



Ecole Centrale de Nantes

Compte-Rendu TP6 :

Evaluation d'une proportion – Moindres carrés avec contraintes linéaires

Préparé par :

Hugo Salou

Edwin Abou Jaoude

Partie 1. Évaluation d'une proportion

On s'intéresse à un cas concret : une élection entre deux candidats C_1 et C_2 . On réalise un sondage auprès d'un grand nombre d'électeurs et on obtient alors une réalisation $\mathbf{x} = (x_1, \dots, x_n)$ (sous forme de 0 ou de 1) d'un échantillon (X_1, \dots, X_n) de taille n , où les X_i suivent une loi de Bernoulli $\mathcal{B}(p)$, où p est la proportion des suffrages pour C_1 . Dans cette section, on essaie d'estimer la valeur de p , et les incertitudes associées à travers un intervalle de confiance à 95%.

1.1. Construction de l'estimateur

On pose $\bar{p}_k = \frac{1}{k} \sum_{i=1}^k x_i$ une réalisation de la variable $\bar{X}_k = \frac{1}{k} \sum_{i=1}^k X_i$, qui est un estimateur de la proportion p recherchée. Cet estimateur est sans biais, il converge presque sûrement vers p , et converge en L^2 .

On sait donc que :

- ◇ la dispersion des \bar{X}_k autour de p tend vers 0 pour k grand ;
- ◇ la suite $(\bar{p}_k)_{k \in \mathbb{N}}$ converge vers p quelle que soit les valeurs de la réalisation (x_1, \dots, x_n) .

1.2. Construction d'un intervalle de confiance

On cherche un intervalle I_k tel que l'on ait la relation $P(p \in I_k) \simeq 1 - \alpha$. On aimerait un intervalle à 95%, on pose donc $\alpha = 5\%$.

Après calcul, on trouve que :

$$I_k = \bar{X}_k \pm z_{\alpha/2} \sqrt{\frac{\bar{X}_k(1 - \bar{X}_k)}{k}}.$$

Dès lors que les inégalités $k \bar{p}_k \geq 5$ et $k(1 - \bar{p}_k) \geq 5$ sont vérifiées, on pourra considérer que l'approximation de l'intervalle de confiance $P(p \in I_k) \simeq 1 - \alpha$ est vérifiée.

1.3. Mise en œuvre sur des échantillons d'intention de vote

Dans cette section, on pose $p = 51\%$, la proportion de candidats à vouloir voter pour le candidat C_1 .

On génère une réalisation x d'un échantillon de $N = 10\,000$ électeurs. Sur la figure ci-après (**Erreur ! Source du renvoi introuvable.**), on donne (k, \bar{p}_k) pour $k = 1\,000, 2\,000, \dots, 10\,000$.

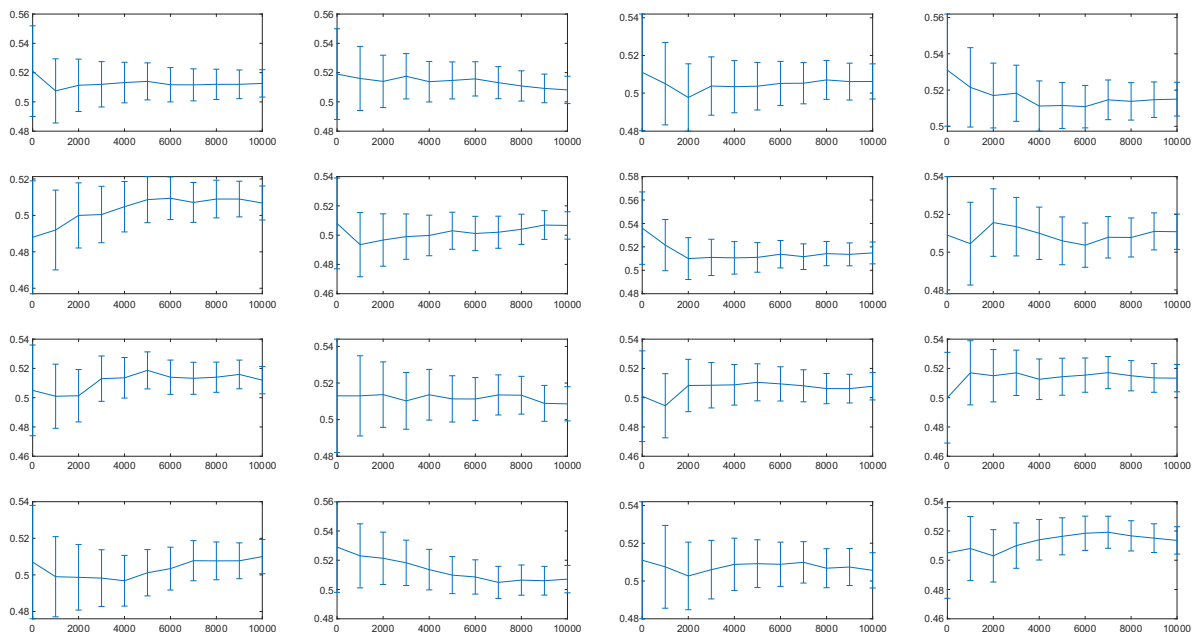


Figure 1. Différentes tentatives d'estimation de la valeur de p

On réalise ce graphe plusieurs fois, avec des réalisations différentes, mais une même valeur de p . On observe que, quand k augmente, nous observons bien les propriétés de l'estimateur :

- ◇ la convergence presque sûre avec la convergence de \bar{p}_k vers p ;
- ◇ la convergence en L^2 avec la diminution de la taille des incertitudes.

