

Modélisation avancée

(c. Preda).

Sommaire

① Données manquantes

- type de d.m.
- gestion de d.m.
- méthodes d'imputation
- imputation multiple
- NIPALS.

② Régression et dimension

- rappel sur la régression linéaire
- $n \geq p$ et $n < p$
- régularisation de la régression linéaire
PCR, PLS, Ridge, Lasso
- la régression logistique et Poisson

③ Analyse de la variance

- facteurs fixes et facteurs aléatoires
- estimation des effets et régression
- interaction des facteurs.

Références :

- The Elements of Statistical Learning
Data Mining, inference and Prediction
(T. Hastie, R. Tibshirani , J. Friedman)
<http://web.stanford.edu/~hastie/local.ftp/Springer>
- Probabilités, analyse des données et statistique . (Ed. 3^{ème})
Disponible à la Bibliothèque de Polytech'Lille.
Voir aussi : <http://cedric.cnam.fr/~saporta>
- Advanced Statistical Modelling.
(Course notes for University of Auckland)
Alan Lee , Ross Ihaka , Chris Triggs
<https://www.stat.auckland.ac.nz/~stats330/coursebook.pdf>
- Design and Analysis of Experiments
(Douglas Montgomery)

Volume :

- 16 h cours / TD
- 12 h TP (R et SAS).

Examen :

- DS écrit (2h) : $\text{coeff} = 1.25$
 - TP - projet : $\text{coeff} = 1.25$
- (UE 8.1 : Rodilisation aliatoire : 7 ECTS)

Gestion des données manquantes

- une problématique fréquente en analyse des données (économie, santé, etc).
- différentes causes responsables de l'information manquante
 - non réponse à une question
 - perte des données
 - impossible d'observer la réponse
 - :
- La question principale est :

Dans quels conditions, les analyses réalisées en présence de valeurs manquantes restent valides?

valide = estimateurs et leur précision (écart-type) restent consistants

Il faut comprendre le mécanisme étant à la base de la génération des données manquantes.

(5)

On se place dans un cadre multivarié
 où
p variables aléatoires ($p \geq 2$) sont
 observées sur
n unités statistiques :

| | $X_1, \dots X_j \dots X_p$ |
|---|------------------------------|
| 1 | |
| 2 | |
| : | |
| i | x_{ij} |
| : | |
| n | |

$= \bar{X} = X_{\text{obs}} \cup X_m$

↓ ↓
 données données
 observées manquantes

indicateur de données manquantes :

$$R_{ij} = \begin{cases} 1 & \text{si } x_{ij} \text{ est observé} \\ 0 & \text{si } x_{ij} \text{ est manquant} \end{cases}$$

| $R_{(ij)}$ | $\dots j \dots p$ |
|------------|---------------------|
| 1 | |
| 2 | |
| : | |
| i | R_{ij} |
| : | |
| n | |

$= R$

Mécanismes de génération des données manquantes

M1 : Données manquantes complètement aléatoires
 (MCAR = missing completely at Random)

\Leftrightarrow la donnée manquante ne dépend pas des données observées ni des données manquantes.

$$\mathbb{P}(R|X) = \mathbb{P}(R|X_{\text{obs}}, X_m) = \mathbb{P}(R)$$

Ce type de mécanisme est parfois appelé uniforme.

Dans ce type de scénario, l'analyse des cas complets conduit à des résultats valides (mais échantillon réduit).

M2 : Données manquantes aléatoires:
 (MAR = missing at random)

\Leftrightarrow la donnée manquante ne dépend pas des autres données manquantes mais que des données observées:

$$\mathbb{P}(R|X_{\text{obs}}, X_m) = \mathbb{P}(R|X_{\text{obs}}).$$

Exemple :

| etudiant \ matiere | e preuve 1 | e preuve 2 | ... |
|--------------------|------------|------------|-----|
| 1 | 12 | 13 | |
| 2 | 8 | ? | |
| 3 | 14 | 17 | |
| 4 | 6 | ? | |

Mécanisme générant les valeurs manquantes :

⚠ l'épreuve 2 est réalisée si $e preuve 2 \geq 10$

Cas particulier : non-réponses par niveau de la variable :

- $X = \text{poids}$: le patient refuse de donner son poids car obèse
- $X = \text{revenu}$: refus car trop élevé/petit.

Biais dans l'estimation des moments (moyennes,...)
 (pas de biais si analyses par classes !)
 (niveaux)

M3 : Données manquantes non-aliéatoires
 (MNAR = Missing Not At Random)

$\Leftrightarrow P(R | X_{obs}, X_m)$ ne peut pas être simplifiée !

La présence d'une donnée manquante n'est plus explicable ^{que} par les données observées, mais dépend aussi des observations manquantes.

inférences valides \Rightarrow préciser un modèle pour

$$\underline{P(R | X_{obs}, X_m)}$$



Remarques :

- il est difficile de statuer sur le mécanisme générateur des données manquantes MCAR, MAR, MNAR.
- il est rare de savoir le bon modèle pour MNAR
- il est important de savoir comment les analyses sont influencées par le mécanisme choisi : MAR/MCAR. (analyse de sensibilité).

Quelle méthodologie adopter en présence de données manquantes ?

Méthode 1 : Cas complets

- élimine les sujets/unités statistiques ayant des données manquantes
- très simple !
- méthode par défaut des analyses multivariées (ACP, ...)

Problèmes :

- perte de puissance (tests statistiques, ...)
- biais (si MAR)
- ou élimine des informations disponibles (observations partielles).

Recommandations :

- si % de données manquantes $\leq 5\%$ OK
- sinon : utiliser une méthode de gestion des données manquantes et utiliser toute l'information.

Méthode 2 (point de vue très utilisateur !
ce n'est pas le cas d'un étudiant(e)
GIS !).

Données manquantes gérées par la
procédure (technique) statistique
employée

Exemple : la procédure FASTCLUS de SAS
- classification non-supervisée

$$d(i,j) = \sqrt{\frac{n}{m} \left(\sum_{k=1}^m (x_{ik} - x_{jk})^2 \right)}$$

$\begin{cases} n - \text{nombre de variables} \\ m - \text{nombre de variables sans valeurs} \\ \quad \text{manquantes pour les individus } i \text{ et } j \end{cases}$

Problèmes - dépend fortement du logiciel utilisé
- certaines procédures sont naïves
(remplacement avec la moyenne, mode, etc)

Méthode 3 : imputation des données manquantes

imputation = remplacer une donnée manquante par une valeur plausible

le fichier ainsi complété peut être traité ensuite par des techniques standard.

Conjecture: L'imputation est meilleure que l'analyse des cas complets.

Il y a en pratique deux types d'imputation

