



Le ReJMiC présente :



Méthodes d'analyse non supervisées

Journée d'initiation à la bio-informatique n°2

24 juin 2022

A. Godmer



Plan

Partie I : L'Analyse en Composantes Principales (ACP)

Partie II : Clustering



Plan

Partie I : L'Analyse en Composantes Principales (ACP)

Partie II : Clustering



Introduction/ La PCA

PCA = Principal Component Analysis

ACP = Analyse en Composantes Principales

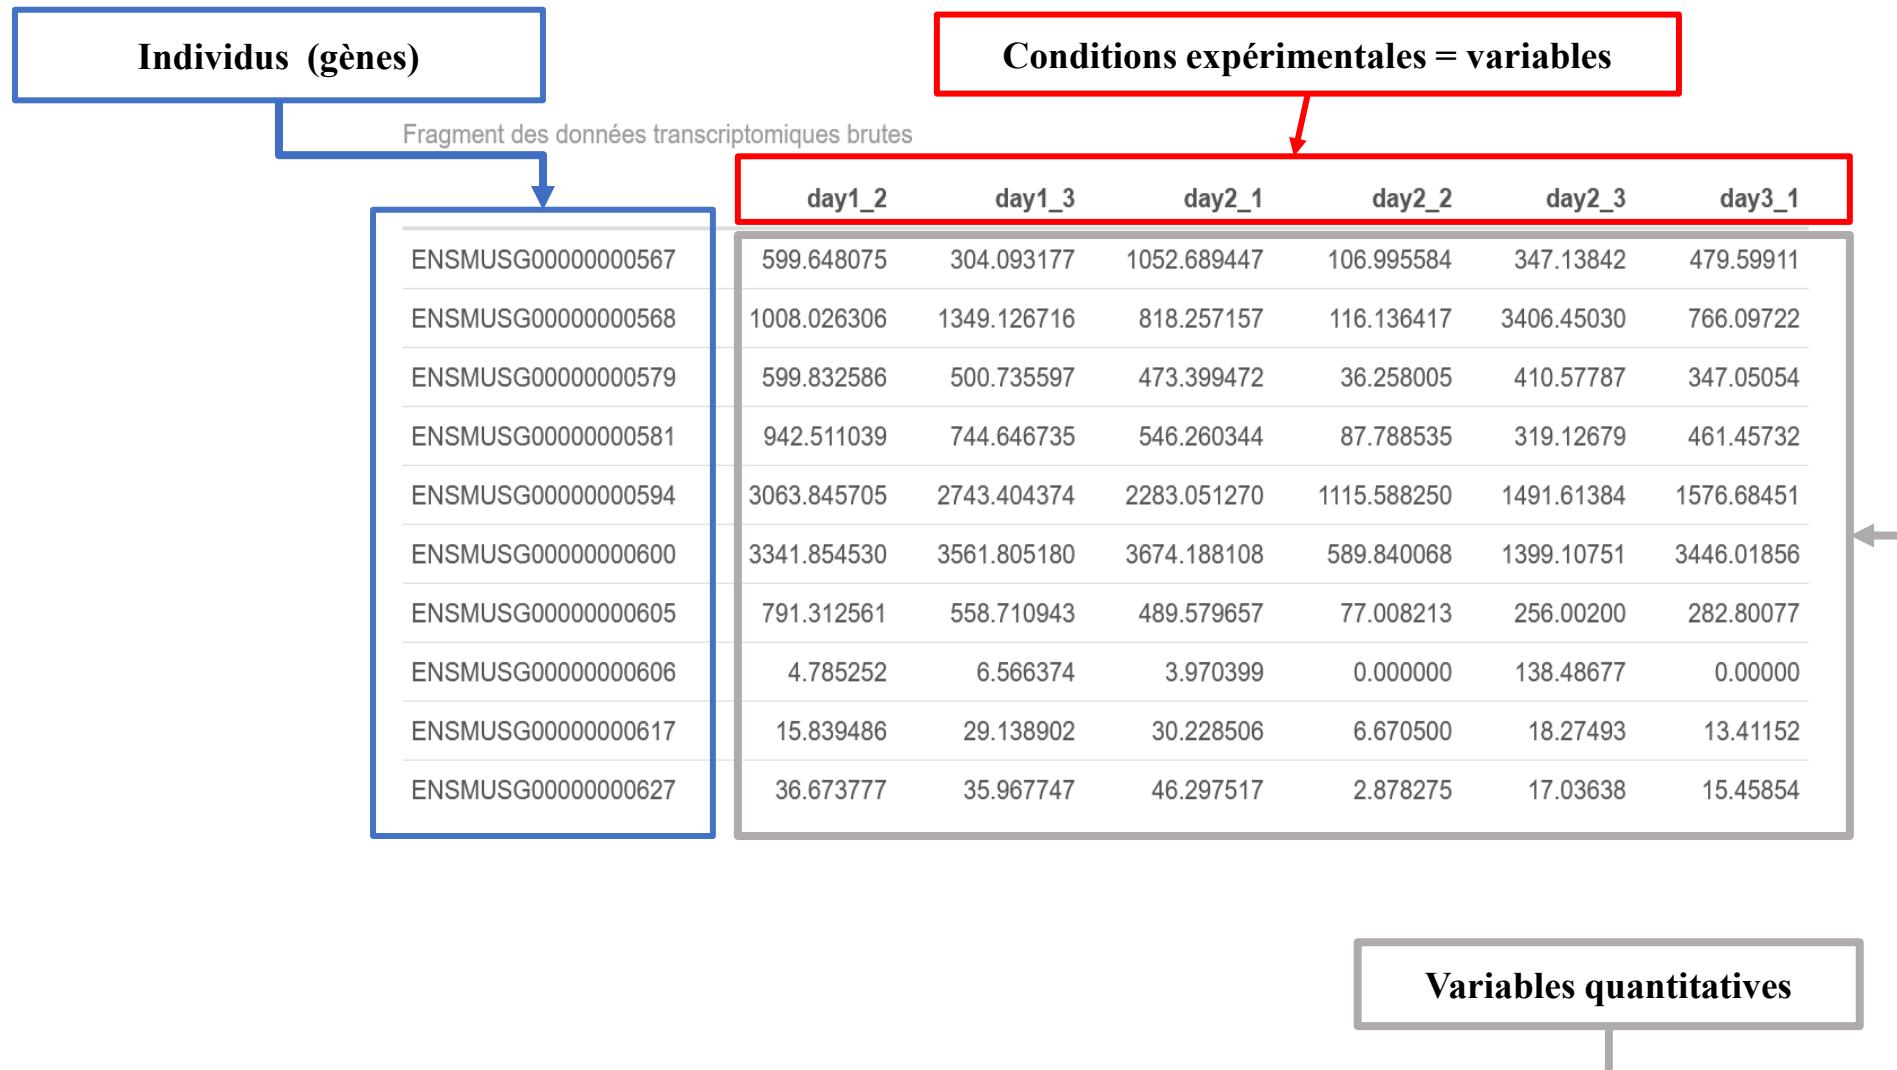
- Analyse **multivariée** (> 2 variables qui caractérisent un individu)
- Jeu de données contenant des **individus** décrits par **plusieurs variables quantitatives**
- Méthode de **visualisation sans a priori** → **méthode non supervisée**

Résumé des informations (tableau de données × individus) :

- **On parle de réduction de dimension**
- **En biologie :** données transcriptomiques, protéomiques...

Les données

Exemple données transcriptomiques



Rappel

Variance : mesure de la dispersion des variables

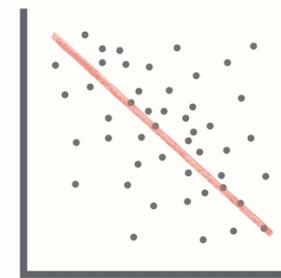
→ variance élevée = points éloignés autour de la moyenne

Covariance : mesure de la liaison entre deux variables

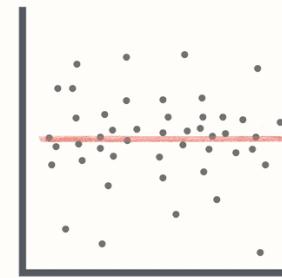
→ covariance élevée = relation forte entre deux variables

Corrélation : mesure standardisée de la covariance

→ la corrélation varie entre -1 et 1



Negative Correlation



No Correlation



Positive Correlation

La variance = information

Pourquoi la PCA ?

- Former des groupes d'individus semblables → ressemblance
- Former des groupes de variables liées entre elles → liaison - corrélation

Caractérisation des groupes d'individus par les variables



Quelles (groupes de) variables expliquent le plus la variabilité inter-individus ?

En biologie (exemple) :

Est-ce que la variance contenue dans les variables permet d'expliquer mes différents phénotypes (individus) ?

Objectifs de la PCA en biologie

- Analyse exploratoire des questions
- Comprendre la structure sous-jacente des données
- Identifier les biais, les erreurs expérimentales, les effets de lot
- Identifier les variables corrélées

Un exemple simple pour comprendre comment ça fonctionne

Notes de 11 élèves de 1 à 20 pour 5 disciplines

Variables

	Maths	Histoire-Géographie	Philosophie	Physique	Biologie fondamentale
eleve 1	10	19	9	4	7
eleve 2	12	12	13	6	9
eleve 3	16	18	14	10	13
eleve 4	7	12	16	1	4
eleve 5	18	9	11	12	15
eleve 6	16	12	17	10	13
eleve 7	13	14	10	7	10
eleve 8	12	14	7	6	9
eleve 9	11	12	15	5	8
eleve 10	9	16	11	3	6
eleve 11	9	16	11	3	6

Comment analyser simultanément ces 5 variables ?

Classiquement on aurait fait

Analyse univariée

→ Etudes des variables (colonnes)

	Maths	Histoire Géographie	Philosophie	Physique	Biologie fondamentale
Moyenne	10,9	13,8	12,3	6,7	8,8
Ecart type	4,6	2,9	3,1	3,2	3,6

→ Etude des individus (lignes)

	eleve 1	eleve 2	eleve 3	eleve 4	eleve 5	eleve 6	eleve 7	eleve 8	eleve 9	eleve 10	eleve 11
Moyenne	8,6	8,3	14,2	8,0	13,0	13,6	10,8	9,6	10,2	9,0	10,3
Ecart type	6,1	4,0	3,0	6,0	3,5	2,9	2,8	3,4	3,8	4,9	2,6

Classiquement on aurait fait

Analyse bivariée (matrice de corrélation)

→ Etudes des variables (colonnes)

	Maths	Histoire-Géographie	Philosophie	Physique	Biologie fondamentale
Maths	1	-0,28	0,11	0,71	0,95
Histoire-Géographie	-0,28	1	-0,33	-0,23	-0,28
Philosophie	0,11	-0,33	1	0,02	0,08
Physique	0,71	-0,23	0,02	1	0,89
Biologie fondamentale	0,95	-0,28	0,08	0,89	1

→ Etude des individus (lignes)

	eleve 1	eleve 2	eleve 3	eleve 4	eleve 5	eleve 6	eleve 7	eleve 8	eleve 9	eleve 10	eleve 11
eleve 1	1	0,73	0,71	0,6	-0,75	-0,13	0,62	0,63	0,48	0,88	0,93
eleve 2	0,73	1	0,29	0,8	-0,89	0,13	0,13	0	0,63	0,65	0,85
eleve 3	0,71	0,29	1	0,63	-0,09	0,38	0,99	0,92	0,68	0,92	0,74
eleve 4	0,6	0,8	0,63	1	-0,44	0,66	0,51	0,27	0,97	0,82	0,85
eleve 5	-0,75	-0,89	-0,09	-0,44	1	0,34	0,05	0,04	-0,22	-0,46	-0,71
eleve 6	-0,13	0,13	0,38	0,66	0,34	1	0,36	0,08	0,8	0,33	0,2
eleve 7	0,62	0,13	0,99	0,51	0,05	0,36	1	0,95	0,59	0,84	0,62
eleve 8	0,63	0	0,92	0,27	0,04	0,08	0,95	1	0,34	0,74	0,52
eleve 9	0,48	0,63	0,68	0,97	-0,22	0,8	0,59	0,34	1	0,79	0,75
eleve 10	0,88	0,65	0,92	0,82	-0,46	0,33	0,84	0,74	0,79	1	0,95
eleve 11	0,93	0,85	0,74	0,85	-0,71	0,2	0,62	0,52	0,75	0,95	1

Classiquement on aurait fait

Analyse bivariée (matrice de corrélation)

→ Etudes des variables (colonnes)

	Maths	Histoire-Géographie	Philosophie	Physique	Biologie fondamentale
Maths	1	-0,28	0,11	0,71	0,95
Histoire-Géographie	-0,28	1	-0,33	-0,23	-0,23
Philosophie	0,11	-0,33	1	0,02	0,86
Physique	0,71	-0,23	0,02	1	0,86
Biologie fondamentale	0,95	-0,28	0,08	0,86	1

→ Etude des individus (lignes)

	eleve 1	eleve 2	eleve 3	eleve 4	eleve 5	eleve 6	eleve 7	eleve 8	eleve 9	eleve 10	eleve 11
eleve 1	1	0,73	0,71	0,6	-0,09	0,6	0,6	0,6	0,48	0,88	0,93
eleve 2	0,73	1	0,29	0,8	0,63	0,63	0,63	0,63	0,63	0,65	0,85
eleve 3	0,71	0,29	1	0,63	-0,09	0,63	0,63	0,63	0,68	0,92	0,74
eleve 4	0,6	0,8	0,63	1	-0,44	0,66	0,66	0,51	0,27	0,97	0,82
eleve 5	-0,75	-0,89	-0,09	-0,44	1	0,34	0,34	0,05	0,04	-0,22	-0,46
eleve 6	-0,13	0,13	0,38	0,66	0,34	1	0,36	0,08	0,8	0,33	0,2
eleve 7	0,62	0,13	0,99	0,51	0,05	0,36	1	0,95	0,59	0,84	0,62
eleve 8	0,63	0	0,92	0,27	0,04	0,08	0,95	1	0,34	0,74	0,52
eleve 9	0,48	0,63	0,68	0,97	-0,22	0,8	0,59	0,34	1	0,79	0,75
eleve 10	0,88	0,65	0,92	0,82	-0,46	0,33	0,84	0,74	0,79	1	0,95
eleve 11	0,93	0,85	0,74	0,85	-0,71	0,2	0,62	0,52	0,75	0,95	1

Et si on essayait la PCA ?

