



Projet Obe Maghreb

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

Gestion et analyse de données d'enquêtes épidémiologiques

Accès aux données (saisie)

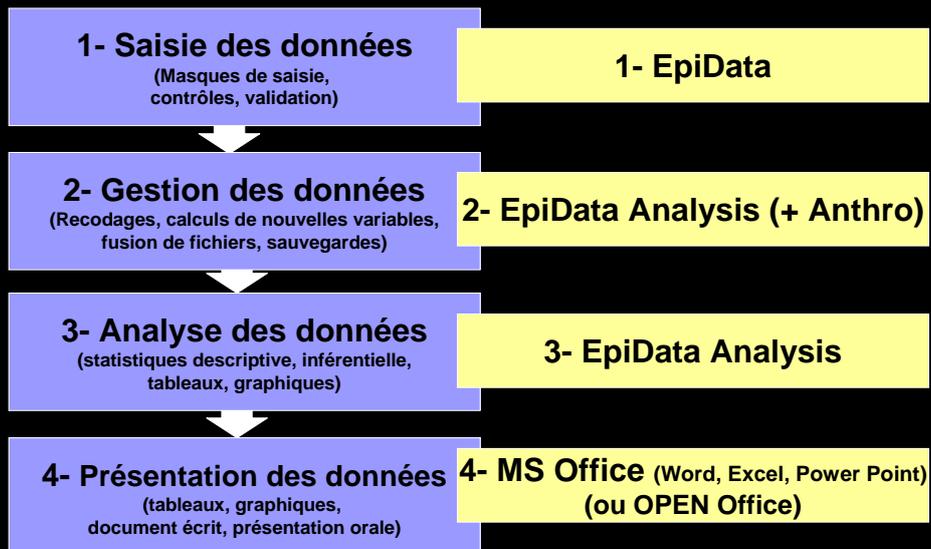


Agnès Gartner, Pierre Traissac
UMR 204 « Prévention des malnutritions et pathologies associées »
IRD, Montpellier, France



