


2. Imputation multiple des valeurs manquantes.


Réplacer une valeur manquante par une seule valeur estimée \Rightarrow pas d'incertitude sur la valeur imputée [difiant majeur]. On sous-estime aussi les variances des estimateurs en général.

Imputation multiple [Rubin 1987] : imputer la valeur manquante par deux ou plusieurs valeurs plausibles



K analyses sont réalisées sur les K bases complétées et les résultats sont ensuite mis ensemble pour obtenir une estimation globale du modèle étudié.

Processus des imputations multiples



⚠ Rubin (1987) $K = 3 \text{ ou } 5$

Comment obtenir K imputations différentes pour une valeur manquante?

• La méthode MICE (Multiple imputation Chained Equation).

- Principe:
Soit X une matrice de taille $n \times p$ avec valeurs manquantes
1. On imprime une première fois les données manquantes (NIPALS par exemple)
 2. On prend une première variable (dites x_1) avec valeurs manquantes. On retire ses valeurs imputées en 1 et on prédit ces valeurs à l'aide des autres variables (x_2, \dots, x_p). On obtient pour x_2 un deuxième set de imputations
 3. On passe à x_2 , etc jusqu'à x_p .
 4. On répète 2 et 3 $(K-1)$ fois.

Avantages du MICE :

- facile à faire
- amélioration efficace surtout sur des grands jeux de données.

Limites : - peu de fondements théoriques !

Implémenté dans le package R : mice.

A lire : Journal of statistical software

mice : Multivariate imputation by Chained Equations in R.

by Stef van Buuren & Karin Groothuis-Oudshoorn.

<https://www.jstatsoft.org/article/view/v045i03/v45i03.pdf>

fonctions à régards : md.pattern() (structure des d.m.)
 mice() (imputations multiples)
 complete()
 pool()

En SAS :

- proc means ... mmiss ... ;
- proc mi nimpute
var ...
ods select misspattern;
- proc glm
by imputation (analyse sur chaque base imputée)
- proc miomalyze ("pool" les résultats).

LA RÉGRESSION LINÉAIRE :

"Régularisation"

Y = variable aliaitaire (scalaire) : la réponse
quantitative

$X = (X_1, X_2, \dots, X_p)$ = variables aliaires
quantitatives : prédicteurs

Régression:

$$y = f(x_1, x_2, \dots, x_p) + \varepsilon$$

Régression linéaire:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon$$

$$\hat{y} = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p$$

Estimation des coefficients de régression:

— moindres carrés ordinaires (MCO)

ou, équivalent

— maximum de vraisemblance
 $(Y|x_1, \dots, x_p \sim \mathcal{W}(\mu, \sigma^2))$.

Estimation à partir des données :

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{pmatrix}, \quad X = \begin{pmatrix} x_{11} & \dots & x_{ij} & \dots & x_{1p} \\ \vdots & & \vdots & & \vdots \\ x_{n1} & \dots & x_{ij} & \dots & x_{np} \\ \vdots & & \vdots & & \vdots \\ x_{n1} & \dots & x_{nj} & \dots & x_{np} \end{pmatrix}$$

la matrice de "design"

Alors, si les variables x_j sont centrées ($\bar{x}_j = 0$)

$$\left\{ \begin{array}{l} \hat{\beta} = (X^T X)^{-1} X^T y \text{ et} \\ \hat{y} = X \hat{\beta} = X (X^T X)^{-1} X^T y \end{array} \right.$$

Remarque : si les variables x_j ne sont pas centrées, alors

$$\hat{\beta}_0 = \bar{y} - (\hat{\beta}_1 \bar{x}_1 + \dots + \hat{\beta}_p \bar{x}_p).$$

On va considérer dans le reste que les variables sont centrées (cela simplifie la présentation).

C'est quoi "la régularisation" de la régression linéaire ?

Régularisation = trouver une méthode pour résoudre les problèmes d'estimation.

