



Projet Obe Maghreb

Ecole thématique gestion et analyse de données  
20 au 29 avril 2010

## Gestion et analyse de données d'enquêtes épidémiologiques

### Gestion de données Mise en œuvre avec EpiData Analysis



Pierre Traissac  
UMR 204 « Prévention des malnutritions et pathologies associées »  
IRD, Montpellier, France



## Gestion de données

1- Accès aux données

2- Gestion des données →

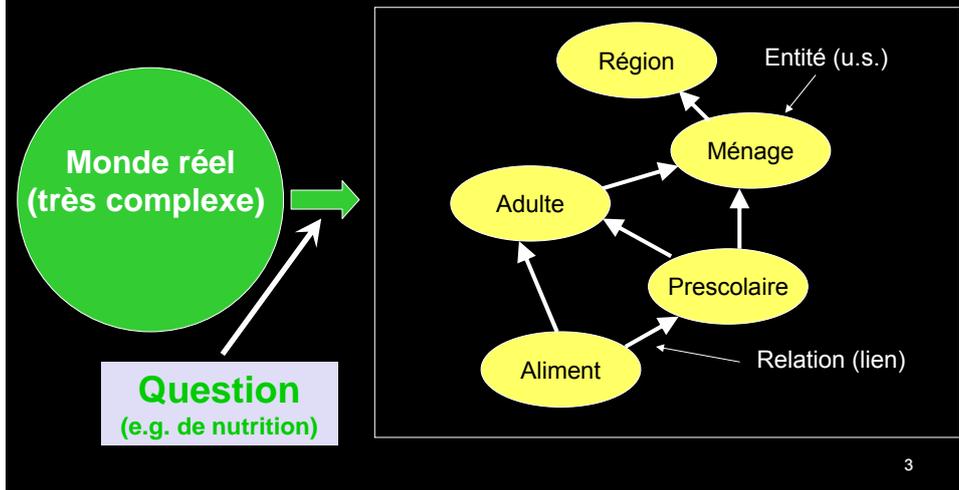
3- Analyse des données

4- Présentation des données

- **Conservation**
  - **sécurité**
  - **sauvegardes**
- **Préparation avant analyse**
  - sélections (individus, variables)
  - mise en relation, fusion de fichiers
  - calcul de nouvelles variables
  - recodages
  - **documentation (versions fichiers, dictionnaires)**
- **Outil logiciel**
  - SGBD (e.g. MS- Access, Oracle, ...)
  - gestion de données dans logiciels statistiques (SAS, Stata, SPSS) ou généralistes (EpiData)
- **Data manager ⇔ spécialiste discipline**

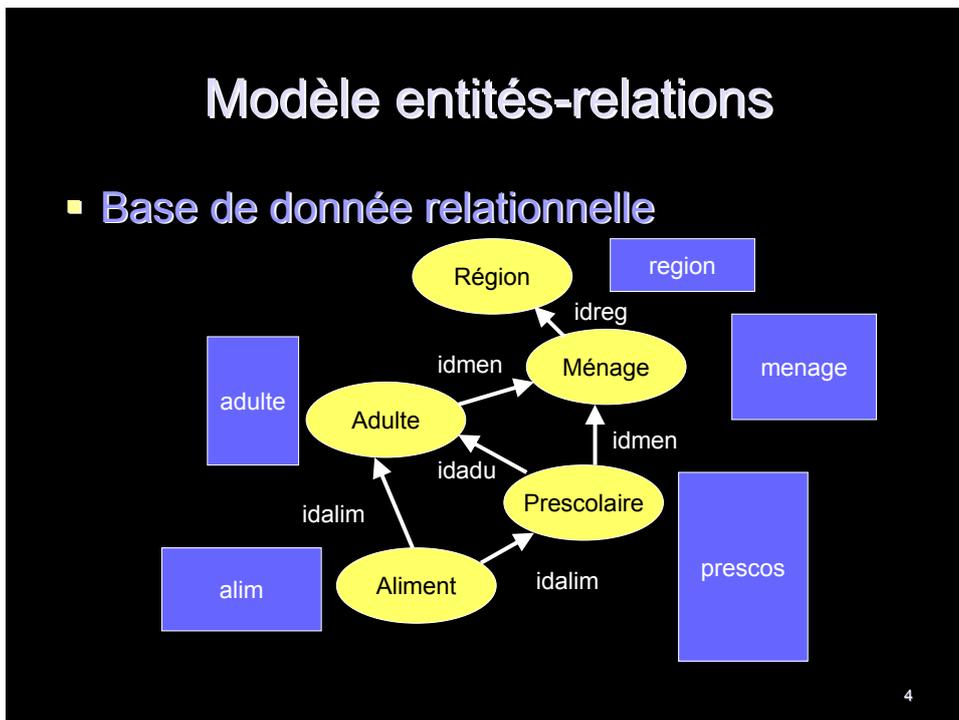
# Modèle de données

- Représentation schématique monde réel



# Modèle entités-relations

- Base de donnée relationnelle



# Gestion de données

## ■ Langage de gestion de données

- mise en forme des données avant analyse
- création de nouvelles tables  
(opérateurs de sélection de lignes, colonnes, fusion de tables)
- création de nouvelles variables  
(recodage, calcul d'indices, de scores, ...)
- documentation des données  
(labels et notes pour tables et variables)

