

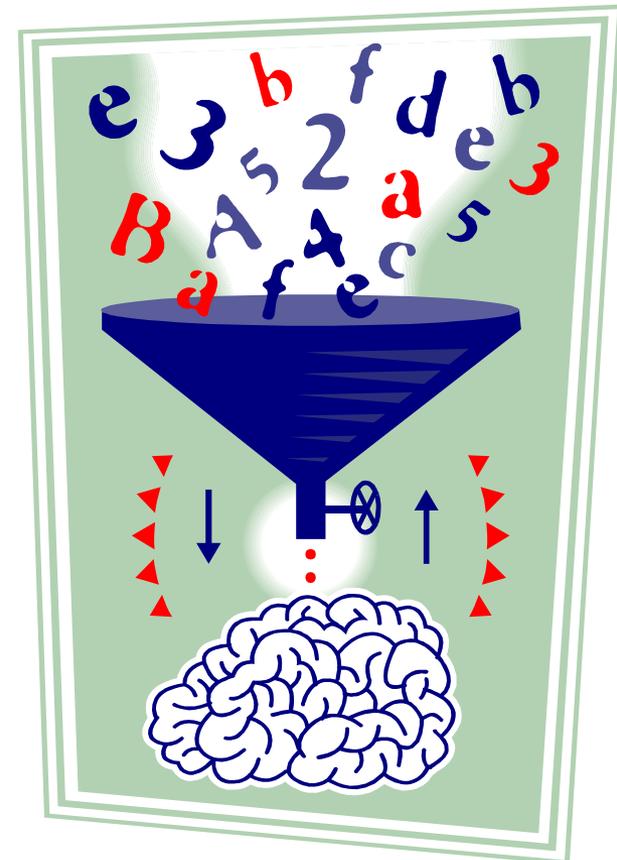
L'AFC pour les nuls

Mise à jour du 8 août 2010

Rémi Bachelet

La version à jour de ce cours
d'analyse factorielle des composantes
est disponible <http://rb.ec-lille.fr>

Cette formation est également
enregistrée en vidéo



Source des images indiquées au-dessous

Cours distribué sous licence **Creative Commons**,
selon les conditions suivantes :



Comment utiliser ce COURS :

1. Mettre les diapos en format plein écran en cliquant sur 
2. Faire défiler l'animation en cliquant **sur** les diapositives

(attention : cliquer sur une image ou un lien ouvre la page web correspondante)



Objectifs du cours d'Analyse Factorielle des Correspondances

Méthode développée notamment par Jean-Paul Benzécri (1970+)

1. Comprendre les fondements de l'Analyse Factorielle des Correspondances
2. Savoir quel est le processus de calcul et ses logiques
3. Pouvoir expliquer le mapping produit par une AFC
4. Également :
 - Connaître quelques logiciels d'administration d'enquêtes et de traitement de données
 - Avoir des éléments de comparaison AFC – ACP (ACP = Analyse en Composantes Principales).

Principes de l'AFC et données d'entrées

1. Principe général de l'AFC

2. Exemples :

- **Les limites des représentations graphiques intuitives**
- **Comment donner du sens aux informations**

Principe général de l'analyse factorielle des correspondances (AFC)

« L'analyse factorielle traite des tableaux de nombres.

Elle **remplace un tableau de nombres** difficile à analyser par **une série de tableaux plus simples** qui sont une bonne approximation de celui-ci »

Ces tableaux sont « simples », car **ils sont exprimables sous forme de graphiques**

Pourquoi « des correspondances » ?

variables numériques \Rightarrow Corrélation

variables nominales \Rightarrow Correspondance

Pourquoi « factorielle » ?

Il s'agit de décomposer le tableau original en une somme de tableaux/matrices qui sont chacun le **produit** de facteurs simples.

Autrement dit, on les « met en facteurs »

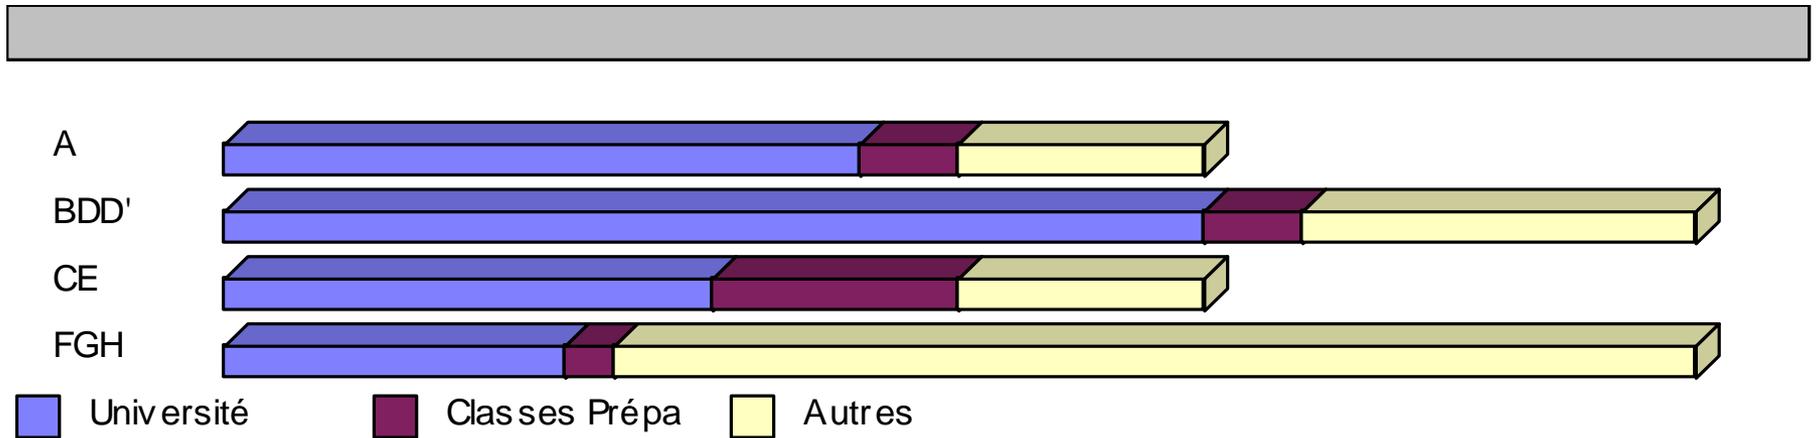
Principale source d'informations, et de l'exemple utilisé pour ce cours : *Que sais-je ? « L'analyse factorielle » - N°2095, Philippe*

Exemple : que deviennent les bacheliers ?

