

## Dérivation

---

### Exercice 1: différentielle, gradient, Hessien : quelques cas simples, changement de métrique

1. Retrouver le gradient  $\nabla f(x)$  et le Hessien  $\nabla^2 f(x)$  des fonctions :
  - $\mathbb{R}^n \rightarrow \mathbb{R}, x \mapsto f(x) = a^\top x$
  - $\mathbb{R}^n \rightarrow \mathbb{R}, x \mapsto f(x) = x^\top Ax$
2. Soit la fonction  $f : \mathbb{S}_{++} \rightarrow \mathbb{R}, X \mapsto \log \det(X)$ . Préciser sa différentielle (en un point  $X$  quelconque) et calculer son gradient.
3. Dans  $\mathbb{R}^n$ , on se donne les produits scalaires  $\langle x, y \rangle = x^\top y$  et  $\langle x, y \rangle_W = x^\top W y$ , où  $W \in \mathbb{S}_{++}$ . Pour une fonction  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  :
  - (a) Rappeler la définition de sa différentielle (on notera  $Df(x; u)$  la différentielle de  $f$  au point  $x$ , appliquée à  $u$ ).
  - (b) En prenant le produit scalaire usuel,  $\langle \cdot, \cdot \rangle$ , rappeler la définition du vecteur gradient  $\nabla f(x)$ .
  - (c) Pour la métrique définie par le produit scalaire  $\langle \cdot, \cdot \rangle_W$ , écrire la définition du vecteur gradient correspondant  $\nabla_W f(x)$ .
  - (d) En déduire le lien entre les gradients  $\nabla_W f(x)$  et  $\nabla f(x)$  dans les deux métriques.

## Modèles linéaires

---

**Exercice 2: estimateurs linéaires sans biais et moindres carrés** On souhaite estimer un paramètre dont la véritable valeur est notée  $\theta \in \mathbb{R}^n$ . On dispose pour cela d'observations  $\mathbf{y} \in \mathbb{R}^m$  dont on suppose qu'elles sont données par le modèle

$$\mathbf{y} = \mathbf{A}\theta + \mathbf{b}$$

où  $\mathbf{A} \in \mathbb{R}^{m \times n}$  ( $m \geq n$ ) est une matrice fixée de rang colonne plein ( $\text{rank } \mathbf{A} = n$ ) et  $\mathbf{b}$  est un bruit aléatoire. On supposera  $\mathbb{E}\{\mathbf{b}\} = \mathbf{0}$  et  $\text{Cov}\{\mathbf{b}\} = \mathbb{E}\{\mathbf{b}\mathbf{b}^\top\} = \sigma^2 \mathbf{I}_m$ . Enfin, par définition, pour des matrices symétriques  $\mathbf{M}$  et  $\mathbf{N}$ , on notera  $\mathbf{N} \preceq \mathbf{M}$  lorsque  $\mathbf{M} - \mathbf{N}$  est semi-définie positive.

1. Soit l'estimateur des moindres carrés  $\hat{\theta}_{\text{ls}} = \text{Arg min}_{\theta} \|\mathbf{y} - \mathbf{A}\theta\|_2^2$ . Retrouver l'expression analytique de  $\hat{\theta}_{\text{ls}}$  et montrer que c'est un estimateur linéaire (comme fonction du vecteur d'observations  $\mathbf{y}$ ).
2. Calculer  $\mathbb{E}\{\hat{\theta}_{\text{ls}}\}$  et montrer que  $\hat{\theta}_{\text{ls}}$  est non biaisé.
3. Calculer la matrice de covariance de  $\hat{\theta}_{\text{ls}}$ .
4. Soit  $\hat{\theta}$  un autre estimateur. Montrer que si  $\hat{\theta}$  est linéaire et non biaisé, alors  $\hat{\theta} = \mathbf{B}\mathbf{y}$  où  $\mathbf{B} \in \mathbb{R}^{n \times m}$  vérifie  $\mathbf{B}\mathbf{A} = \mathbf{I}_n$ . Calculer  $\text{Cov}\{\hat{\theta}\}$ .
5. Montrer que si  $\mathbf{B}\mathbf{A} = \mathbf{I}_n$ , alors  $\mathbf{B}\mathbf{B}^\top \succeq (\mathbf{A}^\top \mathbf{A})^{-1}$ .
6. Déduire de ce qui précède que si  $\hat{\theta}$  est un estimateur linéaire et non biaisé, alors :
  - $\text{Cov}\{\hat{\theta}\} \succeq \text{Cov}\{\hat{\theta}_{\text{ls}}\}$ ,
  - $\mathbb{E}\{\|\hat{\theta} - \bar{\theta}\|_2^2\} = \text{Var}\{\hat{\theta}\} \geq \mathbb{E}\{\|\hat{\theta}_{\text{ls}} - \bar{\theta}\|_2^2\} = \text{Var}\{\hat{\theta}_{\text{ls}}\}$ ,
  - pour tout  $\mathbf{c} \in \mathbb{R}^n$ ,  $\mathbb{E}\{(\mathbf{c}^\top \hat{\theta} - \mathbf{c}^\top \bar{\theta})^2\} \geq \mathbb{E}\{(\mathbf{c}^\top \hat{\theta}_{\text{ls}} - \mathbf{c}^\top \bar{\theta})^2\}$ .
7. Les propriétés précédentes sont connues sous le nom de «estimateur BLUE (Best Linear Unbiased Estimator)». Justifier que chercher l'estimateur BLUE revient à résoudre le problème d'optimisation suivant :

