

TD 4

---

**Exercice 1 – Évaluation(s) de l’erreur**


---

**Q 1.1** Rappelez la fonction coût au sens des moindres carrés sur un problème d’apprentissage binaire. Proposer quelques exemples pour montrer que les échantillons correctement classés participent à la fonction coût.

**Q 1.2** En faisant appel à vos connaissances sur le perceptron, proposez une nouvelle fonction coût ne pénalisant que les points mal classés.

**Q 1.3** En imaginant une fonction  $f$  de complexité infinie (capable de modéliser n’importe quelle frontière de décision), tracez à la main la frontière de décision optimale au sens des coûts définis précédemment pour le deux problèmes jouets de la figure 1. Ces frontières sont-elles *intéressantes*? Quels problèmes se posent?




FIGURE 1 – Gaussiennes non séparables linéairement

---

**Exercice 2 – Perceptron**


---

**Q 2.1** Soit  $\mathbf{w} = (2, 1)$  le vecteur de poids d’une séparatrice linéaire. Dessinez cette séparatrice dans le plan. Précisez sur le dessin les quantités  $\langle \mathbf{w}, \mathbf{x} \rangle$  par rapport à un exemple  $\mathbf{x}$  bien classé et mal classé. Que se passe-t-il pour le produit scalaire dans le cas d’un exemple mal classé avec la mise-à-jour  $\mathbf{w} \leftarrow \mathbf{w} + y\mathbf{x}$ ?

**Q 2.2** Comment sont les classifieurs suivants par rapport à celui de la question précédente :  $w^1 = (1, 0.5)$ ,  $w^2 = (200, 100)$ ,  $w^3 = (-2, -1)$ ?

**Q 2.3** Montrez que l’algorithme du perceptron correspond à une descente de gradient. La solution est-elle unique?

**Q 2.4** Quel problème peut-il se poser pour certaines valeurs de  $w$ ? Comment y remédier?

**Q 2.5** Donner un perceptron qui permet de réaliser le AND logique entre les entrées binaires  $x_1$  et  $x_2$  (positif si les deux sont à 1, négatif sinon) et un autre pour le OR logique.

---

**Exercice 3 – Expressivité des séparateurs linéaires**


---

On se place dans l'espace des séparateurs linéaires :  $f(\mathbf{x}_i) = \sum_j x_{ij} w_j$ .

**Q 3.1** Quelle est la dimension du vecteur  $\mathbf{w}$ ? Rappeler l'écriture matricielle de  $f(\mathbf{x}_i)$ . Tracer approximativement les frontières optimales en utilisant un modèle linéaire basique sur la figure de l'exercice 1.

**Q 3.2** Nous allons augmenter l'expressivité du modèle en étendant l'espace de représentation initial dans le cas 2D :  $\mathbf{x} = [x_1, x_2]$ . Soit la transformation  $\phi$  suivante :  $\phi(\mathbf{x}) = [1, x_1, x_2, x_1^2, x_2^2, x_1 x_2]$ , considérons le modèle linéaire  $f(\mathbf{x}_i) = \sum_j \phi_j(\mathbf{x}_i) w_j$ .

- Quelle est la dimension du vecteur  $\mathbf{w}$  dans ce cas ?
- A quoi correspond la projection  $\phi$  ?
- Retracer les frontières de décision optimales sur la figure en utilisant cette nouvelle représentation.
- Pouvons nous retrouver les frontières linéaires de la question précédente dans ce nouvel espace ? Dans l'affirmative, donner les coefficients  $w_j$  associés.

**Q 3.3** Les frontières sont-elles plus *intéressantes* en utilisant la première ou la seconde représentation des données ? Pouvez vous comparer grossièrement l'amplitude de la fonction coût (au sens des moindres carrés par exemple) dans les cas linéaires et quadratiques ? Qu'en déduire ? Sur quel élément vous basez vous pour mesurer la qualité du modèle créé ?

**Q 3.4** Afin d'augmenter l'expressivité de notre classe de séparateur, nous nous tournons vers les représentations gaussiennes. Nous créons une grille de points  $\mathbf{p}^{i,j}$  sur l'espace 2d, puis nous mesurons la similarité gaussienne du point  $\mathbf{x}$  par rapport à chaque point de la grille :  $s(\mathbf{x}, \mathbf{p}^{i,j}) = K e^{-\frac{\|\mathbf{x} - \mathbf{p}^{i,j}\|^2}{\sigma}}$ . La nouvelle représentation de l'exemple est le vecteur contenant pour chaque dimension la similarité de l'exemple à un point de la grille.

- Quelle est la dimension du vecteur  $\mathbf{w}$  ?
- Donnez l'expression littérale de la fonction de décision.
- Quelle est la différence avec l'algorithme des fenêtres de Parzen ?
- Quel rôle joue le paramètre  $\sigma$  ?

**Q 3.5** Introduction (très) pragmatique aux noyaux

- Que se passe-t-il en dimension 3 si nous souhaitons conserver la résolution spatiale du maillage ?
- Afin de palier ce problème, nous proposons d'utiliser la base d'apprentissage à la place de la grille : les points servant de support à la projection seront ceux de l'ensemble d'apprentissage. Exprimer la forme littérale de la fonction de décision dans ce nouveau cadre. Quelle est la nouvelle dimension du paramètre  $\mathbf{w}$  ?
- Que se passe-t-il lorsque  $\sigma$  tend vers 0 ? vers l'infini ? A-t-on besoin de toutes les dimensions de  $w$  ou est-il possible de retrouver la même frontière de décision en limitant le nombre de données d'apprentissage ? A quoi cela correspond-il pour  $\|\mathbf{w}\|$  ?