<i>destination</i>				
	<i>université</i>	<i>classes prépa</i>	<i>autres</i>	<i>total</i>
<i>A</i>	13	2	5	20
<i>BDD'</i>	20	2	8	30
<i>CE</i>	10	5	5	20
<i>FGH</i>	7	1	22	30
total	50	10	40	100

Stats MEN 1975 - 1975 204 489 lycéens

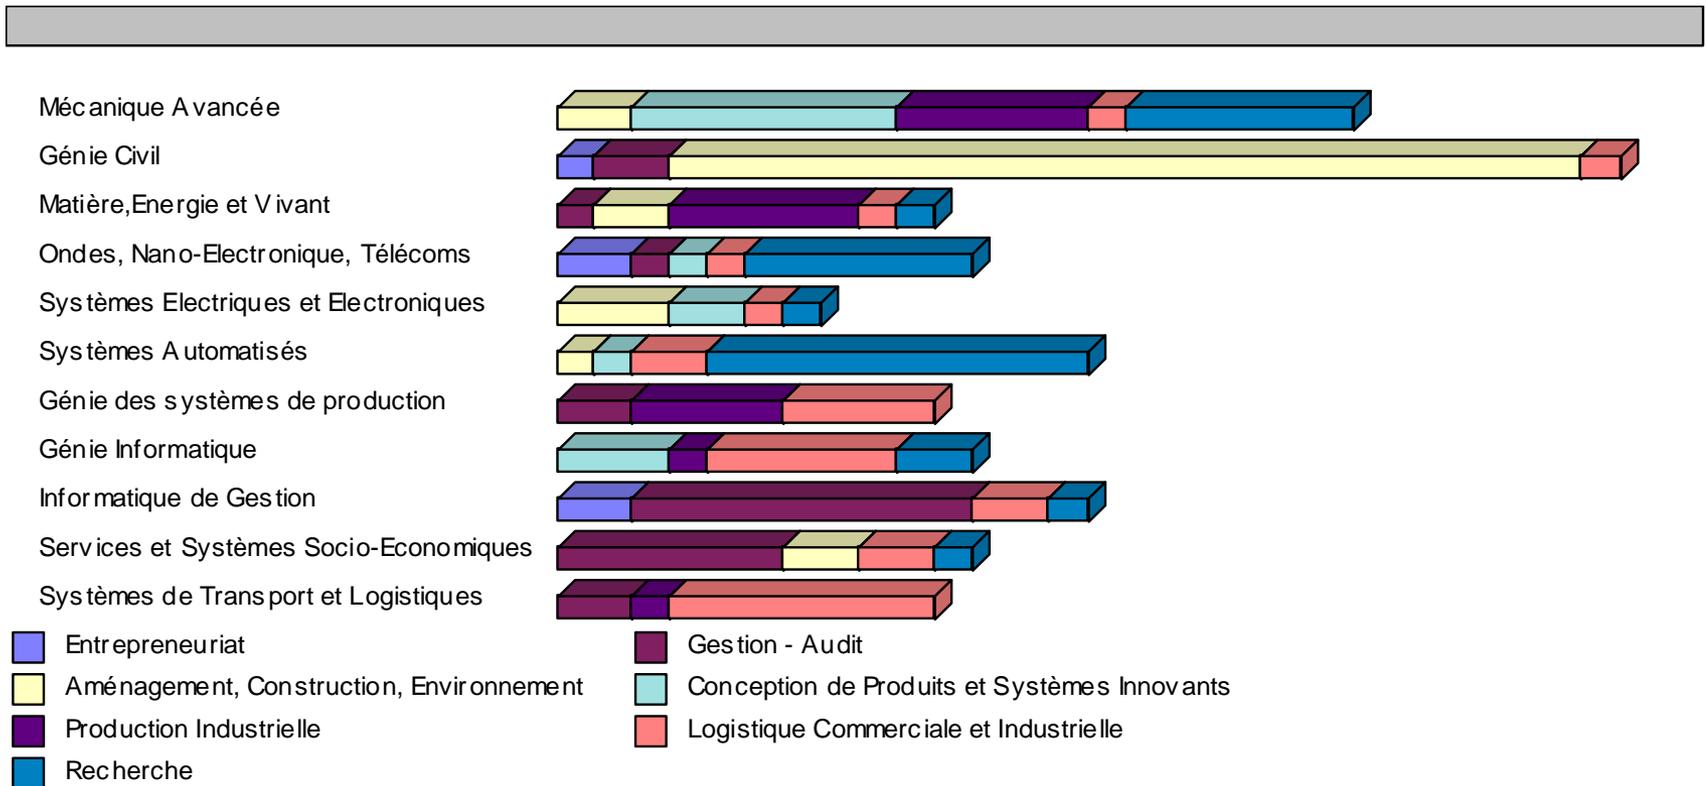
Une représentation graphique intuitive



Exemple : quels souhaits d'orientation ?

Premiers vœux 2003 de Génie / filière.	Entrepreneuriat	Gestion - Audit	Aménagement, Construction, Environnement	Conception de Produits et Systèmes Innovants	Production Industrielle	Logistique Commerciale et Industrielle	Recherche
Mécanique Avancée	0	0	2	7	5	1	6
Génie Civil	1	2	24	0	0	1	0
Matière,Énergie et Vivant	0	1	2	0	5	1	1
Ondes, Nano- Electronique, Télécoms	2	1	0	1	0	1	6
Systèmes Electriques et Electroniques	0	0	3	2	0	1	1
Systèmes Automatisés	0	0	1	1	0	2	10
Génie des systèmes de production	0	5	0	0	4	4	0
Génie Informatique	0	0	0	3	1	5	2
Informatique de Gestion	2	11	0	0	0	2	1
Services et Systèmes Socio-Economiques	1	6	3	0	0	2	1
Systèmes de Transport et Logistiques	0	2	0	0	1	8	0

.. Pas toujours suffisante :



Comment donner du sens à ces données

Idée : ce qui est intéressant, c'est de mettre en évidence ce qui est **inattendu** dans ces répartitions

Inattendu = en quoi on dévie d'une répartition uniforme

On va donc :

1. Évaluer ce que serait une situation d'uniformité, d'indépendance
2. Calculer en quoi la situation constatée en diffère
3. Exprimer cette différence graphiquement pour pouvoir l'analyser
4. Interpréter le mapping obtenu ...
5. et en optimiser la lisibilité

Première opérations sur les matrices

- 1. Matrice « T » des données d'entrée**
 - Matrice R des écarts à l'indépendance
- 2. Mise en facteur d'une matrice**
 - Exprimer « simplement » R

Matrice « T » des données d'entrée

	<i>destination</i>			
	<i>université</i>	<i>classes prépa</i>	<i>autres</i>	<i>total</i>
<i>A</i>	13	2	5	20
<i>BDD'</i>	20	2	8	30
<i>CE</i>	10	5	5	20
<i>FGH</i>	7	1	22	30
total	50	10	40	100

Ce tableau est aussi une matrice, appelons-la « T »

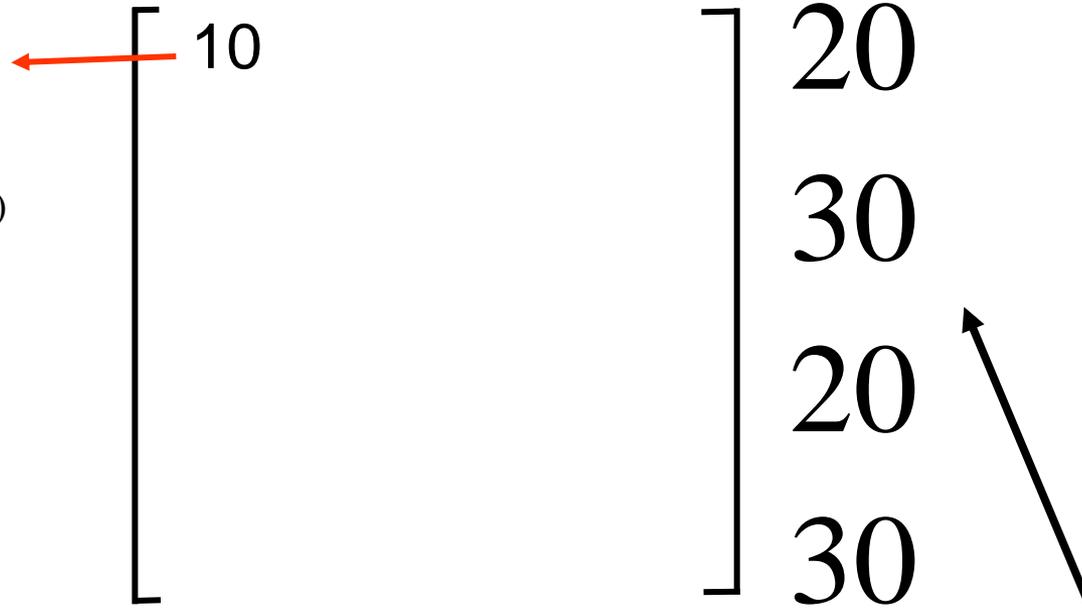
Quelle matrice aurait-on si la répartition dans les filières post-Bac ne dépendait pas du type de Bac ?

