

Manuel d'utilisation

STATA
Version 7.0

Valérie LAUWERS-CANCES
Pascale GROSCLAUDE
Mélanie WHITE-KONING

..... Septembre 2002

Notions générales	4
Les 4 fenêtres de Stata	5
Les boutons	6
Quelques notions d'écriture des commandes	8
By var1 var2 : commande	9
If exp	9
In range	9
Quelques notions concernant les variables	7
Format d'enregistrement: %#. # format	7
Les variables qualitatives : string variables %s	7
Les variables quantitatives : real variables	7
Variables dates %d	8
Données manquantes	8
Gérer une base de données avec Stata	9
Use	10
Importer des données	10
Insheet	10
Infile	11
Commandes principales des bases de données	11
Clear : clear	11
Edit : edit	11
Save : save	12
List : list	12
Fusion de plusieurs fichiers Merge/Append	12
Merge	12
Append	13
Outils de description de la base de données	14
Codebook	14
Inspect	14
Describe	14
Création de nouvelles variables : Gen - Egen - Replace - Recode	15
Gen	15
Créer des variables qualitatives	16
Manipulations de chaînes de caractères plus complexes	16
Générer des variables dates	17
Générer une variable aléatoire	17
Egen	17
Quelle est la différence entre gen et egen ?	18
Replace	18
Recode	18
Suppression de variables ou d'enregistrements Drop - Keep	19
Drop	19
Keep	19
Recherche et manipulation de doublons	19
Identification des doublons	19
Comment enlever les doublons ?	20
Manipulation de fichiers	21
collapse	21
contract	22
fillin	22
Quelques statistiques descriptives élémentaires	24
Contrôle de la nature de la distribution	24
SUM	24
SKTEST	24
SWILK	25

LADDER	25
Tab	25
Commandes Graphiques	26
Gladder	26
Kdensity	27
Graph	27
histogramme	27
Options des histogrammes	28
Diagramme en barres	28
Diagrammes en secteurs	28
box-plot	29
nuages de points	29
Titre du graphique et des axes	31
options concernant les axes :	31
Positionnement de droites dans un graphique	31
Option Connect : relie les points entre eux	32
Option Symbol Spécifie la forme des points	32
Sauvegarde des graphiques	33
A partir de la barre de titre quand la fenêtre graphique est active	33
A partir de l'option saving	33
Sauvegarder plusieurs graphiques dans le même fichier	33
Introduction à l'analyse bivariée : quels tests faut-il choisir ?	34
Comparaison de variables qualitatives	34
Comparaison d'une variable quantitative et qualitative	34
Comparaison de 2 variables quantitatives	34
1 ^{ère} partie : séries indépendantes.....	35
1) à partir d'une base de données.....	35
2) Calcul direct sans base de données.....	37
2 ^{ème} partie : séries appariées.....	39
1) à partir d'une base de données.....	39
2) calcul direct sans base de données.....	39
Comparaison de moyennes	40
Par rapport à une moyenne théorique	40
Pour deux échantillons indépendants	40
Pour deux échantillons appariés	42
Calculs directs sans base de données	44
Test d'une moyenne observée à une moyenne théorique	44
Test de deux moyennes issues d'échantillons indépendants	44
Pour plus de deux échantillons indépendants : Analyse de variance	44
Comparaison de 2 variables quantitatives : Tests de corrélation	49
Coefficient de corrélation	50
Test non paramétrique de corrélation	51
Courbes ROC (Receiver Operating Characteristic)	52
Introduction à l'analyse multivariée	53
Quand la variable à expliquer est quantitative	54
Régression linéaire	54
Quand la variable à expliquer est dichotomique	57
Régression logistique	57

Notions générales sur Stata

Stata **est** un logiciel vous permettant d'organiser vos données, de les analyser et de les représenter graphiquement. Il se compose de deux répertoires principaux sur les disquettes d'installation

- Data : qui comprend les données que vous souhaitez analyser
- Stata : qui comprend les programmes permettant la gestion des fichiers et leur analyse

Un dossier complémentaire « ado » est créé après l'installation. Il comprend toutes les commandes utilisés par le logiciel. Les mises à jour et les nouvelles commandes que vous pouvez développer vous même doivent aussi aller là.

Les mises à jour sont disponibles sur internet en saisissant la commande

➤ Update from <http://www.stata.com> ↵

Principes généraux

Stata fonctionne sur différents systèmes d'exploitation en particulier MAC OS, PC Window, Unix, Linux.

Les fichiers sont totalement compatibles entre Mac et PC

Stata analyse des fichiers de données auxquels il donne une structure propre. Ces fichiers peuvent provenir de différents types de fichier :

texte ascii, formaté ou avec séparateur,
fichier excel

Après avoir été lus, ces fichiers prennent le format Stata et peuvent être enregistrés dans ce format à votre demande. Si vous cliquez sur un fichier de données au format stata le logiciel s'ouvrira directement avec la base de données que vous venez d'ouvrir. Sinon il faudra d'abord ouvrir le logiciel et lui indiquer le chemin à suivre pour aller chercher le fichier qui vous intéresse.

Stata **n'est pas** un logiciel fait pour saisir un grand nombre de données, il ne permet ni la création d'un masque de saisie ni les contrôles lors de la saisie.

L'analyse se fait en demandant au logiciel d'exécuter des commandes Pour écrire ces commandes on utilise des (macro) commandes programmées dans le logiciel que l'on appelle en écrivant leur nom abrégé. La commande peut être précisée grâce à des options.

Le texte des commandes doit respecter une syntaxe simple propre à Stata.

Il ne faut pas utiliser de majuscules dans les commandes. Pour Stata Majuscule et minuscule d'une même lettre sont deux caractères différents

L'analyse peut se faire soit en mode interactif, soit en mode batch.

En mode interactif, l'utilisateur tape une commande, attend la réponse de la machine, tape une nouvelle commande, etc ..

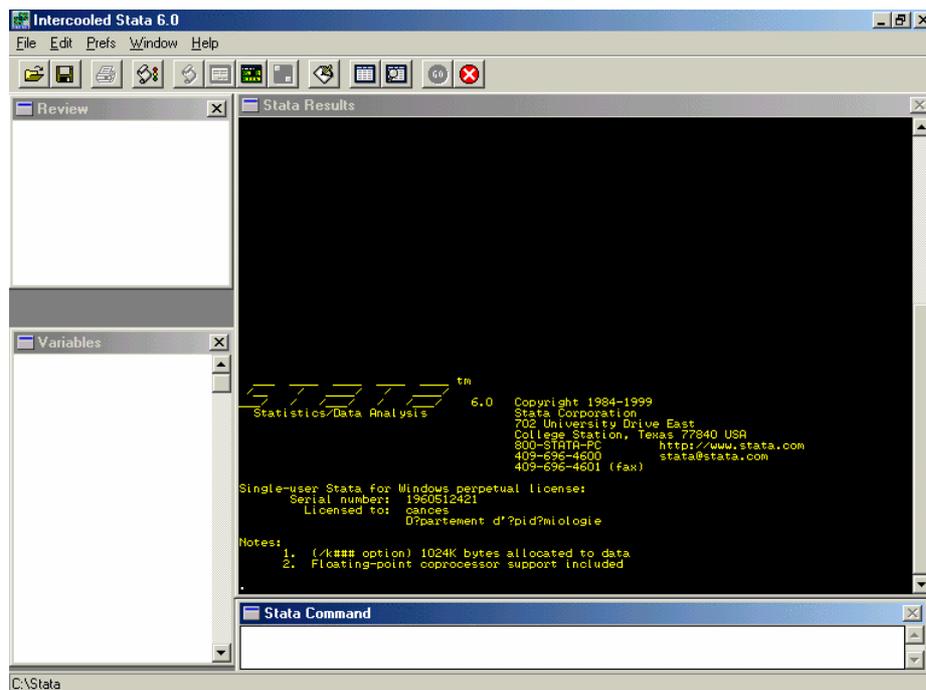
En mode batch, l'utilisateur lance une série de commandes prés enregistrées, le logiciel les exécute et rend la main à l'utilisateur à la fin de l'exécution (ou s'il s'est planté à cause d'une commande mal écrite).

Les deux modes de travail peuvent être associés dans une même session.

Extensions de fichiers utilisés pour identifier les différents types de fichiers

Mabase.**dta** : fichier de données formatées pour stata
Monprogramme.**do** : fichier de programme (pour le mode batch)
Mesresultats.**log** : fichier de sortie des résultats
Mesgraph.**gph** : fichier de sauvegarde des graphiques
Mesgraph.**wmf** : fichier de graphique au format Windows metafile pour les PC
Mesgraph.**pic** : fichier de graphique au format Pict pour les MAC

Les 4 fenêtres de Stata



Lorsque vous ouvrez Stata 4 fenêtres apparaissent par défaut :

- Fenêtre review : permet de revenir sur les commandes effectuées depuis l'ouverture du logiciel. Ces commandes peuvent être sélectionnées par un simple clic et rappelées par un double clic.
- Variables : liste des variables comprises dans la base de données. En fin de liste s'affichent les variables nouvellement créées. Ces variables peuvent être sélectionnées par un simple clic
- Stata commands : zone de saisie des commandes par l'utilisateur.

- Stata Results : permet la lecture des résultats au fur et à mesure de l'analyse. Attention les résultats ne sont pas archivés automatiquement. Pour archiver les résultats il faut créer un fichier xxxx.log

D'autres fenêtres peuvent apparaître à votre demande en cours d'analyse

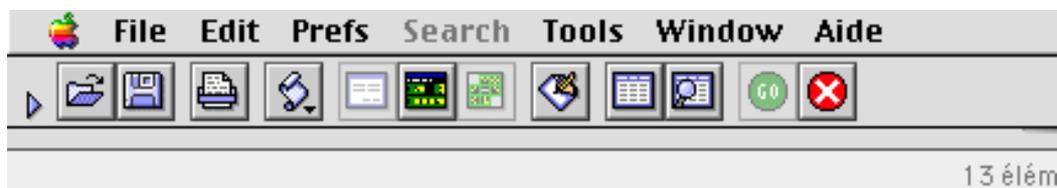
Les graphiques

La base de données en cours d'utilisation

Le fichier d'archivage des résultats : xxxx.log

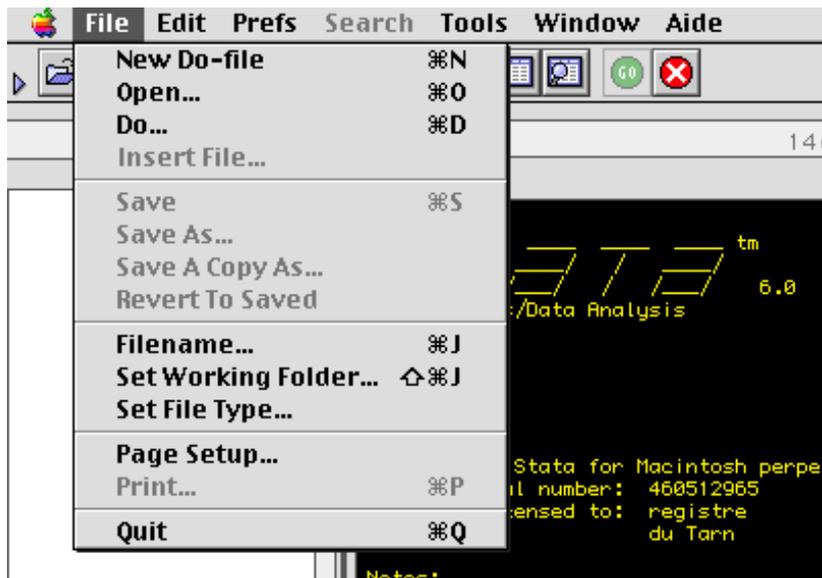
L'aide en ligne

Les boutons de commande et les menus



- Ouvrir : permet de choisir une base de données à analyser sous réserve que celle-ci soit enregistrée sous un format Stata ex : mabase.dta
- Enregistrer : permet d'enregistrer les modifications effectuées dans la base de données. Un message de confirmation apparaît à l'écran si vos données ont été modifiées après l'ouverture.
- Imprimer : permet d'imprimer les résultats de vos analyses
- Ouvrir un fichier de résultats : entraîne la commande log qui permet d'ouvrir un fichier de résultats qui permettra de sauvegarder les commandes que vous saisissez par la suite
- Permet de faire dérouler le fichier de résultats pour vous permettre de revenir au début de votre analyse.
- Permet de faire apparaître en premier plan et de rendre active la fenêtre de résultats
- Permet de faire apparaître en premier plan la fenêtre graphique.
- Permet de faire apparaître la base de données et de la modifier, permet de coller directement une base de données issue d'Excel.
- Permet de faire apparaître en lecture seule la base de données
- Permet de gérer le mode de défilement des résultats
- Permet d'interrompre la sortie de résultats qui est en train d'être exécutée.

D'autres commandes sont aussi disponibles dans des menus déroulant



Quelques notions concernant les variables

Dans la base de données les variables sont stockées sous des formats différents pour économiser la place occupée en mémoire.

Il ne faut pas confondre le format de stockage et la façon dont les variables s'affichent à l'écran et la présentation que vous pouvez en demander

Format d'affichage: %#. # format

% spécifie le début du format

#place occupée par la variable

.# nombre de décimaux après la virgule

format; g(général) ; f(fixe) ; e(scientifique)

Il existe aussi des format pour les variables textuelle et les dates
s(string) ; t(date)

Vous pouvez à tout moment changer le format des variables que vous utilisez pour cela vous avez besoin de savoir comment stata code les variables c'est à dire quel est le format d'enregistrement et quelle est la commande qui vous permet de passer d'un format à un autre.