## ■ Concepts vs. mise en œuvre pratique

- concepts, opérateurs : invariants
- mise en œuvre informatique: dépend du logiciel  
Oracle, Ms-Access, SAS, SPSS, Stata, EpiData Analysis, ...
- SQL (Standard Query Language) +/- standard (pas dans EpiData Analysis)
- Menus vs. langage de commande / programmes  
(documentation, tracabilité)

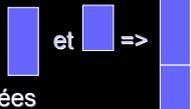
5

# Gestion de données

## ■ Opérateurs sur une seule table

- sélection (sélection de lignes)  => 
- projection (sélection de colonnes/variables)  => 
- changement d'unité statistique  
(table large devient table longue ou inversement)  => 

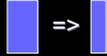
## ■ Opérateurs sur 2 tables et +

- langage relationnel (intersection, réunion, jointure)
- fusion horizontale (mise en relation) :  et  => 
- fusion verticale :  et  => 
- requêtes imbriquées

6

## Gestion de données

### Opérateurs sur une seule table

- sélection (sélection de lignes)  => 
- projection (sélection de colonnes/variables)  => 
- changement d'unité statistique (table large devient table longue ou inversement)  => 

### Opérateurs sur 2 tables et +

- langage relationnel (intersection, réunion, jointure)
- fusion horizontale (mise en relation) :  et  => 
- fusion verticale :  et  => 
- requêtes imbriquées

7

## Gestion de données

### Sélection de colonnes

- But : créer table « anthro » à partir de la table « adultes »  
sélection colonnes : sexe, gross, taille, poids, tt, th

<u>idadu</u>	<u>idreg</u>	sexe	age	csp	nivsko	gross	taille	poids	tt	th

- Epidata Analysis

```
read "adultes.rec" /close (possible aussi de lire format .dbf)
keep idadu sexe gross taille poids tt th
ou drop idreg age csp nivsko
savedata "anthro.rec" /replace (création table anthro)

read "adultes.rec" /close
list (ou browse) idadu sexe gross taille poids tt th (liste variables à afficher à l'écran)
!!! IDENTIFIANT(S) !!!
```

8

# Gestion de données

## ■ Epidata Analysis

TABLES region

Région administrative	N	%
1	290	15.7
2	234	12.7
3	313	16.9
4	265	14.3
5	285	15.4
6	210	11.4
7	252	13.6
Total	1849	100.0

# Gestion de données

## ■ Sélection de lignes

- But : créer table « hommes » à partir de la table « adultes »  
sélection des lignes sexe masculin

idadu	idreg	sexe	age	csp	nivscs	gross	taille	poids	tt	th
		1								
		2								
		1								

- Epidata

```
read "adultes.rec" /close
select if sexe=1 (sélection temporaire)
count (donne le nombre de lignes sélectionnées)
list (ou browse) (affichage écran de la sélection)
```

```
read "adultes.rec" /close
select if sexe=1
savedata "hommes.rec" /replace (création table hommes)
```

## Gestion de données

### ■ Sélection de lignes

- `sexe=1` condition logique (résultat=0 (faux) ou 1 (vrai) )

si vrai : ligne sélectionnée,

si faux : ligne non sélectionnée

- Exemples de conditions

`age<=24 poidsnai<2500 region<>3 obese=«oui»`

doivent respecter les domaines

- Combinaison de conditions avec and, or, not

`sexe=1 and csp=5` (et logique)

`sexe=1 or csp=5` (ou inclusif)

`malade=1 and not(csp=5)`

`sexe=2 and gross=2 and (csp=3 OR nivsco>=2)`

- Annulation sélection temporaire : `select` (sans rien ...) sinon sélections s'additionnent (équivalent de AND)

11

## Gestion de données

### ■ Sélection de lignes et colonnes

- But : créer table « anthroF » à partir de la table « adultes »

sélection colonnes : sexe, taille, poids, tt, th

sélection lignes : femmes non enceintes

- Epidata Analysis

```
read "adultes.rec" /close
```

```
select if sexe=2 and gross=2
```

```
keep idadu sexe taille poids tt th
```

```
savadata " anthroF.rec" / replace (création table anthroF)
```

**!!! IDENTIFIANT(S) !!!**

ou

```
read "adultes.rec" /close
```

```
select if sexe=2 and gross=2
```

```
list (ou browse) idadu sexe taille poids tt th (liste de variables à afficher)
```