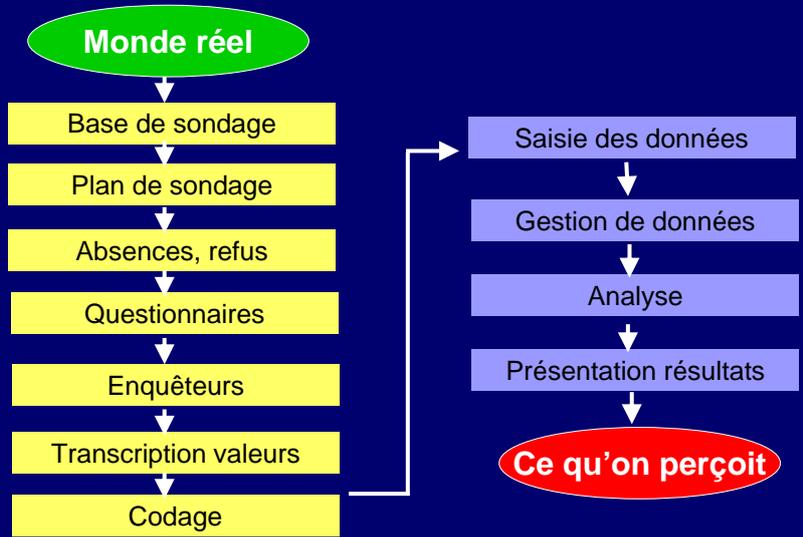
1

Pourquoi EpiData



2

Des données à l'information

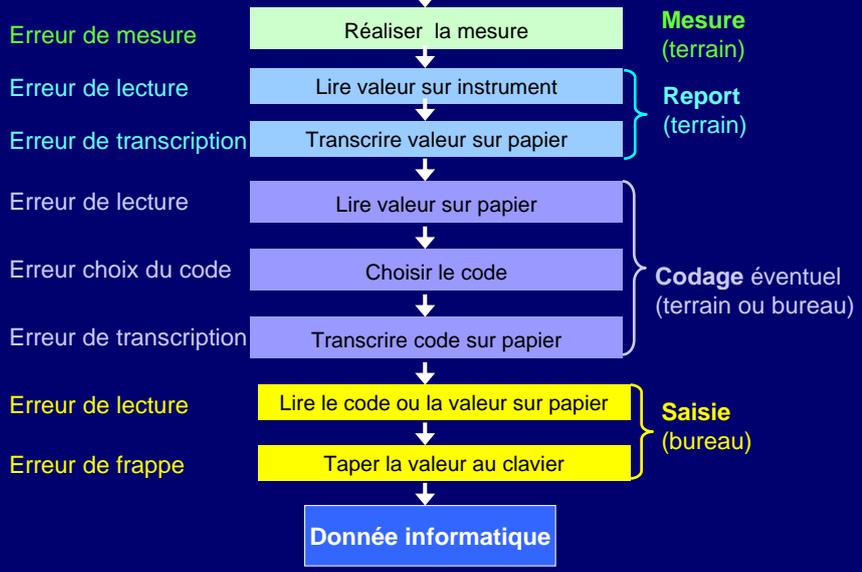


3

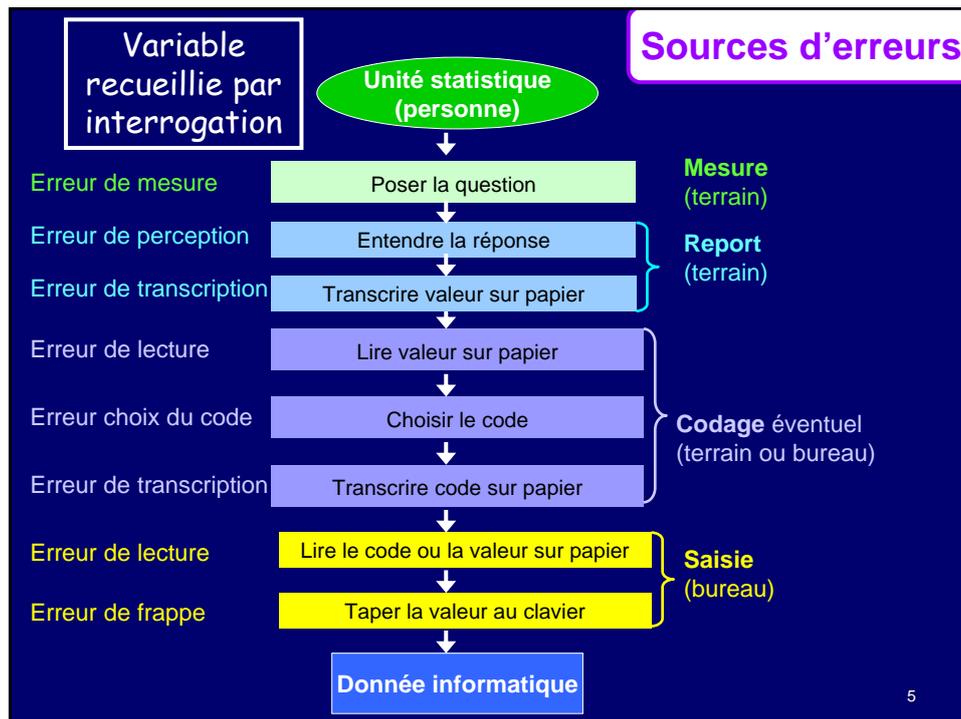
Variable mesurée

Unité statistique (personne)

Sources d'erreurs



4



Saisie des données

➤ **Acquisition des données**

- saisie = lecture du questionnaire & frappe au clavier

➤ **Disposer données sur support informatique**

- fidèles à celles recueillies sur terrain
- cohérentes
- **documentées** (dictionnaire de variables) !!!

➤ **Recherche et correction d'erreurs**



6

Détection et correction d'erreurs

➤ Erreurs liées à la mesure

- réalisation mesure, lecture et transcription
 - formation enquêteurs
- supervision
 - vérification des questionnaires « le plus près possible » du terrain

➤ Erreurs liées au codage

- lecture, choix du code, transcription
 - formation codeurs, guide de codage

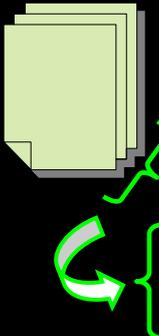
➤ Erreurs de saisie

- Erreur de lecture, erreur d'entrée (frappe clavier, choix dans un menu)
 - Ergonomie du questionnaire papier, du masque de saisie
- Formation opérateurs de saisie

Détection et correction d'erreurs

7

x questionnaires → x lignes



	IDFEM	IDMEN	DATENQ	MILIEU	POIDS	TAILLE	GLYCEMIE
1	1107011	110701	13/10/1996	1	94.7000	157	5.0000
2	1107021	110702	13/10/1996	1	83.3000	150	5.2000
3	1107022	110702	13/10/1996	1	87.2000	156	4.8000
4	1107031	110703	13/10/1996	1	59.0000	154	.
5	1107041	110704	13/10/1996	1	92.0000	157	.
6	1107042	110704	13/10/1996	1	48.0000	165	.
7	1107051	110705	13/10/1996	1	83.0000	161	.
8	1108081	110808	13/10/1996	1	43.3000	154	4.2000
9	1110071	111007	13/10/1996	1	74.4000	152	4.8000
10	1110081	111008	13/10/1996	1	59.4000	145	5.1000
11	1110082	111008	13/10/1996	1	45.7000	150	3.9000
12	1110083	111008	13/10/1996	1	70.4000	152	5.2000

Saisie des données

- Intégrité d'entité (! identifiants principaux)
- Intégrité de référence (! identifiants secondaires)
- Intégrité de domaine (valeurs de chaque variable)
- Cohérence (2 variables ou plus)
- Autres erreurs (erreurs du 5^{ème} type 😊 ...)

9

identifiants

- Intégrité d'entité (! identifiants principaux)
- Intégrité de référence (! identifiants secondaires)

saisis ou programmés

ménages

	IDMEN	DATENQ	REGION	HABITAT	ECO1	DEPENSES
1	110701	13/10/1996	1	1	74.6000	150
2	110702	13/10/1996	1	1	65.5400	150
3	110703	13/10/1996	1	1	67.2600	200

femmes

	IDFEM	IDMEN	DATENQ	MILIEU	POIDS	TAILLE	GLYCEMIE
1	1107011	110701	13/10/1996	1	94.7000	157	5.0000
2	1107021	110702	13/10/1996	1	83.3000	150	5.2000
3	1107022	110702	13/10/1996	1	87.2000	156	4.8000

domaine

➤ Intégrité de domaine (valeurs de chaque variable)

	IDFEM	IDMEN	DATENQ	MILIEU	POIDS	TAILLE	GLYCEMIE
1	1107011	110701	13/10/1996	1	94.7000	157	5.0000
2	1107021	110702	13/10/1996	1	83.3000	150	5.2000
3	1107022	110702	13/10/1996	1	87.2000	156	4.8000

1107011 à 8324061
et UNIQUE

13/01/1996 à 28/12/1997

135 à 185
taille=129 ?

