

Mise à niveau

Modèle linéaire

A. Godichon-Baggioni

I. Modèle linéaire

MODÈLE DE RÉGRESSION


L'objectif est d'expliquer une variable Y en fonction de variables explicatives X . Plus précisément, un modèle de regression est un modèle où on considère :

- ▶ des variables aléatoires à expliquer Y_1, \dots, Y_n
- ▶ des vecteurs $X_1, \dots, X_n \in \mathbb{R}^p$ (variables explicatives)
- ▶ une fonction de régression $g : \mathbb{R}^p \rightarrow \mathbb{R}$
- ▶ des variables aléatoires indépendantes et centrées
 $\epsilon_1, \dots, \epsilon_n$


Le modèle de régression est défini comme

$$Y_i = g(X_i) + \epsilon_i.$$

EXEMPLE 1 : $Y_i = ax_i^2 + bx_i + c + \epsilon_i$



EXEMPLE 2 : $Y_i = ax_i + b + \epsilon_i$



MODÈLE LINÉAIRE

Définition

Lorsque la fonction de régression est linéaire, i.e de la forme

$$g(X) = X^T \beta$$

avec $\beta \in \mathbb{R}^p$, le modèle de régression associé est dit linéaire.

FORME MATRICIELLE

On considère le modèle linéaire

$$Y_i = g(X_i) + \epsilon_i = X_i^T \beta + \epsilon_i.$$

On note $\mathbf{Y} = (Y_1, \dots, Y_n)^T$, $\epsilon = (\epsilon_1, \dots, \epsilon_n)^T$ et

$$\mathbf{X} = (X_1, \dots, X_n)^T = \begin{pmatrix} X_{1,1} & \dots & X_{1,p} \\ \vdots & \ddots & \vdots \\ X_{n,1} & \dots & X_{n,p} \end{pmatrix}.$$

La forme matricielle du modèle linéaire s'écrit alors

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon.$$

EXEMPLE 1 : MODÈLE LINÉAIRE SIMPLE

On a $x_1, \dots, x_n \in \mathbb{R}$ et pour tout i

$$y_i = a + bx_i + \epsilon_i.$$

Le modèle s'écrit sous la forme

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon.$$

avec

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \quad \text{et} \quad \beta = \begin{pmatrix} a \\ b \end{pmatrix}.$$

La fonction $x \mapsto a + bx$ est dite droite de régression.

EXEMPLE 2 : RÉGRESSION POLYNOMIALE

On a $x_1, \dots, x_n \in \mathbb{R}$ et pour tout i

$$y_i = a_0 + a_1x_i + \dots + a_px_i^p + \epsilon_i.$$

Le modèle s'écrit sous la forme

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon.$$

avec

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 & \dots & x_1^p \\ \vdots & \vdots & & \vdots \\ 1 & x_n & \dots & x_n^p \end{pmatrix}, \quad \text{et} \quad \beta = \begin{pmatrix} a_0 \\ \vdots \\ a_p \end{pmatrix}.$$

Comment estimer β ?

II. Méthode des moindres carrés

ESTIMATEUR DES MOINDRES CARRÉS

La méthode des moindres carrés consiste à chercher $\hat{\beta} \in \mathbb{R}^p$ qui minimise la quantité suivante :

$$\|\mathbf{Y} - \mathbf{X}\beta'\|^2 = \sum_{i=1}^n (Y_i - X_i^T \beta')^2.$$

$\hat{\beta}$ est appelé estimateur des moindres carrés.

- ▶ Existence d'une solution ?
- ▶ Unicité ?

EXISTENCE ET UNICITÉ

Théorème

Si \mathbf{X} est de rang p , alors l'estimateur des moindres carrés est unique et est défini par

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$$

PROPOSITION

Proposition

La matrice $\mathbf{X}^T \mathbf{X}$ est semi-définie positive. De plus, elle est positive si et seulement si \mathbf{X} est de rang p .

Remarque : La matrice \mathbf{X} ne peut être de rang p que si $n \geq p$.

MOINDRES CARRÉS ET PROJECTION

On dote $D \subset \mathbb{R}^p$ le sous espace vectoriel engendré par les colonnes de \mathbf{X} . Le problème de minimization peut s'écrire comme

$$\min_{\beta' \in \mathbb{R}^p} \|\mathbf{Y} - \mathbf{X}\beta'\|^2 = \min_{h \in D} \|\mathbf{Y} - h\|^2$$

et chercher le minimum revient donc à chercher la projection orthogonale de \mathbf{Y} sur D .

Remarque : $\dim(D) = \text{rang}(\mathbf{X})$.

MOINDRES CARRÉS ET PROJECTION

Théorème

Si $\text{rang}(\mathbf{X}) = p$, i.e si $\mathbf{X}^T \mathbf{X}$ est inversible, alors la matrice

$$P_D = \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$$

est la matrice de projection orthogonale sur D et $\text{rang}(H) = p$.