$$\begin{aligned} \min. \quad & \mathbf{B}\mathbf{B}^\top \quad (\text{par rapport à l'ordre } \preceq) \\ \text{s.t.} \quad & \mathbf{B}\mathbf{A} = \mathbf{I}_n \end{aligned}$$

Montrer qu'il s'agit d'un problème d'optimisation convexe (généralisé).

8. On suppose dorénavant que le bruit est gaussien  $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I}_m)$ .

- Préciser la loi de  $\hat{\boldsymbol{\theta}}_{\text{ls}}$ .
- Calculer  $\hat{\boldsymbol{\theta}}_{\text{ml}}$  l'estimateur du maximum de vraisemblance.

**Exercice 3: «least-squares» et «ridge»** On souhaite estimer un paramètre dont la véritable valeur est notée  $\bar{\boldsymbol{\theta}} \in \mathbb{R}^n$ . On dispose pour cela d'observations  $\mathbf{y} \in \mathbb{R}^m$  dont on suppose qu'elles sont données par le modèle

$$\mathbf{y} = \mathbf{A}\bar{\boldsymbol{\theta}} + \mathbf{b} \quad (1)$$

où  $\mathbf{A} \in \mathbb{R}^{m \times n}$  ( $m \geq n$ ) est une matrice fixée et  $\mathbf{b}$  est un bruit aléatoire. On supposera  $\mathbb{E}\{\mathbf{b}\} = \mathbf{0}$  et  $\text{Cov}\{\mathbf{b}\} = \mathbb{E}\{\mathbf{b}\mathbf{b}^\top\} = \sigma^2 \mathbf{I}_m$ . Enfin, par définition, pour des matrices symétriques  $\mathbf{M}$  et  $\mathbf{N}$  on notera  $\mathbf{N} \preceq \mathbf{M}$  lorsque  $\mathbf{M} - \mathbf{N}$  est semi-définie positive.

1. De façon générale, soit  $\hat{\boldsymbol{\theta}}$  un estimateur de  $\bar{\boldsymbol{\theta}}$ . On définit :

- son biais :  $\text{biais}(\hat{\boldsymbol{\theta}}) = \mathbb{E}\{\hat{\boldsymbol{\theta}}\} - \bar{\boldsymbol{\theta}}$
- son erreur quadratique moyenne :  $\text{eqm}(\hat{\boldsymbol{\theta}}) = \mathbb{E}\{\|\hat{\boldsymbol{\theta}} - \bar{\boldsymbol{\theta}}\|_2^2\}$
- sa variance :  $\text{Var}\{\hat{\boldsymbol{\theta}}\} = \mathbb{E}\{\|\hat{\boldsymbol{\theta}} - \mathbb{E}\{\hat{\boldsymbol{\theta}}\}\|_2^2\}$

Montrer que  $\text{eqm}(\hat{\boldsymbol{\theta}}) = \text{Var}\{\hat{\boldsymbol{\theta}}\} + \|\text{biais}(\hat{\boldsymbol{\theta}})\|_2^2$ . Est-il possible d'avoir un estimateur linéaire qui vérifie les propriétés suivantes (voir exercice sur l'estimateur des moindres carrés  $\hat{\boldsymbol{\theta}}_{\text{ls}}$ ) :

- la variance soit plus faible que celle de l'estimateur des moindres carrés ?
- l'erreur quadratique moyenne (eqm) soit plus faible que celle de l'estimateur des moindres carrés ?

2. On définit  $\hat{\boldsymbol{\theta}}_{\text{ridge}} = \text{Arg min}_{\boldsymbol{\theta}} \|\mathbf{y} - \mathbf{A}\boldsymbol{\theta}\|_2^2 + \lambda \|\boldsymbol{\theta}\|_2^2$ , où  $\lambda > 0$  est un paramètre fixé.