1/ S'il y avait situation d'indépendance...

$$10 = 50 * 20\%$$

([produit matriciel](#) /100

puisque'on raisonne en %)



Appellons cette matrice « T_0 »

On reconstitue
la matrice à
partir de ses
marges

2/ La matrice des écarts à l'indépendance est

$$T - T_0 = R$$

$$\begin{bmatrix} 13 & 2 & 5 \\ 20 & 2 & 8 \\ 10 & 5 & 5 \\ 7 & 1 & 22 \end{bmatrix} - \begin{bmatrix} 10 & 2 & 8 \\ 15 & 3 & 12 \\ 10 & 2 & 8 \\ 15 & 3 & 12 \end{bmatrix} = \begin{bmatrix} 3 & 0 & -3 \\ 5 & -1 & -4 \\ 0 & 3 & -3 \\ -8 & -2 & 10 \end{bmatrix}$$

Quelle est la particularité de R ?

3/ Comment exprimer simplement R ?

On décompose la matrice des écarts à l'indépendance en une somme de matrices..

$$R = T_1 + T_2$$

.. Chacune de ces matrices étant mise en facteur (le produit d'un vecteur ligne et d'un vecteur colonne).

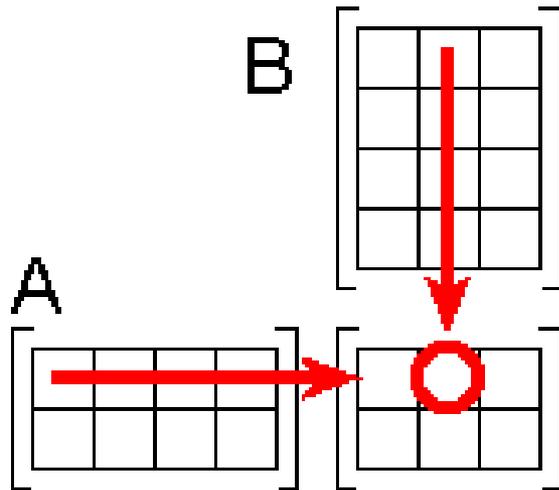
$$T_1 = C_1 L_1$$

(une matrice dont la plus petite dimension est N « rang N » est décomposable au maximum en N matrices pouvant se mettre en facteurs ...

ici $T = T_0 + T_1 + T_2$).

T est de rang 3, mais R est de rang 2....

Produit matriciel : exemple



$$c_{12} = \sum_{r=1}^4 a_{1r} b_{r2} = a_{11}b_{12} + a_{12}b_{22} + a_{13}b_{32} + a_{14}b_{42}$$

Mise en facteur d'une matrice: exemple

$$\mathbf{T} = \mathbf{CL}$$

On met en facteur \mathbf{T} comme le produit d'une matrice colonne \mathbf{C} par une matrice ligne \mathbf{L}

- \mathbf{T} (2X2)
- \mathbf{C} (1X2)
- \mathbf{L} (2X1)

Attention les règles de présentation du [produit matriciel](#) ne sont pas bien respectées dans nos diapos

De plus, la multiplication des matrices n'est pas commutative ($\mathbf{LC} \neq \mathbf{CL}$)

$$R = T_1 + T_2 = C_1 L_1 + C_2 L_2$$

$$\begin{bmatrix} 3 & 0 & -3 \\ 5 & -1 & -4 \\ 0 & 3 & -3 \\ -8 & -2 & 10 \end{bmatrix} = \begin{bmatrix} 1 & 1 & -2 \\ 1 & 1 & -2 \\ 2 & 2 & -4 \\ -4 & -4 & 8 \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ 2 \\ -4 \end{bmatrix} \begin{bmatrix} 2 & -1 & -1 \\ 4 & -2 & -2 \\ -2 & 1 & 1 \\ -4 & 2 & 2 \end{bmatrix} + \begin{bmatrix} 1 \\ 2 \\ -1 \\ -2 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 1 & -2 \\ 2 & -1 & -1 \end{bmatrix}$$

Attention le sens de multiplication écrit ici est LC au lieu de CL

D'une matrice à une présentation graphique

Production et interprétation du mapping

- Vecteurs colonne et vecteurs ligne
- Produit scalaire

3/ bis Comment représenter graphiquement la décomposition ?

Un vecteur colonne (resp. ligne) correspond à une modalité des données en colonnes (resp. lignes)

Un axe unidimensionnel + un axe unidimensionnel = un repère

Un vecteur colonne correspond à une modalité des données en colonnes

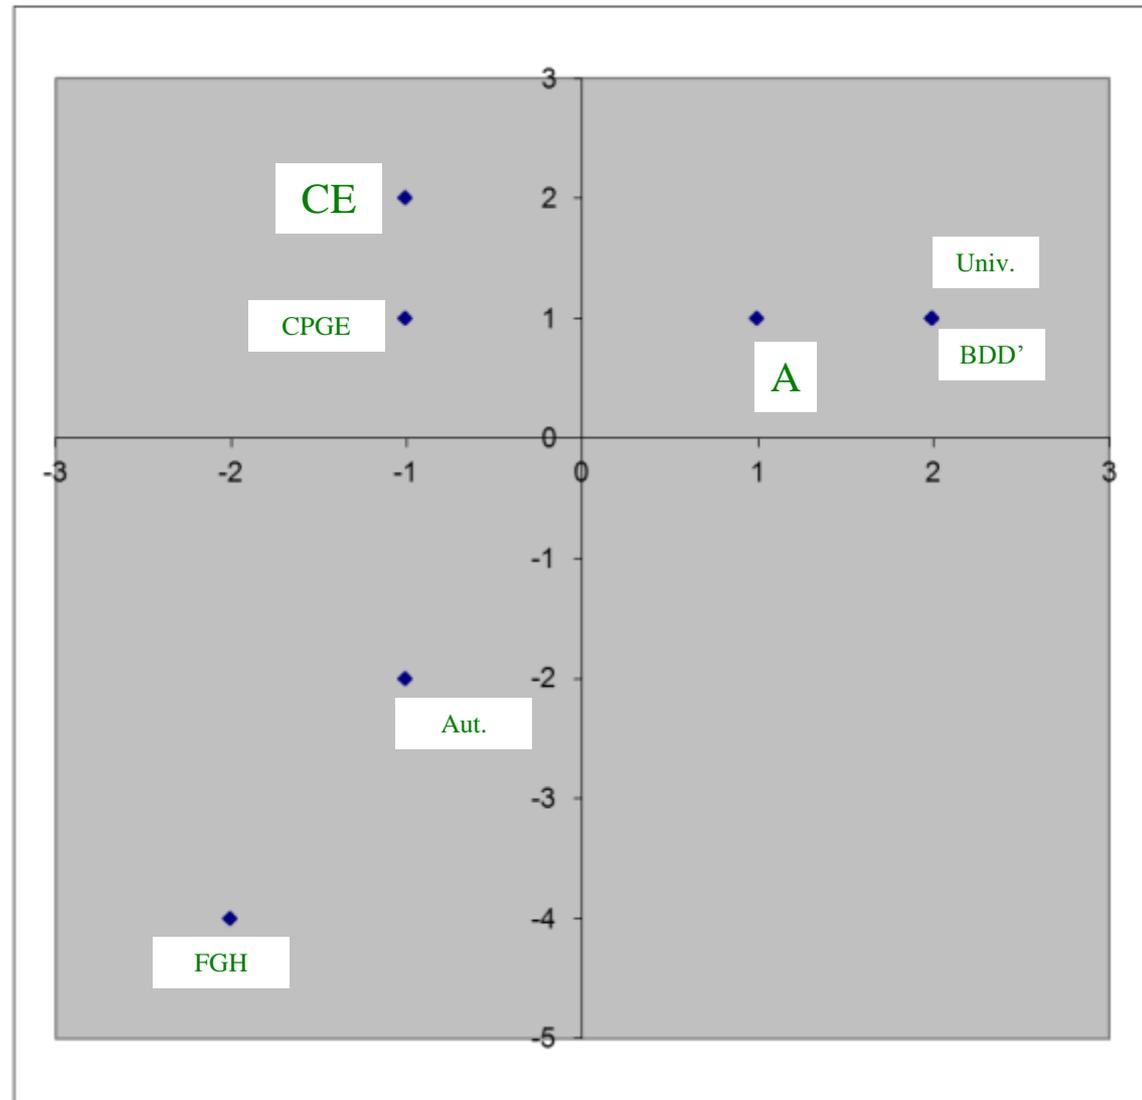
$$\begin{bmatrix} 3 & 0 & -3 \\ 5 & -1 & -4 \\ 0 & 3 & -3 \\ -8 & -2 & 10 \end{bmatrix} = \begin{bmatrix} 1 & 1 & -2 \\ 1 & 1 & -2 \\ 2 & 2 & -4 \\ -4 & -4 & 8 \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ 2 \\ -4 \end{bmatrix} + \begin{bmatrix} 2 & -1 & -1 \\ 4 & -2 & -2 \\ -2 & 1 & 1 \\ -4 & 2 & 2 \end{bmatrix} + \begin{bmatrix} 1 \\ 2 \\ -1 \\ -2 \end{bmatrix}$$
$$\begin{bmatrix} 1 & 1 & -2 \\ 2 & -1 & -1 \end{bmatrix}$$