Les variables qualitatives : string variables %s

Elles comprennent du texte.

Le format des données est enregistré sous forme str# # renvoyant à la place allouée à l'écriture de la variable, la longueur maximale est de 80 caractères

Les variables quantitatives : real variables

Attention si vous importez des nombres décimaux avec une « , », stata ne reconnaît pas un nombre il faut utiliser le « . ».

Ces variables sont affichées sous plusieurs formes

Format général %g	%9.0g	1.414114
Format fixé %f	%9.2f	1.41
Format scientifique %e	%9.2e	1.41 ^e +00

Variables dates %d

Elles sont obtenues après transformation des variables importées.

Elles sont stockées sous le format %t ou %d.

Stata code la date en nombre de jour écoulé à partir du 1^{er} janvier 1960. Toutes les dates antérieures seront des nombres négatifs et toutes celles postérieures seront des nombres positifs.

Données manquantes

Elles sont codées «.» pour les variables qualitatives et «. » pour les variables quantitatives. Attention le format de stockage des données manquantes pour les variables numériques est un nombre qui tend vers l'infini. Ceci implique que vous devez tenir compte des données manquantes lors de nouveaux codages ou de génération de nouvelles variables.

Les labels dans Stata

Pour ne pas avoir à interpréter des codes Stata permet de donner :
des libellés longs et plus explicites qu'un nom de 8 caractères aux variables
des libellés aux différentes modalités d'une même variable

Labeliser une variable

Label vari «ce que contient cette variable»

les guillemets sont nécessaires à cause des blancs.

Labelliser des valeurs

On commence par définir un type de label qui pourra servir pour plusieurs variables

Label define ouinon 1 oui 2 non 9 «ne sait pas»`

Puis on affecte ce label aux variables auquel il correspond

Label value ouinon diabet
Label value ouinon cardiac

Remarque : on peut aussi faire l'inverse, à partir d'une variable texte on crée une variable numérique avec la commande : encode
Encode patho , gen (maladie)

Quelques notions d'écriture des commandes (syntaxe)

[by liste de var :] commande [liste de var] [=exp] [if exp] [in range], [options]

Les annotations entre crochets sont optionnelles.

Si des variables ne sont pas précisées l'analyse portera sur l'ensemble du fichier

By var1 var2 : commande

Stipule que la commande qui suit doit être réalisée pour chaque groupe de variables
Ce préfixe ne s'utilise que lorsque les variables sont triées.

Ex

- sort sexe
- by sexe : sum age, detail

Donne la distribution de l'âge en fonction du sexe.

Commande [liste de var] [=exp]

Permet de définir le type de gestion ou d'analyse que vous effectuez
Chaque commande est suivie d'un espace

If exp

Réduit la commande à l'expression spécifiée. La commande est réalisée sur les enregistrements vérifiant l'expression logique située après if.

Ex

- sum age if sexe==2

By varlist et if peuvent être combinées dans la même ligne de commande

In range

La commande n'est appliquée qu'à une partie de l'échantillon. Celle-ci est définie par le premier numéro d'enregistrement et le dernier ## / ##

Ex

- sum age in 1/20

In range ne peut pas être combiné avec by varlist

In range peut être combiné avec if

Options

Il existe un certain nombre d'options pouvant être utilisées, elles diffèrent en fonction des commandes.

Les options sont toujours écrites après la commande principale et séparée d'elle par une virgule. Plusieurs options sont possibles au cours de la même commande.

Gérer une base de données avec Stata

Ouvrir une base stata existante

Le plus simple c'est de double-cliquer dessus mais on peut faire plus compliqué surtout si on est déjà dans stata et qu'on ne veut pas le quitter

Use

Cette commande est à utiliser quand la base de données est déjà formatée pour Stata

```
➤ use c:\data\mabase.dta ↵
```

Si vous étiez déjà en train de travailler sur un fichier, vous devez obligatoirement ajouter l'option clear

```
➤ use c:\data\mabase.dta, clear ↵
```

Clear permet de fermer la base sur laquelle vous venez de travailler.

Attention : clear ne vous propose pas d'enregistrer les modifications que vous avez apportées. Vous avez donc intérêt à sauvegarder votre fichier avant si vous y avez fait des modifications

Messages d'erreurs pouvant être rencontrés :

“ no data in memory would be lost ” : vous avez oublié de rajouter l'option clear et de sauvegarder la base que vous venez d'utiliser.

“ no room to add more records ” la base de données est trop importante, vous devez augmenter la mémoire allouée à Stata pour travailler en lui demandant avec la commande :
set mem xxm , (attention il faut enregistrer avant)

Importer des données d'une base de données extérieure

Quand la base à importer n'est pas trop volumineuse, le moyen le plus simple d'importer des données est d'effectuer un copier –coller à partir du fichier Excel. Pour cela un minimum de mise en forme est nécessaire

- Supprimer tous les accents compris dans les noms ou les champs des variables
- Donner des noms inférieurs à 8 caractères pour vos variables.
- Remplacer toutes les virgules de vos variables quantitatives par des points sinon stata les traitera comme des variables qualitatives

Puis vous copiez exactement votre fichier dans Excel, sans rajouter de colonnes ou de lignes superflues, sinon stata les traitera comme des enregistrements à données manquantes

Et enfin vous collez dans l'éditeur de données.

Insheet

Commande qui s'utilise pour importer des données en format ascii. Le fichier doit comprendre un enregistrement par ligne et des variables séparées par des tabulations ou des virgules.

Très utile

```
➤ Insheet using c:\data\mabase.txt ↵
```

Infile

Permet d'importer des fichiers en format texte dans lesquels les données ne sont pas formatées (le séparateur pouvant être une virgule, une tabulation ou un espace), les sujets pouvant être positionnés en colonne, les variables ne sont pas nommées.

Emploi peu courant, se rapporter à la documentation pour les options possibles d'importation.

➤ `Infile using c:\data\mabase.raw` ↵

Par défaut après `infile` Stata cherche un fichier `.raw`

Pour donner un nom aux variables lors de l'importation, vous devez les spécifier juste après la commande..

➤ `Infile str10 nom age sexe using c:\data\mabase.raw` ↵

Str10 sert à spécifier que la variable `nom` est qualitative et que la place nécessaire est de 10 caractères. Quand on ne spécifie pas le type de variables stata automatiquement en fait des variables quantitatives.

Infix

Cette commande permettant d'importer du texte en format fixe, ce qui est souvent le cas d'une base de données venant d'un autre logiciel de statistique.

Exporter des données vers une base de données extérieure

Commandes principales des bases de données

Clear : `clear`

Ferme la base de données en cours d'utilisation. Cette commande est nécessaire pour pouvoir lire une autre base de données

➤ `clear` ↵

Edit : `edit`

Donne accès à l'éditeur de données dans lequel il vous est possible d'effectuer des changements ou de compléter une saisie inachevée.

Je vous rappelle que Stata n'est pas un logiciel permettant les saisies importantes, celles – ci devant être réalisées sur des tableaux appropriés.

➤ `edit` ↵

donne accès à la base dans son intégralité

Pour ça on peut aussi utiliser le bouton, mais pas après

➤ `edit var1 var2 var3` ↵

édite uniquement les variables listées

➤ `edit var1 var2 var3 if var3<## & var2~="TT2"` ↵

édite les variables listées si les conditions qui suivent sont vérifiées

➤ `edit in 1/20` ↵

édite toutes les variables des enregistrements (lignes) 1 à 20.

Save : save

Sauvegarde les données qui ont été modifiées avec les nouvelles variables créées. La commande s'écrit :

```
➤ save c:\data\mabase.dta ↵
```

Si le fichier mabase existe déjà sur votre ordinateur il faut rajouter une option : "replace" qui remplace la base ancienne par la base modifiée.

Pour ça on peut aussi utiliser le menu déroulant : FILE > SAVE

```
➤ save c:\data\mabase.dta,replace ↵
```

Si vous souhaitez enregistrer vos données dans un autre fichier pour garder intact le fichier d'origine, utilisez la commande save et changez le nom du fichier.

Pour ça on peut aussi utiliser le menu déroulant : FILE > SAVE AS

```
➤ save c:\data\mabase1.dta ↵
```

Vous pouvez ne sauvegarder qu'un certain nombre de variables ou d'enregistrements en enrichissant les commandes de certains attributs.

```
➤ save nom prenom age sexe in 1/150 using c:\data\mabase1.dta ↵
```

Sauvegarde uniquement les variables nom prénom âge et sexe des enregistrements 1 à 150.

List : list

Permet de contrôler les données dans la fenêtre résultats. Cette commande peut entraîner le défilement de l'ensemble de la base de données. Utiliser des restrictions sur les noms de variables et les enregistrements dans son utilisation.

```
➤ list nom prenom age sexe in 1/3 ↵
```

```
➤ list nom prenom age sexe if age<40 ↵
```

Si par inadvertance vous avez utilisé list vous pouvez interrompre le défilement des enregistrements par le bouton break

```
➤ list ↵
```

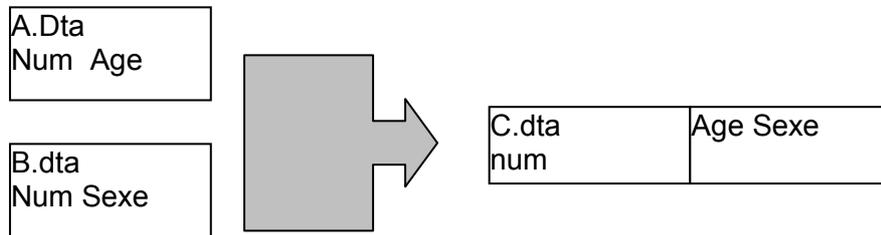
```
➤ Ctrl +break
```

Fusion de plusieurs fichiers Merge/Append

La fusion de fichiers nécessite un numéro d'identification commun aux deux fichiers et un tri préalable à la fusion sur ce numéro d'identification.

Merge

Permet de combiner les fichiers horizontalement et de rajouter des variables à la base de données. Merge ne nécessite pas que les bases contiennent le même nombre d'enregistrements.



- use c:\data\ A.dta ↵
- sort ↵
- save c:\data\A.dta, replace ↵
- use c:\data\ B.dta, clear ↵
- sort ↵
- merge num using c:\data\A.dta ↵
- save c:\data\C.dta ↵

Lors de la fusion stata crée une variable `_merge` qui vous permet de contrôler le bon déroulement de l'opération.

- tab `_merge` ↵

```
. tab _merge
```

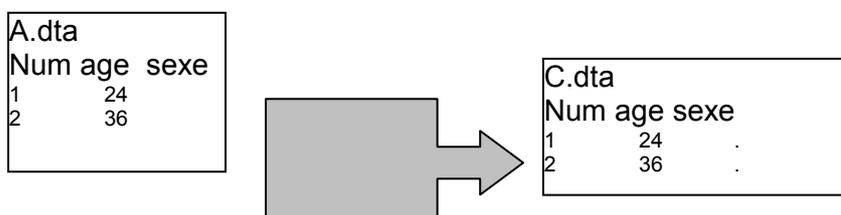
<code>_merge</code>	Freq.	Percent	Cum.
1	18	13.85	13.85
2	14	10.77	24.62
3	98	75.38	100.00
Total	130	100.00	

Les codes s'interprètent de la façon suivante :

- 1 18 enregistrements du fichier A n'ont pas trouvé de correspondants dans le fichier B
- 2 14 enregistrements du fichier B n'ont pas fusionné avec le fichier A
- 3 98 enregistrements ont correctement fusionné entre A et B

Append

Fusion verticale des fichiers, permet d'obtenir plus d'enregistrements.



```
B.dta
Num age sexe
3 F
```

```
3 . F.
```

L'ordre des variables n'a pas d'importance, les fichiers peuvent être de conceptions différentes. Les données appartenant aux même noms de variables seront ajoutées, des valeurs manquantes seront spécifiées pour les variables n'existant pas dans les fichiers A et B.

Pour contrôler la fonction append, vous devez passer par l'éditeur de données et regarder s'il n'existe pas de décalage dans la base.

Outils de description de la base de données.

Codebook

Décrit les caractéristiques de chaque variable comprise dans la base. Le nombre d'enregistrements, le nombre de valeurs manquantes par variables, la distribution des variables quantitatives.

➤ **codebook**
entraîne la description de l'ensemble de la base

➤ **codebook var1 var2 var3**
entraîne la description des variables 1 à 3

Inspect

Moins performant que la commande précédente. Décrit la base par variables en nombre de données positives, négatives, nulles ou manquantes. Associe à la sortie des résultats un histogramme.

Describe

Permet d'obtenir les informations de synthèse de la base de données.

- Nombre d'enregistrements
- Nombre de variables
- Mémoire occupée
- Date de la commande
- Liste des variables avec leur nom et leur type

➤ **desc**
➤ **desc, short**
supprime le listing des variables

```
Contains data from c:\data\autre.dta
  obs:                116
  vars:                184
  size:               87,928 (99.2% of memory free)
                                14 Nov 2000 00:56
```

```

-----
-----
1. num      byte    %8.0g
2. agec1    str2     %9s          1 agec
3. bmi1     float    %9.0g          1 bmi
4. bmi1     float    %9.0g          1 bmi
5. agec2    str2     %9s          2 agec
6. bmi2     float    %9.0g          2 bmi

```

Création de nouvelles variables : Gen - Egen - Replace - Recode

Gen

Cette commande crée de nouvelles variables remplissant les conditions spécifiées après le signe=

Par défaut la variable créée est toujours une variable quantitative.