Cohérence des questions

(5)	Sexe du CM	Homme.....	1	—
		Femme.....	2	
(6)	Age du CM	Noter l'âge du chef de ménage en année (Si possible vérifiez sur la carte d'identité)		— —
(7)	Ethnie du chef de ménage	Wolof.....01	Diola.....06	— —
		Lébou.....02	Mandingue.....07	
		Peuhl.....03	Socé/Sarakholé/Soninké..08	
		Toucouleur.....04	Mandjaque.....09	
		Séser.....05	Autre ethnie.....10	
(8)	Sait-il/elle lire ou écrire une phrase dans une langue quelconque ?	Oui.....	1	— —
		Non.....	2	
(9)	Quel niveau scolaire a t-il/elle atteint ?	Pas d'école.....0	Brevet diplôme.....4	—
		Ecole Coranique.....1	Bac diplôme.....5	
			Supérieur.....6	
(10)	Quelle a été la principale activité au cours des 12 derniers mois ?	Travailleur non agricole.....08		— —
		Travailleur agricole.....09		
		Industriel.....10		
		Commerçant.....11		
		Artisan.....12		
		Professionnel.....13		
(11)	État matrimonial du chef de ménage	Marié(e).....1	Veuf(ve).....3	—
		Célibataire.....2	Divorcé(e).....4	
(12)	Si le chef de ménage est un homme	Nombre d'épouses.....	7	—
		Si femme chef de ménage.....	7	

Recherche sur papier
ou en informatique

Détection et correction d'erreurs

- **Détection & correction d'erreurs pendant la saisie :**
contrôles d'entrée
- **Détection & correction d'erreurs après la saisie :**
**validation (double saisie)
apurement**

13

Saisie des données

- **Documenter la saisie**
 - incidents, problèmes pendant la saisie
 - dictionnaire de variables
 - version des fichiers
 - **corrections** (par programmation et non mode interactif)
- **!!! Sauvegarde des fichiers !!!**

14

Logiciel de saisie « data entry »

➤ Fonctionnalités spécifiques

- création « masques de saisie »
- contrôles d'entrée
- validation (double saisie)
- documentation (programmes, codages, ...)

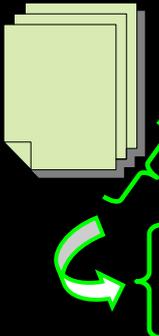
➤ Saisie directe interfaces genre tableur (Excel, autres) ou « feuilles de données » logiciel statistique :

NON, NON et NON !!!

(sauf très petit ensemble de données)

15

x questionnaires → x lignes
n variables → n colonnes



	IDFEM	IDMEN	DATENQ	MILIEU	POIDS	TAILLE	GLYCEMIE
1	1107011	110701	13/10/1996	1	94.7000	157	5.0000
2	1107021	110702	13/10/1996	1	83.3000	150	5.2000
3	1107022	110702	13/10/1996	1	87.2000	156	4.8000
4	1107031	110703	13/10/1996	1	59.0000	154	
5	1107041	110704	13/10/1996	1	92.0000	157	
6	1107042	110704	13/10/1996	1	48.0000	165	

