

# TD-Perceptron

## Exercice 1 – Perceptron linéaire à seuil

**Q 1.1** Un classifieur à deux classes,  $C_1, C_2$ , opère sur des objets de dimension  $d = 2$  :  $X = \begin{bmatrix} x_{11} & x_{12} \\ \mathbf{x}_i \\ x_{N1} & x_{N2} \end{bmatrix}$ , avec  $\mathbf{x} \in \mathcal{X} \subseteq \mathbb{R}^2$  et utilise la fonction discriminante  $g$  :

$$\mathbf{x}_i \mapsto g(\mathbf{x}_i) = w_1 x_{i1} + w_2 x_{i2} - \theta, \theta \text{ est donné}$$

$\mathbf{x}_i$  est mis dans la classe  $C_1$  si  $g(\mathbf{x}_i) > 0$  et dans la classe  $C_2$  si  $g(\mathbf{x}_i) < 0$ .

1. Quelle est l'équation de la frontière de décision ?

2. On peut mettre en bijection les points  $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}^T \in \mathbb{R}^2$  et  $\mathbf{x}' = \begin{bmatrix} 1 \\ x_1 \\ x_2 \end{bmatrix}^T \in \mathbb{R}^3$ . On construit

un classifieur  $g'$  de paramètres  $w = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \end{bmatrix}$  pour traiter les points de  $\mathbb{R}^3$  :  $g'(\mathbf{x}') = \mathbf{x}'w$ . Quelle valeur faut-il donner à  $w$  pour que les deux classifieurs soient équivalents ?

NB : dans l'ensemble du TD, on considère  $\mathbf{x}_i$  comme un vecteur ligne et  $w$  comme un vecteur colonne.

3. On veut coder  $+1$  les objets attribués à la classe  $C_1$  et  $-1$  les objets attribués à la classe  $C_2$  ; quelle fonction  $F$  faut-il utiliser pour que la composée  $F \circ g$  réalise ce codage ?

N.B. dans la terminologie des réseaux de neurones,  $\mathbf{x}$  est une entrée,  $g$  le potentiel de  $\mathbf{x}$ ,  $\theta$  le seuil,  $F$  la fonction d'activation et  $\{-1, +1\}$  les sorties ; le classifieur précédent est un perceptron linéaire à seuil, sans couche cachée, à une cellule de sortie.

### Q 1.2

On veut utiliser le perceptron précédent pour implémenter le ET logique à deux arguments ; pour cela : on identifie *Vrai* :  $+1$  et *Faux* :  $-1$  ; une entrée est un couple  $x_1, x_2 \in \{-1, +1\}$  et une sortie un élément de  $\{-1, +1\}$ .

1. Que vaut ici  $\mathcal{X}$  ? Montrer qu'un perceptron implémente le ET logique si et seulement si  $w =$

$\begin{bmatrix} w_0 \\ w_1 \\ w_2 \end{bmatrix}$  vérifie un certain système d'inéquations.

2. Trouver une solution du système précédent. Est-elle unique ? Démontrer votre résultat à l'aide d'un schéma en 2D puis en 3D (dans  $\mathbb{R}^2$  puis dans  $\mathbb{R}^3$ ).

3. Mêmes questions pour le OU logique.

4. Montrer que le OU Exclusif ne peut pas être implémenté par un perceptron linéaire à seuil.

---

**Exercice 2 – Apprentissage du perceptron**


---

N.B. Les notations sont les mêmes que dans l'exercice précédent.

On dispose d'une base de  $N$  exemples (observations),  $\{\mathbf{x}_i\}_{i=1,\dots,N}$ , dont les classes sont connues; la classe de  $\mathbf{x}_i$  est notée  $d(\mathbf{x}_i)$ . On utilise l'algorithme suivant (une des variantes de l'algorithme du perceptron) pour apprendre automatiquement la valeur des paramètres, c-à-d du vecteur  $w$  : ( $\varepsilon$  est un nombre positif;  $\mathbf{x}^T$  est le transposé de  $\mathbf{x}$ )

---

**Algorithme 1** : Algorithme d'apprentissage du perceptron
 

---

Entrée :  $\{\mathbf{x}_i, d(\mathbf{x}_i)\}_{i=1,\dots,N}$  ;

Initialisation de  $w$  :  $w(1)$ ;