Un vecteur colonne correspond à une modalité des données en colonnes

	A	1
	BDD'	2
	CE	-1
	FGH	-2
Univ	CPGE	Autres
2	-1	-1

Un axe unidimensionnel + un axe unidimensionnel = un repère

A	1	1
BDD'	2	1
CE	-1	2
FGH	-2	-4
Univ	2	1
CPGE	-1	1
Autres	-1	-2



4/ Que veut dire ce mapping ?

1. Conjonction :

Produit scalaire positif

Les Bac CE ont une affinité pour la prépa

2. Opposition

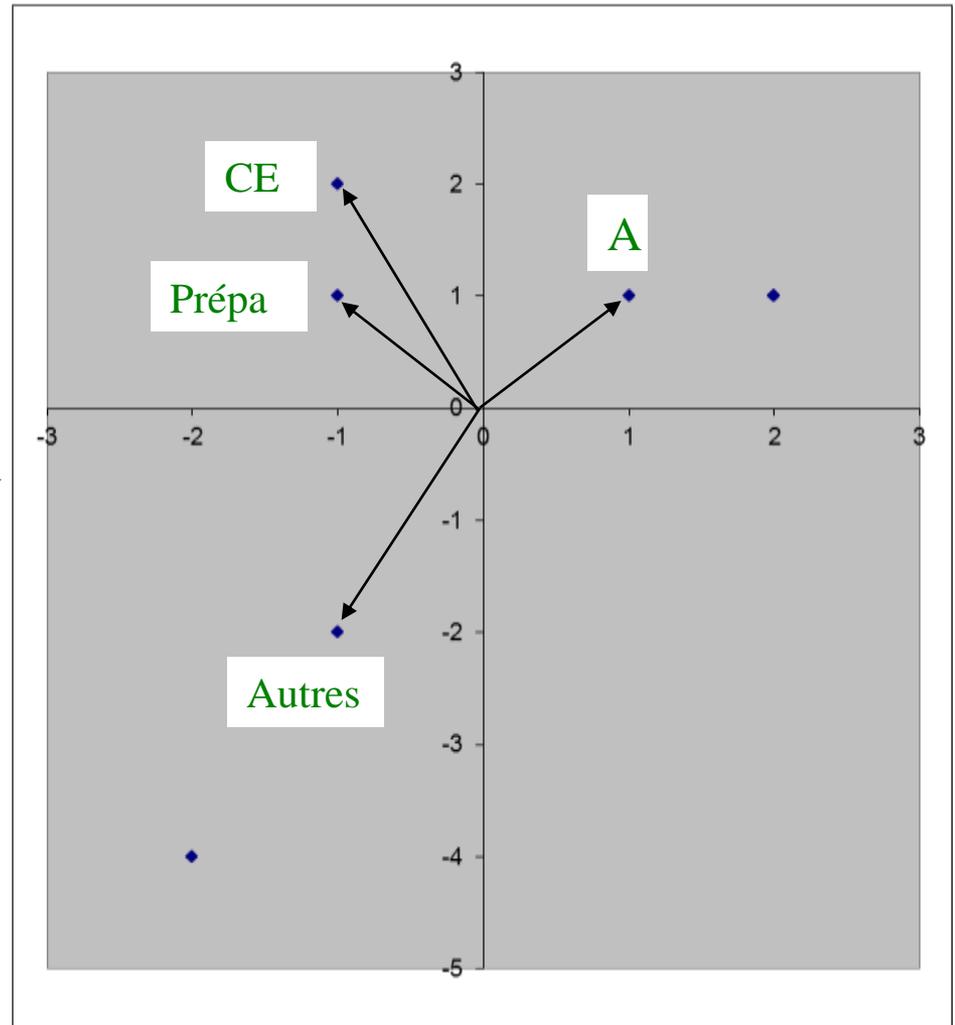
Produit scalaire négatif

Les Bacs A ne vont pas vers les « autres »
(IUT, BTS)

3. Quadrature

Produit scalaire nul

Les bacs A ne vont ni plus ni moins vers
les prépas que la moyenne des
bacheliers



Optimisation de la factorisation

- 1. Le Chi-2 (χ^2) comme métrique**
 - Degrés de liberté
- 2. Retour aux applications**
 - Analyse de mappings

5/ Mais Quelle est la meilleure décomposition possible pour R ?

En effet $R = T_1 + T_2 \dots$ mais il existe aussi

$$R = T'_1 + T'_2 = T''_1 + T''_2 \dots$$

Quel est le critère (la métrique) qui permet de définir les meilleurs T_1 et T_2 ?

Pour une matrice de rang n , on cherche d'abord à trouver la meilleure T_1 , puis la meilleure T_2 de telle manière à ce que le premier axe soit celui qui exprime le plus de sens..

La métrique que nous cherchons, c'est le Chi-2 (χ^2)

Le χ^2 représente l'écart à l'indépendance

- or cette indépendance, est exprimée par T_0
- ... l'écart à l'indépendance peut donc se mesurer comme l'écart à T_0

À partir de la matrice des données pour chaque cellule de T_1 et T_2 , on calcule

1. L'écart avec la cellule correspondante de T_0 **au carré** (d'où le « 2 » du χ^2)
2. On divise par l'effectif théorique de cette cellule (on parle de χ^2 pondéré)
3. Le χ^2 de la matrice est la somme de toutes les « contributions au χ^2 » de ses cellules
4. Le pourcentage des contributions de T_1 et T_2 par rapport au χ^2 de R donne les contributions relatives de T_1 et T_2 au χ^2 de T

Note sur le χ^2 : ses degrés de liberté

$$\chi^2(\mathbf{R}) = \chi^2(\mathbf{T}_1) + \chi^2(\mathbf{T}_2)$$

$$2491 = 1998 + 493$$

Attention à considérer le χ^2 en proportion de la richesse en information de la matrice = de son nombre de ddl.