➤ `gen newvar = exp oldvar` ↵

Exp : Une combinaison de variables existantes quelles soient qualitatives et ou quantitatives

Pour les enregistrements comportant des données manquantes, la nouvelle variable prendra une valeur manquante.

Opérateurs possibles :

+	addition
-	soustraction
*	multiplication
/	division
^	exponentielle
^0.5	racine carrée
()	regroupement d'une expression
<, <=	plus petit que
>, >=	plus grand que
~= ou !=	différent de
==	égal à
&	et
	ou

Ex

- `gen age =(dateexam-ddn) / 365.25`
- `gen bmi=taille/(poids^2)`
- `gen gold=var10>2 & (var11>1|var13>1|var15==1)`

Attention lors de la définition de variable le signe = n'est pas doublé, il correspond à deux choses :

- 1/ l'affectation d'une valeur s'il est suivi d'une valeur,
- 2/ l'identification d'une expression logique s'il est suivi par une expression logique.

Par contre quand on veut parler d'égalité alors le signe est doublé ==.

Ex :

```
Gen malade=diabete==1 | hta==1
```

Code la variable 1 si l'expression est vérifiée et 0 si elle ne l'est pas.

Malade est codé 1 si le sujet présente un diabète ou une hypertension artérielle, 0 s'il ne présente ni l'un ni l'autre

Créer des variables texte

Pour créer des variables qualitatives il faut spécifier son format et sa longueur après la commande gen et avant le nouveau nom de variable.

```
Gen str1 sexe= « M » if codesex==1
```

```
Replace str1 sexe= "F" if codesex==2
```

Plusieurs fonctions peuvent être utilisées avec les variables qualitatives

Ex : extraire les composants d'une date

```
➤ Gen str4 annee=substr(ddn,7,4)
```

```
➤ Gen str2 mois=substr(ddn,4,2) fonction substr(var,#,#) voir plus bas
```

```
➤ Gen str2 jour=substr(ddn,1,2)
```

Convertir une variable quantitative en variable qualitative

```
Gen str1 genre=string(sexe) fonction string(#)
```

Homogénéiser la saisie en modifiant le format (majuscule ou minuscule) des caractères

```
Gen str10 NOM=upper(nom)
```

```
Gen str8 prenom=lower(PRENOM)
```

Créer un code à partir de l'année et du mois de naissance et du sexe du patient

- Gen str7 code=sexe+annee+mois

Manipulations de chaînes de caractères plus complexes

Compter le nombre de caractères dans une chaîne

```
➤ gen longueur=length(nom)
```

```
Si le nom est "Pierre", longueur=6
```

Détecter la place d'un caractère particulier dans une chaîne de caractère

```
➤ gen place=index(nom,"-")
```

```
Si le nom est "Anne-Marie" , place=5
```

```
Si le nom est "Pierre", place=0
```

Enlever des espaces

ltrim : si l'espace est en début de chaîne

rtrim : si l'espace est en fin de chaîne

trim : si l'espace est en début ou en fin de chaîne

➤ `gen str20 nvnom=ltrim(anciennom)`
va remplacer " Anne-Marie" par "Anne-Marie"

Extraire les composants d'une chaîne de caractère : fonction substr(s,n1,n2)

Cette fonction soustrait une sous-chaîne de s à partir de la colonne n1 pour une longueur de n2

Si n1<0, n1 est la distance à partir de la fin de la chaîne

Si n2= . , le restant de la chaîne est renvoyé, quelle que soit sa longueur.

```
substr("abcdef",2,3) = "bcd"
substr("abcdef",-3,2) = "de"
substr("abcdef",2,.) = "bcdef"
substr("abcdef",-3,.) = "def"
substr("abcdef",2,0) = ""
substr("abcdef",15,2) = ""
```

Générer des variables dates

A partir d'une variable qualitative (string)

- `gen datenais=date(ddn, "dmy", 2050)`
remplace la variable string ddn en nombre de jours écoulés depuis le 01/01/1960
- `format datenais %d`
formate le nombre de jours en format jour/mois/année

A partir de 3 variables quantitatives jours, mois, années

`Gen datenais=mdy(mois, jour, annee)`

Générer une variable aléatoire

- `gen alea=uniform()`
Cette fonction renvoie des nombres pseudo-aléatoires distribués selon la loi uniforme entre 0 et 1.
Dans un second temps, cela permet de faire des tirages au sort.

Egen

Cette commande permet d'attribuer à chaque enregistrement un résumé ou une description d'une ou plusieurs variables.

Egen newvar=option(oldvar1 oldvar2 oldvarn)

Les options possibles sont :

- `Count` : Dénombrer le nombre de valeurs non manquantes dans la liste de variables spécifiées
- `diff` : compare les variables, prend la valeur 1 quand les enregistrements sont différents

- max & min : donne la valeur maximale ou minimale de la variable
- mean & median : donne la moyenne ou la médiane de la variable
- pctl # : donne la valeur du percentile spécifié
- sd : donne l'écart type de la variable
- sum : fait la somme des variables spécifiées.

Quelle est la différence entre gen et egen ?

Exemple :

gen sum1=sum(a)

egen sum2=sum(a)

list a	sum1	sum2
1.	1	15
2.	2	15
3.	3	15
4.	4	15
5.	5	15

sum1 est un résultat relatif, sum2 est une constante.

Replace

Permet de remplacer les valeurs d'une variable

- `replace poids=poids*1000`
- `replace taille=taille*100`

Cette commande est souvent utilisée quand l'expression logique servant à définir une variable diffère en fonction des résultats d'une autre variable.

Ex : vous voulez calculer la taille des enfants de 10 ans à 11 ans. Cette augmentation est de 10 cm pour les filles et de 8 cm pour les garçons.

- `gen taille11=taille10 +8 if sexe==1 & taille10~.`
- `replace taille11=taille10+10 if sexe==2 & taille10~.`

Recode

Permet de changer le codage des variables ou de définir des classes pour les variables quantitatives.

- `recode csp 0=0 1=1 2=1`
- `gen ageclas=recode(age,20,45,75)`

recode l'âge en fonction des intervalles spécifiés age<=20 sera codé 20 ; >20 et <=45 sera codé 45 ; >45 et <=75 sera codé 75

Suppression de variables ou d'enregistrements Drop - Keep

Drop

➤ `drop var1 var2 var3`

Supprime les variables spécifiées

➤ `drop var1 var2 var3 in ##`

supprime les variables spécifiées pour un certain nombre d'enregistrement

➤ `drop var1 var2 var3 if var=exp`

supprime les variables spécifiées si la condition est vérifiée

➤ `drop _all`

supprime toutes les variables

Keep

➤ `keep var1 var2 var3`

Garde les variables spécifiées

➤ `keep var1 var2 var3 in ##`

Garde les variables spécifiées pour un certain nombre d'enregistrements

➤ `keep var1 var2 var3 if var=exp`

Garde les variables spécifiées si la condition est vérifiée

Recherche et manipulation de doublons

Identification des doublons

On crée une nouvelle variable appelée **dup**

dup = 0 enregistrement unique

dup = 1 enregistrement en double, première occurrence

dup = 2 enregistrement en double, deuxième occurrence

dup = 3 enregistrement en double, troisième occurrence

etc.

La détermination des doublons se fait sur les variables **name**, **age**, et **sex**.

```
. sort name age sex
```

```
. quietly by name age sex: gen dup = cond(_N==1,0,_n)
```

_N : nombre total d'observation dans le groupe "by"

_n est le numéro d'observation dans le groupe "by"

Pour connaître le décompte des doublons , faire :

```
. tabulate dup
```

La détermination des doublons se fait sur une seule variable **name** :

```
. sort name
```

```
. quietly by name: gen dup = cond(_N==1,0,_n)
```

Comment enlever les doublons ?

Pour ne garder que la première occurrence

```
. drop if dup>1
```

Pour enlever tous les doublons

```
. drop if dup>0
```

Exemple 1

Soit les données suivantes

```
. list
```

	make	price	mpg
1.	VW Diesel	5397	41
2.	BMW 320i	9735	25
3.	Datsun 510	5079	24
4.	Audi 5000	9690	17
5.	BMW 320i	9375	25
6.	VW Diesel	5397	41
7.	BMW 320i	9735	25

Pour rechercher les doublons sur la variable **make**:

```
. sort make
```

```
. quietly by make: gen dup = cond(_N==1,0,_n)
```

Résultat :

```
. list
```

	make	price	mpg	dup
1.	Audi 5000	9690	17	0
2.	BMW 320i	9735	25	1
3.	BMW 320i	9735	25	2
4.	BMW 320i	9375	25	3
5.	Datsun 510	5079	24	0
6.	VW Diesel	5397	41	1
7.	VW Diesel	5397	41	2

```
. drop if dup>1
```

(3 observations deleted)

```
. list
```

	make	price	mpg	dup
1.	Audi 5000	9690	17	0
2.	BMW 320i	9735	25	1
3.	Datsun 510	5079	24	0
4.	VW Diesel	5397	41	1

Manipulation de fichiers

collapse

Cette commande permet de faire un nouveau fichier de données contenant des résultats (moyennes, médianes,...) provenant de variables de type quantitatif

➤ `collapse (stat) var1 [(stat) var2], by (var3)`

Pour stat; les possibilités sont les suivantes :

- Moyenne : `mean` (par défaut)
- Déviation standard : `sd`
- Somme : `sum`
- Nombre de données non manquantes : `count`
- Maximum : `max`
- Minimum : `min`
- Médiane : `median`
- Premier percentile : `p1` etc.

Exemple :

```
list marque weight price
```

	marque	weight	price
1.	AMC	3,350	4,749
2.	AMC	2,640	3,799
3.	AMC	2,930	4,099
4.	Audi	2,070	6,295
5.	Audi	2,830	9,690
6.	BMW	2,650	9,735
7.	Buick	3,400	4,082
8.	Buick	4,080	7,827
9.	Buick	3,880	10,372
10.	Buick	2,230	4,453

```
. collapse (mean) weight price, by(marque)
```

```
. list marque weight price
```

	marque	weight	price
1.	AMC	2,973.3	4,215.7
2.	Audi	2,450	7,992.5
3.	BMW	2,650	9,735
4.	Buick	3,397.5	6,683.5

contract

Cette commande permet de faire un nouveau fichier de données contenant les fréquences des combinaisons de variables

➤ **contract var1 var2, options**

Les options sont les suivantes :

- `freq(newvar)` : permet de donner un nouveau nom à la variable
- `zero` : pour avoir les combinaisons de variables avec des fréquences=0
- `nomiss` : les observations avec données manquantes sont éliminées

Exemple :

```
list marque foreign rep78
```

	marque	foreign	rep78
1.	AMC	Domestic	3
2.	AMC	Domestic	3
3.	AMC	Domestic	.
4.	Audi	Foreign	5
5.	Audi	Foreign	3
6.	BMW	Foreign	4
7.	Buick	Domestic	3
8.	Buick	Domestic	3
9.	Buick	Domestic	.
10.	Buick	Domestic	3

```
. contract marque foreign, freq(nouveau) zero
```

```
. list foreign marque nouveau
```

	foreign	marque	nouveau
1.	Domestic	AMC	3
2.	Foreign	AMC	0
3.	Domestic	Audi	0
4.	Foreign	Audi	2
5.	Domestic	BMW	0
6.	Foreign	BMW	1
7.	Domestic	Buick	4
8.	Foreign	Buick	0

fillin

Cette commande rajoute des observations avec des données manquantes de telle sorte que l'ensemble des combinaisons des variables spécifiées existent. Elle crée une nouvelle variable `_fillin` qui prend la valeur 1 pour les observations créées et 0 pour les observations préexistantes.

Exemple :

```
list marque foreign rep78 price weight
```

	marque	foreign	rep78	price	weight
1.	AMC	Domestic	3	4,099	2,930
2.	AMC	Domestic	3	4,749	3,350
3.	Audi	Foreign	3	6,295	2,070
4.	Audi	Foreign	5	9,690	2,830
5.	BMW	Foreign	4	9,735	2,650

```
. fillin marque foreign rep78
```

```
. list marque foreign rep78 price weight _fillin
```

	marque	foreign	rep78	price	weight	_fillin
1.	AMC	Domestic	3	4,749	3,350	0
2.	AMC	Domestic	3	4,099	2,930	0
3.	AMC	Domestic	4	.	.	1
4.	AMC	Domestic	5	.	.	1
5.	AMC	Foreign	3	.	.	1
6.	AMC	Foreign	4	.	.	1
7.	AMC	Foreign	5	.	.	1
8.	Audi	Domestic	3	.	.	1
9.	Audi	Domestic	4	.	.	1
10.	Audi	Domestic	5	.	.	1
11.	Audi	Foreign	3	6,295	2,070	0
12.	Audi	Foreign	4	.	.	1
13.	Audi	Foreign	5	9,690	2,830	0
14.	BMW	Domestic	3	.	.	1
15.	BMW	Domestic	4	.	.	1
16.	BMW	Domestic	5	.	.	1
17.	BMW	Foreign	3	.	.	1
18.	BMW	Foreign	4	9,735	2,650	0
19.	BMW	Foreign	5	.	.	1

Quelques statistiques descriptives élémentaires

Contrôle de la nature de la distribution

SUM

➤ sum var

sum age

Variable	Obs	Mean	Std. Dev.	Min	Max
-----+-----					
acbil	102	9.46902	2.278692	3.75	15.2

Moyenne et écart type

➤ sum var, detail

Sum age, detail

Percentiles		Smallest		
1%	4.25	3.75		
5%	5.75	4.25		
10%	6.92	5.33	Obs	102
25%	7.83	5.58	Sum of Wgt.	102
50%	9.2		Mean	9.46902
		Largest	Std. Dev.	2.278692
75%	11.08	13.5		
90%	12.42	14.75	Variance	5.192439
95%	13.1	15	Skewness	.1570892
99%	15	15.2	Kurtosis	2.963282

Donne les estimateurs de tendances de dispersion, la nature de la distribution.

