

UE

Modélisation

Topic 3:

MLG





Maintenant commence la partie « statistique » de l'UE. Plus précisément, le but est de vous présenter le modèle linéaire généralisé (MLG).

Uniquement pour fixer les notations et servir de rappel.

O. Rappel : Le modèle linéaire simple

1. Préambule : La démarche statistique

Ω / \mathbb{P}

Description du système étudié
/ Modélisation de la population étudiée

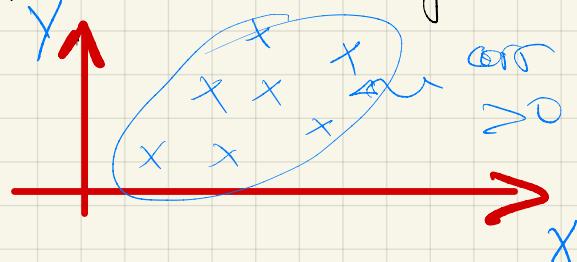
Analyste univariée

Histogrammes / Moy
/ Ecart-type / Médiane -

Analyste bivariée
 (X, Y)

Corrélation empirique -
/ Comparaison de moy

Analyste multi-varieé



a pour but de répondre à la question :

« Comment expliquer une variable Y en fonction

de plusieurs variables explicatives, X^1, X^2, \dots, X^k ? »

Dans ce cours, on verra

↳ le modèle linéaire

$$Y = \sum_{j=1}^R \theta_j X^j + \varepsilon$$

paramètres

variables

du modèle

explicatives.

↳ Bruit / Erreur

$$\mathbb{E}(\varepsilon) = 0$$

$$\text{Var}(\varepsilon) = \sigma^2$$

Écriture matricielle $\mathbf{Y} = \mathbf{X} \boldsymbol{\theta} + \varepsilon$

avec $X^0 = 1$ (intercept).

Remarque : On peut allégrement modifier le modèle pour inclure des non-linéarités

$$Y = \sum_{j=1}^R f_j(X^j, \theta) + \varepsilon$$

↳ fonctions à estimer (ex: polynôme)

ou pire encore : (Ex: $f_j(x, \theta) = \sum_{k=0}^{d_j} x^k \theta_{j,k}$)

$$Y = F_\theta(X^1, X^2, X^3, \dots, X^k) + \varepsilon$$

↳ Fonction à estimer

par sécail de moindres

ou plus précisément par descente de gradient

régression
paramétrique

Sondage: Faire un TP de régression paramétrique?

Oui / Non.

Sondage: Faire un TP avec réseaux de neurones.

Oui / Non.

② Estimation MCO (Méthodes carres ordinaires)
/ OLS (Ordinary Least Squares).

$$\left\{ \begin{array}{l} Y_1 = X_1 \theta + \varepsilon_1 \\ Y_2 = X_2 \theta + \varepsilon_2 \\ \vdots \\ Y_n = X_n \theta + \varepsilon_n \end{array} \right. \quad \varepsilon_i \text{ iid} \quad \Rightarrow \quad \mathbb{Y} = \mathbb{X} \theta + \varepsilon$$

L'estimation MCO / OLS consiste à prendre

$$\hat{\theta}_n^{\text{OLS}} = \underset{\theta}{\operatorname{Arg\,min}} \quad \| \mathbb{Y} - \mathbb{X} \theta \|^2$$

Loss / Perte quadratique

Proposition: $\hat{\theta}_n^{\text{OLS}} = (\mathbb{X}^T \mathbb{X})^{-1} \mathbb{X}^T \mathbb{Y}$



$$\hat{\theta}_n^{\text{OLS}} = \hat{\theta}_n^{\text{MLE}} \leftarrow \text{Estimateur de max de vraisemblance}$$
$$= \underset{\theta}{\operatorname{Arg\,max}} \log L(\theta)$$

lorsque $\mathcal{E} = (\mathcal{E}_1, \dots, \mathcal{E}_n)$ iid Gaussiens.

