

Correction du sujet ENS 2025.

Partie I

1. (a) •
- Si $a > 0$
- ,

$$\text{pour } x \in \mathbb{R}, F_Y(x) = P(aX + b \leq x) = P\left(X \leq \frac{x-b}{a}\right) = F_X\left(\frac{x-b}{a}\right)$$

$$F_X \text{ est de classe } C^\infty \text{ sur } \mathbb{R} \text{ donc } Y \text{ est de densité : } x \mapsto \frac{1}{a} \phi_{\mu, \sigma}\left(\frac{x-b}{a}\right)$$

$$\begin{aligned} \text{or } \frac{1}{a} \phi_{\mu, \sigma}\left(\frac{x-b}{a}\right) &= \frac{1}{a\sqrt{2\pi\sigma^2}} \exp\left(-\frac{\left(\frac{y-b}{a} - \mu\right)^2}{2\sigma^2}\right) \\ &= \frac{1}{\sqrt{2\pi(a\sigma)^2}} \exp\left(-\frac{(y - (a\mu + b))^2}{2(a\sigma)^2}\right) \end{aligned}$$

On reconnaît cette densité : Y suit la loi $\mathcal{N}(a\mu + b, a^2\sigma^2)$

-
- Si $a < 0$
- ,

$$\text{pour } x \in \mathbb{R}, F_Y(x) = P(aX + b \leq x) = P\left(X \geq \frac{x-b}{a}\right) = 1 - F_X\left(\frac{x-b}{a}\right)$$

$$F_X \text{ est de classe } C^\infty \text{ sur } \mathbb{R} \text{ donc } Y \text{ est de densité : } x \mapsto -\frac{1}{a} \phi_{\mu, \sigma}\left(\frac{x-b}{a}\right)$$

$$\begin{aligned} \text{or } -\frac{1}{a} \phi_{\mu, \sigma}\left(\frac{x-b}{a}\right) &= -\frac{1}{a\sqrt{2\pi\sigma^2}} \exp\left(-\frac{\left(\frac{y-b}{a} - \mu\right)^2}{2\sigma^2}\right) \\ &= \frac{1}{\sqrt{2\pi(a\sigma)^2}} \exp\left(-\frac{(y - (a\mu + b))^2}{2(a\sigma)^2}\right) \quad (\sqrt{a^2} = -a) \end{aligned}$$

On retrouve le résultat : Y suit la loi $\mathcal{N}(a\mu + b, a^2\sigma^2)$

- (b) En appliquant (a) avec
- $a \leftarrow \frac{1}{\sigma}$
- et
- $b \leftarrow -\frac{\mu}{\sigma}$
- on a :
- $Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(a\mu + b, a^2\sigma^2)$
- donc la loi
- $\mathcal{N}(0, 1)$

$Z \sim \mathcal{N}(0, 1)$

2. On note
- Φ
- la fonction de répartition de la loi
- $\mathcal{N}(0, 1)$
- .

- (a)
- Φ
- est une bijection strictement croissante de
- \mathbb{R}
- dans
- $]0, 1[$
- .

*(En effet : $\phi_{0,1}$ est continue et strictement positive sur \mathbb{R})*Autrement dit : pour tout $\alpha \in]0, 1[$ il existe un unique $u(\alpha) \in \mathbb{R}$ tel que : $\Phi(u(\alpha)) = \int_{-\infty}^{u(\alpha)} \phi_{0,1}(x) dx = \alpha$ $u = \Phi^{-1}$ est bien continue et strictement croissante sur $]0, 1[$.*Remarque : u est souvent appelée fonction des quantiles de la loi $\mathcal{N}(0, 1)$.*

- (b) On sait que
- $\forall x \in \mathbb{R}, \Phi(x) + \Phi(-x) = 1$
- (En effet :
- $x \mapsto \Phi(x) + \Phi(-x)$
- est de dérivée nulle et en 0 elle vaut 1)
-
- Pour
- $\alpha \in]0, 1[$
- ,
- $\Phi(-u(\alpha)) = 1 - \Phi(u(\alpha)) = 1 - \alpha$
- donc :
- $-u(\alpha) = u(1 - \alpha)$

- 3.

$$\begin{aligned} P(|X_1 - \mu_1| \geq \delta) &= P\left(\left|\frac{X_1 - \mu_1}{\sigma_1}\right| \geq \frac{\delta}{\sigma_1}\right) \\ &= 1 - P\left(-\frac{\delta}{\sigma_1} \leq \frac{X_1 - \mu_1}{\sigma_1} \leq \frac{\delta}{\sigma_1}\right) \\ &= 2 - 2\Phi\left(\frac{\delta}{\sigma_1}\right) \end{aligned}$$

On montre de même : $P(|X_2 - \mu_2| \geq \delta) = 2 - 2\Phi\left(\frac{\delta}{\sigma_2}\right)$

or $\sigma_1 \leq \sigma_2$ et Φ est croissante donc $\Phi\left(\frac{\delta}{\sigma_1}\right) \geq \Phi\left(\frac{\delta}{\sigma_2}\right)$ ce qui entraîne :

$$\boxed{P(|X_1 - \mu_1| \geq \delta) \leq P(|X_2 - \mu_2| \geq \delta)}$$

Interprétation :

La variable aléatoire X_1 est moins dispersée autour de μ_1 que X_2 autour de μ_2 .