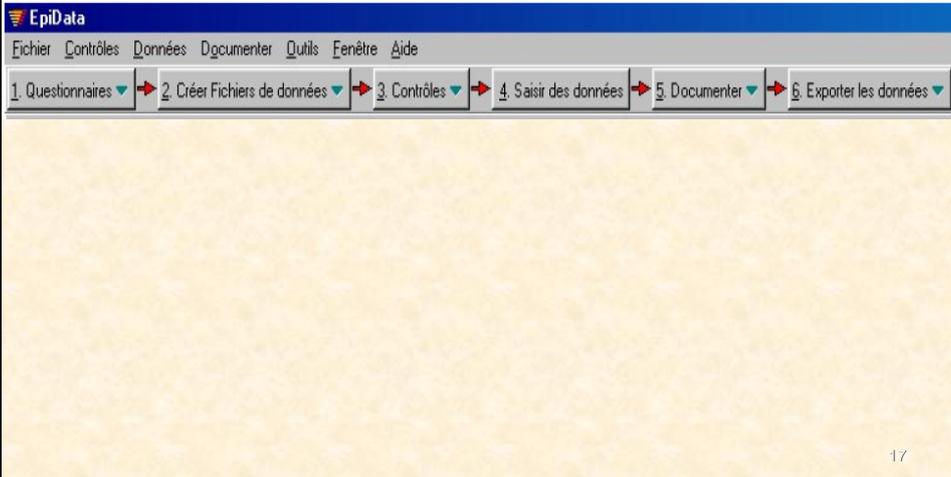
saisie de données avec



EpiData

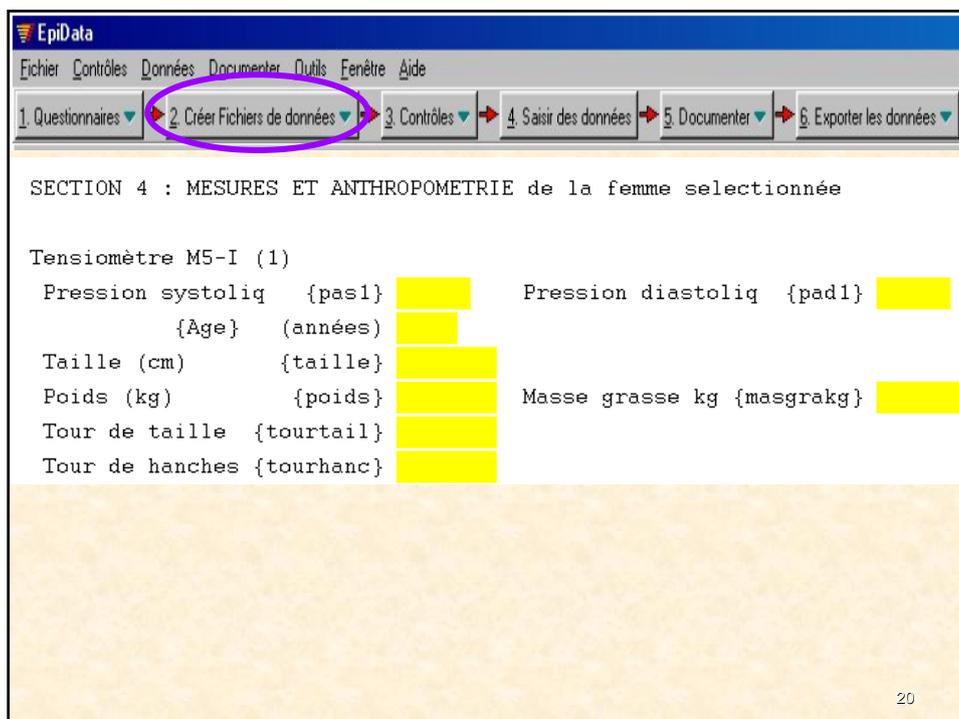
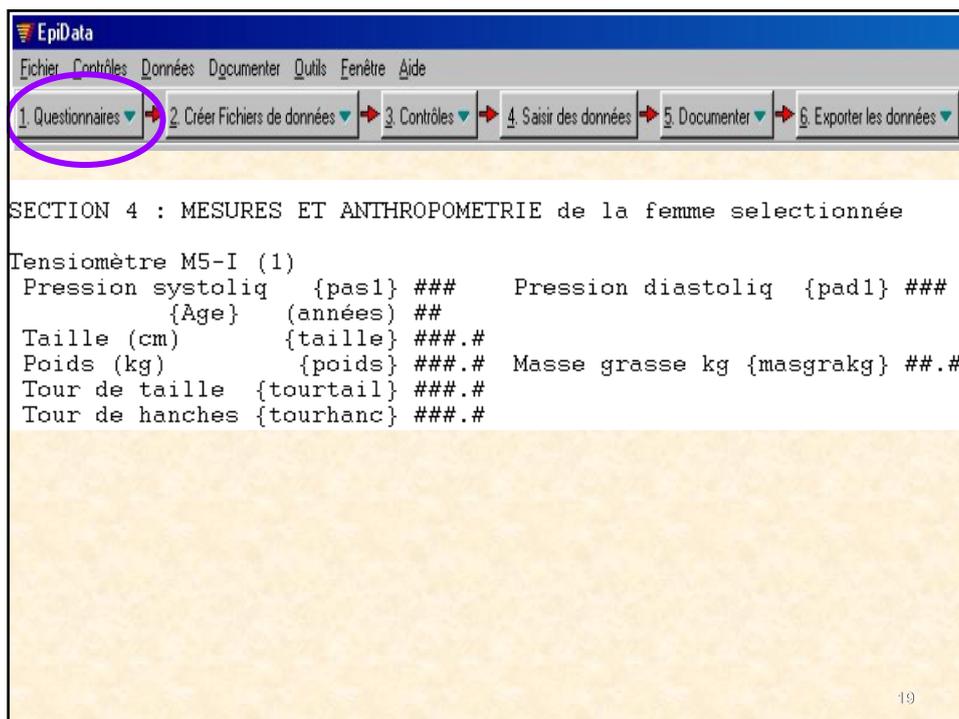


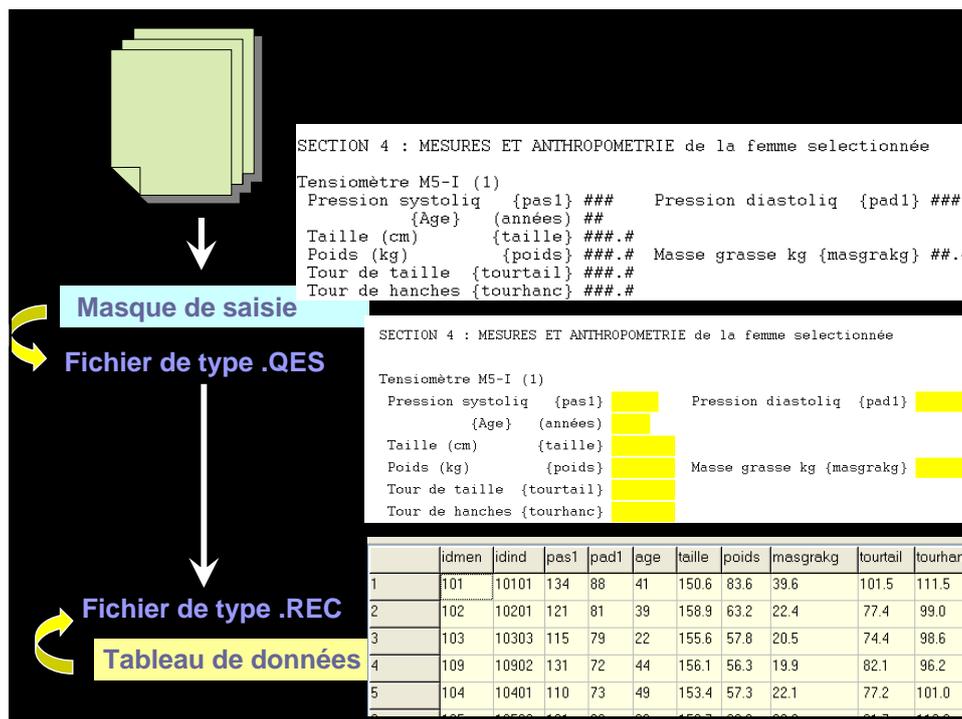
EpiData



SECTION 4 : MESURES et ANTHROPOMETRIE de la femme sélectionnée

<i>Tensiomètre M5-I (1^{ère} mesure)</i>	
Pression systolique _ _ _	Pression diastolique _ _ _
Age (années) _ _	
Taille (cm) _ _ _ , _	
Poids (kg) _ _ _ , _	Masse grasse (kg) _ _ , _
Tour de taille (cm) _ _ _ , _	
Tour de hanches (cm) _ _ _ , _	