12

# Gestion de données

## ■ Changement d'unité statistique

- But : créer une variable nombre d'adultes par ménage (nbadult) ou somme des revenus par ménage (revtotal) à partir de la table « adultes »

u.s. : adulte

idadu	idmen	sexe	revenus	...
100010201	1000102	1	900	
100010202	1000102	2	800	
100010203	1000102	2	0	
100010301	1000103	1	1100	
100010302	1000103	2	600	
100010303	1000103	1	0	
100010304	1000103	1	400	
100010401	1000104	1	800	
100010402	1000104	2	0	

u.s. : ménage

idmen	nbadult	revtotal
1000102	3	1700
1000103	4	2100
1000104	2	800

13

# Gestion de données

## ■ Changement d'unité statistique

- Epidata Analysis

```
read "adultes.rec" /close
```

```
aggregate idmen /sum="revenus" /close (possible aussi /save="...")
```

idmen	N	Nrevenus	SUMrevenus
1000102	3	3	1700
1000103	4	3	2100
1000104	2	2	800

```
drop nrevenus
```

```
rename n to nbadult
```

```
rename sumrevenus to revtotal
```

```
savdata "men_rev.rec" /replace
```

14

# Gestion de données

## ■ Changement d'unité statistique

u.s. : adulte

<u>idadu</u>	<u>idmen</u>	sexe	revenus	...
100010201	1000102	1	900	
100010202	1000102	2	800	
100010203	1000102	2	0	
100010301	1000103	1	1100	
100010302	1000103	2	600	
100010303	1000103	1	0	
100010304	1000103	1	400	
100010401	1000104	1	800	
100010402	1000104	2	0	

u.s. : ménage

<u>idmen</u>	nbadult	revtotal
1000102	3	1700
1000103	4	2100
1000104	2	800

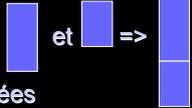
15

# Gestion de données

## ■ Opérateurs sur une seule table

- sélection (sélection de lignes)  => 
- projection (sélection de colonnes/variables)  => 
- changement d'unité statistique (table large devient table longue ou inversement) 

## ■ Opérateurs sur 2 tables et +

- langage relationnel (intersection, réunion, jointure)
- fusion horizontale (mise en relation) :  et  => 
- fusion verticale :  et  => 
- requêtes imbriquées

16

## Gestion de données

### ■ Fusion horizontale - Relation 1:1

- But

table : adusoec(idadu, idmen, sexe, age, statmat, csp, nivsco) n x 7

table : adunutr(idadu, idmen, cal, lip, glu, pro) n x 6

création table :

adutot(idadu, sexe, age, statmat, csp, nivsco, cal, lip, glu, pro) n x 12

!!! Identifiant commun idadu !!!

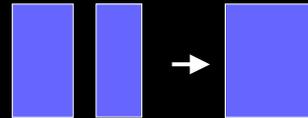
- Epidata Analysis

```
read "adusoec.rec" /close
```

```
merge idadu /file= "adunutr.rec" /table
```

```
browse ou list (affichage écran)
```

```
savadata "adutot.rec" /replace (création table adutot)
```



- Si les n sont différents (pb de référence) ?

17

## Gestion de données

### ■ Fusion horizontale (mise en relation)- Relation 1:n

- But

table : adunutr(idadu, idmen, cal, lip, glu, pro) n x 6

table : menage(idmen, datenqm, nbpers, revenus) m x 4       $m \leq n$

création table :

adunutrme(idadu, idmen, cal, lip, glu, pro, datenq, nbpers, revenus) n x 9

!!! Identifiant commun idmen !!!


- Epidata Analysis

```
read "adunutr.rec" /close
```

```
merge idmen /file="menage.rec" /table
```

```
browse ou list (affichage écran)
```

```
savadata "adunutrme.rec" /replace (création table adunutrme)
```

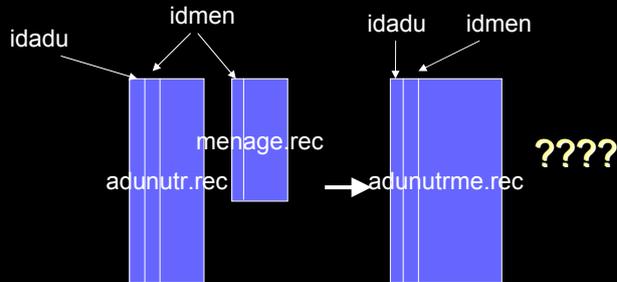


- Si pb de référence (idmen présent dans adunutr mais pas dans menage) ?

