

ASI (L2) : TP9

Objectifs du TP :

Effectuer une analyse textuelle, lire et utiliser des macros *Excel* mises dans des fichiers-texte, lire et utiliser des programmes *Rstat*.

1. Une analyse textuelle

On veut produire les dictionnaires alphabétiques et fréquentiels du texte FOGG.TXT.

Quel(s) logiciel(s) ou quelle(s) page(s) *Web* peut-on utiliser ?

Combien y a-t-il de mots en tout ? et de mots différents ? Quel en est le rapport ?

Quels sont les "vrais" mots les plus fréquents ? Que peut-on en déduire ?

Combien de fois le mot "jour" et le mot "jours" apparaissent-ils ?

On veut maintenant connaître les environnements du mot "jour" et du mot "jours" avec 3 mots avant et 4 mots après.

Quel(s) logiciel(s) ou quelle(s) page(s) *Web* peut-on utiliser ?

Attention : le texte à analyser ne commence qu'à la ligne 262.

2. Lire et utiliser des macros *Excel*

Après avoir lu le fichier `STEMLEAF.TXT` essayer de réaliser sous *Excel* le diagramme tige et feuille de la variable `AGE` puis de la variable `FORM_ANBAC` pour le dossier `CETOP2`.

Que pouvez-vous en conclure ?

Après avoir lu le fichier `BOXPLOTS.TXT` essayer de réaliser sous *Excel* un affichage en boîtes à moustaches pour les vins puis pour les catégories de vins du dossier `VINS`.

Que voit-on ?

Comment utiliser le fichier-modèle `ASGQT.XLT` pour réaliser sous *Excel* l'analyse séparée et l'analyse conjointe de toutes les QT d'un dossier, par exemple pour le dossier `ANTAL` ?

3. Lire et utiliser des programmes *Rstat*

Après avoir lu le fichier `STATGH.R` essayer de réaliser très rapidement l'analyse séparée et l'analyse conjointe de toutes les QT du dossier `ANTAL` puis les catégories de vins dans le dossier `VINS`.

Effectuer ensuite à l'aide des programmes de `STATGH.R` la comparaison des moyennes d'âges des hommes et des femmes du dossier `ELF`.

Effectuer enfin la comparaison des pourcentages d'hommes et de femmes survivantes dans le dossier `TITANIC`.

Esquisse de SOLUTION

Une analyse textuelle

Si on utilise la page *Web* d'Analexies, on obtient comme résultats :

```
Dans le texte il y a sans doute 6579 mots en tout
                                et 1986 mots differents ;
chaque mot est donc repete 3.31 fois en moyenne.
```

Avec le logiciel *analexies* du disque K: on obtient

```
Il y a : 6694 mots repartis en :
          6675 mots courants dont 2024 mots courants differents
```

(soit alors une répétition moyenne de 3.298 fois par mots).

La différence tient à la définition de ce qu'est un mot, à la gestion de la ponctuation...

Les "vrais" mots les plus fréquents sont

fogg	55
passpartout	33
bombay	25
phileas	24
heures	21

On reconnaît le nom des héros et la ville des chapitres 9, 10 et 11 ainsi qu'un mot important : *heures*.

Le mot *jour* apparaît 3 fois et le mot *jours* 9 fois.

Voici les environnements fournis par le logiciel `analexies` du disque K:

STATISTIQUES fournies par les dictionnaires

=====

Mot	Occurences
---	-----
jour	3
jours	9

Les environnements sont affichés avec 3 mots avants et 4 mots après.

deux fois par	jour	on faisait de la
quatre repas par	jour	sans que jamais ni
se modifier chaque	jour	autrefois on y voyageait
de bombay ce	jour	là ils célébraient une
en quatre vingts	jours	non toute cette gymnastique
en quatre vingts	jours	pourrait bien cacher quelque
gain de deux	jours	que phileas fogg inscrivit
bombay à trois	jours	seulement de calcutta le
emploieraient pas trois	jours	à la franchir mais
en quatre vingts	jours	en attendant et après
et recomptait les	jours	écoulés maudissait les haltes
du soleil les	jours	étaient plus courts d
j ai deux	jours	d avance à sacrifier