Un exemple simple pour comprendre comment ça fonctionne

Notes de 11 élèves de 1 à 20 pour 5 disciplines

Variables

	Maths	Histoire-Géographie	Philosophie	Physique	Biologie fondamentale
eleve 1	10	19	9	4	7
eleve 2	12	12	13	6	9
eleve 3	16	18	14	10	13
eleve 4	7	12	16	1	4
eleve 5	18	9	11	12	15
eleve 6	16	12	17	10	13
eleve 7	13	14	10	7	10
eleve 8	12	14	7	6	9
eleve 9	11	12	15	5	8
eleve 10	9	16	11	3	6
eleve 11	9	16	11	3	6

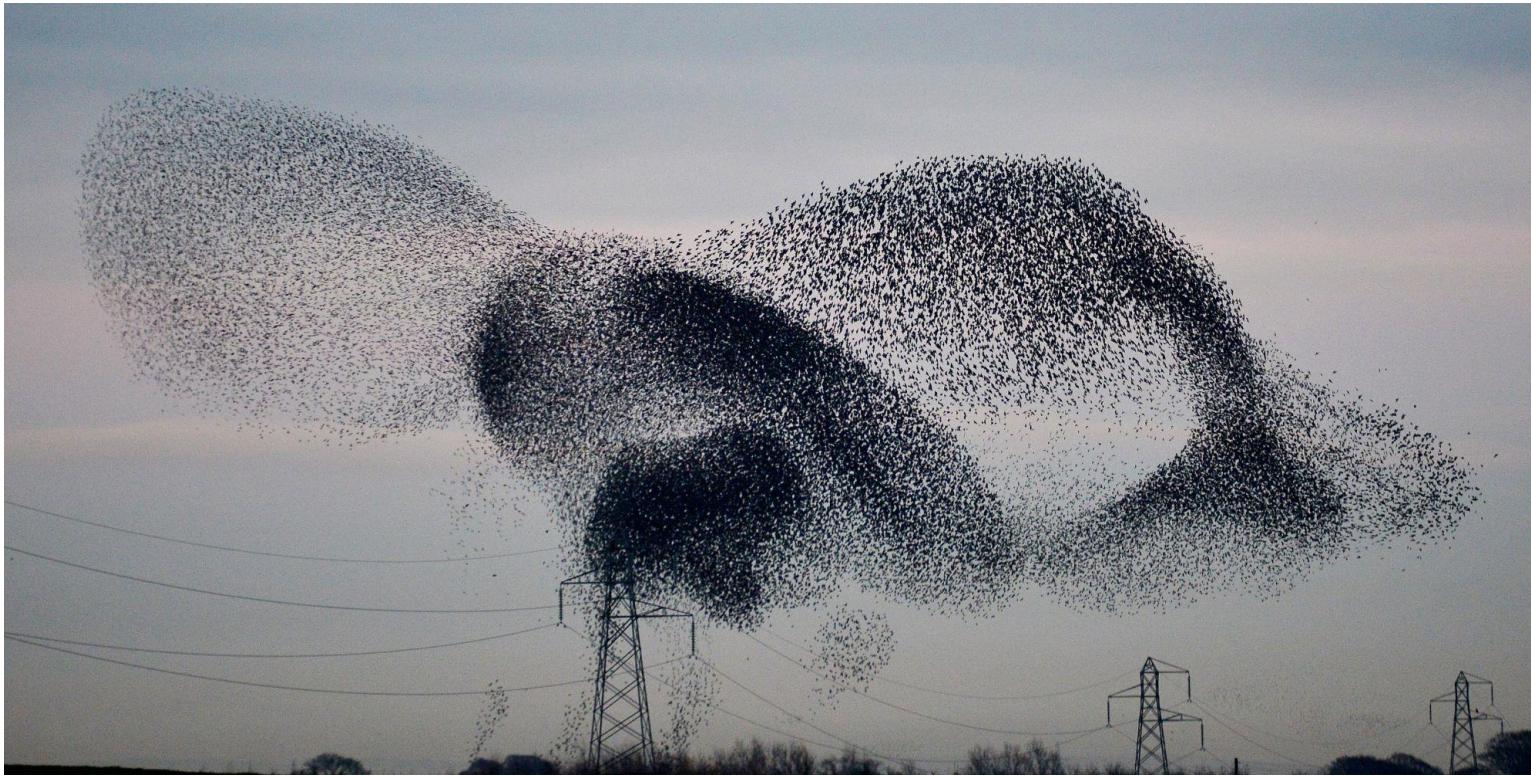
Comment analyser simultanément ces 5 variables ?

Etude des individus

- Un individu = 1 ligne du tableau → 1 point dans un espace à p ($n=\text{variables}$) dimensions
 - si $p = 2 \rightarrow$ nuage de points
 - si $p = 3 \rightarrow$ espace 3D
 - si $p \geq 4 \rightarrow$ représentation impossible
- Notion de ressemblance entre les individus
 - deux individus se ressemblent → valeurs proches sur l'ensemble des p variables
 - mesure de la distance entre les individus (somme des carrés des écarts pour chaque variable)
- Visualisation de la forme du nuage de points → étude des individus

Etude des individus

- Visualisation d'un nuage de point en 2D (photo) à partir d'un espace 3D

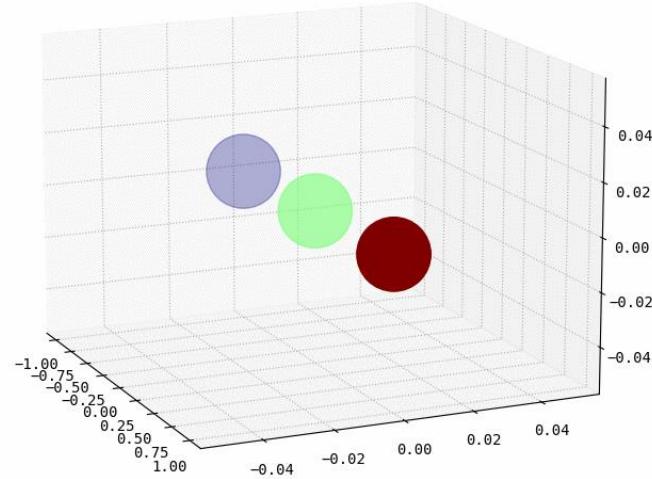


[Comment les oiseaux synchronisent-ils leur vol ? \(vidéo\) | Etrange et Insolite \(jack35.fr\)](#)

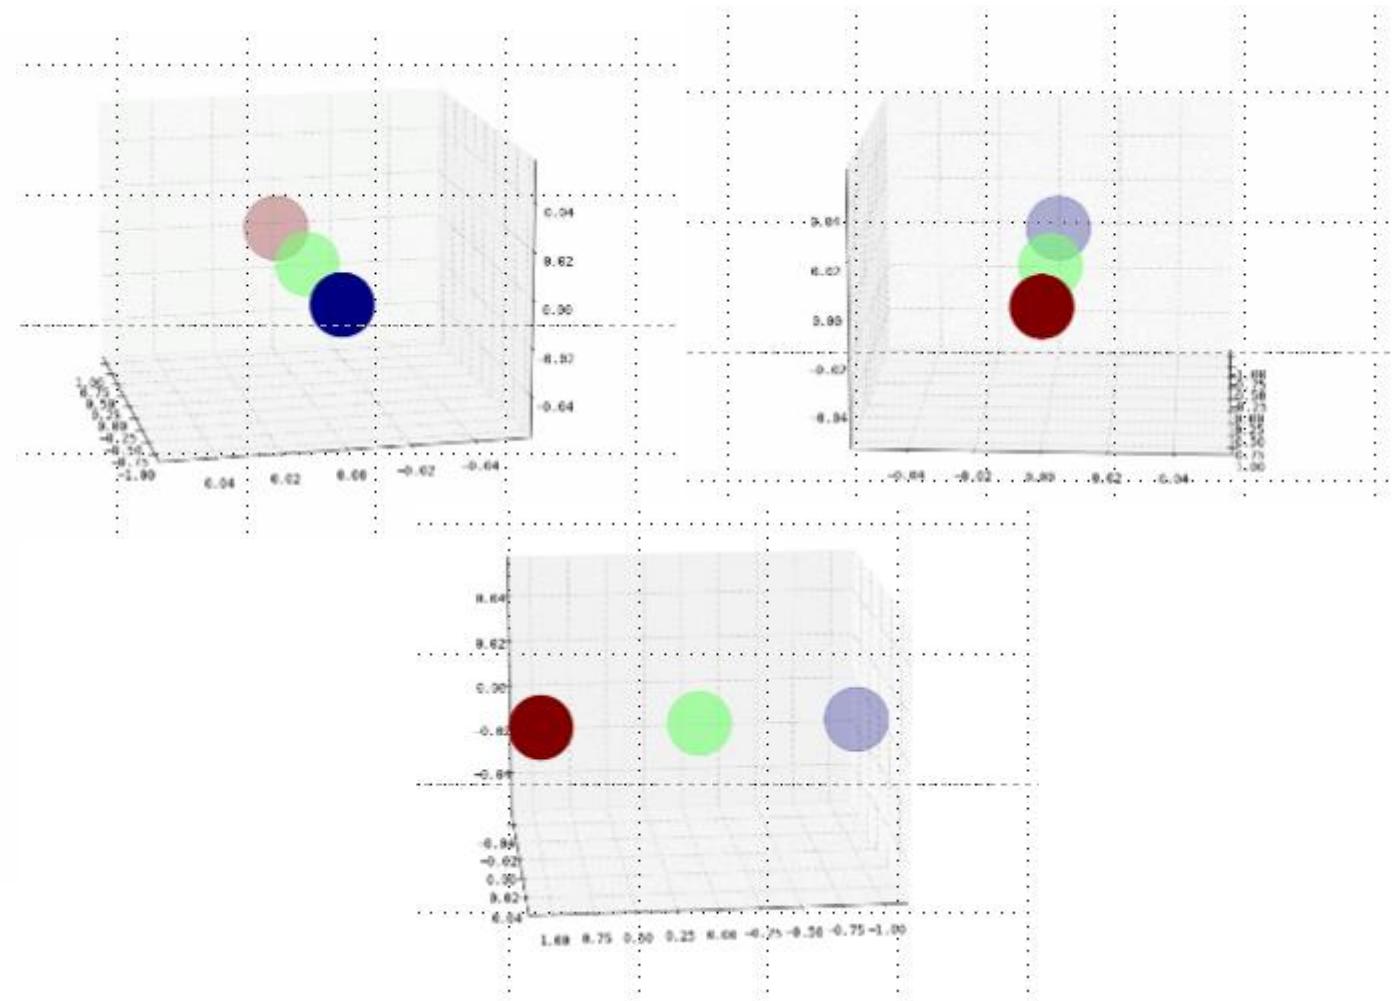
- L'ACP va fournir une image simplifiée
- Trouver le sous espace qui résume le plus fidèlement les données (restitution de l'image originale)

Etude des individus

- Quelle représentation choisir ?

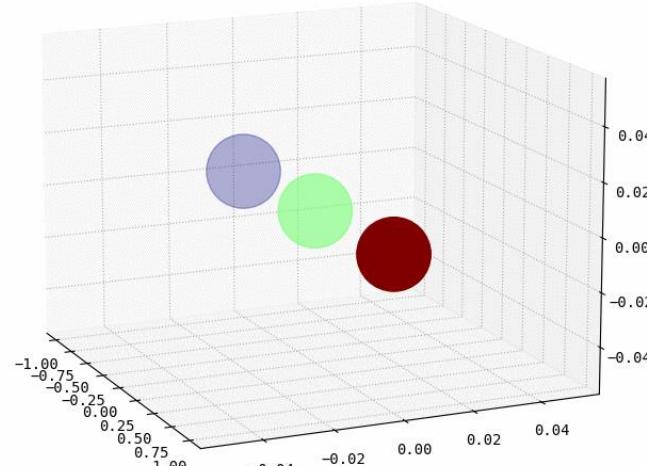


<https://github.com/matplotlib/matplotlib/issues/5830/>

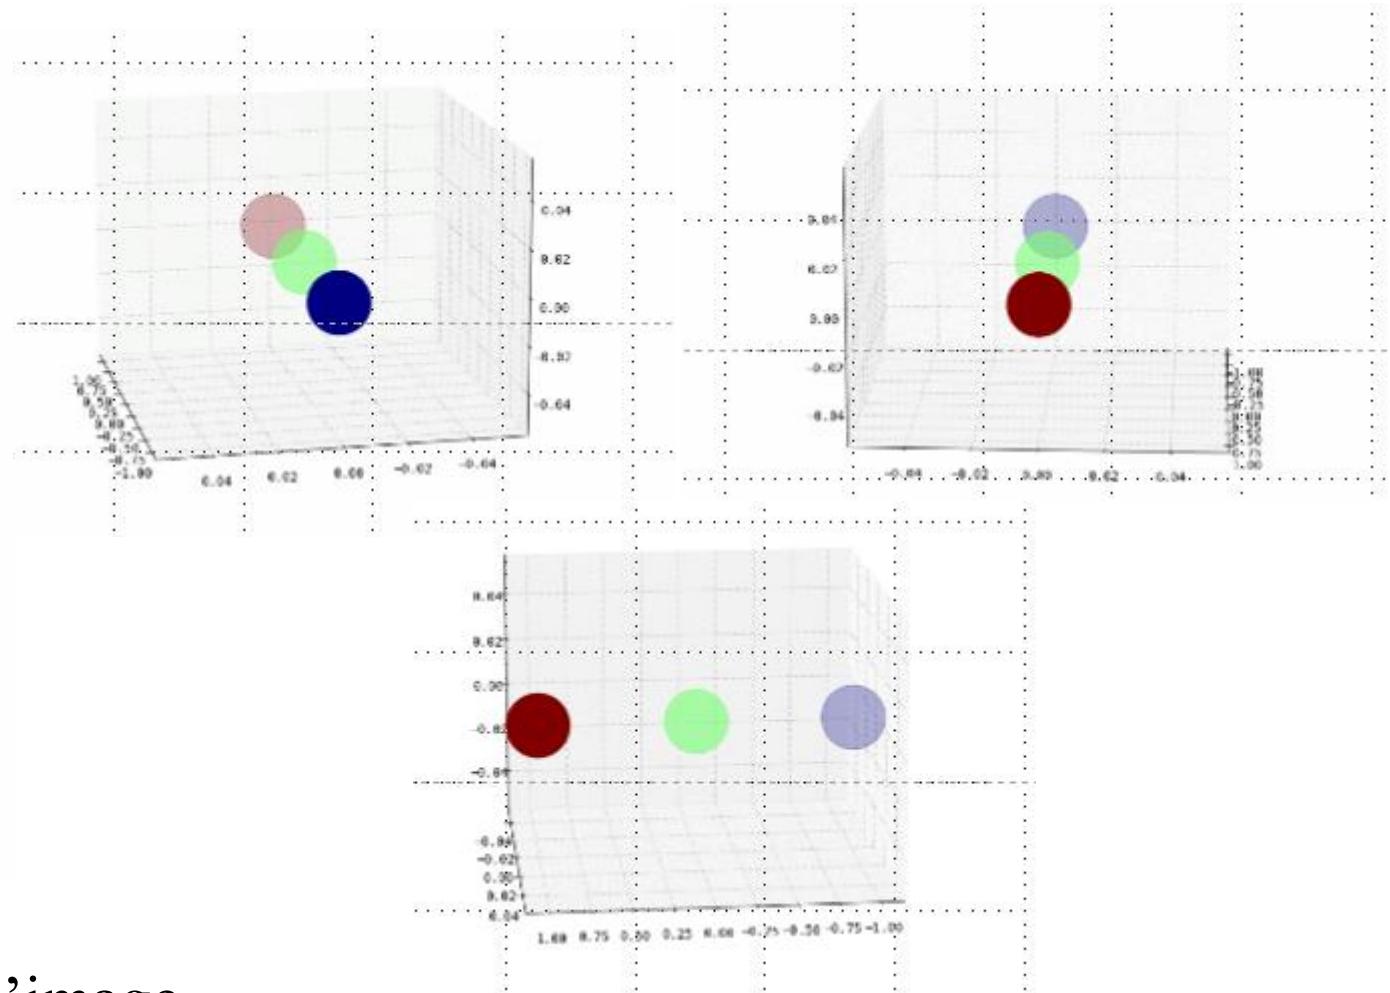


Etude des individus

- Quelle représentation choisir ?