En effet $L(\theta) =$ Densité d'observer

$$(y_1, \dots, y_m) = \mathbf{y}$$

$$(x_1, \dots, x_n) = \mathbf{x}.$$

= Densité d'observer :

$$\text{iid} \rightsquigarrow \mathcal{E} = \mathbf{Y} - \mathbf{X}\theta = \begin{pmatrix} y_1 - x_1\theta \\ \vdots \\ y_m - x_m\theta \end{pmatrix}$$

$$= \prod_{j=1}^m P_{\mathcal{E}_j} (y_j - x_j\theta)$$

$$= \prod_{j=1}^m \exp\left(-\frac{\|y_j - x_j\theta\|^2}{2\sigma^2}\right) / \sqrt{2\pi\sigma^2}$$

$$= \exp\left(-\sum_{j=1}^m \frac{\|y_j - x_j\theta\|^2}{2\sigma^2}\right) / (2\pi\sigma^2)^{m/2}$$

$$\text{nd } \log L(\theta) = -\sum_{j=1}^m \frac{\|y_j - x_j\theta\|^2}{2\sigma^2} - \frac{m}{2} \log(2\pi\sigma^2)$$

$$\text{Puis } \hat{\theta}_n^{\text{MLE}} = \operatorname{Argmax}_{\theta} \log L(\theta)$$

$$= \operatorname{Argmax}_{\theta} -\sum_{j=1}^m \frac{\|y_j - x_j\theta\|^2}{2\sigma^2} - \frac{m}{2} \log(2\pi\sigma^2)$$

$$= \operatorname{Argmax}_{\theta} -\|\mathbf{Y} - \mathbf{X}\theta\|^2$$

$$= \operatorname{Argmin}_{\theta} \|\mathbf{Y} - \mathbf{X}\theta\|^2$$

$$= \hat{\theta}_n^{\text{OLS}}$$

Propriétés de $\hat{\theta}_m^{\text{OLS}}$:

- $\hat{\theta}_m^{\text{OLS}} = (\mathbf{t} \mathbf{X} \mathbf{X})^{-1} \mathbf{t} \mathbf{X} \mathbf{y}$
 $= \theta + (\mathbf{t} \mathbf{X} \mathbf{X})^{-1} \mathbf{t} \mathbf{X} \varepsilon$
- $\hat{\theta}_m^{\text{OLS}}$ est consistent ($\hat{\theta}_m^{\text{OLS}} \xrightarrow{P} \theta$) et sous hypothèse ε Gaussien
- $\hat{\theta}_m^{\text{OLS}} = \mathcal{D}(\theta, \sigma^2 (\mathbf{t} \mathbf{X} \mathbf{X})^{-1})$
- $\hat{\theta}_m^{\text{OLS}}$ sans biais,

(3) Résidus et valeurs ajustées

Après estimation de $\hat{\theta}_m$ on peut former :

\hookrightarrow "les valeurs ajustées" / les prédictions

$$\hat{y} = \mathbf{X} \hat{\theta}_m \stackrel{D}{=} \mathcal{D}(\mathbf{X} \theta, \mathbf{X} (\mathbf{t} \mathbf{X} \mathbf{X})^{-1} \mathbf{t} \mathbf{X})$$

si ε Gaussien

\hookrightarrow "les résidus" / les erreurs de prediction

$$\hat{\varepsilon} = y - \hat{y}$$

Propriétés : Si ε Gaussien

$$\begin{array}{ll} \hat{y} & \perp \hat{\varepsilon} \\ \hat{\varepsilon} & \perp \hat{\theta}_m \end{array}$$

(4) Estimation de σ^2

Le bon estimateur de σ^2 est

$$\hat{\sigma}_m^2 = \frac{1}{n-k} \|\hat{\epsilon}\|^2 = \frac{1}{n-k} \sum_{j=1}^m \hat{\epsilon}_j^2$$

ℓ nombre de facteurs

(l'intercept $X^1 = 1$ inclus !)

Sous hypothèse de \mathcal{E} Gaussien :

Propriétés : ① $\hat{\epsilon} \perp \hat{\sigma}_m^2$ & $\hat{\sigma}_m^2 \perp \hat{\Omega}_m$

② $\frac{(n-k)\hat{\sigma}_m^2}{\sigma^2} \stackrel{d}{=} \chi^2_{n-k}$ (Somme de $n-k$ carrés de normales)

③ $\hat{\Omega}_m$ sens biais et de

Variance $\frac{2\sigma^4}{n-k} \xrightarrow[n \rightarrow +\infty]{} 0$

Exercice : Montrer que $② \Rightarrow ③$

et $③ \Rightarrow \hat{\sigma}_m^2$ est un estimateur constant.