-- Fin de recherche d'environnement

Lire et utiliser des macros *Excel*

Pour les diagrammes "*Tige et Feuilles*", il n'y a qu'une seule macro dans le fichier `STEMLEAF.TXT` nommée *StemAndLeaf*. On peut l'exécuter via le menu `Outils / Macro / Macros`. Il faut visiblement deux onglets, l'un nommé *Stem* et l'autre *Data*. Les données doivent être en colonne 1, à partir de la ligne 2 (en ligne 1 il y a sans doute le nom de la variable). Les données doivent être triées par ordre croissant. On trouvera les résultats sur la page suivante.

Pour l'âge, on en déduit qu'il à beaucoup de non-réponses (valeur 0) et que la plupart des gens ont de 30 à 40 ans.

Pour le nombre d'années de formation, il y a là aussi beaucoup de non-réponses; la plupart des gens ont un bac +5.

Pour les diagrammes "*Boites à moustaches*", il y a plusieurs sous-programmes, le premier, nommé *CreerFeuilleBoxPlot* étant le programme principal. Pour exécuter le programme, il faut sélectionner les données à tracer avant de passer par le menu `Outils / Macro / Macros` (sans les *id* de ligne).

Le programme crée alors un onglet avec les résultats numériques et le graphique. Il serait plus judicieux de mettre le graphique seul dans une feuille (on le fait "à la main" rapidement avec un clic-droit dans le graphique à l'aide du menu `Emplacement`).

Pour traiter les catégories de vins, il faut transposer les données du dossier `VINS`. Pour ce faire, il faut sélectionner les données, faire `Edition / Copier` puis `Edition / Collage special` et cocher la case `Transposé`.

Pour utiliser le fichier-modèle `ASGQT.XLT`, il suffit de le recopier sur le disque `D:`, de l'ouvrir en activant les macros et de faire ce que dit l'onglet *Aides*, à savoir :

- insérer les données à partir de la cellule `L1C1` dans l'onglet *Données*; (en principe la ligne 1 doit contenir le nom des colonnes et la colonne 1 le nom des lignes),
- cliquer sur le bouton "départ". dans l'onglet *Statistiques*,
- lorsque l'affichage est stabilisé, utiliser les boutons 1 à 6 pour trier la colonne correspondante.

Il faut certainement modifier les formats de cellule pour une meilleure lisibilité. Attention au calcul des meilleures corrélation car les bornes 0.6 et 0.9 sont fixes (et sans doute mal gérées...).

