

Examen final

Durée 2h - Sans document, sans matériel - 6 novembre 2019

Exercice 1 (2 pts) Expliquer clairement comment l'on peut évaluer le taux d'erreur associé à un classifieur résultant d'une forêt aléatoire.

Exercice 2 (8 pts) Soit Y un facteur binaire à expliquer, $Y \in \{0, 1\}$ et $X > 0$ une variable explicative réelle positive. Nous supposons que $\mathbb{P}(Y = 0) = \mathbb{P}(Y = 1) = 1/2$ et

$$X|Y = 0 \sim f_0(x) = \frac{1}{4} \exp\left(-\frac{x}{4}\right) \mathbb{I}_{x>0}$$

$$X|Y = 1 \sim f_1(x) = \exp(-x) \mathbb{I}_{x>0}.$$

- 1) (1 pt) Donner la loi de $Y|X = x$.
- 2) (2 pts) Expliciter le classifieur optimal g^1 associé à la fonction de coût élémentaire $h_1(y, d) = \mathbb{I}_{y \neq d}$.
- 3) (1 pt) Un classifieur alternatif g^0 consiste à affecter à la classe 0 si $x > 2.5$ et à la classe 1 sinon. Expliquer sa logique de construction.
- 4) (2 pts) Comparer g^1 et g^0 pour un critère bien choisi.
- 5) (2 pts) On considère maintenant la fonction de coût élémentaire h_2 telle que

$$h_2(y, d) = \begin{cases} 0 & \text{si } y = d \\ 2 & \text{si } y = 1 \text{ et } d = 0 \\ 1 & \text{si } y = 0 \text{ et } d = 1 \end{cases}.$$

Expliciter le classifieur optimal g^2 associé à h_2 , discuter de la modification induite par un changement de fonction de coût.

Exercice 3 (4 pts) Le principe général du boosting consiste à construire une famille d'estimateurs qui sont ensuite agrégés par une moyenne pondérée des estimations (en régression) ou un vote à la majorité (en classification). Les estimateurs sont construits de manière récursive : chaque estimateur est une version adaptative du précédent en donnant plus de poids aux observations mal ajustées ou mal prédites. L'estimateur construit à l'étape k concentrera donc ses efforts sur les observations mal ajustées par l'estimateur à l'étape $k - 1$.

L'algorithme adaboost développé par Freund et Schapire (1997) est le plus populaire dans la famille des algorithmes boosting. On désigne par $g(x)$ une règle de classification faible. Par faible, nous entendons une règle dont le taux d'erreur est légèrement meilleur que celui d'une règle purement aléatoire. L'idée consiste à appliquer cette règle plusieurs fois en affectant judicieusement un poids différent aux observations à chaque itération.

On se place dans le contexte de la classification supervisée binaire. On dispose d'un échantillon d'apprentissage $D_n = \{(x_1, y_1), \dots, (x_n, y_n)\}$ et d'une règle faible qui peut s'appliquer à un échantillon pondéré (par exemple les arbres CART).

Algorithme adaboost

1. Initialiser les poids $w_i = 1/n$ pour tout $i \in \{1, \dots, n\}$
2. Pour l de 1 à L
 - (a) Ajuster la règle faible sur l'échantillon D_n pondéré par les poids w_1, \dots, w_n on note $g_l(x)$ le classifieur issu de cet ajustement

- (b) Calculer

$$e_l = \frac{\sum_{i=1}^n w_i \mathbb{I}_{y_i \neq g_l(x_i)}}{\sum_{i=1}^n w_i}$$

- (c) Calculer

$$\alpha_l = \log \left(\frac{1 - e_l}{e_l} \right)$$

- (d) Réajuster les poids

$$w_i = w_i \exp(\alpha_l \mathbb{I}_{y_i \neq g_l(x_i)})$$

Notons que la règle est faible mais respecte tout de même le fait que $e_m < 1/2$. Une fois terminées les itérations de l'algorithme adaboost l'observation x à prévoir est affectée à la classe 0 si $\sum_{l=1}^L \alpha_l g_l(x) < 1/2$ et à la classe 1 sinon.

