

Mastère M2 MVA 2009/2010 - Modèles graphiques

Exercices à rendre pour le 21 Octobre 2009.

Ces exercices peuvent s'effectuer par groupe de deux élèves.

1 Apprentissage dans les modèles discrets

On considère le modèle suivant où z et x sont des variables discrètes pouvant prendre respectivement M et K valeurs : $p(z = m) = \pi_m$, $p(x = k|z = m) = \theta_{mk}$.

Calculer l'estimateur du maximum de vraisemblance de π et θ à partir de données i.i.d.

2 Classification linéaire

Les fichiers `classificationA.train`, `classificationB.train` et `classificationC.train` contiennent des ensembles de données (x_n, y_n) où $x_n \in \mathbb{R}^2$ et $y_n \in \{0, 1\}$ (chaque ligne est composée des 2 composantes de x_n puis de y_n). Le but de cet exercice est d'implémenter les méthodes de classification linéaire et de les tester sur ces 3 jeux de données. Le langage de programmation est libre (MATLAB, Octave, Scilab ou R sont néanmoins recommandés). Le code source doit être remis avec les résultats.

1. Modèle génératif (LDA). Etant donnée la classe, les données sont normales avec des moyennes différentes et la même matrice de covariance :

$$y \sim \text{Bernoulli}(\pi), \quad x|y = i \sim \text{Normale}(\mu_i, \Sigma).$$

Calculer et implémenter le maximum de vraisemblance pour ce modèle et l'appliquer aux données. Représenter graphiquement les données ainsi que la droite définie par

$$p(y = 1|x) = 0.5$$

Indication : le modèle a été vu en cours mais pas le calcul du maximum de vraisemblance. On pourra s'inspirer de la Section 7.2 du polycopié (qui traite le cas où Σ est diagonale).

2. Régression logistique : implémenter la régression logistique en utilisant l'algorithme IRLS (Newton-Raphson) décrit en cours et dans le polycopié (ne pas oublier le terme constant). Représenter graphiquement les données ainsi que la droite définie par

$$p(y = 1|x) = 0.5$$

3. Régression lineaire : en considérant la classe y comme variable réelle prenant les valeurs 0 et 1, implémenter la regression linéaire par résolution de l'équation normale. Représenter graphiquement les données ainsi que la droite pour laquelle la fonction de regression vaut 0.5.
4. Les données contenues dans les fichiers `classificationA.test`, `classificationB.test` et `classificationC.test` ont respectivement été générées par la même distribution que les données dans les fichiers `classificationA.train`, `classificationB.train` et `classificationC.train`. Tester les différents modèles sur ces données en calculant le taux d'erreur, et comparer/commenter les résultats pour les trois jeux de données.
5. BONUS : Modèle génératif (QDA). Etant donnée la classe, les données sont normales avec des moyennes et des matrices de covariance différentes :

$$y \sim \text{Bernoulli}(\pi), \quad x|y = i \sim \text{Normale}(\mu_i, \Sigma_i).$$

Implémenter le maximum de vraisemblance pour ce modèle et l'appliquer aux données. Représenter graphiquement les données ainsi que la conique définie par

$$p(y = 1|x) = 0.5$$