Principes et règles de base

- **“Dessiner” l’outil**
à travers lequel les données seront saisies
- **Créer la liste des variables**
(colonnes du tableau de données)
- **Pour chaque variable**
 - Choisir un nom
 - Définir le type
 - Définir le format
- **Soigner la présentation**
 - Présentation fidèle à celle du questionnaire papier
➡ facilite le travail de saisie
 - Commentaires pour clarifier le questionnaire

Noms des variables

- **Règles à retenir**
 - Pas plus de 8 caractères
 - Chiffres autorisés mais pas en 1er caractère
 - Pas de caractères spéciaux (* ; _ , % . & : etc.)
 - Éviter caractères accentués
- **Plusieurs façons de les créer**
 - Le premier mot de la question
 - Les 8 premiers caractères
 - Les caractères entre { } (y compris si plusieurs sur la même ligne) :
conseillé

23

Types et format des variables

- **Alphanumérique (caractère)**
 - Standard : _____ (autant de traits que de caractères possibles)
 - Majuscules : <A > (toutes entrées transformées en majuscules)
- **Numérique**
 - Entiers simples : ### (autant de # que de chiffres voulus)
 - Avec décimales : ##.###
- **Date**
 - Européennes : <dd/mm/yyyy>
 - Anglosaxonnes : <mm/dd/yyyy>
- **Autres**
 - Dichotomiques : <Y> (n'accepte que 'Y' ou 'N', ou '1' ou '0')
 - Numéros séquentiels : <idnum>
 - Date du jour : <today-dmy>
 - Cryptées : <S >

24

Types et format des variables

Assistant champs

Numérique | Texte | Date | Autre

Entiers: 1

Décimales: 0

Champ à insérer: #

Longueur du champ: 1

Insérer

Assistant champs

Numérique | Texte | Date | Autre

Date

<dd/mm/yyyy>

<mm/dd/yyyy>

<yyyy/mm/dd>

Dates automatiques

<Today-dmy>

<Today-mdy>

<Today-ymd>

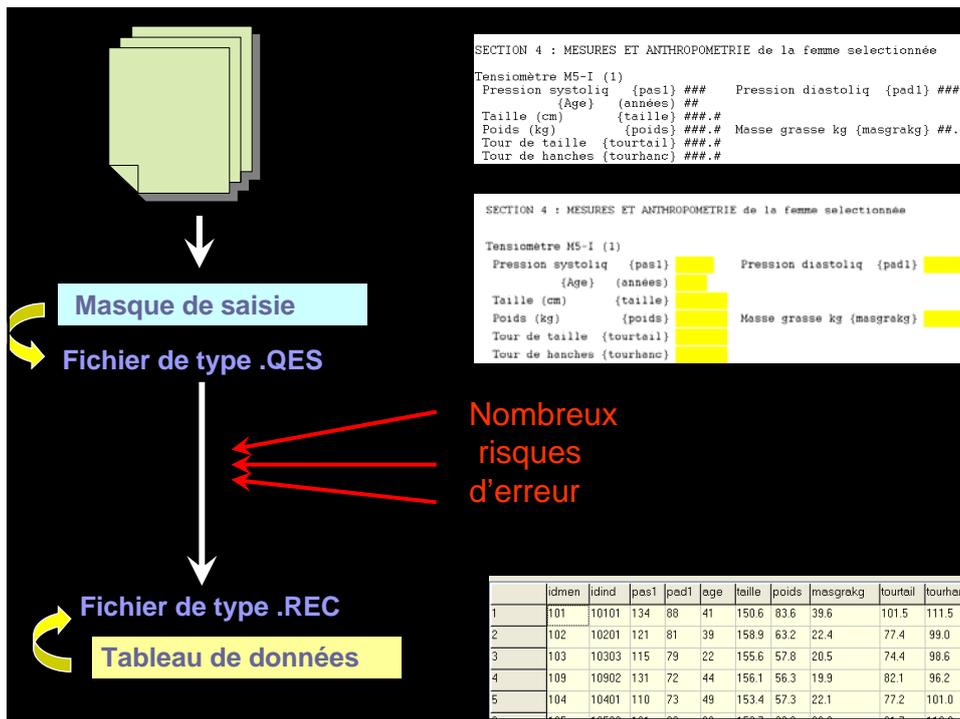
Insérer

25

Pièges à éviter

- **Mélanger plusieurs u.s. dans un même fichier**
exemple :
 - le ménage et la personne
 - la personne et ses 'n' hospitalisations
- **Identifiants non uniques, voire manquants !**
- **Oublier les identifiant(s) de niveau supérieur !!**
nécessaires à la mise en relation hiérarchique des fichiers
(très classique : « *quel est le ménage de cette personne ??* »)

26



Détection et correction d'erreurs

- **Détection & correction d'erreurs pendant la saisie :**
contrôles d'entrée
- **Détection & correction d'erreurs après la saisie :**
validation (double saisie) purement

Contrôle de la saisie

- **But** : limiter au maximum les **erreurs de saisie**, tout en facilitant et simplifiant le travail de saisie
- **Création d'un fichier de contrôle** (extension .CHK) dans lequel sont spécifiées **toutes les opérations** à faire :
- **De la plus simple...**
 - Définir les valeurs autorisées pour chaque variable
 - **Rendre la saisie obligatoire dans un champ donné**
 - Remplir automatiquement certains champs
 - **S'assurer de l'unicité des valeurs des identifiants**
 - Déplacement conditionnel du curseur (sauts)
- **A la plus compliquée !**
 - Attribuer et faire apparaître des « labels »
 - **Utilisation de boîtes de dialogue**
 - Faire des calculs cumulatifs
 - **Vérifications sur plusieurs fichiers liés etc.**

