

TP6 : Bayésien naïf

Exercice 1. Objectifs :

- Découvrir les fonctions R qui font du Bayésien naïf.
- Comparer les performances du Bayésien naïf au LDA et au QDA sur les données "Desbois".

Dans R, la méthode du Bayésien naïf est implémentée dans le package `e1071` avec la fonction `naiveBayes` et dans le package `klaR` avec la fonction `NaiveBayes`. La fonction du package `klaR` implémente en plus l'estimation non paramétrique de densité (à noyau) pour les variables d'entrée quantitatives.

1. Exectuez pas à pas le code ci-dessous et commentez le.

```
library(e1071)
## Données d'entrée binaires
data(HouseVotes84, package = "mlbench")
?mlbench::HouseVotes84
g <- naiveBayes(Class ~ ., data = HouseVotes84)
g$apriori
g$tables
predict(g, HouseVotes84[1,])
predict(g, HouseVotes84[1,], type = "raw")
pred <- predict(g, HouseVotes84)
table(pred, HouseVotes84$class)


# Données d'entrée quantitatives
data(iris)
g <- naiveBayes(Species ~ ., data = iris)
## ou encore:
#m <- naiveBayes(iris[, -5], iris[, 5])
g$apriori
g$tables
table(predict(g, iris), iris[, 5])

library(klaR)
?NaiveBayes
m <- NaiveBayes(Species ~ ., data = iris)
names(predict(m))
table(predict(m)$class, iris[, 5])

m2 <- NaiveBayes(Species ~ ., data = iris, usekernel=TRUE)
names(predict(m2))
table(predict(m2)$class, iris[, 5])
```

2. Reprendre les données "Desbois" de l'exercice 3 de la feuille de TP5 et ajouter la méthode Bayésien naïf aux boxplots de la question 5.

```
## Le chargement a nécessité le package : MASS
```



Exercice 2. (à rendre) Objectif : Implémenter le Bayésien naïf pour des données d'entrées quantitatives.

On considère le jeu de données d'apprentissage habituel dispose de 100 données d'apprentissage. On note X^1 et X^2 les deux coordonnées de X . On rappelle que le bayésien naïf est une approche indirecte où l'on fait l'hypothèse d'indépendance des variables d'entrée conditionnellement à Y :

$$\forall x \in \mathbb{R}^2, \forall k \in \{1, 2\} \quad f_k(x) = f_{k,1}(x_1)f_{k,2}(x_2)$$

où f_k est la densité conditionnelle de X sachant $\{Y = k\}$, et $f_{k,1}$ et $f_{k,2}$ sont les densités conditionnelles respectivement de X^1 et X^2 sachant $\{Y = k\}$. De plus on suppose que pour tout $k \in \{1, 2\}$ et tout $j \in \{1, 2\}$ la loi de X^j sachant $\{Y = k\}$ est $\mathcal{N}(\mu_{kj}, \sigma_{kj}^2)$.

1. Donner les estimateurs du maximum de vraisemblance de tous les paramètres du bayésien naïf considéré.
2. Ecrire la règle de décision associée.
3. Charger le jeu de données dans R. Transformer la variable de sortie y en facteur.

```
train <- read.table(file="../data/synth_train.txt", header=TRUE)
dim(train)

## [1] 100 3

train$y <- as.factor(train$y)
```

4. Implémenter la méthode du bayésien naïf.

- (a) On pourra commencer par créer une fonction `bn_estim` qui prend en argument les données et calcul les estimateurs des différents paramètres associés à la modélisation du bayésien naïf.
- (b) Puis, on pourra écrire une fonction `bn_predict` permettant de prédire la classe associée à une observation x (cette fonction utilisera les paramètres estimés par la fonction précédente).

5. Tester les fonctions : appliquer la fonction `bn_estim` avec l'échantillon d'apprentissage, puis utiliser la fonction `bn_predict` pour prédire les points de coordonnées $(0, 1)$ et $(-2, 2)$.

```
## [1] 2 1
```

6. Calculer le taux d'erreur d'apprentissage du bayésien naïf.

```
## [1] 0.09
```

7. Charger le jeu de données test `synth_test.txt` puis calculer le taux d'erreur test du bayésien naïf.

```
test <- read.table(file="../data/synth_test.txt", header=TRUE)
dim(test)
```

```
## [1] 200 3
```

```
## [1] 0.07
```