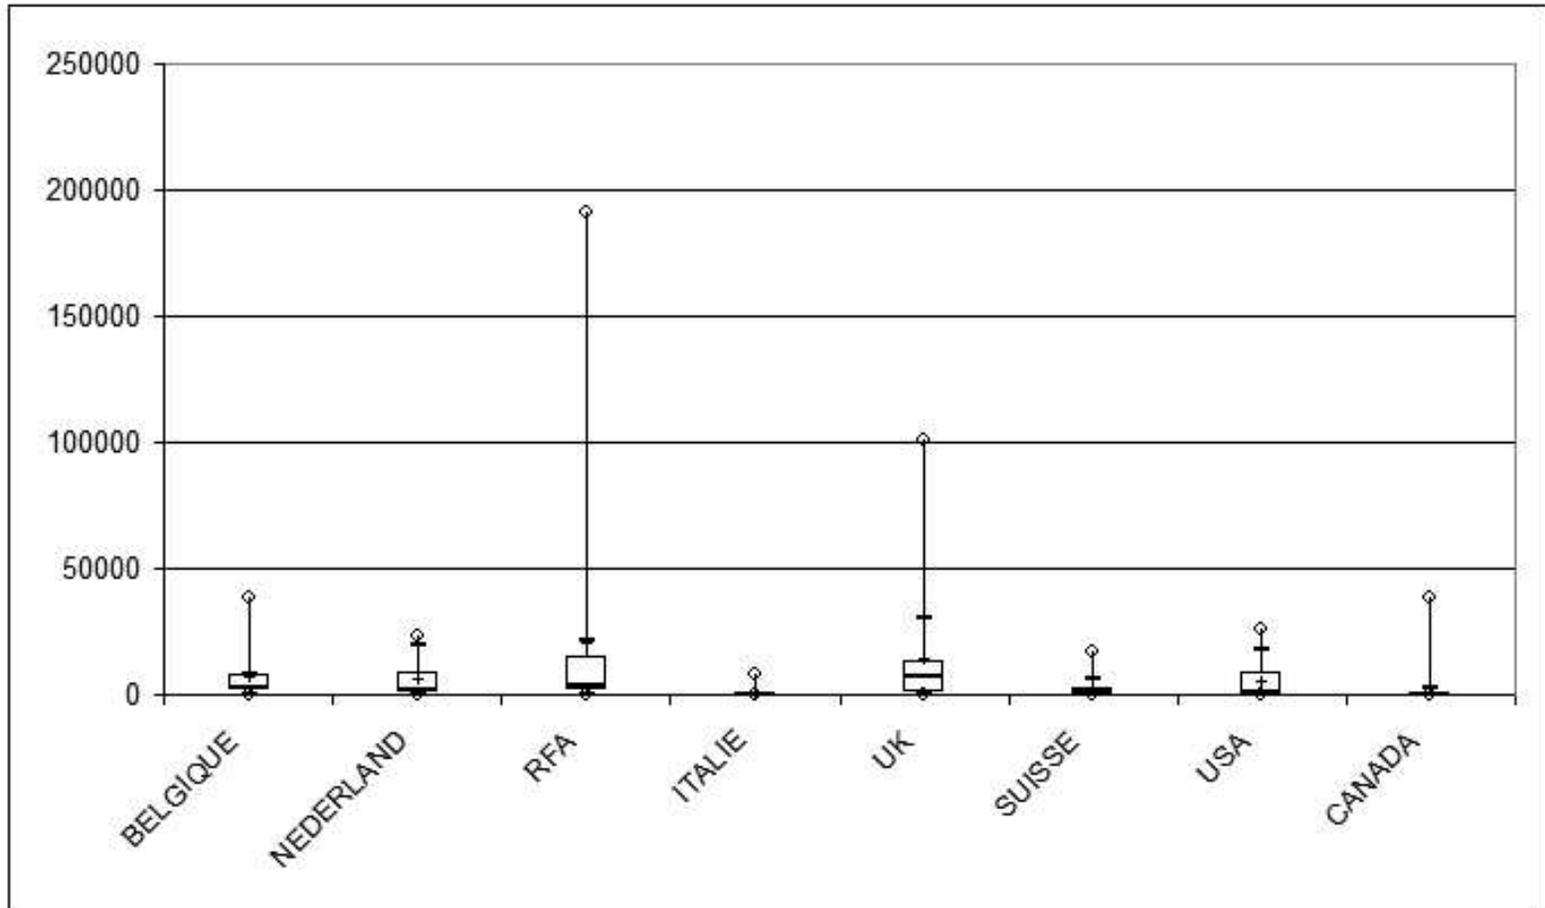
Pays importateurs de vins

NOM	BELGIQUE	NEDERLAND	RFA	ITALIE	UK	SUISSE	USA	CANADA
q1	1986	707,25	1391,75	1,5	1187	119,75	441,5	71
min	24	74	135	0	284	0	0	0
moust. inf.	24	74	135	0	284	0	0	0
med	2512	1824	3671	27	7398	536	1007	286
moy	7470	6261	20262	1119	14299	2965	5153	2814
moust. sup.	7950	19840	21023	98	30025	6544	17487	2346
max	38747	22806	191140	8037	101108	17327	26192	38503
q3	7729,75	8849,25	15128,75	87,75	13389,75	2713	8793,5	1127
nb atyp. inf.	0	0	0	0	0	0	0	0
nb atyp. sup.	4	2	2	4	2	3	1	2
effectif	18	18	18	18	18	18	18	18