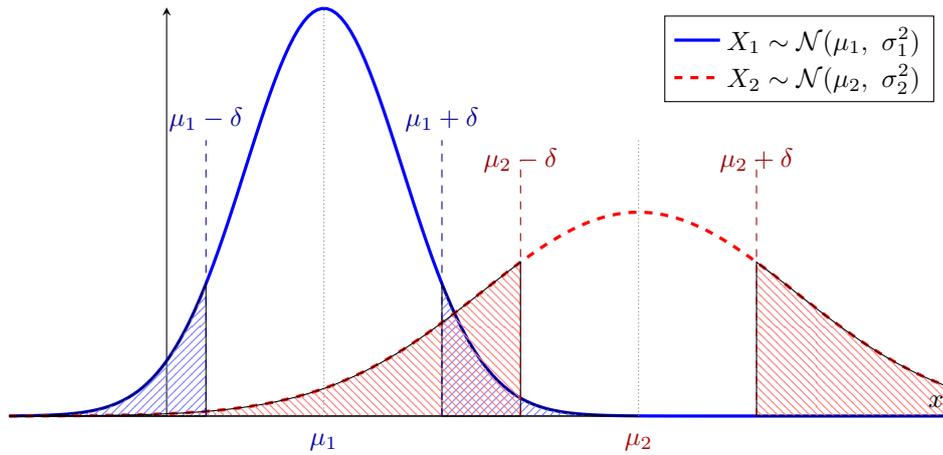
Comme σ_1 est plus faible que σ_2 ,

il est moins probable que X_1 s'éloigne de sa moyenne d'au moins δ que X_2 ,

X_1 est plus concentrée autour de sa moyenne.

Illustration graphique :

On représente la densité continue des deux variables aléatoires et on hachure l'aire correspondant aux deux probabilités.



4. (a) i. La linéarité de $E(\cdot)$ donne : $E(Y) = E(X_1) + E(X_2)$ et ainsi $\boxed{E(Y) = 0}$

Par indépendance de X_1 et X_2 , $V(Y) = V(X_1) + V(X_2)$ et ainsi $\boxed{V(Y) = \sigma_1^2 + \sigma_2^2}$

ii.

$$\begin{aligned} f_1(y-x)f_2(x) &= \frac{1}{\sqrt{2\pi\sigma_1^2}} \exp\left(-\frac{(y-x)^2}{2\sigma_1^2}\right) \times \frac{1}{\sqrt{2\pi\sigma_2^2}} \exp\left(-\frac{x^2}{2\sigma_2^2}\right) \\ &= \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{(y-x)^2}{2\sigma_1^2} - \frac{x^2}{2\sigma_2^2}\right) \end{aligned}$$

- D'une part : $-\frac{(y-x)^2}{2\sigma_1^2} - \frac{x^2}{2\sigma_2^2} = -\frac{y^2}{2\sigma_1^2} + \frac{xy}{\sigma_1^2} - \frac{1}{2}\left(\frac{\sigma_1^2 + \sigma_2^2}{\sigma_1^2\sigma_2^2}\right)x^2$

- D'autre part :

$$\begin{aligned} -\frac{y^2}{2(\sigma_1^2 + \sigma_2^2)} - \frac{\left(x - \frac{y\sigma_2^2}{\sigma_1^2 + \sigma_2^2}\right)^2}{2\frac{\sigma_1^2\sigma_2^2}{\sigma_1^2 + \sigma_2^2}} &= -\frac{y^2}{2(\sigma_1^2 + \sigma_2^2)} - \frac{\sigma_1^2 + \sigma_2^2}{2\sigma_1^2\sigma_2^2} \left(x^2 - \frac{2\sigma_2^2}{\sigma_1^2 + \sigma_2^2}xy + \frac{\sigma_2^4}{(\sigma_1^2 + \sigma_2^2)^2}y^2\right) \\ &= -\frac{y^2}{2(\sigma_1^2 + \sigma_2^2)} - \frac{\sigma_1^2 + \sigma_2^2}{2\sigma_1^2\sigma_2^2}x^2 + \frac{1}{\sigma_1^2}xy - \frac{\sigma_2^2}{\sigma_1^2(\sigma_1^2 + \sigma_2^2)}y^2 \\ &= -\frac{y^2}{2\sigma_1^2} + \frac{xy}{\sigma_1^2} - \frac{1}{2}\left(\frac{\sigma_1^2 + \sigma_2^2}{\sigma_1^2\sigma_2^2}\right)x^2 \end{aligned}$$

donc

$$\boxed{f_1(y-x)f_2(x) = \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{y^2}{2(\sigma_1^2 + \sigma_2^2)} - \frac{\left(x - \frac{y\sigma_2^2}{\sigma_1^2 + \sigma_2^2}\right)^2}{2\frac{\sigma_1^2\sigma_2^2}{\sigma_1^2 + \sigma_2^2}}\right)}$$

iii. Le théorème donnant une densité de la somme de deux variables aléatoires indépendantes donne la convergence de l'intégrale suivante, que l'on calcule avec la formule précédente :

$$\begin{aligned} \int_{-\infty}^{+\infty} f_1(y-x)f_2(x) dx &= \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{y^2}{2(\sigma_1^2+\sigma_2^2)}\right) \int_{-\infty}^{+\infty} \exp\left(-\frac{\left(x-\frac{y\sigma_2^2}{\sigma_1^2+\sigma_2^2}\right)^2}{2\frac{\sigma_1^2\sigma_2^2}{\sigma_1^2+\sigma_2^2}}\right) dx \\ &= \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{y^2}{2(\sigma_1^2+\sigma_2^2)}\right) \underbrace{\sqrt{2\pi\frac{\sigma_1^2\sigma_2^2}{\sigma_1^2+\sigma_2^2}}}_{\text{on utilise la densité d'une gaussienne}} \\ &= \frac{1}{\sqrt{2\pi(\sigma_1^2+\sigma_2^2)}} \exp\left(-\frac{y^2}{2(\sigma_1^2+\sigma_2^2)}\right) \end{aligned}$$

