


Neurone artificiale basato sulla regressione logistica

Ridefiniamo i target $y_i = 0, 1$

e definiamo la funzione sigmoide

$$\sigma(\phi(z)) = \begin{cases} 1 & \text{se } \phi(z) > \frac{1}{2} \\ 0 & \text{se } \phi(z) < \frac{1}{2} \end{cases}$$

Ricordiamo che $z = \vec{w} \cdot \vec{x}$ funzione d'errore



$$f(p) = \log\left(\frac{p}{1-p}\right) \quad p \in [0, 1]$$

$$f(\phi(z)) = z$$

$$\log\left(\frac{\phi(z)}{1-\phi(z)}\right) = z$$

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

$$\phi(z) = e^z(1-\phi(z))$$

$$\phi(z)(1+e^z) = e^z$$

$$\phi(z) = \frac{e^z}{1+e^z} = \frac{1}{1+e^{-z}} \quad \text{funzione sigmoide}$$

Definiamo una funzione PERFORMANCE $L(\vec{w}) = \prod_{i=1, N_{samples}} (\phi(z^i))^{y^i} (1-\phi(z^i))^{(1-y^i)}$

$L(\vec{w})$ andrebbe massimizzata, ma si preferisce

$$J(\vec{w}) = -\log L(\vec{w})$$

$$J(\vec{w}) = \sum_{i=1, N_{samples}} -y^i \log(\phi(z^i)) - (1-y^i) \log(1-\phi(z^i))$$

$$\frac{\partial J(\vec{w})}{\partial w_j} = \sum_{i=1, N_{samples}} -y^i \frac{1}{\phi(z^i)} \frac{\partial \phi(z^i)}{\partial w_j} - (1-y^i) \frac{1}{(1-\phi(z^i))} \frac{\partial \phi(z^i)}{\partial w_j}$$

Dove

$$\frac{\partial \phi(z^i)}{\partial w_j} = \frac{\partial}{\partial w_j} \left(\frac{1}{1+e^{-z^i}} \right) = -\frac{1}{(1+e^{-z^i})^2} (-e^{-z^i}) = \frac{x_j^i e^{-z^i}}{(1+e^{-z^i})^2}$$

$$= \phi(z^i)(1-\phi(z^i)) x_j^i$$

$$\frac{\partial J}{\partial w_j} = \sum_{i=1, N_{samples}} (-y^i + \phi(z^i)) x_j^i$$

NOTA: vogliamo evitare l'overfitting



Si introduce un termine di penalità nella funzione d'errore

$$J'(\vec{w}) = C J(\vec{w}) + \frac{1}{2} \vec{w} \cdot \vec{w}$$

↑ costante positive


SUPPORT VECTOR MACHINE

Notazioni

$$\vec{x} = (x_1, \dots, x_n)$$

$$\vec{w} = (w_0, \dots, w_n)$$

$$y = -1, 1$$



Supponiamo il problema sia linearmente separabile

l'ipotesi che separa le soluzioni è data da un'equazione del tipo

$$\phi(\vec{x}) = 0 \quad \text{con } \phi(\vec{x}) = \vec{w} \cdot \vec{x} + w_0$$

I vettori più vicini al piano di separazione sono detti support vector, li chiamo \vec{x}^{sup} e \vec{x}^{neg}

$$\text{Voglio che } \phi(\vec{x}^{sup}) = 1 \quad \text{e } \phi(\vec{x}^{neg}) = -1$$


$$\begin{cases} \vec{w} \cdot \vec{x}^{sup} + w_0 = 1 \\ \vec{w} \cdot \vec{x}^{neg} + w_0 = -1 \end{cases}$$

Consideriamo i piani $\phi(\vec{x}) = 1$ e $\phi(\vec{x}) = -1$ detti margini

Mostriamo che \vec{w} è \perp ai margini


Sia $\Delta \vec{x}$ vettore entro il margine

$\vec{x}^{sup} + \Delta \vec{x}$ include un punto nel margine



$$\phi(\vec{x}^{sup} + \Delta \vec{x}) = 1$$

$$\vec{w} \cdot (\vec{x}^{sup} + \Delta \vec{x}) + w_0 = 1 \Rightarrow \vec{w} \cdot \Delta \vec{x} = 0$$