Quels problèmes en régression linéaire ?

$$\mathbf{V}^{-1} = (\mathbf{X}^T \mathbf{X})^{-1} \text{ n'existe pas !}$$

Cette situation apparaît au moins dans deux cas :

— $n \leq p$ (peu d'observations par rapport au nb. de variables).

— multicollinearité: variables redondantes dans le modèle

$\exists \alpha_1, \alpha_2, \dots, \alpha_p$ constantes pas toutes nulles t.q.

$$\underline{\alpha_1 x_1 + \dots + \alpha_p x_p = 0}$$

Déceler ces deux problèmes est assez facile:
 - multicollinearité : à l'aide de l'ACP.

$$\nabla u = \lambda u$$

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p > 0 \quad , \quad \begin{array}{l} \lambda_i \in \mathbb{R}_+ \\ u_i \in \mathbb{R}^p \end{array}$$

$$\downarrow \quad \downarrow \quad \downarrow \\ u_1 \quad u_2 \quad u_p$$

S'il existe q tel que $\lambda_q = 0$ alors:

$$\begin{matrix} q \\ \vdots \\ 1, \dots, p. \end{matrix}$$

$c_q = x_1 u_{q,1} + \dots + x_p u_{q,p}$ est telle que

$$\nabla_{\text{ac}}(c_q) = \lambda_q = 0$$

et donc

$$x_1 \underbrace{u_{q,1}}_{\lambda_1} + \dots + x_p \underbrace{u_{q,p}}_{\lambda_p} = 0$$

(45)

Observons pourquoi la multicollinearité pose problème :

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad \text{et}$$

$$\sqrt{\text{Var}(\hat{\beta})} = \hat{\sigma}^2 (\mathbf{X}^T \mathbf{X})^{-1} = \hat{\sigma}^2 \mathbf{V}^{-1} \quad \text{avec}$$

$$\hat{\sigma}^2 = \frac{1}{n-p-2} \sum (y_i - \hat{y}_i)^2$$

(variance résiduelle)

Si multicollinearité, alors

$$\sqrt{\text{Var}(\hat{\beta}_j)} \rightarrow \infty \quad \forall j = 1 \dots p.$$

et comme conséquence : $\begin{cases} H_0 : \beta_j = 0 \\ H_1 : \beta_j \neq 0 \end{cases}$

n'est pas significatif

$$T = \frac{\hat{\beta}_j}{\sqrt{\text{Var}(\hat{\beta}_j)}} \approx 0 \quad (\text{p-value} \approx 1)!$$

Dès que aucune variable n'est pas associée à Y.

Démonstration du fait que

$$\text{Var}(\beta_j) \rightarrow \infty \quad \text{si } V^{-1} = (X^T X)^{-1} \\ \text{n'existe pas.}$$

(On dit aussi que V est mal-conditionnée).

Par la formule de reconstitution des données en ACP

$$X = c_1 \cdot u_1^+ + c_2 \cdot u_2^+ + \dots + c_p \cdot u_p^+$$

on a que l'espace linéaire engendré par les colonnes de X (donc, par les variables $x_j, j=1 \dots p$) est le même que celui engendré par les composantes principales; Donc, la régression de Y sur $\{x_1, \dots, x_p\}$ est équivalente à la régression linéaire de Y sur $\{c_1, \dots, c_p\}$.

$$\hat{Y} = \hat{\beta}_1 x_1 + \dots + \hat{\beta}_p x_p$$

$$= \hat{\gamma}_1 c_1 + \dots + \hat{\gamma}_p c_p \quad \text{avec lo.}$$

relation

$$\boxed{\beta_j = \sum_{k=1}^p \hat{\gamma}_k \cdot \hat{u}_{kj}}$$

(47)

