

## Modèle linéaire et modèles dérivés, partie 2 : session 2

### Exercice 1

On se place dans le modèle linéaire généralisé inverse gaussien avec lien canonique. La loi inverse gaussienne de paramètres  $\lambda > 0$  et  $\mu > 0$  notée  $IG(\mu, \lambda)$  a pour densité

$$f_{\mu,\lambda}(y) = \sqrt{\frac{\lambda}{2\pi y^3}} \exp -\frac{\lambda(y - \mu)^2}{2\mu^2 y}$$

sur  $\mathbb{R}_+$ .

1. Écrire cette densité sous la forme d'une densité de la famille exponentielle paramétrée, comme dans le cours, par  $\theta$  et  $\phi$ .
2. Écrire  $\theta$  et  $\phi$  en fonction de  $\lambda$  et  $\mu$ . Que valent  $\mathbb{E}(Y)$  et  $\mathbb{V}(Y)$  quand  $Y$  a la loi  $IG(\mu, \lambda)$ ?
3. Quel est le lien canonique dans ce modèle ? On notera  $\beta$  le paramètre de régression.
4. On dispose d'un échantillon  $(X_i, Y_i)_{i=1, \dots, n}$  dans ce modèle. Quelle équation vérifie l'estimateur au maximum de vraisemblance  $\hat{\beta}$  ?
5. Quelle est la loi asymptotique de  $\sqrt{n}(\hat{\beta} - \beta)$
6. Donner la forme des résidus de déviance dans ce modèle.
7. Proposer un estimateur de  $\phi$ .

### Exercice 2

1. On considère un problème de classification avec pour  $i = 1, \dots, n$

- des features  $X_i \in \mathbb{R}^d$
- des labels  $Y_i \in \{-1, 1\}$

et un ensemble de "weak learners"  $\mathcal{H} = \{h_1, \dots, h_L\}$  où chaque  $h_l : \mathbb{R}^d \rightarrow \{-1, 1\}$  est un learner très simple

On va procéder par boosting, c'est-à-dire en combinant additivement des weak learners

$$g^{(B)}(x) = \sum_{b=1}^B \eta^{(b)} h^{(b)}(x)$$

avec  $\eta^{(b)} \geq 0$  pour espérer en obtenir un meilleur. L'algorithme de boosting le plus connu en classification est AdaBoost (ADAPtive BOOSTing) dont le pseudo-code est

---

**Algorithm 1** Adaboost

---

1: Posons  $p^1(i) = 1/n$  pour  $i = 1, \dots, n$   
2: **for**  $b = 1, \dots, B$  **do**  
3:  $h^{(b)} \in \operatorname{argmin}_{h \in \mathcal{H}} \sum_{i=1}^n p^{(b)}(i) \mathbb{1}_{Y_i h(X_i) < 0}$   
4:  $\varepsilon^{(b)} \leftarrow \sum_{i=1}^n p^{(b)}(i) \mathbb{1}_{Y_i h^{(b)}(X_i) < 0}$   
5:  $\eta^{(b)} \leftarrow \frac{1}{2} \log \left( \frac{1 - \varepsilon^{(b)}}{\varepsilon^{(b)}} \right)$   
6:  $Z^{(b)} \leftarrow 2\sqrt{\varepsilon^{(b)}(1 - \varepsilon^{(b)})}$   
7:  $p^{(b+1)}(i) \leftarrow p^{(b)}(i) \frac{e^{-\eta^{(b)} Y_i h^{(b)}(X_i)}}{Z^{(b)}}$   
8: **end for**  
9: **return** Un boosting classifieur  $g^{(B)}(x) = \sum_{b=1}^B \eta^{(b)} h^{(b)}(x)$ .