- Calculer l'expression analytique de  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$ .
- Vérifier directement que  $(\mathbf{A}^\top \mathbf{A} + \lambda \mathbf{I}_n)^{-1} \mathbf{A}^\top = \mathbf{A}^\top (\mathbf{A} \mathbf{A}^\top + \lambda \mathbf{I}_m)^{-1}$ . En déduire une autre expression de  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$ .
- Noter que  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$  est solution du problème d'optimisation :

$$\begin{aligned} \min. \quad & \frac{1}{2} (\|\mathbf{u}\|_2^2 + \lambda \|\boldsymbol{\theta}\|_2^2) \\ \text{s.t.} \quad & \mathbf{u} = \mathbf{A}\boldsymbol{\theta} - \mathbf{y} \end{aligned}$$

Ecrire les conditions d'optimalité KKT de ce problème et montrer que, en cherchant les solutions de ces conditions, on peut trouver l'une ou l'autre des expressions précédentes pour  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$ .

3. Calculer biais  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$  et eqm  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$  (en passant par  $\text{Cov}\{\hat{\boldsymbol{\theta}}_{\text{ridge}}\}$  et  $\text{Var}\{\hat{\boldsymbol{\theta}}_{\text{ridge}}\}$ ).

4. On suppose ici  $\mathbf{A}^\top \mathbf{A} = \mathbf{I}_n$ .

- Donner une expression simplifiée de  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$ .
- Calculer eqm  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$ .
- Montrer qu'il existe  $\lambda > 0$  tel que  $\text{eqm} \hat{\boldsymbol{\theta}}_{\text{ridge}} \leq \text{eqm} \hat{\boldsymbol{\theta}}_{\text{ls}}$  puis calculer le paramètre  $\lambda$  qui minimise eqm  $\hat{\boldsymbol{\theta}}_{\text{ridge}}$ .

5. On suppose maintenant explicitement que  $\bar{\boldsymbol{\theta}}$  est la réalisation d'un vecteur aléatoire  $\boldsymbol{\theta}$  centré de matrice de covariance  $\sigma_{\boldsymbol{\theta}}^2 \mathbf{I}_n$ . Les observations sont toujours données par l'équation (1) et le bruit est indépendant de  $\boldsymbol{\theta}$ .

On s'intéresse aux estimateurs linéaires du type  $\hat{\boldsymbol{\theta}} = \mathbf{B}\mathbf{y}$  où  $\mathbf{B}$  est une matrice.

- Calculer eqm  $\hat{\boldsymbol{\theta}}$  en fonction de  $\mathbf{A}$ ,  $\mathbf{B}$ ,  $\sigma^2$ ,  $\sigma_{\boldsymbol{\theta}}^2$ .

- (b) On cherche l'estimateur qui minimise  $\text{eqm} \hat{\theta}$ . Montrer qu'il est obtenu par un problème de minimisation par rapport à  $\mathbf{B}$  d'une expression dépendant de  $\mathbf{A}$ ,  $\mathbf{B}$ ,  $\frac{\sigma^2}{\sigma_\theta^2}$ . Calculer la dérivée de cette expression.
- (c) Montrer que l'estimateur linéaire qui minimise l'erreur quadratique moyenne est donné par  $\hat{\theta}_{\text{ridge}}$  avec une valeur de  $\lambda$  que l'on précisera.
- (d) Retrouver l'expression ci-dessus en travaillant dans l'espace des variables aléatoires de carré sommable et en cherchant la projection de  $\theta$  sur l'espace vectoriel engendré par  $\mathbf{y}$ .

## Analyse en composantes indépendantes

---

**Exercice 4: (in)dépendance de variables aléatoires** Soient  $X$  et  $Y$  deux va indépendantes.  $X$  suit une loi de Bernoulli et prend de façon équiprobable les valeurs  $\{-1, 1\}$ . On admet que la fonction de répartition de  $Y$  est continue et vérifie la symétrie  $F_Y(-y) = 1 - F_Y(y)$ . Soit  $Z$  la va  $Z = XY$ .

1. Calculer la fonction de répartition de  $(X, Z)$  et en déduire que  $X$  et  $Z$  sont indépendantes.
  2. Montrer que, sauf cas particulier,  $Y$  et  $Z$  ne sont pas indépendantes.
- 

**Exercice 5: variables binaires : indépendance mutuelle et par paires** Soient  $X$  et  $Y$  deux va qui suivent chacune une loi de Bernoulli et prennent de façon équiprobable les valeurs  $\{-1, 1\}$ .

