

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 $\mathbf{w} = (2, 1, 1)$ le vecteur de poids d'une séparatrice linéaire. Dessinez en 2D 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 : $w^1 = (1, 0.5, 0.5)$, $w^2 = (200, 100, 100)$, $w^3 = (-2, -1, -1)$?

Q 2.3 Toujours en 2D, donnez un perceptron qui permet de réaliser le AND logique entre les entrées x_1 et x_2 (positif si les deux sont à 1, négatif sinon) et un autre pour le ET logique.

Q 2.4 Montrez que l'algorithme du perceptron correspond à une descente de gradient. La solution est-elle unique?

Q 2.5 Soit $w_0 = 0$. Exprimer $\|\sum y^i \mathbf{x}^i\|$ en fonction de $w_{t+1} - w_t$ (on ne considérera que les itérations où

il y a effectivement une mise-à-jour); puis en fonction de w_{T+1} la dernière itération; enfin en fonction de $\sqrt{\sum \|\mathbf{w}_t + y_t \mathbf{x}_t\|^2 - \|\mathbf{w}_t\|^2}$. Montrer que cette dernière expression est inférieure à $\sqrt{\sum \|\mathbf{x}_t\|^2}$

Q 2.6 Montrer le théorème de Novikoff : Soit $\mathbf{x}_1, \dots, \mathbf{x}_T$ une séquence de T points, et r tel que $\|\mathbf{x}_t\| \leq r$; s'il existe $\rho > 0$ et \mathbf{w} tels que $\rho \leq \frac{y_i \langle \mathbf{w}, \mathbf{x}_t \rangle}{\|\mathbf{w}\|}$, alors le nombre de mise-à-jour effectuées par l'algorithme du perceptron est borné par r^2/ρ^2 . Vous partirez de $\frac{\mathbf{w} \sum y_t \mathbf{x}_t}{\|\mathbf{w}\|}$.

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 ϕ suivante : $\phi(\mathbf{x}) = [x_1, x_2, x_1^2, x_2^2, x_1 x_2]$, 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?
- 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 avec 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 σ ?

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} ?
- Soit K la matrice regroupant l'ensemble des produits scalaires, donner les dimensions de K . Exprimer la fonction de décision en fonction de K .
- Que se passe-t-il lorsque σ 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 $\|\mathbf{w}\|$?