

Traitement des Données Manquantes

Pr Roch Giorgi

 roch.giorgi@univ-amu.fr

Problématique Générale (1)

- L'ensemble des données avec lequel on doit travailler n'est pas toujours complet (NA)

Variables

Observations

	1	2	3	...	P
1		NA			
2					
3			NA		
.					
.					
.			NA		
N					NA

Problématique Générale (2)

- Données manquantes
 - ✓ Variable à expliquer
 - ✓ Variable(s) explicative(s)
 - Différents cadres sont possibles
 - ✓ Essais thérapeutique
 - Sortis de l'étude
 - Perdus de vue
 - Critère manquant
 - ✓ Enquêtes
 - Non réponse totale
 - Non réponse partielle
- } Absence de valeur pour le critère de jugement

Problématique Générale (3)

- Impacts

- ✓ Perte d'information non pertinente et/ou non informative
 - Impact nul
- ✓ Perte d'information pertinente et/ou informative
 - Impact fonction du taux de NA
 - **Biais** possible dans l'estimation de la précision et de l'exactitude

- Solutions

- ✓ Ne rien faire
 - Lorsque la proportion de NA de l'échantillon est faible ($\leq 5\%$)
- ✓ Utiliser une procédure adaptée de remplacement des NA

Impacts (1)

- Analyse univariée

Variables

	1	2	3	4	5
Observations					
1		NA		NA	
2					
3	NA				
4		NA		NA	NA
5					
6			NA	NA	
% NA	16,7	33,3	16,7	50,0	16,7

NA observations exclues de l'analyse

Impacts (2)

- Analyse multivariée


Variables

		1	2	3	4	5
Observations	1		NA		NA	
	2					
	3	NA				
	4		NA		NA	NA
	5					
	6				NA	NA


33,3 % d'observations complètes

NA observations exclues de l'analyse


Pattern des Données Manquantes



Univarié



Monotone



Général Multivarié

Classification des Données Manquantes (1)

- **MCAR** : manquant complètement au hasard
 - ✓ La **probabilité** qu'une observation soit incomplète est une **constante**
 - ✓ i.e le fait de ne pas avoir la valeur pour une variable X_i est indépendant des autres variables $X_{j \neq i}$
- **Exemple**
 - ✓ $X_1 = \text{âge}$; $X_2 = \text{sexe}$; $X_3 = \text{glycémie}$
 - ✓ La probabilité que l'âge soit NA ne dépend ni du sexe, ni des valeurs de glycémie
 - ✓ Elle est la même pour tous les sujets

Classification des Données Manquantes (2)

- **MAR** : manquant au hasard
 - ✓ La **probabilité** qu'une observation soit incomplète **ne dépend que de valeurs observées** (pas de valeurs manquantes)
 - ✓ i.e le fait de ne pas avoir la valeur pour une variable X_i est dépendant d'une autre ou d'autres variables $X_{j \neq i}$ observées
- **Exemple**
 - ✓ $X_1 = \text{âge}$; $X_2 = \text{sexe}$; $X_3 = \text{glycémie}$
 - ✓ La probabilité que l'âge soit NA ne dépend que du sexe et des valeurs de la glycémie (valeurs observées)
 - ✓ Elle n'est pas la même pour tous les sujets

Classification des Données Manquantes (3)

- **NMAR** : ne manquant pas au hasard (informative)
 - ✓ La **probabilité** qu'une observation soit incomplète **dépend de valeurs non observées**, elle n'est **pas aléatoire**
 - ✓ i.e le fait de ne pas avoir la valeur pour une variable X_i observée est dépendant d'une autre ou d'autres valeurs non observées des variables $X_{j \neq i}$ observées
- **Exemple**
 - ✓ $X_1 = \text{âge}$; $X_2 = \text{sexe}$; $X_3 = \text{glycémie}$
 - ✓ La probabilité que l'âge soit NA dépend des valeurs manquantes pour le sexe et la glycémie (valeurs non observées)
 - ✓ Elle n'est pas la même pour tous les sujets

Commentaires / Remarques (1)

