

# Линейна регресия с множество променливи

Доц. д-р Ивайло Пенев

Кат. „Компютърни науки и технологии“

# Понятия и означения

- Линейна регресия с множество променливи – многовариантна линейна регресия (multivariate linear regression)
- $x_j^{(i)}$  - стойност на променливата  $j$  в ред  $i$  от обучителните данни
- $x^{(i)}$  - вектор колона с всички променливи в ред  $i$  от обучителните данни
- $m$  – брой обучителни данни (training examples)
- $n = |x^{(i)}|$  - брой променливи

# Функция на хипотезата (Hypothesis function)

$$h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_3 + \dots + \theta_n x_n$$

- Пример:

- $\theta_0$  - базова цена на къща
- $\theta_1$  - цена на  $m^2$
- $\theta_2$  - цена на етаж
- ...
- $x_1$  - площ на къщата ( $m^2$ )
- $x_2$  - брой етажи
- ...

# Векторно представяне на функцията

- Векторизация на функцията на хипотезата за един обучителен пример (training example)

$$h_{\theta}(x) = [\theta_0 \quad \theta_1 \quad \dots \quad \theta_n] \begin{bmatrix} x_0 \\ x_1 \\ \dots \\ x_n \end{bmatrix} = \theta^T x$$

- За удобство приемаме, че  $x_0^{(i)} = 1$  за  $(i \in 1, \dots, m)$  – така векторите  $\theta$  и  $x$  имат еднаква размерност

# Матрично представяне на обучителните данни

- $X = \begin{bmatrix} x_0^{(1)} & x_1^{(1)} \\ x_0^{(2)} & x_1^{(2)} \\ x_0^{(3)} & x_1^{(3)} \end{bmatrix}$  - матрица с обучителни данни
- $\theta = \begin{bmatrix} \theta_0 \\ \theta_1 \end{bmatrix}$  - вектор с параметри (коефициенти) на функцията
- Функцията на хипотезата се изчислява като вектор  $m \times 1$ :

$$h_{\theta}(x) = X\theta$$

# Функция на цената (Cost function)

- За вектор с параметри  $\theta$  ф-та на цената е:

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$$

- Векторна форма на ф-та:

$$J(\theta) = \frac{1}{2m} (X\theta - \vec{y})^T (X\theta - \vec{y})$$

- $\vec{y}$  - вектор с всички стойности  $y$

# Градиентно спускане за множество променливи (Gradient Descent)

- За линейна регресия с множество променливи градиентното спускане има следният вид:  
Повтаряй до достигане на минимум на  $\phi$ -та на цената  $J(\theta)$

{

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

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

$$\theta_2 := \theta_2 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) x_2^{(i)}$$

...

}

# Обобщен вид на градиентното спускане

Повтаряй до достигане на минимум на  $\phi$ -та на цената  $J(\theta)$

{

$$\theta_j := \theta_j - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) x_j^{(i)} \text{ за } j = 0, 1, 2, \dots, n$$

}



# Векторна форма на градиентното спускане

- $\theta = \theta - \alpha \nabla J(\theta)$ , където

$$\nabla J(\theta) = \begin{bmatrix} \frac{\partial J(\theta)}{\partial \theta_0} \\ \frac{\partial J(\theta)}{\partial \theta_1} \\ \dots \\ \frac{\partial J(\theta)}{\partial \theta_n} \end{bmatrix} \text{ - вектор колона}$$

# Векторно представяне на градиента $\nabla J(\theta)$

- Компонент  $j$  на вектора  $\nabla J(\theta)$  има следният вид:

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

- $x_j^{(i)} = \vec{x}_j$  - вектор с  $m$  елемента за променливата  $x_j$
- $(h_{\theta}(x^{(i)}) - y^{(i)})$  - вектор с отклонения на предсказаната стойност  $h_{\theta}(x^{(i)})$  и коректната стойност  $y^{(i)}$
- $\vec{y}$  - вектор с коректни стойности
- $X$  - вектор с обучителни данни (training set)

$$\frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \vec{x}_j^T (X\theta - \vec{y})$$

$$\nabla J(\theta) = \frac{1}{m} X^T (X\theta - \vec{y})$$

# Векторна форма на градиентното спускане

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