Dans la plupart des cas, le candidat C_1 qui a la majorité (51%) des électeurs gagne. Mais, bien plus rarement, il arrive que ce soit le candidat C_2 qui gagne l'élection. On montre un de ces cas dans la **Erreur ! Source du renvoi introuvable.** ci-dessous.




Figure 2. Le candidat C_1 perd l'élection

On considère que C_1 perd l'élection dès lors que $\bar{p}_k < 50\%$. La victoire de C_2 , quand elle a lieu, est bien plus souvent pour des plus petites valeurs de k ($k = 1\ 000$, ou $k = 2\ 000$ notamment).

On estime p avec $k = 10\ 000$ réalisations et on vérifie si $p \in I_k$. On réalise ce protocole 100 fois, afin d'estimer le niveau asymptotique de I_k . On obtient des résultats « proches » de 95%, qui varient généralement entre 87% et 100%. On a donc bien un intervalle de confiance de niveau asymptotique 95%.

Partie 2. Moindres carrés avec contraintes linéaires

2.1. Moindres Carrés Avec Contraintes Linéaires

Nous allons nous intéresser à un problème de moindres carrés avec des contraintes linéaires uniquement. On souhaite trouver \mathbf{x} qui minimise $\frac{1}{2} \|\mathbf{C}\mathbf{x} - \mathbf{d}\|_2^2$ avec la contrainte $\mathbf{A}_{\text{éq}}\mathbf{x} = \mathbf{b}_{\text{éq}}$, où :

- $\mathbf{C} \in \mathcal{M}_{n,m}(\mathbb{R})$ de rang n ,
- \mathbf{d} est un vecteur.

Le seul point de minimum \mathbf{x}^* sur l'ensemble des contraintes est accompagné d'un multiplicateur de Lagrange $\boldsymbol{\lambda}^*$ tel que le couple $(\mathbf{x}^*, \boldsymbol{\lambda}^*)$ soit solution du système suivant :

$$\begin{pmatrix} \mathbf{C}^T \mathbf{C} & \mathbf{A}_{\text{éq}}^T \\ \mathbf{A}_{\text{éq}} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{x} \\ \boldsymbol{\lambda} \end{pmatrix} = \begin{pmatrix} \mathbf{C}^T \mathbf{d} \\ \mathbf{b}_{\text{éq}} \end{pmatrix}$$

La recherche se porte sur le vecteur \mathbf{x} qui satisfait au mieux le système $\mathbf{C}\mathbf{x} = \mathbf{d}$ avec les données suivantes :

$$\mathbf{C} = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \\ 1 & 3 & 9 \\ 1 & 4 & 16 \\ 1 & 5 & 25 \end{pmatrix}, \quad \mathbf{d} = \begin{pmatrix} 65.5 \\ -142 \\ 82.5 \\ -12 \\ 25 \\ -45 \end{pmatrix}, \quad \mathbf{A}_{\text{éq}} = \begin{pmatrix} 4 & 0 & 1 \\ 3 & 1 & 0 \end{pmatrix}, \quad \mathbf{b}_{\text{éq}} = \begin{pmatrix} 7 \\ 7 \end{pmatrix}$$

En utilisant la fonction `lsqlineq` dans le script, on obtient la solution $\mathbf{x}^* = (2, 1, -1)$, $\boldsymbol{\lambda}^* = (-1, 2)$ et $J(\mathbf{x}^*) = 1.6796 \times 10^4$ avec le résidu suivant :

$$\text{Résidu} = \begin{pmatrix} -63.5 \\ 144 \\ -82.5 \\ 8 \\ -35 \\ 27 \end{pmatrix}.$$

Il y a une différence entre la solution obtenue avec la fonction de `lsqlin` de Matlab.

```
x =
    1.7476
    1.7573
   -1.1609

>> jval

jval =

    3.3591e+04

>> residual

residual =

   -63.7524
   144.3440
   -81.8814
    8.5715
   -34.7974
   26.5119
```

Figure 3. Résultats en utilisant `sqlin`

2.2. Approximation-interpolation d'un nuage de points

On cherche à déterminer un polynôme P de la forme $P(x) = a_3x^3 + a_2x^2 + a_1x + a_0$ qui interpole les points $(-3,2)$ et $(3,5)$ et qui s'ajuste au mieux, selon la méthode des moindres carrés, aux autres points donnés :

x_i	-2	-1	0	1	2
y_i	6	4	5	3	1

L'objectif est de minimiser la fonction $\|Cx - d\|^2$ ou C est une matrice de la forme :

$$C = \begin{bmatrix} 1 & \dots & x_1^3 \\ \vdots & \ddots & \vdots \\ 1 & \dots & x_5^3 \end{bmatrix}$$

Cette matrice est de rang 5 car les x_i sont distincts. Le vecteur \mathbf{x} est défini comme :

$$\mathbf{x} = \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{bmatrix}$$

et est de dimension 4. La contrainte est donnée par $A\mathbf{x} = \mathbf{b}$ où :

$$A = \begin{bmatrix} 1 & -3 & (-3)^2 & (-3)^3 \\ 1 & 3 & 3^2 & 3^3 \end{bmatrix} \text{ et } \mathbf{b} = \begin{bmatrix} 5 \\ 2 \end{bmatrix}$$

Après application de la méthode décrite, le polynôme $P(x)$ trouvé est $P(x) = 0.2622x^3 - 0.0521x^2 - 1.8598x + 3.9691$




Figure 4. Graphe du polynôme sur l'intervalle $[-3; 3]$