

# TP 11 - MODÈLE LINÉAIRE GAUSSIEN

## 1 Modèle de régression simple

On considère tout d'abord dans ce TP le modèle de régression linéaire simple

$$Y_i = a + bX_i + \epsilon_i \quad i = 1 \dots n$$

où  $a$  et  $b$  sont les paramètres inconnus du modèle et les  $(\epsilon_i)_{i=1\dots n}$  sont des variables aléatoires indépendantes gaussiennes centrées de variance  $\sigma^2$  inconnue. L'objectif consiste à construire un ensemble de confiance  $A_\alpha(X, Y)$  de niveau  $\alpha$  à partir des données  $(X_i, Y_i)$ , ensemble tel que

$$P(a + bx \notin A_\alpha(X, Y)) \leq \alpha$$

1. Rappeler le principe de l'algorithme de Box-Muller et écrire une fonction BoxMuller.m simulant une loi gaussienne de moyenne et variance à préciser en paramètres.
2. Générer les données  $(X_i, Y_i)_{i=1\dots n}$  avec  $n = 50$ ,  $a = 1.5$ ,  $b = -1$  et  $\sigma = 0.5$  pour des  $X_i$  uniformément distribués sur  $[0; 1]$  et les  $Y_i$  construits via l'algorithme de Box-Muller.
3. Représenter le nuage de points grâce à l'option 's' de plot et en ayant préalablement classé par ordre croissant les  $X_i$ .
4. Identifier pour votre modèle, en fonction de vos données,  $\hat{a}$ ,  $\hat{b}$  et  $\hat{\sigma}^2$ .
5. Donner un intervalle de prédiction pour la loi conditionnelle  $\mathcal{L}(Y|X = x)$ , de niveau  $\alpha$  quelconque, en fonction du quantile symétrique  $h_\alpha$  d'ordre  $\alpha$  pour une loi de Student (à combien de degrés de liberté?).
6. Donner un intervalle de confiance de niveau  $\alpha$  quelconque, qui contiendra  $a + bx$ , en fonction des mêmes quantités précédemment évoquées.
7. Tracer sur le même graphique les données, la fonction à estimer, l'ensemble de prédiction et la droite de régression obtenus.
8. Écrire alors un programme.m automatisant ces procédures, prenant en argument  $a, b, \sigma, n$  et lancer le programme plusieurs fois pour vérifier que la région de confiance couvre la régression.

## 2 Test d'hypothèse linéaire gaussienne

Soit  $X$  le vecteur des observations, on dit que  $X$  satisfait un modèle linéaire gaussien ssi

$$X = A\theta + \epsilon$$

où

- $\theta$  est un paramètre du modèle de taille  $p$  (à estimer)
- $A$  est une matrice  $n \times p$  connue
- $\epsilon$  est un vecteur gaussien centré de variance  $\sigma^2 I_n$ .

Une autre écriture possible est

$$X = m + \epsilon$$

où  $m \in V = ImA$  et  $\epsilon \sim \mathcal{N}(0, \sigma^2 I_n)$ .

**Question 1** Montrer que ces deux écritures précédentes sont parfaitement équivalentes lorsque  $A$  est injective.

## 2.1 Régression linéaire

**Question 2** Préciser le modèle obtenu dans le cadre de la régression linéaire. Que vaut  $A$ ? Dans quel espace vit la moyenne  $m$  de  $X$ ?

## 2.2 Analyse de variance à un facteur

Ce modèle est utilisé pour étudier une variable d'intérêt en fonction d'une autre variable (ou facteur). La donnée de base est la donnée de  $I$  échantillons indépendants (un échantillon par valeurs possibles du facteur) :  $(X_{ij})_{i,j}$  où  $i \in \{1 \dots I\}, j \in \{1 \dots n_i\}$ . On suppose de plus que chacun des  $I$  échantillons est gaussien et que tous les échantillons ont la même variance.

**Question 3** Écrire le modèle précédent sous la forme de modèle linéaire gaussien. Que vaut  $A$ ? Dans quel espace vit la moyenne  $m$ ?

## 2.3 Analyse de variance à deux facteurs

A noter que le modèle précédent peut être étendu à deux facteurs d'influence.

**Question 4** Écrire le modèle à deux facteurs sous la forme de modèle linéaire gaussien. Que vaut  $A$ ? Dans quel espace vit la moyenne  $m$ ?

## 2.4 Estimateurs

**Question 5** Montrer l'équivalence entre l'estimateur des moindres carrés de  $(\theta, \sigma^2)$  et l'estimateur du maximum de vraisemblance dans le modèle linéaire gaussien.