Skewness permet de juger de la symétrie

Kurtosis de l'amplitude

percentiles de la distribution

➤ pctile newvar= var, nq(10) genp(pourcent)

crée une nouvelle variable pourcent qui stipule quelle est la valeur des centiles spécifiés dans nq

Ici, il est demandé de donner les valeurs prises pour chaque décile (nq(10)).

➤ xtile newvar= var, nq(4)

crée une nouvelle variable stipulant dans quel centile se trouve la valeur de la variable quantitative. Dans cet exemple il est créé une variable à 4 classes, représentant les quartiles de la distribution.

SKTEST

➤ sktest var

```
. sktest acbil
```

Teste H0 : la distribution est normalement distribuée

```
Skewness/Kurtosis tests for Normality
```

Variable	Pr(Skewness)	Pr(Kurtosis)	adj chi-sq(2)	joint Pr(chi-sq)
acbil	0.493	0.814	0.53	0.7661

SWILK

```
➤ swilk var
```

test de Shapiro – Wilk, valide pour les bases de données comportant peu d'enregistrements.

Teste l'hypothèse nulle : la distribution est normale

```
. swilk age
```

```
Shapiro-Wilk W test for normal data
```

Variable	Obs	W	V	z	Pr > z
acbil	102	0.99226	0.650	-0.956	0.83053

LADDER

Permet de tester les transformations simples permettant d'atteindre la normalité

```
➤ ladder var
```

```
ladder ins60
```

Transformation	formula	Chi-sq(2)	P(Chi-sq)
cube	ins60^3	.	0.000
square	ins60^2	.	0.000
raw	ins60	33.96	0.000
square-root	sqrt(ins60)	8.68	0.013
log	log(ins60)	1.19	0.551
reciprocal root	1/sqrt(ins60)	18.74	0.000
reciprocal	1/ins60	39.59	0.000
reciprocal square	1/(ins60^2)	67.48	0.000
reciprocal cube	1/(ins60^3)	.	0.000

Tab

Permet de regarder la distribution des variables qualitatives

```
➤ tab var
```

Options pour tab : row pourcentages en ligne
 col pourcentages en colonne
 missing inclus les données manquantes
 chi2 chi2 de Pearson
 exact test exact de Fisher

tab sexe

sexe	Freq.	Percent	Cum.
1	43	37.07	37.07
2	73	62.93	100.00
Total	116	100.00	

. tab sexe scol, row col chi2 exact

sexe	scol		Total
	0	1	
1	26	16	42
	61.90	38.10	100.00
	29.89	57.14	36.52
2	61	12	73
	83.56	16.44	100.00
	70.11	42.86	63.48
Total	87	28	115
	75.65	24.35	100.00
	100.00	100.00	100.00

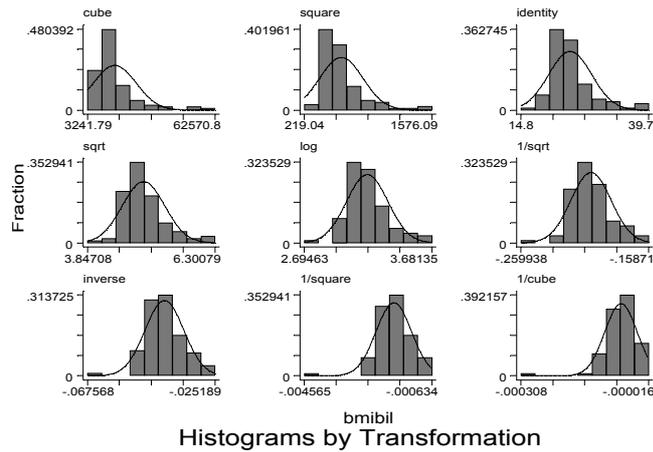
Pearson chi2(1) = 6.7887 Pr = 0.009
 Fisher's exact = 0.013
 1-sided Fisher's exact = 0.009

Commandes Graphiques

Gladder

Visualisation graphique (histogramme) des transformations simples d'une variable quantitative.

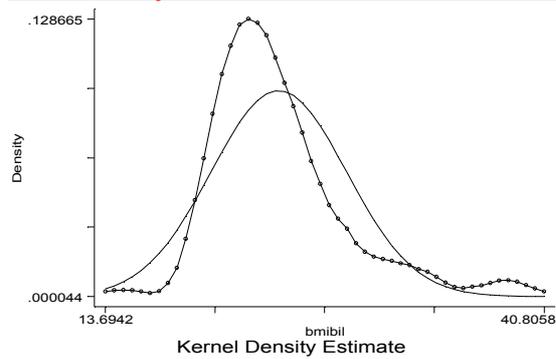
➤ **gladder var**



Kdensity

Donne la densité de $f(x)$: fonction de répartition de la variable. L'option normal permet le tracé d'une loi normale appliquée aux données

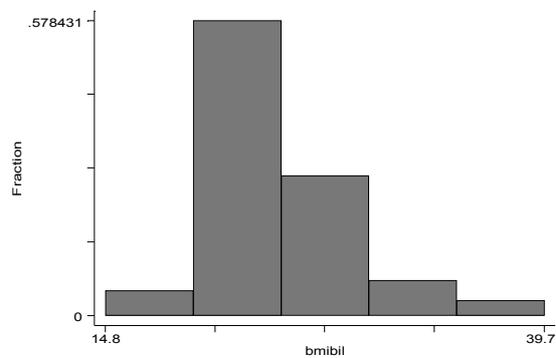
```
➤ kdensity var, normal
```



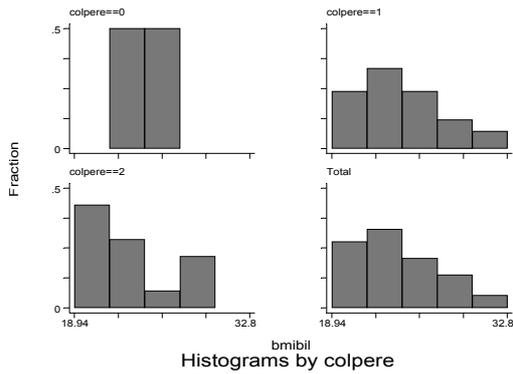
Graph

Permet de représenter graphiquement les variables **histogramme**

```
➤ graph var, hist
```



```
➤ sort var2  
➤ graph var, hist by(var2) total
```

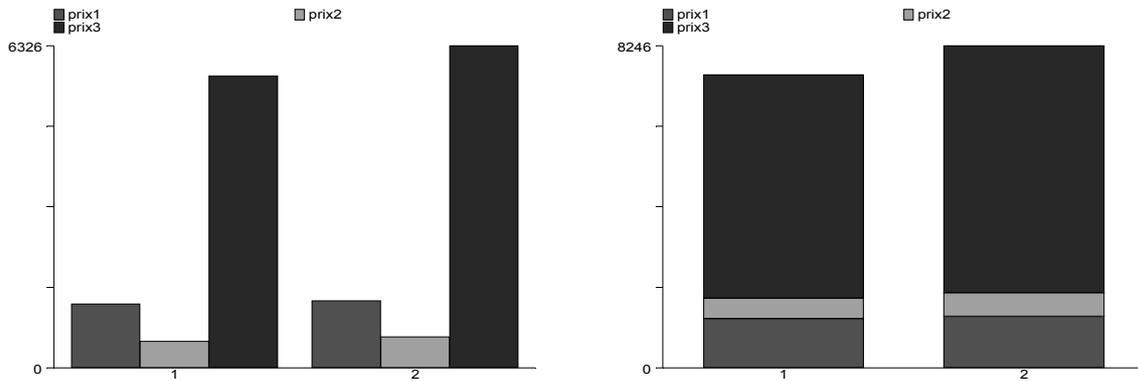


Options des histogrammes

- bin (#): spécifie le nombre d'intervalles à utiliser pour les barres
- freq : fréquence relative de l'axe des ordonnées
- normal : dessine la distribution normale

Diagramme en barres

➤ `graph var1 var2 var3, bar by(sexe)` `graph var1 var2 var3, bar by(sexe) stack`



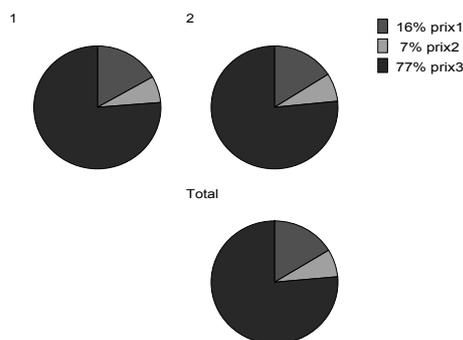
La taille des barres est proportionnelle à la somme des variables

Option des diagrammes en barre

- Stack : barres empilées
- Means : taille des barres est proportionnelle à la moyenne des variables
- Shading : permet de gérer les couleurs des barres

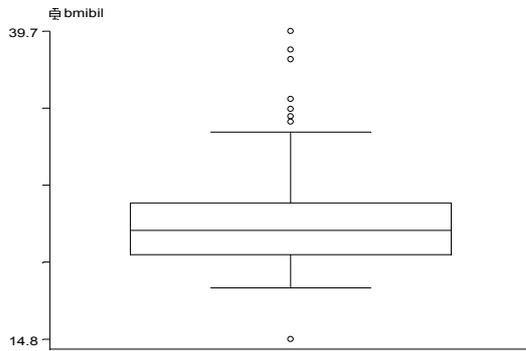
Diagrammes en secteurs

➤ `graph var1 var2 var3, pie by(sexe)`



box-plot

➤ `graph var , box`



Les données représentées par des points sont à vérifier, il peut s'agir de données aberrantes.

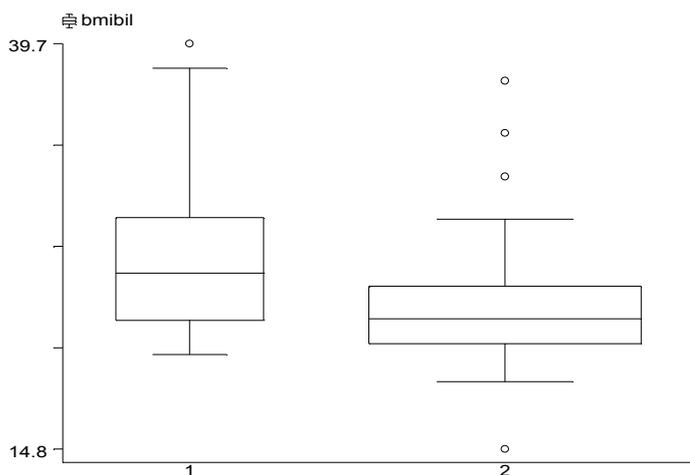
Le rectangle central correspond à la médiane de la distribution et au premier et 3^{ème} quartile de la distribution. La distance entre le 25^{ème} et le 75^{ème} centile est appelée espace interquartile.

Les lignes partant du rectangle correspondent à 1,5 fois l'espace interquartile. Les données situées hors de cet espace sont à vérifier.