$(\hat{\sigma}_m^2 \xrightarrow[n \rightarrow +\infty]{P} \sigma^2)$

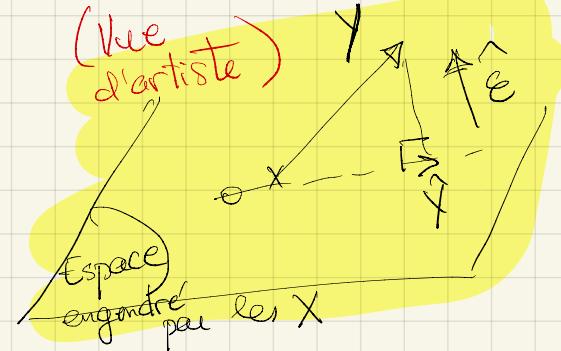
⑤ Analyse et exploitation de la régression

→ ANOVA (Analyse de la variance)

Il est question de savoir si la régression est pertinente. Pour cela on observe la décomposition

$$Y = \hat{Y} + \hat{\epsilon}$$

En fait c'est une décomposition



mis en variables indépendantes (Propriétés en ⑤)

donc

$$\text{Var } Y = \text{Var } \hat{Y} + \text{Var } \hat{\epsilon}$$

mis en vecteurs orthogonaux (indépendante
après centrage géométrique)

$$\text{donc } \|Y - \bar{Y}\|^2 = \|\hat{Y} - \bar{\hat{Y}}\|^2 + \|\hat{\epsilon}\|^2$$

↑
Variance expliquée

Variance

La qualité de la régression est mesurée
par le critère R^2 = $\frac{\|\hat{Y} - \bar{Y}\|^2}{\|Y - \bar{Y}\|^2} \in [0, 1]$

$\left\{ \begin{array}{l} \text{Si } R^2 \approx 1, \text{ alors } X \text{ explique bien } Y. \\ \text{Si } R^2 \approx 0, \text{ l'inverse} \end{array} \right.$

⑥ Tests de nullité :

$$(H_0: \theta_j = 0)$$

on a: $\hat{\theta}_j \stackrel{d}{=} \mathcal{N}(\theta_j, \sigma^2 (\mathbf{X} \mathbf{X})^{-1})$

mais σ^2 inconnue !

Alors:

$$\left\{ \begin{array}{l} \frac{\hat{\theta}_j - \theta_j}{\sqrt{\sigma^2 (\mathbf{X} \mathbf{X})^{-1}}} \stackrel{d}{=} \mathcal{N}(0, 1) \\ (n-k) \frac{\hat{\sigma}_m^2}{\sigma^2} \stackrel{d}{=} \chi^2_{n-k} \end{array} \right.$$

\downarrow sous
hypothèse
de E
Gaussian

$$\text{Par ratio, } T = \frac{\hat{\theta}_j - \theta_j}{\sqrt{\hat{\sigma}_n^2 (\mathbf{X}^\top \mathbf{X})_{jj}}} = \frac{\mathcal{N}(0, 1)}{\sqrt{\frac{\chi^2_{m-k}}{m-k}}} \xrightarrow{\text{D}}$$

$\xrightarrow{\text{D}}$ Student ($n-k$)

\leftarrow définition de cette loi

Si $t_{1-\alpha/2}$ est le $(1-\frac{\alpha}{2})^{\text{e}}$ quantile de cette loi

$$\text{Alors } IC_{1-\alpha}(\theta_j) = \hat{\theta}_j + \sqrt{\hat{\sigma}_n^2 (\mathbf{X}^\top \mathbf{X})_{jj}} \times [-t_{1-\frac{\alpha}{2}}, t_{1-\frac{\alpha}{2}}]$$

est l'intervalle de confiance avec certitude α

remarque On rejette H_0 si $|\hat{\theta}_j| \geq t_{1-\frac{\alpha}{2}} \sqrt{\hat{\sigma}_n^2 (\mathbf{X}^\top \mathbf{X})_{jj}}$

Le modèle linéaire généralisé

I - Introduction

Il existe plusieurs variantes du modèle linéaire (polynômes, paramétrique, non-paramétrique) :

$$Y = \underbrace{X}_{\substack{\text{Variable} \\ \text{d'intérêt}}} \underbrace{\beta}_{\substack{\text{Facteurs} \\ \text{à estimer}}} + \varepsilon \quad \xrightarrow{\text{Bruit}}$$

Toutefois, il y a des cas très simples où ceci n'a aucune chance de fonctionner.