PROPRIÉTÉS DE L'ESTIMATEUR DES MOINDRES CARRÉS

Proposition

Soit $\epsilon = (\epsilon_1, \dots, \epsilon_n)$ avec $\mathbb{E}[\epsilon] = 0_{\mathbb{R}^n}$ et $\text{Var}[\epsilon] = \sigma^2 I_n$, $\sigma^2 > 0$. On suppose de plus que $\text{rang}(\mathbf{X}) = p$. Alors

$$\mathbb{E} \left[\hat{\beta} \right] = \beta \quad \text{et} \quad \text{Var} \left[\hat{\beta} \right] = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} .$$

DÉFINITIONS

Définition

1. On appelle

$$\hat{\boldsymbol{\epsilon}} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}$$

le vecteur des résidus.

2. On appelle

$$SCR = \|\hat{\boldsymbol{\epsilon}}\|^2 = \|\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}\|^2$$

la somme des carrés des résidus.

ESTIMATION DE σ^2

Théorème

Soit $\epsilon = (\epsilon_1, \dots, \epsilon_n)$ avec $\mathbb{E}[\epsilon] = \mathbf{0}_{\mathbb{R}^n}$ et $\text{Var}[\epsilon] = \sigma^2 I_n$, $\sigma^2 > 0$. On suppose de plus que $\text{rang}(\mathbf{X}) = p$. Alors

$$\hat{\sigma}^2 = \frac{\|\mathbf{Y} - \mathbf{X}\hat{\beta}\|^2}{n-p} = \frac{1}{n-p} \sum_{i=1}^n \left(Y_i - \mathbf{X}_i^T \hat{\beta} \right)^2$$

est un estimateur sans biais de σ^2 .

III. Modèle linéaire gaussien

MODÈLE LINÉAIRE GAUSSIEN

Définition

Le modèle de régression linéaire

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon$$

est dit modèle linéaire gaussien si ϵ est un vecteur gaussien de loi $\mathcal{N}(0, \sigma^2 I_n)$ avec $\sigma^2 > 0$.

Proposition

Dans le cadre du modèle linéaire gaussien, l'estimateur des moindres carrés coïncide avec l'estimateur du maximum de vraisemblance.

PROPRIÉTÉS DES ESTIMATEURS

Théorème

Soit $\epsilon \sim \mathcal{N}(0, \sigma^2 I_n)$, $\sigma^2 > 0$. On suppose de plus que $\text{rang}(\mathbf{X}) = p$.

Alors

1. $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1})$.
2. $\hat{\beta}$ et $\hat{\sigma}^2$ sont indépendantes.
3. $\frac{(n-p)}{\sigma^2} \hat{\sigma}^2 \sim \chi_{n-p}^2$.

INTERVALLE DE CONFIANCE

Théorème

Soit $x_0 \in \mathbb{R}^p$. Un intervalle de confiance de niveau $1 - \alpha$ pour $x_0^T \beta$ est donné par

$$\left[x_0^T \hat{\beta} - \hat{\sigma} \sqrt{v_0} t_{n-p, 1-\alpha/2}; x_0^T \hat{\beta} + \hat{\sigma} \sqrt{v_0} t_{n-p, 1-\alpha/2} \right]$$

avec $v_0 = x_0^T (\mathbf{X}^T \mathbf{X})^{-1} x_0$ et $t_{n-p, 1-\alpha/2}$ est le quantile d'ordre $1 - \alpha/2$ de la loi de Student à $n - p$ degrés de liberté.

INTERVALLES DE PRÉDICTION

Théorème

Soit $x_0 \in \mathbb{R}^p$. Un intervalle de prédiction de niveau $1 - \alpha$ de y_0 est donné par

$$\left[x_0^T \hat{\beta} - \hat{\sigma} \sqrt{1 + v_0} t_{n-p, 1-\alpha/2}; x_0^T \hat{\beta} + \hat{\sigma} \sqrt{1 + v_0} t_{n-p, 1-\alpha/2} \right]$$

avec $v_0 = x_0^T (\mathbf{X}^T \mathbf{X})^{-1} x_0$ et $t_{n-p, 1-\alpha/2}$ est le quantile d'ordre $1 - \alpha/2$ de la loi de Student à $n - p$ degrés de liberté.

Remarque : L'intervalle de prédiction est plus grand que l'intervalle de confiance car il doit également prendre en compte la variance de ϵ_0 .