On sait que $y \mapsto \int_{-\infty}^{+\infty} f_1(y-x)f_2(x) dx$ est une densité de $Y = X_1 + X_2$ (car X_1 et X_2 sont indépendantes) et on reconnaît ci-dessus la densité continue de la loi $\mathcal{N}(0, \sigma_1^2 + \sigma_2^2)$ donc

$$\boxed{Y \text{ suit la loi } \mathcal{N}(0, \sigma_1^2 + \sigma_2^2)}$$

iv. Soient $X_1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$ et $X_2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$ deux variables aléatoires indépendantes.

on a alors $X_1 - \mu_1 \sim \mathcal{N}(0, \sigma_1^2)$ et $X_2 - \mu_2 \sim \mathcal{N}(0, \sigma_2^2)$ (d'après la question 1.(a))

et $X_1 - \mu_1$ et $X_2 - \mu_2$ sont indépendantes.

donc d'après la question précédente : $X_1 - \mu_1 + X_2 - \mu_2 \sim \mathcal{N}(0, \sigma_1^2 + \sigma_2^2)$

et en réutilisant la question 1) il vient : $\boxed{X_1 + X_2 \sim \mathcal{N}(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)}$

Ce qui achève la démonstration du lemme 1 dans le cas $n = 2$.

(b) On suppose connaître (X_1, \dots, X_n) n variables aléatoires indépendantes et $(a_1, \dots, a_n) \in \mathbb{R}^n$ tels que :

$$X_i \sim \mathcal{N}(\mu_i, \sigma_i^2) \quad \text{et} \quad (a_1, \dots, a_n) \neq 0_n$$

(Il suffit de l'établir pour (a_1, \dots, a_n) vérifiant $\forall i \in \llbracket 1; n \rrbracket, a_i \neq 0$, ce qui simplifiera la récurrence)

• On vient de montrer que la somme de deux gaussiennes indépendantes est une gaussienne.

On montre alors par récurrence sur n avec le lemme de coalition que toute combinaison linéaire de n gaussiennes mutuellement indépendantes est une gaussienne. (toute combinaison linéaire avec des coefficients non tous nuls !)

donc on peut affirmer que $\sum_{i=1}^n a_i X_i$ est une gaussienne.

• Ensuite pour avoir l'espérance et la variance, il suffit de calculer l'espérance et la variance de la variable aléatoire $\sum_{i=1}^n a_i X_i$: sachant que $E(X_i) = \mu_i$ et $V(X_i) = \sigma_i^2$:

- La linéarité de $E(\cdot)$ donne : $E\left(\sum_{k=1}^n a_k X_k\right) = \sum_{k=1}^n a_k E(X_k)$ et ainsi $\boxed{E\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i \mu_i}$

- Par indépendance mutuelle des X_i , $V\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i^2 V(X_i)$ et ainsi $\boxed{V\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i^2 \sigma_i^2}$

En conclusion, on a bien $\boxed{\sum_{i=1}^n a_i X_i \text{ est une gaussienne d'espérance } \sum_{i=1}^n a_i \mu_i \text{ et de variance } \sum_{i=1}^n a_i^2 \sigma_i^2}$

Ce qui achève la démonstration du lemme 1 dans le cas général.

(c) Notons $b = M^T a$, comme $a \notin \ker(M^T)$ on a $b \neq 0_k$

on a alors $a^T M X = \sum_{i=1}^k b_i X_i$ et ainsi d'après le lemme 1,

$$a^T M X \text{ suit la loi normale de d'espérance } \sum_{i=1}^k b_i \mu_i \text{ et de variance } \sum_{i=1}^k b_i^2 \sigma_i^2$$

$$\text{or } a^T M \mu = b^T \mu = \sum_{i=1}^k b_i \mu_i \quad \text{et} \quad a^T M \Sigma M^T a = b^T \Sigma b = \sum_{i=1}^k b_i^2 \sigma_i^2$$

$$\text{donc on a bien : } \boxed{a^T M X \sim \mathcal{N}(a^T M \mu; a^T M \Sigma M^T a)}$$

Partie II

1. (a) $x \in \ker(A + U_1 C U_2)$ donc $Ax + U_1 C U_2 x = 0_k$ ce qui entraîne en multipliant à gauche par $C U_2 A^{-1}$:

$$C U_2 x + C U_2 A^{-1} U_1 C U_2 x = 0_k$$

et comme $C U_2 x = f(x)$ on obtient $f(x) + C U_2 A^{-1} U_1 f(x) = 0_k$ ou encore $C^{-1} f(x) + U_2 A^{-1} U_1 f(x) = 0_k$

$$\text{d'où } \boxed{f(x) \in \ker(C^{-1} + U_2 A^{-1} U_1)}$$

$$\begin{aligned} g \circ f(x) &= (-A^{-1} U_1)(C U_2)x \\ &= -A^{-1}(U_1 C U_2)x \\ &= -A^{-1}(-Ax) \quad \text{car } x \in \ker(A + U_1 C U_2) \\ &= x \end{aligned}$$

(b) $x \in \ker(C^{-1} + U_2 A^{-1} U_1)$ donc $C^{-1}x + U_2 A^{-1} U_1 x = 0_k$ ce qui entraîne en multipliant à gauche par $-A^{-1} U_1 C$:

$$-A^{-1} U_1 x - A^{-1} U_1 C U_2 A^{-1} U_1 x = 0_k$$

et comme $-A^{-1} U_1 x = g(x)$ on obtient $g(x) + A^{-1} U_1 C U_2 g(x) = 0_k$ ou encore $A g(x) + U_1 C U_2 g(x) = 0_k$

$$\text{d'où } \boxed{f(x) \in \ker(A + U_1 C U_2)}$$

$$\begin{aligned} f \circ g(x) &= (C U_2)(-A^{-1} U_1)x \\ &= -C(U_2 A^{-1} U_1)x \\ &= -C(-C^{-1}x) \quad \text{car } x \in \ker(C^{-1} + U_2 A^{-1} U_1) \\ &= x \end{aligned}$$

(c) On note $\tilde{f} : E \rightarrow F$ avec $E = \ker(A + U_1 C U_2)$ et $F = \ker(C^{-1} + U_2 A^{-1} U_1)$
 $x \mapsto f(x)$

- \tilde{f} est bien définie d'après (a) et est linéaire car f est linéaire.
- les questions (a) et (b) montrent qu'il existe une application g telle que : $g \circ f = Id_E$ et $f \circ g = Id_F$ on peut en déduire que g est bijective.