Par exemple, si la variable d'intérêt est binaire ($\in \{0, 1\}$) et que l'on s'intéresse à la probabilité

$$P = P(Y=1)$$

Le comptage ($\in \mathbb{N}$).

Ainsi nous renons dans ce chapitre une généralisation dans deux directions

Utilisation de lois plus générales

dans le cadre des lois de la famille exponentielle.
En effet, le modèle linéaire et son étude sont très « gaussiens » ?

↳ Incorporation d'une transformation pour passer de \mathbb{R} à $[0, 1]$; \mathbb{N} ; $\{0, 1\}$

Le modèle linéaire généralisé se décompose en 3 composantes.

① La composante aléatoire Y (\equiv Variable d'intérêt) à laquelle est associée une loi de proba. / de réponse

② La composante déterministe composée d'une combinaison linéaire de X^1, X^2, \dots, X^p (variables explicatives) sur $X\beta$ où $X = (X^1, \dots, X^p)$

③ Un lien c'est-à-dire une transformation entre {la composante déterministe} un paramètre de la composante aléatoire.

Ex: $y \stackrel{\text{L}}{\sim} P(p, 1)$
|| un lien
 $X\beta$

II - Les 3 composantes

II - 1 - La composante déterministe

C'est juste la combinaison lin. $X\beta = \sum \beta_i X^i$

Variables fixées par l'exp.

Autre nom : Prédicteur linéaire

I - 2 - La composante aléatoire.

On dispose de n observations (y_1, y_2, \dots, y_n) de la v.a Y . On choisit une loi dans la famille exponentielle en fonction de la nature de Y .

$\hookrightarrow Y \in \mathbb{R}$, valeur quantitative.

Ex naturel $\hookrightarrow Y \stackrel{\text{distr}}{\sim} \mathcal{N}(\mu, \sigma^2)$, et $\mu = \mathbb{E}(Y) \in \mathbb{R}$

$\hookrightarrow Y \in \{0, 1\}$ (succès / échec).

Ex naturel $\hookrightarrow Y \stackrel{\text{distr}}{\sim} \text{Bernoulli}(\pi)$ où $\pi = \mathbb{E}(Y) \in [0, 1]$

$\hookrightarrow Y \in \mathbb{N}$ (Comptage)

Exemple naturel $\hookrightarrow Y \stackrel{\text{distr}}{\sim} \text{Poisson}(\lambda)$

où $\lambda = \mathbb{E}(Y) \in \mathbb{R}_+$

III - 3 - La fonction de lien

Définition : On définit $g : I$ intervalle $\rightarrow \mathbb{R}$

donnant $g(\mathbb{E}(Y)) = X\beta$ où $\beta = \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}$

$X = (X_1^1, X_1^2, \dots, X_1^p)$

Dit Simplement

Partie déterministe

$X\beta$

$\xleftarrow{\text{fonction de lien}}$ $\mathbb{E}(Y)$ $\xrightarrow{\text{Partie aléatoire}}$ y

Partie aléatoire

Exemples: \hookrightarrow Si $y \stackrel{D}{=} \mathcal{P}(\nu, \sigma^2) = \nu + \sigma \mathcal{N}(0, 1)$

Alors $g(\nu) = \nu$

$$\Rightarrow y = X\beta + \underbrace{\sigma \mathcal{N}(0, 1)}_{\varepsilon}$$

C'est le modèle linéaire.

\hookrightarrow Si $y \stackrel{D}{=} \mathcal{P}(\lambda)$

$$\text{Alors } X\beta = g(E(y)) = g(\lambda) = \log \lambda$$

$$\text{donne } y \stackrel{D}{=} \mathcal{P}(\lambda = e^{X\beta})$$

(Modèle log-linéaire)

\hookrightarrow Si $y \stackrel{D}{=} \text{Bernoulli}(\pi)$

$$\text{Alors } X\beta = g(E(y)) = g(\pi) = \log\left(\frac{\pi}{1-\pi}\right)$$

donne

$$y \stackrel{D}{=} \text{Bernoulli}(\text{logit}^{-1}(X\beta)) = \text{logit}(\pi)$$

(Modèle de régression logistique)

$$\Delta \quad \text{logit}^{-1}(y) = \frac{1}{1+e^{-y}} = \frac{e^y}{1+e^y} \quad (\text{Fonction sigmoïde})$$

$$y = \text{logit}(\alpha) \Leftrightarrow e^y = \frac{x}{1-x} \Leftrightarrow e^{-y} = \frac{1-x}{x}$$

$$\Leftrightarrow 1+e^{-y} = \frac{1}{x}$$

$$\Leftrightarrow x = \frac{1}{1+e^{-y}}$$

III - Familles exponentielles

Large famille qui contient

↳ Bernoulli, Binomiale, Poisson (1 param)

↳ Normale, Gamma, Binomiale négative (2 param)

↳ Multinomiale (et de 2 param).

