отделяме в друг клас. Решаваме бинарна класификационна задача. Повтаряме това за всеки възможен клас. Накрая избираме прогнозата с най-висока вероятност.

Пример за класификация с 3 възможни класа

One-vs-all (one-vs-rest):

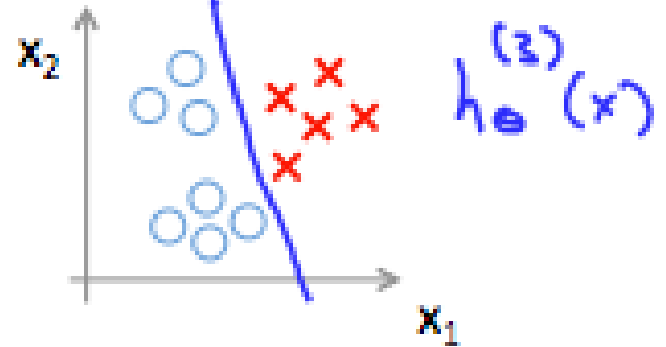

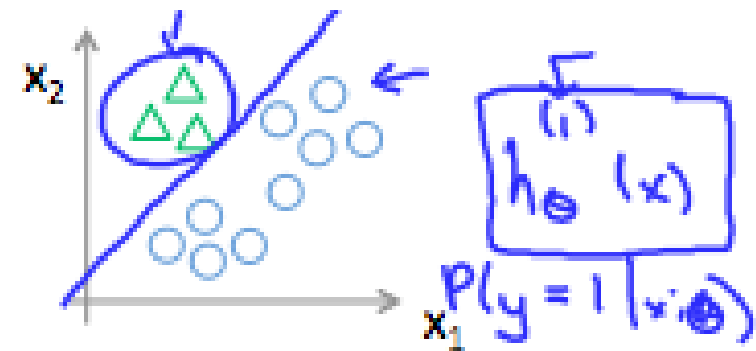


Class 1: \triangle ←

Class 2: \square ←

Class 3: \times ←

$$h_{\theta}^{(i)}(x) = P(y = i | x; \theta) \quad (i = 1, 2, 3)$$



Обобщение

- Обучаваме хипотеза с логаритмична регресия (логаритмичен класификатор) $h_{\theta}(x)$ за всеки възможен клас i – определяме вероятността за $y=i$
- За да определим към кой клас принадлежи неизвестна променлива x , избираме класа с максимална $h_{\theta}(x)$