

EXERCICES : GESTION de DONNÉES

G-1 : ajout de variables, formule, assignation texte/numérique, tri, coloriage

Ouvrir la feuille de données STATISTICA : *Agressivité.sta* (3v par 50c).

La feuille contient le sexe de l'individu et deux variables (AGR1 et AGR2). Ces variables mesurent, sur une échelle de 0 (doux) à 10 (violent), l'indice d'agressivité lorsque mis en face de deux situations susceptibles d'une réaction dans le cadre d'une simulation.

- (a) Ajouter une nouvelle variable $AGR = (AGR1 + AGR2)/2$
 (b) Ajouter une nouvelle variable CLAGR : agressivité de l'individu selon 4 niveaux :

AGR	CLAGR
(0.00, 0.25]	faible
(0.25, 0.50]	moyenne
(0.50, 0.75]	forte
(0.75, 1.00]	élevée

- (c) Quel code numérique a été assigné à la variable CLAGR ?
 Remplacer le code numérique par les 4 valeurs suivantes : 1 – 2 – 3 – 4.
 (d) Trier les observations par SEXE et selon les valeurs croissantes de AGR.
 (e) Colorer en jaune : les cellules de sexe féminin ayant une valeur de AGR > 0.76
 (f) Changer la police de caractères par « Times New Roman » ; centrer toutes les colonnes.

G-2 : importation, en-tête, format, tri, moyenne, écart type

Ouvrir la feuille de données EXCEL : *Température.xls*

La feuille contient 4 variables : Date, Ville, Température (degrés F), Condition atmosphérique de 30 villes américaines en date du 22, 23 ou 24 Août 1998.

- (a) Importer la feuille dans une feuille de données STATISTICA ; sauvegarder le fichier sous le nom *Température.sta*
 (b) Ajouter un en-tête descriptif au fichier.
 (c) Changer le format de la variable DATE pour le format : mois-année, (AUG-1998).
 (d) Transformer la température en degrés Celsius.
 (e) Trier les observations en ordre de température croissante. Quelle ville a la température la plus élevée ?
 (f) Trouver la moyenne et l'écart type de la variable *température*.

G-3 : création d'une feuille de données, saisie de données, assignation d'un nom pour les observations (cas), ajout/élimination variables/ observations statistiques de blocs

- (a) Créer une nouvelle feuille de données avec le nom *EX-G3.sta*
 Saisir les 12 observations des 5 variables suivantes : ID1, ID2, X, Y, Z

ID1	ID2	X	Y	Z
1	AB	4	14	101.3
2	CD	7	-2	21.8
3	EF	9	7	122.1
4	GH	8	16	131.9
5	IJ	12	-22	99.2
6	KL	3	49	88.5
7	MN	5	-17	110.0
8	OP	7	6	87.4
9	QR	1	19	24.7
10	ST	2	-15	45.5
11	UV	1	-36	17.2
12	WX	4	0	99.6

le fichier « nouveau » contient toujours

10 variables (colonnes) par 10 observations. (lignes)

Il faudra ajouter 2 lignes

Utilisez le bouton "Observations".

- (b) Ajouter un "en tête de fichier" intitulé « fichier pour l'exercice G-3 ».
Sauvegarder la feuille avec la commande "Enregistrez sous...".
- (c) Nommer les observations avec la variable ID2. Employer "Gestionnaire de Noms d'Observations"
- (d) Éliminer la colonne 10. Employez le bouton "Variables".
- (e) Définir, dans les colonnes 6 à 9, les variables R (colonne 6), S (colonne 7), T (colonne 8) U (colonne 9). Les équations de définition sont :

$$R = X + Y + Z ; \quad S = \text{Log}10(R^2) ; \quad T = R^2 + \text{Rnd}(100) ; \quad U = 100 + \text{RndNormal}(10)$$

Ouvrir la boîte de dialogue à l'aide d'un double clic sur le nom de la variable

Rnd (100) : données simulées selon loi uniforme sur (0,100)

RndNormal(10) : données simulées selon loi normale de moyenne 0 et d'écart type 10

Sauvegarder la feuille sous le même nom.

- (f) Ajouter 5 rangées (cases) additionnelles après la rangée 12. Employez le bouton "Observations".
- (g) Saisir le bloc formé par les colonnes ID2, X, Y, Z et les rangées 1, 2, 3, 4, 5 (le bloc est en noir) et copier ce bloc ("Copier de Edition") et collez le bloc ("Coller de Edition") dans les rangées 13 à 17 et les colonnes ID2, X, Y, Z.
- (h) Déplacer les variables R, S, T, U après la colonne ID2. Faites une sauvegarde du fichier sous le nom EXG3-A. L'opération suivante (i) sera exécutée sur ce fichier.
- (i) Obtenir toutes les statistiques : MIN -MAX - MOYENNE - ÉCART TYPE des variables X, Y, Z avec la commande "Statistiques de blocs" du bouton Statistiques de la barre principale de STATISTICA. Sauvegardez le résultat sous le nom EXG3-B.

