

Introduction à SPlus

Exercice 1

0- Les résumés unidimensionnels :

```
> Y_c(4,1,0,3,6,3,0,3,1,4,3,0,3,6,3,0,1,1,3,3,0,0,6,6)
> dim(Y)_c(8,3)
> summary(data.frame(Y))
```

Y.1	Y.2	Y.3
Min.:0.00	Min.:0.00	Min.:0.00
1st Qu.:0.75	1st Qu.:0.75	1st Qu.:0.75
Median:3.00	Median:3.00	Median:2.00
Y.1	Y.2	Y.3
Mean:2.50	Mean:2.50	Mean:2.50
3rd Qu.:3.25	3rd Qu.:3.25	3rd Qu.:3.75
Max.:6.00	Max.:6.00	Max.:6.00

1- Les moyennes des variables colonnes

```
> weighted.mean(Y)
[1] 2.5
```

2- Le tableau centré

On retranche sa moyenne à chacune des colonnes :

```
> centre(Y)
      [,1] [,2] [,3]
[1,]  1.5 -1.5 -1.5
[2,] -1.5  1.5 -1.5
[3,] -2.5  0.5  0.5
[4,]  0.5 -2.5  0.5
[5,]  3.5  0.5 -2.5
[6,]  0.5  3.5 -2.5
[7,] -2.5  0.5  3.5
[8,]  0.5 -2.5  3.5
```

3- La matrice de covariance

```
> varx(Y)
      [,1] [,2] [,3]
[1,]  3.75 -0.75 -2.25
[2,] -0.75  3.75 -2.25
[3,] -2.25 -2.25  5.25
```

4- La matrice de corrélation

On obtient le vecteur des corrélations et des écarts-types sigma :

```
> corx(Y)
      [,1] [,2] [,3]
[1,]  1.0000000 -0.2000000 -0.5070926
[2,] -0.2000000  1.0000000 -0.5070926
[3,] -0.5070926 -0.5070926  1.0000000
attr(,"sigma"):
[1] 1.936492 1.936492 2.291288
```

5- Les variances et écarts-types

Variance :

```
> diag(varx(Y))
```

```
[1] 3.75 3.75 5.25
```

Écarts-Types :

On retrouve les memes resultats qu'au sigma du (4-)

```
> sqrt(diag(varx(Y)))
```

```
[1] 1.936492 1.936492 2.291288
```

Exercice 2

1) Nombre de mots par ligne

On réalise 13 observations pondérées, puis on reconstitue le tableau des données :

```
> X_c(5,6,7,8,9,10,11,12,13,14,15,16,17) #matrice des données
> P_c(1/100,1/100,1/100,1/100,1/50,3/50,9/50,1/4,3/20,17/100,7/100,1/25,1/50)
#poids
> Y_rep(X,100*P)
> Y

[1]  5  6  7  8  9  9 10 10 10 10 10 10 11 11 11 11 11 11 11 11 11 11 11 11
    11 11 11 11 12 12 12 12 12 12 12 12 12 12 12 12 12 12 12 12 12 12 12
    12 12 13 13 13
[59] 13 13 13 13 13 13 13 13 13 13 13 13 13 14 14 14 14 14 14 14 14 14 14 14
    14 14 14 15 15 15 15 15 15 15 16 16 16 16 17 17
```

```
> dim(Y)_c(100,1)
> varx(Y)
```


```
      [,1]
[1,] 4.3156
```

```
> sqrt(varx(Y))
```

```
      [,1]
[1,] 2.077402
```


Affichage des diagrammes :

```
> v_1:13
> abs_v+.2*(v-2)
> X11()
> barplot(P)
> text(abs,-1,X)
> title("Exercice2")
```



On observe que le nombre moyen de mots par ligne est d'environ 12 et que la plupart des lignes a entre 10 et 14 mots.

```
> boxplot(Y)
```



On retrouve les mêmes résultats qu'avec le barplot mais en un peu plus lisible. Ce graphique fournit plusieurs informations intéressantes sur le tableau que nous avons entré :

Le bloxplot nous donne la valeur de la médiane (environ 12), ainsi que les différents quartiles. En noir sont représentés les deuxièmes et troisièmes quartiles. Le premier quartile nous informe que 25% des valeurs se trouvent entre 7 et 11, si on ne tient pas compte des valeurs originales. En effet, celles-ci sont représentées par des traits horizontaux à l'extérieur du boxplot. Cette représentation est destinée à ne pas fausser la visualisation du contexte général à cause de quelques observations originales.

