

Машинно обучение  
Лабораторно упражнение 6  
Логаритмична регресия. Регуляризация

Целта на упражнението е да се реализира логаритмична регресия в класификационна задача както и да се демонстрира използването на регуляризация за получаване на адекватна хипотеза (модел).

## I. Логаритмична регресия без регуляризация


Като пример ще използваме следната задача:

Разполагаме с данни за оценки на кандидат-студенти от два изпита (резултатите са в брой точки). Решението дали студентът ще бъде приет в университета или не се взема от комисия. В обучителните данни за всеки студент имаме резултат 1 (приет в университета) или 0 (не е приет). Ще построим хипотеза, която предсказва дали студент ще бъде приет на базата на дадени оценки от двата изпита.

Обучителните данни са във файла grades.txt, а Python кодът на скрипта е в lab6.py.

### 1. Визуализиране на обучителните данни

Задача 1. Визуализирайте обучителните данни в следната графика (фиг. 1):



Фиг. 1. Визуализиране на обучителните данни

### 2. Сигмоидна функция

В логаритмичната регресия хипотезата има следният вид:

$$h_{\theta}(x) = g(\theta^T x)$$

, където  $g$  се нарича сигмоидна функция със следната дефиниция:

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

, където:

$z = \theta^T x$  – параметър на сигмоидната функция

$e$  – неперово число ( $e \cong 2,72$ ).

**За всяка стойност на параметъра  $z$ ,  $0 \leq g(z) \leq 1$ .**

Задача 2. Довършете функцията  $\text{sigmoid}(z)$ , която изчислява стойност на сигмоидна функция с параметър  $z$ .

### 3. Функция на цената (cost function)

Функцията на цената в логаритмичната регресия с изчислява по следния начин:

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

, където

$J(\theta)$  – функцията на цената с параметри вектор  $\theta$

$m$  – брой входни данни

$x^{(i)}$  – входните данни (за оценки от два изпита)

$y^{(i)}$  – изходни стойности (1 – приет, 0 – не е приет)

$\log$  – функция логаритъм (с основа числото  $e$ )

Задача 3. Довършете функцията  $\text{costFunction}(\theta, X, y)$ , която изчислява цената за  $\theta$ ,  $X$  и  $y$ .

Резултат:

Cost:

0.69314718056

### 4. Градиент на цената

Градиентът на цената представлява вектор със същата размерност като вектора  $\theta$ , като стойността на елемент  $j$  (за  $j=0,1,2,\dots,n$ ) се изчислява по следния начин:

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

**Обърнете внимание, че градиентът се изчислява по същия начин както и при линейната регресия. Разликата е, че хипотезата  $h_{\theta}$  е различна, защото линейната и логаритмичната регресия имат различни дефиниции за  $h_{\theta}(x)$ .**

Задача 4. Довършете функцията `gradient(theta, X, y)` за изчисляване на цената на градиента.

Резултат:

Grad:

`[-0.1 -12.00921659 -11.26284221]`

#### 5. Намиране на минимум на функцията на цената

В предишните упражнения реализирахме градиентно спускане за намиране на стойности на параметрите  $\theta$ , при които функцията на цената  $J$  има минимална стойност. В това упражнение ще използваме функцията `minimize` от библиотеката `scipy.optimize`. Извикваме функцията по следния начин:

```
res = minimize(costFunction, initial_theta, args=(X,y), method=None, jac=gradient, options={'maxiter':400})
```

Тази функция намира минимум на  $\phi$ -та `costFunction` и съответните стойности на параметрите `initial_theta`.

**Наблюдавайте резултата от изпълнението на тази функция в променливата `res`. Търсените стойности на параметрите са в `res.x`:**

**`-25.1613, 0.206232, 0.201472`**

#### 6. Оценяване на построената хипотеза

За да проверим построената хипотеза за логаритмична регресия, ще проверим каква е вероятността за приемане на студент с оценка 1 – 45 точки и оценка 2 – 87 точки.

Задача 5. Да се изчисли вероятността за приемане на студент с оценка 1 – 45 точки и оценка 2 – 87 точки.

Резултат:

0.776

Как се обяснява този резултат?

## II. Логаритмична регресия с регуляризация

Регуляризацията е метод за предотвратяване на един от най-важните проблеми в машинното обучение - т.нар. припокриване (overfitting). Този проблем се изразява в точно (или почти точно) съвпадение на построената хипотеза с обучителните данни (т.е. точност близка до 100%). Това трябва да бъде предотвратено, защото ще доведе до големи отклонения при прилагане на хипотезата за нови (т.е. неизвестни при обучението) данни.

Разполагаме с данни за тестове на електронни чипове. В обучителните данни за всеки чип имаме резултат от изпитване 1, изпитване 2 и решение дали чипът е дефектен (1) или не е дефектен (0). Ще построим хипотеза, която предсказва дали чип ще бъде определен за годен на базата на резултатите от тест.

Обучителните данни са във файла chip\_data.txt, а Python кодът на скрипта е в lab6\_Regularization.py.

Регуляризацията се изразява в добавяне на нов терм, съдържащ параметър  $\lambda$  - параметър на регуляризацията. Целта е да се увеличи значението на параметрите  $\theta_j$ , което съответно намалява значението на променливите  $x_j$ .

1. Регуляризирана функция на цената

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m [y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)}))] + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2$$

Векторна форма на регуляризираната функция на цената

$$J(\theta) = \frac{1}{m} \left( (\log(g(X\theta)))^T y + (\log(1 - g(X\theta)))^T (1 - y) \right) + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2$$

2. Регуляризиран градиент

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

Векторна форма на регуляризиания градиент

$$\frac{\delta J(\theta)}{\delta \theta_j} = \frac{1}{m} X^T (g(X\theta) - y) + \frac{\lambda}{m} \theta_j$$

Регуляризация на параметър  $\theta_0$  не се прави.

Задача 6. Във функцията за изчисляване на цената добавете регуляризация.

Наблюдавайте графиките на построените хипотези при  $\lambda = 0$ ,  $\lambda = 1$  и  $\lambda = 100$ . В коя от хипотезите се наблюдава overfitting и при коя голямо отклонение (high bias)? Коя е най-адекватната хипотеза?