$t = 1$ ;

**repeat**

  Tirer aléatoirement un exemple :  $\mathbf{x}_i$  ;

**if**  $d(\mathbf{x}_i) \times \mathbf{x}_i w(t) \geq 0$  **then**

$w(t+1) \leftarrow w(t)$

**else**

$w(t+1) \leftarrow w(t) + \varepsilon d(\mathbf{x}_i) \mathbf{x}_i^T$

$t = t + 1$ ;

**until** (*critère d'arrêt satisfait*) ;

---

Le critère d'arrêt peut être, par exemple qu'il n'y a pas eu d'erreur de classification pendant un certain nombre d'itérations successives.

**Q 2.1** Que signifie la condition  $d(\mathbf{x}_i) \times \mathbf{x}_i w(t) \geq 0$ ? Expliquez le principe de l'algorithme.

**Q 2.2** Faites tourner l'algorithme sur le problème du OU logique en itérant sur la base d'apprentissage constituée des 4 exemples distincts possibles, avec successivement pour valeur initiale  $w(0)$  :

1.  $w(0) = (0; 0; 0)$  ;
2.  $w(0) = (1; 1; 1)$  ;
3.  $w(0) = (1; -1; 1)$ .

(Prendre  $\varepsilon = 1$ ) Représenter graphiquement l'évolution de la frontière de décision d'itération en itération.

**Q 2.3** Dérouler l'algorithme sur le problème du ET logique avec  $w(0) = (2; 2; 2)$ .

**Q 2.4** On suppose qu'il existe  $w^*$  classant parfaitement tous les exemples (séparabilité linéaire). On considère une itération de l'algorithme où l'exemple courant,  $x [= x(t)]$ , vérifie  $x \in C_1$  mais est mal classé par le vecteur  $w [= w(t)]$  courant, qui est alors modifié pour devenir  $w^\dagger [= w(t+1)]$ .

1. Vérifier qu'alors :  $w^* \cdot \mathbf{x} > 0$ ;  $w \cdot \mathbf{x} < 0$ ;  $w^\dagger = w + \varepsilon \mathbf{x}$
2. Montrer que :  $\|w^\dagger - w^*\|^2 \leq \|w - w^*\|^2 + \varepsilon[\varepsilon\|\mathbf{x}\|^2 - 2w^* \cdot \mathbf{x}]$
3. On pose  $m = \min_{i=1,\dots,N} w^* \cdot \mathbf{x}_i$  et  $M = \max_{i=1,\dots,N} \|\mathbf{x}_i\|^2$ . Montrer qu'en prenant  $\varepsilon = \frac{m}{M}$ , on obtient l'inégalité  $\|w^\dagger - w^*\|^2 \leq \|w - w^*\|^2 - \frac{m^2}{M}$ .
4. Admettant que l'inégalité précédente est aussi valable dans le cas symétrique ( $\mathbf{x} \in C_2$  et mal classé), montrer qu'il y a un nombre fini d'itérations où  $w$  est modifié; en déduire que l'algorithme peut être arrêté au bout d'un nombre fini d'itérations.

---

**Exercice 3 – Alternative algorithmique pour apprendre le perceptron**

---

Nous présentons ici l'algorithme ADALINE (suivant la règle dite de Widrow-Hoff)

---

**Algorithme 2 : Algorithme ADALINE**

---

Entrée :  $\{\mathbf{x}_i, d(\mathbf{x}_i)\}_{i=1,\dots,N}$  ;

Initialisation de  $w$  :  $w(1)$ ;

$t = 1$ ;

**repeat**

**for**  $i = 1, \dots, N$  **do**

$w(t+1) \leftarrow w(t) - \varepsilon (d(\mathbf{x}_i) - \mathbf{x}_i w(t)) \mathbf{x}_i^T$

$t = t + 1$ ;

**until** (*critère d'arrêt satisfait*) ;

---

**Q 3.1** Repérer quelles sont les dimensions des différentes matrices/vecteurs de l'algorithme. Quelles sont les différences entre les deux algorithmes vus dans ce TD ?

**Q 3.2** Montrer que cet algorithme correspond à une descente de gradient. Quelle est la fonction coût minimisée ?

**Q 3.3** Imaginer au moins trois critères distincts pour sortir des boucles while de ces deux algorithmes.