Analyser et commenter cette procédure.

Exercice 4

1 (2 pts) On se place dans le contexte d'un problème de reconnaissance des chiffres manuscrits à partir d'image 28×28 . Deux modèles implémentés en utilisant la bibliothèque `keras` de `Python` sont mis en oeuvre. On peut accéder à une description des modèles en utilisant l'attribut `summary()`. On obtient les résultats donnés à la page suivante.

Layer (type)	Output Shape	Param #
flatten (Flatten)	(None, 784)	0
dense (Dense)	(None, 512)	401920
dense (Dense)	(None, 512)	262656
dropout (Dropout)	(None, 512)	0
dense (Dense)	(None, 10)	5130

Total params: 669,706
 Trainable params: 669,706
 Non-trainable params: 0

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 28, 28, 6)	60
max_pooling2d (MaxPooling)	(None, 14, 14, 6)	0
dropout (Dropout)	(None, 14, 14, 6)	0
conv2d (Conv2D)	(None, 14, 14, 8)	440
max_pooling2d (MaxPooling)	(None, 7, 7, 8)	0
dropout (Dropout)	(None, 7, 7, 8)	0
flatten (Flatten)	(None, 392)	0
dense (Dense)	(None, 30)	11790
dropout (Dropout)	(None, 30)	0
dense (Dense)	(None, 10)	310

Total params: 12,600
 Trainable params: 12,600
 Non-trainable params: 0

Décrire clairement les modèles proposés.

(1)

Correction examen
final HPPA 303
06/11/2019

Exercice 1

On utilise l'arbre Out-Of-Bay

Exercice 2

$$1] P(Y=1|X=\kappa) = \left[\frac{e^{-\kappa}}{e^{-\kappa} + \frac{1}{4} e^{-\frac{\kappa}{4}}} \right]$$

2] Le classifieur optimal
- consiste à choisir la

- classe 1 si $P(Y=1|X=\kappa) \geq \frac{1}{2}$

$$\Leftrightarrow e^{-\kappa} \geq \frac{1}{2} \left[e^{-\kappa} + \frac{1}{4} e^{-\frac{\kappa}{4}} \right]$$

$$\Leftrightarrow \kappa \leq \frac{4}{3} \log(4)$$

3] $g^0(x)$ choisit la classe (2)
dont la valeur de x
est la plus proche de
sa moyenne.

$$\begin{aligned} 4] C(g^0) &= \mathbb{P}(Y \neq g^0(X)) \\ &= \mathbb{P}(Y=1 \wedge X \geq \frac{4}{3} \log(4)) \\ &\quad + \mathbb{P}(Y=0 \wedge X < \frac{4}{3} \log(4)) \\ &= \left(\frac{1}{2}\right) \int_{\frac{4}{3} \log(4)}^{\infty} e^{-x} dx \\ &\quad + \left(\frac{1}{2}\right) \int_0^{\frac{4}{3} \log(4)} \frac{1}{4} e^{-\frac{x}{4}} dx \\ &= \frac{1}{2} \left(e^{-\frac{4}{3} \log(4)} + 1 - e^{-\frac{1}{3} \log(4)} \right) \end{aligned}$$

$$C(g^2) = \frac{1}{2} \left(e^{-\frac{5}{2}} + 1 + e^{-\frac{5}{8}} \right)$$

5] On choisit la
classe 1 si

(3)

$$P(Y=1 | X=x) \geq \frac{1}{3}$$

$$\Leftrightarrow e^{-x} \geq \frac{1}{3} \left(e^{-x} + \frac{1}{4} e^{-\frac{x}{4}} \right)$$

$$\Leftrightarrow x \leq \frac{4}{3} \log(8)$$

Comme $\log(8) > \log(4)$

on choisit dans ce cas
plus fréquemment la

classe 1. En effet, c'est

deux fois plus sûr que

ici et toujours lorsque

la classe 1 est vraie.