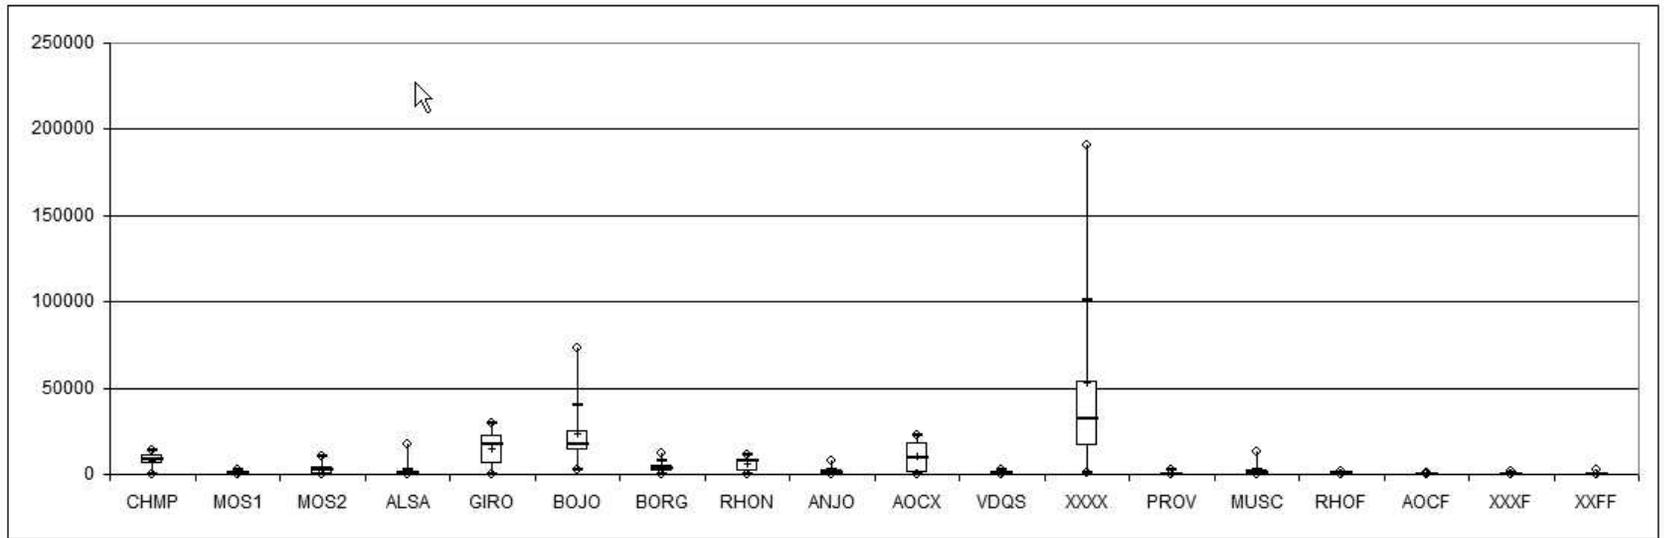
7

Boxplot de *vins* :

6



Boxplot de *vins* transposé :



4. Lire et utiliser des programmes *Rstat*

Le fichier STATGH.R permet de réaliser l'analyse de toutes les QT via `anaQT` une fois qu'on a lu le fichier des données. Par exemple, on peut écrire :

```
source("statgh.r")
antaldbf <- read.dbf("antal.dbf")
antalmat <- antaldbf$dbf
nbl      <- (dim(antalmat)[1])
nbc      <- (dim(antalmat)[2])
antal    <- antalmat[1:nbl,2:nbc]

anaQT(antal,colnames(antal))
```

Pour comparer les moyennes d'âges des hommes et des femmes du dossier ELF le plus simple est d'utiliser `compMoyData` puisqu'on dispose des données :

```
elf <- read.dbf("elf.dbf")

sexe <- elf$dbf[2]
age  <- elf$dbf[3]

agehom <- age[sexe==0]
agefam <- age[sexe==1]

compMoyData(agehom,agefam)
```

Pour le dossier TITANIC, on utilise la fonction `compPourc` :

```
tit <- read.dbf("titanic.dbf")
sexe <- tit$dbf[4]
surv <- tit$dbf[5]

nbhom <- sum( sexe==1 )
nbfam <- sum( sexe==0 )

nbhomsurv <- sum( (sexe==1) & (surv==1) )
nbfamsurv <- sum( (sexe==0) & (surv==1) )

compPourc(nbhomsurv,nbhom,nbfamsurv,nbfam)
```