Or, puisque les variables $\{c_k\}_{k=1 \dots p}$ sont non-correlées, on a :

$$\text{Var}(\hat{x}_k) = \frac{\sigma^2}{n-p-1} \cdot \frac{1}{\lambda_k}$$

Rémarque: la matrice V de variance-covariance des $\{c_1, \dots, c_p\}$ est

$$V = \begin{pmatrix} \lambda_1 & 0 \\ 0 & \ddots & \lambda_p \end{pmatrix}$$

↓

$$V^{-1} = \begin{pmatrix} \frac{1}{\lambda_1} & 0 \\ 0 & \frac{1}{\lambda_p} \end{pmatrix}$$

et donc, comme

$$\hat{\beta}_j = \hat{x}_1 \cdot u_{1j} + \hat{x}_2 \cdot u_{2j} + \dots + \hat{x}_p \cdot u_{pj} \quad \text{il suit que}$$

$$\begin{aligned} \text{Var}(\hat{\beta}_j) &= \frac{\sigma^2}{n-p-1} \cdot \left[u_{1j}^2 \text{Var}(\hat{x}_1) + u_{2j}^2 \text{Var}(\hat{x}_2) + \dots + u_{pj}^2 \text{Var}(\hat{x}_p) \right] \\ &= \frac{\sigma^2}{n-p-1} \cdot \sum_{k=1}^p u_{kj}^2 \cdot \frac{1}{\lambda_k} \end{aligned}$$

Donc si $\lambda_q \approx 0$, $1 \leq q \leq p$, alors

$$\frac{1}{\lambda_q} \rightarrow \infty \quad \text{et donc}$$

$$\text{Var}(\hat{\beta}_j) \rightarrow \infty.$$

(fin démonstration).

Ce qu'il faut donc retenir est que
la présence des valeurs propres $\lambda_q \approx 0$
dans l'ACP (synonyme de multicollinearité)
introduit une forte instabilité des coefficients
de la régression de Y sur $3x_1 \dots x_p$.

Remarque : si $n < p$ alors évidemment,
comme $(X^T X)$ est une matrice $p \times p$, dans
ce cas $\lambda_q = \lambda_{q+1} = \dots = \lambda_p = 0$, $\underline{q = n}$.
car le rang $(X^T X)$ est au plus n .
→ donc ; dans ce cas multicollinearité "forcée"
(pas naturelle).

⚠ Que faire en multicollinearité ?

Solution : dans la formule de reconstruction
des données (page 46), garder que
les composantes avec $\lambda_k \gg 0$.
(composantes explicatives des données).

Que faire si multicollinearité ?

Solutions : - faire un choix des variables :

(selection)

Vu en GIS3

Régression sur
les composants
principaux

AIC, BIC, ...
mais aussi, choix basé sur une
bonne connaissance des variables.
("je veux dans le modèle telle et
telle variable...")

- garder uniquement celles
composantes principales biens
explicatives des données

La régression sur les composantes principales

(Principal components regression : PCR)

Idée : garder dans la formule de reconstitution des données que les composantes importantes.

Problème : les composantes "importantes" ne sont pas forcément celles les plus corrélates à Y !


En effet, si on garde les $h < p$ comp. princ.

$$R^2(Y, \gamma_1 c_1 + \dots + \gamma_h c_h) = R^2(Y, c_1) + \dots + R^2(Y, c_h).$$

[Rappel] : le critère de PCO revient à chercher β_1, \dots, β_p t.q. $R^2(Y, \beta_1 x_1 + \dots + \beta_p x_p)$ soit maximal.

Choix des composantes principales :

→ méthode pas-à-pas de sélection (stépniose)



Le choix des composantes principales est donc un compromis entre :

- l'ajustement de Y (choisir des composantes fortement corrélées avec Y)

et

- expliquer l'information dans X (choisir des composantes fortement explicatives de X (grands λ_i)).

On peut dire aussi que ce compromis est aussi entre l'ajustement et la stabilité des coefficients (robustesse) (modèle).

Pas toujours facile à faire !

La régression PLS (Partial Least squares) apporte une réponse (parmi d'autres) à cela.



Voir une application de pcr sur le fichier car.txt