- MAR et NMAR
 - ✓ MAR et méthode d'analyse pertinente \Rightarrow inférences correctes (seules les informations observées sont utiles)
- MCAR et MAR
 - ✓ On parle de processus ignorable ou non-informatif
 - ✓ Si analyse correcte, ne nécessite pas de modéliser le processus d'observation
- NMAR
 - ✓ On parle de processus non-ignorable ou informatif
 - ✓ Inférence sur la population étudiée nécessite
 - Poser des hypothèses fortes
 - Ou d'obtenir des informations complémentaires
 - ✓ Nécessité de modéliser le processus d'observation

Commentaires / Remarques (2)

- Processus MAR ou NMAR ?
 - ✓ Cela revient à se demander si la probabilité qu'une observation soit complète dépend ou non d'une quantité inconnue \Rightarrow impossible
 - ✓ Cas particulier
 - Données MAR lorsqu'il est prévu un recueil incomplet dans une situation définie
 - Exemple
 X_1, X_2, \dots, X_k recueillies pour tous les sujets
 $X_{k+1}, X_{k+2}, \dots, X_p$ recueillies uniquement chez certains sujets en dépendant uniquement de X_1, X_2, \dots, X_k
 - ✓ Hypothèse $H_1 = \text{MCAR}$ vs $H_0 = \text{MAR}$ peut être testée
 - Si $H_1 = \text{MCAR}$ n'est pas rejetée, l'hypothèse d'un processus ignorable est plus crédible

Stratégies d'Analyse

- Fonction de plusieurs questions
 - ✓ Quelle(s) hypothèse(s) formule-t-on sur le processus d'observation ?
 - ✓ En fonction de cela, quelles données va-t-on modéliser ?
 - ✓ Si l'on n'écarte pas la possibilité de données NMAR, comment tenir compte du risque de biais ?

Méthodes de Traitement

- Analyse de données complètes
- Indicateur de données manquantes
- Analyse pondérée
- Imputation simple
- Imputation multiple

Analyse de Données Complètes (1)

Au lieu de travailler sur ...

	1	2	3
1			
2	NA		
3		NA	
4			
5			
6			
7		NA	
8			
9			NA
10			
11			NA
12			
13			
14			

	1	2	3
1			
4			
5			
6			
8			
10			
12			
13			
14			

... l'analyse ne porte que sur les enregistrements complets

Analyse de Données Complètes (2)

- Stratégie la plus courante
- Généralement **imposée** par les logiciels
- Proportion d'observations complètes peut être faible même si, pour chaque variable, la probabilité qu'une donnée soit observée est grande
- Résultats non biaisés si les données sont MCAR
 - ✓ Mais diminution de la précision et de la puissance
- Sinon biais importants

Exemple : Risque prématurité

(Chavance-Manfredi, 2000)

- Risque de prématurité
- Facteurs étudiés
 - ✓ Antécédents obstétricaux pathologique
 - ✓ Consommation de tabac \geq à 5 cigarettes par jour pendant le troisième trimestre de grossesse (7 % de NA)

	Antécédent obstétrical pathologique	
	Log(ORa)	ET(Ora)
Données complètes	1,46	0,12

ORa : Odds Ratio ajusté sur la consommation de tabac \geq 5 cig./jour pendant le troisième trimestre de la grossesse

Indicateur de Données Manquantes (1)

Au lieu de travailler sur ...

	1
1	1
2	NA
3	2
4	2
5	2
6	1
7	NA
8	2
9	NA
10	1
11	NA
12	1
13	2
14	2

on ajoute une modalité à
la variable catégorielle
incomplètement observée

	1
1	1
2	9
3	2
4	2
5	2
6	1
7	9
8	2
9	9
10	1
11	9
12	1
13	2
14	2

et l'analyse portera sur
tous les enregistrements

Indicateur de Données Manquantes (2)

- Suppose des données MCAR ou MAR
- Peut améliorer la précision de certains estimateurs
- Permet d'apprécier le risque de biais
 - ✓ Une interaction significative entre l'indicatrice de données manquantes et une variable explicative signale l'existence d'un problème
- Mais ne protège pas contre le risque de biais

Exemple : Risque prématurité

(Chavance-Manfredi, 2000)