Voici le résultat de l'exécution de ces commandes :

```
> #####
> source("statgh.r")

statgh.r, version 1.34 Mars 2005

> #####

> antaldbf <- read.dbf("antal.dbf")
> antalmat <- antaldbf$dbf
> nbl <- (dim(antalmat)[1])
> nbc <- (dim(antalmat)[2])
> antal <- antalmat[1:nbl,2:nbc]
>
> anaQT(antal,colnames(antal))

Données
$DOU0
[1] 0 0 0 6 6 6 4 0 0 0 0 0 0 4 4 2 2 0
    0 0 0 4 4 12 12 12 12 0 0 0 2 2 4 4 2 2

$DOU1
[1] 0 2 4 4 10 10 12 14 14 0 4 12 14 16 12 12 14 18
    0 4 4 12 20 14 10 10 10 0 0 0 4 8 8 8 8 6

$DOU2
[1] 0 4 16 18 12 8 4 6 6 0 6 10 16 10 12 16 10 8
    0 6 20 18 12 7 10 10 10 0 0 0 16 8 8 4 8 12

$DOU3
[1] 28 28 18 10 8 12 16 16 16 22 22 16 8 8 10 10 14 14
    18 20 14 6 4 7 8 8 8 22 22 34 14 10 14 16 10 10

$DOU4
[1] 12 6 2 2 4 4 4 4 4 18 8 2 2 2 2 0 0 0
    22 10 2 0 0 0 0 0 0 18 18 6 4 4 6 8 12 10

$DOU5
[1] 25 13 5 5 9 9 9 9 9 37 17 5 5 5 5 1 1 1
    45 21 5 1 1 1 1 1 1 37 37 13 9 9 13 17 25 21
```

Par cdv décroissant

Nom	Num	Taille	Moyenne	Ecart-type	Coef. de variation	Minimum	Maximum
1	DOU0	36	2.944	3.756	129.4	0.000	12.000
5	DOU4	36	5.444	5.899	109.9	0.000	22.000
6	DOU5	36	11.889	11.799	100.6	1.000	45.000
2	DOU1	36	8.278	5.541	67.9	0.000	20.000
3	DOU2	36	8.639	5.583	65.5	0.000	20.000
4	DOU3	36	14.472	6.784	47.5	4.000	34.000

Par ordre d'entrée

Nom	Num	Taille	Moyenne	Ecart-type	Coef. de variation	Minimum	Maximum
1	DOU0	36	2.944	3.756	129.4	0.000	12.000
2	DOU1	36	8.278	5.541	67.9	0.000	20.000
3	DOU2	36	8.639	5.583	65.5	0.000	20.000
4	DOU3	36	14.472	6.784	47.5	4.000	34.000
5	DOU4	36	5.444	5.899	109.9	0.000	22.000
6	DOU5	36	11.889	11.799	100.6	1.000	45.000

Par moyenne décroissante

Nom	Num	Taille	Moyenne	Ecart-type	Coef. de variation	Minimum	Maximum
4	DOU3	36	14.472	6.784	47.5	4.000	34.000
6	DOU5	36	11.889	11.799	100.6	1.000	45.000
3	DOU2	36	8.639	5.583	65.5	0.000	20.000
2	DOU1	36	8.278	5.541	67.9	0.000	20.000
5	DOU4	36	5.444	5.899	109.9	0.000	22.000
1	DOU0	36	2.944	3.756	129.4	0.000	12.000

Matrice des corrélations

	DOU0	DOU1	DOU2	DOU3	DOU4	DOU5
DOU0	1.000					
DOU1	0.334	1.000				
DOU2	0.223	0.405	1.000			
DOU3	-0.600	-0.705	-0.672	1.000		
DOU4	-0.463	-0.723	-0.693	0.555	1.000	
DOU5	-0.463	-0.723	-0.693	0.555	1.000	1.000

