

*Examen du cours Apprentissage Statistique*  
*Masters Math. UPMC – Spécialité Big Data*  
 16/02/2016  
 Durée 2 h  
 Notes de cours autorisées

On dispose d'un ensemble de données non étiquetées, on s'intéresse à construire un système qui réponde « 1 » sur des données proches de cet ensemble d'apprentissage et « -1 » ailleurs. Pensez à un problème de classification où l'on ne dispose que d'exemples positifs et pas d'exemple négatifs.

On considère un ensemble de données  $\{x^1, \dots, x^N\}$ , avec  $x^i \in \mathbb{R}^n$ , on va définir un classifieur à marge qui répond « 1 » dans un voisinage de ces données et « -1 » partout ailleurs.


Pour cela, on va résoudre le problème suivant (pb 1):

$$\min_{w, \rho} \frac{1}{2} \|w\|^2 - \rho$$

sous les contraintes  $w \cdot x^i \geq \rho$

avec  $\rho \in \mathbb{R}$

1. Considérons la figure suivante



1.1. Soit  $H$  l'hyperplan d'équation  $F(x) = w \cdot x - \rho = 0$ . Pour un point  $x$ , on note  $x_p$  sa projection sur l'hyperplan  $H$ . Montrer que la distance de  $x$  à  $H$  s'écrit  $\frac{F(x)}{\|w\|}$ . On pourra par exemple écrire  $x$  sous la forme  $x = x_p + r \frac{w}{\|w\|}$  où  $r$  est la distance recherchée. En déduire que la distance de l'origine à  $H$  vaut  $\frac{|\rho|}{\|w\|}$ .

1.2. La fonction de décision sera  $G(x) = \text{sgn}(F(x))$ . Positionner sur la figure un hyperplan qui résout le problème (pb 1)

1.3. Cet hyperplan est-il unique (justifier) ?

2. Ecrire le Lagrangien  $L(w, \rho, \alpha)$  du problème (pb 1).

3. Calculer les dérivées  $\frac{\partial L}{\partial w_j}$  et  $\frac{\partial L}{\partial \rho}$ .
4. En déduire  $w = \sum_{i=1}^N \alpha_i x_i$  et  $\sum_{i=1}^N \alpha_i = 1$
5. Montrer que la formulation duale du problème (pb 1) s'écrit (pb 2) :

$$\max_{\alpha} \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j x^i \cdot x^j$$

sous les contraintes  $\alpha_i \geq 0$  et  $\sum_{i=1}^N \alpha_i = 1$

6. Montrer qu'à l'optimum, seuls les points pour lesquels  $w \cdot x^i = \rho$  ont un coefficient  $\alpha_i$  non nul.
7. Montrer  $\rho = w \cdot x^i$  pour  $x^i$  vecteur support quelconque.

On va maintenant développer un algorithme pour résoudre le problème (pb 2) .

Considérons que toutes les variables  $\alpha_i$  sont fixées pour  $i = 3..N$ , on va chercher à optimiser  $\alpha_1$  et  $\alpha_2$ .

8. Montrer que le problème de minimisation pour  $\alpha_1, \alpha_2$  peut se re-écrire sous la forme:

$$\max_{\alpha_1, \alpha_2} \frac{1}{2} \sum_{i,j=1}^2 \alpha_i \alpha_j x^i \cdot x^j + \sum_{i=1}^2 \alpha_i C_i + C$$

sous les contraintes  $\alpha_1, \alpha_2 \geq 0$  et  $\sum_{i=1}^2 \alpha_i = R$  avec  $R = 1 - \sum_{j=3}^N \alpha_j$

avec  $C_i = \sum_{j=3}^N \alpha_j x^i \cdot x^j$  et  $C = \sum_{i,j=3}^N \alpha_i \alpha_j x^i \cdot x^j$

9. On note  $Q = \frac{1}{2} \sum_{i,j=1}^2 \alpha_i \alpha_j x^i \cdot x^j + \sum_{i=1}^2 \alpha_i C_i$

Montrer en utilisant les contraintes du problème :

$$Q = \frac{1}{2} (R - \alpha_2)^2 (x^1)^2 + (R - \alpha_2) \alpha_2 x^1 \cdot x^2 + \frac{1}{2} \alpha_2^2 (x^2)^2 + (R - \alpha_2) C_1 + \alpha_2 C_2$$

10. Exprimer la solution  $\alpha_2$  qui minimise  $Q$ , et en déduire  $\alpha_1$  et montrer que ces solutions résolvent  $\min_{\alpha_1, \alpha_2} \frac{1}{2} \sum_{i,j=1}^2 \alpha_i \alpha_j x^i \cdot x^j + \sum_{i=1}^2 \alpha_i C_i + C$ .
11. Proposer la forme générale d'un algorithme pour résoudre le problème (pb 2).
12. Lien avec la classification à deux classes. Supposons que  $(w^*, \rho^*)$  soit une solution du problème (pb 1), montrer que  $(w^*, 0)$  paramétrise l'hyperplan séparateur optimal pour l'ensemble étiqueté  $\{(x^1, 1), \dots, (x^N, 1), (-x^1, -1), \dots, (-x^N, -1)\}$ .