

Régression logistique :

Jeu de données : $(x_1, y_1), \dots, (x_n, y_n)$

où $x \in \mathbb{R}^d$ et $y \in \{0, 1\}$.

Modèle probabiliste :

$$\mathbb{P}[Y=1 \mid X=x] = g(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)$$

$$\text{où } g(z) = \frac{1}{1 + e^{-z}} = \frac{e^z}{1 + e^z} \quad \text{fonction logistique}$$

On peut voir $x = (1, x_1, \dots, x_p)^T$.

et noter

$$= \beta^T x \quad \text{ou} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}.$$


$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$

On peut écrire donc :

$$\mathbb{P}(Y=y | X=x) = g(\beta^T x)^y (1 - g(\beta^T x))^{1-y}$$

La fonction logistique



$g(z)$



La fonction de perte :

$$l(y, g(\beta^T x)) =$$

$$\begin{cases} -\ln(g(\beta^T x)) & \text{si } y = 1 \\ -\ln(1 - g(\beta^T x)) & \text{si } y = 0 \end{cases}$$



donc, si on note $x_i = (1, x_{i1}, \dots, x_{ip})$
la perte de l'individu du jeu de données est donnée par

$$l(y_i, g(\beta^T x_i)) = -y_i \ln(g(\beta^T x_i)) - (1 - y_i) \ln(1 - g(\beta^T x_i))$$

pour un jeu de données de taille n ; la perte est
donnée par
$$L(\beta) = \frac{1}{n} \sum_{i=1}^n l(y_i, g(\beta^T x_i)).$$

On souhaite calculer

$$\hat{\beta} = \underset{\beta \in \mathbb{R}^{p+1}}{\operatorname{argmin}} L(\beta)$$

On va calculer

$$\nabla_{\beta} L(\beta) = \left[\begin{array}{c} \frac{\partial}{\partial \beta_0} L(\beta) \\ \vdots \\ \frac{\partial}{\partial \beta_j} L(\beta) \end{array} \right] \text{ le gradient}$$

$$\frac{\partial}{\partial \beta_j} L(\beta) = \frac{\partial}{\partial \beta_j} \left(\frac{1}{n} \sum_{i=1}^n \ell(y_i, g(\beta^T x_i)) \right)$$

$$= \frac{1}{n} \sum_{i=1}^n \frac{\partial}{\partial \beta_j} \left[y_i \ln(g(\beta^T x_i)) + (1 - y_i) \ln(1 - g(\beta^T x_i)) \right]$$

$$\frac{\partial}{\partial \beta_j} \left(y_i \ln(g(\beta^T x_i)) + (1 - y_i) \ln(1 - g(\beta^T x_i)) \right)$$

$$= \left(y_i \frac{1}{g(\beta^T x_i)} - \frac{(1 - y_i)}{1 - g(\beta^T x_i)} \right) \frac{\partial}{\partial \beta_j} g(\beta^T x_i)$$

on sait que $g(z) = \frac{1}{1 + e^{-z}}$ et $1 - g(z) = \frac{e^{-z}}{1 + e^{-z}}$

on peut donc écrire :

$$\frac{\partial}{\partial \beta_j} (g(\beta^T x_i)) = \frac{e^{-\beta^T x_i}}{(1 + e^{-\beta^T x_i})^2} \frac{\partial}{\partial \beta_j} (\beta^T x_i)$$

$$= \frac{e^{-\beta^T x_i}}{1 + e^{-\beta^T x_i}} \times \frac{1}{1 + e^{-\beta^T x_i}} x_{ij}$$

$$\text{dove: } \frac{\partial}{\partial \beta_j} (g(\beta^T x_i)) = g(\beta^T x_i) (1 - g(\beta^T x_i)) x_{ij}$$

On ridet dovce:

$$\frac{\partial}{\partial \beta_j} (y_i \ln(g(\beta^T x_i)) + (1 - y_i) \ln(1 - g(\beta^T x_i)))$$

$$= \left(\frac{y_i}{g(\beta^T x_i)} - \frac{(1 - y_i)}{1 - g(\beta^T x_i)} \right) \frac{\partial}{\partial \beta_j} (g(\beta^T x_i))$$

$$= \frac{y_i (1 - g(\beta^T x_i)) - (1 - y_i) g(\beta^T x_i)}{g(\beta^T x_i) (1 - g(\beta^T x_i))} \times \cancel{g(\beta^T x_i) (1 - g(\beta^T x_i))} x_{ij}$$

$$= (y_i - g(\beta^T x_i)) x_{ij} = - (g(\beta^T x_i) - y_i) x_{ij}$$

on déduit que :

$$\begin{aligned} \frac{\partial L(\beta)}{\partial \beta_j} &= - \frac{1}{n} \sum_{i=1}^n \frac{\partial}{\partial \beta_j} \left(y_i \ln(g(\beta^T x_i)) + (1 - y_i) \ln(1 - g(\beta^T x_i)) \right) \\ &= \frac{1}{n} \sum_{i=1}^n (g(\beta^T x_i) - y_i) x_{ij} \end{aligned}$$

Descente du gradient :

$$\beta_j \leftarrow \beta_j - \eta \frac{1}{n} \sum_{i=1}^m (g(\beta^T x_i) - y_i) x_{ij}$$