	Antécédent obstétrical pathologique	
	Log(ORa)	ET(Ora)
Données complètes	1,46	0,12
Indicateur de données manquantes	1,36	0,11

Analyse Pondérée (1)

- Pour des données MAR
- Estimation de la probabilité qu'une observation soit complète pour chaque combinaison des variables influençant cette probabilité
- Exemple
 - ✓ Échantillon aléatoire représentatif
 - ✓ 2 catégories de sujets avec taux de réponses 50 % et 100 %
 - ✓ Chacune des observations de la première catégorie représente 2 fois plus de sujets qu'une observation de la deuxième

Analyse Pondérée (2)

- Affectation pour chaque observation complète d'un poids inversement proportionnel à la probabilité d'effectuer une observation complète
- Correction du biais éventuel
- Augmentation de l'imprécision
- Nécessite une correction particulière pour estimer la variance

Exemple : Risque prématurité

(Chavance-Manfredi, 2000)

	Antécédent obstétrical pathologique	
	Log(ORa)	ET(Ora)
Données complètes	1,46	0,12
Indicateur de données manquantes	1,36	0,11
Analyse pondérée	1,34	0,12

Imputation Simple (1)

Au lieu de travailler sur ...

	1	2	3
1			
2	NA		
3		NA	
4			
5			
6			
7		NA	
8			
9			NA
10			
11			NA
12			
13			
14			

$f(X)$

	1	2	3
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			
11			
12			
13			
14			

on remplace chaque NA par une données prédite ou simulées

et l'analyse portera sur tous les enregistrements

Imputation Simple (2)

- Hypothèse d'un processus d'observation MAR
- Produit une valeur « artificielle » pour remplacer la valeur NA
- Les informations disponibles sur les individus qui ne fournissent qu'une réponse partielle peuvent être utilisées comme variables auxiliaires pour améliorer la qualité des valeurs imputées

IS : Dernière Observation

- Last Observation Carried Forward
- Lors de mesures répétées
- Suppose que la vraie valeur reste inchangée depuis la dernière mesure
- Si pas de mesure disponible pendant le suivi, la valeur initiale est utilisée

	X_Temps0	X_Temps1	X_Temps2	X_Temps3	X_Temps4	X_Temps5
1	18	20	NA	15	21	NA
2	24	NA	NA	NA	15	NA

IS : Hot-Deck et Cold-Deck (1)

- Hot-Deck
 - ✓ La valeur manquante est remplacée par une valeur observée chez un individu ayant les mêmes caractéristiques
- Cold-Deck
 - ✓ La valeur manquante est remplacée par une valeur observée chez un individu ayant les mêmes caractéristiques, mais provenant d'une autre source d'information
- mêmes caractéristiques \Leftrightarrow « plus proche voisin »
 - ✓ Fonction de distance basée sur une ou plusieurs variables auxiliaires
 - ✓ Quelle fonction de distance ?

IS : Hot-Deck et Cold-Deck (2)

	X1	X2	X3	X4
1	1	3	1	2
2	1	NA	1	5
3	2	3	NA	2
4	NA	3	NA	5

IS : par la Moyenne

- Remplacement d'une valeur manquante par la moyenne des mesures disponibles
- La même pour toutes les NA d'une même variable
- Estimations non biaisées si les données sont MCAR


IS : par un modèle de Régression (1)

- Remplacement d'une valeur manquante Y_i par une valeur prédite Y^* obtenue par régression de Y sur X_1, X_2, \dots
- Possibilité d'ajouter un aléa à la prédiction
- Estimation ponctuelle correcte
- Variance sous-estimée

IS : par un modèle de Régression (2)

- Exemple : régression linéaire simple

	X	Y
1		
2		
...		
a		
...		
n		



Modélisation sur les cas complets $y_i = \hat{\alpha} + \hat{\beta}x_i \quad i = 1, \dots, a$


Imputation par la prédiction du modèle de régression

$$y_i^* = \hat{\alpha} + \hat{\beta}x_i \quad i = a + 1, \dots, n$$

IS : par un modèle de Régression (3)

