

Exercice 1 : Estimation

Partie 1 : variance σ^2 connue

1) La vraisemblance de (y_1, \dots, y_n) est définie par

$$\begin{aligned} L(y_1, \dots, y_n; a) &= \prod_{i=1}^n f(y_i; a), \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{(y_i - ax_i)^2}{2\sigma^2} \right], \\ &= (2\pi\sigma^2)^{-n/2} \exp \left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - ax_i)^2 \right]. \end{aligned}$$

On a alors

$$\ln L(y_1, \dots, y_n; a) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - ax_i)^2.$$

En étudiant le signe de $\frac{\partial \ln L(x_1, \dots, x_n; \lambda)}{\partial a}$, on obtient :

$$\begin{aligned} \frac{\partial \ln L(y_1, \dots, y_n; a)}{\partial a} &\geq 0 \iff \frac{1}{\sigma^2} \left[\sum_{i=1}^n y_i x_i - a \sum_{i=1}^n x_i^2 \right] \geq 0, \\ &\iff a \leq \frac{\sum_{i=1}^n y_i x_i}{\sum_{i=1}^n x_i^2}. \end{aligned}$$

La vraisemblance possède donc un maximum global unique obtenu pour $a = \frac{\sum_{i=1}^n y_i x_i}{\sum_{i=1}^n x_i^2}$ d'où

$$\hat{a}_{\text{MV}} = \frac{\sum_{i=1}^n Y_i x_i}{\|x\|^2}.$$

2) Le biais de l'estimateur \hat{a}_{MV} est défini par

$$\text{Biais}(\hat{a}_{\text{MV}}) = E[\hat{a}_{\text{MV}}] - a,$$

avec

$$\begin{aligned} E[\hat{a}_{\text{MV}}] &= \frac{1}{\|x\|^2} \sum_{i=1}^n E[Y_i] x_i, \\ &= \frac{1}{\|x\|^2} \sum_{i=1}^n (ax_i) x_i, \\ &= a. \end{aligned}$$

L'estimateur \hat{a}_{MV} est donc un estimateur non biaisé de a .

3) La borne de Cramer-Rao pour les estimateurs non biaisés du paramètre a est définie par

$$\begin{aligned} BCR(a) &= \frac{-1}{E \left[\frac{\partial^2 \ln L(Y_1, \dots, Y_n; a)}{\partial a^2} \right]}, \\ &= \frac{-1}{E \left[\frac{-1}{\sigma^2} \sum_{i=1}^n x_i^2 \right]}, \\ &= \frac{\sigma^2}{\|x\|^2}, \end{aligned}$$

tandis que la variance de l'estimateur \hat{a}_{MV} est

$$\begin{aligned} \text{var} [\hat{a}_{\text{MV}}] &= \frac{1}{\|x\|^4} \text{var} \left[\sum_{i=1}^n Y_i x_i \right], \\ &= \frac{1}{\|x\|^4} \sum_{i=1}^n x_i^2 \text{var} (Y_i), \\ &= \frac{\sigma^2}{\|x\|^2}. \end{aligned}$$

L'estimateur \hat{a}_{MV} est donc l'estimateur efficace de a .

4) En vertu de l'indépendance entre les variables aléatoires e_1, \dots, e_n , le vecteur (y_1, \dots, y_n) est un vecteur Gaussien. Donc par transformation affine d'un vecteur Gaussien, \hat{a}_{MV} est une variable aléatoire normale $\mathcal{N} \left(a, \frac{\sigma^2}{\|x\|^2} \right)$. On a alors

$$\frac{\hat{a}_{\text{MV}} - a}{\frac{\sigma}{\|x\|}} \sim \mathcal{N}(0, 1).$$

On a alors

$$\begin{aligned} P \left[\left| \frac{\hat{a}_{\text{MV}} - a}{\frac{\sigma}{\|x\|}} \right| < u \right] &= \int_{-u}^u \frac{1}{\sqrt{2\pi}} \exp \left(-\frac{u^2}{2} \right) du, \\ &= 1 - 2G(u). \end{aligned}$$