En conclusion : f est un isomorphisme de $\ker(A + U_1 C U_2)$ dans $\ker(C^{-1} + U_2 A^{-1} U_1)$

2. *Raisonnons par équivalence.*

$$\begin{aligned} A + U_1 C U_2 \text{ est inversible} &\iff \ker(A + U_1 C U_2) = \{0_n\} \\ &\iff \ker(C^{-1} + U_2 A^{-1} U_1) = \{0_k\} \quad (\text{car ces deux noyaux sont isomorphes}) \\ &\iff C^{-1} + U_2 A^{-1} U_1 \text{ est inversible} \end{aligned}$$

On suppose que ces matrices sont inversibles et alors :

$$\begin{aligned} (A + U_1 C U_2) (A^{-1} - A^{-1} U_1 (C^{-1} + U_2 A^{-1} U_1)^{-1} U_2 A^{-1}) &= I_n - U_1 (C^{-1} + U_2 A^{-1} U_1)^{-1} U_2 A^{-1} \\ &\quad + U_1 C U_2 A^{-1} - U_1 C U_2 A^{-1} U_1 (C^{-1} + U_2 A^{-1} U_1)^{-1} U_2 A^{-1} \\ &= I_n + U_1 C U_2 A^{-1} \\ &\quad - (U_1 + U_1 C U_2 A^{-1} U_1) (C^{-1} + U_2 A^{-1} U_1)^{-1} U_2 A^{-1} \\ &= I_n + U_1 C U_2 A^{-1} \\ &\quad - U_1 C (C^{-1} + U_2 A^{-1} U_1) (C^{-1} + U_2 A^{-1} U_1)^{-1} U_2 A^{-1} \\ &= I_n + U_1 C U_2 A^{-1} - U_1 C U_2 A^{-1} \\ &= I_n \end{aligned}$$

Ce calcul permet de conclure la démonstration du lemme 2 avec :

$$(A + U_1 C U_2)^{-1} = A^{-1} - A^{-1} U_1 (C^{-1} + U_2 A^{-1} U_1)^{-1} U_2 A^{-1}$$

3. On raisonne avec $t > 0$, pour $t = 0$ il n'y a pas de difficulté.

(a) On sait que : $\forall x \in \mathbb{R}^n, x \neq 0_n \implies x^T A x > 0$ et $x^T (t \mathbb{1}_n \mathbb{1}_n^T) x = t \left(\sum_{i=1}^n x_i \right)^2$

donc $\forall x \in \mathbb{R}^n, x \neq 0_n \implies x^T V x > 0$ et ainsi $\forall x \in \mathbb{R}^n, x \neq 0_n \implies V x \neq 0$ et ainsi V est inversible

On applique le lemme 2 en posant $M = tI_1$, $U_1 = \mathbb{1}_n$ et $U_2 = \mathbb{1}_n^T$
sachant par ailleurs que V est inversible son inverse est donné par le lemme :

$$V^{-1} = A^{-1} - \frac{t}{1 + t \mathbb{1}_n^T A^{-1} \mathbb{1}_n} \cdot A^{-1} \mathbb{1}_n \mathbb{1}_n^T A^{-1}$$

(b) $V^{-1} = A^{-1} - \frac{t}{1 + t \mathbb{1}_n^T A^{-1} \mathbb{1}_n} \cdot A^{-1} \mathbb{1}_n \mathbb{1}_n^T A^{-1}$ donc

$$\begin{aligned} \mathbb{1}_n^T V^{-1} \mathbb{1}_n &= \mathbb{1}_n^T A^{-1} \mathbb{1}_n - \frac{t}{1 + t \mathbb{1}_n^T A^{-1} \mathbb{1}_n} \cdot \mathbb{1}_n^T A^{-1} \mathbb{1}_n \mathbb{1}_n^T A^{-1} \mathbb{1}_n \\ &= p_A - \frac{t p_A^2}{1 + t p_A} \end{aligned}$$

$$\boxed{\mathbb{1}_n^T V^{-1} \mathbb{1}_n = \frac{p_A}{1 + t p_A}}$$

de même on a : $\mathbb{1}_n^T V^{-1} y = \mathbb{1}_n^T A^{-1} y - \frac{t}{1 + t p_A} p_A \mathbb{1}_n^T A^{-1} y$ et ainsi :

$$\boxed{\mathbb{1}_n^T V^{-1} y = \frac{\mu_A}{1 + t p_A}}$$

(c) • $\mathbb{1}_n^T V^{-1} \mathbb{1}_n = \frac{p_A}{1 + t p_A} \in \mathbb{R}$ donc $(\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} = \frac{1 + t p_A}{p_A}$.