À partir des distributions marginales on peut obtenir plusieurs matrices T_n , mais pour chaque ligne et chaque colonne, la dernière “case” est imposée par la contrainte du total marginal

Définition :

- On appelle degré de liberté par ligne (ddl) le nombre de colonnes (de modalités) diminué de 1.
- On appelle degré de liberté par colonne (ddc) le nombre de lignes (de modalités) diminué de 1.
- Le **degré de liberté du khi-deux** de la matrice est le produit ddl x ddc = ddl.
- Pour une matrice donnée, le χ^2 à prendre en compte est en fait χ^2 / ddl

Matrice T_1 maximisant le χ^2 dans notre cas

$$\chi^2(\mathbf{R}) = \chi^2(\mathbf{T}_1) + \chi^2(\mathbf{T}_2)$$

$$2491 = 1998 + 493$$

$$100\% = 80.2\% + 19.8\%$$

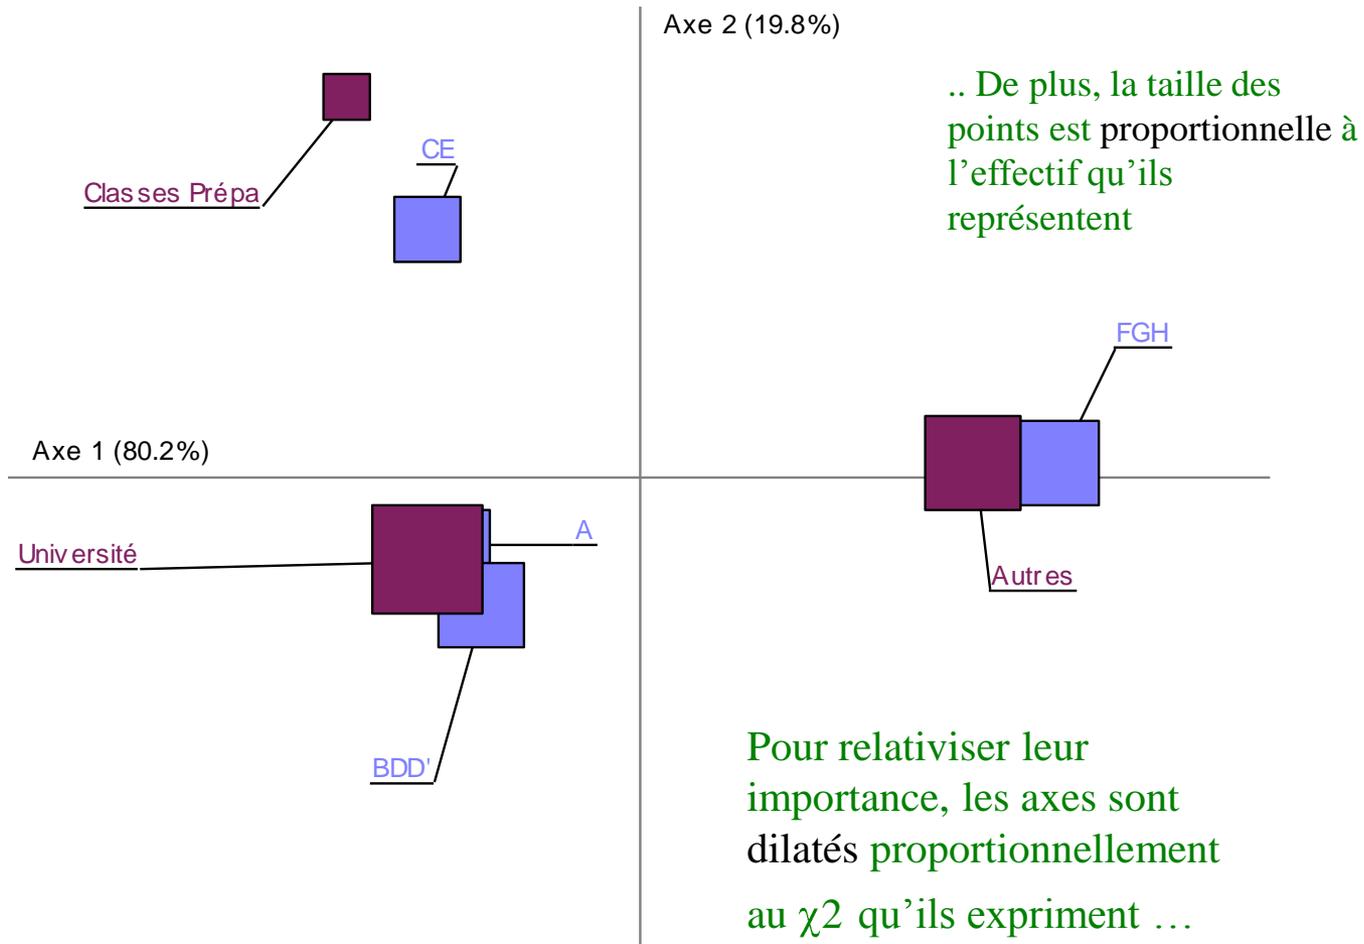
Cette ‘concentration’ de ce que l’on appelle le **pourcentage de la variance expliquée par un axe** est particulièrement intéressante lorsque la taille du tableau de données augmente...

$$\chi^2(\mathbf{R}) = \chi^2(\mathbf{T}_1) + \chi^2(\mathbf{T}_2) + \chi^2(\mathbf{T}_3) + \chi^2(\mathbf{T}_4) ..$$

Pourquoi ?

➔ On ne peut que représenter que deux axes à la fois sur un mapping ... autant représenter les plus significatifs.