Meilleure corrélation 1 pour DOU5 et DOU4
Formule $DOU4 = 0.500 * DOU5 - 0.500$

Vous pouvez utiliser r.ps pour voir la courbe correspondante

Coefficients de corrélation par ordre décroissant

```

1.000 pour      6 et      5 soit DOU5 DOU4
-0.723 pour      6 et      2 soit DOU5 DOU1
-0.723 pour      5 et      2 soit DOU4 DOU1
-0.705 pour      4 et      2 soit DOU3 DOU1
-0.693 pour      6 et      3 soit DOU5 DOU2
-0.693 pour      5 et      3 soit DOU4 DOU2
-0.672 pour      4 et      3 soit DOU3 DOU2
-0.600 pour      4 et      1 soit DOU3 DOU0
 0.555 pour      6 et      4 soit DOU5 DOU3
 0.555 pour      5 et      4 soit DOU4 DOU3
-0.463 pour      5 et      1 soit DOU4 DOU0
-0.463 pour      6 et      1 soit DOU5 DOU0
 0.405 pour      3 et      2 soit DOU2 DOU1
 0.334 pour      2 et      1 soit DOU1 DOU0
 0.223 pour      3 et      1 soit DOU2 DOU0
>
> #####
>
>     elf <- read.dbf("elf.dbf")
>
>     sexe <- elf$dbf[2]
>     age  <- elf$dbf[3]
>
>     agehom <- age[sexe==0]
>     agefam <- age[sexe==1]
>
>     compMoyData(agehom,agefam)

```

COMPARAISON DE MOYENNES (valeurs fournies)

Variable	nbVal	Moyenne	Variance	Ecart-type	Cdv
A	35	36.400	285.365	16.893	46 %
B	64	35.516	324.984	18.027	51 %

différence réduite : 0.2431

au seuil de 5 % soit 1.96, on peut accepter l'hypothèse d'égalité des moyennes.

```

> #####
>
>   tit <- read.dbf("titanic.dbf")
>   sexe <- tit$dbf[4]
>   surv <- tit$dbf[5]
>
>   nbhom <- sum( sexe==1 )
>   nbfam <- sum( sexe==0 )
>
>   nbhomsurv <- sum( (sexe==1) & (surv==1) )
>   nbfamsurv <- sum( (sexe==0) & (surv==1) )
>
>   compPourc(nbhomsurv,nbhom,nbfamsurv,nbfam)

```

COMPARAISON DE POURCENTAGES

population A,	367	individus marqués sur	1731	soit une proportion de	0.212
population B,	344	individus marqués sur	470	soit une proportion de	0.732
globalisation,	711	individus marqués sur	2201	soit une proportion de	0.323

écart-réduit : 21.3746

au seuil de 5 % soit 1.96, on peut refuser l'hypothèse d'égalité des pourcentages.

Remarques sur la transposition des données

Comme nos matrices de données comportent en ligne 1 le nom des colonnes et en colonne 1 le nom des lignes, pour transposer une matrice de données, on ne peut pas se contenter d'utiliser la fonction *t* car sinon les nouvelles lignes de données sont transformées en caractères. On pourra s'en rendre compte avec les instructions

```

vins      <- read.dbf("vins.dbf")
vinsdata <- vins$dbf
t(vinsdata)

```

Il faut donc procéder plus prudemment, à savoir :

```
vins      <- read.dbf("vins.dbf")
vinsdata <- vins$dbf

anomlig  <- vinsdata[,1]
anomcol  <- colnames(vinsdata)
anblig   <- dim(vinsdata)[1]
anbcol   <- dim(vinsdata)[2]
valnum   <- vinsdata[ ,2:anbcol ]
dim(valnum)

snivdata <- matrix(nrow=anbcol-1,ncol=anblig+1)
snivdata[1:(anbcol-1), 2:(anblig+1)] <- t(valnum)
snivmat  <- as.data.frame(snivdata)
snivmat[,1] <- anomcol[2:anbcol]
colnames(snivmat) <- c("VIN",anomlig)
nomcol   <- anomlig

nbl      <- (dim(snivmat)[1])
nbc      <- (dim(snivmat)[2])
sniv     <- snivmat[1:nbl,2:nbc]
allQT(sniv,nomcol)
```