Si on se fixe

$$\alpha = P \left[\left| \frac{\hat{a}_{\text{MV}} - a}{\frac{\sigma}{\|x\|}} \right| < u \right],$$

on a

$$u = G^{-1} \left(\frac{1 - \alpha}{2} \right).$$

Un intervalle de confiance pour \hat{a}_{MAP} avec le coefficient de confiance α est donc défini par

$$\left| \frac{\hat{a}_{\text{MV}} - a}{\frac{\sigma}{\|x\|}} \right| < G^{-1} \left(\frac{1 - \alpha}{2} \right),$$

c'est-à-dire

$$-\frac{\sigma}{\|x\|}G^{-1}\left(\frac{1-\alpha}{2}\right) < \hat{a}_{\text{MV}} - a < \frac{\sigma}{\|x\|}G^{-1}\left(\frac{1-\alpha}{2}\right),$$

et finalement

$$\hat{a}_{\text{MV}} - \frac{\sigma}{\|x\|}G^{-1}\left(\frac{1-\alpha}{2}\right) < a < \hat{a}_{\text{MV}} + \frac{\sigma}{\|x\|}G^{-1}\left(\frac{1-\alpha}{2}\right).$$

L'intervalle de confiance pour le paramètre a avec un degré de confiance α est donc

$$\left[\hat{a}_{\text{MV}} - \frac{\sigma}{\|x\|}G^{-1}\left(\frac{1-\alpha}{2}\right), \hat{a}_{\text{MV}} + \frac{\sigma}{\|x\|}G^{-1}\left(\frac{1-\alpha}{2}\right) \right].$$

5) La loi a posteriori de $a|y_1, \dots, y_n$ est définie par

$$\begin{aligned} f(a|y_1, \dots, y_n) &\propto \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - ax_i)^2\right] \exp\left[-\frac{1}{2\sigma_a^2} (a - m_a)^2\right], \\ &\propto \exp\left[-\frac{(a - \mu)^2}{2v^2}\right] \end{aligned}$$

qui est loi normale $\mathcal{N}(\mu, v^2)$. Le calcul de μ et de v^2 a été fait en cours. En identifiant les coefficients de a^2 et de a , on obtient

$$\begin{aligned} \frac{1}{v^2} &= \frac{1}{\sigma^2} \sum_{i=1}^n x_i^2 + \frac{1}{\sigma_a^2}, \\ \frac{\mu}{v^2} &= \frac{1}{\sigma^2} \sum_{i=1}^n y_i x_i + \frac{m_a}{\sigma_a^2}, \end{aligned}$$

c'est-à-dire

$$\begin{aligned} v^2 &= \frac{\sigma^2 \sigma_a^2}{\|x\|^2 \sigma_a^2 + \sigma^2}, \\ \mu &= \frac{\sigma_a^2}{\|x\|^2 \sigma_a^2 + \sigma^2} \sum_{i=1}^n y_i x_i + \frac{\sigma^2}{\|x\|^2 \sigma_a^2 + \sigma^2} m_a. \end{aligned}$$

L'estimateur MAP est la valeur qui maximise cette loi a posteriori, d'où

$$\hat{a}_{\text{MAP}} = \frac{\|x\|^2 \sigma_a^2}{\|x\|^2 \sigma_a^2 + \sigma^2} \left(\frac{1}{\|x\|^2} \sum_{i=1}^n Y_i x_i \right) + \frac{\sigma^2}{\|x\|^2 \sigma_a^2 + \sigma^2} m_a.$$

On voit que cet estimateur est une combinaison linéaire de \hat{a}_{MV} et de la moyenne de la loi a priori m_a . De plus

- quand $\sigma_a^2 \rightarrow 0$, on a

$$\frac{\|x\|^2 \sigma_a^2}{\|x\|^2 \sigma_a^2 + \sigma^2} \simeq 0 \text{ et } \frac{\sigma^2}{\|x\|^2 \sigma_a^2 + \sigma^2} \simeq 1,$$

ce qui montre que \hat{a}_{MAP} se comporte comme la moyenne de la loi a posteriori m_a (la loi a priori est très informative et donc on lui fait confiance),

- quand $\sigma_a^2 \rightarrow \infty$, on a

$$\frac{\|x\|^2 \sigma_a^2}{\|x\|^2 \sigma_a^2 + \sigma^2} \simeq 1 \text{ et } \frac{\sigma^2}{\|x\|^2 \sigma_a^2 + \sigma^2} \simeq 0,$$

ce qui montre que \hat{a}_{MAP} se comporte comme \hat{a}_{MV} (la loi a priori est très peu informative et donc on fait confiance aux données).

