

# EXAMEN 2019 - 2020

## (3 HEURES – DOCUMENTS NON AUTORISÉS)

**Exercice 1 (Régression avec features orthogonales, 8pts)**

On considère une matrice (déterministe)  $\mathbf{X} = [X_i^j]_{1 \leq i \leq n, 1 \leq j \leq d}$  de taille  $n \times d$  dont les  $d$  colonnes  $X^j \in \mathbb{R}^n$  sont des vecteurs non nuls et deux à deux orthogonaux. On note  $\delta_j = \|X^j\|$  les normes euclidiennes des  $d$  colonnes de  $\mathbf{X}$  et  $\delta^{-2} = \sum_{j=1}^d \delta_j^{-2}$ . On suppose  $n > d \geq 2$ . On observe un vecteur aléatoire  $Y \in \mathbb{R}^n$  donné par  $Y = \mathbf{X}\beta + \varepsilon$  où  $\beta \in \mathbb{R}^d$  est un vecteur de paramètres inconnus et  $\varepsilon \in \mathbb{R}^n \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$  où  $\mathbf{I}$  est la matrice identité dans  $\mathbb{R}^n$  avec  $\sigma^2 > 0$  inconnu également.

1. (1pt) Explicitez les estimateurs des moindres carrés  $\widehat{\beta}$  et  $\widehat{\sigma}^2$  de  $\beta$  et  $\sigma^2$  respectivement, rappelez leurs lois et rappelez rapidement pourquoi ils sont indépendants.
2. (1pt) Donnez un intervalle de confiance pour  $\sigma^2$  de niveau 95%.
3. (1,5pt) Que peut-on dire des coordonnées  $\widehat{\beta}_1, \dots, \widehat{\beta}_d$  de  $\widehat{\beta}$ ? Quelle est la loi de  $\sum_{j=1}^d \widehat{\beta}_j$ ? Construisez un intervalle de confiance pour  $\sum_{j=1}^d \beta_j$  au niveau 99% puis un test de  $H_0 : \sum_{j=1}^d \beta_j = 0$  contre  $H_1 : \sum_{j=1}^d \beta_j \neq 0$  au niveau 1%.
4. (1,5pt) Soit  $q$  un entier fixé,  $1 \leq q \leq d-1$ . Proposez un test de niveau 5% de l'hypothèse  $H_0 : \beta_j = 0$  pour tout  $j = q+1, \dots, d$ .
5. (1pt) On considère maintenant l'estimateur des moindres carrés pénalisé par la norme  $\ell_1$  (LASSO) donné pour  $\lambda > 0$  par

$$\widehat{\beta}_\lambda \in \operatorname{argmin}_{\beta \in \mathbb{R}^d} \left\{ \frac{1}{2} \|Y - \mathbf{X}\beta\|^2 + \lambda \|\beta\|_1 \right\}$$

où  $\|\beta\|_1 = \sum_{j=1}^d |\beta_j|$ . Expliquez pourquoi  $\widehat{\beta}_\lambda$  est unique dans le cadre considéré ici.

6. (2pt) Montrez que

$$\widehat{\beta}_\lambda \in \operatorname{argmin}_{\beta \in \mathbb{R}^d} \left\{ \sum_{j=1}^d \left( \frac{\delta_j^2}{2} (Y^\top X^j / \delta_j^2 - \beta_j)^2 + \lambda |\beta_j| \right) \right\}$$

puis montrez que  $\widehat{\beta}_j = \delta_j^{-2} \operatorname{sign}(Y^\top X^j) (|Y^\top X^j| - \lambda)_+$  où  $x_+ = \max(x, 0)$  pour  $x \in \mathbb{R}$  et en déduire une condition suffisante sur  $\lambda$  pour que  $\widehat{\beta}_\lambda = 0_d$ .