<https://github.com/matplotlib/matplotlib/issues/5830/>



- Une image est bonne :

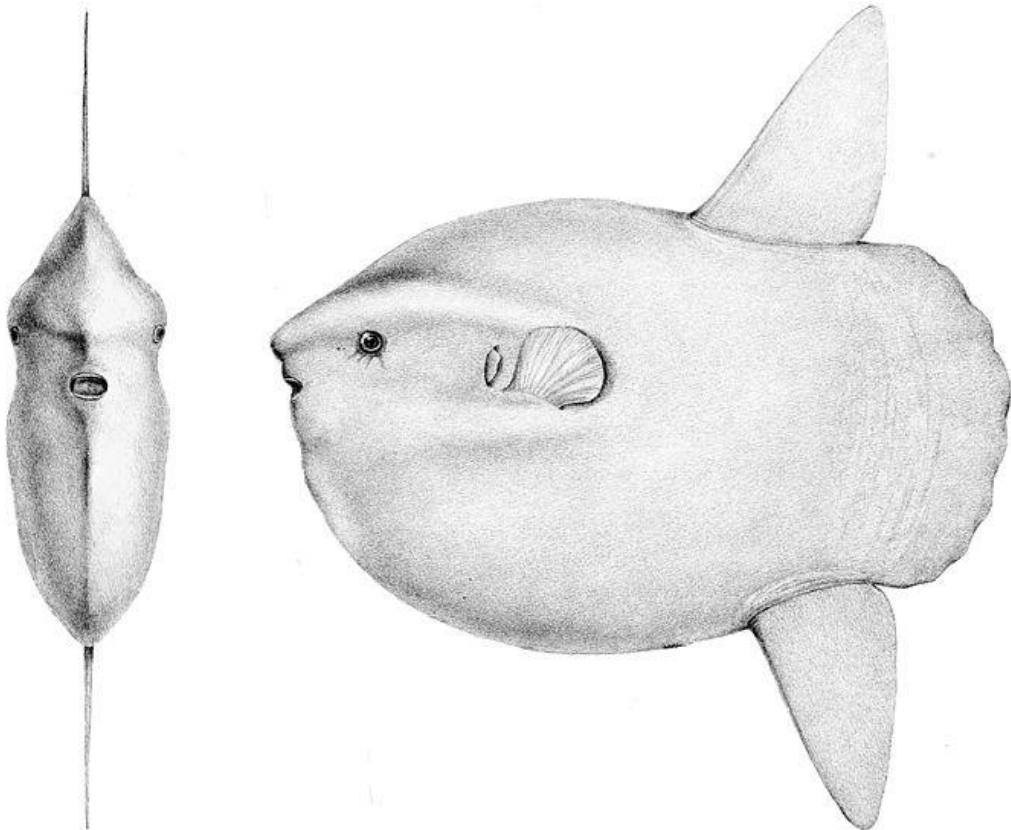
- si elle restitue la forme initiale de l'image
- si elle ne déforme pas les distances entre les individus
- si elle représente au mieux la diversité et la variabilité des données

Etude des individus

- Comment dire qu'une image est de bonne qualité ?
 - Notion de variabilité ou de dispersion sur plusieurs dimensions = inertie
 - Inertie = variance généralisée sur plusieurs dimensions

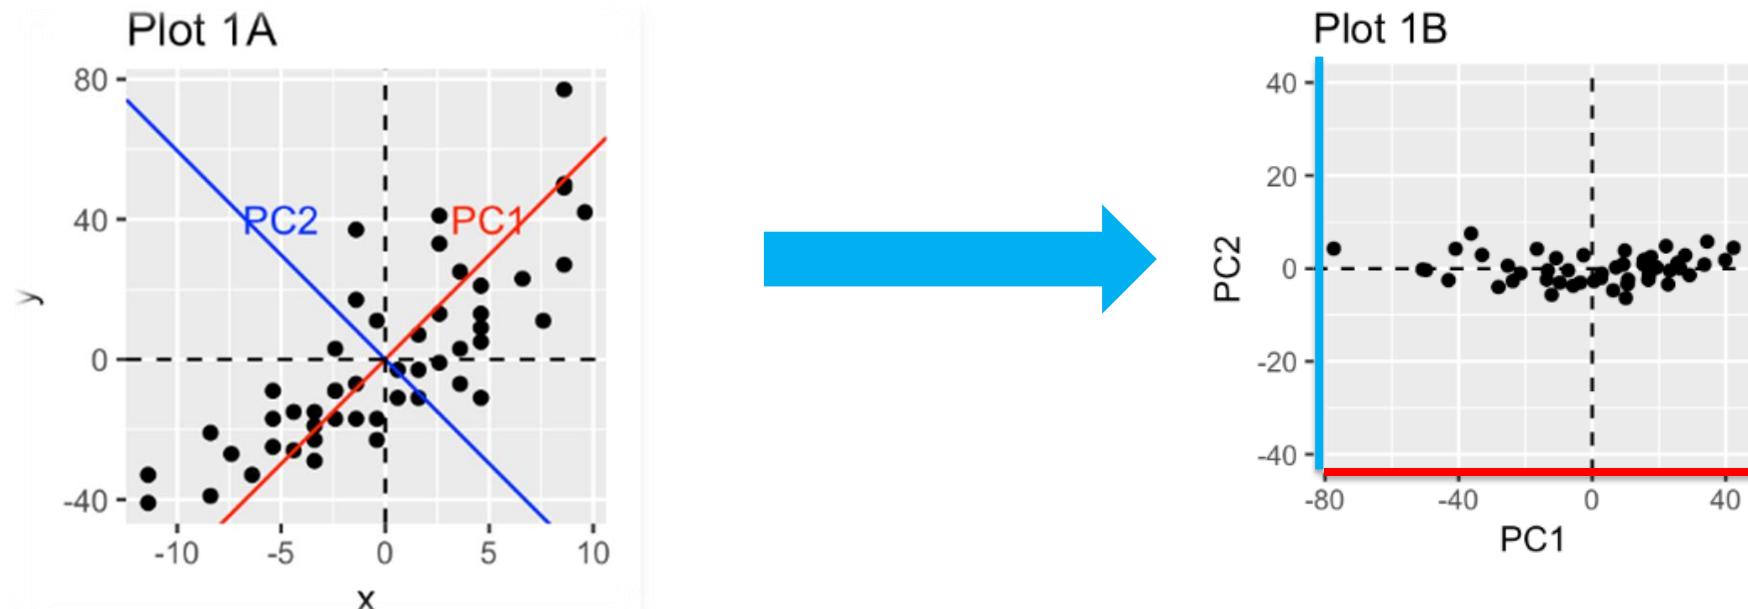


[https://fr.wikipedia.org/wiki/M%C3%A3le_\(poisson\)#/media/Fichier:Sunfish2.jpg](https://fr.wikipedia.org/wiki/M%C3%A3le_(poisson)#/media/Fichier:Sunfish2.jpg)



https://fr.m.wikipedia.org/wiki/Fichier:Mola_mola_face_profile.jpg

Etude des individus



<https://www.analyticsvidhya.com/blog/2020/12/an-end-to-end-comprehensive-guide-for-pca/>

→ Composantes principales :

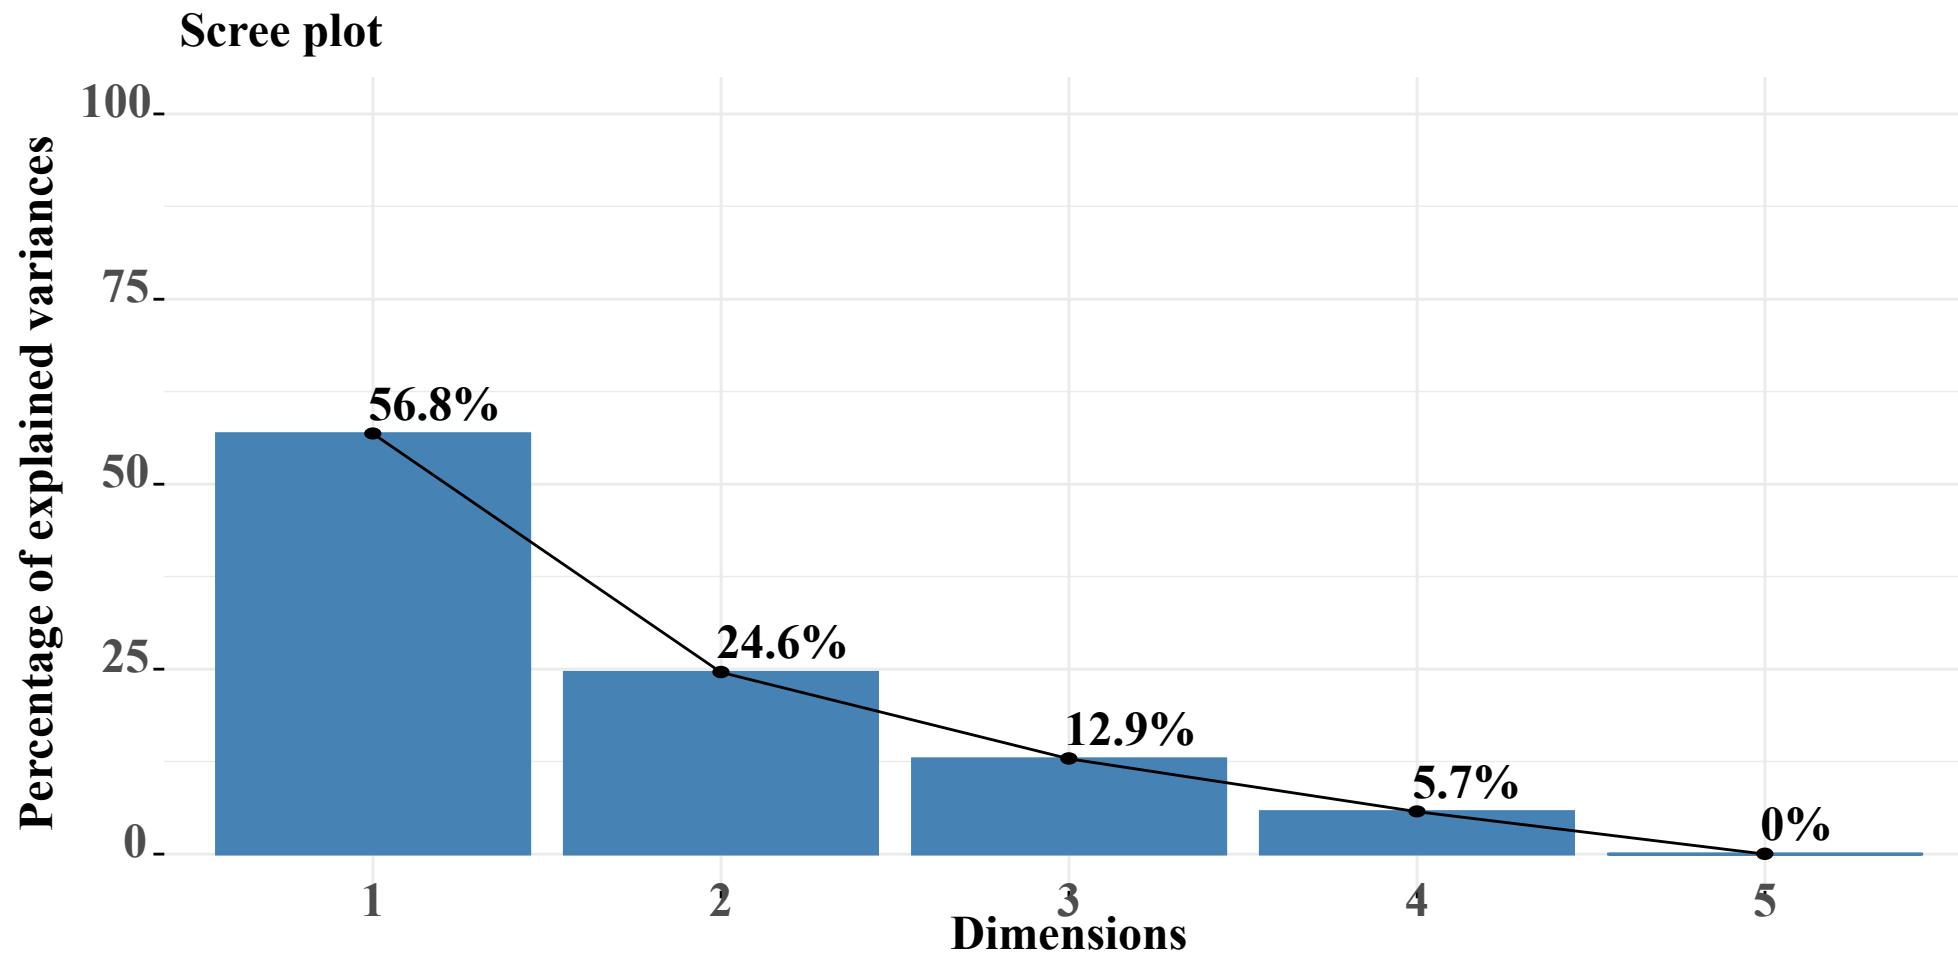
- Les variables originales = variable artificielles pour expliquer l'information (ici la variance)

