

Feuille de Travaux Dirigés n° 22

Analyse factorielle des correspondances

Exercice XXII.1. Présidentielles

1. Récupérer les données dans R en exécutant les instructions suivantes. Penser à remplacer "C :\\..." par le répertoire dans lequel vous avez enregistré le fichier que vous souhaitez ouvrir.

```
> Chemin <- "C:\\..."
> presid <- read.csv(paste(Chemin, "Presidentielle.CSV",
+   sep = ""), row.names = 1)
```

2. Quelles sont les différentes variables reproduites dans le tableau au verso ? Quelle est leur nature ? Quelles sont les modalités sur lesquelles on va faire porter l'analyse factorielle des correspondances ? Obtenir les statistiques descriptives, en utilisant la fonction `summary`, et les représentations graphiques suivantes du jeu de données.

	Sarkozy	Bayrou	Royal	Le.Pen
1	Min. : 56819	Min. : 18979	Min. : 33493	Min. : 23432
2	1st Qu. : 289229	1st Qu. : 165316	1st Qu. : 217393	1st Qu. : 91391
3	Median : 362391	Median : 214259	Median : 322212	Median :143926
4	Mean : 492330	Mean : 293479	Mean : 408817	Mean :166272
5	3rd Qu. : 544817	3rd Qu. : 379599	3rd Qu. : 554790	3rd Qu. :182804
6	Max. :1931429	Max. :1143081	Max. :1593033	Max. :430553

	Besanc.	Villiers	Voynet	Laguiller
1	Min. : 5941	Min. : 1908	Min. : 2119	Min. : 1346
2	1st Qu. : 37473	1st Qu. : 21474	1st Qu. :13284	1st Qu. :13690
3	Median : 58312	Median : 28166	Median :20382	Median :18623
4	Mean : 64976	Mean : 35469	Mean :24793	Mean :21152
5	3rd Qu. : 83281	3rd Qu. : 40957	3rd Qu. :29837	3rd Qu. :25618
6	Max. :181247	Max. :107895	Max. :89885	Max. :52965

```
> library(graphics)
> install.packages("vcd")
> library(vcd)
> presidtable <- as.table(as.matrix(presid[, -c(13, 14)]))
> assoc(presidtable, shade = T, las = 2, rot_labels = 90,
+   labeling_args = list(abbreviate = c(A = TRUE), varnames = F,
+   main = "Associations et résidus du test du chi2"))
```

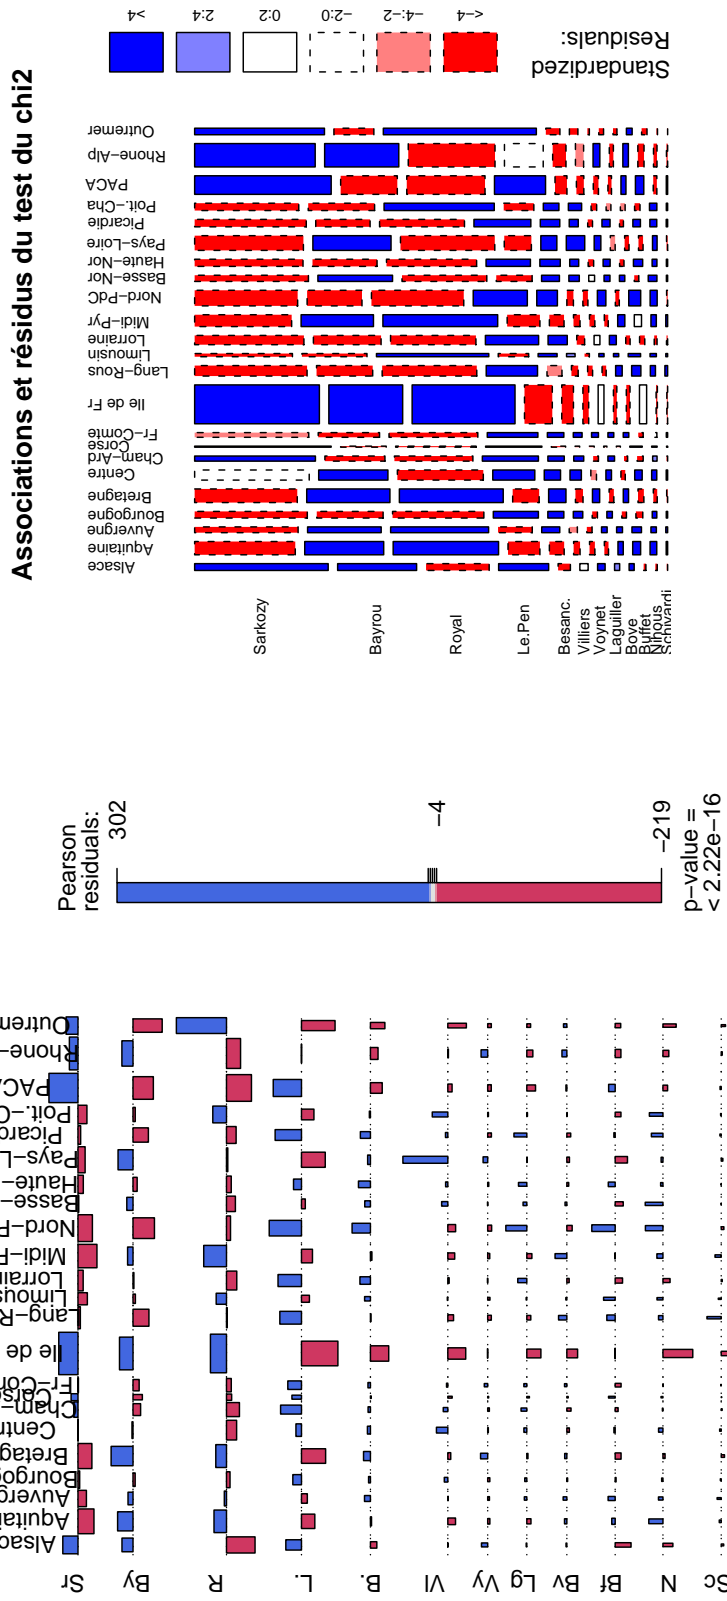
	Bove	Buffet	Nihous	Schivardi
1	Min. : 1659	Min. : 5163	Min. : 2260	Min. : 450
2	1st Qu. :12430	1st Qu. : 14878	1st Qu. : 9697	1st Qu. : 2806
3	Median :14904	Median : 22334	Median :20439	Median : 4207
4	Mean :20832	Mean : 30673	Mean :18265	Mean : 5361
5	3rd Qu. :27677	3rd Qu. : 36333	3rd Qu. :23426	3rd Qu. : 7026
6	Max. :57453	Max. :110967	Max. :43595	Max. :12386


