

```
#####
###          TP REVISION TESTS STATISTIQUES          ###
#####
```

```
#####
##          Exercice 1 : Application sur le jeu de données souris (moodle)          ##
#####
```

Importer des données

fonctions : read.table()->fichier .txt, ou read.csv()-> fichier .csv (excel)

```
# charger le tableau de données souris.txt (fichier texte)
souris<- read.table("souris.txt", header = TRUE, sep="\t", row.names = 1)
# header=TRUE --> pour dire que 1ere ligne= noms colonnes/variables
# sep= "\t"--> separateur colonnes=tabulation,
# row.name=1--> 1ere colonne = identifiant des individus échantillonnés
```

Toujours commencer par visualiser les données

class(), str(), summary(), plot(), View()...

names(souris) # donne le nom des variables
#(NB: R remplace automatiquement les espaces par des points dans le nom des variables)
pour la 5e variable, le "é" de activité est remplacé par un caractère spécial "Ã" --> R n'aime pas les caractères spéciaux, évitez les. On va donc changer le nom des variables.

Renommez les variables comme suit : Masse, Taille, Sexe, Regime, Activite, Pelage
names(souris)<-c("Masse", "Taille", "Sexe", "Regime", "Activite", "Pelage")

Pensez à transformer en facteur les variables qualitatives qui sont susceptibles d'être utilisées
pour faire des comparaisons statistiques (qui définissent des groupes)
souris\$Sexe<-as.factor(souris\$Sexe)
souris\$Pelage<-as.factor(souris\$Pelage)

vérifiez la présence de NA dans le data frame
which(is.na (souris))

```
#####
#          A) Est ce que la taille des souris (quel que soit le sexe)          #
#          est conforme à une valeur moyenne de référence de 165mm?          #
#####
```

quel test réaliser ?
comparaison d'une moyenne observée avec une moyenne théorique (165mm)
Quand la moyenne de la population est connue (μ) mais pas sa variance
on peut employer la fonction t.test

quelles conditions d'application ?

verification de la normalité

a) test de Shapiro-Wilk
shapiro.test(souris\$Taille)
--> normalité OK

```

## b) graphiquement (normalité OK)
qqnorm(souris$Taille) ; qqline(souris$Taille) # Dessiner un « qqplot »
qqPlot(souris$Taille, col="brown",pch=19,main="QQplot Taille") # necessite de charger package "car"

histo<-hist(souris$Taille, prob=TRUE, breaks = seq(88,98, 1.02),
  include.lowest=TRUE, right = FALSE, col = "grey",
  main = "Répartition des tailles des souris", xlab = "taille",
  ylab="Densité",xlim = c(88,98))

abline(v=mean(souris$Taille), col="black", lwd=3, lty=4)
# Ajouter une ligne verticale correspondant à la moyenne, de couleur col= noir,
# lwd= epaisseur trait, lty=type trait (plein, tiret, pointillé...)
abline(v=median(souris$Taille), col="dark blue", lwd=3, lty=5)
# Ajouter une ligne verticale correspondant à la moyenne, de couleur col= noir,
# lwd= epaisseur trait, lty=type trait (plein, tiret, pointillé...)
curve(dnorm(x,mean(souris$Taille),sd(souris$Taille)),add=TRUE, lwd=3,col="red")
# ajouter une courbe de densité normale de couleur bleue sur votre graph
# (de meme mean et SD que votre echantillon)

#### quelle(s) conclusion(s) ?
t.test(souris$Taille, mu = 165)
# H1 = la moyenne observée de notre échantillon est différente de la moyenne théorique.

t.test(souris$Taille, mu = 165, alternative = "less") # si on a une idée a priori du sens de la différence
# la taille des souris de notre échantillon est significativement
# inferieure à la moyenne théorique

#####
#           B) Est ce que la taille des males et femelles      #
#           differe significativement ?                          #
#####

#### Réalisez un graphique approprié ?
boxplot(souris$Taille, na.rm=TRUE) # boxplot des tailles de souris sans distinction de sexe (na.rm=T est non
necessaire ici car pas de valeurs manquantes, mais sachez que cet arument optionnel existe aussi pour les graphs)

## Faire un boxplot pour chaque sexe (plusieurs options)
boxplot(souris[souris$Sexe=="F","Taille"],souris[souris$Sexe=="M","Taille"],names=c("Femelles","Mâles"), col =
c("yellow","green"),ylab="Taille (mm)") # même chose mais en distinguant les sexes et personnalisant le
graphique
boxplot(souris$Taille~souris$Sexe, col = c("yellow","green"),ylab="Taille (mm)") # ou plus simplement Taille en
fonction sexe

# On peut aussi utiliser la fonction subset pour extraire du dataframe global, les variables par sexe:
Fem<-subset(souris, Sexe=="F") # extraction de TOUTES les variables des femelles
Mal<-subset(souris, Sexe=="M") # idem males
boxplot(Fem$Taille,Mal$Taille,names=c("Femelles","Mâles"), col = c("yellow","green"),ylab="Taille (mm)") # ici,
on utilise seulement variable Taille
#### quel test réaliser ?
# Comparaison des moyennes de deux échantillons indépendants (t.test?)

#### quelles conditions d'application ?

### Vérification de la normalité