• On remarque que $A^{-1} \mathbb{1}_n = r$ et $p_A = \mathbb{1}_n^T r$ donc

$$\begin{aligned} V^{-1} \mathbb{1}_n &= A^{-1} \mathbb{1}_n - \frac{t}{1 + t \mathbb{1}_n^T A^{-1} \mathbb{1}_n} \cdot A^{-1} \mathbb{1}_n \mathbb{1}_n^T A^{-1} \mathbb{1}_n \\ &= r - \frac{t}{1 + t p_A} \cdot r \mathbb{1}_n^T r \\ &= r - \frac{t}{1 + t p_A} \cdot p_A r \\ &= \frac{1}{1 + t p_A} r \end{aligned}$$

On en déduit que $(\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n = \frac{1}{p_A} r$, or $p_A = \mathbb{1}_n^T r$ donc

$$\boxed{(\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n = (\mathbb{1}_n^T r)^{-1} r}$$

Partie III

1. (On fait comme si on ne connaissait pas l'inégalité de Cauchy-Schwarz)

(a) on note $b = \frac{1}{n} \mathbb{1}_n$

$$\begin{aligned} \sum_{i=1}^n a_i^2 &= \sum_{i=1}^n (a_i - b_i + b_i)^2 \\ &= \sum_{i=1}^n (a_i - b_i)^2 + 2 \sum_{i=1}^n (a_i - b_i) b_i + \sum_{i=1}^n b_i^2 \\ &= \sum_{i=1}^n (a_i - b_i)^2 + 2 \sum_{i=1}^n a_i b_i - 2 \sum_{i=1}^n b_i^2 + \sum_{i=1}^n b_i^2 \\ &= \sum_{i=1}^n (a_i - b_i)^2 + \frac{2}{n} \sum_{i=1}^n a_i - \frac{2}{n^2} \sum_{i=1}^n 1 + \frac{1}{n^2} \sum_{i=1}^n 1 \quad (\text{car } b = \frac{1}{n} \mathbb{1}_n) \\ &= \sum_{i=1}^n (a_i - b_i)^2 + \frac{1}{n} \quad (\text{car } a^T \mathbb{1}_n = 1) \end{aligned}$$

Ainsi $\sum_{i=1}^n a_i^2 \geq \frac{1}{n}$ et l'égalité est réalisée pour le vecteur $b = \frac{1}{n} \mathbb{1}_n$

(b) On note $b = \left(\sum_{i=1}^n r_i \right)^{-1} r$

$$\begin{aligned} \sum_{i=1}^n \frac{1}{r_i} a_i^2 &= \sum_{i=1}^n \frac{1}{r_i} (a_i - b_i + b_i)^2 \\ &= \sum_{i=1}^n \frac{1}{r_i} (a_i - b_i)^2 + 2 \sum_{i=1}^n \frac{1}{r_i} a_i b_i - \sum_{i=1}^n \frac{1}{r_i} b_i^2 \\ &= \sum_{i=1}^n \frac{1}{r_i} (a_i - b_i)^2 + 2 \left(\sum_{i=1}^n r_i \right)^{-1} \sum_{i=1}^n a_i - \left(\sum_{i=1}^n r_i \right)^{-2} \sum_{i=1}^n r_i \\ &= \sum_{i=1}^n \frac{1}{r_i} (a_i - b_i)^2 + \left(\sum_{i=1}^n r_i \right)^{-1} \end{aligned}$$

Donc $\sum_{i=1}^n \frac{1}{r_i} a_i^2 \geq \left(\sum_{i=1}^n r_i \right)^{-1}$ et l'égalité est réalisée pour le vecteur $b = \left(\sum_{i=1}^n r_i \right)^{-1} r$

(c) i. • $V = M^T M$ donc $V^T = M^T (M^T)^T = M^T M = V$ donc V est symétrique

• Si $x^T V x \leq 0$ alors $\|Mx\|^2 \leq 0$ ce qui entraîne $Mx = 0_m$ puis $x = 0_n$ (car $rg(M) = n$ donc on a bien $\forall x \in \mathbb{R}^n, x \neq 0_n \implies x^T V x > 0$).

ii. • V est symétrique réelle donc (théorème spectral) V diagonalisable

• Pour $x \neq 0_n$ et $\lambda \in \mathbb{R}$, si $Vx = \lambda x$ alors $x^T V x = \lambda \|x\|^2$ or on sait $x^T V x > 0$ donc $\lambda > 0$

toutes les valeurs propres de V sont strictement positives.

iii. • On vient de montrer que 0 n'est pas valeur propre de V donc V est inversible

• Soit $x \in \mathbb{R}^n$ tel que $x \neq 0_n$, on note $y = V^{-1}x$ (on sait que $y \neq 0_n$),

$$\begin{aligned} x^T V^{-1} x &= (Vy)^T V^{-1} (Vy) \\ &= y^T V y > 0 \end{aligned}$$

donc $\forall x \in \mathbb{R}^n, x \neq 0_n \implies x^T V x > 0$

iv. On note $b = (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n$ et on remarque que : V^{-1} est symétrique et $\mathbb{1}_n^T V^{-1} \mathbb{1}_n \in \mathbb{R}$

$$\begin{aligned} a^T V a &= (a - b + b)^T V (a - b + b) \\ &= (a - b)^T V (a - b) + (a - b)^T V b + b^T V (a - b) + b^T V b \\ &= (a - b)^T V (a - b) + a^T V b + b^T V a - b^T V b \end{aligned}$$

$$\begin{aligned} b^T V a &= (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} \mathbb{1}_n^T V^{-1} V a \\ &= (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} \mathbb{1}_n^T a \\ &= (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} \quad (\text{car } \mathbb{1}_n^T a = 1) \end{aligned}$$

et $b^T V a = (a^T V b)^T$ car ce sont des matrices 1×1 et $V^T = V$ donc $b^T V a = a^T V b$

$$\begin{aligned} b^T V b &= (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} \mathbb{1}_n^T V^{-1} V (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n \\ &= (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-2} (\mathbb{1}_n^T V^{-1} \mathbb{1}_n) \\ &= (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} \end{aligned}$$

donc

$$a^T V a = (a - b)^T V (a - b) + (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1}$$