**Question 6** En terme de projection, préciser les estimateurs obtenus pour  $\hat{m}$  et  $\hat{\sigma}^2$ .

**Question 7** Donner les formules analytiques obtenues pour  $\hat{\theta}$  et  $\hat{\sigma}^2$  en fonction de  $A$ ,  $X$  et  $n$ .

**Question 8** Montrer que  $\hat{m}$  et  $\hat{\sigma}^2$  sont indépendantes et que

$$\hat{m} \sim \mathcal{N}(m, \sigma^2 \Pi_V) \quad \text{et} \quad n\hat{\sigma}^2/\sigma^2 \sim \chi_{n-\dim V}^2$$

## 3 Tests statistiques et simulations

### 3.1 Tests et intervalles de confiance

L'objectif des tests sur le modèle linéaire gaussien est de tester l'hypothèse :  $\mathcal{H}_0 = "m \in W"$  contre  $\mathcal{H}_1 = "m \notin W"$  où  $W$  est un s.e.v. de  $V$ . Ce test est destiné à diminuer le nombre de paramètres dans le modèle linéaire gaussien.

**Question 9** Dans le cas du modèle de régression, on souhaite tester si  $\theta_1 = 0$ , ce qui signifie que la première des variables explicatives est superflue dans le modèle. Que vaut  $W$ ?

**Question 10** Dans le cas d'analyse de variance à un facteur, on veut tester par exemple  $\mathcal{H}_0$  : "pour chaque facteur, la moyenne est identique" contre l'hypothèse opposée  $\mathcal{H}_1$ . Que vaut  $W$ ?

**Question 11** On décide de former un test d'acceptation ou de rejet de  $\mathcal{H}_0$ . Quel test vous semble-t-il naturel d'utiliser ? Donner, sous  $\mathcal{H}_0$ , la statistique de

$$F := \frac{\frac{1}{\dim V - \dim W} \|\Pi_V(X) - \Pi_W(X)\|^2}{\frac{1}{n - \dim V} \|X - \Pi_V(X)\|^2}$$

En déduire une région de rejet de  $\mathcal{H}_0$  de niveau  $\alpha$  en fonction de  $n, V$  et  $W$ .

**Question 12**

1. Écrire une fonction  $[p, f] = \text{homvar}(y)$  qui prend comme argument une matrice  $n \times \text{nech}$  contenant  $\text{nech}$  échantillons de taille  $n$  et qui renvoie
  - dans  $p$  une matrice  $p(i, j)$ ,  $i$  et  $j$  variant de 1 à  $\text{nech}$  contenant la P-valeur du test d'égalité des variances pour les échantillons  $i$  et  $j$ .
  - dans  $f$  une matrice  $f(i, j)$  contenant la statistique de Fisher du test d'égalité des variances.
2. Écrire une fonction  $[p, t, \text{tsub}, f] = \text{testlin}(y, A, A_{\text{sub}})$  qui prend comme arguments un vecteur  $y$  contenant l'échantillon de données,  $A$  la matrice  $n \times p$  du modèle linéaire,  $A_{\text{sub}}$  la matrice  $n \times q$  du sous-modèle à tester et qui renvoie :
  - $p$  la P-valeur du test d'hypothèse linéaire
  - $f$  la statistique de Fisher du test d'hypothèse linéaire
  - $t$  l'estimation des paramètres du modèle
  - $\text{tsub}$  l'estimation des paramètres du sous-modèle.

**Question 13** Exemple issu du Bickel & Doksum On donne les limites d'élasticité des fils électriques de neufs cables utilisés sur un réseau haute tension. Chaque cable est fait de 12 fils.

Cable 1	5	-13	-5	-2	-10	-6	-5	0	-3	2	-7	-5
Cable 2	-11	-13	-8	8	-3	-12	-12	-10	5	-6	-12	-10
Cable 3	0	-10	-15	-12	-2	-8	-5	0	-4	-1	-5	-11
Cable 4	-12	4	2	10	-5	-8	-12	0	-5	-3	-3	0
Cable 5	7	1	5	0	10	6	5	2	0	-1	-10	-2
Cable 6	1	0	-5	-4	-1	0	2	5	1	-2	6	7
Cable 7	-1	0	2	1	-4	2	7	5	1	0	-4	2
Cable 8	-1	0	7	5	10	8	1	2	-3	6	0	5
Cable 9	2	6	7	8	15	11	-7	7	10	7	8	1

Quel test faire pour s'assurer que ces données proviennent d'un modèle linéaire ? Construire un test pour savoir si les limites d'élasticité moyenne.