	Sarkozy_2	Royal_2
1	Min. : 93771	Min. : 62209
2	1st Qu. : 470508	1st Qu. : 408900
3	Median : 641324	Median : 583406
4	Mean : 817371	Mean : 723216
5	3rd Qu. : 915508	3rd Qu. : 987746
6	Max. :2885762	Max. :2612107

```

> mosaicplot(presidtable, type = "pearson", shade = T,
+   las = 2, main = "Associations et résidus du test du chi2")
> install.packages("ade4")
> library(ade4)
> table.value(presidtable, grid = T, col.labels = names(presid))


```





3. Faire l'analyse factorielle des correspondances du tableau de données en traitant les résultats du second tour, colonnes Sarkozy_2 et Royal_2, comme des colonnes supplémentaires, puis construire les diagrammes des valeurs propres suivants. Par combien d'axes l'information est-elle résumée de manière satisfaisante ?

```
> library(FactoMineR)
> res.ca <- CA(presid, col.sup = c(13, 14), graph = FALSE)
> barplot(res.ca$eig$per, ylab = "Inertie expliquée (%)",
+         xlab = "Composante")
> barplot(res.ca$eig$cum, ylab = "Inertie cumulée expliquée (%)",
+         xlab = "Composante")
> abline(h = 80, lty = 2, lwd = 2)
```



```
> res.ca$call$marge.row
```

res.ca.call.marge.row	
Alsace	0.02751
Aquitaine	0.05360
Auvergne	0.02333
Bourgogne	0.02677
Bretagne	0.05507
Centre	0.04073
Cham-Ard	0.02070
Corse	0.00422
Fr-Comte	0.01886
Ile de Fr	0.15695
Lang-Rous	0.04237
Limousin	0.01284
Lorraine	0.03747
Midi-Pyr	0.04787
Nord-PdC	0.06293
Basse-Nor	0.02502
Haute-Nor	0.02899
Pays-Loire	0.05936
Picardie	0.03006
Poit.-Cha	0.02964
PACA	0.07500
Rhone-Alp	0.09433
Outremer	0.02637

```
> res.ca$call$marge.col
```

3. Représenter le premier et le second plan factoriel.

	res.ca.call.marge.col
Sarkozy	0.31113
Bayrou	0.18546
Royal	0.25835
Le.Pen	0.10507
Besanc.	0.04106
Villiers	0.02241
Voynet	0.01567
Laguiller	0.01337
Bove	0.01316
Buffet	0.01938
Nihous	0.01154
Schivardi	0.00339

```
> plot(res.ca, col.col.sup = "black", cex = 0.8)
> plot(res.ca, col.col.sup = "black", axes = c(3, 4),
+      cex = 0.8)
```


Commenter la qualité de la représentation obtenue sur les quatre premiers axes factoriels en analysant le contenu des tableaux suivants :

- `res.cacolcoord`, `res.cacolcos2`, `res.cacolcontrib`.
- `res.carowcoord`, `res.carowcos2`, `res.carowcontrib`.