➤ `sort var2`

➤ `graph var, vw box by(var2)`

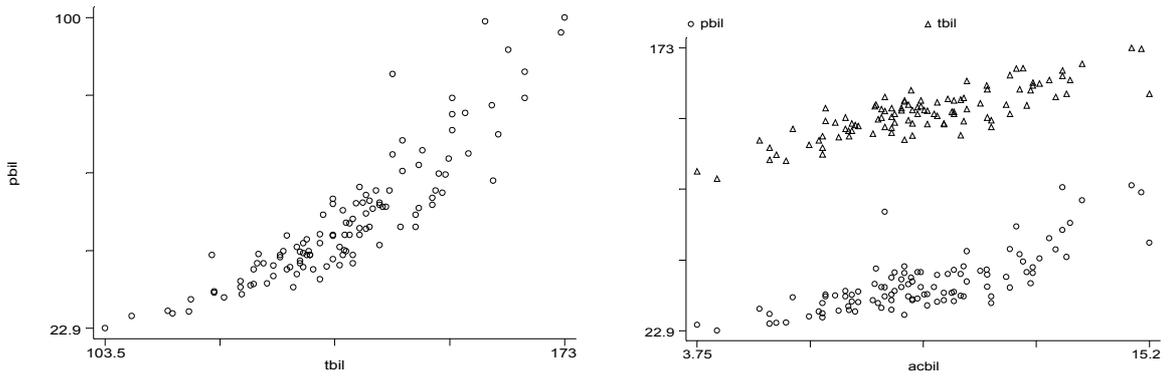
l'option `vw` proportionne les boites en fonction du nombre d'enregistrements de la variable 2



nuages de points

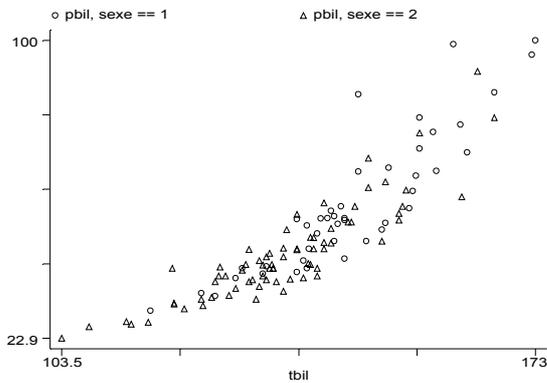
➤ `graph poids taille`

`graph poids taille age`



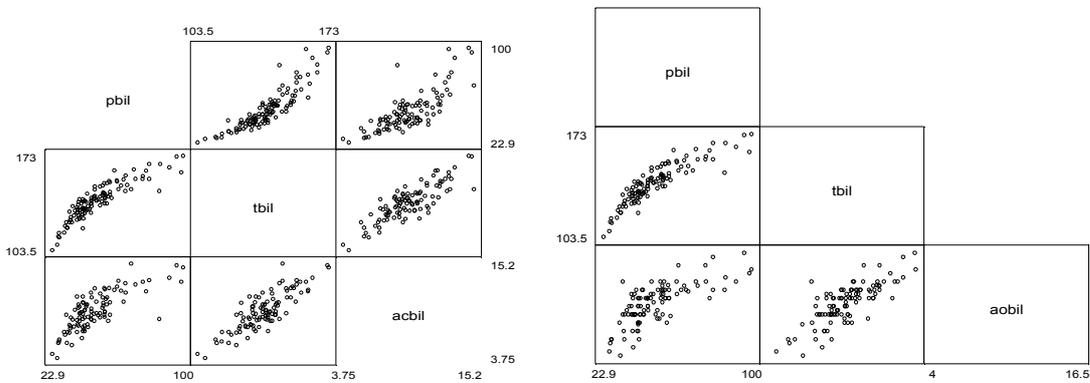
Caractérisation d'une variable qualitative (ex : sexe)

- **separate poids, by(sexe)**
Stata crée deux nouvelles variables nommées poids1(homme) poids2(femme)
- **graph poids1 poids2 taille**



Le poids des filles est marqué par un triangle
Le poids des garçons est marqué par un rond.

- **graph poids taille age, matrix**
- **graph poids taille age, matrix half**



options pour les matrices graphiques

- **half** donne simplement la partie inférieure de la matrice

Titre du graphique et des axes

Le titre du graphique par défaut est positionné en bas et centré. Un sous titre peut être ajouté.

Positionnement : en haut (top t), en bas (bottom b), à droite (right r), à gauche (left l)

- **title**(« ____ ») : titre centré en bas
- **t1title**(« ____ ») : titre centré en haut **t2title**(« ____ ») : sous-titre centré en haut
- **b1title**(« ____ ») : titre centré en bas **b2title**(« ____ ») : sous-titre centré en bas
- **r1title**(« ____ ») : titre centré à droite **r2title**(« ____ ») : sous-titre centré à droite
- **l1title**(« ____ ») : titre centré à gauche **l2title**(« ____ ») : sous-titre centré à gauche

options concernant les axes :

Par défaut, stata ne spécifie sur les axes que la première et la dernière valeur de l'étendue de la variable. Pour améliorer la présentation on peut utiliser certaines options.

- **xtick**(#,...,#) insère une marque à l'endroit spécifié sur l'axe des abscisses
- **xlabel**(#,...,#) insère une marque et le nombre correspondant sur l'abscisse
- **xscale**(#) spécifie l'étendue de l'axe des abscisses

La modification de la première lettre permet de spécifier l'axe qui est concerné

x pour abscisse
y pour l'ordonnée
r pour l'axe de droite
t pour l'axe du haut

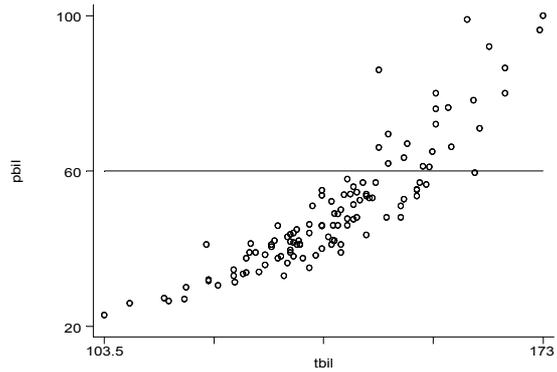
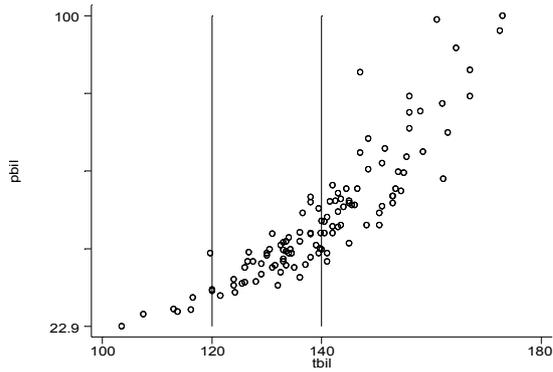
Positionnement de droites dans un graphique

Marquage d'une ou de plusieurs valeurs seuil sur les axes

- **xline**(#, , #)
- **yline**(#, , #)

➤ **graph poids taille, xline(120,140)**

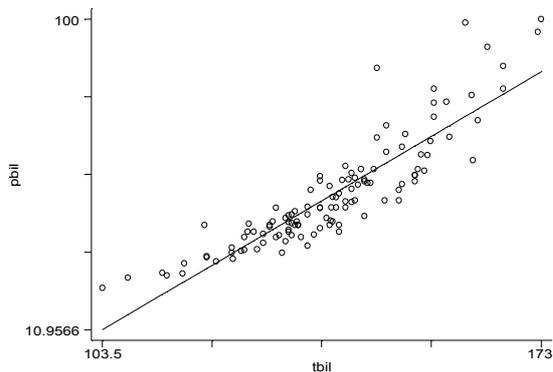
graph poids taille, yline(60)



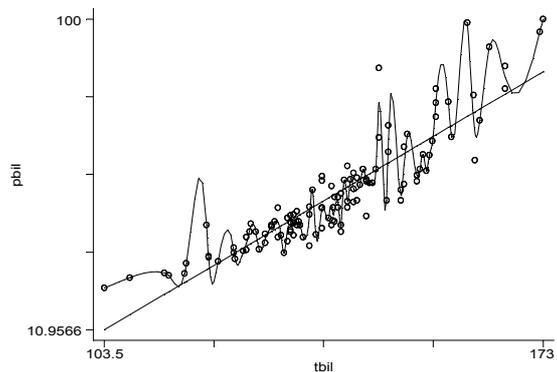
Droite de régression ou de corrélation

La droite de régression ne peut être positionnée que si elle a été au préalable estimée (regress pbil tbil / predict hat)

- graph poids hat taille , c(.l) s(Oi) sort



- graph poids hat taille , c(sl) s(Oi) sort



Option Connect : relie les points entre eux

- Graph var1 var2 var3, c(.l)
 - . pas de connexion (valeur par défaut)
 - l connexion par une ligne

Option Symbol Spécifie la forme des points

- Graph var1 var2 var3, s(Oi)
 - O grand cercle / o petit cercle
 - T grand triangle
 - S grand carré
 - p plus
 - d losange
 - i invisible

s(Oi) le premier point est marqué par un cercle , le second est invisible.

Sauvegarde des graphiques

Deux formats de sauvegarde sont possibles : *.gph et *.wmf. Pour pouvoir améliorer les graphiques grâce aux outils du pack office il faut enregistrer le fichier en format windows metafile *.wmf

A partir de la barre de titre quand la fenêtre graphique est active

File

Save graph as

Donner un nom au fichier : mongraph.wmf

Spécifié l'option windows metafile

OK

A partir de l'option saving

Le seul format de sauvegarde possible à partir de ce fichier est un format *.gph

- `graph var1 var2, saving(c:\rep\mongraph)`
- `graph var1 var2, saving(c:\rep\mongraph, replace)`
L'option **replace** permet d'écraser le fichier déjà enregistré

Sauvegarder plusieurs graphiques dans le même fichier

Etape-1 - Sauvegarder individuellement tous les fichiers

- `graph var1 var2, saving(c:\rep\mongraph1)`
- `graph var1 var3, saving(c:\rep\mongraph2)`
- `graph var1 var4, saving(c:\rep\mongraph3)`

Etape-2 – Rappeler et sauvegarder tous les fichiers dans un même graphique

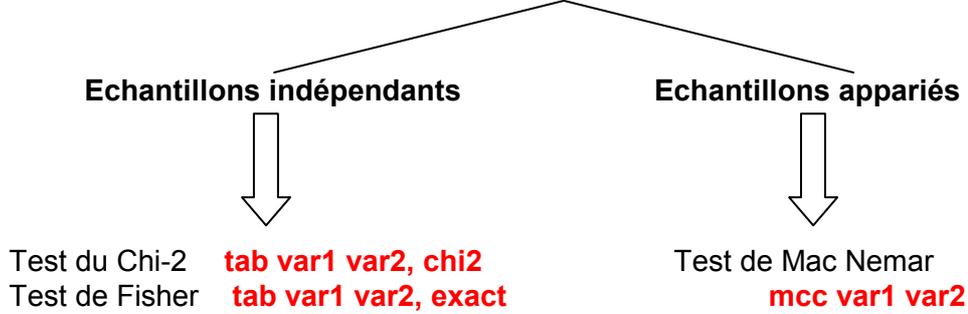
- `graph using c:\rep\mongraph1 c:\rep\mongraph2 c:\rep\mongraph3, saving c:\rep\graph123`

Etape-3 – Enregistrer le fichier comprenant tous les graphiques. A ce moment vous pouvez modifier le format d'enregistrement

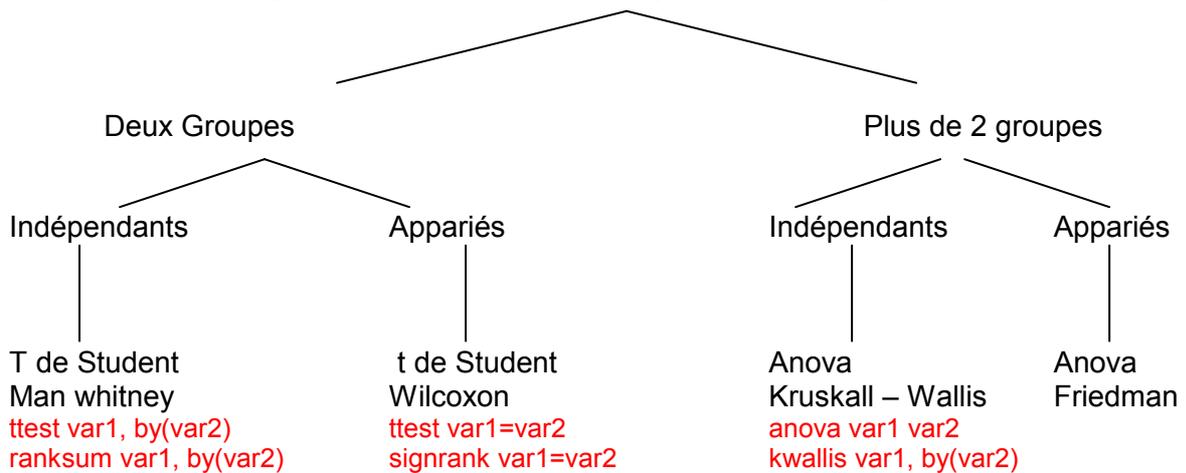
- `gphprint, saving c:\rep\graph123.wmf`

Introduction à l'analyse bivariable : quels tests faut-il choisir ?

Comparaison de variables qualitatives



Comparaison d'une variable quantitative et qualitative



Comparaison de 2 variables quantitatives



Association entre 2 variables qualitatives var1 et var2

1^{ère} partie : séries indépendantes

1) à partir d'une base de données

➤ **Tabulate var1 var2, chi2**

Ex : on veut savoir s'il existe une relation entre le fait d'avoir vécu seul (variable appelée : seul) et d'être placé en maison de retraite (variable appelée institut).

L'option **chi2** (de la commande tabulate) teste l'hypothèse nulle : l'indépendance entre les 2 variables c'est-à-dire qu'il y a autant de personnes ayant vécu seules que de personnes ayant vécu en couple dans les maisons de retraite. Le chi2 nous permettra de dire s'il est raisonnable de rejeter cette hypothèse.

On se fixe un seuil de décision de 5%, c'est-à-dire que l'on accepte de se tromper dans 5% des cas.

tabulate seul institut, row chi2

SEUL	INSTITUT		Total
	0	1	
0	168 82.35	36 17.65	204 100.00
1	38 69.09	17 30.91	55 100.00
Total	206 79.54	53 20.46	259 100.00

Pearson chi2(1) = 4.6813 Pr = 0.030

On obtient un tableau à 4 cases et stata nous apprend :

- que 17.65% des personnes vivant en couple sont parties en maison de retraite alors que 30.9% des personnes seules sont parties en maison de retraite
- que le chi2 à 1 ddl est égal à 4.68, si on consulte la tables du chi2, on voit que pour 1 ddl, une valeur supérieure à 3.84 s'observe dans moins de 5% des cas.