```

```
# a) test de Shapiro-Wilk (normalité OK)
shapiro.test(souris[souris$Sexe=="F","Taille"]) # sous échantillonnage des lignes "femelle" et de la colonne "taille"
uniquement
shapiro.test(souris[souris$Sexe=="M","Taille"]) # idem pour lignes "males"
```

```
## b) Dessiner un « qqplot », histogramme et/ou kernel pour chaque échantillon
qqPlot(souris[souris$Sexe=="F","Taille"],ylab="Taille",main = "QQplot Femelles")
qqPlot(souris[souris$Sexe=="M","Taille"],ylab="Taille",main = "QQplot Males")
#ou
qqnorm(souris[souris$Sexe=="F","Taille"]);qqline(souris[souris$Sexe=="F","Taille"])
qqnorm(souris[souris$Sexe=="M","Taille"]);qqline(souris[souris$Sexe=="M","Taille"])
```

```
histo<-hist(souris[souris$Sexe=="F","Taille"], prob=TRUE, breaks = seq(90,98,0.5),
  include.lowest=TRUE, right = FALSE, col = "grey", main = "Répartition des tailles des femelles",
  xlab = "taille", ylab="Densité",xlim = c(90,98))
abline(v=mean(souris[souris$Sexe=="F","Taille"]), col="black", lwd=3, lty=4)
abline(v=median(souris[souris$Sexe=="F","Taille"]), col="dark blue", lwd=3, lty=5)
curve(dnorm(x,mean(souris[souris$Sexe=="F","Taille"]),sd(souris[souris$Sexe=="F","Taille"])),add=TRUE,
lwd=3,col="red")
```

```
histo<-hist(souris[souris$Sexe=="M","Taille"], prob=TRUE, breaks = seq(88,96,1),
  include.lowest=TRUE, right = FALSE, col = "grey", main = "Répartition des tailles des males",
  xlab = "taille", ylab="Densité",xlim = c(88,96))
abline(v=mean(souris[souris$Sexe=="M","Taille"]), col="black", lwd=3, lty=4)
abline(v=median(souris[souris$Sexe=="M","Taille"]), col="dark blue", lwd=3, lty=5)
curve(dnorm(x,mean(souris[souris$Sexe=="M","Taille"]),sd(souris[souris$Sexe=="M","Taille"])),add=TRUE,
lwd=3,col="blue")
```

```
kernel_taille_F <- density(souris[souris$Sexe=="F","Taille"])
plot(kernel_taille_F,main="kernel taille femelles",col="brown")
```

```
kernel_taille_M <- density(souris[souris$Sexe=="M","Taille"])
plot(kernel_taille_M,main="kernel taille males",col="orange")
```

