



Partiel avec documents autorisés

1) Règle de décision Bayésienne

- On considère un problème de classification à deux classes  $C_0$  et  $C_1$  de probabilités a priori  $\pi_0 = P(C_0)$  et  $\pi_1 = P(C_1)$ . On suppose que les vecteurs de données à classifier sont des éléments de  $\mathbb{R}^n$ . On note  $x = [x(1), \dots, x(n)]^T$  un vecteur à classifier et  $z \in \{-1, 1\}$  une étiquette indiquant la classe de ce vecteur  $x$  ( $z = -1$  si  $x \in C_0$  et  $z = 1$  si  $x \in C_1$ ). On suppose que les densités de  $x$  conditionnellement aux classes  $C_0$  et  $C_1$  sont gaussiennes de moyennes  $\mu_0$  et  $\mu_1$  (avec  $\mu_0 \neq \mu_1$ ) et de même matrice de covariance  $\Sigma$ .

– Déterminer la probabilité a posteriori  $P(C_1|x)$  et montrer qu'elle peut s'écrire

$$P(z = 1|x) = P(C_1|x) = \frac{1}{1 + \exp(-x^T\beta - \beta_0)}$$

où  $\beta = (\beta_1, \dots, \beta_n)^T$  est un vecteur de  $\mathbb{R}^n$  et  $\beta_0$  un scalaire que l'on donnera en fonction de  $\mu_0, \mu_1, \pi_0$  et  $\pi_1$ . Déterminer de la même façon  $P(z = -1|x) = P(C_0|x)$ . En déduire

$$P(z = \varepsilon|x) = \frac{1}{1 + \exp[-\varepsilon(x^T\beta + \beta_0)]}, \quad \varepsilon \in \{-1, 1\}.$$

On notera  $P(\varepsilon|x) = P(z = \varepsilon|x)$  dans ce qui suit.

- Les auteurs de l'article posent  $P_1 = P(z = 1|x)$  (notation que l'on pourrait critiquer car  $P_1$  dépend de  $x$ !). Montrer que l'équation (1) de l'article est correcte.
- En utilisant l'expression de  $P(z = \pm 1|x)$  donnée ci-dessus, déterminer la règle de décision Bayésienne associée à ce problème (en fonction de  $\beta$  et  $\beta_0$ ) dans le cas où les deux classes  $C_0$  et  $C_1$  sont équiprobables et pour des fonctions de coût  $c_{ij} = 1 - \delta_{ij}$ . Représenter les régions associées aux décisions  $d^*(x) = C_0$  et  $d^*(x) = C_1$  dans le cas particulier  $n = 2$  (i.e.  $x = (x_1, x_2)^T$ ).
- Montrer que la loi de  $T(x) = x^T\beta + \beta_0$  conditionnellement à la classe  $C_0$  est une loi normale dont on déterminera les paramètres  $m_0$  et  $\sigma^2$  en fonction de  $\beta, \beta_0, \mu_0$  et  $\Sigma$  (i.e.  $T(x)|C_0 \sim \mathcal{N}(m_0, \sigma^2)$ ). Montrer que la loi de  $T(x) = x^T\beta + \beta_0$  conditionnellement à la classe  $C_1$  est une loi normale  $\mathcal{N}(m_1, \sigma^2)$  où on précisera la valeur de  $m_1$  en fonction de  $\beta, \beta_0$  et  $\mu$ . Montrer enfin que  $m_1 = -m_0$  (on supposera dans la suite  $m_1 > 0$  et  $m_0 < 0$ )

En déduire que la probabilité d'erreur du classifieur Bayésien s'écrit

$$P_e = F\left(\frac{m_0}{\sigma}\right) = F\left(-\frac{m_1}{\sigma}\right) \text{ avec } F(u) = \int_{-\infty}^u \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) dx$$

Que se passe-t-il lorsque  $\sigma \rightarrow 0$  ?

## 2) Apprentissage

On désire estimer  $\beta$  et  $\beta_0$  à l'aide d'une base d'apprentissage constituée de  $p$  vecteurs  $x_1, \dots, x_p$  de  $\mathbb{R}^n$  dont les classes sont connues. Chaque vecteur  $x_i$  est muni d'une étiquette  $z_i \in \{-1, 1\}$  telle que

$$P(z_i | x_i) = \frac{1}{1 + \exp[-z_i (x_i^T \beta + \beta_0)]}, \quad z_i \in \{-1, 1\}$$

- En supposant que les étiquettes  $z_1, \dots, z_p$  sont indépendantes conditionnellement à  $x_1, \dots, x_p$ , déterminer

$$g(\beta, \beta_0) = \ln P(z_1, \dots, z_p | x_1, \dots, x_p)$$

- Déterminer le système de  $n + 1$  équations à  $n + 1$  inconnues que l'on doit résoudre pour déterminer  $\beta$  et  $\beta_0$  qui maximisent  $g(\beta, \beta_0)$ .
- Comment peut-on en pratique déterminer  $\beta$  et  $\beta_0$  ?

## 3) Perceptron Multi-couches

Dans la partie 2.5, les auteurs proposent d'utiliser un perceptron multi-couches pour la classification des signaux EEG issus de patients normaux ou épileptiques.

- Quelle est la structure du perceptron proposée dans cet article (on définira avec soin le nombre et la nature des entrées du réseau, le nombre de couches et de noeuds par couche, ainsi que la sortie désirée du réseau pour chaque classe).
- On suppose dans la suite que les non-linéarités du réseau sont des fonctions sigmoïdales définies par

$$f(x) = \frac{1}{1 + e^{-\alpha x}}$$

avec  $\alpha > 0$ . Donner les règles de mise à jour des poids du réseau issues de la règle du gradient (on notera  $u_1, \dots, u_m, a$  les poids et le biais de la dernière couche et  $w_{i,j}$  et  $b_j$  les poids et les biais de la première couche).

## 4) Questions diverses sur l'article

- Comment les auteurs de l'article motivent-ils l'utilisation de la transformée en ondelettes pour détecter les EEG issus de patients épileptiques (plutôt par exemple que d'utiliser le spectre des signaux EEG) ?
- A quoi correspondent les quatre signaux représentés sur les figures 1 ?
- Comment peut-on déterminer  $A_i$  à partir de  $A_{i+1}$  et  $D_{i+1}$  sur la figure 3 ?
- Comment les auteurs ont-ils procédé pour déterminer le nombre de noeuds du perceptron représenté sur la figure 5 ?
- À plusieurs reprises, les auteurs parlent de l'algorithme "Backpropagation". De quel algorithme s'agit-il ?
- p. 95, les auteurs parlent de "Receiver operating characteristic (ROC) analysis". De quoi s'agit-il ?