La différence est significative, donc on observe plus de personnes ayant vécu seules en maison de retraite que de personnes ayant vécu en couple et cette différence n'est pas due au hasard.

Autrement dit : $p = 0.03$ c'est la probabilité, si l'hypothèse nulle est vraie, que le hasard explique la différence observée ici. Or, cette probabilité est inférieure à 5% donc on conclue : les différences observées ne sont pas dues au seul hasard, il existe donc une différence significative à 5%.

On peut afficher les pourcentages en lignes et en colonnes :

tab seul institut, **row col** chi2

SEUL	INSTITUTB		Total
	0	1	
0	168	36	204
	82.35	17.65	100.00
	81.55	67.92	78.76
1	38	17	55
	69.09	30.91	100.00
	18.45	32.08	21.24
Total	206	53	259
	79.54	20.46	100.00
	100.00	100.00	100.00

Pearson chi2(1) = 4.6813 Pr = 0.030

Remarque importante : Contrairement à certains logiciels de statistiques, stata ne fait pas de test par défaut, mais seulement ceux qu'on lui demande, même si les conditions d'application ne sont pas respectées.

Rappel : pour le test du chi2, la condition d'application est d'avoir des effectifs théoriques supérieurs à 5.

Ex : on veut savoir s'il existe une relation entre le fait d'avoir une anorexie (variable appelée : nut) et d'être placé en maison de retraite (variable appelée institut).

$$\text{Test du chi2 } \chi^2 = \frac{\sum(o - c)^2}{C}$$

tabulate nut institut, chi2

NUT	INSTITUT		Total
	0	1	
0	202	48	250
1	1	3	4
Total	203	51	254

Pearson chi2(1) = 7.6390 Pr = 0.006

Stata a calculé le chi2 sans donner de message d'erreur, or certains effectifs théoriques sont inférieurs à 5, et dans ce cas, le résultat du chi2, n'est pas valide, et il est indispensable d'utiliser un test exact de Fisher.

Test exact de Fisher

➤ **Tabulate var1 var2, exact**

L'option **exact** (de la commande tabulate) permet d'obtenir un test exact de Fisher.

Cette option est valide pour une table 2x2 mais également pour une table r X c avec plusieurs lignes ou colonnes. Dans ce cas, le temps nécessaire à stata pour faire le calcul peut atteindre plusieurs minutes... et vous pouvez avoir recours à l'option break !

$$\text{test exact de Fisher : } P = \frac{(a + b)!(c + d)!(a + c)!(b + d)!}{a!b!c!d!(a + b + c + d)!}$$

. tabulate nut institut, exact

NUT	INSTITUT		Total
	0	1	
0	202	48	250
1	1	3	4
Total	203	51	254

Fisher's exact = 0.026
1-sided Fisher's exact = 0.026

2) Calcul direct sans base de données

Ex : dans un article, l'auteur déclare qu'il existe une relation entre le fait d'avoir vécu seul et d'être placé en maison de retraite mais ne vous donne pas le résultat du test, or, vous disposez des effectifs dans un tableau décrivant sa population d'étude.

La commande **tabi** teste l'hypothèse nulle : l'indépendance entre les 2 variables c'est à dire il y a autant de personnes ayant vécu seules que de personnes ayant vécu en couple dans les maisons de retraite. Le test nous permettra de dire s'il est raisonnable de rejeter cette hypothèse.

➤ **Tabi a b \ c d**

Où a, b, c et d sont les effectifs du tableau à 4 cases

row	col		Total
	1	2	
1	a	b	a+b
2	c	d	c+d
Total	a+c	b+d	a+b+c+d

Exemple : tabi 30 18 \ 38 14

row	col		Total
	1	2	
1	30	18	48
2	38	14	52
Total	68	32	100

1	30	18	48
2	38	14	52
Total	68	32	100

Fisher's exact = 0.289
 1-sided Fisher's exact = 0.179

NB :

- par défaut, stata donne le résultat d'un test de Fisher, mais on peut lui donner comme option chi2
- cette commande est valide pour les tableaux 2X2, mais également les tableaux r X c.

2^{ème} partie : séries appariées

1) à partir d'une base de données

➤ `mcc var1 var2`

2) calcul direct sans base de données

Ex : dans un article, l'auteur déclare que pour une série de sujets ayant bénéficié à un mois d'intervalle de 2 traitements différents (1 et 2) qu'il existe plus d'effets indésirables avec le traitement 1 qu'avec le traitement 2 mais ne vous donne pas le résultat du test, or, vous disposez des effectifs dans un tableau décrivant sa population d'étude. NB : chaque sujet a donc reçu les deux traitements.

La commande `mcci` teste l'hypothèse nulle : il y a autant d'évènements indésirables avec le traitement 1 qu'avec le traitement 2. Le test nous permettra de dire s'il est raisonnable de rejeter cette hypothèse.

Rappel : pour le test du chi2 de Mac Nemar (ou de Mantel-haenszel), la condition d'application est d'avoir la somme des paires discordantes supérieure ou égale à 10.

➤ `mcci a b c d`

Où a, b, c et d sont les effectifs du tableau à 4 cases

cas	témoins		Total
	expose	non expose	
expose	a	b	a+b
non expose	c	d	c+d
Total	a+c	b+d	a+b+c+d

Exemple : `mcci 16 4 12 18`

EI avec TTT2	EI avec TTT1		Total
	oui	non	
oui	16	4	20
non	12	18	30
Total	28	22	50

McNemar's chi2(1) = 4.00 Pr>chi2 = 0.0455
Exact McNemar significance probability = 0.0768

Proportion with factor

Cases	.4		
Controls	.56	[95% conf. interval]	
difference	-.16	-.3303945	.0103945
ratio	.7142857	.5128527	.9948355
rel. diff.	-.3636364	-.7797718	.0524991
odds ratio	.3333333	.0783559	1.099907 (exact)

Comparaison de moyennes

Par rapport à une moyenne théorique

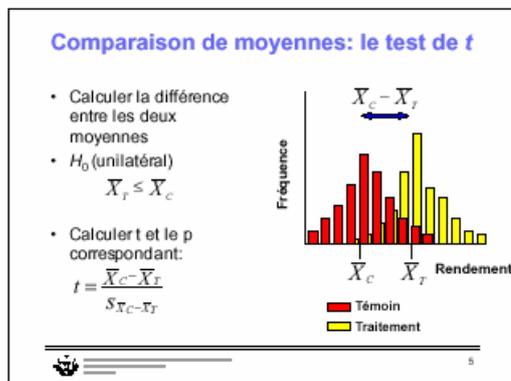
➤ `ttest var1 = #`

- `ttest age =10`

Permet de comparer la moyenne observée à une moyenne théorique dont la variance est inconnue

Pour deux échantillons indépendants

Test de Student : ttest



➤ `ttest var1, by(var2)`

☺ Option : `level`, permet de fixer l'intervalle de confiance choisi

- `ttest age, by(sexe)`

Two-sample t test with equal variances

Group	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf. Interval]	
1	43	10.39535	.363232	2.381871	9.662317	11.12838
2	73	9.191781	.2607342	2.227714	8.672017	9.711545
combined	116	9.637931	.2181414	2.349455	9.205835	10.07003
diff		1.203568	.439396		.3331279	2.074008

Degrees of freedom: 114

Ho: mean(1) - mean(2) = diff = 0

Ha: diff < 0	Ha: diff ~ = 0	Ha: diff > 0
t = 2.7391	t = 2.7391	t = 2.7391
P < t = 0.9964	P > t = 0.0072	P > t = 0.0036

Cette commande ne vous permet pas directement de vérifier l'hypothèse d'égalité des variances entre les groupes.

Analyse de variance à un facteur : oneway

➤ `oneway var1 var2, tab` ↵

`.oneway age sexe, tab`

Summary of Age			
sexe	Mean	Std. Dev.	Freq.
1	10.395349	2.3818714	43
2	9.1917808	2.2277139	73
Total	9.637931	2.3494553	116

Analysis of Variance					
Source	SS	df	MS	F	Prob > F
Between groups	39.1989652	1	39.1989652	7.50	0.0072
Within groups	595.594138	114	5.22450998		
Total	634.793103	115	5.51994003		

Bartlett's test for equal variances: $\chi^2(1) = 0.2379$ Prob> $\chi^2 = 0.626$

↵ Ce test vous permet de vérifier l'égalité des variances entre les groupes

☺ Option : `tab` vous permet d'obtenir les moyennes observées entre les groupes

Si les conditions d'utilisation des tests ne sont pas vérifiées

- ↵ normalité des distributions
- ↵ variances identiques entre les groupes

Vous devez alors utiliser un test non paramétrique

Test de Mann-Whitney : ranksum

Comparaison de deux moyennes: le test U de Mann-Whitney

- On veut comparer le rendement du groupe témoin et du groupe traitement. Chacun des groupes contient 4 champs (ch.) (réplicats)
- Calculer la somme des rangs (R_C , R_T) pour chacun des groupes.
- $H_0: R_C = R_T$
- Calculer U et le p correspondant

Ch.	Témoin		Traitement	
	Rendement	Rang	Rendement	Rang
1	20	2	19	1
2	36	6	41	7
3	28	3	33	5
4	31	4	45	8
Somme des rangs		15		21

➤ `ranksum var1, by(var2)` ↵

```
.ranksum age, by(sexe)
```

Two-sample Wilcoxon rank-sum (Mann-Whitney) test

sexe	obs	rank sum	expected
1	5	43.5	50
2	14	146.5	140
combined	19	190	190

```
unadjusted variance      116.67
adjustment for ties      -5.32
-----
adjusted variance       111.35
```

```
Ho: age(sexe==1) = age(sexe==2)
      z = -0.616
      Prob > |z| = 0.5379
```

Pour deux échantillons appariés

Ces tests sont basés sur la comparaison de la différence à 0

Test de Student pour séries appariées ttest

Condition d'utilisation : la différence a une distribution normale

➤ **ttest var1 =var2**

```
. ttest agecj5= agecj1
```

Paired t test

Variable	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf. Interval]	
agecj5	98	11.39128	.213929	2.117789	10.96669	11.81586
agecj1	98	10.06224	.21469	2.125322	9.636144	10.48834
diff	98	1.329031	.0325416	.3221454	1.264445	1.393617

Ho: mean(agecj5 - agecj1) = mean(diff) = 0

Ha: mean(diff) < 0
t = 40.8410
P < t = 1.0000

Ha: mean(diff) ~= 0
t = 40.8410
P > |t| = 0.0000

Ha: mean(diff) > 0
t = 40.8410
P > t = 0.0000

SI : la différence est distribuée normalement
SINON utilisez un test non paramétrique

Test des rangs de Wilcoxon : signrank

➤ **signrank var1=var2**

```
.signrank agecj5=agecj1
```

```
Wilcoxon signed-rank test
```

sign	obs	sum ranks	expected
positive	16	136	68
negative	0	0	68
zero	0	0	0
all	16	136	136

unadjusted variance	374.00
adjustment for ties	-0.75
adjustment for zeros	0.00
adjusted variance	373.25

```
Ho: agecj5 = agecj1
```

```
z = 3.520  
Prob > |z| = 0.0004
```

Calculs directs sans base de données

Test d'une moyenne observée à une moyenne théorique

```
➤ ttesti #obs #mean #sd #val, level(#)
```

```
. ttesti 97 24 6 22
```

One-sample t test

```
-----+-----  
      |      Obs      Mean   Std. Err.   Std. Dev.   [95% Conf. Interval]  
-----+-----  
      x |      97          24    .6092077         6    22.79073    25.20927  
-----+-----
```

Degrees of freedom: 96

```
Ho: mean(x) = 22  
Ha: mean < 22      Ha: mean ~= 22      Ha: mean > 22  
t = 3.2830          t = 3.2830          t = 3.2830  
P < t = 0.9993     P > |t| = 0.0014     P > t = 0.0007
```

Test de deux moyennes issues d'échantillons indépendants

```
➤ ttesti #obs1 #mean1 #sd1 #obs2 #mean2 #sd2 , level(#) unequal
```

```
. ttesti 97 24 6 108 22 9
```

Two-sample t test with equal variances

```
-----+-----  
      |      Obs      Mean   Std. Err.   Std. Dev.   [95% Conf. Interval]  
-----+-----  
      x |      97          24    .6092077         6    22.79073    25.20927  
      y |     108          22    .8660254         9    20.28321    23.71679  
-----+-----  
combined |     205    22.94634    .5429301    7.773576    21.87587    24.01682  
-----+-----  
diff |          2    1.081026          - .1314797    4.13148  
-----+-----
```

Degrees of freedom: 203

```
Ho: mean(x) - mean(y) = diff = 0  
Ha: diff < 0      Ha: diff ~= 0      Ha: diff > 0  
t = 1.8501          t = 1.8501          t = 1.8501  
P < t = 0.9671     P > |t| = 0.0658     P > t = 0.0329
```

Pour plus de deux échantillons indépendants : Analyse de variance

Pourquoi ne pas utiliser plusieurs tests de t?

