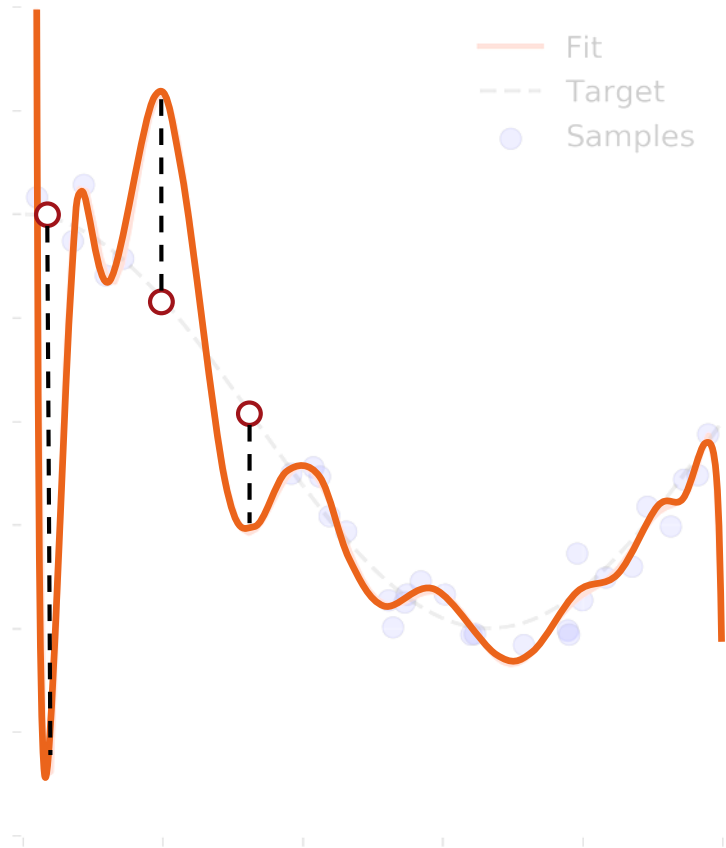


تنظیم: بر خورد با بیش بر ارزش

سید ناصر رضوی www.snrazavi.ir

۱۳۹۷

بیش‌برازش و تنظیم



□ بیش‌برازش. یک مشکل بسیار متداول در یادگیری ماشین

□ مدل بیش از حد نیاز پیچیده

■ مثلاً به دلیل تعداد بسیار زیاد ویژگی‌ها

□ عملکرد بسیار خوب مدل بر روی داده‌های آموزشی


□ عملکرد بسیار بد مدل بر روی داده‌های جدید

■ عدم قابلیت تعمیم برای داده‌های جدید!

□ تنظیم. یک روش مؤثر برای کاهش یا حذف بیش‌برازش.

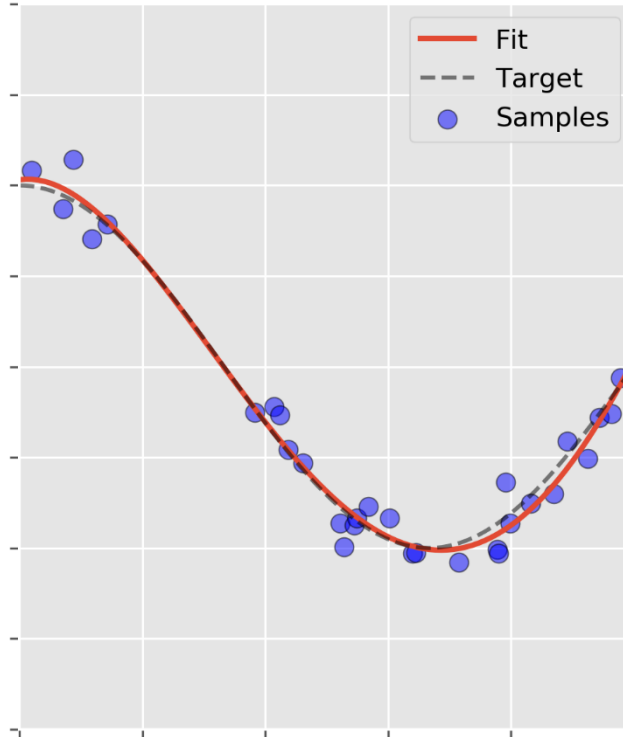
بیش‌برازش و رگرسیون

Degree 1, MSE = 0.41




کم‌برازش

Degree 4, MSE = 0.04




مدل درست

Degree 15, MSE = 182815432.94




بیش‌برازش


بیش‌برازش و دسته‌بندی



کم‌برازش





مدل درست




بیش‌برازش

□ ایده. جلوگیری از بزرگ شدن بیش از حد مقدار پارامترها با افزودن یک جمله به تابع هزینه به منظور جریمه کردن مقادیر بزرگ پارامترها.