**Exercice 2 (Loi binomiale négative, 5pt)**

Si  $T \sim \text{Gamma}(\alpha, \beta)$  alors  $T$  a pour densité  $f_T(t) = \frac{\beta^\alpha}{\Gamma(\alpha)} t^{\alpha-1} e^{-\beta t} \mathbf{1}_{t \geq 0}$  où  $\alpha, \beta > 0$  et  $\Gamma$  désigne la fonction gamma. On rappelle que l'espérance et la variance de  $\text{Gamma}(\alpha, \beta)$  valent  $\alpha/\beta$  et  $\alpha/\beta^2$  respectivement. Si  $Z \sim \text{NegBin}(r, \gamma)$  (binomiale négative) alors  $Z$  a pour densité  $f_Z(z) = \frac{\Gamma(z+r)}{z! \Gamma(r)} \gamma^r (1-\gamma)^z \mathbf{1}_{z \in \mathbb{N}}$  avec  $r > 0$  et  $\gamma \in (0, 1)$ .

1. (1pt) Vérifiez que pour deux variables aléatoires réelles  $Y$  et  $\Theta$  avec  $Y$  dans  $L^2$ , on a

$$\mathbb{V}(Y) = \mathbb{V}(\mathbb{E}(Y|\Theta)) + \mathbb{E}(\mathbb{V}(Y|\Theta)).$$

2. (1pt) On suppose que  $\Theta \sim \text{Gamma}(\alpha, \alpha)$  avec  $\alpha > 0$  et que la loi conditionnelle de  $Y$  sachant  $\Theta$  est une loi de Poisson  $\mathcal{P}(\lambda\Theta)$  avec  $\lambda > 0$ . Calculez  $\mathbb{V}(Y)$  et  $\mathbb{E}(Y)$ .
3. (1,5pt) Montrez que  $Y \sim \text{NegBin}(\alpha, \alpha/(\alpha + \lambda))$ .
4. (1,5pt) On suppose  $\alpha$  connu. Montrez que la loi  $\text{NegBin}(\alpha, \alpha/(\alpha + \lambda))$  est dans la famille exponentielle naturelle et utilisez cela pour retrouver le résultat de la Question 2.

**Exercice 3 (Résidus “studentisés” et données aberrantes en régression, 12pts)**

Continuons avec le modèle de régression linéaire, mais cette fois-ci on sait juste que la matrice  $\mathbf{X} = [X_i^j]_{1 \leq i \leq n, 1 \leq j \leq d}$  est de rang plein. On considère à nouveau le modèle linéaire  $Y = \mathbf{X}\beta + \varepsilon$  avec  $\beta \in \mathbb{R}^d$  inconnu et  $\varepsilon \in \mathbb{R}^n \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$  où  $\sigma^2 > 0$  est inconnu. On considère  $\hat{\beta}$  l’estimateur des moindres carrés et le vecteur des prédictions  $\hat{Y} = \mathbf{X}\hat{\beta}$ . On considère le vecteur des résidus de régression  $E = Y - \hat{Y}$  de coordonnées  $E_i = Y_i - \hat{Y}_i = Y_i - X_i^\top \hat{\beta}$ .

1. (1pt) Montrez que  $E \sim \mathcal{N}(0, \sigma^2(\mathbf{I} - \mathbf{H}))$  où  $\mathbf{H} = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top$  est la matrice “chapeau”.
2. (1pt) On introduit  $\hat{\sigma}^2 = \frac{1}{n-d} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$ . Expliquez rapidement pourquoi on ne peut pas dire que les résidus “standardisés”

$$R_i = E_i / \sqrt{\hat{\sigma}^2(1 - h_{i,i})}$$

sont de loi de student où  $h_{i,i}$  est le “levier” du  $i$ -ème échantillon, c’est-à-dire le  $i$ -ème élément diagonal de  $\mathbf{H}$ .

