

## Machine Learning TD1

1. Considérons 2 variables binaires  $X_1$  et  $X_2$ . Le tableau 1 décrit les lois jointes  $P(X_1, X_2)$  et conditionnelles  $P(Y = 1|X_1, X_2)$  :

$X_1$	$X_2$	$P(X_1, X_2)$	$P(Y = 1 X_1, X_2)$
0	0	0.3	0.6
0	1	0.3	0.2
1	0	0.2	0.4
1	1	0.2	0.8

TABLE 1 – Distribution  $P(Y, X_1, X_2)$

- Quel est le classifieur "Bayes optimal"  $f^*(x_1, x_2)$  de  $y$ ? Que vaut son erreur de généralisation?
  - Construire un classifieur naïf de Bayes et calculer son erreur de généralisation. Comparez-le à  $f^*$ .
  - Construire un arbre de décision de niveau 1 (avec le gain de gini) et calculer son erreur de généralisation. Comparez-le à  $f^*$ .
  - Construire un échantillon de 10 exemples par un procédé de tirage aléatoire que vous explicitez. Quelle est sa log vraisemblance d'après le vrai modèle? Construire un classifieur naïf de Bayes et un arbre de décision de niveau 1. Comparez les performances avec les précédentes. Conclure.
2. Quelle est l'entropie d'une variable aléatoire gaussienne?
  3. On cherche à caractériser la fonction  $f^*(\cdot)$  à valeur continue dans  $[0, 1]$  qui minimise l'espérance de la fonction coût  $l(Y, f(X)) = |Y - f(X)|^q$  en fonction de  $q$ . Caractériser la solution pour  $q = 2$  et  $q = 1$  dans le cas discret et continu.
  4. On pose  $L_{ij}$  le coût lorsqu'on assigne  $x$  à  $\mathcal{C}_j$  alors que  $x \in \mathcal{C}_i$ .
    - Exprimer la classe optimale  $\mathcal{C}_i$  de  $x$  en fonction des  $p(\mathcal{C}_j|x)$  et des  $L_{ij}$ .
    - Dans le cas de deux classes,  $\mathcal{C}_0$  et  $\mathcal{C}_1$ . On pose  $p = p(\mathcal{C}_1|x)$ , trouver le seuil de décision optimal  $p^*$  en fonction des  $L_{ij}$ .
  5. Dans le tableau 2 figurent les résultats d'un classifieur multi-label sur une base de test.
    - Quelles sont les fonctions de coût que l'on peut proposer pour quantifier les erreurs de prédictions en apprentissage multi-label?
    - Comment se généralisent le rappel, la précision et la F-mesure au cas multi-label? Faire l'application numérique à partir du tableau 2.

$Y_1$	1	0	1	1
$Y_2$	1	1	0	1
$\hat{Y}_1$	0	0	1	1
$\hat{Y}_2$	1	1	1	0

TABLE 2 – Prédiction obtenues sur la base de test

- Dans le tableau 3, figurent les probabilités conditionnelles  $P(Y_1, Y_2|X)$  estimées par un classifieur probabiliste multilabel pour un  $X$  donné.

$Y_1$	$Y_2$	$\hat{P}(Y_1, Y_2 X)$
0	0	0.25
0	1	0.30
1	0	0.27
1	1	0.18

TABLE 3 – Estimation de  $P(Y_1, Y_2|X)$  par un classifieur probabiliste multilabel.

- Calculer la prédiction optimale avec le *Hamming loss*, le *zero-one loss*, le rappel, la précision et la F-mesure.
  - Montrer que la solution qui minimise le *Hamming loss* ne dépend que des marginales  $P(Y_j|X)$ . En déduire une procédure simple d'apprentissage multilabel pour minimiser le *Hamming loss*.
6. Dans le tableau ci-dessous figurent les prédictions (ordonnées) d'un classifieur probabiliste avec les valeurs binaires cibles sur un jeu de test.
- Calculer le *rank loss*, la précision, le rappel, la F-mesure.
  - Dessiner la courbe ROC associée à ces prédictions répétées. Que vaut l'AUC?
  - Si le coût de se tromper sur un exemple positif est 2 fois plus élevé que sur un exemple négatif, quels sont les seuils qui minimisent le coût moyen sur ce jeu de test?

True $Y$	1	1	0	1	0	1	0	1	0	0
$\hat{P}(Y = 1   X)$	1.0	0.9	0.8	0.7	0.6	0.5	0.4	0.3	0.2	0.1

TABLE 4 – Prédiction d'un classifieur probabiliste sur une base de test.