G-4 : type de variables valeurs de date, saisie rapide des données par extrapolation

- (a) Créer une nouvelle feuille de données avec le nom EX-G4.sta (5v par 100c).
Nommer les variables : ID JOUR MOIS AN MACHINE (dans cet ordre)
- ID variable numérique avec une décimale.
- JOUR, AN variables de type entier.
- MOIS variable de type texte avec les codes numériques suivants :
- | | | | |
|-------------|-------------|----------|-----------|
| janvier = 1 | février = 2 | mars = 3 | avril = 4 |
|-------------|-------------|----------|-----------|
- MACHINE variable de type texte.
- (a) Sauvegarder le fichier.
- (b) Compléter la feuille de données selon les informations suivantes.
1. ID commence à 10.0 et se poursuit avec 10.1, 10.2,
 2. JOUR : valeur de 15 pour les observations 1 à 20
valeur de 16 pour les observations 21 à 40
valeur de 17 pour les observations 41 à 60
valeur de 18 pour les observations 61 à 80
valeur de 19 pour les observations 81 à 100
 3. MOIS : janvier pour les cas 1 à 5
février pour les cas 6 à 10
mars pour les cas 11 à 15
avril pour les cas 16 à 20
recommencer la structure précédente pour les cas 21 à 40,, 81 à 100
 4. AN : commencer en 1901 suivie de 1902, 1903,, 2000
 5. MACHINE : cas 1 à 25 machine = A
cas 26 à 75 machine = B
cas 76 à 100 machine = A
- (c) Ajouter une sixième variable : DATE combinant les variables JOUR /MOIS /AN en une seule colonne dans un format d'affichage « date » de Statistica.

G - 5 : ajout de variables, recodification, tri, statistiques de blocs, formules

Ouvrir la feuille de données : *Baseball.sta* (7v par 40c)

- Trier les données par année (YEAR) en ordre croissant et, pour chaque année, en ordre décroissant de la variable BA (moyenne au bâton).
- À quel numéro de cas correspond la meilleure moyenne au bâton en 1967?
- Introduire une nouvelle variable SCORE dans la feuille

$$\text{SCORE} = 1000 * (\text{RUNS} + \text{DP}) / \text{WALKS}.$$
- Introduire une nouvelle variable TYPE de match dans la feuille :

Score < 1600	TYPE = ennuyeux
1600 ≤ Score < 1900	TYPE = normal
1900 ≤ Score	TYPE = excitant

Durant la période de 1965 à 1968, y a-t-il eu plus de matchs ennuyeux que de matchs excitants ?

EXERCICES : ANALYSE STATISTIQUE de BASE Module Statistiques Élémentaires et fonctions Graphiques

Ouvrir la feuille de données : *Expérience mémoire.sta* (8v par 48c)

Mettre tous les résultats de cet exercice dans une filière que l'on nommera : *Expérience .mémoire.stw*

S -1 : statistiques descriptives, décompositions , vérification normalité, test -t

- variable STRESS - Calculer la moyenne l'écart type, le 5^{ème} percentile, le 95^{ème} percentile
- variable STRESS - La variable est-elle normalement distribuée ?
- variable STRESS - Calculer la moyenne et la variance selon la variable SEXE.
- variable STRESS - Si on veut comparer les moyennes de STRESS pour les hommes et les femmes allez vous employer un test t (par groupe) ou un test non paramétrique?

S - 2 : corrélations, tests de significatifs, p-level

Ouvrir la feuille de données : *Textile2.sta* (5v par 27c)

Il s'agit de données obtenues par l'exécution d'un plan expérimental avec 3 facteurs variant à 3 modalités.

- Trouver les coefficients de corrélations entre les variables LOAD, AMPLITUDE, LENGHT, LOG_CYCL. Les trois premières variables sont les facteurs contrôlés de l'expérience et LOG_CYCL représente la variable de réponse.
- Quels sont les coefficients qui sont statistiquement significatif au seuil de 0.05?
- Tracer le nuage de points de LENGTH et LOG_CYCL.
- Créer le graphique de réponse de LOG_CYCL en fonction de LENGTH et LOAD. Quel est le comportement de la réponse lorsque LOAD décroît et que LENGTH croît?
- Tracer le graphique de normalité des variables CYCLES et LOG_CYCL. Les variables suivent-elles loi normale?
- Tracer le graphique Quantile-Quantile et le graphique Probabilité-Probabilité. Comparer les graphiques de la question (f) avec les graphiques de la question (e).