TEST DE SIGNIFICATIVITÉ D'UN PARAMÈTRE

Soit $k \in \{1, \dots, p\}$, on souhaite tester

$$H_0 : \beta_k = 0 \quad \text{contre} \quad H_1 : \beta_k \neq 0.$$

Proposition

Dans le cadre du modèle linéaire gaussien, un test de significativité du k -ème coefficient de niveau α est donné par la zone de rejet

$$ZR_{\alpha,k} = \left\{ 0 \notin \left[\hat{\beta}_k \pm \hat{\sigma} \sqrt{v_k} t_{n-p, 1-\alpha/2} \right] \right\},$$

où $v_k = \left((\mathbf{X}^T \mathbf{X})^{-1} \right)_{k,k}$ est le k -ème coefficient diagonal de

$(\mathbf{X}^T \mathbf{X})^{-1}$ et $t_{n-p, 1-\alpha/2}$ est le quantile d'ordre $1 - \alpha/2$ de la loi de Student à $n - p$ degrés de liberté.

TEST DE SIGNIFICATIVITÉ DE PLUSIEURS COEFFICIENTS

On souhaite tester la significativité de plusieurs coefficients $\beta_{i_1}, \dots, \beta_{i_k}$. Pour simplifier les notations, on souhaite tester

$H_0 : "$ $\beta_{p_0+1}, \dots, \beta_p = 0$ $"$ contre $H_1 : "$ $\exists i \in \{p_0 + 1, \dots, p\}, \beta_i \neq 0$ $"$.

TEST DE SIGNIFICATIVITÉ DE PLUSIEURS COEFFICIENTS

On note

- ▶ $\mathbf{X}_0 = [X_1, \dots, X_{p_0}] \in \mathbb{R}^{n \times (p_0)}$
- ▶ $\mathbf{X}_1 = [X_{p_0+1}, \dots, X_p] \in \mathbb{R}^{n \times (p-p_0)}$
- ▶ $\mathbf{X} = [\mathbf{X}_0, \mathbf{X}_1] \in \mathbb{R}^{n \times p}$.

Le test de significativité revient à faire la comparaison de modèles suivante :

$$H_0 : \text{''}\mathbf{Y} = \mathbf{X}_0\beta_0 + \epsilon\text{''} \quad \text{contre} \quad \text{''}H_1 : \mathbf{Y} = \mathbf{X}\beta + \epsilon\text{''}.$$

TEST DE SIGNIFICATIVITÉ DE PLUSIEURS COÉFFICIENTS

Théorème

On considère la statistique de test

$$F = \frac{\|\hat{Y} - \hat{Y}_0\|^2}{(p - p_0) \hat{\sigma}^2} =: \frac{\hat{\sigma}_0^2}{\hat{\sigma}^2},$$

avec $\hat{Y}_0 = \mathbf{X}_0 \hat{\beta}_0$, et $\hat{\beta}_0$ est l'estimateur des moindres carrés dans le modèle H_0 . Alors, sous H_0 ,

$$F \sim \mathcal{F}(p - p_0, n - p).$$

Corollaire

Tester la significativité des coefficients au risque α revient à considérer la zone de rejet

$$ZR_\alpha = \{F > f_{1-\alpha, p-p_0, n-p}\}$$

IV. Modèles emboîtés

MODÈLES EMBOÎTÉS

Le test de Fisher précédent est un cas particulier du test entre modèles emboîtés. On considère :

- ▶ $\mathbf{Y} \sim \mathcal{N}(\mu, \sigma^2 I_n)$ avec $\sigma^2 > 0$.
- ▶ $\mathcal{M}_0 \subset \mathcal{M}_1 \subset \mathbb{R}^n$ deux sous espaces vectoriels de \mathbb{R}^n

On souhaite tester

$$H_0 : \mathbb{E}[\mathbf{Y}] = \mu \in \mathcal{M}_0 \quad \text{contre} \quad H_1 : \mathbb{E}[\mathbf{Y}] = \mu \in \mathcal{M}_1.$$

CONSTRUCTION DE LA STATISTIQUE DE TEST

On considère $P_{\mathcal{M}_0}, P_{\mathcal{M}_1}$ les projections orthogonales sur \mathcal{M}_0 et \mathcal{M}_1 . On considère la statistique

$$\mathcal{F} = \frac{\dim(\mathcal{M}_1^\perp) \|P_{\mathcal{M}_0} \mathbf{Y} - P_{\mathcal{M}_1} \mathbf{Y}\|^2}{(\dim(\mathcal{M}_1) - \dim(\mathcal{M}_0)) \|P_{\mathcal{M}_1^\perp} \mathbf{Y}\|^2}$$

Proposition

Sous H_0 ,

$$\mathcal{F} \sim F(\dim(\mathcal{M}_1) - \dim(\mathcal{M}_0), \dim(\mathcal{M}_1^\perp))$$

TEST DES MODÈLES EMBOÎTÉS

Corollaire

Faire le test des modèles emboîtés revient donc à considérer la zone de rejet

$$ZR_\alpha = \left\{ \mathcal{F} > f_{1-\alpha, \dim(\mathcal{M}_1) - \dim(\mathcal{M}_0), \dim(\mathcal{M}_1^\perp)} \right\}$$