→ Séparation avec les composantes principales (PC1 et PC2) :

- La direction des axes = maximisation de la variance
- PC1 : premier axe principal → direction selon le maximum de variance entre les individus
- PC2 : deuxième axe principal → seconde direction la plus importante, orthogonale à PC1

Valeurs propres/Variances

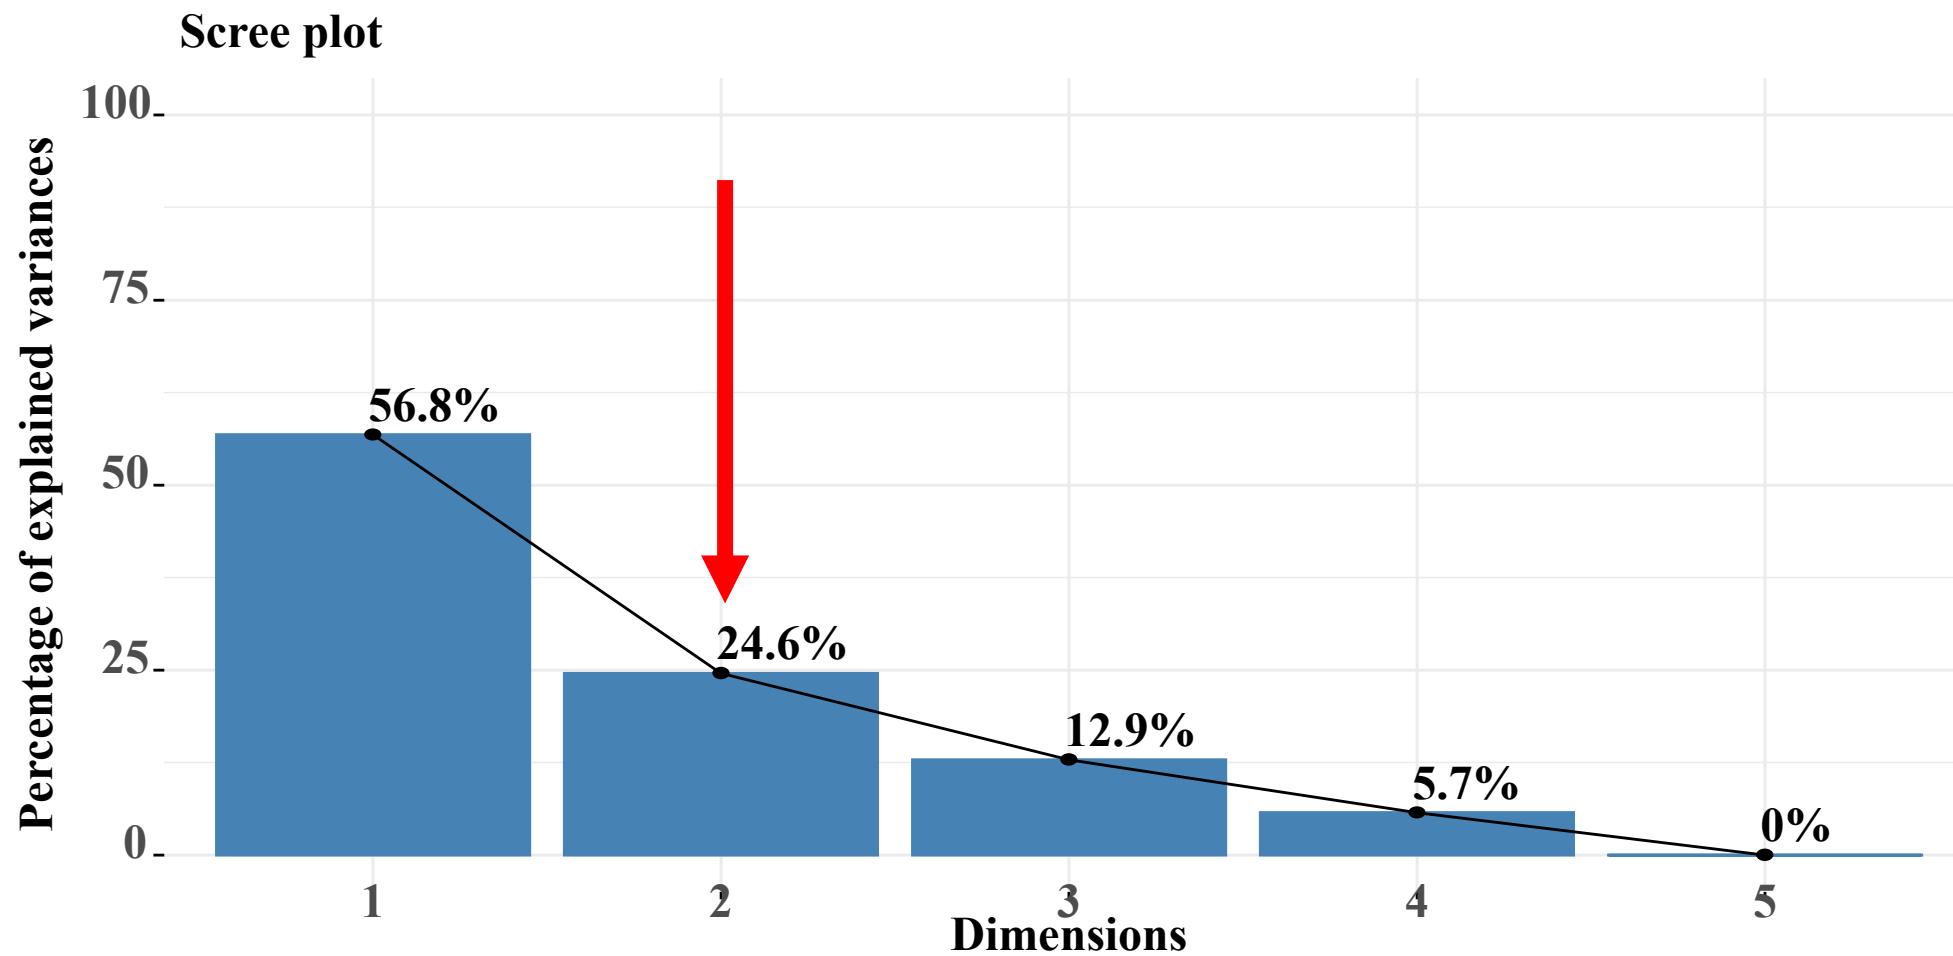
Valeurs propres (eigenvalues en anglais) : mesure de la quantité de variance par composante



Quantité d'information (variance) par composante

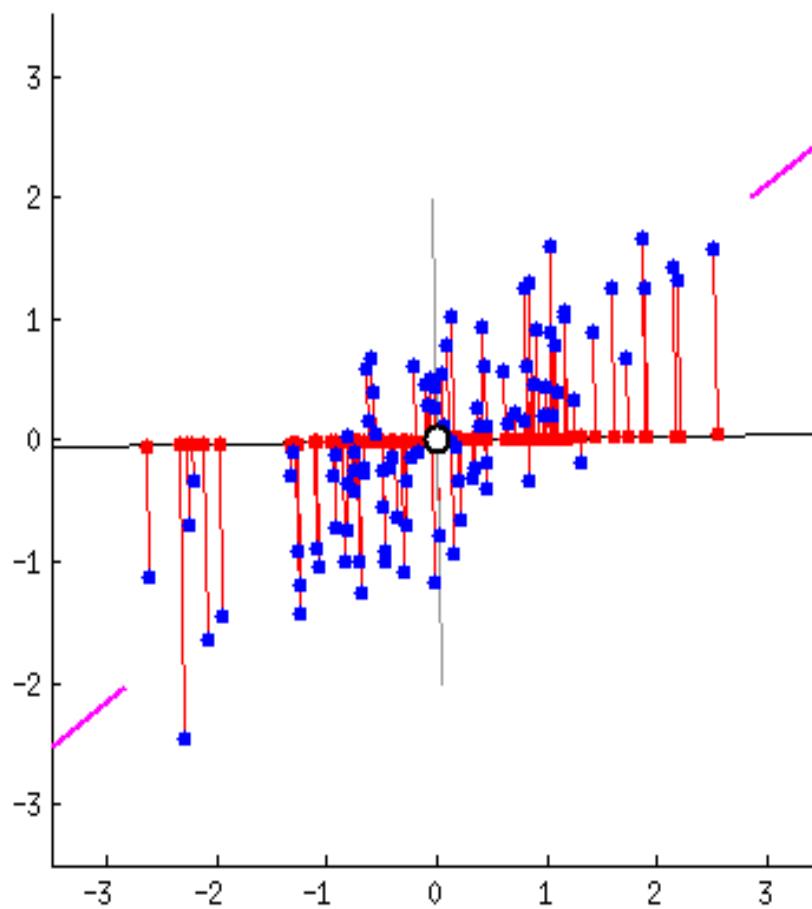
Valeurs propres/Variances

Valeurs propres (eigenvalues en anglais) : mesure de la quantité de variance par composante



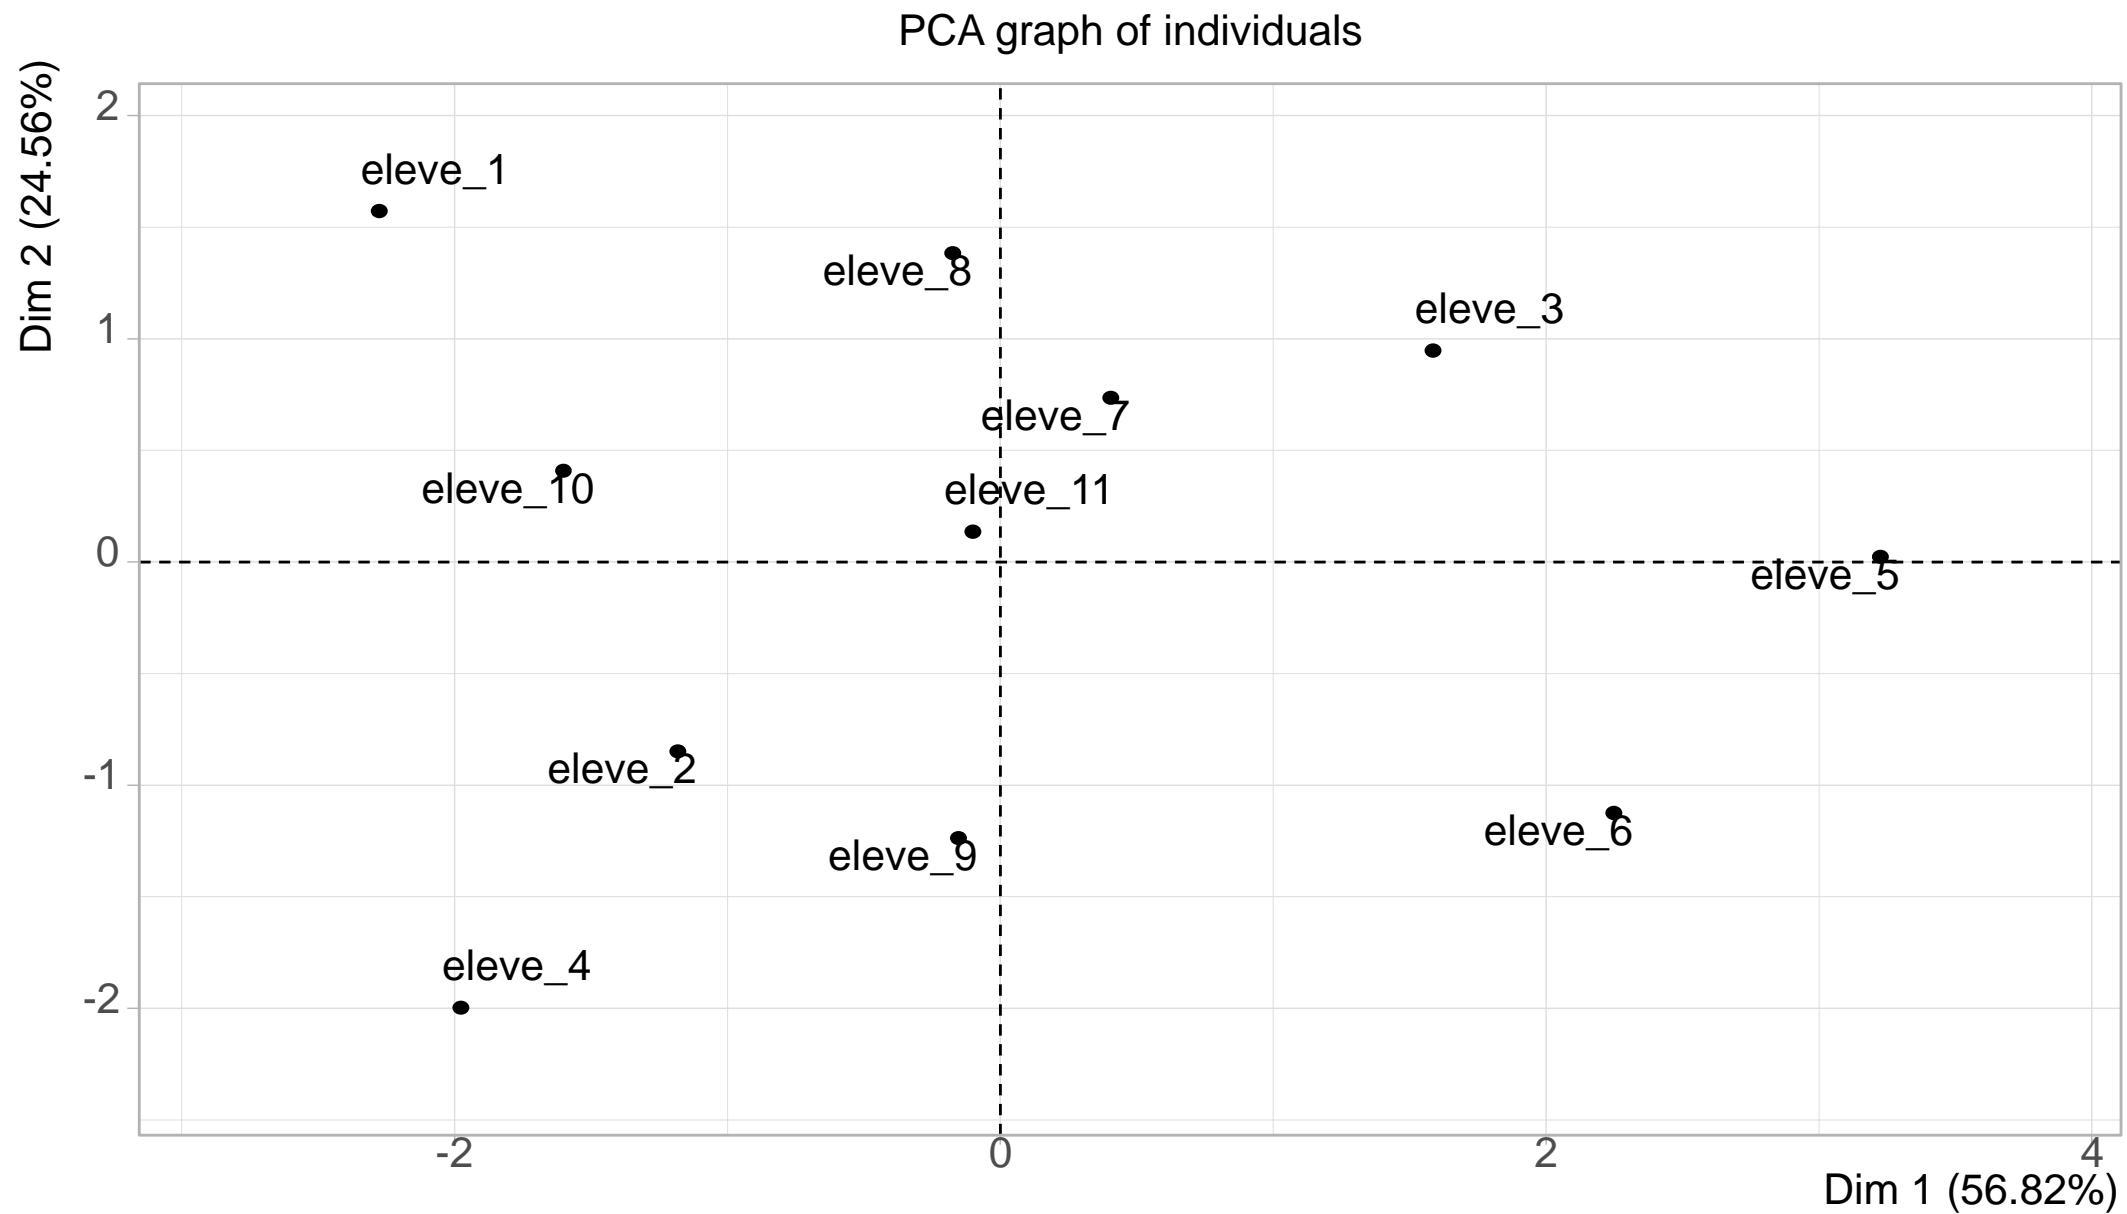
Quantité d'information (variance) par composante