29

Contrôle de la saisie

▪ Principes généraux

- Le fichier de contrôle (.CHK) doit porter le même nom que le fichier des données (.REC)
- L'écriture du fichier de contrôle peut se faire :
 - **de façon assistée (boîte de dialogue, pour contrôles simples)**
 - en éditant le fichier (contrôles plus complexes, syntaxe)
- Principes (conseils...)
 - **Adapter la complexité des contrôles au type de questionnaire, au niveau des opérateurs de saisie... et à son propre niveau !**
 - Commencer par les contrôles simples en utilisant l'assistant, puis éditer le fichier pour les opérations plus complexes
 - **Tester les opérations complexes au fur et à mesure**

30

Contrôle de la saisie

▪ L'assistant

DATENQ	
Date de l'enquête Date (dmy)	
Range, Legal	01/01/2002-
Jumps	
Must enter	Yes
Repeat	No
Value label	

Sauver Editer
Quitter

Nom de variable + description

Valeurs autorisées: continues (Range) ou non (Legal)

Sauts conditionnels

Champ à entrée obligatoire

Champ à valeur répétée (d'un enregistrement à l'autre)

Attribution de labels: prédéfinis ou création

Pour modifier ou compléter les contrôles (par ex KEY UNIQUE)

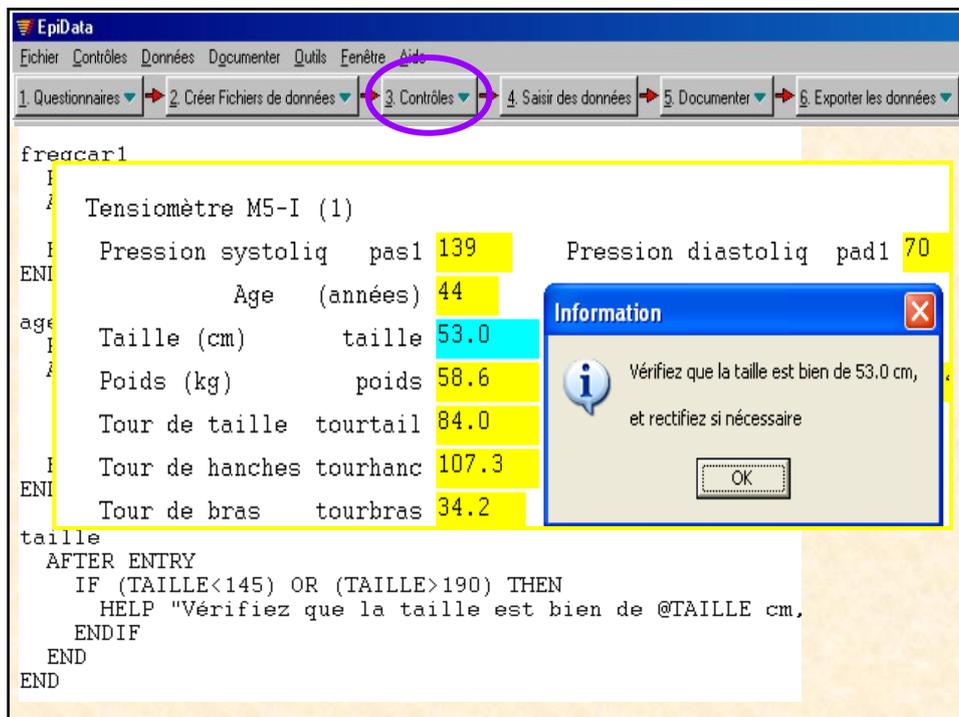
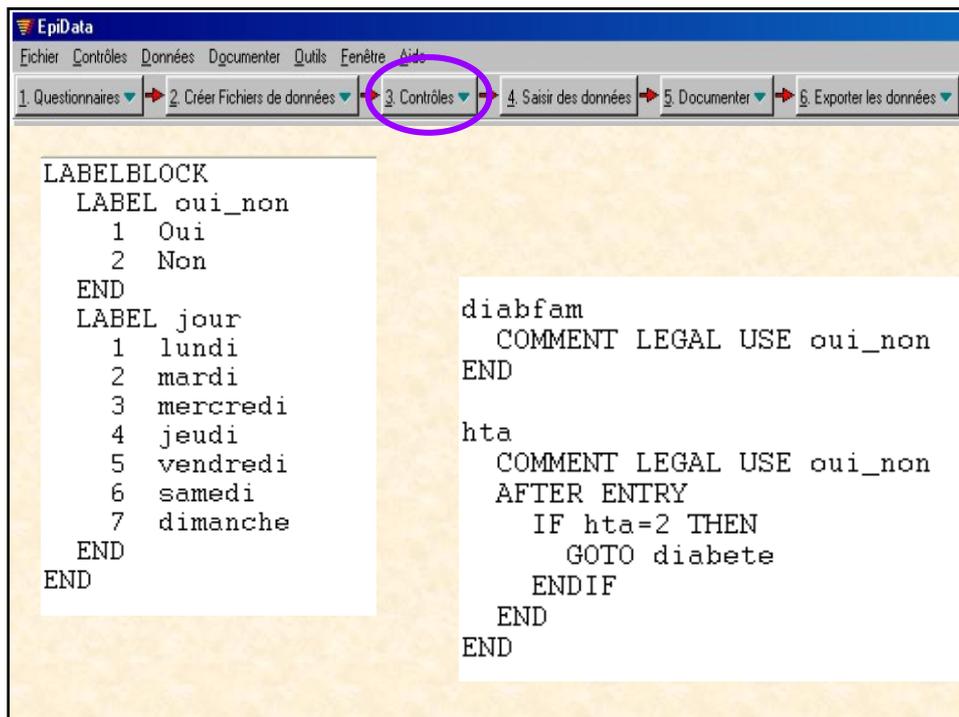
31

