

Convergence de l'algorithme du perceptron

On considère un perceptron correspondant à une fonction $f: \mathbb{R}^p \rightarrow \{-1, 1\}$ déterminée par

$$f(x_1, \dots, x_p) = \begin{cases} 1 & \text{si } \omega_1 x_1 + \dots + \omega_p x_p + \theta \geq 0 \\ -1 & \text{sinon} \end{cases}$$

Rq: La fonction est à valeurs dans $\{-1, 1\}$ au lieu de $\{0, 1\}$ pour faciliter l'exposé, mais cela ne change rien au fond de l'étude...

On se donne un ensemble d'apprentissage

$$A = \{(x^1, y^1), \dots, (x^N, y^N)\}$$

avec pour chaque $i \in \{1, \dots, N\}$, $x^i = (x_1^i, \dots, x_p^i) \in \mathbb{R}^p$ et $y^i \in \{1, -1\}$ la réponse attendue par le perceptron.

Déf: On dit que la base d'apprentissage A est linéairement séparable s'il existe des coefficients $(\omega_1, \dots, \omega_p) \in \mathbb{R}^p \setminus \{(0, \dots, 0)\}$ et $\theta \in \mathbb{R}$ tel que

$$\forall 1 \leq i \leq N, y^i = \text{sgn}(\omega_1 x_1^i + \dots + \omega_p x_p^i + \theta)$$

en posant

$$\text{sgn}(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x = 0 \\ -1 & \text{si } x < 0 \end{cases}$$

Pour alléger les notations, on va poser $\theta = \omega_0$ et convenir $x_0^i = 1$ pour chaque $i \in \{1, \dots, N\}$ de sorte que les expressions $\omega_1 x_1 + \dots + \omega_p x_p + \theta$ s'écrivent plus légèrement

$$\omega_0 x_0 + \omega_1 x_1 + \dots + \omega_p x_p$$

La définition du perceptron se ramène alors la détermination d'un vecteur synaptique

$$\omega = (\omega_0, \omega_1, \dots, \omega_p) \in \mathbb{R}^{p+1}$$

L'algorithme d'apprentissage du perceptron est alors le suivant :

On choisit arbitrairement un vecteur synaptique $\omega^0 \in \mathbb{R}^{p+1}$.

Tant que les réponses produites ne sont pas toutes correctes :

on choisit un exemple (x^i, y^i) dans la base d'apprentissage.

Si la réponse produite par le perceptron sur cet exemple est incorrecte Alors
on modifie chaque poids synaptiques par la relation :

$$\omega_j^{t+1} := \omega_j^t + y^i x_j^i$$

Fin Si

Fin Tant que

Théorème :

Si la base d'apprentissage est linéairement séparable, cet algorithme s'arrête et détermine donc un perceptron solution.

dém. :

Puisque la base est linéairement séparable, il existe un vecteur $\omega^* = (\omega_0^*, \omega_1^*, \dots, \omega_p^*)$ non nul tel que

$$\forall 1 \leq i \leq N, y_i = \text{sgn}(\omega_0^* + \omega_1^* x_1^i + \dots + \omega_p^* x_p^i)$$

Pour alléger les notations, introduisons $(\cdot | \cdot)$ le produit scalaire canonique sur \mathbb{R}^{p+1} . On a donc

$$\forall 1 \leq i \leq N, y_i = \text{sgn}(\omega^* | x^i)$$

avec rappelons-le $x^i = (1, x_1^i, \dots, x_p^i)$.

Posons

$$\delta = \min_{1 \leq i \leq n} |(\omega^* | x^i)| > 0 \text{ et } M = \max_{1 \leq i \leq n} \|x^i\| \in \mathbb{R}^+$$

Si par l'absurde, l'algorithme précédent ne s'arrête pas, il construit une suite infinie de vecteurs $(\omega^t)_{t \in \mathbb{N}}$ avec la propriété

$$\omega^{t+1} = \omega^t + y^i x^i$$

lorsque la réponse du perceptron défini par le vecteur synaptique ω^t n'est pas bonne sur l'exemple (x^i, y^i) .

D'une part

$$(\omega^{t+1} | \omega^*) = (\omega^t | \omega^*) + y^i (x^i | \omega^*) = (\omega^t | \omega^*) + \text{sgn}(\omega^* | x^i) (\omega^* | x^i)$$

donc

$$(\omega^{t+1} | \omega^*) = (\omega^t | \omega^*) + |(\omega^* | x^i)| \geq (\omega^t | \omega^*) + \delta$$

puis par récurrence

$$(\omega^t | \omega^*) \geq (\omega^0 | \omega^*) + t\delta \tag{1}$$

D'autre part

$$\|\omega^{t+1}\|^2 = \|\omega^t\|^2 + 2y^i (\omega^t | x^i) + \|x^i\|^2$$

Or $y^i (\omega^t | x^i) \leq 0$ car la réponse fournie par le perceptron donné par le vecteur synaptique ω^t est supposée incorrecte sur l'exemple (x^i, y^i) et donc

$$\|\omega^{t+1}\|^2 \leq \|\omega^t\|^2 + \|x^i\|^2 \leq \|\omega^t\|^2 + M^2$$

puis par récurrence

$$\|\omega^t\|^2 \leq \|\omega^0\|^2 + tM^2 \tag{2}$$

Par l'inégalité de Cauchy-Schwarz

$$|(\omega^t | \omega^*)| \leq \|\omega^t\| \|\omega^*\|$$

donc (1) et (2) donnent

$$(\omega^0 | \omega^*) + t\delta \leq \sqrt{\|\omega^0\|^2 + tM^2} \|\omega^*\|$$

ce qui est incompatible avec un passage à la limite à l'infini : par exemple en divisant par t avant de faire tendre t vers $+\infty$, on obtient $\delta \leq 0$ qui est contraire aux hypothèses de travail.