Etudes des individus

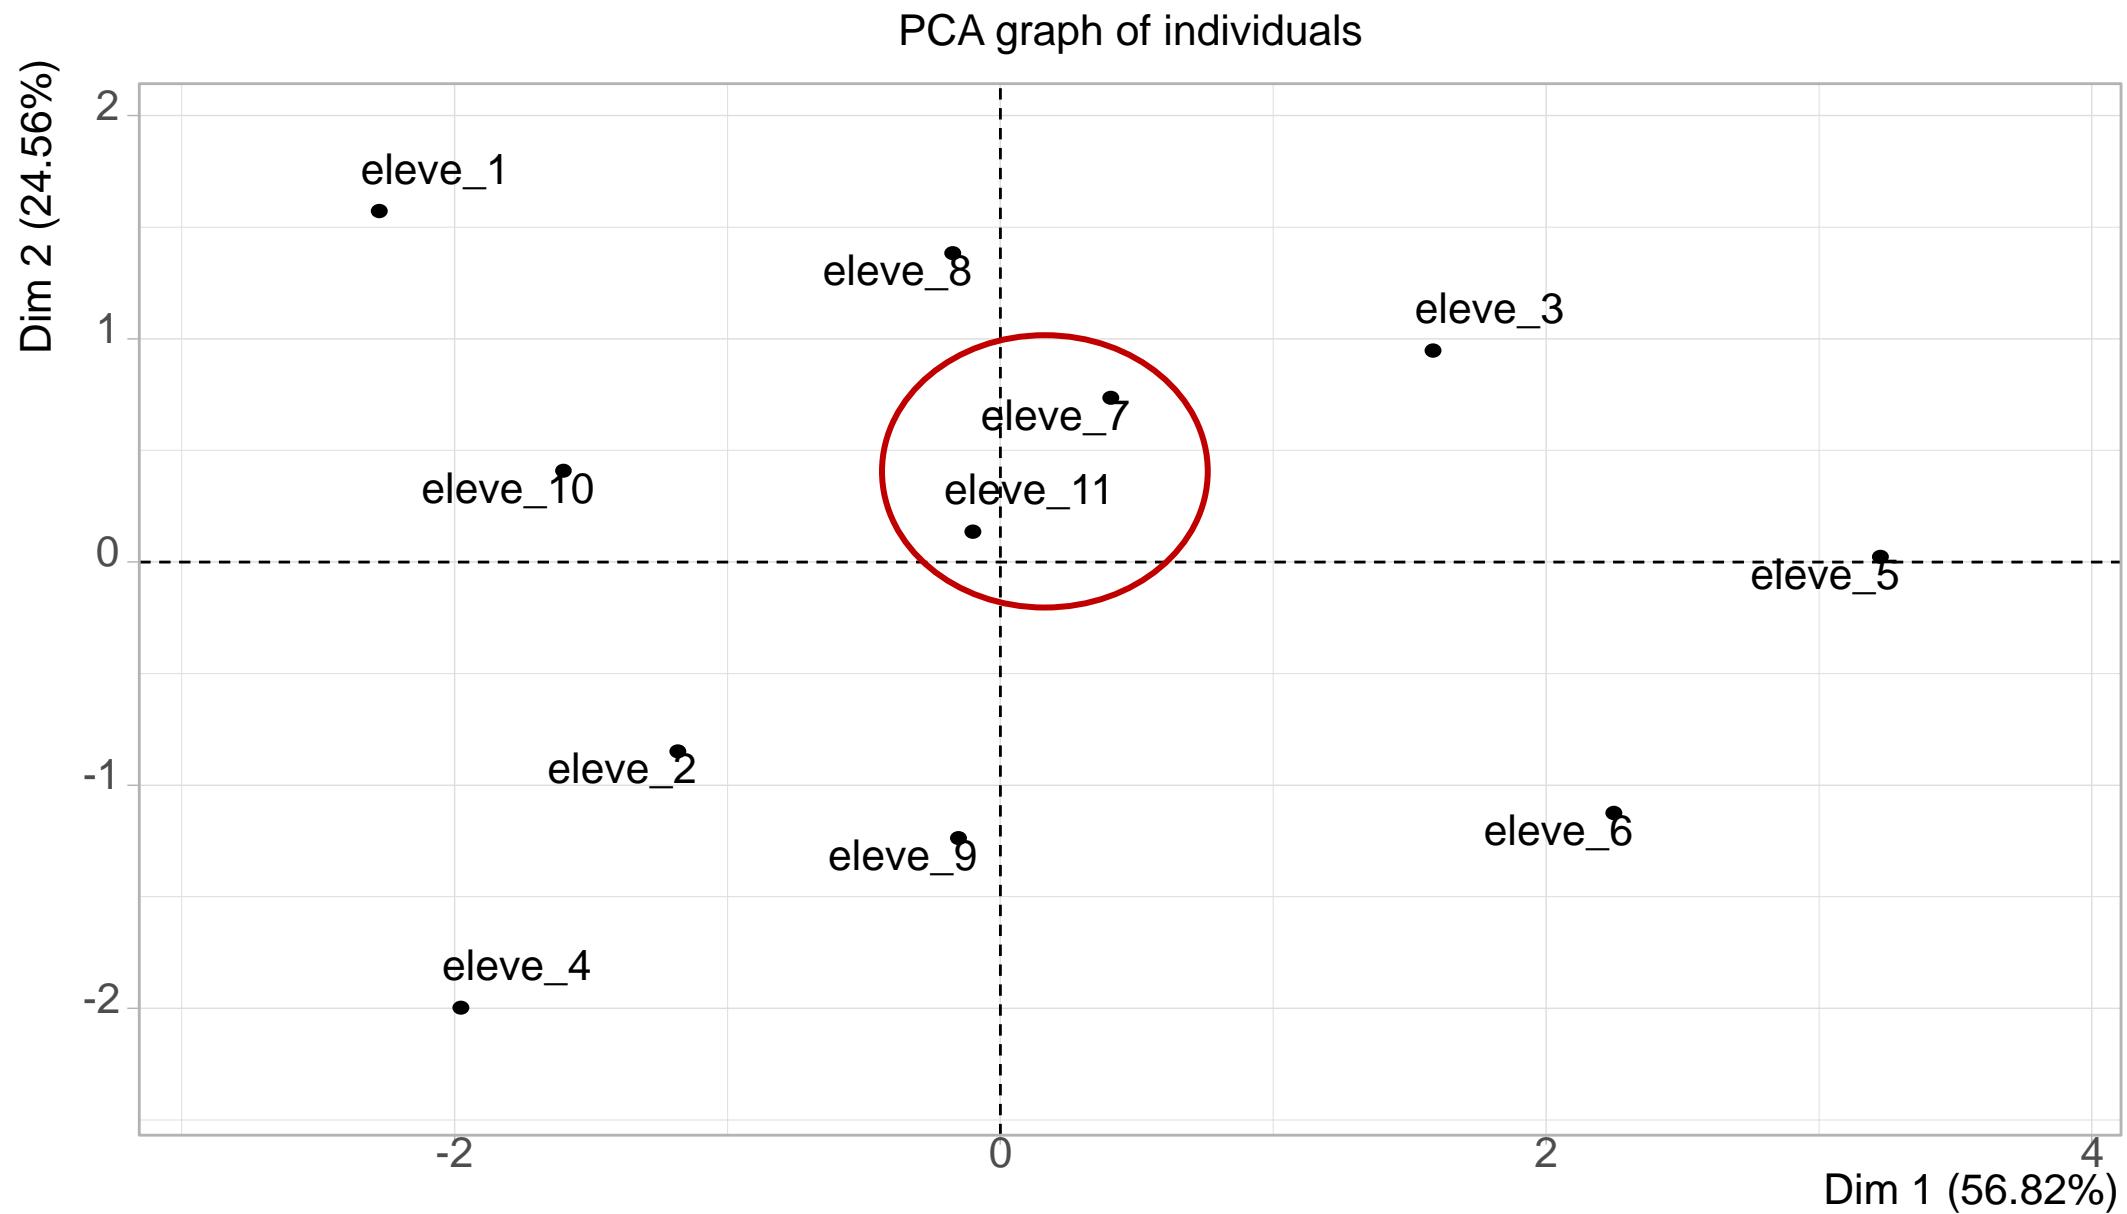


Composantes = combinaisons linéaires des variables initiales (les valeurs propres)