Vérification de l'homoscedasticité

```
## a) Test de comparaison des variances
# Si la distribution est normale alors on peut vérifier l'homoscedasticité (égalité des variances).
# Pour cela il faut comparer les variances de deux échantillons :
# faire un test d'égalité des variances sur la taille des souris en fonction de leur sexe en
# comparant les variances des Males et des Femelles
var.test(souris$Taille ~ souris$Sexe)
# si la p-value < 0.05 alors hétéroscedasticité, si elle est supérieure à 0.05 alors on ne peut pas rejeter H0 =
hypothèse d'homoscedasticité.
# Homoscedasticité OK
```

```
## b) On peut également comparer directement les écarts-types
# On considère que si l'un des écarts types est au moins 1.5 fois plus grand que l'autre alors on rejette
# l'homoscedasticité.
varTaille_Sx<-aggregate( souris$Taille, by = souris["Sexe"], FUN = sd)
varTaille_Sx
varTaille_Sx[2,2]/varTaille_Sx[1,2] # 1.2 (avec écart type le plus grand au numérateur)→ Homoscedasticité OK
```

```
# alternative pour mettre automatiquement au numérateur le plus grand des écart types
comp_ET<-max(varTaille_Sx[2,2],varTaille_Sx[1,2])/min(varTaille_Sx[2,2],varTaille_Sx[1,2])
comp_ET # 1.2 → Homoscédasticité OK
```

```
### Après avoir vérifié et validé les conditions de normalité et d'homoscédasticité → t.test() pour échantillons indépendants (les individus sont non appariés)
t.test(souris$Taille~souris$Sexe, var.equal=TRUE) # test bilatéral si on n'a pas d'a priori sur le sens de la différence
```

```
t.test(souris$Taille~souris$Sexe, var.equal=TRUE, alternative="greater") # unilatéral si on a une idée a priori du sens de la différence (ex ici Taille Femelles > Males)
# NB : dans la colonne "sexe", la modalité Femelle apparaît en premier -avant modalité Mâle-, on test donc ici Femelles > Males. Si on veut tester l'hypothèse inverse (Femelles < Males), il faut indiquer alternative="less".
```

```
#### quelle(s) conclusion(s) ?
# test bilatéral : la différence est hautement significative
# test unilatéral : la taille des femelles est hautement significativement plus grande que celle des males
```

```
#####
#          C) Est ce que la masse des souris avant et après une modification de leur régime          #
#          alimentaire durant 1 mois (conditions contrôlées) diffère significativement ?          #
#####
```

```
#### Réalisez un graphique approprié ?
## Faire un boxplot de la masse avant vs après régime
boxplot(souris$Masse,souris$Regime) # version basique (a gauche variable n°1 ,a droite variable n°2)
# version personnalisée :
boxplot(souris$Masse, souris$Regime, col=c("#00FFCC", "#3366FF"), ylab="Masse (g)", xlab="Avant vs Après régime", main="Souris soumises à un changement de régime alimentaire") # on peut utiliser un code hexadécimale pour les couleurs "#xxxxxx" modifiable directement sur google)
```

```
#### quel test réaliser ?
# Comparaison de moyennes de deux échantillons appariés (t.test apparié ?)
```

```
#### quelles conditions d'application ?
# vérification de la normalité sur les différences (les di), on commence par créer un vecteur di :
Avant<- souris$Masse
Après<- souris$Regime
di<-Avant-Après
di
```

```
### vérification normalité (OK)
shapiro.test(di)
```

```
hist(di, breaks = seq(-1,6,0.7),prob=TRUE,include.lowest=TRUE, right = FALSE, col = "grey")
curve(dnorm(x,mean(di),sd(di)),add=TRUE, lwd=3,col="blue")
```

```
qqPlot(di, pch=19, col="black", main="QQplot di") # Dessiner un « qqplot »
```

```
# Si on vérifie la condition de normalité → t.test() pour échantillons appariés :
t.test(Après,Avant, paired=TRUE) # si on veut tester simplement une différence de masse avant/après
t.test(Après, Avant, paired=TRUE, alternative="less") # si on veut tester masse Après < masse Avant
```

```
#### quelle(s) conclusion(s) ?
# Bilatéral -> différence significative
```