S - 3 : test t pour échantillons indépendants, diagramme Boîte à Moustaches

Ouvrir la feuille de données : *Machine.sta* (5v par 55c)

- Comparer les 2 machines avec un test t pour 2 échantillons indépendants. Faites le test avec les variables des 2 premières colonnes seulement.
Les hypothèses de base pour exécuter d'un test t sont-elles vérifiées?
- Résumer le résultat du test t avec un diagramme boîte à moustaches.
- Les colonnes 3 et 4 contiennent les mêmes données que les colonnes 1 et 2 mais organisées différemment. Exécuter le test t de comparaison des machines en employant les colonnes 4 et 5.

Comparer avec le résultat obtenu avec le résultat obtenu en (a).

S – 4 : décompositions, statistiques de groupes, ANOVA, comparaison a posteriori

Ouvrir la feuille de données : *Ventes GSC Inc.sta* (13v par 130c)

- Représenter avec un seul graphique, le volume (axe vertical) par période (axe horizontal) pour chaque région. **Suggestion** : employer les variables des colonnes 8 à 13.
- Employer la procédure *Décompositions & ANOVA à 1 facteur* du module *Statistiques Élémentaires* pour comparer le volume des ventes des 6 régions entre les années 1996 et 2000. Le volume moyen du volume des ventes est-il statistiquement différent au seuil de 0.05?
- Obtenir les différents graphiques qui permettent de visualiser les données et de vérifier si les données suivent une distribution normale.
- Obtenir le résultat du test de comparaison *Post Hoc (a posteriori)* HSD de Tukey permettant de comparer les régions 2 à 2.

S – 5 : tableaux et tris croisé, test du khi deux, graphique d'interaction d'effectifs

Ouvrir la feuille de données : *Funmage.sta* (2 v par 50 c)

- Obtenir une table de fréquences pour la variable catégorie d'âge.
- L'âge est-elle liée à l'habitude de fumer? En d'autres termes existe-t-il une relation entre la variable catégorie d'âge et le fait d'être un fumeur? **Suggestion** : exécuter un test du khi deux.
- Obtenir un graphique d'interaction des fréquences.

S – 6 : tests non paramétriques

Ouvrir la feuille de données : *Animaux.sta* (2 v par 24 c)

- Vérifier au moyen d'un graphique que la variable POIDS ne suit pas une distribution normale.
- Exécuter un test de Mann-Whitney pour comparer le groupe contrôle avec le groupe traitement. Fixer le seuil à 0.10.
- Représenter les données au moyen d'un diagramme *Boîte à Moustaches*.

S- 7 : Test des signes, test de Wilcoxon

Ouvrir la feuille de données : *Accidents.sta* (3v par 12 c)

- Créer des noms d'observations à l'aide de la variable MOIS.
- Les données d'accidents de chaque mois constituent-elles 2 échantillons indépendants?
- Exécuter un test des signes sur les données.
- Exécuter un test de Wilcoxon pour les données appariées. La différence est-elle significative?

S – 8 : création et exécution d'une analyse macro de session

L'analyse macro s'appliquera sur une feuille de données dont les deux premières variables sont quantitatives.

Ouvrir une feuille de données, par exemple *Diamètres.sta* (3v par 100c)

- Créer une analyse macro de session qui fera la séquence des opérations suivantes sur chacune des 2 premières variables de la feuille. Nommer la macro *MACROTEST*.
 - le calcul de la moyenne et de l'écart type;
 - l'histogramme;
 - le diagramme Boîtes à Moustaches;
 - le calcul de la matrice de corrélation;
 - le test t de comparaison des moyennes en considérant les deux variables comme deux échantillons dépendants (appariés).
 Enregistrer la macro sous le nom de *MACROTEST*.
- Exécuter *MACROTEST* sur la feuille de données *IRIS.sta* (5v par 150c)

S-9 : distributions de probabilité : z (Normale) t (Student) F (Fisher)

remarque : repose sur une connaissance des lois de probabilités

Aller à la fonction « *Calculateur* » du module *STATISTIQUES ÉLÉMENTAIRES*.
Compléter le tableau ici-bas.

DISTRIBUTION	PARAMÈTRES DE LA DISTRIBUTION	PROBABILITÉ (p)	VALEUR DU PERCENTILE
z (Normal)	moyenne = 100 écart type = 10	0.85	X = ?
z (Normal)	moyenne = 100 écart type = 10	p = ?	X = 85
t (Student)	dl = 5	0.95	t = ?
t (Student)	dl = 10	p = ?	t = 2.00
F (Fisher)	df ₁ = 3 df ₂ = 7	p = 0.80	F = ?
F (Fisher)	df ₁ = 5 df ₂ = 15	p = ?	F = 1.55