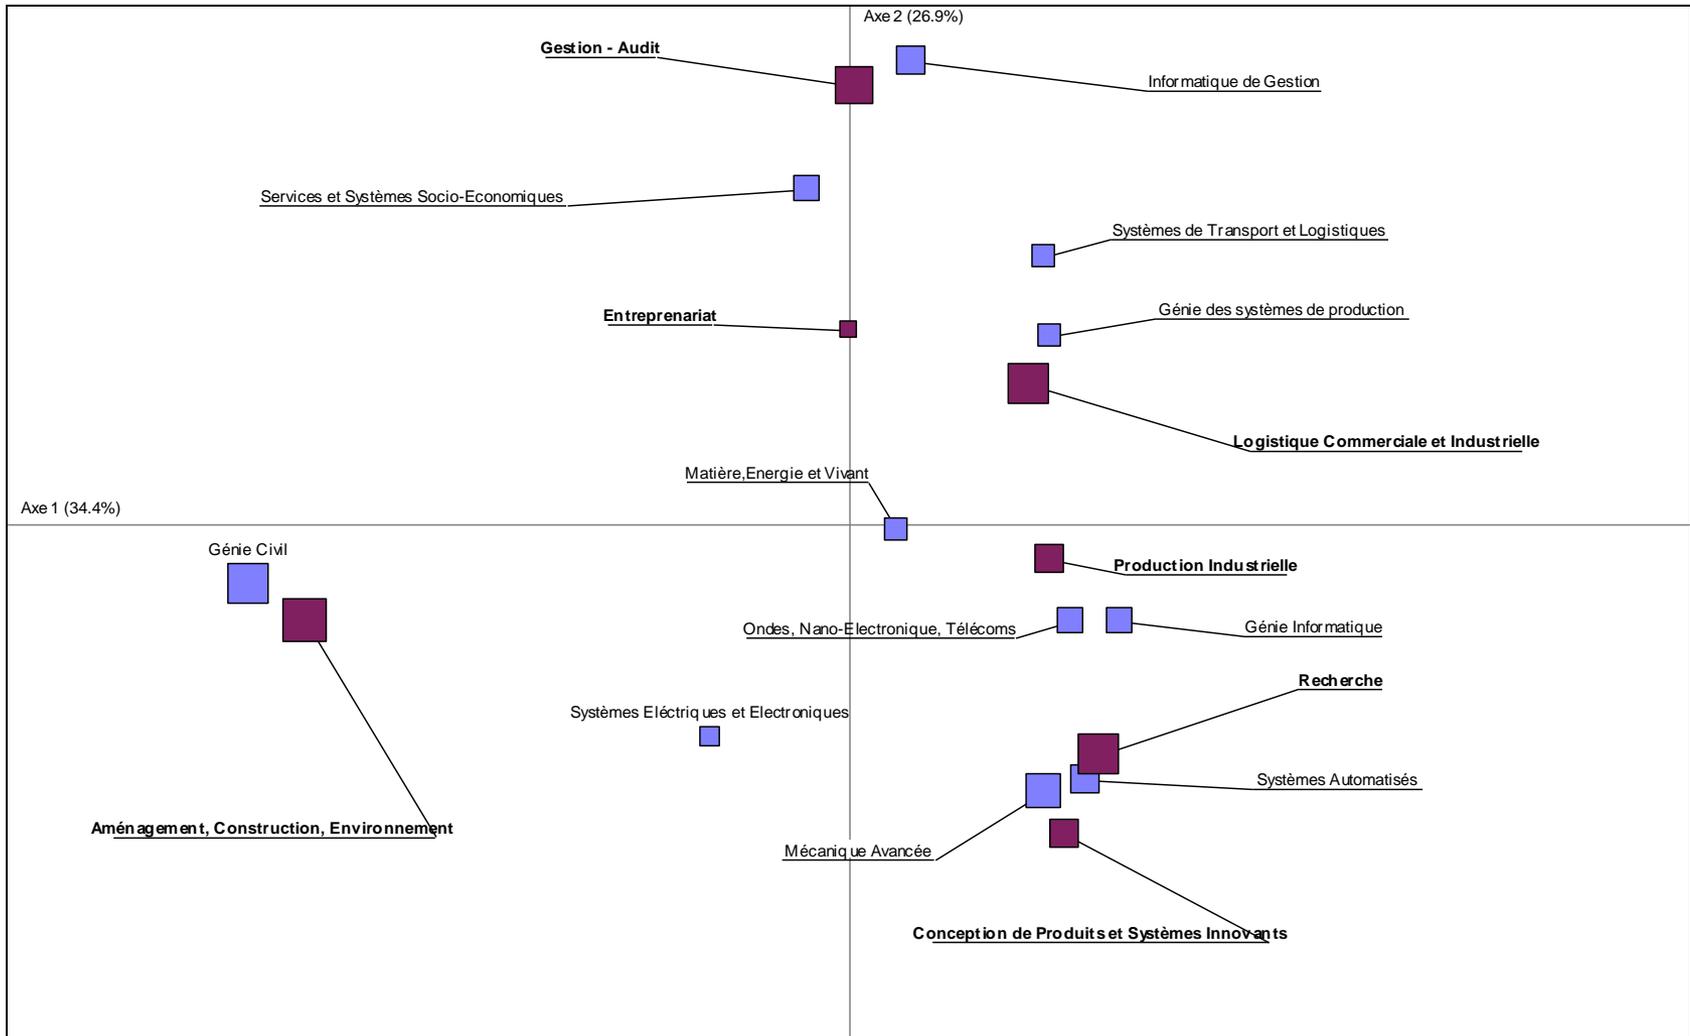
On obtient alors ce nouveau mapping



Application : quels souhaits d'options?

Premiers vœux 2003 de Génie / filière.	Entrepreneuriat	Gestion - Audit	Aménagement, Construction, Environnement	Conception de Produits et Systèmes Innovants	Production Industrielle	Logistique Commerciale et Industrielle	Recherche
Mécanique Avancée	0	0	2	7	5	1	6
Génie Civil	1	2	24	0	0	1	0
Matière, Energie et Vivant	0	1	2	0	5	1	1
Ondes, Nano- Electronique, Télécoms	2	1	0	1	0	1	6
Systèmes Electriques et Electroniques	0	0	3	2	0	1	1
Systèmes Automatisés	0	0	1	1	0	2	10
Génie des systèmes de production	0	5	0	0	4	4	0
Génie Informatique	0	0	0	3	1	5	2
Informatique de Gestion	2	11	0	0	0	2	1
Services et Systèmes Socio-Economiques	1	6	3	0	0	2	1
Systèmes de Transport et Logistiques	0	2	0	0	1	8	0

Mapping des choix de filière / génie



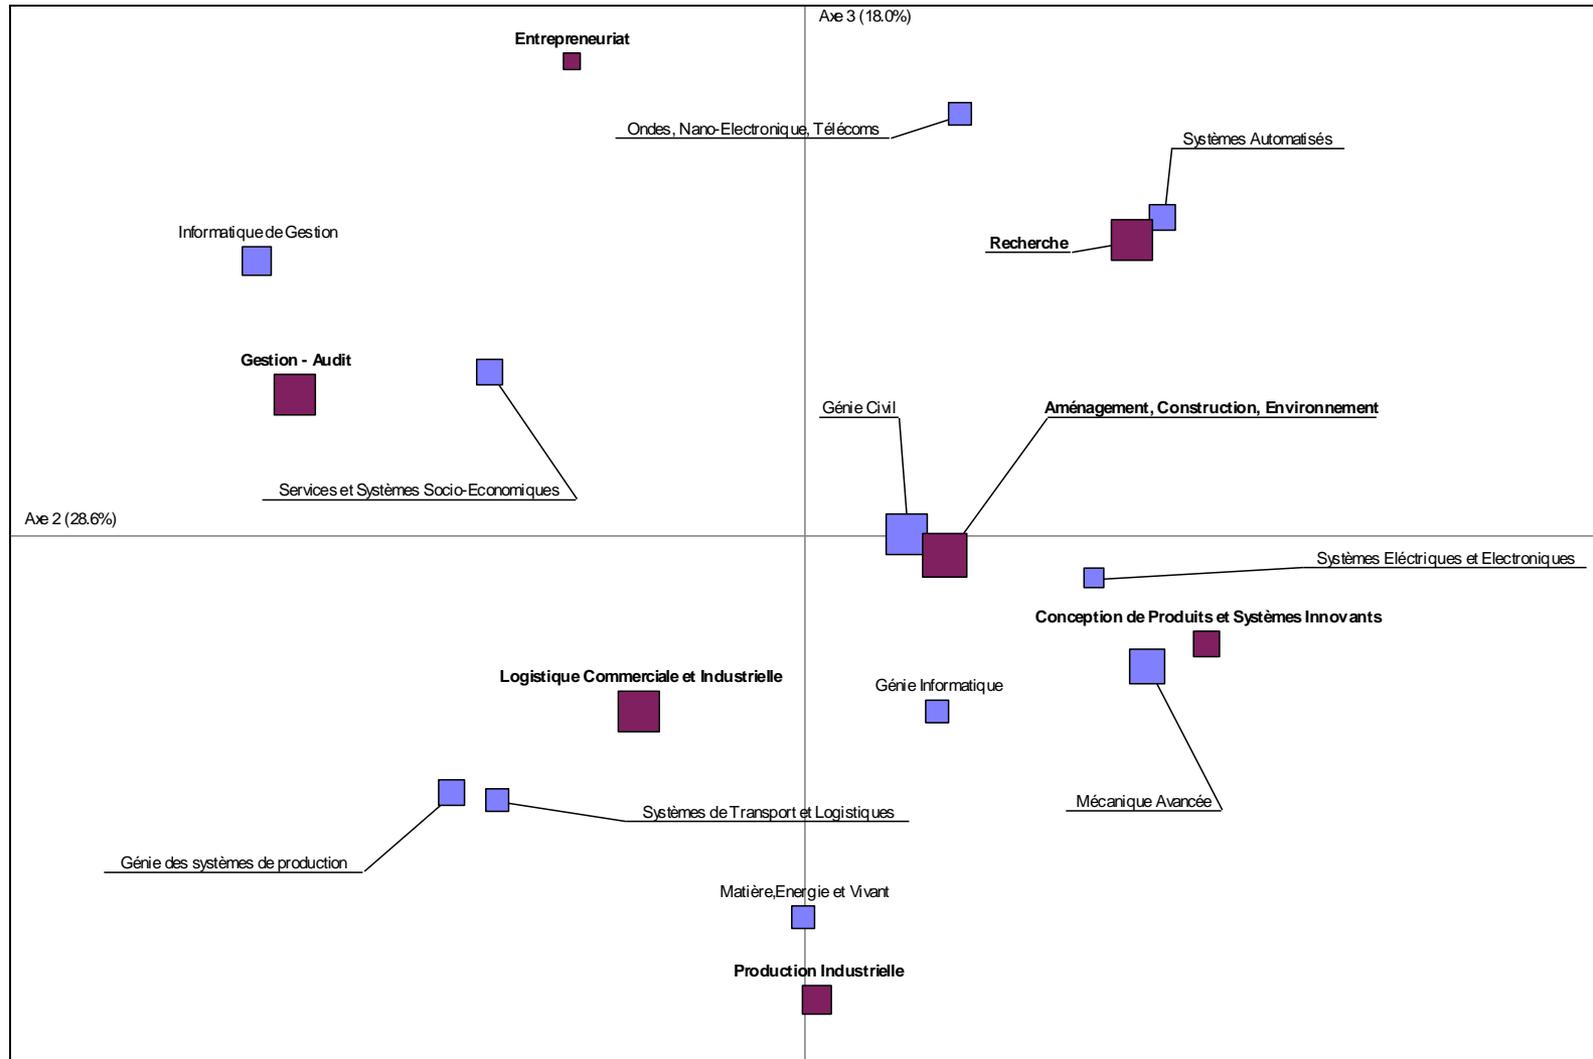
Premiers choix de génie / filière des 147 G2 en 2003