Unilatéral -> différence significative (Après<Avant)

```
#####  
#           D) Est ce qu'en moyenne, il y a une différence de taille, masse et/ou           #  
#           Activite entre les souris présentant une couleur de pelage différente?           #  
#####
```

Réalisez les graphiques appropriés ?

Avec la fonction boxplot, représenter chaque variable quantitative (Taille, Masse, Regime, Activite) en fonction
de la couleur de pelage des souris :

```
boxplot(souris$Taille~souris$Pelage, col=c("yellow", "brown", "orange"), ylab="Taille")  
boxplot(souris$Masse~souris$Pelage, col=c("yellow", "brown", "orange"), ylab="Masse")  
boxplot(souris$Regime~souris$Pelage, col=c("yellow", "brown", "orange"), ylab="Masse post-régime")  
boxplot(souris$Activite~souris$Pelage, col=c("yellow", "brown", "orange"), ylab="Activite")
```

quel test réaliser ?

ANOVA 1 facteur (?):

```
aov_Taille<-aov(souris$Taille~souris$Pelage)  
summary(aov_Taille) # NS (Non Significatif)
```

```
aov_Masse<-aov(souris$Masse~souris$Pelage)  
summary(aov_Masse) # NS
```

```
aov_Regime<-aov(souris$Regime~souris$Pelage)  
summary(aov_Regime) # NS
```

```
aov_Activite<-aov(souris$Activite~souris$Pelage)  
summary(aov_Activite)  
# Il y a une différence très significative entre au moins 2 groupes de souris (couleur pelage)
```

quelles conditions d'application ?

Vérifier si les résidus du modèle suivent une distribution normale

```
shapiro.test(residuals(aov_Activite)) # normalité OK  
plot(aov_Activite,2,pch=19)  
hist(residuals(aov_Activite))  
kernel_residus <- density(residuals(aov_Activite))  
plot(kernel_residus,main="kernel residus",col="dark blue")
```

Vérification de l'homoscedasticité :

```
bartlett.test(souris$Activite~souris$Pelage) # OK
```

Si les conditions ne sont pas satisfaites--> Kruskal-Wallis.

Si elles sont satisfaites on peut interpreter le test ANOVA et chercher quels échantillons diffèrent des autres

avec un test post hoc de comparaisons multiples 2 à 2 (Tukey HSD):

```
TukeyHSD(aov_Activite) # toutes les p-values sont <0.05 (donc significatives)
```

et aucun intervalle de confiance n'inclus 0

quelle(s) conclusion(s) ?

L'Activite des souris en fonction de leur couleur de pelage

est très significativement différente, pour tous les groupes comparés.

```
#####
#           E) Est ce que la distribution de la couleur du pelage           #
#           des souris varie selon le sexe des individus ?                   #
#####
```

```
#### quel test réaliser ?
# 25 males et 25 femelles = 2 échantillons --> Chi² homogeneite
Souris_PelSx<-chisq.test(souris$Pelage,souris$Sexe)
Souris_PelSx
```

```
#### quelles conditions d'application ?
# pas d'effectif attendu <5 (ou <20% d'effectifs attendus <5, mais sans 0)
Souris_PelSx$expected
Souris_PelSx$expected<=5
```

```
addmargins(Souris_PelSx$observed) # pour obtenir le TDC
difference<-Souris_PelSx$observed-Souris_PelSx$expected
```

```
#### quelle(s) conclusion(s) ?
# pas de différence significative de la couleur du pelage selon le sexe
```

```
#####
##           Exercice 2 : Alliage           ##
#####
```

```
# on recode la variable de dureté :
# tf=1, f=2, m=3, F=4, TF=5
Haute_T<-c(1, 2, 2, 3, 4, 1, 2)
Basse_T<-c(2, 3, 3, 5, 1, 4, 4, 5, 5)
wilcox.test(Haute_T,Basse_T)
# différence non significative au seuil alpha = 0.05, mais la différence serait significative au seuil alpha = 0.1.

# correction du test version « à la main » :
```