2) Longueur des feuilles de platane

On étudie 75 feuilles de platane réparties en classes de longueur.

```
> X_c(104,109,114,119,124,129,134,139,144,149,154,159,164,169,174,179,184,189)
#classes
> N_c(1,0,3,3,2,4,5,4,6,9,10,7,6,4,5,3,2,1) #nombre d'éléments par classe
> dim(X)_c(18,1)
> X
      [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9] [,10]
[1,]  104  109  114  119  124  129  134  139  144  149

      [,11] [,12] [,13] [,14] [,15] [,16] [,17] [,18]
[1,]   154   159   164   169   174   179   184   189

> grav(X,N)

[1] 150.3333

> Y_rep(X,N)
> dim(Y)_c(75,1)
> varx(Y)
      [,1]
[1,] 354.2222

> sqrt(varx(Y))
      [,1]
[1,] 18.82079
```

Si on regroupe les classes par 2 :

```
> X_c(109,119,129,139,149,159,169,179,189)
> N_c(1,6,6,9,15,17,10,8,3)
> dim(X)_c(9,1)
> grav(X,N)
```

```
[1] 153
```


```
> Y_rep(X,N)
> dim(Y)_c(75,1)
> varx(Y)
```

```
      [,1]
[1,] 357.3333
```

```
> sqrt(varx(Y))
      [,1]
[1,] 18.90326
```

On observe que les résultats sont légèrement supérieurs à ceux obtenus précédemment. En effet il aurait été plus judicieux de faire la moyenne pondérée des classes lors de la fusion desdites classes.

```
> boxplot(Y)
```



Indices statistiques de base

Exercice 1

Exemple 1 :

```
> exp1_c(-4,-1,-1,-4,-1,-1,2,4,4,2,2,3,1,-2,-3,-1,1,1,-1,-1)
> dim(exp1)_c(10,2)
> P1_c(1,1,1,2,2,2,3,3,3,3) #nous permet de definir 3 classes dans exp1
> exp1
      [,1] [,2]
[1,]    -4     2
[2,]    -1     3
[3,]    -1     1
[4,]    -4    -2
[5,]    -1    -3
[6,]    -1    -1
[7,]     2     1
      [,1] [,2]
[8,]     4     1
[9,]     4    -1
[10,]    2    -1
```

Calcul de l'inertie totale :

```
> inerx(exp1)
```

```
[1] 10.8
```

Calcul de l'inertie inter-classes :

```
> interx(exp1,P1)
```

```
[1] 8.4
```

La formule intertie totale = inertie inter + inertie intra nous donne :
inertie intra = 2.4

Même calcul à partir du carré des distances inter-points :

```
> d_dist(exp1) #distances inter-point
> inerd(d) #distance euclidienne par défaut
```

```
[1] 10.8
```

On continue de même pour chacune des classes :

```
> i1_inerd(dist(exp1[1:3,]))
> i2_inerd(dist(exp1[4:6,]))
> i3_inerd(dist(exp1[7:10,]))
> 0.3*i1+0.3*i2+0.4*i3 #inertie intra
```

```
[1] 2.4
```

On retrouve les mêmes résultats que précédemment.

Exemple 2

```
> exp2_c(4,1,0,3,6,3,0,3,1,4,3,0,3,6,3,0,1,1,3,3,0,0,6,6)
> dim(exp2)_c(8,3)
      [,1] [,2] [,3]
[1,]     4     1     1
[2,]     1     4     1
[3,]     0     3     3
[4,]     3     0     3
[5,]     6     3     0
[6,]     3     6     0
[7,]     0     3     6
[8,]     3     0     6
```

```
> C2_c(1,1,1,1,2,2,2,2) #permet de definir les classes et les poids
```

Calcul des poids et des centres de gravités des classes.

```
> poidsc(C2,C2/12)
```

```
[1] 0.3333333 0.6666667
```

```
> gravc(exp2,C2,C2/12)
```

```
  [,1] [,2] [,3]  
1     2     2     2  
2     3     3     3  
attr(,"poidscl"):  
[1] 0.3333333 0.6666667
```

Calcul des variances totales, inter et intra :

```
> varx(exp2,C2/12) #matrice de covariance
```

```
      [,1]      [,2]      [,3]  
[1,]  4.0555556 -0.4444444 -2.9444444  
[2,] -0.4444444  4.0555556 -2.9444444  
[3,] -2.9444444 -2.9444444  6.5555556
```

```
> between(exp2,C2,C2/12) #covariance inter
```

```
      [,1]      [,2]      [,3]  
[1,] 0.2222222 0.2222222 0.2222222  
[2,] 0.2222222 0.2222222 0.2222222  
[3,] 0.2222222 0.2222222 0.2222222
```

```
> within(exp2,C2,C2/12) #covariance intra
```

```
      [,1]      [,2]      [,3]  
[1,]  3.8333333 -0.6666667 -3.1666667  
[2,] -0.6666667  3.8333333 -3.1666667  
[3,] -3.1666667 -3.1666667  6.3333333
```

Calcul des inerties totales et inter

```
> inerx(exp2,C2/12) #totale
```

```
[1] 14.66667
```

```
> interx(exp2,C2,C2/12) #inter
```

```
[1] 0.6666667
```

Les centres de gravités des classes sont très proches car la covariance inter est petite devant la covariance intra.