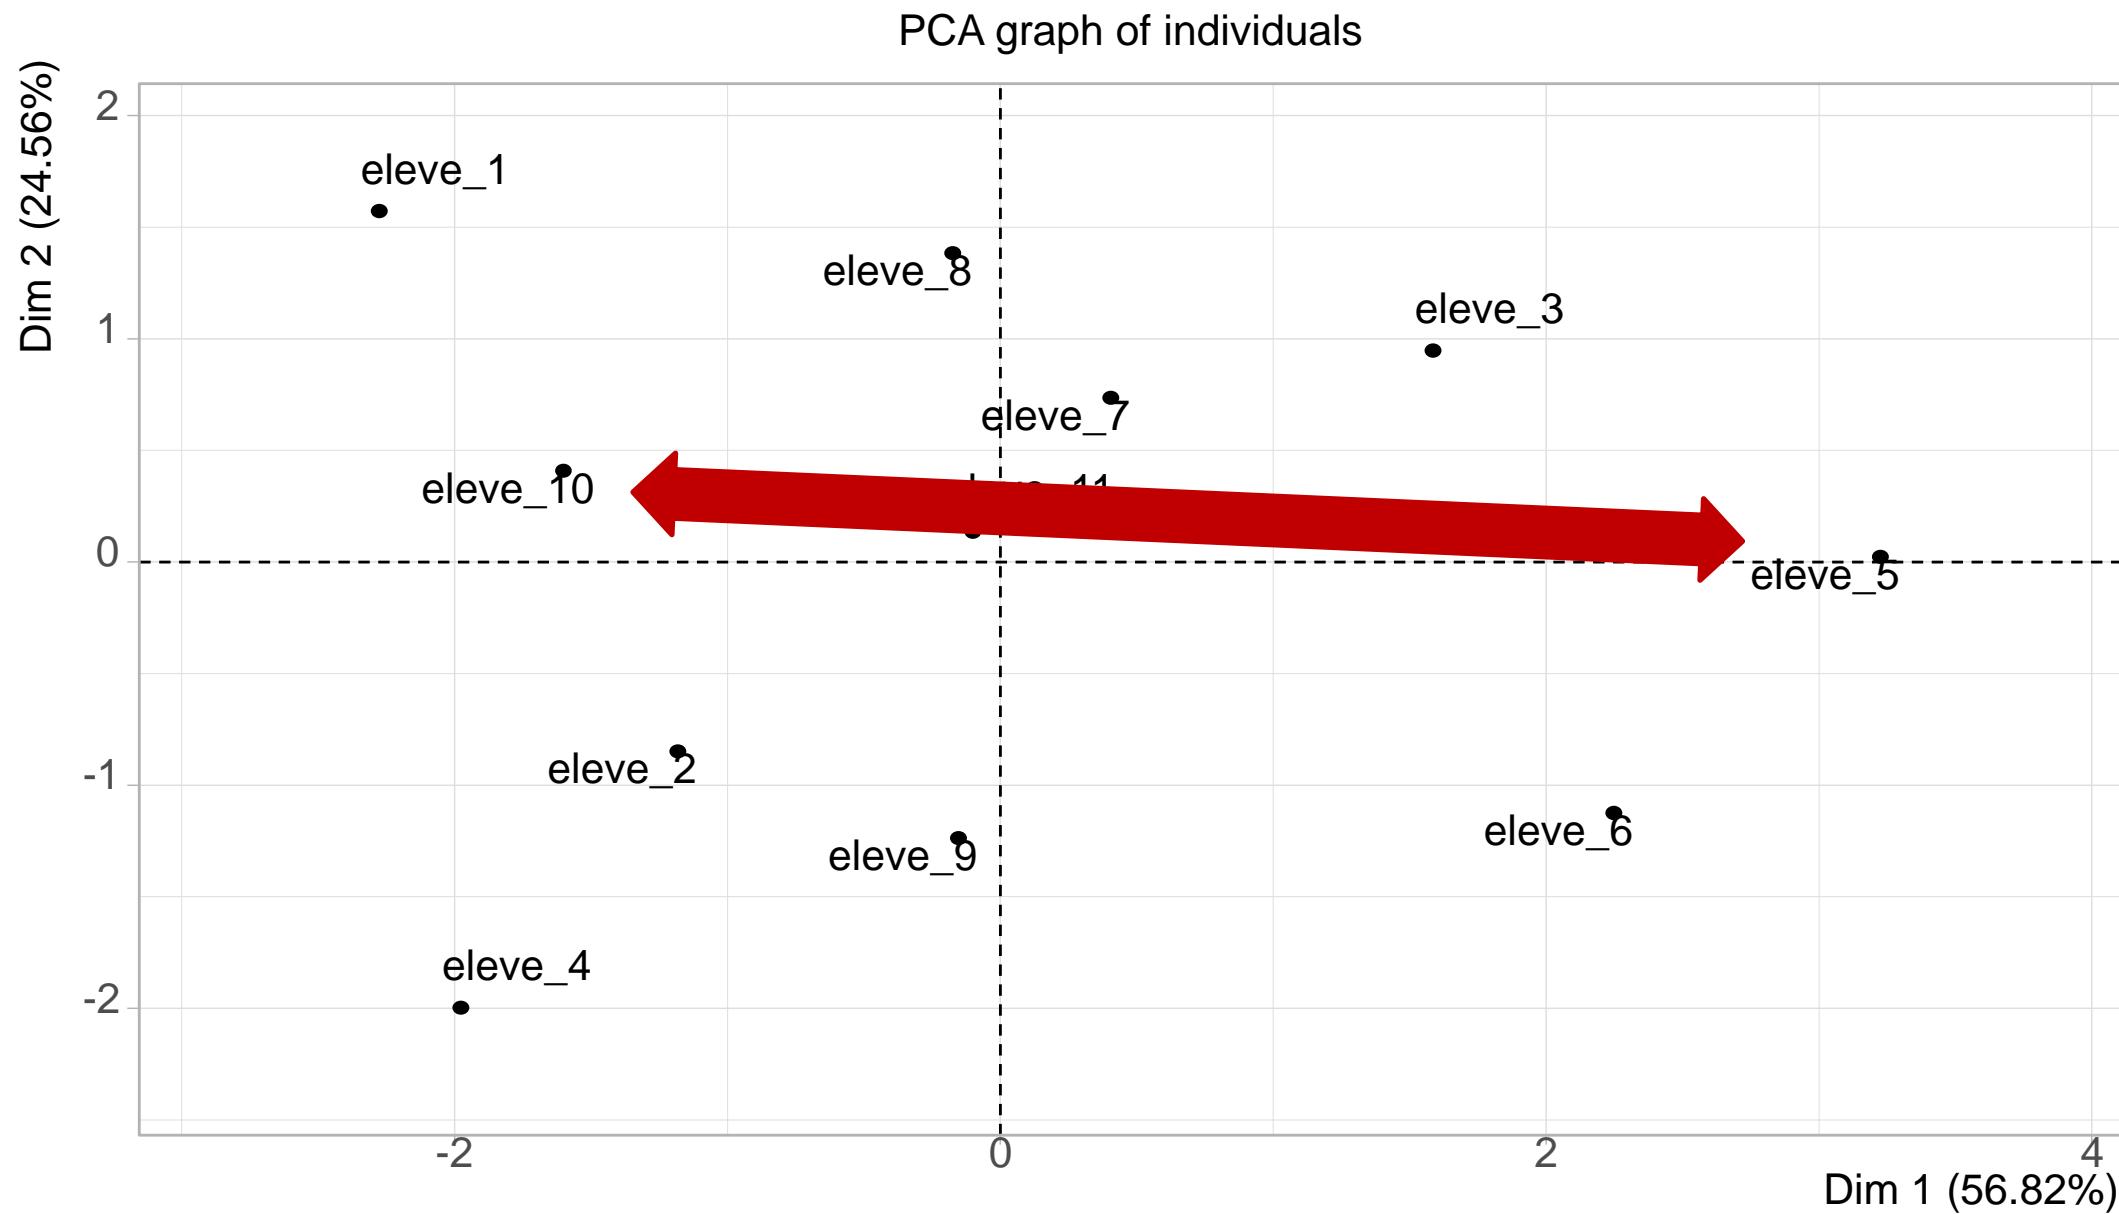
Etudes des individus/Graphe des individus



Etudes des individus/Graphe des individus

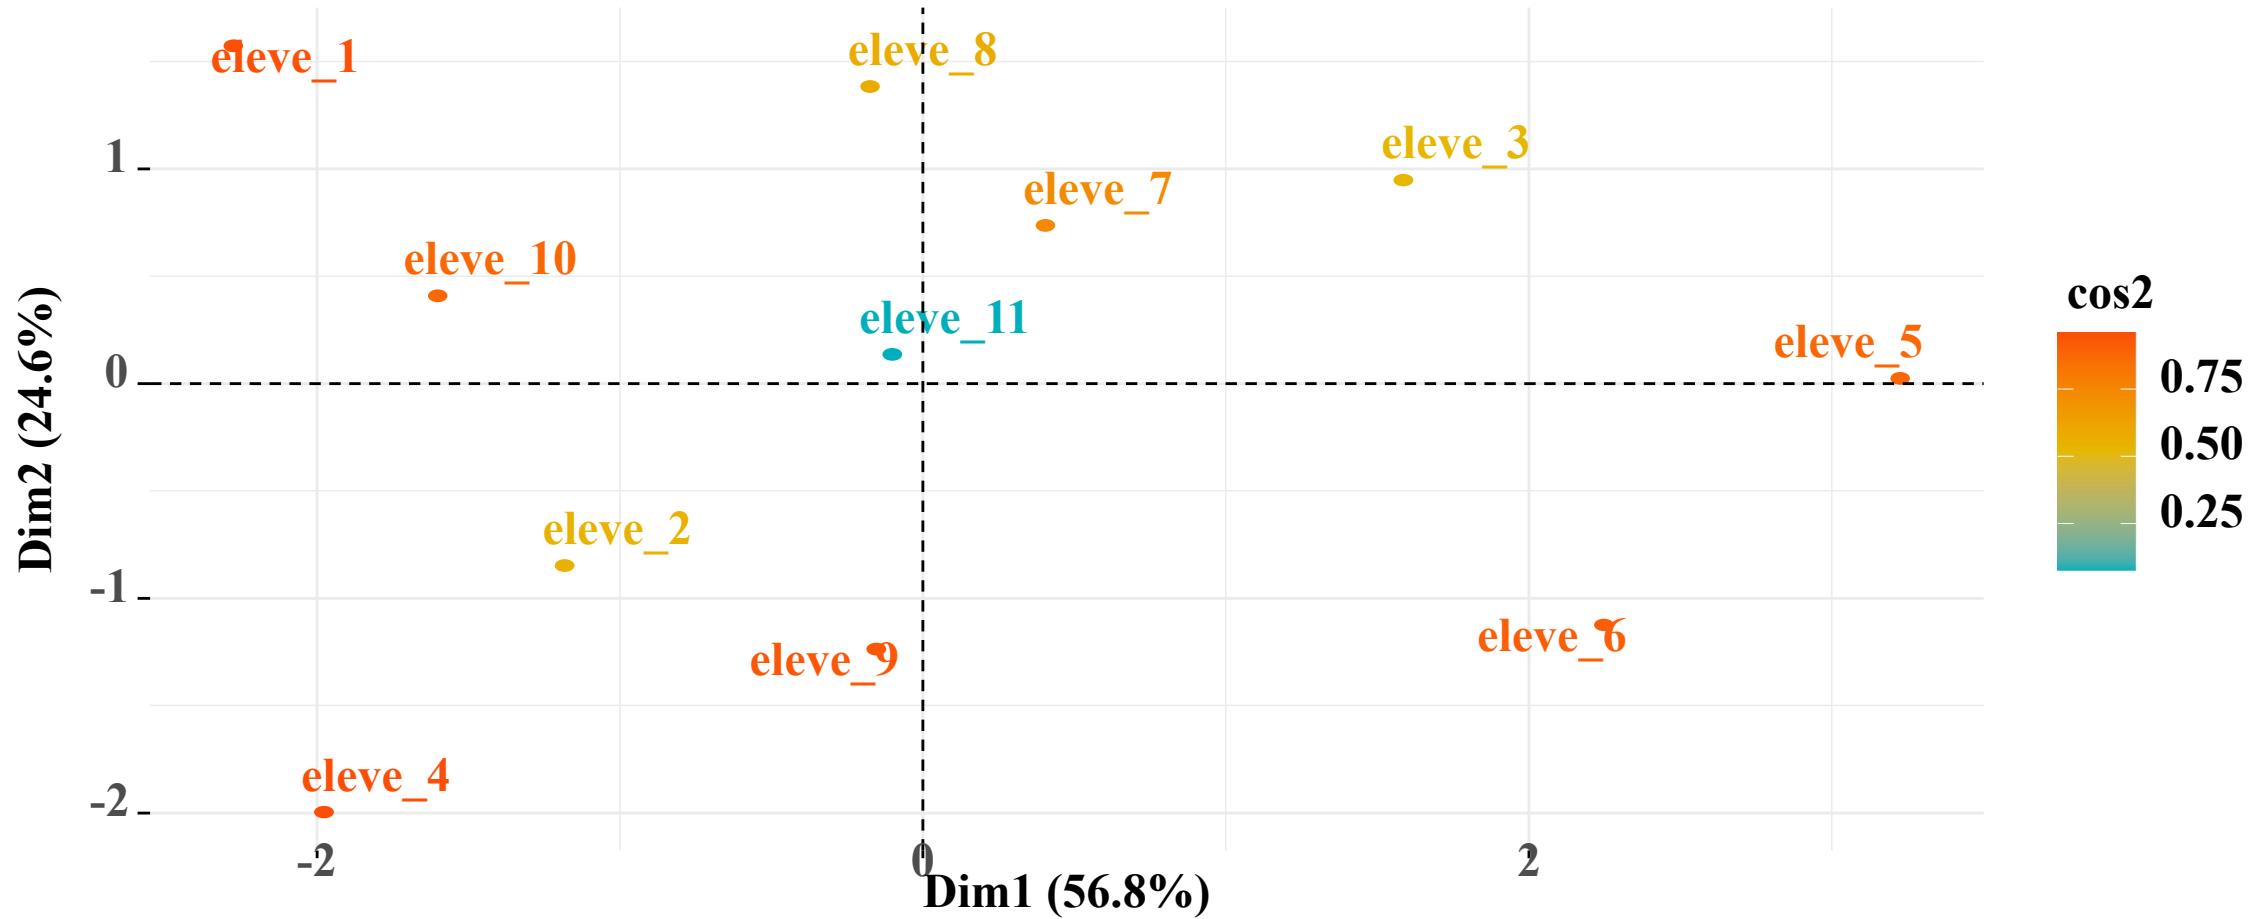


Etudes des individus/Graphe des individus



Etudes des individus/Graphe des individus

Individuals - PCA



Cosinus carré → qualité de la représentation de chaque individu sur chaque axe

Etude des variables

- Une variable = 1 colonne du tableau → 1 point dans un espace à N ($n=\text{individus}$) dimensions
- Variables = représentées par des flèches