- Exemple : régression linéaire simple avec résidus aléatoires

	X	Y
1		
2		
...		
a		
...		
n		



Modélisation sur les cas complets $y_i = \hat{\alpha} + \hat{\beta}x_i \quad i=1, \dots, a$ et $\hat{\sigma}^2$

Imputation par la prédiction du modèle de régression

$$y_i^* = \hat{\alpha} + \hat{\beta}x_i + e_i \quad i = a + 1, \dots, n$$

avec $e_i \sim \mathbf{N}(0, \hat{\sigma}^2)$

Exemple : Risque prématurité

(Chavance-Manfredi, 2000)


	Antécédent obstétrical pathologique	
	Log(ORa)	ET(Ora)
Données complètes	1,46	0,12
Indicateur de données manquantes	1,36	0,11
Analyse pondérée	1,34	0,12
Imputation simple	1,34	0,11

Imputation Multiple

- Méthode consistant à créer plusieurs valeurs possibles d'une valeur manquante
- Les buts **sont**
 - ✓ De refléter correctement l'incertitude des NA
 - ✓ De préserver les aspects importants des distributions
 - ✓ De préserver les relations importantes entre les variables
- Les buts **ne sont pas**
 - ✓ De prédire les données manquantes avec la plus grande précision
 - ✓ De décrire les données de la meilleur façon possible


Imputation Multiple : les Étapes (1)

- Remplacer chaque valeur manquante par $M > 1$ valeurs tirées d'une distribution appropriée




Imputation Multiple : les Étapes (2)

- Analyses indépendantes et avec la même méthode standard des $M > 1$ bases de données complètes



Imputation Multiple : les Étapes (3)

- Combiner les résultats des analyses afin de refléter la variabilité supplémentaire due aux données manquantes



IM : Commentaires / Remarques (1)

- Approche générale
- Un ensemble d'imputation peut servir pour plusieurs analyses
- Les résultats définitifs incorporent l'incertitude des non réponses
- Très efficace même pour des petites valeurs de M (> 3)
- Hypothèse d'un processus d'observation MAR
- Les distributions prédictives des données manquantes sont très compliquées

IM : Commentaires / Remarques (2)

- IM possibles grâce aux méthodes
 - ✓ Algorithme EM (Expectation – Maximisation)
 - Procédure itérative en 2 étapes
 - Calcul de l'espérance : identification de la distribution des données manquantes en fonction des données observées et des variables explicatives
 - Maximisation : remplace les données manquantes par les valeurs attendues
 - Itération jusqu'à l'obtention d'une stabilisation dans les valeurs attendues
 - ✓ Méthodes de calcul MCMC (Monte Carlo Markov Chain)
 - Création d'une chaîne de Markov qui converge vers la distribution prédictive a posteriori des données manquantes

Exemple : Risque prématurité

(Chavance-Manfredi, 2000)

	Antécédent obstétrical pathologique	
	Log(ORa)	ET(Ora)
Données complètes	1,46	0,12
Indicateur de données manquantes	1,36	0,11
Analyse pondérée	1,34	0,12
Imputation simple	1,34	0,11
Imputation multiple (M =3)	1,34	0,11
Imputation multiple (M =30)	1,34	0,11
Imputation multiple (M =100)	1,34	0,11

Une Synthèse (1)

- Analyses préliminaires des données
 - ✓ Pattern des données manquantes
 - ✓ % de NA pour chaque variables
 - ✓ % de NA par sujets
 - ✓ % de NA total
 - ✓ Corrélation entre les variables
 - ✓ Autres ?

Une Synthèse (2)

- Analyse des données complètes
 - ✓ Méthode la moins satisfaisante en terme de biais et de précision
- Indicateur de données manquantes
 - ✓ Plus précis, permet d'identifier certains problèmes de biais, ne les traite pas de façon pleinement satisfaisante
- Analyse pondérée
 - ✓ Corrige le biais éventuel de données MAR, mais augmente l'imprécision

Une Synthèse (3)

- Imputation simple
 - ✓ Exige souvent un processus d'observation MCAR
- Imputation multiple
 - ✓ Prend en compte simultanément les problèmes de biais et de précision
 - ✓ Flexible
 - ✓ Adaptée pour des données qualitatives et quantitatives
 - ✓ Utilisable pour différents type d'analyse (régression logistique, ...)