Partie 2 : variance σ^2 inconnue

1) L'estimateur du maximum de vraisemblance du vecteur $\theta = (a, \sigma^2)$ s'obtient en annulant les dérivées partielles de la vraisemblance par rapport à a et σ^2 . On obtient alors

$$\begin{aligned} \frac{\partial \ln L(y_1, \dots, y_n; a)}{\partial a} &= 0 \implies a = \frac{\sum_{i=1}^n y_i x_i}{\|x\|^2}, \\ \frac{\partial \ln L(y_1, \dots, y_n; a)}{\partial \sigma^2} &= 0 \implies -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (y_i - ax_i)^2 = 0, \end{aligned}$$

d'où

$$\begin{aligned} a &= \frac{\sum_{i=1}^n y_i x_i}{\|x\|^2}, \\ \sigma^2 &= \frac{1}{n} \sum_{i=1}^n (y_i - ax_i)^2. \end{aligned}$$

On en conclut que l'estimateur du maximum de vraisemblance de $\theta = (a, \sigma^2)$ est $\hat{\theta}_{\text{MV}} = (\hat{a}_{\text{MV}}, \hat{\sigma}_{\text{MV}}^2)$ avec

$$\begin{aligned} \hat{a}_{\text{MV}} &= \frac{\sum_{i=1}^n Y_i x_i}{\|x\|^2}, \\ \hat{\sigma}_{\text{MV}}^2 &= \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{a}_{\text{MV}} x_i)^2. \end{aligned}$$

2) On sait que

$$E[\hat{a}_{\text{MV}}] = E\left[\frac{\sum_{i=1}^n Y_i x_i}{\|x\|^2}\right] = a.$$

Il reste donc à déterminer $E[\hat{\sigma}_{\text{MV}}^2]$ comme suit

$$E[\hat{\sigma}_{\text{MV}}^2] = \frac{1}{n} \sum_{i=1}^n E[(Y_i - \hat{a}_{\text{MV}} x_i)^2].$$

Mais

$$\begin{aligned} E[(Y_i - \hat{a}_{\text{MV}} x_i)^2] &= E[Y_i^2] - 2E[x_i Y_i \hat{a}_{\text{MV}}] + x_i^2 E[\hat{a}_{\text{MV}}^2] \\ &= \sigma^2 + a^2 x_i^2 - 2E[(x_i Y_i) \hat{a}_{\text{MV}}] + x_i^2 E[\hat{a}_{\text{MV}}^2], \end{aligned}$$

d'où

$$\begin{aligned}
E \left[\widehat{\sigma}_{\text{MV}}^2 \right] &= \sigma^2 + a^2 \frac{1}{n} \sum_{i=1}^n x_i^2 - \frac{2}{n} E \left[\left(\sum_{i=1}^n x_i Y_i \right) \widehat{a}_{\text{MV}} \right] + \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) E \left[\widehat{a}_{\text{MV}}^2 \right], \\
&= \sigma^2 + \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) (a^2 + E \left[\widehat{a}_{\text{MV}}^2 \right]) - \frac{2}{n} E \left[\|x\|^2 \widehat{a}_{\text{MV}} \right], \\
&= \sigma^2 + \left(\frac{1}{n} \|x\|^2 \right) \left(a^2 + a^2 + \frac{\sigma^2}{\|x\|^2} \right) - \frac{2}{n} \|x\|^2 \left(a^2 + \frac{\sigma^2}{\|x\|^2} \right), \\
&= \sigma^2 \left(1 + \frac{1}{n} - \frac{2}{n} \right), \\
&= \frac{n-1}{n} \sigma^2.
\end{aligned}$$

