

TD 5 et 6

Exercice 1 – Support Vector Machine

On considère ici un problème de classification binaire vers $Y = \{-1, +1\}$ de données dans un espace de description $X \in \mathbb{R}^d$. On note $\{(\mathbf{x}^i, y^i) \in (X, Y)\}, i \in \{1, \dots, n\}$ l'ensemble d'apprentissage considéré. La fonction de décision du classifieur considéré est donnée par : $f_{\mathbf{w},b}(\mathbf{x}) = \text{sign}(\mathbf{w}^T \mathbf{x} + b)$.

On considère dans un premier temps un ensemble de données linéairement séparable. Cet ensemble de données et la frontière de décision sont représentés (en 2D) sur la figure 1.

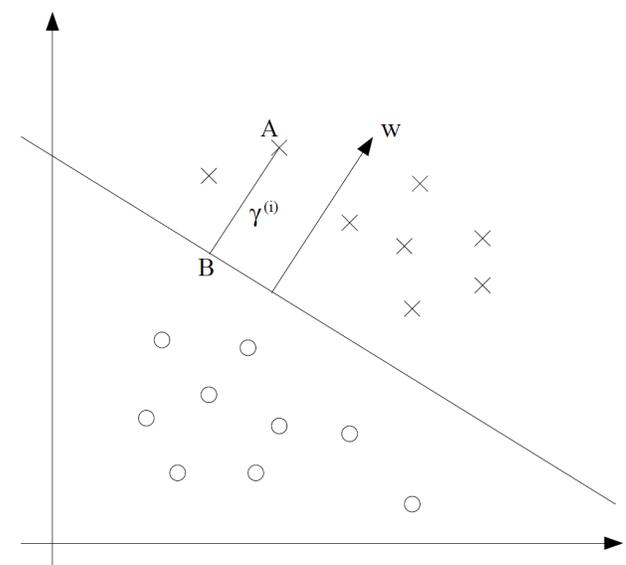


FIGURE 1 – Ensemble de données linéairement séparables

Q 1.1 Marge

Sur cette figure, l'échantillon \mathbf{x}^i et de label y^i est représenté par le point A. On s'intéresse à sa distance signée γ^i à la frontière de décision (dont le point le plus proche est représenté en B sur la figure).

Q 1.1.1 Sachant que $\mathbf{w}/\|\mathbf{w}\|$ est un vecteur unitaire orthogonal à la frontière de décision, donner l'expression de γ^i en fonction de $\mathbf{x}^i, y^i, \mathbf{w}$ et b .

Q 1.1.2 Montrer que la distance et la solution ne change pas en multipliant la solution par un scalaire, i.e. pour $(\alpha\mathbf{w}, \alpha b)$. Que cela implique-t-il si l'on souhaite éloigner au maximum (au sens géométrique) les points de la frontière de décision ?

Q 1.2 Formulation du SVM

On considère alors le problème d'optimisation sous contraintes suivant :

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2$$

$$s.t. \quad y^i (\mathbf{w}^T \mathbf{x}^i + b) \geq 1, \forall i \in \{1, \dots, n\}$$

Q 1.2.1 Pourquoi choisit-on la contrainte ≥ 1 plutôt que ≥ 0 ? Pourquoi 1 ?

Q 1.2.2 Poser le Lagrangien à considérer pour optimiser ce problème sous contraintes

Q 1.2.3 Donner la solution analytique de la minimisation de ce Lagrangien selon \mathbf{w} et b

Q 1.2.4 En déduire une nouvelle formulation “duale” de notre problème d’optimisation sous contraintes

Q 1.2.5 Que cette nouvelle formulation permet-elle ?

Q 1.2.6 Quel est le problème du problème d’optimisation que l’on a considéré ? Proposer une nouvelle formulation qui corrige ce problème

Q 1.2.7 Proposer la formulation duale de ce nouveau problème

Q 1.2.8 Donner la fonction de classification obtenue après optimisation de cette formulation duale du SVM

Q 1.2.9 D’après les conditions de Karush-Kuhn-Tucker (KKT) concernant les propriétés de la solution optimale d’un Lagrangien, on a : $a_i(1 - \xi_i - y^i(\mathbf{w}^T \mathbf{x}^i + b)) = 0$, $\forall i \in \{1..N\}$ et $\beta_i \xi_i = 0$, $\forall i \in \{1..N\}$. Qu’en déduire pour les paramètres a_i obtenus à l’optimum ?