18

## Gestion de données

### ▪ Fusion horizontale (mise en relation)- Relation 1:n



- Duplication (redondance) des données ménage dans table résultante :
  - . non unicité de idmen
  - . tous adultes d'un même ménage ont même valeur des variables ménage

19

## Gestion de données

### ▪ Relation 1: n - Duplication données ménage

- table adunutrme(idadu, idmen, cal, lip, glu, pro, datenqm, nbpers, revenus) n x 9

<u>idadu</u>	<u>idmen</u>	cal	lip	glu	pro	datenqm	nbpers	revenus
100010203	1000102					24/10/2000	5	10000
100010206	1000102					24/10/2000	5	10000
100020702	1000207					31/10/2000	7	8500
100020703	1000207					31/10/2000	7	8500
100020704	1000207					31/10/2000	7	8500
100031706	1000317					04/11/2000	2	12000
100031803	1000318					12/11/2000	3	9000
100031806	1000318					12/11/2000	3	9000
100010203	1000102					12/11/2000	4	5000

20

## Gestion de données

### ■ Fusion 1:n (e.g u.s. ménage : u.s. personne)

- Nécessaire pour certaines analyses  
(étude conjointe variables ménage et personne)
- Ne pas utiliser pour analyses u.s. ménage  
**!!! Redondance données ménages !!!**

21

## Gestion de données

### ■ Fusion verticale

#### - But :

table Tunisie : adutun(idadu, idmen, sexe, age, statmat, csp, nivsco)  $n_1 \times 7$

table Maroc : adumar(idadu, idmen, sexe, age, statmat, csp, nivsco)  $n_2 \times 7$

création table :

adumag(idadu, idmen, sexe, age, statmat, csp, nivsco)  $(n_1 + n_2) \times 7$

mêmes variables, lignes des 2 tables

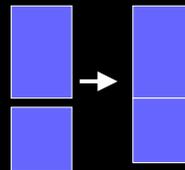
#### - Epidata Analysis

```
read "adutun.rec" /close
```

```
append "adumar.rec"
```

```
browse ou list (affichage écran)
```

```
savedata "adumag.rec" /replace (création table adumag)
```



- **ATTENTION** : unicité de idadu dans adumag ???? Code pays ????

- Si les variables sont différentes ? se passe +/- bien suivant logiciel.

22

## Gestion de données

### ■ Requête imbriquée

- sélection de lignes d'une table  
sur une condition utilisant une variable d'une autre table

- adunutr(idadu, idmen, cal, lip, glu, pro) n x 6

- sélectionner dans cette table les individus dont le ménage  
comprend plus de 2 adultes

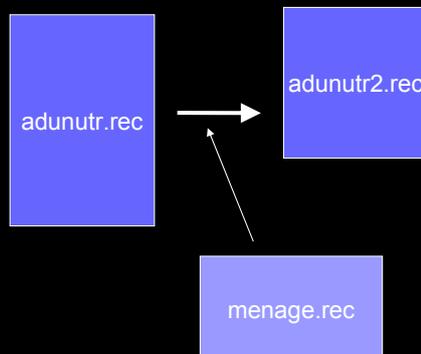
- ? variable nbadult dans : menage(idmen, datenqm, nbadult, revtotal)

- certains langages (e.g. SQL, mais pas Epidata Analysis) :  
requêtes imbriquées directes sans fusion des tables

23

## Gestion de données

### ■ Requête imbriquée



24

## Gestion de données

### ▪ (pseudo) requête imbriquée Epidata

- mise en relation (fusion temporaire) tables adunutr et menage
- sélection de lignes
- création table adunutr2 contenant seulement les variables adunutr pour les u.s. sélectionnées
- Epidata Analysis

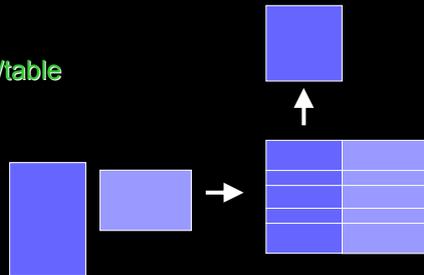
```
read "adunutr.rec" /close
```

```
merge idmen /file="menage.rec" /table
```

```
select if nbadult>=2
```

```
keep idadu idmen cal lip glu pro
```

```
save "adunutr2.rec" /replace
```



25

## Gestion de données

### ▪ Sélection lignes, colonnes

### ▪ Fusion verticale, horizontale

### ▪ !!!! Vérifier la table résultante !!!!

- nombre de lignes ?
- nombre de colonnes ?
- mise en relation correcte ?