Imputation Multiple : Logiciels

- SOLAS
 - ✓ http://www.statsol.ie/html/solas/solas_home.html
- SAS PROC MI et PROC MIANALYZE
 - ✓ <http://support.sas.com/rnd/app/da/new/dami.html>
- S-Plus
 - ✓ <http://www.insightful.com/>
- MICE* pour R et S-Plus
 - ✓ <http://www.multiple-imputation.com>
- NORM*
 - ✓ <http://www.stat.psu.edu/~jls/misoftwa.html>

* Gratuit

Imputation Multiple : MICE

- Package MICE à télécharger et à installer dans R
 - ✓ <http://cran.r-project.org/> dans Software, Packages
- Avant son utilisation dans R
 - ✓ Il faut le charger dans R
 - ✓ Menu « Packages », « Charger le package... », sélectionner « `mice` »
- Contient le fichier `nhanes`
 - ✓ 25 sujets
 - ✓ 4 variables
 - `age` : groupes d'âge : 1=20-39, 2=40-59, 3=60+
 - `bmi` : index de masse corporelle (kg/m²)
 - `hyp` : hypertension : 1=non, 2=oui
 - `chl` : cholestérol total (mg/dL)

Exemple nhanes (1)

- > Importation des données
- > Visualisation des données pour les 5 premières lignes

- > Proportion de données NA par variables
- > Proportion de données NA par individus

```
R Console
> data(nhanes)
> nhanes[1:5 , ]
  age  bmi  hyp  chl
1   1   NA  NA  NA
2   2 22.7   1 187
3   1   NA   1 187
4   3   NA  NA  NA
5   1 20.4   1 113
> colSums(is.na(nhanes))/nrow(nhanes)
  age  bmi  hyp  chl
0.00 0.36 0.32 0.40
> rowSums(is.na(nhanes))/ncol(nhanes)
   1    2    3    4    5    6    7    8
0.75 0.00 0.25 0.75 0.00 0.50 0.00 0.00
   9   10   11   12   13   14   15   16
0.00 0.75 0.75 0.75 0.00 0.00 0.25 0.75
  17   18   19   20   21   22   23   24
0.00 0.00 0.00 0.25 0.75 0.00 0.00 0.25
  25
0.00
> █
```

Exemple nhanes (2)

- Pattern des données manquantes

13 lignes sont complètes →
3 lignes où seule `chl` est NA →
Nombre total de NA = 27 →

```
R Console
> md.pattern(nhanes)
      age hyp bmi chl
13    1  1  1  1  0
 1    1  1  0  1  1
 3    1  1  1  0  1
 1    1  0  0  1  2
 7    1  0  0  0  3
      0  8  9 10 27
> █
```

Exemple nhanes (3)

- La fonction `mice` (multivariate imputation by chained equations)
- Arguments
 - `data` : data frame, matrice des données (NA)
 - `m` : nombre d'imputations multiples (m=5 *)
 - `imputationMethod` : méthode utilisée pour les imputations
 - `norm` : régression linéaire bayésienne (numeric)
 - `pmm` * : moyenne prédite par « appariement » (numeric)
 - `mean` : moyenne marginale (numeric)
 - `logreg` * : régression logistique (2 catégories)
 - `logreg2` : régression logistique (minimisation directe) (≥ 2 catégories)
 - `polyreg` * : régression logistique multinomiale (≥ 2 catégories)
 - `lda` : analyse discriminante linéaire (≥ 2 catégories)
 - `sample` : échantillonnage aléatoire à partir des données observées

* Valeurs par défaut

Exemple nhanes (4)

> Algorithme d'imputation

Valeur par défaut →

Récapitulatif des NA →

Méthodes par défaut →

Ordre dans lequel les variables
sont utilisées pour l'imputation →

Indicatrice des variables utilisées
pour chaque variable avec NA →

```
R Console
> imp <- mice(nhanes)
> imp
Multiply imputed data set
Call:
mice(data = nhanes)
Number of multiple imputations: 5
Missing cells per column:
age bmi hyp chl
 0  9  8 10
Imputation methods:
age  bmi  hyp  chl
 "" "pmm" "pmm" "pmm"
VisitSequence:
bmi hyp chl
 2  3  4
PredictorMatrix:
      age bmi hyp chl
age   0  0  0  0
bmi   1  0  1  1
hyp   1  1  0  1
chl   1  1  1  0
Random generator seed value: NA
> █
```