| Dureté | tf | tf | tf | f | f | f | f | m | m | m | F | F | F | TF | TF | TF |
|---------------|------|-----|----|----------------|-----|-----|---------|---|---------|-----|---|-----|-------------|----|----|----|
| Temp | H | H | B | H | H | H | B | H | B | B | H | B | B | B | B | B |
| Score B | | | 1 | | | | 3,5 | | 5,5 | 5,5 | | 6,5 | 6,5 | 7 | 7 | 7 |
| Score H | 0,5 | 0,5 | | 1,5 | 1,5 | 1,5 | | 3 | | | 5 | | | | | |
| | | | | | | | | | | | | | | | | |
| Somme Score B | 49,5 | | | verification : | | | U1 + U2 | = | n1 x n2 | | | | Uobs = 13,5 | | | |
| Somme Score H | 13,5 | | | | | | 63 | | 63 | | | | Uthéo = 12 | | | |

```
#####
##           Exercice 3 : Prairie           ##
#####
```

```
Prairie_1<-c(19.8, 20.6, 27.0, 29.5, 29.9)
Prairie_2<-c(15.9, 19.8, 20.9, 22.5, 26.3)
```

```
# on nous dit que la normalité de la variable de rendement est respectées, donc on part sur une comparaison de moyennes pour 2 échantillons indépendants → test de Student (avec ou sans correction de Welch ? ou wilcoxon ?)
```

il faut vérifier la condition d'homogénéité des variances :

```
var.test(Prairie_1,Prairie_2) # OK
```

on peut donc effectuer le test de Student pour échantillon indépendants et variances homogènes :

```
t.test(Prairie_1,Prairie_2, var.equal = T) # var.equal=T car homogénéité des variances respectée.
```

au seuil de 5%, le test est non significatif ; on ne peut pas conclure à une différence de rendement entre les 2 prairies.

pour l'entraînement, vérifions quand même la condition de normalité à partir des données des échantillons :

```
shapiro.test(Prairie_1) # OK
```

```
shapiro.test(Prairie_2) # OK
```

qqPlot(Prairie_1) # les points (observations) ne s'alignent pas très bien avec la droite. Ils tombent dans l'IC à 95% car celui-ci est très large en raison du faible effectif de l'échantillon.

```
qqPlot(Prairie_2) # même remarque + 2 points borderline
```

la normalité de la distribution de la variable rendement dans les 2 échantillons est difficile à établir sur de si petits effectifs. Par sécurité, il vaut mieux utiliser un test non paramétrique : test de Wilcoxon-Mann-Whitney avec la fonction wilcox.test()

```
wilcox.test(Prairie_1,Prairie_2)
```

même conclusion, pas de différence significative.