26

# Gestion de données

1- Accès aux données

2- Gestion des données

3- Analyse des données

4- Présentation des données

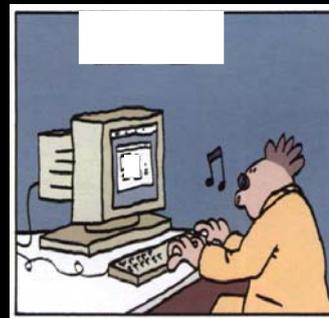
- Conservation
  - sécurité
  - sauvegardes
- Préparation avant analyse
  - sélections (individus, variables)
  - mise en relation, fusion de fichiers
  - calcul de nouvelles variables
  - recodages
  - documentation (versions fichiers, dictionnaires)
- Outil logiciel
  - SGBD (e.g. MS- Access, Oracle, ...)
  - gestion de données dans logiciels statistiques (SAS, Stata, SPSS) ou généralistes (EpiData)
- Data manager ⇔ spécialiste discipline

27

# Gestion de données

## Exercices pratiques gestion de données (1)

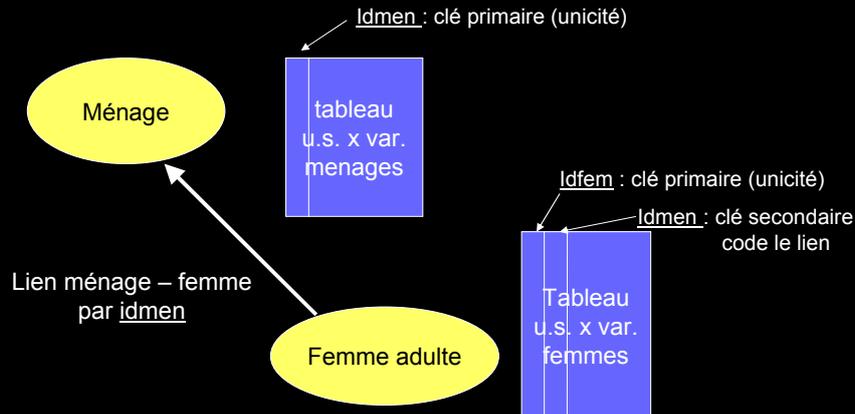
- lecture de fichiers, visualisation
- vérifications (tris, stat. élémentaires)
- sélection de lignes, colonnes
- changement d'unité statistique
- fusion de tables
- sauvegarde des nouvelles tables
- documentation



28

# Gestion de données

## ■ Modèle de données pour les exercices



29

# Gestion de données

1- Accès aux données

2- Gestion des données

3- Analyse des données

4- Présentation des données

- **Conservation**
  - **sécurité**
  - **sauvegardes**
- **Préparation avant analyse**
  - sélections (individus, variables)
  - mise en relation, fusion de fichiers
  - calcul de nouvelles variables
  - recodages
  - **documentation (versions fichiers, dictionnaires)**
- **Outil logiciel**
  - SGBD (e.g. MS- Access, Oracle, ...)
  - gestion de données dans logiciels statistiques (SAS, Stata, SPSS) ou généralistes (EpiData)
- **Data manager ⇔ spécialiste discipline**

30

## Gestion de données

### ▪ Différents types statistiques de variables

- Quantitative
  - . continue (taille en cm : 175,6 ; ingéré : 2456 kcal)
  - . discrète (nombre de personnes dans ménage : 12)

Valeurs dans domaine (intervalle)

- Qualitative
  - . ordonnée (état habitat : bon , moyen, mauvais)
  - . quelconque (statut matrimonial :  
célibataire, marié, veuf, divorcé, autre)
  - . dichotomique (sexe : F/M, fumeur : oui/non)

Modalités exclusives, exhaustives (catégorie « autre »)

Modalités dans domaine (liste de modalités)

31

## Gestion de données

### ▪ Différents types informatiques de variables

- numériques (entiers, réels)
- caractère

(- date : type numérique, nombre de jours depuis date de référence , souvent le 1<sup>er</sup> janvier 1960)

### ▪ Notion de codage

32

## Gestion de données

### ■ Variables numériques

- entiers : 0, 1, 15, 345
- réels : 3.56, 100, -2.5
- longueur, décimales ( #, ###, ####.##)
- opérations algébriques : +, x, -, /, log, ^2, ....
- comparaisons : < >, <=, =, <>
- valeur manquante : .

- Création de variable dans Epidata Analysis (e.g. variable réelle)

```
define caltot ####.##
```

```
caltot=calprot+calglu+callip+calalc
```

ou

```
gen caltot=calprot+calglu+callip+calalc
```

```
label caltot « Energie totale (calories) »
```

possible préciser le type (i :entier, f: réel)

```
gen i var= .....
```

```
gen f var=.....
```

33

## Gestion de données

### ■ Variables caractère (alphanumériques)

- contenu : obèse, oui, non, c2, 145, 4.5, pierre
- longueur
- pas d'opérations algébriques
- comparaison =
- fonctions spécifiques (sous chaînes, ...)
- valeur manquante : chaîne vide

- Création de variable dans Epidata Analysis

```
define nom _____ (nom, type caractère, longueur 8)
```

```
nom=expression
```

ou `gen s nom=expression`

```
label nom «Norm de famille de la personne»
```

- Epidémiologie / statistique : peu utilisées en pratique

34

## Gestion de données

### ■ Variables date

- type numérique, nombre de jours depuis le 1<sup>er</sup> janvier 1960
- différents formats
- opérateurs, comparaisons  
(~ idem variables numériques)
- valeur manquante : .