- Pour un nombre de comparaisons k , si H_0 est vraie, la probabilité de l'accepter pour tous les k est $(1 - \alpha)^k = (0.95)^4 = .735$
- alors, α (pour toutes les comparaisons) = 0.265
- alors en comparant les moyennes des quatre échantillons provenant de la même population on s'attend à détecter des différences significatives pour une paire dans 27% des cas

Tableau d'ANOVA

Sources de variation	Somme des carrés	Degré de liberté (df)	Carré moyen (MS)	F
Totale	$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2$	$n - 1$	SC/df	
Inter-groupe	$\sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2$	$k - 1$	SC/df	$\frac{MS_{intergroupe}}{MS_{erreur}}$
Erreur	$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$	$n - k$	SC/df	

Conditions d'application de l'ANOVA

- Les résidus sont indépendants les uns des autres
- Les résidus sont distribués normalement
- La variance des résidus ne varie pas entre les traitements (homoscédasticité)
- À noter: ces conditions s'appliquent aux résidus et non aux données brutes
- ...on doit tester les conditions d'application après que l'analyse soit faite et que les résidus soient obtenus

Anova

➤ Anova var1 var2 ↵

```
. anova age var1
```

Number of obs =	116	R-squared =	0.6845
Root MSE =	1.33126	Adj R-squared =	0.6789

Source	Partial SS	df	MS	F	Prob > F
Model	434.528736	2	217.264368	122.59	0.0000
var1	434.528736	2	217.264368	122.59	0.0000
Residual	200.264368	113	1.77225104		
Total	634.793103	115	5.51994003		

Vérifications des conditions d'application

➤ Predict res ↵

Création d'une nouvelle variable qui correspond à l'erreur d'estimation individuelle

- `swilk res` ↵ ou
 - `sktest res` ↵ ou
 - `pnorm res` ↵ ou
 - `kdensity res, normal`
- permet de tester la normalité

- `Levenef res` ↵ ou
 - `oneway res var1` ↵ ou
 - `graph res, box by(var1)`
- Permet de tester l'homoscédasticité

Pour pouvoir interpréter les résultats il faut faire apparaître le tableau de moyennes en fonction des groupes

- `Table var1, c(mean age sd age n age)` ↵

var1	mean (age)	sd (age)	N (age)
1	4.5	.5773503	4
2	8.90805	1.386246	87
3	13	1.190238	25

- ☺ Options possibles : `f(%#. # f)` pour formater les cellules
`col` pour avoir la moyenne par colonne
`row` pour avoir la moyenne par ligne
`c` pour afficher les indicateurs (maximum 5)
 (min max med n mean sd)

```
table var1, c(mean age sd age n age min age max age ) f( %6.2f) row
```

var1	mean (age)	sd (age)	N (age)	min (age)	max (age)
1	4.50	0.58	4	4.00	5.00
2	8.91	1.39	87	6.00	11.00
3	13.00	1.19	25	12.00	16.00
Total	9.64	2.35	116	4.00	16.00

Si les conditions d'utilisations ne sont pas respectées utilisez un test non paramétrique.

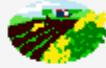
Test de Kruskal et Wallis

L'alternative non-paramétrique: ANOVA de Kruskal-Wallis

- Calculer la somme des rangs (Rg) pour chaque groupe
- $H_0: R_1 = R_2 = R_3$
- Calculer la statistique K-W H:

$$H = \frac{12}{N(N+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(N+1)$$

- qui est distribué comme χ^2 avec k-1 df si N pour chaque groupe est assez grand, autrement, utiliser la valeur critique de H



Champ	Témoin		Traitement 1		Traitement 2	
	Rendement	Rang	Rendement	Rang	Rendement	Rang
1	24	3	25	4	32	9
2	19	1	20	2	27	6
3	28	7	30	8	36	11
4	26	5	33	10	41	12
Somme des rangs		16	24	38		

➤ **Kwallis var1, by(var2)**

```
. kwallis pj1, by(var1)
Test: Equality of populations (Kruskal-Wallis Test)

      var1      _Obs      _RankSum
      ----      ----      -
      0             52      3068.50
      1             51      2945.00
      2             13       772.50

chi-squared =      0.047 with 2 d.f.
probability =      0.9766

chi-squared with ties =      0.047 with 2 d.f.
probability =      0.9766
```

Anova à deux facteurs

➤ **Anova quant1 var1 var2 var1*var2**

```
anova age var1 scol var1*scol

              Number of obs =      115      R-squared      = 0.7024
              Root MSE      = 1.31604      Adj R-squared = 0.6888

-----+-----
Source | Partial SS      df      MS      F      Prob > F
-----+-----
Model | 445.598703      5      89.1197407      51.46      0.0000
-----+-----
var1 | 344.016225      2      172.008112      99.31      0.0000
scol | 2.55585275      1      2.55585275      1.48      0.2271
var1*scol | .370916338      2      .185458169      0.11      0.8985
-----+-----
Residual | 188.783905      109      1.73196243
-----+-----
Total | 634.382609      114      5.56475973
```

➤ **Table var1 var2, c(mean quant1 sd quant1 n quant1)**

```
. table var1 scol, c(mean age sd age n age) f(%6.2f) row col
```

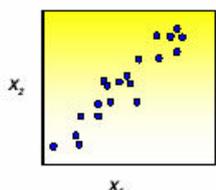
var1	scol		
	0	1	Total
1	4.33	5.00	4.50
	0.58		0.58
	3	1	4
2	8.74	9.56	8.91
	1.33	1.46	1.39
	68	18	86
3	12.81	13.33	13.00
	1.22	1.12	1.19
	16	9	25
Total	9.33	10.61	9.64
	2.25	2.47	2.36
	87	28	115

Comparaison de 2 variables quantitatives : Tests de corrélation

Mesure de la corrélation

- Le coefficient de corrélation, r , entre deux variables avec n paires d'observations est calculé comme:

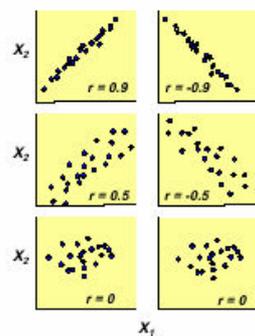
$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

$$= \frac{\text{Cov}(X, Y)}{\sigma_x \sigma_y}$$


X_2
 X_1

Mesure de la corrélation

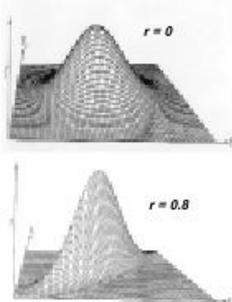
- r se situe toujours entre -1 et 1.
- r^2 est le *coefficient de détermination* qui mesure la proportion de la variabilité d'une variable qui peut être "expliquée" par l'autre.



X_2
 X_1

Hypothèses implicites I: distribution binormale

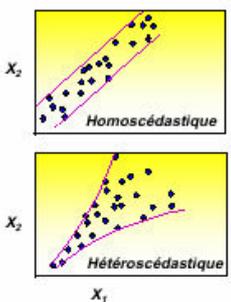
- Pour chaque valeur de X_1 , les valeurs de X_2 sont normalement distribuées et vice versa.



$r = 0$
 $r = 0.8$

Hypothèses implicites II: Homoscédasticité

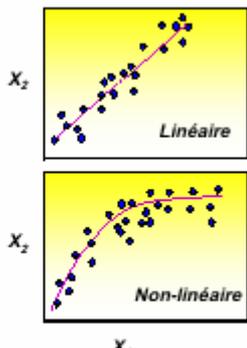
- La variance de X_1 est indépendante de celle de X_2 et vice versa.
- Mais les variances de X_1 et X_2 ne sont pas nécessairement égales.



X_2
 X_1

Hypothèses implicites III: Linéarité

- La relation entre X_1 et X_2 est linéaire.



X_2
 X_1

Coefficient de corrélation

Conditions d'application :

Régression entre x et y est linéaire

Une des 2 distributions est normale et de variance constante par rapport à l'autre

➤ Corr ↵

Donne la matrice de corrélation de toutes les variables de la base
Utiliser si le nombre de variables est petit

➤ Corr var1 var2 ↵

Donne le coefficient de corrélation de la var1 et de la var2

☺ Options possibles :

means donne m, sd, min et max des variables
C donne la covariance de x et y

```
. corr pbil tbil  
(obs=115)
```

```
-----+-----  
          |      pbil      tbil  
-----+-----  
pbil |      1.0000  
tbil |      0.8904      1.0000
```

```
corr pbil tbil, c  
(obs=115)
```

```
-----+-----  
          |      pbil      tbil  
-----+-----  
pbil |      255.67  
tbil |      189.407      176.998
```

Pour tester la significativité du coefficient de corrélation vous devez utiliser un autre test

➤ pwcorr var1 var2 ↵

☺ Options possibles :

obs : nbre de sujets

sig : test de significativité

b pour tenir compte des comparaisons multiples (bonferroni)

```
pwcorr pbil tbil
```

```
-----+-----  
          |      pbil      tbil  
-----+-----  
pbil |      1.0000  
tbil |      0.8904      1.0000
```

```
pwcorr pbil tbil, obs sig
```

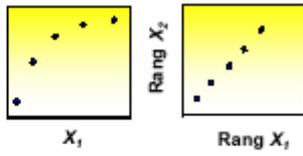
```
-----+-----  
          |      pbil      tbil  
-----+-----  
pbil |      1.0000  
      |           116  
      |           116  
tbil |      0.8904      1.0000  
      |           0.0000  
      |           115      115  
      |           115
```

Test non paramétrique de corrélation

Test de corrélation des rangs de Spearman

Corrélations non-paramétriques

- Utiliser si une ou plusieurs des conditions d'application ne sont pas respectées.
- C'est une corrélation de rang.
- La méthode la plus commune: corrélation de rang de Spearman.


$$r_s = 1 - \frac{6 \sum_{j=1}^N (R_{X_1} - R_{X_2})^2}{N^3 - N}$$

Observation	X_1		X_2	
	Valeur	Rang	Valeur	Rang
1	3.5	5	25.4	5
2	5.0	4	43.7	4
3	6.5	3	52.9	3
4	8.0	2	56.3	2
5	9.5	1	58.7	1

20

H0 : les variables sont indépendantes

➤ `spearman var1 var2`

```
. spearman pbil tbil if num<20

Number of obs =      19
Spearman's rho =      0.8097

Test of Ho: pbil and tbil independent
Pr > |t| =      0.0000
```

Courbes ROC (Receiver Operating Characteristic)

➤ roctab refvar var1 ↵

La variable de référence correspond à votre gold standard, elle doit être dichotomique codée en 0 et 1

La variable var1 est une variable quantitative continue, les valeurs les plus hautes doivent correspondre aux sujets les plus à risque

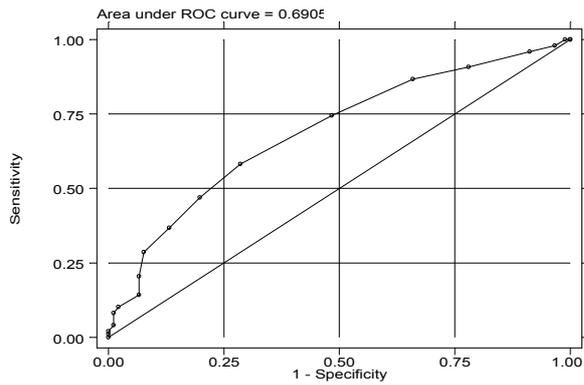
Options possibles : tab donne la table de contingence
 Détail affiche la sensibilité, la spécificité, les rapports de vraisemblance positif et négatif, le % de sujets bien classés
 Nograph : annule la sortie graphique
 Level (#) : IC de l'aire sous la courbe
 cont(#) Spécifie le nombre de groupe étudié à partir de la variable quantitative. Cette option est obligatoire si la variable quantitative possède plus de 20 valeurs distinctes.

```
. roctab volemie dppl,detail
```

Detailed report of Sensitivity and Specificity

Cut point	Sensitivity	Specificity	Correctly Classified	LR+	LR-
(>= 0)	100.00%	0.00%	51.85%	1.0000	
(>= 1)	100.00%	1.10%	52.38%	1.0111	0.0000
(>= 2)	97.96%	3.30%	52.38%	1.0130	0.6190
(>= 3)	95.92%	8.79%	53.97%	1.0516	0.4643
(>= 4)	90.82%	21.98%	57.67%	1.1640	0.4179
(>= 5)	86.73%	34.07%	61.38%	1.3155	0.3894
(>= 6)	74.49%	51.65%	63.49%	1.5406	0.4939
(>= 7)	58.16%	71.43%	64.55%	2.0357	0.5857
(>= 8)	46.94%	80.22%	62.96%	2.3730	0.6614
(>= 9)	36.73%	86.81%	60.85%	2.7857	0.7288
(>= 10)	28.57%	92.31%	59.26%	3.7143	0.7738
(>= 11)	20.41%	93.41%	55.56%	3.0952	0.8521
(>= 12)	14.29%	93.41%	52.38%	2.1667	0.9176
(>= 13)	10.20%	97.80%	52.38%	4.6429	0.9181
(>= 14)	8.16%	98.90%	51.85%	7.4286	0.9286
(>= 15)	4.08%	98.90%	49.74%	3.7143	0.9698
(>= 16)	2.04%	100.00%	49.21%		0.9796
(>= 17)	1.02%	100.00%	48.68%		0.9898
(> 17)	0.00%	100.00%	48.15%		1.0000

Obs	ROC Area	Std. Err.	-Asymptotic Normal-- [95% Conf. Interval]	
189	0.6905	0.0382	0.61570	0.76532