La densité utilise deux paramètres $\psi = (\theta, \phi)$

où $\left\{ \begin{array}{l} \theta : \text{Paramètre principal lié à } \mathbb{E}(Y) \\ \phi : \text{Paramètre de nuisance lié à } \text{Var}(Y) \end{array} \right.$
(Prendre 0 si loi à 1 param)

Y appartient à la famille exponentielle avec param (θ, ϕ) lorsque

$$\mathbb{P}(Y \in dy) = dy f(y; \theta, \phi) \quad (\text{Continue})$$

ou

$$\mathbb{P}(Y = y) = f(y; \theta, \phi) \quad (\text{discret})$$

avec

$$f(y; \theta, \phi) = \exp \left[\frac{\theta y - b(\theta)}{a(\phi)} + c(y, \phi) \right]$$

Les expressions exactes de $c(y, \phi)$ & $a(\phi)$ ne sont pas importantes et sont identifiées au cas par cas. On a tout de même les propriétés suivantes, que l'on peut établir

en toute généralité :

Thm:

$$\left\{ \begin{array}{l} b'(\theta) = \mathbb{E}(Y) \iff \theta = (b')^{<-1}(\mathbb{E}(Y)) \\ \text{Var}(Y) = \alpha(\phi) b''(\theta) \end{array} \right.$$

Si un seul paramètre au modèle, on prend $\alpha(\phi) = 1$
Lien avec MLG : Dans toute famille exponentielle

$$\begin{aligned} X\beta &= g(\mathbb{E}(Y)) && \text{par déf de MLG} \\ &= g(b'(\theta)) \end{aligned}$$

utilisée pour MLG

$y \stackrel{\text{d}}{=} \text{Famille exp } (\theta, \phi)$

Pose $\theta = X\beta$ comme paramètre de la loi

donne $\theta = g \circ b'(\theta) \iff g = (b')^{<-1}$

Preuve : Montrons que $\mathbb{E}(Y) = b'(\theta)$
en toute généralité.

Préuve assez simple de statisticien :

Je vais calculer l'estimateur de max de vraisemblance

$\hat{\theta}_n$ pose un tirage iid. Par consistance $\hat{\theta}_n \xrightarrow{P} \theta$

Calcul : $L(y; \theta, \phi) = \prod_{i=1}^n \exp\left(\frac{\theta y_i - b(\theta)}{\alpha(\phi)} + c(y_i, \phi)\right)$

où $y = (y_1, \dots, y_n)$ 'échantillon observé'

Donc

$$\begin{aligned}\hat{\theta}_m &= \operatorname{Argmax}_{\theta} \log L(y_i; \theta, \phi) \\&= \operatorname{Argmax}_{\theta} \sum_{i=1}^m \left(\frac{\theta y_i - b(\theta)}{a(\phi)} + c(y_i, \phi) \right) \\&= \operatorname{Argmax}_{\theta} \theta \left(\sum_{i=1}^m y_i \right) - m b(\theta) \\&= \operatorname{Argmax}_{\theta} \theta \left(\frac{\sum_{i=1}^m y_i}{n} \right) - b(\theta)\end{aligned}$$

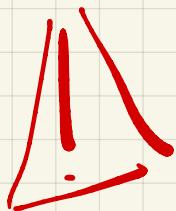
d'où

$$\frac{\partial}{\partial \theta} = 0 \iff \frac{\sum_{i=1}^m y_i}{n} = b'(\theta)$$
$$\iff \theta = (b')^{-1} \left(\frac{\sum_{i=1}^m y_i}{n} \right)$$

Donc

$$\hat{\theta}_m = (b')^{-1} \left(\frac{\sum_{i=1}^m y_i}{n} \right) \xrightarrow{n \rightarrow \infty} \theta$$

$$(b')^{-1}(\mathbb{E}(Y))$$



Ce résultat est
difficile à montrer
en calculant



$\mathbb{E}(Y)$ à partir de la densité!