Vogliamo scegliere \vec{w} in maniera da massimizzare la distanza tra i margini:

$$d = \frac{(\vec{x}^{sup} - \vec{x}^{neg}) \cdot \vec{w}}{|\vec{w}|}$$

$$= \frac{\vec{x}^{sup} \cdot \vec{w}}{|\vec{w}|} - \frac{\vec{x}^{neg} \cdot \vec{w}}{|\vec{w}|} \pm \frac{w_0}{|\vec{w}|}$$

$$= \frac{\vec{x}^{sup} \cdot \vec{w} + w_0}{|\vec{w}|} - \frac{(\vec{x}^{neg} \cdot \vec{w} + w_0)}{|\vec{w}|} = \frac{2}{|\vec{w}|}$$

Questo è equivalente a minimizzare

$$J(\vec{w}) = \frac{1}{2} \vec{w} \cdot \vec{w}$$

che va minimizzata con la condizione $y^i \frac{(w_0 + \vec{w} \cdot \vec{x}^i)}{\phi(\vec{x}^i)} \geq 1$

Minimizzazione con condizioni di disuguaglianza

Voglio trovare $\min_{\vec{x}} f(\vec{x})$ con la condizione $g(\vec{x}) \geq 0$

il minimo sta in $g(\vec{x}) > 0$ e $\vec{\lambda} = 0$ (stesso minimo del senso contrario) altrimenti deve stare su $g(\vec{x}) = 0$

$$P^* = \min_{\vec{x}} f(\vec{x}) \quad \text{con } g(\vec{x}) \geq 0$$

$$J(\vec{x}) = \begin{cases} f(\vec{x}) & \text{se } g(\vec{x}) > 0 \\ +\infty & \text{altrimenti} \end{cases}$$

$$P^* = \min_{\vec{x}} J(\vec{x})$$

$$H(\vec{x}, \lambda) = f(\vec{x}) - \lambda g(\vec{x}) \quad \lambda \geq 0$$

$$\max_{\lambda} H(\vec{x}, \lambda) = J(\vec{x})$$

$$P^* = \min_{\vec{x}} \max_{\lambda} H(\vec{x}, \lambda)$$

$$H(\vec{x}, \lambda) \leq J(\vec{x})$$

$$\min_{\vec{x}} H(\vec{x}, \lambda) \leq \min_{\vec{x}} J(\vec{x})$$

$$\max_{\lambda} \min_{\vec{x}} H(\vec{x}, \lambda) \leq P^*$$

Supponiamo sia scrivibile con '=' strong duality

Applicazione a SVM

$$H = \frac{1}{2} \vec{w} \cdot \vec{w} - \sum_{i=1, N_{samples}} \lambda_i y^i (\vec{w} \cdot \vec{x}^i + w_0)$$

Minimizziamo prima rispetto a \vec{w} e w_0

$$\frac{\partial H}{\partial \vec{w}} = \vec{w} - \sum_{i=1, N_{samples}} \lambda_i y^i \vec{x}^i = 0 \Rightarrow \vec{w} = \sum_{i=1, N_{samples}} \lambda_i y^i \vec{x}^i$$

$$\frac{\partial H}{\partial w_0} = \sum_{i=1, N_{samples}} \lambda_i y^i = 0$$

$$H = \frac{1}{2} \left(\sum_{i=1, N_{samples}} \lambda_i y^i \vec{x}^i \right) \cdot \left(\sum_{j=1, N_{samples}} \lambda_j y^j \vec{x}^j \right) - \sum_{i=1, N_{samples}} y^i \lambda_i \vec{x}^i \cdot \left(\sum_{j=1, N_{samples}} y^j \lambda_j \vec{x}^j \right)$$

$$= -\frac{1}{2} \sum_{i,j=1, N_{samples}} \lambda_i \lambda_j y^i y^j \vec{x}^i \cdot \vec{x}^j$$

de va MASSIMIZZATA λ_i

Problemi non lineari