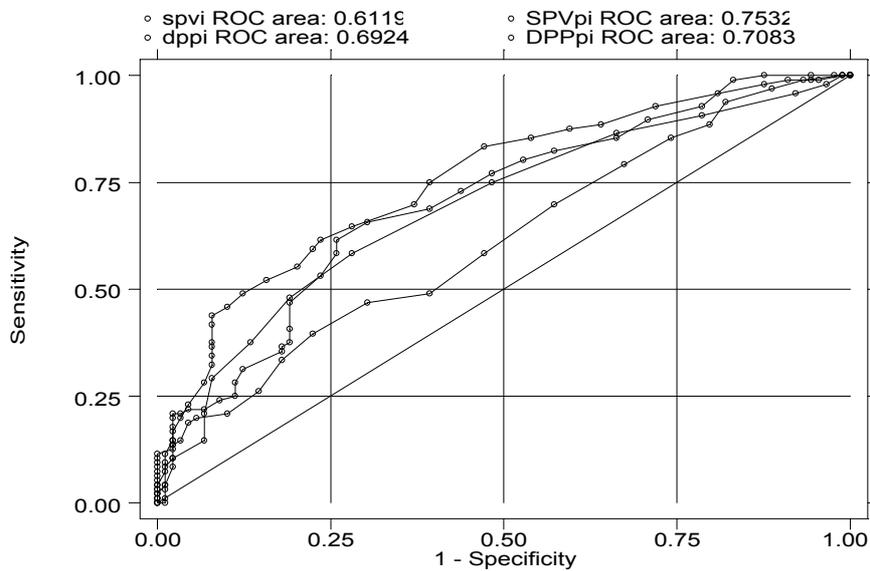
➤ **Rocomp refvar var1 var2**

Permet la comparaison des aires sous la courbes

```
. roccomp volemie spvi SPVpi dppi DPPpi
```

	Obs	ROC Area	Std. Err.	-Asymptotic Normal-- [95% Conf. Interval]	
DPPpi	185	0.7083	0.0378	0.63420	0.78247
SPVpi	185	0.7532	0.0354	0.68383	0.82260
dppi	185	0.6924	0.0386	0.61682	0.76801
spvi	185	0.6119	0.0411	0.53138	0.69252

Ho: area(DPPpi) = area(SPVpi) = area(dppi) = area(spvi)
 chi2(3) = 21.40 Pr>chi2 = 0.0001



Introduction à l'analyse multivariée

L'analyse multivariée ou modélisation vous permet de tenir compte de l'effet propre des variables que vous étudiez et des facteurs de confusion.

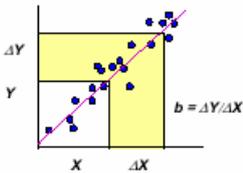
Quand la variable à expliquer est quantitative

Régression linéaire

Rappel de modélisation issu du cours du Dr Morin de l'Université d'Ottawa
<http://simulium.bio.uottawa.ca/bio4518/>

Ce qu'elle fait

- Ajuste une ligne droite à travers un nuage de points
- Teste et quantifie l'effet d'une variable **indépendante** X sur la variable **dépendante** Y
- L'intensité de l'effet est donnée par la pente (b) de la régression
- L'importance de l'effet est donné par le coefficient de détermination (r^2)

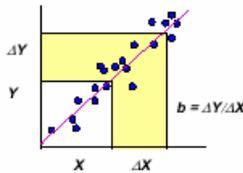


$b = \Delta Y / \Delta X$

2

Ce qu'elle fait

- Ajuste une ligne droite à travers un nuage de points
- Teste et quantifie l'effet d'une variable **indépendante** X sur la variable **dépendante** Y
- L'intensité de l'effet est donnée par la pente (b) de la régression
- L'importance de l'effet est donné par le coefficient de détermination (r^2)



$b = \Delta Y / \Delta X$

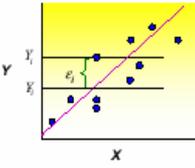
2

Comment

- Par la méthode des moindres carrés qui consiste à minimiser la somme des écarts au carré entre les observations et la droite de régression, c'est-à-dire, minimiser les résidus
- L'écart au carré d'une observation est donnée par:

$$\epsilon_i^2 = (Y_i - \hat{Y}_i)^2$$

Résidu: $\epsilon_i = Y_i - \hat{Y}_i$



4

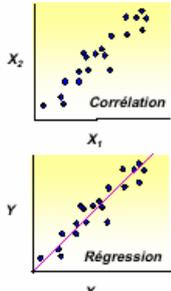
Régression ou corrélation?

- Corrélation:** degré d'association entre deux variables X et Y, pas de relation causale impliquée.
- Régression:** permet de prédire la valeur de la variable dépendante pour une valeur donnée de la variable indépendante. Implique une relation causale.

5

Quand utiliser la régression?

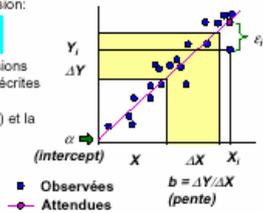
- Ne pas l'utiliser pour déterminer le degré d'association entre deux variables
- L'utiliser si on veut faire des prédictions



6

Modèle d'une régression linéaire simple

- Le modèle de la régression: $Y_i = \alpha + bX_i + \epsilon_i$
- alors, toutes les régressions linéaires simples sont décrites par deux paramètres, l'ordonnée à l'origine (α) et la pente (b)



$b = \Delta Y / \Delta X$ (pente)

7

Hypothèses implicites

- Les résidus sont indépendants et normalement distribués
- La variance des résidus est égale pour tous les X (homoscédasticité)
- La relation entre Y et X est linéaire
- Il n'y a pas d'erreur de mesure sur X (régression de type I)



8

Erreur de mesure

- Cette condition peut être vérifiée avant l'analyse
- on s'en préoccupe si l'erreur est grande par rapport à X (> 10%)
- si cette condition n'est pas respectée, utiliser la régression de type II



9

Robustesse de la régression aux violations des conditions d'application

Conditions d'application	Robustesse	Remarque
Normalité	Élevée	Seulement si la taille de l'échantillon >10
Indépendance	Basse	Mais dépend de la force de la corrélation
Homoscédasticité	Basse	Spécialement pour les petits échantillons
Linéarité	Basse	Assurez vous d'avoir celle-là!
Pas d'erreur sur X	Élevée	Si l'erreur < 10% c'est ok, sinon utiliser le type II



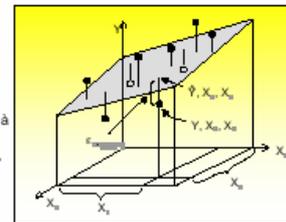
14

Le modèle général de la régression multiple

•Le modèle général:

$$Y_i = \alpha + \sum_{j=1}^k \beta_j X_{ij} + \varepsilon_i$$

qui définit un plan à k-dimensions, ou α = ordonnée à l'origine, β_j = coefficient de régression partiel de Y sur X_j , X_j est la valeur de la jème observation de la variable dépendante X_j , et ε_i est la valeur des résidus de la ième observation.



4

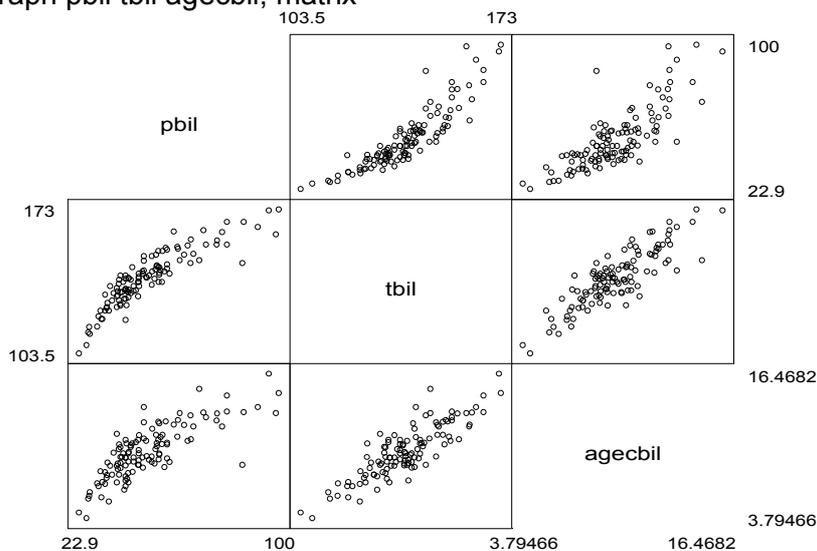
Commandes sous Stata

`regress var1 var2 var3` ↗

Ex : effet de l'âge et de la taille sur le poids des enfants

Vérifier que la taille et le l'âge sont linéairement associés au poids

`graph pbil tbil agec bil, matrix`



Regarder la force de l'association entre le poids et l'âge et le poids et la taille

```
regress pbil agecbil
```

Source	SS	df	MS		Number of obs =	116
Model	18500.607	1	18500.607		F(1, 114) =	197.47
Residual	10680.2632	114	93.6865195		Prob > F =	0.0000
					R-squared =	0.6340
					Adj R-squared =	0.6308
Total	29180.8703	115	253.746698		Root MSE =	9.6792

pbil	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
agecbil	5.432455	.3865821	14.053	0.000	4.666639	6.198271
_cons	-2.907795	3.839573	-0.757	0.450	-10.51396	4.698369

```
regress pbil tbil
```

Source	SS	df	MS		Number of obs =	115
Model	23106.321	1	23106.321		F(1, 113) =	432.28
Residual	6040.03937	113	53.4516758		Prob > F =	0.0000
					R-squared =	0.7928
					Adj R-squared =	0.7909
Total	29146.3604	114	255.669828		Root MSE =	7.3111

pbil	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
tbil	1.070112	.0514688	20.791	0.000	.9681426	1.172081
_cons	-100.0593	7.230332	-13.839	0.000	-114.3839	-85.7347

Regarder l'effet de la taille sur le poids à âge égal

```
. regress pbil tbil agecbil
```

Source	SS	df	MS		Number of obs =	115
Model	23209.4103	2	11604.7052		F(2, 112) =	218.92
Residual	5936.95007	112	53.0084827		Prob > F =	0.0000
					R-squared =	0.7963
					Adj R-squared =	0.7927
Total	29146.3604	114	255.669828		Root MSE =	7.2807

pbil	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
tbil	.949502	.1005334	9.445	0.000	.750308	1.148696
agecbil	.7974374	.5718241	1.395	0.166	-.3355588	1.930434
_cons	-90.90416	9.743854	-9.329	0.000	-110.2104	-71.59796

Conclusion à âge égal seule la taille explique la variation du poids

Vérification des hypothèses sous jacentes

Predict res

Calcule les résidus de la régression

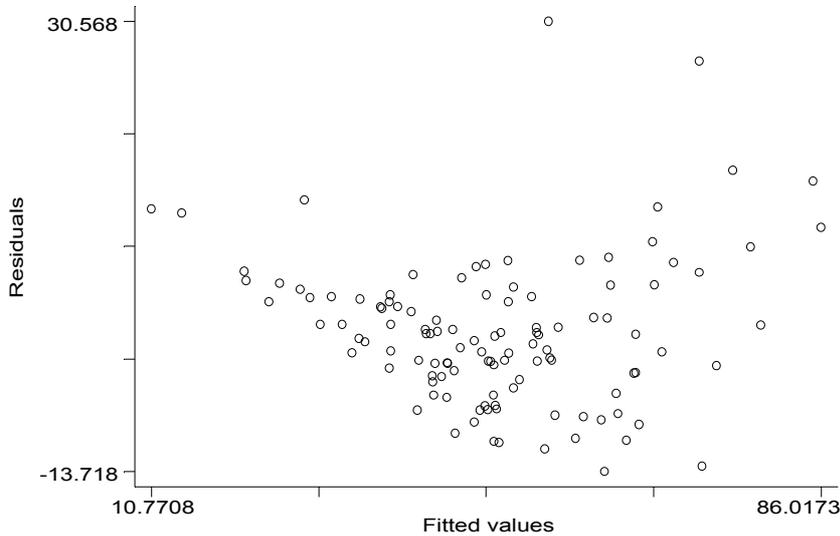
swilk res ↵ ou

sktest res ↵ ou

pnorm res ↵ ou

kdensity res, normal
 permet de tester la normalité

rvfplot



Permet de tester l'indépendance des résidus

Quand la variable à expliquer est dichotomique

Régression logistique

➤ **Logit varY varX1 varX2** pour obtenir les coefficients

Où varY est la variable à expliquer et varX1, VarX2 les variables explicatives.

```
logit varY VarX1 VarX2 VarX3
```

```
Logit estimates                               Number of obs   =          74
                                                LR chi2(3)      =          29.20
                                                Prob > chi2     =          0.0000
Log likelihood = -30.431911                    Pseudo R2      =          0.3242
```

varY	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
VarX1	2.463793	.6897299	3.572	0.000	1.111947 3.815639
VarX2	-.0008301	.0003781	-2.195	0.028	-.0015712 -.000089
VarX3	-.9703005	.5309147	-1.828	0.068	-2.010874 .0702732
_cons	2.010878	1.662173	1.210	0.226	-1.246921 5.268678

➤ **Logistic varY varX1 varX2** pour obtenir les OR

```
. logistic varY VarX1 VarX2 VarX3
```

```
Logit estimates                               Number of obs   =          74
                                                LR chi2(3)      =          29.20
```

Log likelihood = -30.431911

Prob > chi2 = 0.0000
Pseudo R2 = 0.3242

varY	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
VarX1	11.74929	8.103839	3.572	0.000	3.040273	45.40576
VarX2	.9991702	.0003778	-2.195	0.028	.99843	.999911
VarX3	.3789691	.2012003	-1.828	0.068	.1338716	1.072801