Contrôle de la saisie

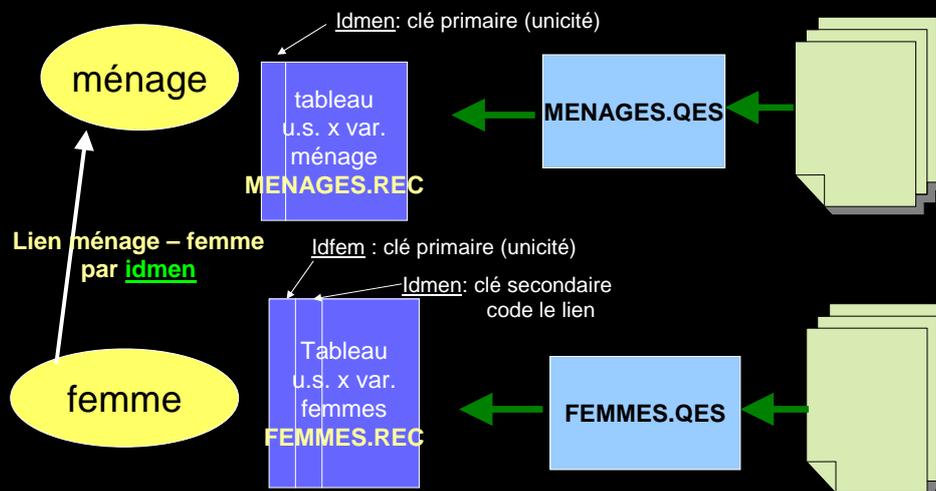
▪ Structure

- La structure du fichier de contrôle comporte une succession de « blocs de commandes », tous terminés par le mot clef **END**
- Les blocs de commande peuvent commencer par:
 - Un **NOM DE VARIABLE**: les opérations concernent la variable, ou en tout cas seront effectuées lors de la saisie lorsque le curseur se trouvera dans le champ correspondant
 - **BEFORE** (ou **AFTER**) **FILE** (ou **RECORD**, ou **ENTRY**): les opérations seront effectuées au début (ou à la fin) de la saisie d'un fichier (ou d'un enregistrement, ou d'un champ)
 - **LABEL** (ou **LABELBLOCK**): pour préciser les listes de codes
- Il n'est pas possible d'écrire des instructions entre deux blocs de commande; mais un bloc peut être inclus dans un autre bloc

32



Modèle de données



35

Modèle de données

- Identifiant ménage
 - grappe,
 - numéro de ménage dans la grappe
exemple idmen = 215
- Identifiant femme
 - grappe,
 - numéro de ménage dans la grappe,
 - numéro de femme dans le ménage
exemple idfem = 21503
- Prévoir les champs dans le masque

36

EpiData 3.1 - [menage_sale.chk]

Fichier Editer Fichier de données Documenter Outils Fenêtre Ai

1. Questionnaires 2. Fichiers de données 3. Contrôles

```

grappe
  RANGE 19 50
  MUSTENTER
END

codemen
  RANGE 1 30
  MUSTENTER
  AFTER ENTRY
  IDMEN=GRAPPE*100+CODEMEN
  END
END

idmen
  KEY UNIQUE 1
  NOENTER
END

< ... dernière variable de la fiche ménage
  RANGE 1 9
  AFTER ENTRY
  ** À PRÉCISER
  RELATE idmen femme_sale.rec 1
  RELATE idmen adolescent_sale.rec
  END
END

```

EpiData 3.1 - [femme_sale.chk]

Fichier Editer Fichier de données Document

1. Questionnaires 2. Fichiers de données

```

idmen
  KEY 1
  END

codeind
  MUSTENTER
  AFTER ENTRY
  IDIND=IDMEN*100+CODEIND
  END

idind
  KEY UNIQUE 2
  NOENTER
  END

```

Calculs de clés primaires :

- $2 \times 100 + 15 = 200 + 15 = 215$
- $215 \times 100 + 03 = 21500 + 03 = 21503$

EpiData 3.1 - [menage_sale.rec]

Fichier Aller à Filtre Fenêtre Aide

Obe Maghreb Maroc

Numero de saisie

Enquete "Double Charge" au Maroc 2009

SECTION 0 : IDENTIFICATION DU MENAGE

province 441

commune

UPDC 4 UPN 150 USN 6 Strate Grappe 19

Code ménage codemen 1

Identifiant ménage (automatique) idmen 1901

EpiData 3.1 - [femme_sale.rec]

Fichier Aller à Filtre Fenêtre Aide

Identifiant ménage idmen 1901

SECTION 3 : FEMME DE 20-49 ANS SELECTIONNÉE

Date de l'enquête dateng 06/10/2009

Equipe d'enquete equipeng 1

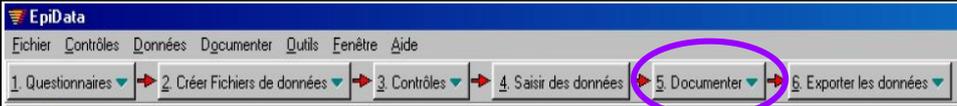
Code individu codeind 1

Identifiant individu (automatique) idind 190101

Détection et correction d'erreurs

- **Détection & correction d'erreurs pendant la saisie :**
contrôles d'entrée
- **Détection & correction d'erreurs après la saisie :**
validation (double saisie)
apurement

39



The screenshot shows the EpiData software interface. The menu bar includes 'Fichier', 'Contrôles', 'Données', 'Documenter', 'Outils', 'Fenêtre', and 'Aide'. The 'Documenter' menu item is circled in purple. Below the screenshot, the word 'Validation' is written in purple and enclosed in a purple rounded rectangle.