□ ایده. جلوگیری از بزرگ شدن بیش از حد مقدار پارامترها با افزودن یک جمله به تابع هزینه به منظور جریمه کردن مقادیر بزرگ پارامترها.



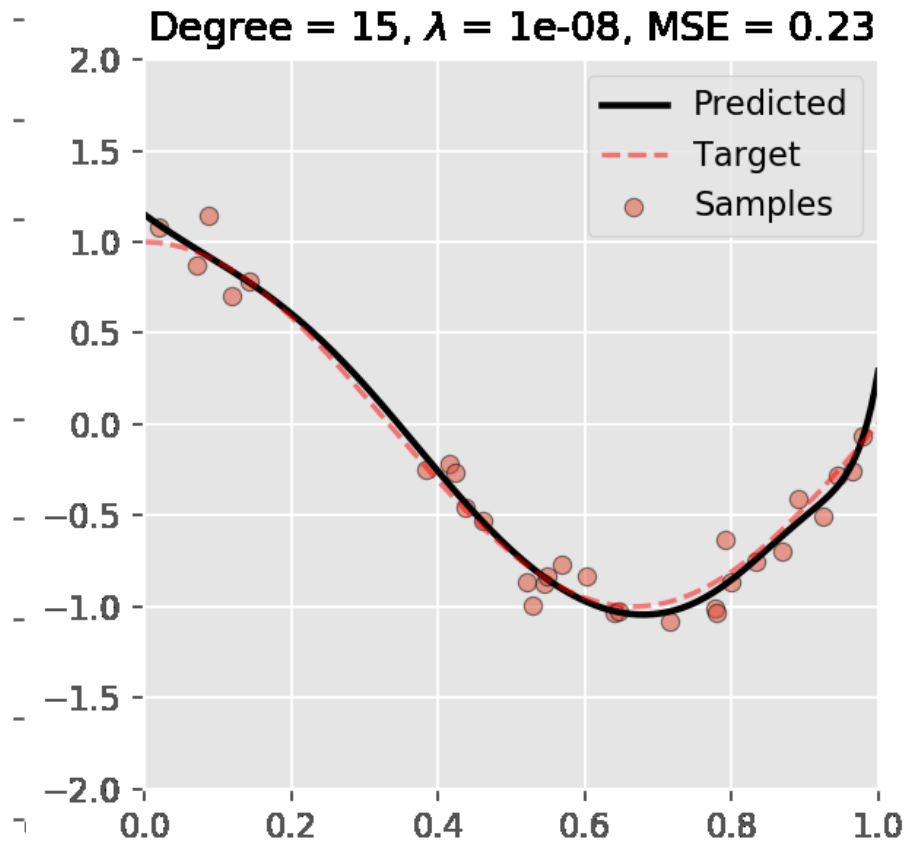
$$J(\theta) = \frac{1}{m} \sum_{i=1}^m Cost(x^{(i)}, y^{(i)}) + \lambda R(\theta)$$

$$R(\theta) = \sum_{j=1}^n \theta_j^2 = \|\theta\|_2^2 \quad \text{تنظیم L2}$$

$$R(\theta) = \sum_{j=1}^n |\theta_j| = \|\theta\|_1 \quad \text{تنظیم L1}$$



□ ایده. جلوگیری از بزرگ شدن بیش از حد مقدار پارامترها با افزودن یک جمله به تابع هزینه به منظور جریمه کردن مقادیر بزرگ پارامترها.



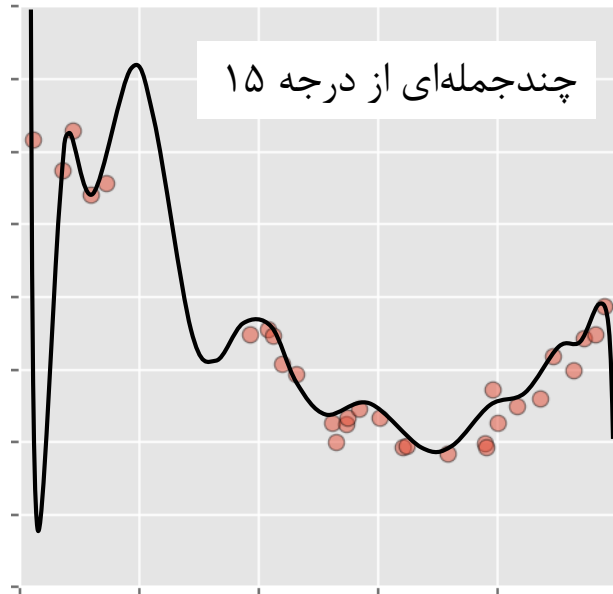
$$J(\theta) = \frac{1}{m} \sum_{i=1}^m Cost(x^{(i)}, y^{(i)}) + \lambda R(\theta)$$

□ ضریب تنظیم. برقرای توازن میان اهداف فوق.