Exemple nhanes (5)

> Données imputées pour bmi

Lignes où bmi est NA

```
R Console
> imp$imp$bmi
      1      2      3      4      5
1  33.2  29.6  20.4  27.5  29.6
3  29.6  29.6  29.6  29.6  30.1
4  24.9  25.5  27.2  21.7  21.7
6  24.9  24.9  24.9  24.9  24.9
10 27.4  22.0  26.3  22.0  22.0
11 35.3  29.6  35.3  27.5  29.6
12 22.7  22.0  28.7  22.0  26.3
16 35.3  33.2  33.2  35.3  30.1
21 33.2  22.5  33.2  30.1  35.3
>
```

Valeurs 1^{ère} imputation

2^{ème} imputation

...

5^{ème} imputation

Exemple nhanes (6)

- > Visualisation des 5 premières lignes du premier jeux de données complètes

```
R Console
> complete(imp, 1)[1:5 , ]
  age  bmi  hyp chl
1   1 33.2   1 229
2   2 22.7   1 187
3   1 29.6   1 187
4   3 24.9   1 184
5   1 20.4   1 113
> █
```

⋮

- > Visualisation des 5 premières lignes du cinquième jeux de données complètes

```
R Console
> complete(imp, 5)[1:5 , ]
  age  bmi  hyp chl
1   1 29.6   1 187
2   2 22.7   1 187
3   1 30.1   1 187
4   3 21.7   1 206
5   1 20.4   1 113
> █
```

Exemple nhanes (7)

- Analyse complète
 - ✓ Régression linéaire de `chl` sur `age` et `hyp`

```
R Console
> fit <- lm.mids(chl ~ age + hyp, imp)
> pool(fit)
Call: pool(object = fit)

Pooled coefficients:
(Intercept)      age      hyp
 128.11019    16.88824    33.15435

Fraction of information about the coefficients missing due to nonresponse:
(Intercept)      age      hyp
 0.1638523    0.2561456    0.2518272
>
```

- ① Régression linéaire sur des données imputées multiples
- ② Pour obtenir les résultats uniques des m analyses complètes
- ③ Résultat final de la régression linéaire
- ④ Fraction de l'information due à la non-réponse

Exemple nhanes (8)

- Analyse complète
 - ✓ Régression linéaire de `chl` sur `age` et `hyp`

```
R Console
> summary(pool(fit))
              est      se      t      df      Pr(>|t|)
(Intercept) 128.11019 27.69687 4.625439 16.78156 0.0002494190
age          16.88824 12.19378 1.384988 13.35101 0.1887631610
hyp          33.15435 24.99010 1.326700 13.50286 0.2066086715
              lo 95      hi 95 missing      fmi
(Intercept)  69.616901 186.60348      NA 0.1638523
age          -9.384586  43.16107      0 0.2561456
hyp          -20.629804  86.93851      8 0.2518272
> █
```

Résultats plus généraux de l'analyse de régression linéaire sur des données imputées multiples

Références & Liens Utiles

- Chavance M, Manfredi R. Modélisation d'observations incomplètes. *Rev Epidém et Santé Publ* 2000; 48:389-400.
- Schafer JL. *Analysis of incomplete multivariate data*. Chapman & Hall, 2000.
- Horton NJ, Stuart RL. Multiple imputation in practice: comparison of software packages for regression models with missing variables. *The American Statistician* 2001;55:244-254.
(<http://www.biostat.harvard.edu/~horton/tasimpute.pdf>)
- van Buuren S, Oudshoorn CGM. *Multivariate imputation by chained equations*. MICE V1.0 User's manual.
(<http://web.inter.nl.net/users/S.van.Buuren/mi/docs/Manual.pdf>)
- Multiple imputation online : <http://www.multiple-imputation.com>
- The multiple imputation FAQ page :
<http://www.stat.psu.edu/~jls/mifaq.html>