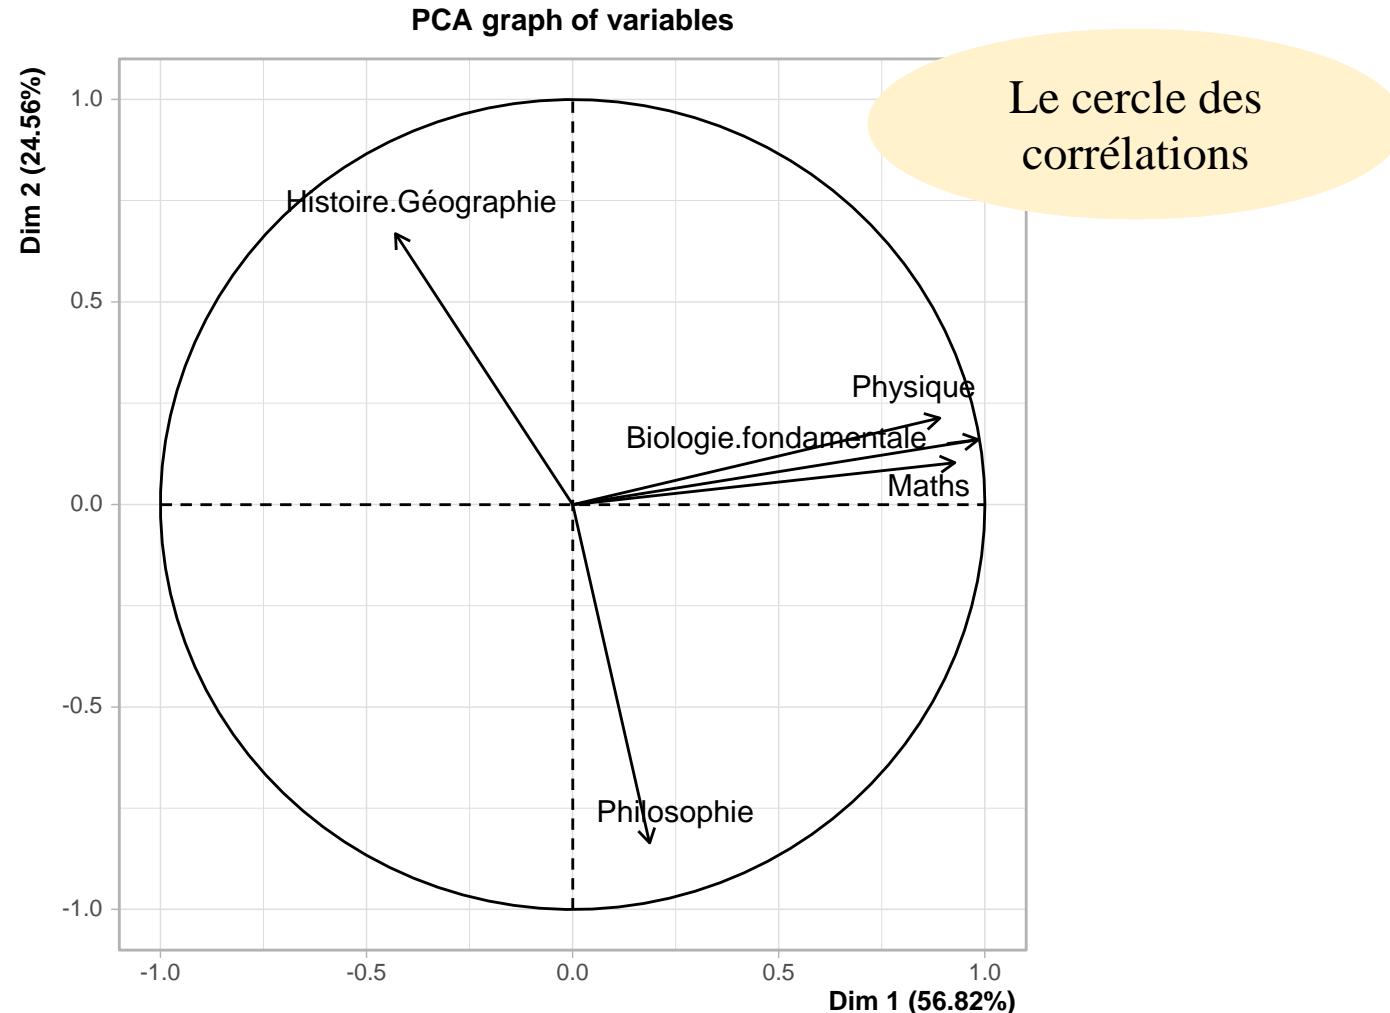
```
> res.pca.raw$var$coord
```

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Maths	0.9271567	0.1032435	0.08920569	-0.3489464200	3.778953e-32
Histoire.Géographie	-0.4298643	0.6691947	0.60613132	-0.0000828758	1.672270e-47
Philosophie	0.1866839	-0.8357073	0.51396389	0.0508290836	7.838766e-48
Physique	0.8907839	0.2135242	0.01972722	0.4006524254	2.643445e-32
Biologie.fondamentale	0.9839317	0.1603253	0.06537553	-0.0435917477	-5.954092e-32

Etude de la corrélation des variables avec les composantes principales

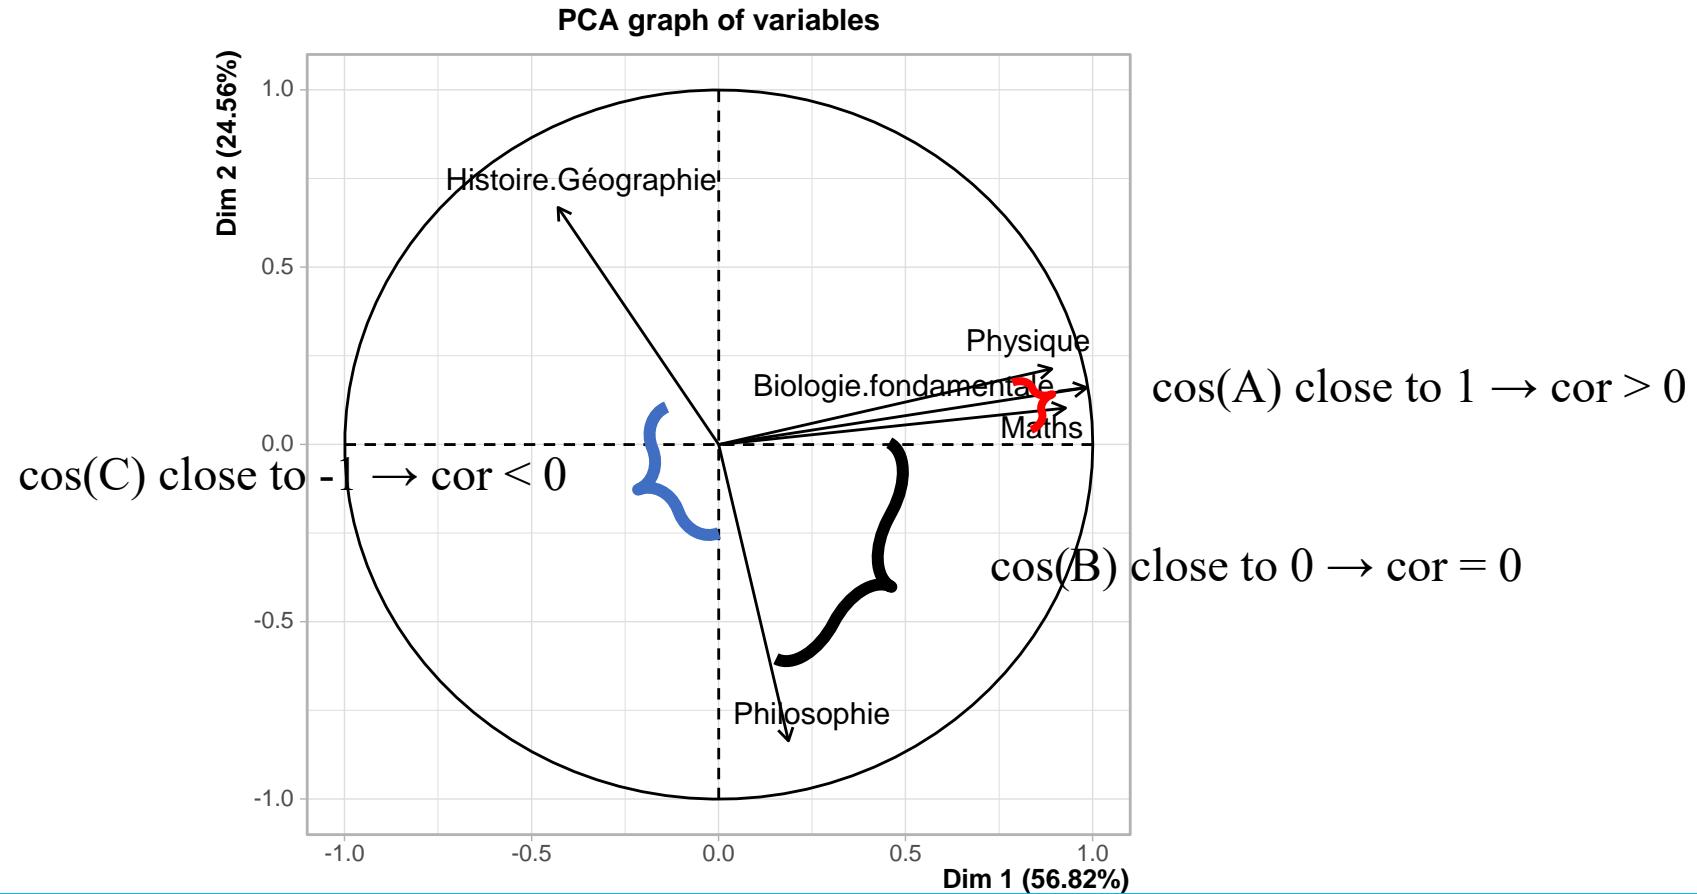
Etude des variables

- Représentation des variables dans espaces déterminés par les composantes
- Coordonnées de la variable = corrélation entre la variable et chaque composante



Etude des variables

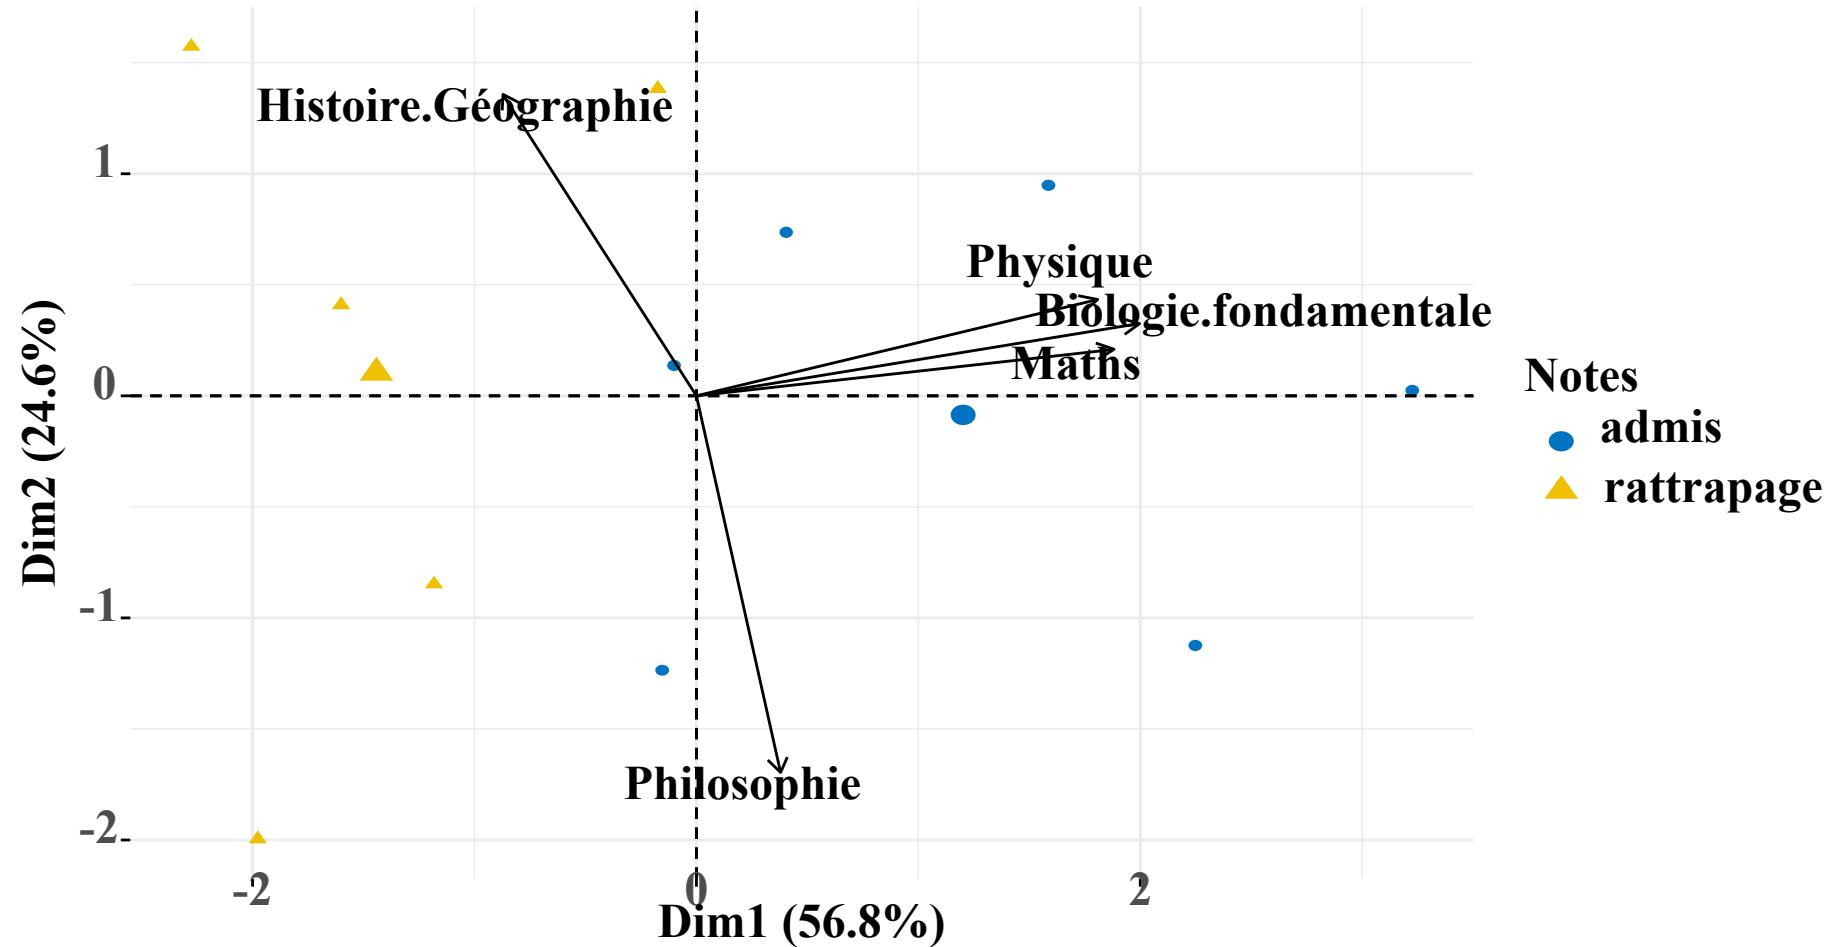
- Représentation des variables dans espaces déterminés par les composantes
- Coordonnées de la variable = corrélation entre la variable et chaque composante



Visualisation de la corrélation entre les variables
Identification des groupes de variables corrélées entre elles

Biplot/Analyse simultanée

PCA - Biplot



Un individu qui se trouve du même côté d'une variable donnée a une valeur élevée pour cette variable ;
Un individu qui se trouve sur le côté opposé d'une variable donnée a une faible valeur pour cette variable.