On en déduit qu'un estimateur non biaisé de σ^2 est

$$\widetilde{\sigma}^2 = \frac{n}{n-1} \widehat{\sigma}_{\text{MV}}^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \widehat{a}_{\text{MV}} x_i)^2.$$

3) Pour déterminer les variances minimales d'estimateurs non biaisés de a et σ^2 , il faut déterminer l'inverse de la matrice d'information de Fisher

$$\begin{pmatrix} E \left[\frac{\partial^2 \ln L}{\partial a^2} \right] & E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] \\ E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] & E \left[\frac{\partial^2 \ln L}{\partial (\sigma^2)^2} \right] \end{pmatrix}$$

dont les termes se calculent comme suit

$$\begin{aligned}
E \left[\frac{\partial^2 \ln L}{\partial a^2} \right] &= E \left[\frac{-1}{\sigma^2} \sum_{i=1}^n x_i^2 \right] = \frac{-1}{\sigma^2} \sum_{i=1}^n x_i^2, \\
E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] &= E \left[\frac{-1}{\sigma^4} \left(\sum_{i=1}^n Y_i x_i - a \sum_{i=1}^n x_i^2 \right) \right] = \frac{-1}{\sigma^4} \sum_{i=1}^n [x_i (ax_i) - ax_i^2] = 0, \\
E \left[\frac{\partial^2 \ln L}{\partial (\sigma^2)^2} \right] &= E \left[\frac{n}{2\sigma^4} + \frac{-2}{2} \sum_{i=1}^n (y_i - ax_i)^2 \right] = \frac{n}{2\sigma^4} - \frac{n\sigma^2}{\sigma^6} = \frac{-n}{2\sigma^4}.
\end{aligned}$$

La matrice d'information de Fisher est donc diagonale et s'écrit

$$\begin{pmatrix} E \left[\frac{\partial^2 \ln L}{\partial a^2} \right] & E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] \\ E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] & E \left[\frac{\partial^2 \ln L}{\partial (\sigma^2)^2} \right] \end{pmatrix} = \begin{pmatrix} \frac{-1}{\sigma^2} \sum_{i=1}^n x_i^2 & 0 \\ 0 & \frac{-n}{2\sigma^4} \end{pmatrix}.$$

Son inverse vérifie

$$\begin{pmatrix} E \left[\frac{\partial^2 \ln L}{\partial a^2} \right] & E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] \\ E \left[\frac{\partial^2 \ln L}{\partial a \partial \sigma^2} \right] & E \left[\frac{\partial^2 \ln L}{\partial (\sigma^2)^2} \right] \end{pmatrix}^{-1} = \begin{pmatrix} \frac{-\sigma^2}{\|x\|^2} & 0 \\ 0 & \frac{-2\sigma^4}{n} \end{pmatrix}.$$

On en déduit les inégalités

$$\text{var} [\widehat{a}] \geq \frac{\sigma^2}{\|x\|^2} \text{ et } \text{var} [\widehat{\sigma}^2] \geq \frac{2\sigma^4}{n}.$$

Exercice 2 : Test de Neyman-Pearson

1) Le test de Neyman-Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > S_\alpha.$$

Mais

$$\begin{aligned} \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > S_\alpha &\Leftrightarrow \frac{(2\pi\sigma^2)^{-n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - a_1 x_i)^2\right]}{(2\pi\sigma^2)^{-n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - a_0 x_i)^2\right]} > S_\alpha, \\ &\Leftrightarrow \exp\left[\frac{1}{2\sigma^2} \left(\sum_{i=1}^n (y_i - a_0 x_i)^2 - \sum_{i=1}^n (y_i - a_1 x_i)^2\right)\right] > S_\alpha, \\ &\Leftrightarrow 2(a_1 - a_0) \sum_{i=1}^n y_i x_i + (a_0^2 - a_1^2) \sum_{i=1}^n x_i^2 > \nu_\alpha. \end{aligned}$$