Sachant que $(a - b)^T V (a - b) \geq 0$ et $(a - b)^T V (a - b) = 0 \implies a = b$ il vient :

$$\boxed{a^T V a \geq (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1}, \text{ et l'égalité est réalisée pour le vecteur } b = (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n}$$

v. • En prenant $V = I_n$ (ou $M = I_n$) on obtient $a^T a \geq \frac{1}{n}$ et l'égalité pour $b = \frac{1}{n} \mathbb{1}_n$
on retrouve le résultat de la question 1.(a).

• En prenant $V = \text{Diag} \left(\frac{1}{r_i} \right)$ (ou $M = \text{Diag} \left(\frac{1}{\sqrt{r_i}} \right)$) on obtient bien : $\sum_{i=1}^n \frac{a_i^2}{r_i} \geq \left(\sum_{i=1}^n r_i \right)^{-1}$

et l'égalité pour $b = \left(\sum_{i=1}^n r_i \right)^{-1} r$

on retrouve le résultat de la question 1.(b).

2. (a) En utilisant les résultats de la partie I on sait que $Y_i \sim \mathcal{N}(\mu, \sigma^2)$ et $M_n = \frac{1}{n} \sum_{i=1}^n Y_i$ est une gaussienne :

la linéarité de $E(\cdot)$ donne $E(M_n) = \mu$ et l'indépendance mutuelle des Y_i donne $V(M_n) = \frac{\sigma^2}{n}$

$$\boxed{M_n \sim \mathcal{N} \left(\mu, \frac{\sigma^2}{n} \right)}$$

(b) En prenant pour vecteur déterministe : $a = \frac{1}{n} \mathbb{1}_n$, on peut affirmer que M_n est un estimateur linéaire et comme de plus $E(M_n) = \mu$ il vient :

$$\boxed{M_n \text{ est un estimateur linéaire sans biais de } \mu}$$

(c) $Q_n(a)$ est un estimateur linéaire donc $Q_n(a)$ est une gaussienne :

la linéarité de $E(\cdot)$ donne $E(Q_n(a)) = \sum_{i=1}^n \mu a_i = \mu$ et l'indépendance mutuelle des Y_i donne

$$V(Q_n(a)) = \sum_{i=1}^n a_i^2 \sigma^2$$

$$\boxed{Q_n(a) \text{ est une gaussienne d'espérance } \mu \text{ et de variance } a^T a \sigma^2}$$

(d) $a \in F_n$, $Q_n(a) = \sum_{i=1}^n a_i Y_i$ et $E(Q_n(a)) = \mu$

$$\boxed{Q_n(a) \text{ est un estimateur linéaire sans biais de } \mu}$$

(e) on a vu à la question 1.(a) que $a^T a \geq \frac{1}{n}$ donc $a^T a \sigma^2 \geq \frac{\sigma^2}{n}$

$$\boxed{V(Q_n(a)) \geq V(M_n)}$$

Interprétation : M_n est l'estimateur linéaire sans biais de μ avec le plus faible écart-type.

(f) Il suffit d'appliquer le résultat de la question I 3. avec $\sigma_1 = V(M_n)$ et $\sigma_2 = V(Q_n(a))$

$$\boxed{\mathbb{P}[|M_n - \mu| \geq \delta] \leq \mathbb{P}[|Q_n(a) - \mu| \geq \delta]}$$

Interprétation :

M_n s'éloigne moins de μ que $Q_n(a)$, M_n est le moins dispersé des estimateurs linéaires de μ .

(Voir interprétation Partie I)

(g) L'inégalité de Bienaymé-Tchebychev donne : $0 \leq \mathbb{P}[|M_n - \mu| \geq \delta] \leq \frac{\sigma^2}{n\delta^2}$ donc (th. des gendarmes)

$$\boxed{\lim_{n \rightarrow \infty} \mathbb{P}[|M_n - \mu| \geq \delta] = 0}$$

Interprétation : (Loi faible des grands nombres, (M_n) converge en probabilité vers μ)

Pour n suffisamment grand la moyenne arithmétique est une bonne approximation du paramètre μ .

Et cet estimateur est le "meilleur" parmi l'ensemble des estimateurs linéaires sans biais de μ .

3. (a) $Y_i \sim \mathcal{N}\left(\mu, \frac{\sigma}{r_i}\right)$ et $Q_n(r) = \left(\sum_{i=1}^n r_i\right)^{-1} \sum_{i=1}^n r_i Y_i$ donc

$$E(Q_n(r)) = \left(\sum_{i=1}^n r_i\right)^{-1} \sum_{i=1}^n r_i E(Y_i) = \mu \quad V(Q_n(r)) = \left(\sum_{i=1}^n r_i\right)^{-2} \sum_{i=1}^n r_i^2 V(Y_i) = \frac{\sigma^2}{\sum_{i=1}^n r_i}$$

et ainsi avec le lemme 1 :

$$\boxed{Q_n(r) \text{ suit la loi normale d'espérance } \mu \text{ et de variance } \frac{\sigma^2}{\sum_{i=1}^n r_i}}$$

On sait que : $\left(\sum_{i=1}^n r_i\right) \left(\sum_{i=1}^n \frac{1}{r_i}\right) \geq n^2$ (question III 1. (b)) et on a supposé : $\sum_{i=1}^n \frac{1}{r_i} \leq n$

donc $\forall n \in \mathbb{N}, \sum_{i=1}^n r_i \geq n$ et ainsi $\lim_{n \rightarrow +\infty} V(Q_n(r)) = 0$