← $\lambda \rightarrow 0$ دادن اهمیت بیشتر به فضای مجموعه آموزشی


← $\lambda \rightarrow \infty$ دادن اهمیت بیشتر به فضای تعمیم

رگرسیون بدون تنظیم




$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \text{Cost}(x^{(i)}, y^{(i)})$$

رگرسیون با تنظیم




$$\frac{1}{m} \sum_{i=1}^m \text{Cost}(x^{(i)}, y^{(i)}) + \lambda R(\theta)$$

مقدار پارامترها در صورت استفاده از تنظیم




$$R(\theta) = \sum_{j=1}^n \theta_j^2 = \|\theta\|_2^2 \quad \text{تنظیم L2}$$

رگرسیون با تنظیم




$$\frac{1}{m} \sum_{i=1}^m \text{Cost}(x^{(i)}, y^{(i)}) + \lambda R(\theta)$$

مقدار پارامترها در صورت استفاده از تنظیم



$$R(\theta) = \sum_{j=1}^n |\theta_j| = \|\theta\|_1 \quad \text{تنظیم L1}$$



رگرسیون با تنظیم



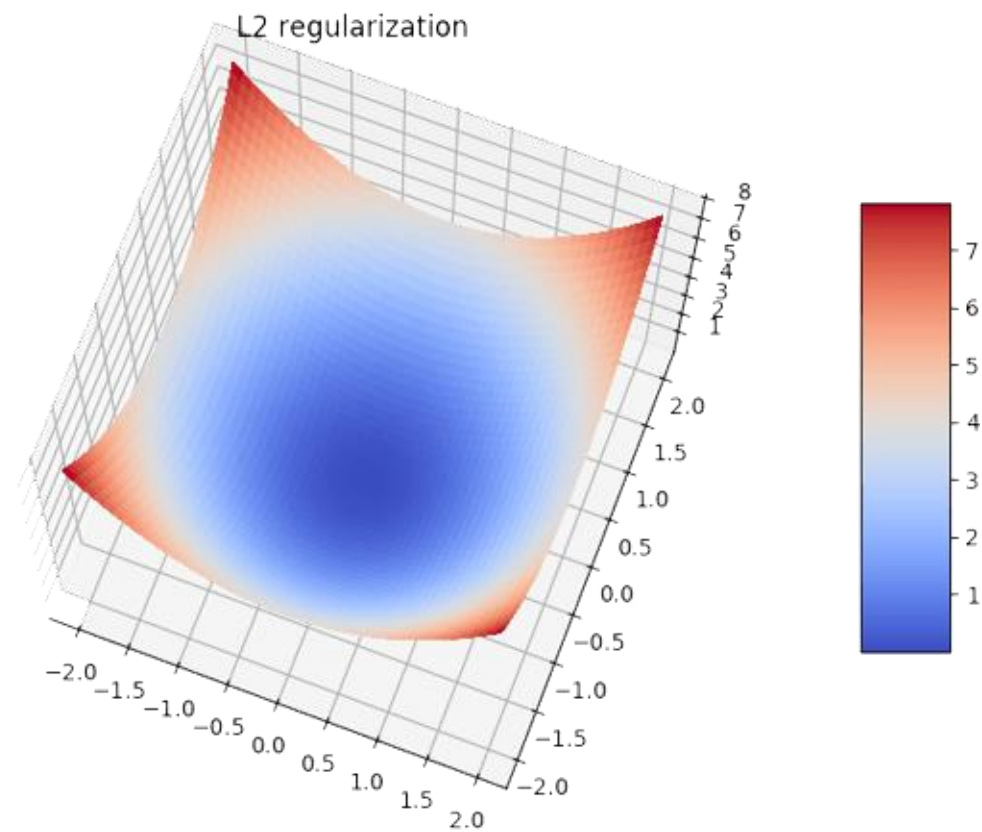

$$\frac{1}{m} \sum_{i=1}^m Cost(x^{(i)}, y^{(i)}) + \lambda R(\theta)$$

تنظیم L1 و L2

۱۲



تنظیم L1 و L2



رگرسیون خطی تنظیم شده

۱۴

رگرسیون خطی تنظیم شده

□ تابع هزینه.