- Création de variable dans Epidata

```
define datvis <dd/mm/yyyy>
```

```
datvis=dmy(jourvis,moisvis, anvis) (par exemple) datvis=today
```

```
ou
```

```
gen d datvis=dmy(jourvis,moisvis, anvis)
```

```
label datvis «Date de visite»
```

35

## Gestion de données

### ■ Notion de codage

- variable quantitative : unités

taille : 1.756 m, 175.6 cm, 1756 mm

- variable qualitative : codes (beaucoup de choix possibles)

Satut matrimonial :

Valeurs	-----	Différents codages possibles					-----
Célibataire	Célibataire	CEL	C	1	5	4	
Marié(e)	Marié	MAR	M	2	4	5	
Veuf(ve)	Veuf	VEU	V	3	3	6	
Divorcé(e)	Divorcé	DIV	D	4	2	7	
Autre	Autre	AUT	A	5	1	8	

- !!! codes ≠ valeurs de la variable (cf. analyse) !!!

- documentation : unités, codes (variables de base ET calculées)

36

## Gestion de données

### ■ Codage valeurs manquantes

- u.s. : ménage (définition ...)
- variable : « nombre de personnes dans le ménage »
  - type statistique : quantitative discrète (1 à 20)
  - informatique : variable nbpers numérique
- Valeurs manquantes ??
  - statistique /épidémiologie : on n'a pas la donnée pour ce ménage
  - informatique : on n'a pas affecté de valeur pour ce ménage (vide)

#### Choix possibles :

- codage(s) spécifique(s) manquants (e.g. code 9 ou 99 ou 9999)
  - => manquant « statistique » différent de « manquant informatique »
  - on peut imaginer avoir à la fois des . (i.e. on n'a rien saisi)
  - et des 99 (on a saisi code manquant)
- codage par non affectation de valeur (e.g. pas de saisie) si pas la donnée
  - => les deux notions se confondent

37

## Gestion de données

### ■ Variables transformées (recodages)

- Taille en m (1,756) => Taille en cm (175,6)  
quantitatif => quantitatif
- Catégories d'âge
  - 18 <= âge < 25 : catégorie 1
  - 25 <= âge < 40 : catégorie 2
  - 40 <= âge : catégorie 3quantitatif => qualitatif
- Anémie :
  - hb < 110 g /L : oui
  - hb >= 110 g/L : nonquantitatif => dichotomique

38

## Gestion de données

### ■ Variables transformées (recodages)

- Marié (oui/non) :

statut matrimonial = marié : oui  
statut matrimonial = célibataire, veuf, divorcé, autre : non  
qualitatif « quelconque » => dichotomique  
dichotomique : codage en 1/2 ou en 1/0

- Variable qualitative => indicatrices (pour les modèles)

une nouvelle variable en 0/1 (=indicatrice) pour chaque modalité de la variable qualitative  
statut matrimonial : 5 modalités => 5 indicatrices

39

## Gestion de données

### ■ Variables calculées (indices, scores)

A réfléchir en fonction de l'étape « Analyse des données »

- IMC = poids/taille<sup>2</sup> kg/m<sup>2</sup> (quantitatif => quantitatif)

- Equipement du ménage

WC (oui/non), électricité (oui/non), eau (oui/non), égout (oui/non)  
=> score d'équipement : 0 à 4 (quantitative discrète)

- questionnaire de fréquence activité physique

=> dépense énergétique totale

- questionnaire échelle d'attitudes

=> attitude vis-à-vis de l'obésité

40

## Gestion de données

### ■ Variables transformées (unités)

taille	=>	taille2
taille en m		taille en cm
1.534		153.4

```
gen taille2=taille*100  
label taille2 «Taille en cm»
```

agejour	=>	agemois
âge en jours		âge en mois décimaux
567		18.62

```
gen agemois=agejour/30.4375  
label agemois «Age en mois»
```

Vérifier les recodages (e.g. describe taille taille2)

41

## Gestion de données

### ■ Variables transformées (recodages)

- qualitatif => qualitatif

Statmat : type numérique valeurs (1,2,3,4,5)  
(célibataire, marié, veuf, divorcé, autre)

=> statmat3 : type numérique valeurs (1,2,3)  
(célibataire, marié, autre)

```
define statmat3 #  
recode statmat to statmat3 1=1 2=2 3,4,5=3  
label statmat3 «Statut matrimonial en 3 classes»  
(possible aussi d'attribuer des « labelsvalues » (exercices))
```

- Vérifier le recodage (tables statmat statmat3)
- Mettre à jour le dictionnaire de variables