Pour $a_1 > a_0$, on en déduit le test équivalent

$$\text{Rejet de } H_0 \text{ si } T_n = \sum_{i=1}^n Y_i x_i > K_\alpha.$$

La statistique du test de Neyman-Pearson est donc

$$T_n = \sum_{i=1}^n x_i Y_i.$$

La région critique de ce test est définie par

$$\left\{ y \in \mathbb{R}^n \mid \sum_{i=1}^n x_i Y_i > K_\alpha \right\}.$$

2) Le risque de première espèce α est défini par

$$\begin{aligned} \alpha &= P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}], \\ &= P[T_n > K_\alpha \mid a = a_0]. \end{aligned}$$

Puisque les variables aléatoires $Y_i, i = 1, \dots, n$ sont indépendantes, le vecteur (Y_1, \dots, Y_n) est un vecteur Gaussien et donc dans la mesure où $x = (x_1, \dots, x_n)$ est non nul, la transformation affine $\sum_{i=1}^n x_i Y_i$ est distribuée suivant une loi normale. La moyenne et la variance de cette loi normale sont

$$\begin{aligned} E\left[\sum_{i=1}^n x_i Y_i\right] &= \sum_{i=1}^n x_i (a x_i) = a \|x\|^2, \\ \text{var}\left[\sum_{i=1}^n x_i Y_i\right] &= \sigma^2 \left(\sum_{i=1}^n x_i^2\right) = \sigma^2 \|x\|^2. \end{aligned}$$

On en déduit

$$\begin{aligned}
\alpha &= P [T_n > K_\alpha \mid a = a_0], \\
&= P [T_n > K_\alpha \mid T_n \sim \mathcal{N}(a_0 \|x\|^2, \sigma^2 \|x\|^2)], \\
&= P \left[U_n = \frac{T_n - a_0 \|x\|^2}{\sigma \|x\|} > \frac{K_\alpha - a_0 \|x\|^2}{\sigma \|x\|} \mid U_n \sim \mathcal{N}(0, 1) \right], \\
&= G \left(\frac{K_\alpha - a_0 \|x\|^2}{\sigma \|x\|} \right).
\end{aligned}$$

De la même façon

$$\begin{aligned}
\beta &= P [\text{Rejeter } H_1 \mid H_1 \text{ vraie}], \\
&= P [T_n \leq K_\alpha \mid a = a_1], \\
&= 1 - P [T_n > K_\alpha \mid a = a_1], \\
&= 1 - P [T_n > K_\alpha \mid T_n \sim \mathcal{N}(a_1 \|x\|^2, \sigma^2 \|x\|^2)], \\
&= 1 - G \left(\frac{K_\alpha - a_1 \|x\|^2}{\sigma \|x\|} \right).
\end{aligned}$$

3) Les courbes caractéristiques opérationnelles du récepteur (courbes COR) expriment la puissance du test $\pi = 1 - \beta$ en fonction de α . Dans le cas présent, on a

$$\frac{K_\alpha - a_0 \|x\|^2}{\sigma \|x\|} = G^{-1}(\alpha).$$

Donc

$$K_\alpha = \sigma \|x\| G^{-1}(\alpha) + a_0 \|x\|^2.$$

En remplaçant cette valeur de K_α dans l'expression de la puissance, on obtient

$$\begin{aligned}
\pi &= G \left(\frac{K_\alpha - a_1 \|x\|^2}{\sigma \|x\|} \right), \\
&= G \left[G^{-1}(\alpha) - (a_1 - a_0) \frac{\|x\|}{\sigma} \right].
\end{aligned}$$

On voit donc que la performance du test dépend de la quantité

$$(a_1 - a_0) \frac{\|x\|}{\sigma}.$$

En particulier, plus $\|x\|$ est grand, plus la puissance du test est élevée.