Analyse en composantes principales

Exercice 1 : ACP Notes

```
> notes_c
(6,8,6,14.5,14,11,5.5,13,9,6,8,7,14.5,14,10,7,12.5,9.5,5,8,11,15.5,12,5.
5,14,8.5,12.5,5.5,8,9.5,15,12.5,7,11.5,9.5,12,8,9,11,8,10,13,10,12,18)
> dim(notes)_c(9,5)
> dimnames(notes)_list(c("JE", "AL", "AN", "MO", "DI", "AD", "PI", "BR",
"EV"), c("m", "s", "f", "l", "dm"))
```

```
ACP sur les variables centrées réduites :
> res_acp(notes)
```

ACP du tableau "notes" sur variables reduites

Inertie totale : 5

Inertie expliquée (en %) :

	f1	f2	f3	f4	f5
	58	23	20	0	0
Cumul	58	80	100	100	100

```
Composantes principales :
> res$vectors
```

	f1	f2	f3	f4	f5
m	0.47764775	-0.5287000	-0.16117378	-0.29869388	0.6141123
s	0.53101865	-0.3959114	-0.09874597	0.52660628	-0.5236491
f	0.44395376	0.5779663	0.23195987	0.46927256	0.4414045
l	0.53983875	0.3604182	0.11348528	-0.64195022	-0.3920381
dm	0.03675592	0.3158865	-0.94741119	0.03392601	0.0112169

```
Les valeurs propres correspondantes :
> res$values
```

	f1	f2	f3	f4	f5
	2.878226	1.134815	0.983605	0.002373772	0.0009810042

L'inertie nous montre que les 3 premières composantes principales conservent la totalité de l'inertie et donc concentrent la majeure partie de l'information.

Nouveau tableau de données dans la base des composantes principales :

```
> reconacp(res)
```

	m	s	f	l	dm
JE	6.0	6.0	5.0	5.5	8
AL	8.0	8.0	8.0	8.0	9
AN	6.0	7.0	11.0	9.5	11
MO	14.5	14.5	15.5	15.0	8
DI	14.0	14.0	12.0	12.5	10
AD	11.0	10.0	5.5	7.0	13
PI	5.5	7.0	14.0	11.5	10
BR	13.0	12.5	8.5	9.5	12
EV	9.0	9.5	12.5	12.0	18

```
> contri(res)
Contribution des axes principaux aux individus
```

	Axe1	Axe2	Axe3	Axe4	Axe5	Tot
JE	883	55	62	0	0	1000
AL	790	58	151	0	0	1000
AN	489	469	41	2	0	1000
MO	879	3	117	0	0	1000
DI	879	112	8	0	1	1000
AD	246	390	363	0	1	1000
PI	30	755	215	0	0	1000
BR	183	584	230	3	0	1000
EV	54	353	592	0	0	1000
Tot	576	227	197	0	0	1000

```
Qualite de la representation des individus
sur les ss-esp. principaux
```

	Axe 1	Axesla2	Axesla3	Axesla4	Axesla5	tot
JE	883	938	1000	1000	1000	1000
AL	790	849	999	1000	1000	1000
AN	489	957	998	1000	1000	1000
MO	879	882	1000	1000	1000	1000
DI	879	991	999	999	1000	1000
AD	246	636	999	999	1000	1000
PI	30	785	1000	1000	1000	1000
BR	183	767	997	1000	1000	1000
EV	54	407	999	1000	1000	1000
Tot	576	803	999	1000	1000	1000

```
(on voit bien que les 2 premiers axes suffisent à décrire assez bien les
individus sauf dans le cas de l'individu EV)
```

```
Contribution des individus aux axes principaux
```

	Axe1	Axe2	Axe3	Axe4	Axe5	Tot	ORI
JE	298	47	61	122	150	194	194
AL	62	12	34	41	23	45	45
AN	41	99	10	155	3	48	48
MO	371	3	145	146	121	243	243
DI	160	52	4	21	401	105	105
AD	35	140	150	2	247	81	81
PI	5	294	97	72	19	89	89
BR	15	124	56	300	0	48	48
EV	14	229	443	141	36	147	147
Tot	1000	1000	1000	1000	1000	1000	1000

```
Contribution des facteurs aux variables
```

	f1	f2	f3	f4	f5	tot
m	657	317	26	0	0	1000
s	812	178	10	1	0	1000
f	567	379	53	1	0	1000
l	839	147	13	1	0	1000
dm	4	113	883	0	0	1000
Tot	576	227	197	0	0	1000

```
Qualite de la representation des variables
sur les ss-esp. principaux
```

	f1	fla2	fla3	fla4	fla5	tot
m	657	974	999	1000	1000	1000
s	812	989	999	1000	1000	1000
f	567	946	999	1000	1000	1000
l	839	986	999	1000	1000	1000
dm	4	117	1000	1000	1000	1000
Tot	576	803	999	1000	1000	1000

(les 2 premières composantes donnent une bonne représentation des variables sauf pour dm)

Contribution des variables aux facteurs

	f1	f2	f3	f4	f5	Tot	VARI
m	228	280	26	89	377	200	233
s	282	157	10	277	274	200	183
f	197	334	54	220	195	200	246
l	291	130	13	412	154	200	162
dm	1	100	898	1	0	200	177
	1000	1000	1000	1000	1000	1000	1000

A partir des résultats on déduit facilement que les deux premières composantes principales suffisent à conserver l'essentiel des informations