42

## Gestion de données

### ■ Variables transformées (recodages)

- qualitatif => qualitatif dichotomique

Statmat : type numérique valeurs (1,2,3,4,5)  
(célibataire, marié, veuf, divorcé, autre)  
=> marie : type numérique valeurs (1,0)  
(marié, autre)

```
define marie #  
recode statmat to marie (2=1) (1,3,4,5=0)  
ou  
select statmat<>. (sinon les manquants sont recodés en 0)  
gen i marie=(statmat=2)  
select  
label marie «Statut matrimonial en 2 classes : marié ou non»
```

- Vérifier le recodage ( e.g. freq statmat marie )
- Mettre à jour le dictionnaire de variables

43

## Gestion de données

### ■ Variables transformées (recodages)

- Quantitatif => qualitatif
- age (âge en années) : type numérique valeurs 18 à 79  
=> catage3 : type numérique 1: 18 à 24, 2: 25 à 39, 3: 40 et +

```
define catage3 #  
recode age to catage3 lo-24.999=1 25-39.999=2 40-hi=3  
label catage3 «Age en 3 classes»
```

- Vérifier recodage (min et max de age par catégorie de catage3)
- ```
means age catage3  
ou bien  
sort age  
browse age catage3
```

- Mettre à jour le dictionnaire de variables

44

## Gestion de données

### ■ Variables transformées (recodages)

- Variable qualitative => indicatrices

Statmat : type numérique valeurs (1,2,3,4,5) (célibataire, marié, veuf, divorcé, autre)

=> 5 indicatrices : type numérique valeurs (1,0)

| idadu     | statmat | mat1 | mat2 | mat3 | mat4 | mat5 |
|-----------|---------|------|------|------|------|------|
| 100010203 | 3       | 0    | 0    | 1    | 0    | 0    |
| 100010206 | 1       | 1    | 0    | 0    | 0    | 0    |
| 100020702 | 1       | 1    | 0    | 0    | 0    | 0    |
| 100020703 | 4       | 0    | 0    | 0    | 1    | 0    |
| 100020704 | 2       | 0    | 1    | 0    | 0    | 0    |
| 100031706 | 5       | 0    | 0    | 0    | 0    | 1    |
| 100031803 | 5       | 0    | 0    | 0    | 0    | 1    |

45

## Gestion de données

### ■ Variables transformées (recodages)

- Variable qualitative => indicatrices

`select statmat<>`. (sinon les manquants sont recodés en 0)

`gen i mat1=(statmat=1)` (si statmat=1 mat1=1 et 0 sinon)

`gen i mat2=(statmat=2)` (si statmat=2 mat2=1 et 0 sinon)

`gen i mat3=(statmat=3)` (si statmat=3 mat3=1 et 0 sinon)

`gen i mat4=(statmat=4)` (si statmat=4 mat4=1 et 0 sinon)

`gen i mat5=(statmat=5)` (si statmat=5 mat5=1 et 0 sinon)

`select`

Vérifier les nouvelles variables

`freq statmat`

`freq mat1 mat2 mat3 mat4 mat5`

(freq de mat1=1 : fréquence de modalité 1 de statmat, etc..)

- Utile pour codage des variables qualitatives dans les modèles

e.g. `regress imc mat1 mat2 mat3 mat4` (à voir + tard...)

46

## Gestion de données

### ■ Calcul nouvelles variables (indices, scores)

- Calcul âge :  
à partir de datenq, datnai : type date

```
gen agean= (datenq - datnai)/365.25  
label agean «Age en années»  
describe agean
```

- Calcul IMC (indice)  
à partir de poids (poids en kg), taille (taille en m)

```
gen imc= poids / (taille^2)  
label imc «Indice de masse corporelle en kg/m2»  
describe imc
```

- Exemple : recodage IMC  $\geq 30$ kg/m<sup>2</sup> (obésité)

```
select imc<>.  
generate obese=(imc>=30)  
select  
label obese «Personne obèse (1:oui, 0:non) »  
means imc obese
```

- Vérifier les nouvelles variables - Mettre à jour le dictionnaire de variables

47

## Gestion de données

### ■ Calcul nouvelles variables (indices, scores)

- e.g. score de biens possédés par le ménage  
à partir de frigo, malav, cuisu, tv, voitu, para, ordi, intern  
toutes de type #, 1:oui 0:non

```
gen i nbiens=frigo+malav+ cuisu + tv+ voitu+para+ordi+intern  
=> nbiens : domaine (valeurs) de 0 à 8
```

Remarque : possible pondérer (valeur monétaire, autre ...)

```
gen i val_biens=400*frigo+500*malav+ 250*cuisu +250* tv  
+ 5000*voitu+300*para+1000*ordi+250*intern
```

- Examen distribution :

```
freq nbiens /m  
bar nbiens
```

Recodage e.g. 3 catégories (voir signification en fonction répartition)

```
define nbiensc3 #  
recode nbiens to nbiensc3 0,1,2=1 3,4,5=2 6,7,8=3  
freq nbiens nbiensc3
```