août 10

Utilisation ou copie interdites sans citation



C'était les deux premiers axes = 62% de la variance expliquée
On peut aussi regarder l'axe 3.. = 18%



Conclusion

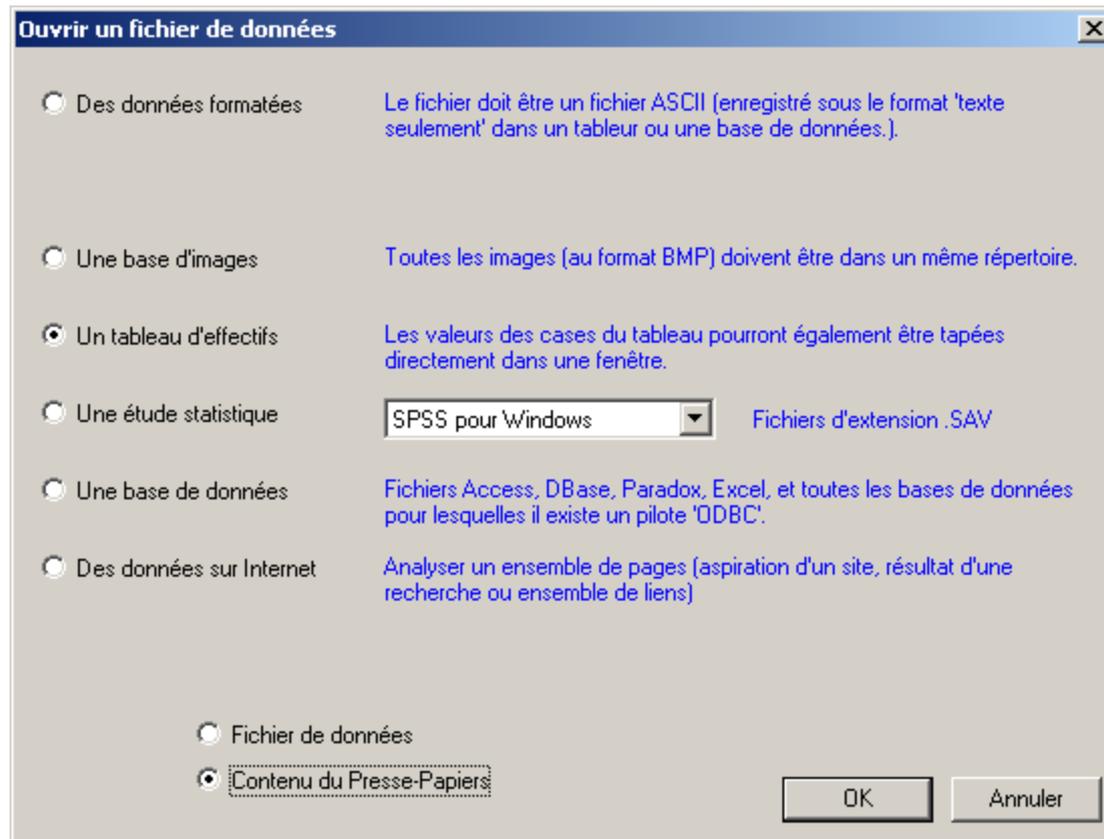
1. Mise en œuvre logicielle

- Sphinx, SPSS, SAS

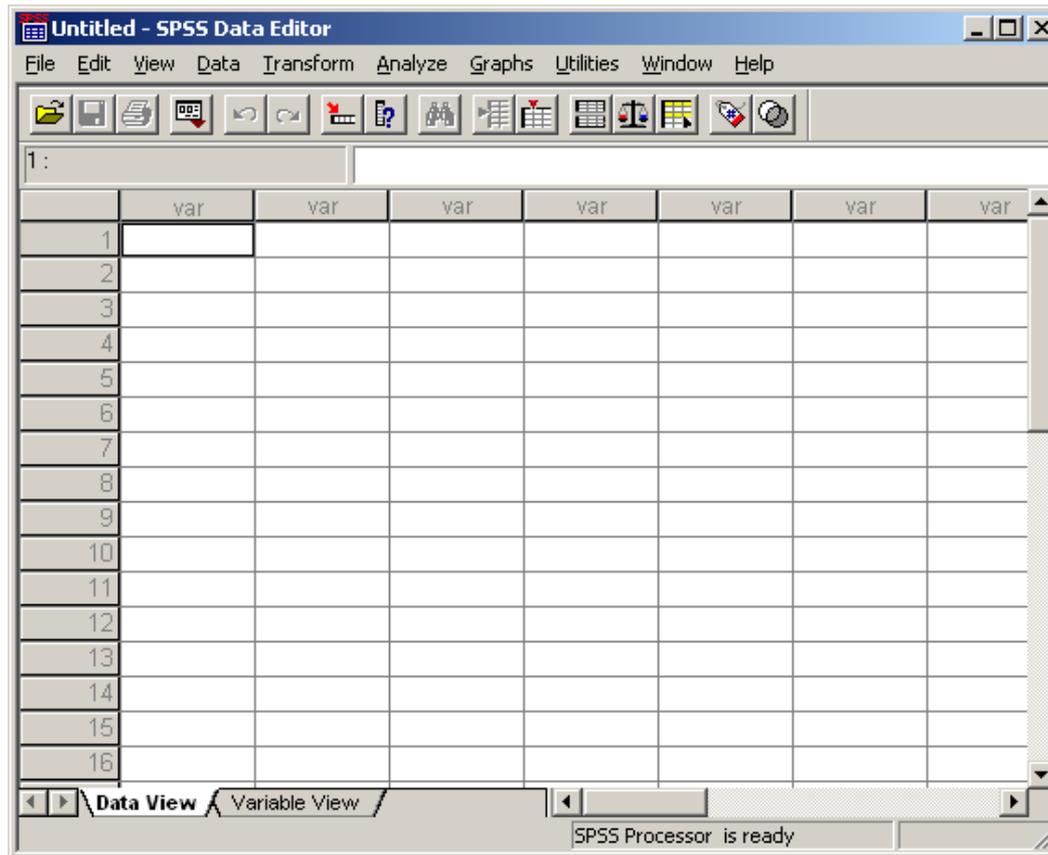
2. Généralisation de l'AFC

- Comparaison avec l'Analyse en Composantes Principales (ACP)
- Généralisation de l'AFC
- Pour approfondir

Mise en œuvre logicielle de l'AFC : Sphinx



Mise en œuvre logicielle : SPSS



Mise en œuvre logicielle : SAS

The SAS System 09:30 Tuesday, July 1, 2002 1

Age

	V1	Frequency	Percent	Cumulative Frequency	Cumulative Percent
0-4		10319	8.9	10319	8.9
5-9		11212	10.5	21531	19.4
10-14		11515	10.7	33046	30.1
15-19		10837	9.3	43883	39.4
20-24		8522	7.3	52405	46.7
25-29		7634	6.8	60039	53.3
30-34		6674	5.7	66713	59.0
35-39		6274	5.4	72987	64.4
40-44		5944	5.9	78931	70.3
45-49		7054	6.1	85985	76.3
50-54		8417	5.5	94402	81.0
55-59		5823	4.0	100225	86.7
60-64		4777	4.1	105002	90.8
65-69		4043	3.5	109045	94.2
70-74		2945	2.5	111990	96.8
75+		3758	3.2	115748	100.0

The SAS System 09:30 Tuesday, July 1, 2002 2

TOTCORB

	TOTCORB	Frequency	Percent	Cumulative Frequency	Cumulative Percent
0		28407	0	0	0
1		17701	15.9	17701	15.9
2		29652	20.4	47353	46.3
3		20814	14.4	68167	60.7
4		18247	9.6	86414	70.6
5		9413	6.8	95827	77.2
6		8189	4.3	104016	81.4
7		4812	3.2	108828	84.6
8		3252	2.2	112080	86.8
9		2477	1.7	114557	88.5
10		2825	1.3	117382	89.9
11		1600	1.1	118982	91.0
12		3329	0.9	122311	91.9
13		1100	0.8	123411	92.6
14		806	0.6	124217	93.3
15		814	0.6	125031	93.8
16		734	0.5	125765	94.3
17		612	0.4	126377	94.8
18		494	0.3	126871	95.1
19		486	0.3	127357	95.4
20		428	0.3	127785	95.7
21		350	0.2	128135	96.0
22		288	0.2	128423	96.2
..	

For help, press F1

Start | Internet Explorer | example1 - WordPad | Adobe Photoshop | 1:50 PM

Généralisations de l'AFC

- Les 'catégories' des questionnaires sont souvent mutuellement exclusives :
 - Sexe : H ou F
 - Politique : gauche, centre, droite
- Aux croisements de plus de deux caractéristiques : Analyse des Composantes Multiples (ACM)
 - Bac X Orientation X sexe

→ Tableau de Burt

1	0	0	0	1	0	1	0
0	2	0	1	1	1	1	1
0	0	2	1	1	1	0	0
0	1	1	2	0	1	1	0
1	1	1	0	3	1	1	1
0	1	1	1	1	2	0	0
1	1	0	1	1	0	2	0
0	1	0	0	1	0	0	1

Autre méthode d'analyse de données proche : l'Analyse en Composantes Principales