1. Montrer que pour le couple  $(X, Y)$  la décorrélation est équivalente à l'indépendance, dans ce cas particulier.
  2. On suppose désormais que  $X$  et  $Y$  sont indépendantes. Soit  $Z = XY$ .
    - (a) Montrer que l'on a indépendance par paires pour  $(X, Y, Z)$  (çàd  $(X, Y)$ ,  $(X, Z)$  et  $(Y, Z)$  sont des couples indépendants).
    - (b) Montrer que les variables aléatoires  $X, Y, Z$  ne sont pas mutuellement indépendantes.
- 

**Exercice 6: statistiques d'ordre supérieur et étude de quelques contrastes**

1. On admet que pour des variables aléatoires centrées, on a les expressions suivantes des cumulants en fonction des moments :

$$\begin{aligned} \text{Cum} \{a, b\} &= \mathbb{E}\{ab\} \\ \text{Cum} \{a, b, c\} &= \mathbb{E}\{abc\} \\ \text{Cum} \{a, b, c, d\} &= \mathbb{E}\{abcd\} - \mathbb{E}\{ab\}\mathbb{E}\{cd\} - \mathbb{E}\{ac\}\mathbb{E}\{bd\} - \mathbb{E}\{ad\}\mathbb{E}\{bc\} \end{aligned}$$

Vérifier qu'à partir de ces relations, on retrouve les propriétés des cumulants :

- multilinéarité
- nullité s'il existe un sous-ensemble de variables indépendantes des autres.

Si  $a, b$  et  $c$  sont indépendantes, que peut-on dire de  $\text{Cum} \{a, b, c\}$ ? Si  $a$  et  $b$  sont indépendantes et  $c$  quelconque, peut-on affirmer que  $\text{Cum} \{a, b, c\} = 0$ ?

2. On note  $C_4\{a\} = \text{Cum} \{a, a, a, a\}$ . Calculer  $C_4\{a\}$  dans les cas suivants :
  - $a$  vaut  $+1$  ou  $-1$  de manière équiprobable.
  - $a$  est une variable aléatoire centrée, de variance unité et distribuée uniformément sur un intervalle.

3. On considère un vecteur  $\mathbf{s} = (s_1, \dots, s_N)^\top$  de sources mutuellement indépendantes,  $\mathbf{G} \in \mathbb{R}^{N \times N}$  une matrice orthogonale et  $\mathbf{y} = \mathbf{G}\mathbf{s}$ . On souhaite étudier les critères de séparation suivant en fonction de  $\mathbf{G}$ .

$$\mathcal{C}_1(\mathbf{y}) \triangleq \sum_{i=1}^N |\mathcal{C}_4\{y_i\}|, \quad \mathcal{C}_2(\mathbf{y}) \triangleq - \sum_{i=1}^N \mathcal{C}_4\{y_i\}, \quad \mathcal{C}_3(\mathbf{y}) \triangleq \sum_{i=1}^N (\mathcal{C}_4\{y_i\})^2$$

On notera  $\kappa_i \triangleq \mathcal{C}_4\{s_i\}$  pour tout  $i$ .

- (a) Développer  $\mathcal{C}_4\{y_i\}$  en fonction des  $\kappa_i$  et des coefficients de la matrice  $\mathbf{G}$ .
  - (b) Montrer que  $\mathcal{C}_1(\mathbf{y}) \leq \sum_{i=1}^N |\kappa_i|$  (indication : utiliser l'orthogonalité de  $\mathbf{G}$ ).
  - (c) On suppose  $\forall i, \kappa_i \neq 0$ . Montrer qu'en cas d'égalité dans la majoration précédente,  $\mathbf{G}$  n'a qu'un et un seul élément non nul sur chaque ligne et chaque colonne et que cet élément vaut  $+1$  ou  $-1$  (indication : utiliser l'orthogonalité de  $\mathbf{G}$ ).
  - (d) Peut-on affaiblir l'hypothèse  $\forall i, \kappa_i \neq 0$ ? Commenter.
4. Reprendre l'étude précédente pour  $\mathcal{C}_2(\mathbf{y})$  en supposant que les  $\kappa_i \neq 0$  sont négatifs. Préciser les hypothèses pour que  $\mathcal{C}_2(\mathbf{y})$  soit un contraste.
5. Prouver que  $\mathcal{C}_3(\mathbf{y})$  est un contraste sous les mêmes hypothèses que  $\mathcal{C}_1(\mathbf{y})$  (indication : utiliser la convexité de  $(\cdot)^2$  afin d'obtenir une majoration).