- Vérifier les nouvelles variables - Mettre à jour le dictionnaire de variables

48

# Gestion de données

- Variables transformées (recodages)
- Variables calculées (indices, scores)
- Rajouter variables dans nouvelle(s) table(s)

```
read "table_entree.rec" /close
  calculs nouvelle(s) variable(s)
  recodages ...
  labels ...
savedata "table_sortie.rec" /replace
```

Mettre à jour le dictionnaire de variables

49

# Gestion de données

1- Accès aux données

2- Gestion des données

3- Analyse des données

4- Présentation des données

- Conservation
  - sécurité
  - sauvegardes
- Préparation avant analyse
  - sélections (individus, variables)
  - mise en relation, fusion de fichiers
  - calcul de nouvelles variables
  - recodages
  - documentation (versions fichiers, dictionnaires)
- Outil logiciel
  - SGBD (e.g. MS- Access, Oracle, ...)
  - gestion de données dans logiciels statistiques (SAS, Stata, SPSS) ou généralistes (EpiData)
- Data manager ⇔ spécialiste discipline

50

# Gestion de données

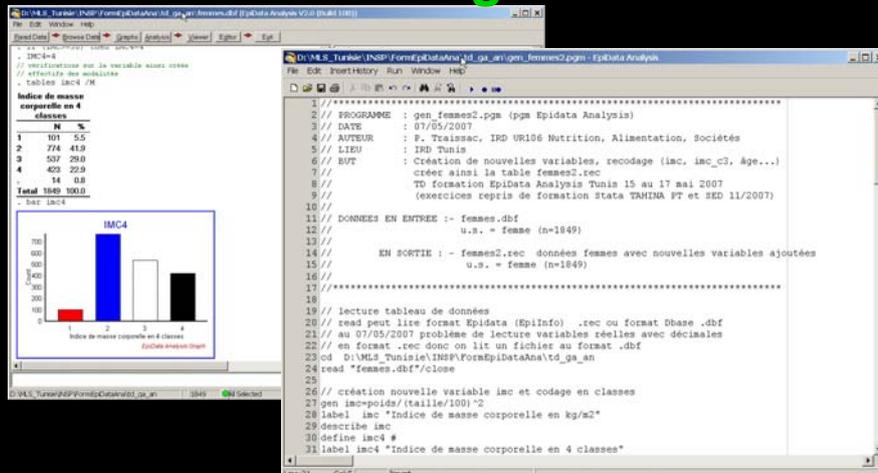
Qualité ↔ Traçabilité ↔ Documentation

- Documenter les opérations sur les fichiers (fusions, création de variables)
- Mise à jour des dictionnaires de variables
- **Programmation vs. mode interactif**
- Entêtes / commentaires dans les programmes (// )

51

## Traçabilité : gestion et analyse

Programmes : oui !



52

## Traçabilité : gestion et analyse

### ▪ Entête des programmes (e.g. Epidata Analysis)

```
*****  
// Nom du programme : gen_femmes2.pgm  
// Type de programme : Epidata Analysis  
// Auteur : PT, IRD, UR 106 Nutrition, Alimentation, Sociétés  
// Date : 08/05/2007  
// Lieu : IRD, Montpellier – IRD, Tunis  
// But : Calculs et recodages données femmes en préalable à analyse  
// facteurs de risque de l'obésité  
//  
// Données en entrée :  
// femmes.rec (u.s. : femme adulte, n=1849)  
//  
// Données en sortie : femmes2.rec (n=1763)  
//  
// Remarques diverses : pgm repris de exercices Stata SED et PT  
*****  
À partir d'ici les instructions de programmation proprement dites
```

53

## Traçabilité : gestion et analyse

### ▪ Commentaires dans les programmes

```
read "femmes.rec " /close  
// création nouvelle variable imc  
gen imc=poids/(taille/100)^2  
label imc "Indice de masse corporelle en kg/m2 "  
// imc en 4 classes (bornes OMS : maigre, surpoids, obésité)  
define imc4 #  
label imc4 "Indice de masse corporelle en 4 classes"  
// à ce stade elle n'a que des valeurs manquantes  
recode imc to imc4 lo-18.4999=1 18.50-24.9999=2 25.0-29.9999=3 30-hi=4  
// on peut assigner des labels aux codes ainsi créés  
labelvalue imc4 /1="maigre" /2="normal" /3="surpoids" /4="obèse"  
// codage obésité  
define obese #  
recode imc to obese lo-29.999=0 30-hi=1  
  
// sauvegarde nouvelles variables dans table femmes2  
savedata "femmes2.rec" /replace
```

54

# Gestion de données

## Exercices pratiques gestion de données (2)

- création de nouvelles variables, indices
- recodages
- sauvegarde des nouvelles variables
- écriture de programmes EpiData Analysis
- mise à jour dictionnaire de variables