---

On veut montrer que c'est équivalent à optimiser la perte exponentielle

$$\exp(-yu).$$

- (a) (Question préliminaire) Pour un classifieur donné  $h \in \mathcal{H}$ , montrer que, pour tout  $i = 1, \dots, n$ , on a  $Y_i h(X_i) \in \{-1, 1\}$ . Puis montrer que  $\varepsilon^{(b)}$  défini à la ligne 4 de l'algorithme s'écrit aussi

$$\varepsilon^{(b)} = 1 - \sum_{i: Y_i h(X_i) = 1} p^{(b)}(i).$$

- (b) A l'itération  $b + 1$ , on cherche  $\eta^{(b+1)}$  et  $h^{(b+1)}$  définis par

$$h^{(b+1)}, \eta^{(b+1)} = \operatorname{argmin}_{h \in \mathcal{H}, \eta \geq 0} L_n \left( (Y_1, X_1), \dots, (Y_n, X_n); h, \eta \right)$$

avec

$$L_n \left( (Y_1, X_1), \dots, (Y_n, X_n); h, \eta \right) = \sum_{i=1}^n \exp \left( - Y_i (g^{(b)}(X_i) + \eta h(X_i)) \right).$$

Donner la forme des poids  $w_i^{(b+1)}$  qui vérifient

$$\sum_{i=1}^n \exp \left( - Y_i (g^{(b)}(X_i) + \eta h(X_i)) \right) = \sum_{i=1}^n w_i^{(b+1)} \exp \left( - Y_i \eta h(X_i) \right).$$

Puis montrer que

$$h^{(b+1)}, \eta^{(b+1)} = \operatorname{argmin}_{h \in \mathcal{H}, \eta \geq 0} \sum_{i=1}^n \frac{w_i^{(b+1)}}{\sum_{i=1}^n w_i^{(b+1)}} \exp \left( - Y_i \eta h(X_i) \right).$$

On note, pour la suite,

$$\pi_i^{(b+1)} = \frac{w_i^{(b+1)}}{\sum_{i=1}^n w_i^{(b+1)}}.$$

- (c) Montrer que

$$\sum_{i=1}^n \pi_i^{(b+1)} \exp \left( - Y_i \eta h(X_i) \right) = \sum_{i=1}^n \pi_i^{(b+1)} \exp(-\eta) + \sum_{i: Y_i h(X_i) = -1} \pi_i^{(b+1)} \left( \exp(\eta) - \exp(-\eta) \right).$$

En déduire que, si  $\pi_i^{(b+1)} = p_i^{(b+1)}$  pour tout  $i$ , alors, pour tout  $\eta > 0$  :

$$\operatorname{argmin}_{h \in \mathcal{H}} \sum_{i=1}^n \pi_i^{(b+1)} \exp \left( - Y_i \eta h(X_i) \right)$$

est égal à  $h^{(b+1)}$  défini à la ligne 3 de l'algorithme.

(d) On fixe donc  $h = h^{(b+1)}$ , solution du problème précédent. Optimiser en  $\eta$

$$\sum_{i=1}^n \pi_i^{(b+1)} \exp \left( - Y_i \eta h^{(b+1)}(X_i) \right)$$

Montrer ensuite que, si  $\pi_i^{(b+1)} = p_i^{(b+1)}$ , la solution se réécrit comme  $\eta^{(b+1)}$ , défini à la ligne 5 de l'algorithme.

(e) Montrer que

$$\pi_i^{(b+1)} = \frac{w_i^{(b+1)}}{\sum_{i=1}^n w_i^{(b+1)}} = \pi_i^{(b)} \frac{\exp \left( - \eta^{(b)} Y_i h^{(b)}(X_i) \right)}{C^{(b)}}$$

où  $C^{(b)}$  est une constante de normalisation. Montrer que  $\sum_{i=1}^n \pi_i^{(b+1)} = 1$  et que c'est équivalent à

$$C^{(b)} = \sum_{i=1}^n \pi_i^{(b)} \exp \left( - \eta^{(b)} Y_i h^{(b)}(X_i) \right)$$

puis que  $C^{(b)} = Z^{(b)}$ , défini à la ligne 6 de l'algorithme. Conclure.

2. Nous considérons désormais une variante au problème de classification précédent dans laquelle les labels  $Y_i$  prennent leurs valeurs dans  $\{-1, 0, 1\}$ . Cela peut par exemple correspondre aux cas où le vrai label n'est pas observé et dans ce cas le label est mis à 0. Comme pour l'algorithme en classification classique, on se considère la perte  $0/1 \mathbb{1}_{y \neq u}$  et son approximation par la perte exponentielle. Proposer un algorithme de boosting dans ce cas en justifiant comme dans la question précédente toutes les étapes de l'algorithme.