4. La fonction `dimdesc` permet d'obtenir une description automatique des axes de l'AFC. Commenter ses résultats lorsqu'elle est appliquée à `res.ca`.


	Sarkozy	Bayrou	Royal	Le Pen	Besanc.	Villiers	Voynet	Laguiller	Bove	Buffet	Nilhous	Schivardi	Sarkozy_2	Royal_2
Alsace	362391	214259	171282	135730	33310	22492	20382	13821	13758	6100	5142	2522	641324	337781
Aquitaine	532127	417546	557300	168664	78230	34028	28285	22046	27941	41791	35300	7572	909798	971807
Auvergne	238152	169395	225477	78704	41522	18730	12090	12936	13532	21920	12474	4207	405352	415650
Bourgogne	297544	175213	241094	119041	42246	24971	13690	14440	12296	18154	12079	3608	515827	434478
Bretagne	557507	451988	564100	143926	94205	41212	39026	25662	28484	31860	21207	5169	921218	1023094
Centre	460425	278175	345352	168912	65347	45720	22655	22279	17395	30003	20567	5696	795959	650777
Cham-Ard	246680	122642	160280	114527	33424	20455	10727	13560	7414	12465	9016	2270	429708	304449
Corse	56819	18979	33493	23432	5941	1908	2119	1346	1659	5163	2260	450	93771	62209
Fr-Comte	212358	114148	165243	94212	30672	16361	12879	10880	10365	9204	7814	2446	371156	297492
Ile de Fr	1931429	1143081	1593033	430553	181247	89498	89885	52965	57453	110967	19890	12386	2885762	2612107
Lang-Rous	470017	234739	395509	214468	62597	28166	20787	17175	27412	38590	21356	11436	809868	687158
Limousin	123870	82445	142237	38525	24040	10789	6144	6566	6629	15695	8029	2284	207618	249470
Lorraine	403919	250195	315596	196696	70940	29183	21562	25574	16094	19229	10378	4211	715247	593561
Midi-Pyr	458093	341651	542038	154777	69177	30850	25267	18623	33687	34076	25280	8778	787351	898194
Nord-PdC	639390	340679	573071	335855	127881	40702	31388	52695	24591	74027	43595	6348	1131904	1117952
Basse-Nor	280914	184256	209308	88569	43997	25722	14389	14652	13180	11211	21449	3090	476255	402149
Haute-Nor	309924	184615	257664	126795	58312	25692	15707	20048	12563	26376	13717	3604	543404	492154
Pays-Loire	636934	457560	552280	158844	93685	107895	38952	28481	25811	26737	26674	6481	1075685	1003684
Picardie	331053	161236	251862	168699	57769	26731	14219	23982	11619	22334	20439	4189	582715	487508
Poit.-Cha	304493	194126	322212	88138	45638	38735	16333	13949	13934	15901	21571	3882	516282	542882
PACA	1010234	419161	579036	377831	88331	54851	38339	26467	36963	61968	26538	9935	1662131	1025774
Rhone-Alp	1121615	689984	807220	360646	123776	75959	63032	38114	51441	57654	32624	10969	1856430	1440224
Outremer	337711	103933	398110	36714	22159	5139	12383	10234	14904	14062	2698	1772	464760	583406

.....

Exercice XXII.2. Effet Guttman


L'effet Guttman traduit une association entre les deux variables qualitatives dont nous étudions la table de contingence. En écologie, il est alors d'usage de parler d'ordination indirecte. Le jeu de données utilisé ci-dessous est un ensemble de Densités à l'hectare de 11 espèces d'arbres par classe de valeurs de l'humidité du sol (moyenne sur plusieurs stations par classe).

```
> library(FactoMineR)
> data(santacatalina, package = "ade4")
> sant = santacatalina
> coasanta = CA(sant, ncp = 1, graph = F)
> table.value(sant, csize = 1.5)
> table.value(sant[order(coasanta$row$coord), order(coasanta$col$coord)],
+           csize = 1.5)
```



À gauche, les données brutes et à droite, le tableau traité : les sites et les espèces sont ordonnés en fonction des sites, les colonnes, qui sont les classes du gradient.

```
> santa.coa <- CA(santacatalina, ncp = 4, graph = F)
> plot(santa.coa)
```



Le package `ade4` propose des représentations complémentaires. Voir l'article de J. Oksanen¹ pour plus de détails.

```
> library(ade4)
> santa.coa <- dudi.coa(santacatalina, scan = F)
> scatter(santa.coa, met = 2)
> scatter(santa.coa, met = 3)
```

1. Exécuter les lignes de commande ci-dessus.
2. Traiter l'exemple qui vous a été proposé en cours.

¹J. Oksanen. Problems of joint display of species and site scores in correspondence analysis. *Vegetatio*, 72 : 51–57, 1987.