

Практически проблеми при
градиентно спускане.
Нормализация. Скорост на
обучение

Доц. д-р Ивайло Пенев

Кат. „Компютърни науки и технологии“

Практически проблеми при градиентно спускане – мащабиране на променливи (Feature Scaling)

- Градиентното спускане може да се ускори, ако стойностите на променливите са в един или в близки диапазони
- При разлика в диапазоните на променливите параметрите θ се приближават бавно към минимума на ϕ -та на цената J
- В идеалният случай диапазонът е:
$$-1 \leq x_{(i)} \leq 1 \text{ или } -0.5 \leq x_{(i)} \leq 0.5$$
- Когато стойностите на променливите са в различни диапазони, те могат да бъдат преобразувани така, че стойностите им да попадат в един диапазон
- Прилагат се два метода – мащабиране (feature scaling) и нормализация на средната стойност (mean normalization)

Мащабиране и нормализация на средната стойност

- Мащабиране (feature scaling) – стойностите на входната променлива се делят на диапазона на изменение на всички стойности на входната променлива (т.е. разликата на максималната и минималната стойност)
- Нормализация на средната стойност (mean normalization) – от всяка стойност на входната променлива се изважда средната стойност от всички стойности на променливата и получената разлика се разделя на диапазона, т.е.:

$$x_i := \frac{x_i - \mu_i}{S_i}$$

, където

μ_i - средна стойност на всички стойности на променливата x_i

S_i - диапазон на изменение на стойностите на x_i (max-min) или стандартно отклонение

Пример за нормализация

- Ако x_i е цена на m^2 за къща с диапазон от 100 до 2000 и средна стойност 1000, то нормализираната x_i има следният вид:

$$x_i := \frac{x_i - 1000}{1900}$$

Влияние на скоростта на обучение върху градиентното спускане

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

{

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

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

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

...

}

α – скорост на обучението (learning rate) – определя стъпката на изменение на параметрите θ

Проследяване на градиентното спускане

- Как да проверим дали градиентното спускане приближава ϕ -та на цената $J(\theta)$ до минимална стойност?
- Чертаем графика с брой итерации на градиентното спускане по оста x и стойността на $J(\theta)$ за всяка итерация. Ако на някоя итерация $J(\theta)$ се увеличи, това означавам че трябва да намалим скоростта на обучение α
- Кога $J(\theta)$ достига минимум?
- Ако на дадена итерация $J(\theta)$ намалява със стойност по-малка от определена стойност ϵ , то това означава, че $J(\theta)$ е достигнала минимум
- ϵ – прагова стойност, която е достатъчно малка, напр. $\epsilon = 10^{-3}$ (практически е трудно да се избере стойност)

Обобщение за скоростта на обучение

- Практически е доказано, че ако α е достатъчно малка, то $J(\theta)$ намалява на всяка итерация
- Проблеми
 - Ако α е прекалено малка, градиентното спускане ще се изпълнява бавно
 - Ако α е голяма, е възможно $J(\theta)$ да не достигне минимум

Подобряване на функцията на хипотезата – полиномна регресия

- Възможно е да комбинираме множество променливи в една
- Напр. можем да комбинираме променливи x_1 и x_2 в една променлива x_3 , където $x_3 = x_1 \cdot x_2$
- Не е задължително функцията на хипотезата да бъде права линия – може да е квадратна, кубична функция, квадратен корен и др.

Примери за нелинейни функции

- Линејна функција $h_{\theta}(x) = \theta_0 + \theta_1 x_1$
- Квадратна функција $h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_1^2$, където е добавена нова променлива $x_2 = x_1^2$
- Кубична функција $h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_1^2 + \theta_3 x_1^3$, където $x_3 = x_1^3$
- Функција квадратен корен $h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 \sqrt{x_1}$
- При таква добавяне на променливи мащабирането е много важно
- Напр., ако x_1 има диапазон от 1 до 1000, то x_1^2 има диапазон от 1 до 1000000, а x_1^3 от 1 до 1000000000