Exercice 3 : Tests d'ajustement

1) La variable aléatoire U_i définie par

$$U_i = \frac{Y_i - ax_i}{\sigma}.$$

est clairement distribuée suivant une loi normale $\mathcal{N}(0, 1)$. Pour effectuer le test du χ^2 , il faut tout d'abord déterminer les quatre classes équiprobables. En vertu de la symétrie de la loi normale, ces classes sont nécessairement de la forme

$$\begin{aligned} C_1 & :]-\infty, -b[, \\ C_2 & : [-b, 0[, \\ C_3 & : [0, b[, \\ C_4 & : [b, \infty[. \end{aligned}$$

On peut déterminer b de la façon suivante

$$\int_b^\infty \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right) du = G(b) = \frac{1}{4},$$

d'où

$$b = G^{-1}\left(\frac{1}{4}\right).$$

Ensuite, on détermine les nombres d'observation u_1, \dots, u_n appartenant à chaque classe notés N_1, \dots, N_4 . On calcule ensuite la statistique de test

$$\phi = \sum_{i=1}^4 \frac{(N_i - np_i)^2}{np_i} = \frac{4}{n} \sum_{i=1}^4 \left(N_i - \frac{n}{4}\right)^2.$$

On sait que ϕ est distribuée suivant une loi du χ_{K-1}^2 sous l'hypothèse H_0 , où $K = 4$ est le nombre classes. On rejette donc l'hypothèse H_0 si

$$\phi > s_\alpha,$$

avec

$$\begin{aligned} \alpha & = P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}], \\ & = P[\phi > s_\alpha \mid \phi \sim \chi_3^2]. \end{aligned}$$

Si $g_n(u)$ est la densité d'une loi du χ_n^2 , on pose

$$\int_x^\infty g_n(u) du = G_n(x),$$

et on obtient

$$\alpha = G_3(s_\alpha) \implies s_\alpha = G_3^{-1}(\alpha).$$

2) Si Z_i est la variable aléatoire définie par

$$Z_i = \begin{cases} 1 & \text{si } \left| \frac{Y_i}{x_i} \right| > 2a \\ 0 & \text{sinon} \end{cases},$$

on a

$$\begin{aligned} p_i &= P[Z_i = 1 | H_0 \text{ vraie}], \\ &= P\left[\left|\frac{Y_i}{x_i}\right| > 2a \mid Y_i \sim \mathcal{N}(a_0x_i, \sigma^2)\right], \\ &= P\left[|Y_i| > 2a_0x_i \mid Y_i \sim \mathcal{N}(a_0x_i, \sigma^2)\right], \\ &= P\left[Y_i > 2a_0x_i \mid Y_i \sim \mathcal{N}(a_0x_i, \sigma^2)\right] \\ &\quad + P\left[Y_i < -2a_0x_i \mid Y_i \sim \mathcal{N}(a_0x_i, \sigma^2)\right], \\ &= P\left[U_i = \frac{Y_i - a_0x_i}{\sigma} > \frac{a_0x_i}{\sigma} \mid U_i \sim \mathcal{N}(0, 1)\right] \\ &\quad + P\left[U_i = \frac{Y_i - a_0x_i}{\sigma} < \frac{-3a_0x_i}{\sigma} \mid U_i \sim \mathcal{N}(0, 1)\right], \\ &= G\left(\frac{a_0x_i}{\sigma}\right) + G\left(\frac{3a_0x_i}{\sigma}\right). \end{aligned}$$

La moyenne et la variance de la variable aléatoire $Z = \sum_{i=1}^n Z_i$ sont alors définies par

$$\begin{aligned} m_Z &= E[Z] = \sum_{i=1}^n p_i, \\ \sigma_Z^2 &= \text{var}[Z] = \sum_{i=1}^n p_i q_i. \end{aligned}$$

Le risque α associé à la stratégie

$$\text{Rejet de } H_0 \text{ si } Z > \frac{n}{10}.$$

se détermine comme suit

$$\begin{aligned} \alpha &= P\left[Z > \frac{n}{10} \mid H_0 \text{ vraie}\right], \\ &= P\left[U = \frac{Z - m_Z}{\sigma_Z} > \frac{\frac{n}{10} - m_Z}{\sigma_Z} \mid U \sim \mathcal{N}(m_Z, \sigma_Z^2)\right], \\ &= G\left(\frac{\frac{n}{10} - m_Z}{\sigma_Z}\right). \end{aligned}$$