Validation

- Double saisie
- Comparaison des 2 fichiers .rec
- Quand différence, vérifier dans le questionnaire
- Correction
- re-validationetc...

40

VALIDATE DUPLICATE DATA FILES REPORT	

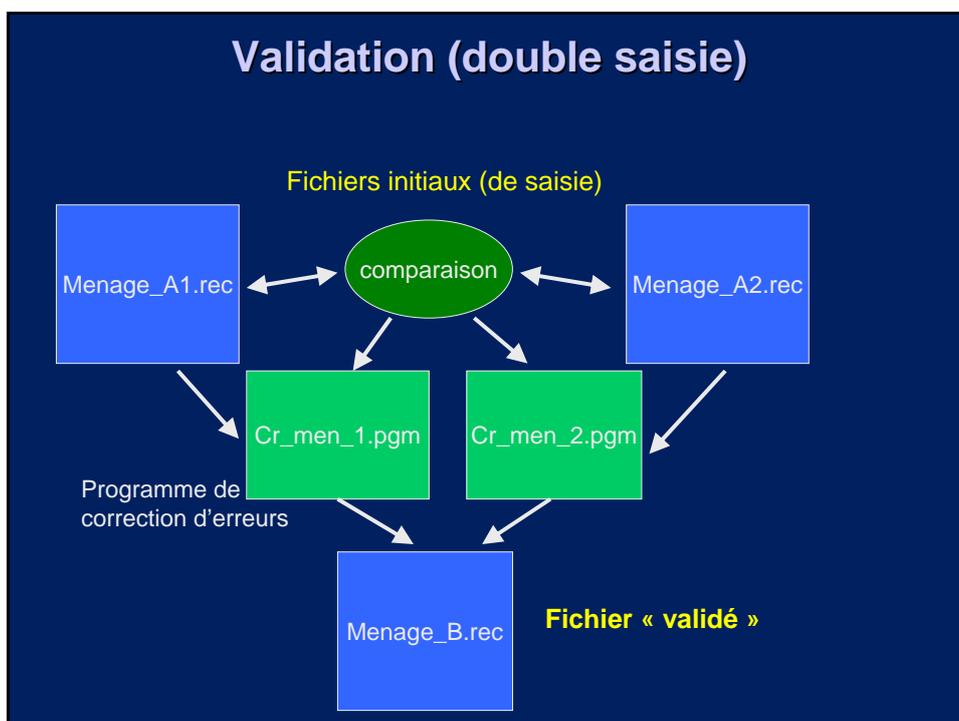
Data file 1: D:\femme.rec Records total:358	

Data file 2: D:\femme_ds.rec Records total:357	

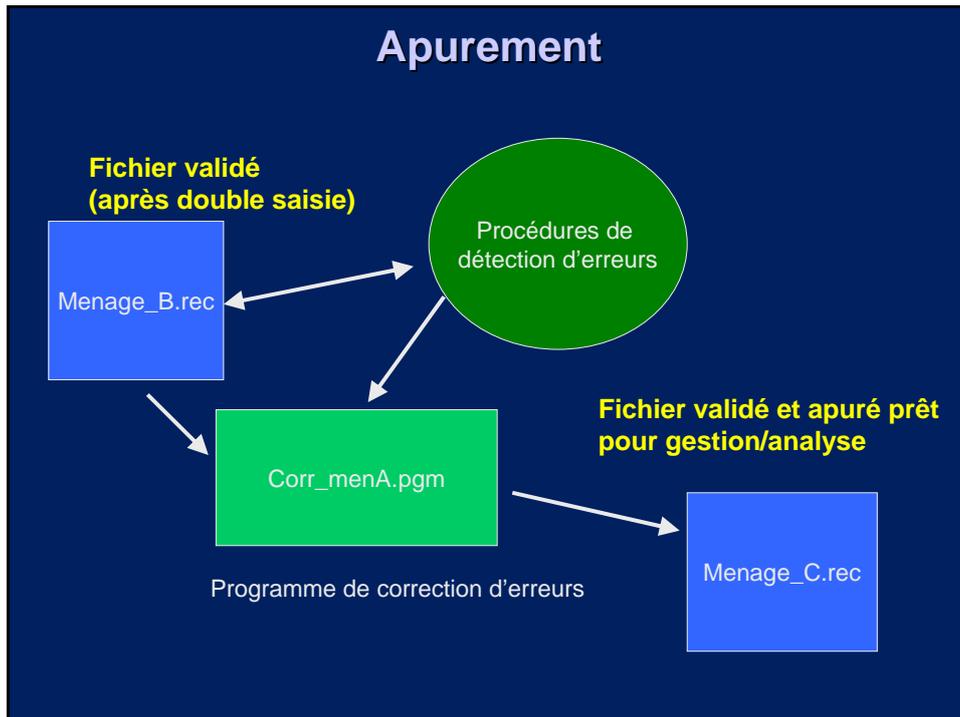
Fields used as <u>index keys</u> : IDIND	

RESULTS OF VALIDATION:	
Records missing in data file 1: 2	
Records missing in data file 2: 3	

DATA FILE 1	DATA FILE 2
Record key field(s): (Rec. # 6)	Record # 6
idind = 10502	
tourtail = 91.7	tourtail = 71.7
-----	-----
Record key field(s): (Rec. # 7)	Record # 7
idind = 10601	
poids = 69.5	poids = 59.5
-----	-----
Record key field(s): (Rec. # 9)	
idind = 10801	
Record not found in data file 2	Record not found
-----	-----
Record key field(s): (Rec. # 13)	Record # 13



Apurement



Contrôle et correction d'erreurs