En appliquant l'inégalité de Bienaymé-Tchebychev il vient : $0 \leq \mathbb{P}[|Q_n(r) - \mu| \geq \delta] \leq \frac{V(Q_n(r))}{\delta^2}$

ce qui permet de conclure (*th. des gendarmes*)

$$\boxed{\lim_{n \rightarrow \infty} \mathbb{P}[|Q_n(r) - \mu| \geq \delta] = 0}$$

(b) M_n est toujours une gaussienne d'espérance $E(M_n) = \mu$ et de variance $V(M_n) = \frac{\sigma^2}{n^2} \sum_{i=1}^n \frac{1}{r_i}$

on a : $\left(\sum_{i=1}^n r_i\right) \left(\sum_{i=1}^n \frac{1}{r_i}\right) \geq n^2$ donc $\boxed{V(Q_n(r)) \leq V(M_n)}$

Comme de l'écart-type de $Q_n(r)$ est plus petit, on va préférer $Q_n(r)$ à M_n .

(On utilise l'interprétation de la question I 3.)

Interprétation de la forme de $Q_n(r)$ (un estimateur linéaire sans biais) :

Il accorde plus d'importance aux données avec le plus faible écart-type pour estimer μ .

4. M_n est toujours une gaussienne d'espérance μ et

$$\begin{aligned} V(M_n) &= V\left(\frac{\sigma \varepsilon_0}{\sqrt{r_0}} + \sum_{i=1}^n \frac{\sigma \varepsilon_i}{\sqrt{r_i}}\right) \\ &= \frac{\sigma^2}{r_0} + \frac{\sigma^2}{n^2} \sum_{i=1}^n \frac{1}{r_i} \quad (\text{Indépendance des } \varepsilon_i) \end{aligned}$$

$$\boxed{M_n \text{ suit la loi normale d'espérance } \mu \text{ et de variance } \frac{\sigma^2}{r_0} + \frac{\sigma^2}{n^2} \sum_{i=1}^n \frac{1}{r_i}}$$

On remarque que la $\lim_{n \rightarrow +\infty} V(M_n) = \frac{\sigma^2}{r_0} \neq 0$

et on sait (question I 3.) que : $P(|M_n - \mu| \geq \delta) = 2 - 2\Phi\left(\frac{\delta}{\sqrt{V(M_n)}}\right)$

donc

$$\boxed{P(|M_n - \mu| \geq \delta) \text{ ne tend pas vers } 0 \text{ quand } n \text{ tend vers } +\infty}$$

Interprétation :

Il a ici une perturbation commune à toutes les données qui explique que M_n fluctue toujours autour de μ même pour une grande quantité de données.

5. (a) $Y = \mu \mathbb{1}_n + \sigma ME$ donc $a^T Y = \mu a^T \mathbb{1}_n + \sigma a^T ME$ ou encore $a^T Y = \mu + \sigma a^T ME$
et en utilisant le corollaire 1 on sait que $a^T ME \sim \mathcal{N}(0, a^T MM^T a)$ donc

$$\boxed{a^T Y \sim \mathcal{N}(\mu, \sigma^2 \|M^T a\|^2)}$$

- (b) (Cherchons l'estimateur avec le plus faible écart-type).

On utilise ici le résultat de la question III 1. (c) :

En posant : $V = MM^T$ (ici il faut inverser l'ordre du produit utilisé dans la partie III)

$\|M^T a\|^2 = a^T V a$ est minimum pour $a = (\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n$

On choisira l'estimateur :

$$\boxed{Z_n = (\mathbb{1}_n^T (MM^T)^{-1} \mathbb{1}_n)^{-1} \mathbb{1}_n^T (MM^T)^{-1} Y}$$

- (c) • Dans la question 2. c'est le cas précédent avec $M = I_n$ ce qui donne bien $Z_n = \frac{1}{n} \sum_{i=1}^n Y_i$

- Dans la question 3. c'est le cas précédent avec $M = \text{Diag}\left(\frac{1}{\sqrt{r_1}}, \dots, \frac{1}{\sqrt{r_n}}\right)$

on a alors $(MM^T)^{-1} = \text{Diag}(r_1, \dots, r_n)$ ce qui donne bien $Z_n = \left(\sum_{i=1}^n r_i\right)^{-1} \sum_{i=1}^n r_i Y_i$

- Dans la question 4. c'est le cas précédent avec $M = \begin{pmatrix} \frac{1}{\sqrt{r_0}} & \frac{1}{\sqrt{r_1}} & 0 & \dots & 0 \\ \frac{1}{\sqrt{r_0}} & 0 & \frac{1}{\sqrt{r_2}} & \dots & 0 \\ \vdots & & & \ddots & \\ \frac{1}{\sqrt{r_0}} & 0 & 0 & \dots & \frac{1}{\sqrt{r_n}} \end{pmatrix}$

6. Avec la matrice précédente on a : $MM^T = A + \frac{1}{r_0} \mathbb{1}_n \mathbb{1}_n^T$ où $A = \text{Diag}\left(\frac{1}{r_1}, \dots, \frac{1}{r_n}\right)$

et on note $V = A + \frac{1}{r_0} \mathbb{1}_n \mathbb{1}_n^T$

En utilisant le résultat de la question II 3. (c) on a : $(\mathbb{1}_n^T V^{-1} \mathbb{1}_n)^{-1} V^{-1} \mathbb{1}_n = (\mathbb{1}_n^T r)^{-1} r$

on obtient alors : $Z_n = (\mathbb{1}_n^T r)^{-1} r^T Y$

on retrouve l'estimateur de la question 3 : $Z_n = \left(\sum_{i=1}^n r_i\right)^{-1} \sum_{i=1}^n r_i Y_i$