3. (1pt) On fait alors la chose suivante : on considère  $\mathbf{X}^{(i)} \in \mathbb{R}^{(n-1) \times d}$  la matrice  $\mathbf{X}$  sans sa  $i$ -ème ligne  $X_i$  et  $Y^{(i)} \in \mathbb{R}^{n-1}$  le vecteur  $Y$  sans sa  $i$ -ème coordonnée. On calcule  $\hat{\beta}^{(i)}$  l’estimateur des moindres carrés sans le  $i$ -ème échantillon et le vecteur des prédictions  $\hat{Y}^{(i)} = \mathbf{X}^{(i)} \hat{\beta}^{(i)}$  associé, de coordonnées  $\hat{Y}_{i'}^{(i)} = X_{i'}^\top \hat{\beta}^{(i)}$  pour  $i' = 1, \dots, n$ . Rappelons la formule de Sherman et Morrison, qui dit que pour toute matrice  $\mathbf{A} \in \mathbb{R}^{k \times k}$  inversible et tous vecteurs  $u, v \in \mathbb{R}^k$ , on a

$$(\mathbf{A} + uv^\top)^{-1} = \mathbf{A}^{-1} - \frac{\mathbf{A}^{-1}uv^\top \mathbf{A}^{-1}}{1 + v^\top \mathbf{A}^{-1}u}$$

si  $1 + v^\top \mathbf{A}^{-1}u \neq 0$ . Utilisez cette formule pour montrer que

$$((\mathbf{X}^{(i)})^\top \mathbf{X}^{(i)})^{-1} = (\mathbf{X}^\top \mathbf{X})^{-1} + \frac{(\mathbf{X}^\top \mathbf{X})^{-1} X_i X_i^\top (\mathbf{X}^\top \mathbf{X})^{-1}}{1 - h_{i,i}}.$$

4. (1,5pt) En déduire que l’on peut exprimer les résidus en fonction des résidus dits “externes” via l’équation

$$Y_i - \hat{Y}_i = (1 - h_{i,i})(Y_i - \hat{Y}_i^{(i)}).$$

5. (2pt) Montrez que l’on a

$$Y_i - \hat{Y}_i^{(i)} \sim \mathcal{N}\left(0, \sigma^2(1 + X_i^\top ((\mathbf{X}^{(i)})^\top \mathbf{X}^{(i)})^{-1} X_i)\right)$$

et que

$$1 + X_i^\top ((\mathbf{X}^{(i)})^\top \mathbf{X}^{(i)})^{-1} X_i = \frac{1}{1 - h_{i,i}}.$$

6. (1pt) On considère alors les résidus dits “studentisés”

$$T_i = E_i / \sqrt{\hat{\sigma}_{(i)}^2(1 - h_{i,i})}$$

où  $\hat{\sigma}_{(i)}^2$  est l’estimateur de  $\sigma^2$  dans le modèle linéaire privé de l’observation  $i$  donné par

$$\hat{\sigma}_{(i)}^2 = \frac{1}{n - d - 1} \sum_{i' \neq i} (Y_{i'} - \hat{Y}_{i'}^{(i)})^2.$$

Montrez que  $(n - d - 1)\hat{\sigma}_{(i)}^2 / \sigma^2$  suit une loi du  $\chi^2(n - d - 1)$  (Chi-deux à  $n - d - 1$  degrés de liberté) et que  $Y_i - \hat{Y}_i^{(i)}$  et  $\hat{\sigma}_{(i)}^2$  sont indépendants et en déduire que  $T_i$  suit une loi  $t(n - d - 1)$  (loi de student à  $n - d - 1$  degrés de liberté).

7. (1pt) Considérons maintenant que  $Y^{(i)} = (\mathbf{X}^{(i)})^\top \beta + \varepsilon^{(i)}$  où  $\varepsilon^{(i)}$  est le vecteur  $\varepsilon$  privé de sa  $i$ -ème coordonnée et que  $Y_i = X_i^\top \beta + \mu_i + \varepsilon_i$  où  $\mu_i \in \mathbb{R}$ . On dit que l’échantillon  $i$  est un outlier si  $\mu_i \neq 0$ . Proposez un test pour  $H_0 : \mu_i = 0$  contre  $H_1 : \mu_i \neq 0$  de niveau  $\alpha \in (0, 1)$  à partir de la Question 6 et calculez sa  $p$ -valeur.
8. (3,5pt) Montrez que l’équation suivante, permettant de calculer les résidus studentisés à partir des résidus normalisés, est vérifiée:

$$T_i = R_i \sqrt{\frac{n - d - 1}{n - d - R_i^2}}.$$