

Une introduction aux plans d'expériences

1 Modèle linéaire

Pour n un entier naturel non nul, on considère le modèle linéaire :

$$Y_i = a^* + b^* f(x_i) + \varepsilon_i, \quad i = 1, \dots, n,$$

où, pour $i = 1, \dots, n$, $x_i \in [0, 1]$ et les variables (ε_i) sont i.i.d. de loi $\mathcal{N}(0, \sigma^2)$. On suppose que f est une fonction continue non constante sur $[0, 1]$.

- 1) Que faut-il supposer sur $(x_i)_{i=1, \dots, n}$ pour que le modèle soit identifiable? A partir de maintenant, on supposera que cette condition est vérifiée et on notera Σ l'ensemble des plans d'expériences qui vérifient cette condition. Soit $\theta^* = (a^*, b^*)^T$. Donner l'estimateur du maximum de vraisemblance $\hat{\theta}_n$ de θ^* . Que vaut la matrice de variance covariance de cet estimateur? On note Γ_{θ^*} cette matrice.
- 2) Afin de fixer les points $x = (x_i)_{i=1, \dots, n}$ du plan d'expériences, on considère le critère :

$$D(x) = \frac{1}{\det \Gamma_{\theta^*}}.$$

Calculer D en fonction de x .

- 3) Montrer qu'il existe $m < M$ tels que la fonction f prenne toutes les valeurs de $[m, M]$. On pose

$$\tilde{D}(y) = D(x) \text{ où } y = (y_i)_{i=1, \dots, n}, \quad y_i = f(x_i), \quad i = 1, \dots, n.$$

Montrer que

$$\max_{x \in \Sigma} D(x) = \max_{y \in \tilde{\Sigma}} \tilde{D}(y),$$

où

$$\tilde{\Sigma} = \{y : y_i \in [m, M] \quad i = 1, \dots, n, \exists i, i' \in \{1, \dots, n\}, i \neq i', y_i \neq y_{i'}\}$$

- 4) Montrer que

$$\tilde{D}(y) = C_n \sum_{i=1}^n (y_i - \bar{y})^2,$$

où $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ et C_n ne dépend que de n . En déduire que

$$\max_{y \in \tilde{\Sigma}} \tilde{D}(y) = \max_{y: y_i \in [m, M], i=1 \dots n} \tilde{D}(y)$$

Soit y^* avec $\max_{y: y_i \in [m, M], i=1 \dots n} \tilde{D}(y) = \tilde{D}(y^*)$. Supposons qu'il existe un indice $i^* \in \{1, \dots, n\}$ avec $m < y_{i^*}^* < M$ et considérons la fonction φ sur $]m, M[$ définie, pour $y \in]m, M[$, par

$$\varphi(y) = \tilde{D}(\tilde{y}^*), \text{ avec, pour } i \neq i^* \quad \tilde{y}_i^* = y_i^* \text{ et } \tilde{y}_{i^*}^* = y.$$

Calculer la fonction φ et étudier ses variations sur $]m, M[$. En déduire que l'hypothèse faite sur $y_{i^*}^*$ est incorrecte et que, pour $i = 1, \dots, n$, $y_i^* \in \{m, M\}$.

5) On pose

$$r^* = \text{Card} \{i \in \{1, \dots, n\} : y_i^* = m\}.$$

On suppose que $n = 2p$ ($p \in \mathbb{N}^*$), que vaut r^* ? Dans le cas $n = 2p + 1$, quelles sont les valeurs possibles pour r^* .

6) Décrire tous les plans d'expériences D -optimaux.

7) On se place dans le cas où $f(x) = 2\pi x \sin(2\pi x)$. Déterminer précisément les plans D -optimaux.

2 Carré Latin

On se propose de construire un générateur aléatoire de carré latin (de taille $n > 1$). Pour cela, on va utiliser les remarques qui suivent.

- Le carré suivant est latin :

$$\begin{array}{cccc} 1 & 2 & \cdots & n \\ 2 & 3 & \cdots & 1 \\ \vdots & & & \vdots \\ n & 1 & \cdots & n-1 \end{array}$$

- Si l'on dispose d'un carré latin, on construit un nouveau carré latin en permuttant ses lignes et/ou ses colonnes.

En utilisant la procédure SCILAB `grand`, construire une fonction qui génère un carré latin aléatoire.

3 D et E optimalités

On considère, pour $x \in [-1, 1]$, le modèle de régression :

$$Y(x) = \sum_{i=1}^k a_i^* f_i(x) + \varepsilon(x).$$

Les fonctions de régression $(f_i)_{i=1, \dots, k}$ sont données.

1. On se place dans le cas où $k = 3$ et $f_i(x) = x^{i-1}, i = 1, 2, 3$. On s'intéresse aux plans d'expériences à $n = 15$ points. En utilisant l'optimiseur de SCILAB, construire les plans D et E optimaux.
2. En utilisant les polynômes de Legendre sous SCILAB, tracer la courbe représentative de la fonction $(x^2 - 1)P_2'(x)$ où P_i désigne le polynôme de Legendre de degré $i \geq 0$. Vérifier alors le plan D -optimal trouvé en 1).
3. On suppose encore que $n = 6$, mais on s'intéresse ici à $k = 3$ avec pour $x \in [-1, 1]$, $f_1(x) = 1$, $f_2(x) = \exp(x)$, $f_3(x) = x^2$. Ecrire un code qui calcule le plan D -optimal. Comparer la variance de ce plan à celle obtenue en utilisant les points $-1, 1, 1/2, -1, 1, 1/2$.

4 D -optimalité en dimension 2

Sur $[-1, 1]^2$, on considère le modèle de régression :

$$Z(x, y) = a^* + b^*x + c^*y + d^*x^2 + e^*y^2 + f^*xy + \varepsilon(x, y).$$

Utiliser l'optimiseur de SCILAB pour déterminer un plan D -optimal à 20 points. Représenter ce plan dans l'espace à deux dimensions.