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

□ هدف. کمینه‌سازی تابع هزینه به منظور یافتن مقدار بهینه پارامترها

$$\min_{\theta} J(\theta)$$

گرادیان کاهششی (بدون تنظیم)

۱۶

□ بدون استفاده از تنظیم.

```
repeat until convergence {
```

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

```
}
```


گرادیان کاهششی (با تنظیم)

□ با استفاده از تنظیم.

repeat until convergence {

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

$$\theta_j = \theta_j - \alpha \left[\sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_j^{(i)} + \lambda \theta_j \right] \quad (j = 1, 2, \dots, n)$$

}

$$\theta_j = \theta_j \underbrace{(1 - \alpha\lambda)}_{< 1} - \alpha \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_j^{(i)}$$

معادله نرمال (با تنظیم)

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

$$\theta = \underbrace{(X^T X + \lambda I)^{-1}}_{\text{وارون پنزیر } (\lambda > 0)} X^T y$$

$$\begin{aligned} \frac{\partial J}{\partial \theta} &= X^T (X\theta - y) + \lambda \theta \\ &= X^T X\theta - X^T y + \lambda \theta \\ &= (X^T X + \lambda I)\theta - X^T y = 0 \\ (X^T X + \lambda I)\theta &= X^T y \end{aligned}$$

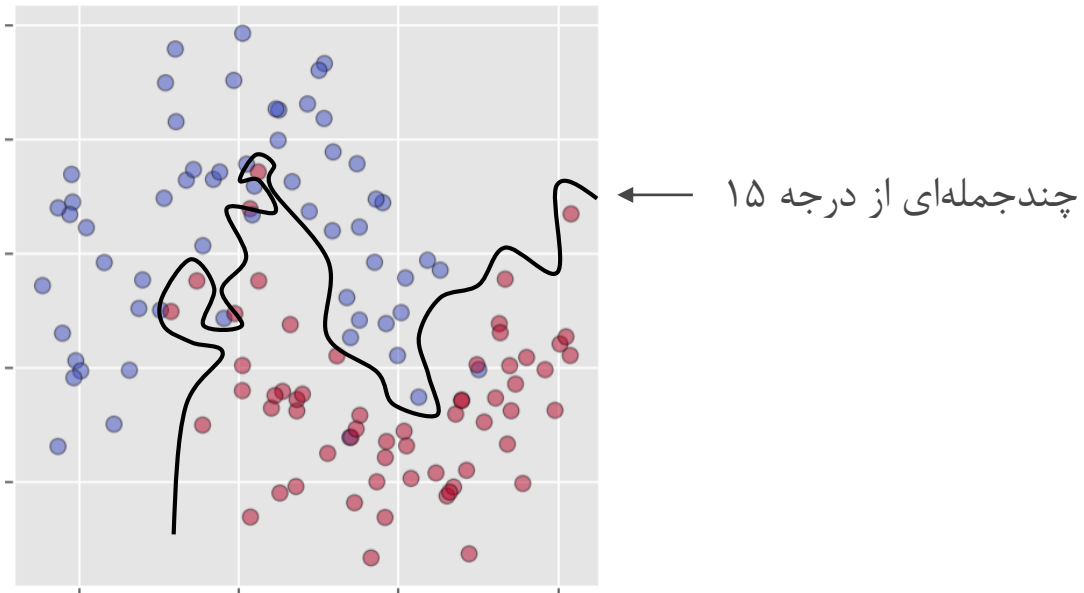
$$\theta = \left(X^T X + \lambda \begin{bmatrix} 0 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \right)^{-1} X^T y$$

رگرسیون لجستیک تنظیم شده

رگرسیون لجستیک (بدون تنظیم)

۲۰

□ فرضیه.




□ تابع هزینه.

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

رگرسیون لجستیک (با تنظیم)

۲۱

□ فرضیه.



□ تابع هزینه.

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

گرادیان کاهش

۲۲


□ با استفاده از تنظیم.

repeat until convergence {

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

$$\theta_j = \theta_j - \alpha \left[\sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_j^{(i)} + \lambda \theta_j \right] \quad (j = 1, 2, \dots, n)$$

}


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

بهینه‌سازی پیشرفته

۲۳

```
from scipy.optimize import minimize
```

```
minimize(J, x0, method='CG', jac=grads)
```

پیاده‌سازی تابع هزینه

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

گرادیان

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