

Hội Qui Tuyển Tính

TS. Nguyễn Thanh Hiền
Email: hien.nguyen@newai.vn

Trợ giảng 1: ThS. Dương Hữu Phúc
Email: phuc.duong@newai.vn



Trợ giảng 2: KS. Nguyễn Tân Kim
Email: kim.nguyen@newai.vn

<https://course.newai.vn>

<https://blog.newai.vn>

Hàm tuyến tính

Xét trong
không gian
hai chiều
hai tuyến
tính là cùng
thẳng dạng
 $y = ax + b$




Cho hai điểm $P_1(2, 2)$, $P_2(3, 4)$ ta sẽ tìm được
đường thẳng $y = ax + b$ với a, b là các tham số

$$\begin{cases} 2 = 2a + b \\ 4 = 3a + b \end{cases} \Rightarrow \begin{cases} a = 2 \\ b = -2 \end{cases}$$

Như vậy: P_1 và P_2 là dữ liệu, a và b là các tham số

Độ dốc



- **Độ dốc** (slope) hay còn gọi là **gradient**: $slope = \frac{\Delta y}{\Delta x} = \frac{y_2 - y_1}{x_2 - x_1}$

Siêu phẳng

- Khi \mathbf{x} là véc-tơ n chiều, ta có siêu phẳng (hyperplane) $y = \mathbf{w}^T \mathbf{x} + b$ trong không gian $n + 1$ chiều


$$\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix}, \quad \mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

- Ta cũng có thể viết như sau

$$y = [w_0 \quad w_1 \quad \dots \quad w_n] \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}, \quad \text{với } b = w_0 \text{ vì } x_0 = 1$$

Siêu phẳng


- Ví dụ siêu phẳng trong không gian 3 chiều



Hồi qui tuyến tính

- Tập huấn luyện có m mẫu: $\{(\mathbf{x}^{(i)}, y^{(i)})\}_{i=1, \overline{m}}$
 - Mỗi cặp (\mathbf{x}, y) là một mẫu huấn luyện
 - \mathbf{x} : véc-tơ đặc trưng n chiều
 - y : kết quả
 - y rời rạc: bài toán phân lớp
 - y liên tục: bài toán hồi qui
- Hồi qui tuyến tính: $\hat{y} = h_{\theta}(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$, $\theta = \{\mathbf{w}, b\}$
- Hàm mất mát (loss function):
 - Ước lượng sự sai biệt giữa \hat{y} và y
 - Kí hiệu: $\mathcal{L}(\hat{y}, y)$

Hồi qui tuyến tính



$$\hat{y} = h_{\theta}(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = [w_1 \quad w_2 \quad \dots \quad w_n] \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} + b = \sum_{i=1}^n w_i x_i + b$$

Hàm chi phí

- Tập huấn luyện: $\{(\mathbf{x}^{(i)}, y^{(i)})\}_{i=1}^m$


- Hàm chi phí (cost function):

$$J(\boldsymbol{\theta}) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(\hat{y}^{(i)}, y^{(i)}) \quad \hat{y}^{(i)} = f(\mathbf{x}^{(i)}; \boldsymbol{\theta}) \quad \boldsymbol{\theta} = \{\mathbf{w}, b\}$$


- Hàm mất mát: $\mathcal{L}(\hat{y}, y)$

- Hàm bình phương sai biệt (square error): $\mathcal{L}(\hat{y}, y) = \frac{1}{2}(\hat{y} - y)^2$

Hồi qui tuyến tính



Hồi qui tuyến tính



Mục tiêu: tìm θ sao cho $J(\theta)$ cực tiểu

Maximum Likelihood

Tập huấn luyện: $\{(\mathbf{x}^{(i)}, y^{(i)})\}_{i=1}^m$

Giải sử các mẫu **i.i.d**: **independent and identically distributed**

$$y^{(i)} = \hat{y}^{(i)} + \epsilon^{(i)} = h_{\theta}(\mathbf{x}^{(i)}) + \epsilon^{(i)}$$

Giải sử: $\epsilon^{(i)} \sim \mathcal{N}(0, \sigma^2)$

$$\begin{aligned} p(\epsilon^{(i)}) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(\epsilon^{(i)})^2}{2\sigma^2}\right) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y^{(i)} - \hat{y}^{(i)})^2}{2\sigma^2}\right) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y^{(i)} - h_{\theta}(\mathbf{x}^{(i)}))^2}{2\sigma^2}\right) \end{aligned}$$

$$\Rightarrow p(y^{(i)} | \mathbf{x}^{(i)}; \theta) \sim \mathcal{N}(h_{\theta}(\mathbf{x}^{(i)}), \sigma^2)$$

Maximum Likelihood



$$\begin{aligned}L(\boldsymbol{\theta}) &= p(\mathbf{y}|\mathbf{X}; \boldsymbol{\theta}) \\&= \prod_{i=1}^m p\left(y^{(i)}|\mathbf{x}^{(i)}; \boldsymbol{\theta}\right) \\&= \prod_{i=1}^m \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y^{(i)} - h_{\boldsymbol{\theta}}(\mathbf{x}^{(i)}))^2}{2\sigma^2}\right)\end{aligned}$$

Maximum Likelihood: Tìm $\boldsymbol{\theta}$ sao cho $L(\boldsymbol{\theta})$ cực đại