les 2 tests convergent en conclusion.

```
#####
```

```
##      Exercice 4 : Apport en Fer      ##
```

```
#####
```

```
omni<-c(11.2,7.6,8.4,9.8,10.9,11,12.2,8.1,10,9.8)
```

```
vege<-c(9.3,10.5,11.7,12.4,8.9,10.8,14.2,10,9.5,9.7)
```

test de Wilcoxon pour échantillons appariés car on compare 10 individus statistiques avant/après traitement

```
wilcox.test(omni,vege,paired=T, alternative = "greater") # test unilatéral pour voir si l'adoption de ce régime alimentaire végétarien conduit à une carence en fer (cad [fer] omni –avant- supérieur à [fer] végétarien –après-)
```

différence non significative

pour info :

```
wilcox.test(omni,vege,paired=T) # test bilatéral, pour tester une simple différence entre les 2 dates
```

non significatif également

```
#####
```

```
##      Exercice 5 : Peupliers      ##
```

```
#####
```

```
Aout<-c(8.1,10,16.5,13.6,9.5,8.3,18.3,13.3,7.9,8.1,8.9,12.6,13.4)
```

```
Novembre<-c(11.2,16.3,15.3,15.6,10.5,15.5,12.7,11.1,19.9,20.4,14.2,12.7,36.8)
```

13 clones mesurés à 2 dates différentes → test de Student apparié ?

```
di<-Aout-Novembre
```

```
shapiro.test(di) # verification de la normalité des di = OK
```

```
t.test(Aout, Novembre, paired = T) # test bilatéral
```

```
# il existe une différence significative de concentration en Aluminium dans le bois entre les 2 dates
```

si on avait suspecté une accumulation d'Aluminium dans le bois entre ces 2 dates, il aurait fallu faire un test unilatéral :

```
t.test(Aout, Novembre, paired = T, alternative = "less")
```

```
# la différence de concentration d'Aluminium est significativement plus grande en Novembre qu'en Aout
```

```
#####
```

```
##      Exercice 6 : Pigments      ##
```

```
#####
```

on a une VD qualitative ordinale à 4 niveaux et une VI qualitative à 3 modalités définissant les groupes à comparer. On ne peut utiliser qu'un test de Kruskal-Wallis car la VD est ordinale.

```
# on recode la variable de concentration en pigments (VD):
```

```
# abs=0, f=1, m=2, F=3
```

```
C_pigments<-c(0,2,1,3,0,2,1,3,2,0,0,3,0,1,0,1,3,1,2,0,3,3,2)
```

```
substrat<-c(rep("Argile",7),rep("Sable",9),rep("Calcaire",7))
```

```
Pigm_subst<-data.frame(C_pigments,substrat)
```

```
View(Pigm_subst)
```

```
kruskal.test(Pigm_subst$C_pigments,Pigm_subst$substrat)
```

```
# il n'y a pas de différence significative de concentration en pigment entre les différents échantillons.
```

```
# correction du test version « à la main » :
```

| | | | | | | | | | | | | |
|--------------------|--------|-------|-----|--------|------|--------------|------|--------|------|---------------|------|------|
| classement | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| Pigmt | abs | abs | abs | abs | abs | abs | abs | f | f | f | f | f |
| Subst | Arg | Arg | Sab | Sab | Sab | Sab | Calc | Arg | Arg | Sab | Sab | Calc |
| Rang | 4 | 4 | 4 | 4 | 4 | 4 | 4 | 10 | 10 | 10 | 10 | 10 |
| classement (suite) | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | |
| Pigmt (suite) | m | m | m | m | m | F | F | F | F | F | F | |
| Subst (suite) | Arg | Arg | Sab | Calc | Calc | Arg | Sab | Sab | Calc | Calc | Calc | |
| Rang (suite) | 15 | 15 | 15 | 15 | 15 | 20,5 | 20,5 | 20,5 | 20,5 | 20,5 | 20,5 | |
| Somme rangs : | Arg = | 78,5 | | n= 7 | | Hobs = | | 2,1479 | | ddl = K-1 = 2 | | |
| | Sab = | 92 | | n= 9 | | correction = | | 0,9353 | | Hthéo = 5,991 | | |
| | Calc = | 105,5 | | n= 7 | | Hobs_corr = | | 2,2965 | | | | |
| | | | | N = 23 | | | | | | | | |