AFC ACP

Données	Catégorielles	Métriques
Décomposition	$T - T_0 = T_1 + T_2$	$T = T_1 + T_2 + T_3$
Métrique	χ^2 pondéré	χ^2

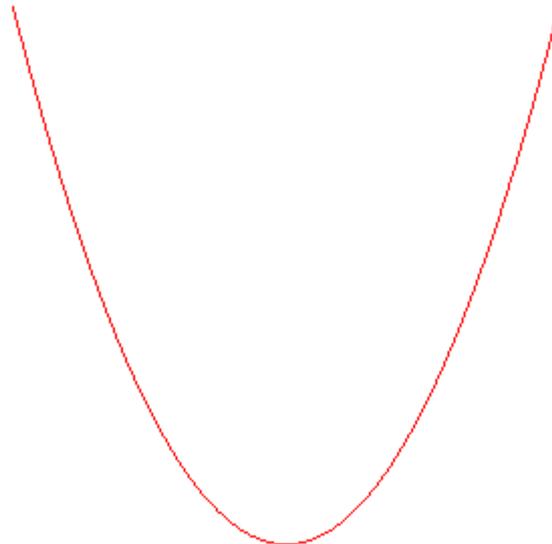
Attention, le poids des cellules à faible effectif est renforcé

Rapports entre ACP et AFC

- Si on a des données permettant de faire une AFC, peut-on y appliquer une ACP ?
 - Non
- Si on a des données permettant de faire une ACP, peut-on y appliquer un AFC ?
 - Oui !
- .. Mais alors ?
 - .. Alors on traite les données numériques, les nombres comme des catégories
 - Si par exemple on travaille sur des notes, 18/20 n'est plus « supérieur à » 10/20, il n'est pas non plus « plus proche » de 16/20 que de 10/20.

Effet particulier lorsque l'on traite des Likert

- Que voit-on sur une AFC s'il existe une relation linéaire entre deux Likert corrélées, comme par exemple
 - Q1 Aimez-vous les mathématiques (beaucoup/assez/un peu/pas du tout)
 - Q2 Avez-vous de bonnes notes en mathématiques (très bonnes/bonnes/moyennes/mauvaises)
- Les points du mapping suivent une parabole (c'est l'effet Guttman)



Pour en savoir plus

- Approches simples : rares
 - Site web de Philippe Cibois, professeur émérite de sociologie
 - [texte](#) d'où est tiré l'exemple développé dans ce cours
 - [Trideux : logiciel libre](#) de dépouillement d'enquête
 - [Analyse factorielle des correspondances](#) dans Wikipédia
 - Leçon [Analyse factorielle des correspondances](#) du CNAM
- Plus complexe : de nombreuses références
 - "[Statistique textuelle](#)" de Lebart et Salem, Chapitre 3
 - ...

Autres cours de méthodologie:

1. Explorer ou vérifier ? Deux catégories d'approches
2. Éventails des démarches de recueil de données
3. Conception de questionnaires
4. Techniques d'entretien et reformulation
5. Validité et Fiabilité des données
6. Mesurer, tester des hypothèses

Merci de votre attention !



Rémi BACHELET

*Enseignant-chercheur,
Ecole Centrale de Lille*

Mon CV est disponible <http://rb.ec-lille.fr>

Mes principaux cours à Centrale

Gestion de projet, sociologie des organisations, recueil, analyse et traitement de données, prévention du plagiat, module de marchés financiers, cours de qualité et méthodes de résolution de problèmes, établir des cartes conceptuelles, utiliser Wikipédia et CentraleWiki, formation au coaching pédagogique et à l'encadrement