Q 1.2.10 Qu’en déduire pour l’estimation du biais b ?

Exercice 2 – Noyaux

Q 2.1 Montrez que si K et K' sont deux noyaux (i.e. il existe ϕ et ϕ' telles que $K(x, y) = \langle \phi(x), \phi(y) \rangle$, $K'(x, y) = \langle \phi'(x), \phi'(y) \rangle$) :

Q 2.1.1 cK est un noyau pour $c \in \mathbb{R}^+$

Q 2.1.2 $K + K'$ est un noyau ;

Q 2.1.3 KK' est un noyau ;

Q 2.1.4 $(1 + \langle x, x' \rangle)^d$ est un noyau.

Exercice 3 – RKHS

Soit $x_1, \dots, x_n \in X$, une fonction $k : X \times X \rightarrow \mathbb{R}$, la matrice de Gram de K est la matrice $\mathcal{K} := k_{i,j} = k(x_i, x_j)$. Une matrice est dite définie semi-positive si $\forall c_i \in \mathbb{R}, \sum_{i,j} c_i c_j k_{i,j} \geq 0$. Dans ce cas, la fonction est dite également définie positive.

Q 3.1 Exprimez $\sum_{i,j} c_i c_j k_{i,j}$ par un produit scalaire. Montrez qu’un noyau est défini positif.

Q 3.2 Le but de cette question est de montrer la contraposée, qu’une fonction symétrique semi définie positive $k : X \times X \rightarrow \mathbb{R}$ est un noyau. Pour cela, il nous faut trouver un espace hilbertien \mathcal{H} , un produit scalaire $Q : \mathcal{H} \times \mathcal{H} \rightarrow \mathbb{R}$ et une projection $\phi : X \rightarrow \mathcal{H}$ telle que $k(x, y) = Q(\phi(x), \phi(y)) \quad \forall x, y \in X$. On va considérer \mathcal{H} l’espace vectoriel engendré par les fonctions de la forme $y \rightarrow k(y, x)$ pour tout $x \in X$. Un élément de \mathcal{H} est donc une fonction de $X \rightarrow \mathbb{R}$.

Soit $\Phi : X \rightarrow \mathcal{H} := k(\cdot, x)$ un mapping de X aux fonctions de \mathcal{H} , $\Phi(x)(x') = k(x', x)$. Soient $\alpha_i \in \mathbb{R}$, $\beta_i \in \mathbb{R}$, $x_i \in X$, $x'_i \in X$ pour $i \in \{1..n\}$. On définit :

$$f(\cdot) = \sum_{i=1}^n \alpha_i \Phi(x_i)(\cdot), \quad g(\cdot) = \sum_{i=1}^n \beta_i \Phi(x'_i)(\cdot), \quad Q(f, g) = \sum_{i=1}^n \sum_{j=1}^n \alpha_i \beta_j k(x_i, x'_j)$$

f et g sont bien dans \mathcal{H} , vu que ce sont des combinaisons linéaires d’éléments de \mathcal{H} .

Q 3.2.1 Montrez que Q peut s’exprimer uniquement à l’aide des β_j et $f(x'_j)$, ou des α_i et $g(x_i)$

Q 3.2.2 Montrez que $Q(f, g)$ est un produit scalaire de f et g (on pourra alors remplacer $Q(f, g)$ par $\langle f, g \rangle$). Pour cela, il s’agit de démontrer que :

- Q est symétrique

- Q est bilinéaire
- $Q(f, f) \geq 0$ (on montrera dans la dernière question que $Q(f, f) = 0 \iff f = 0$).

Q 3.2.3 Que vaut $Q(k(\cdot, x), f)$? $Q(k(\cdot, x), k(\cdot, x'))$? Justifiez le nom de k : *reproducing kernel*.

Q 3.2.4 En admettant que $Q(f, g)^2 \leq Q(f, f)Q(g, g)$, montrez que $|f(x)|^2 \leq k(x, x)Q(f, f)$.
Concluez.

Exercice 4 – Noyaux sur les chaînes de caractères

Soit S une séquence de mots sur un alphabet \mathcal{A} fini. Montrez que :

1. $K(x, x')$ = nombre de sous-chaînes de longueur 5 que x et x' ont en commun est un noyau ;
2. $K(x, x') = 1$ si x et x' ont au moins une sous-chaîne de longueur 5 en commun, 0 sinon, n'est pas un noyau (indice : considérez 3 chaînes x, x' et x'').