Cela donne : $Z_n = \left(\sum_{i=1}^n r_i\right)^{-1} \sum_{i=1}^n r_i \left(\mu + \frac{\sigma \varepsilon_0}{\sqrt{r_0}} + \frac{\sigma \varepsilon_i}{\sqrt{r_i}}\right) = \mu + \frac{\sigma \varepsilon_0}{\sqrt{r_0}} + \sigma \left(\sum_{i=1}^n r_i\right)^{-1} \sum_{i=1}^n \sqrt{r_i} \varepsilon_i$

L'espérance de Z_n est toujours μ et la variance vaut $\frac{\sigma^2}{r_0} + \sigma^2 \left(\sum_{i=1}^n r_i\right)^{-1}$

et $\sum_{i=1}^n \frac{1}{r_i} \leq n$ entraîne que $\forall n \in \mathbb{N}, \sum_{i=1}^n r_i \geq n$ et ainsi $\lim_{n \rightarrow +\infty} V(Z_n) = \frac{\sigma^2}{r_0} \neq 0$

Donc $\boxed{Z_n \text{ ne converge pas en probabilité vers la variable certaine égale à } \mu}$.

Interprétation : Lorsqu'une perturbation est commune à toutes les données on ne parvient pas à trouver un estimateur linéaire sans biais de μ qui converge en probabilité vers μ .

Partie IV

1. (a) $X_{AB} = \mu + \varepsilon_{AB}$ et $\varepsilon_{AB} \sim \mathcal{N}(0, \sigma^2 t_{AB})$ donc (question I 1. (a)) $\boxed{X_{AB} \sim \mathcal{N}(\mu, \sigma^2 t_{AB})}$

$X_A = \mu + \varepsilon_{AB} + \varepsilon_A$ et ε_{AB} et ε_A sont indépendantes donc $\boxed{X_A \sim \mathcal{N}(\mu, \sigma^2(t_{AB} + t_A))}$

de même on montre : $\boxed{X_B \sim \mathcal{N}(\mu, \sigma^2(t_{AB} + t_B))}$

$$(b) Y = \begin{pmatrix} X_A \\ X_B \end{pmatrix} = \begin{pmatrix} \mu + \varepsilon_{AB} + \varepsilon_A \\ \mu + \varepsilon_{AB} + \varepsilon_B \end{pmatrix} = \begin{pmatrix} \mu \\ \mu \end{pmatrix} + \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix} \begin{pmatrix} \varepsilon_{AB} \\ \varepsilon_A \\ \varepsilon_B \end{pmatrix}$$

donc en posant $M_2 = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix}$ on a bien $\boxed{Y = \mu \mathbf{1}_2 + M_2 E}$

(c) Cette question ne pose pas de problème en supposant $\varepsilon_{AB}, \varepsilon_A, \varepsilon_B$ sont mutuellement indépendantes, mais ici on fait juste l'hypothèse d'une indépendance 2 à 2.

Je réponds avec l'hypothèse supplémentaire : " $\varepsilon_{AB}, \varepsilon_A, \varepsilon_B$ sont mutuellement indépendantes" et je n'utilise pas le corollaire 1 de la partie I.

$$Y = \begin{pmatrix} \mu + \varepsilon_{AB} + \varepsilon_A \\ \mu + \varepsilon_{AB} + \varepsilon_B \end{pmatrix} \quad \text{donc} \quad Q_2(a) = a^T Y = \mu + a_1 \varepsilon_A + a_2 \varepsilon_B + (a_1 + a_2) \varepsilon_{AB}$$

donc (comme $a_1 + a_2 + a_1 + a_2 \neq 0$) $Q_2(a)$ est une gaussienne

d'espérance $E(Q_2(a)) = \mu$ et de variance $V(Q_2(a)) = \sigma_2(a_1^2 t_A + a_2^2 t_A + (a_1 + a_2)^2 t_{AB})$

$$\text{or } a^T M_2 D_{AB} M_2^T a = (a_1 \quad a_2) \begin{pmatrix} t_{AB} + t_A & t_{AB} \\ t_{AB} & t_{AB} + t_B \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = a_1^2 t_A + a_2^2 t_A + (a_1 + a_2)^2 t_{AB}$$

$\boxed{Q_2(a) \text{ est une gaussienne d'espérance } \mu \text{ et de variance } a^T M_2 D_{AB} M_2^T a}$

(d)

$$\begin{aligned} M_2 D_{AB} M_2^T &= \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix} \begin{pmatrix} t_{AB} & 0 & 0 \\ 0 & t_A & 0 \\ 0 & 0 & t_B \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & 0 \\ 0 & 1 \end{pmatrix} \\ &= \begin{pmatrix} t_{AB} & t_A & 0 \\ t_{AB} & 0 & t_B \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & 0 \\ 0 & 1 \end{pmatrix} \\ &= \begin{pmatrix} t_{AB} + t_A & t_{AB} \\ t_{AB} & t_{AB} + t_B \end{pmatrix} \\ &= \begin{pmatrix} t_{AB} & t_{AB} \\ t_{AB} & t_{AB} \end{pmatrix} + \begin{pmatrix} t_A & 0 \\ 0 & t_B \end{pmatrix} \end{aligned}$$

on a bien :

$$\boxed{M_2 D_{AB} M_2^T = t_{AB} \mathbf{1}_2 \mathbf{1}_2^T + \begin{pmatrix} t_A & 0 \\ 0 & t_B \end{pmatrix}}$$

2. (Non corrigé)

3. (Non corrigé)