Maximum Log-Likelihood

$$\begin{aligned}\mathcal{L}(\boldsymbol{\theta}) &= \log L(\boldsymbol{\theta}) \\ &= \log \prod_{i=1}^m \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y^{(i)} - h_{\boldsymbol{\theta}}(\mathbf{x}^{(i)}))^2}{2\sigma^2}\right) \\ &= \sum_{i=1}^m \log \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y^{(i)} - h_{\boldsymbol{\theta}}(\mathbf{x}^{(i)}))^2}{2\sigma^2}\right) \\ &= m \log \frac{1}{\sqrt{2\pi\sigma^2}} - \frac{1}{2} \cdot \frac{1}{\sigma^2} \sum_{i=1}^m \left(y^{(i)} - h_{\boldsymbol{\theta}}(\mathbf{x}^{(i)})\right)^2\end{aligned}$$

Tối ưu toàn cục và cục bộ



Huấn luyện mô hình

- Tìm giá trị các tham số w và b sao cho hàm chi phí $J(\theta)$ cực tiểu

$$\underset{\theta}{\text{minimize}} J(\theta)$$

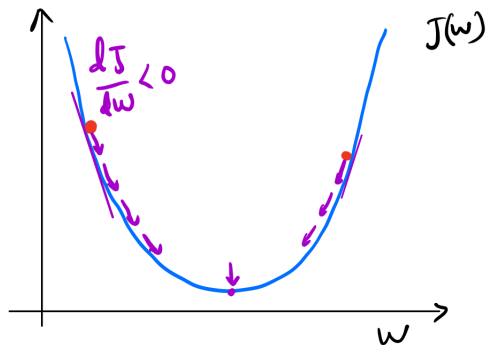
hay

$$\underset{w,b}{\text{minimize}} J(w, b)$$


- Giải thuật huấn luyện: Giảm độ dốc (Gradient descent)

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


Giảm độ dốc





Giảm độ dốc



Giảm độ dốc



Giảm độ dốc



$$\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} - \alpha \frac{\partial J(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}}$$

Với $\boldsymbol{\theta} = \{\boldsymbol{w}, b\}$:

$$\boldsymbol{w} \leftarrow \boldsymbol{w} - \alpha \frac{\partial J(\boldsymbol{w}, b)}{\partial \boldsymbol{w}}$$

$$b \leftarrow b - \alpha \frac{\partial J(\boldsymbol{w}, b)}{\partial b}$$

Giả sử **loss** là bình phương sai lệch:

$$\mathcal{L}(\hat{y}, y) = \frac{1}{2}(\hat{y} - y)^2 = \frac{1}{2}(h_{\boldsymbol{\theta}}(\boldsymbol{x}) - y)^2$$

1 mẫu huấn luyện:

$$\frac{\partial J(\mathbf{w}, b)}{\partial w_j} = \mathcal{L}(\hat{y}, y) \quad (1)$$

$$= \frac{\partial}{\partial w_j} \frac{1}{2} (h_{\boldsymbol{\theta}}(\mathbf{x}) - y)^2 \quad (2)$$

$$= 2 \frac{1}{2} (h_{\boldsymbol{\theta}}(\mathbf{x}) - y) \frac{\partial}{\partial w_j} (h_{\boldsymbol{\theta}}(\mathbf{x}) - y) \quad (3)$$

$$= (h_{\boldsymbol{\theta}}(\mathbf{x}) - y) \frac{\partial}{\partial w_j} \left(\sum_{i=1}^n (w_i x_i + b) - y \right) \quad (4)$$

$$= (h_{\boldsymbol{\theta}}(\mathbf{x}) - y) x_j \quad (5)$$

Giảm độ dốc

m mẫu huấn luyện:

Giảm độ dốc

m mẫu huấn luyện:

$$\frac{\partial J(\mathbf{w}, b)}{\partial w_j} = \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)}) x_j^{(i)} \quad (6)$$

$$\frac{\partial J(\mathbf{w}, b)}{\partial b} = \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)}) \quad (7)$$

Luật cập nhật:

$$w_j \leftarrow w_j - \alpha \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)}) x_j^{(i)} \quad (8)$$

$$b \leftarrow b - \alpha \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)}) \quad (9)$$

Batch Gradient descent (GD)

Lặp *epoch* lần {

Cập nhật w , ($j = \overline{1, n}$):

$$w_j \leftarrow w_j - \alpha \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)}) x_j^{(i)}$$

Cập nhật b :

$$b \leftarrow b - \alpha \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)})$$

}

Stochastic gradient descent (SGD)

Lặp *epoch* lần {

for $i = 1$ to m :

Cập nhật w , ($j = \overline{1, n}$):

$$w_j \leftarrow w_j - \alpha(h_{\theta}(\mathbf{x}) - y)x_j$$

Cập nhật b :

$$b \leftarrow b - \alpha(h_{\theta}(\mathbf{x}) - y)$$

}

Mini-batch gradient descent

Lặp *epoch* lần {

Lấy một khối m mẫu từ tập huấn luyện

$$\{(\mathbf{x}^{(1)}, y^{(1)}), (\mathbf{x}^{(2)}, y^{(2)}), \dots, (\mathbf{x}^{(m)}, y^{(m)})\}$$

Cập nhật w , ($j = \overline{1, n}$):

$$w_j \leftarrow w_j - \alpha \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)}) x_j^{(i)}$$

Cập nhật b :

$$b \leftarrow b - \alpha \sum_{i=1}^m (h_{\theta}(\mathbf{x}^{(i)}) - y^{(i)})$$

}