Exemple biologique simple

	penicillin	streptomycin	neomycin	gramstain
Aerobacter aerogenes	870.000	1.00	1.600	neg
Brucella abortus	1.000	2.00	0.020	neg
Escherichia coli	100.000	0.40	0.100	neg
Klebsiella pneumoniae	850.000	1.20	1.000	neg
Mycobacterium tuberculosis	800.000	5.00	2.000	neg
Proteus vulgaris	3.000	0.10	0.100	neg
Pseudomonas aeruginosa	850.000	2.00	0.400	neg
Salmonella typhosa	1.000	0.40	0.008	neg
Salmonella schottmuelleri	10.000	0.80	0.090	neg
Bacillus anthracis	0.001	0.01	0.007	pos
Diplococcus pneumoniae	0.005	11.00	10.000	pos
Staphylococcus albus	0.007	0.10	0.001	pos
Staphylococcus aureus	0.030	0.03	0.001	pos
Streptococcus fecalis	1.000	1.00	0.100	pos
Streptococcus hemolyticus	0.001	14.00	10.000	pos
Streptococcus viridans	0.005	10.00	40.000	pos

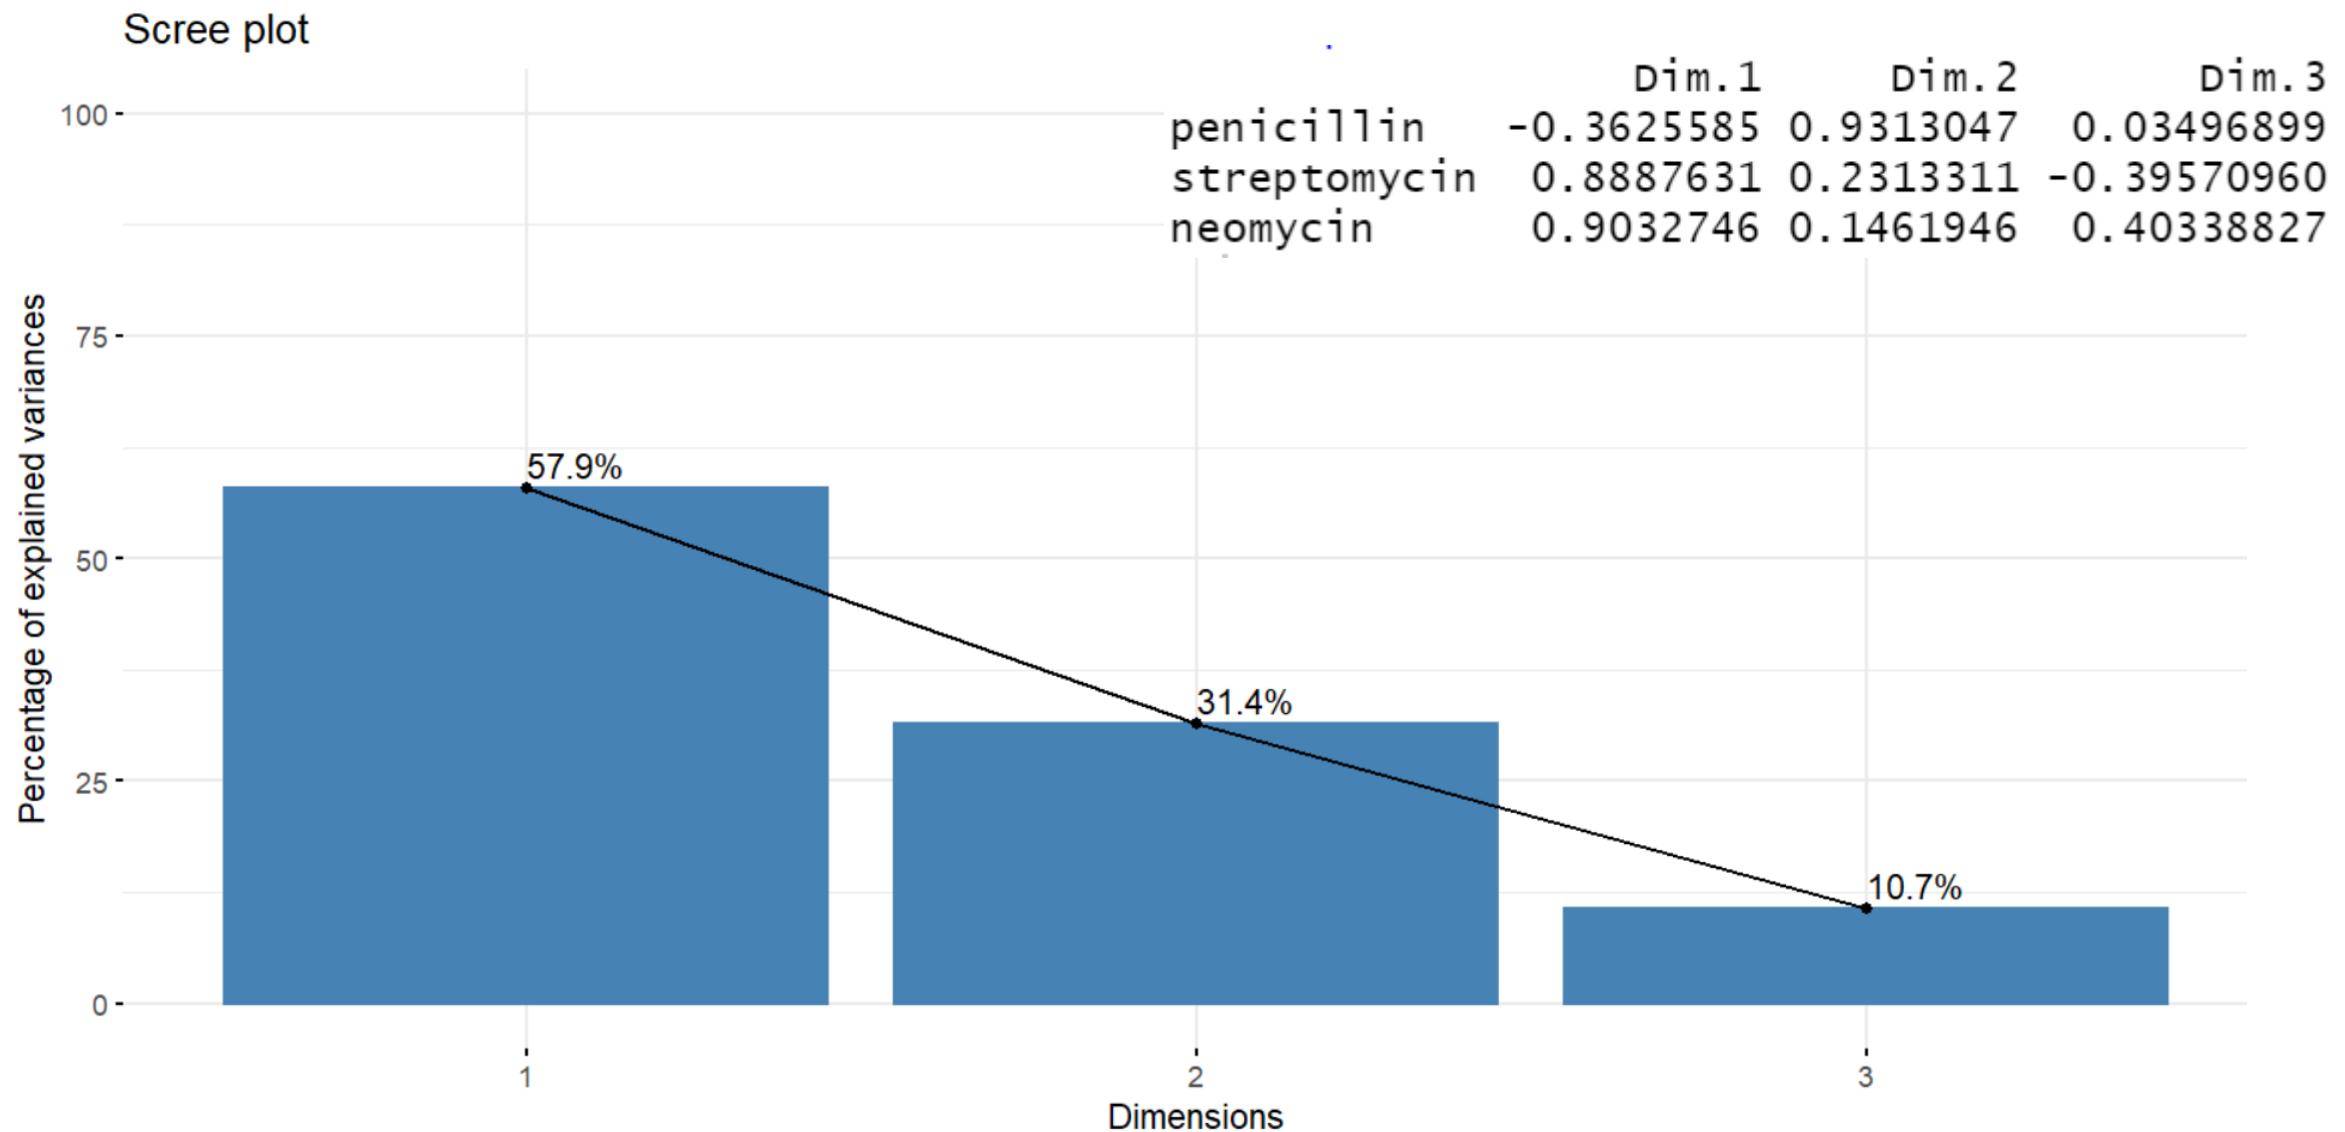
- Données provenant du package R « Lucid »
- “Effectiveness of 3 antibiotics against 16 bacterial species”
- “16 observations on the following 5 variables”

Exemple biologique simple

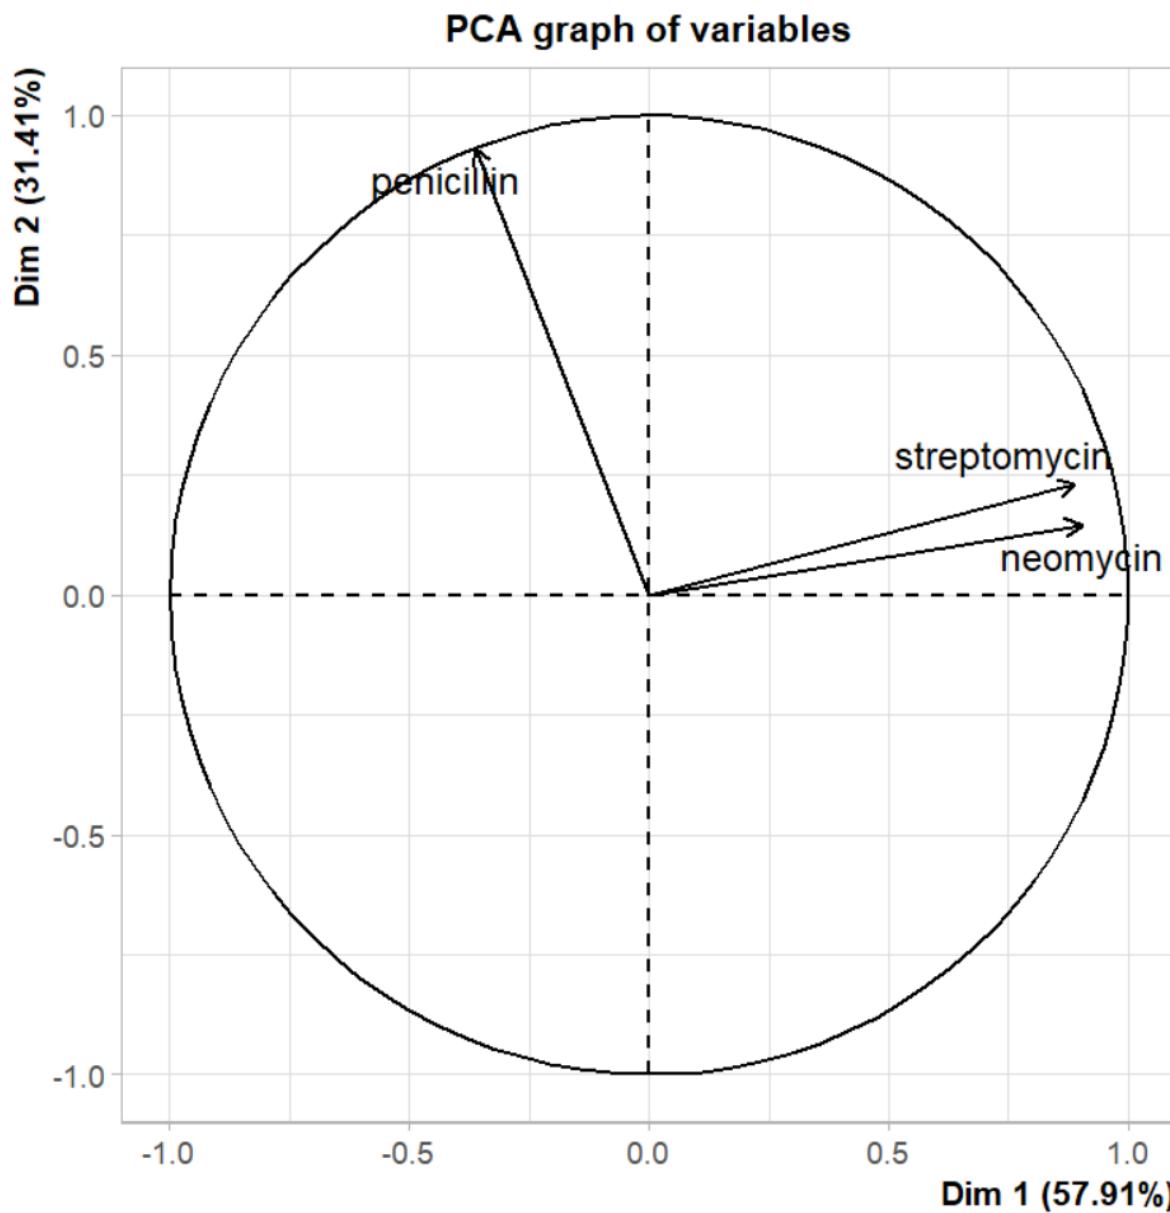
- Définir les variables et les individus ?
- Quelles sont les variables à garder pour la PCA ?

	penicillin	streptomycin	neomycin	gramstain
Aerobacter aerogenes	870.000	1.00	1.600	neg
Brucella abortus	1.000	2.00	0.020	neg
Escherichia coli	100.000	0.40	0.100	neg
Klebsiella pneumoniae	850.000	1.20	1.000	neg
Mycobacterium tuberculosis	800.000	5.00	2.000	neg
Proteus vulgaris	3.000	0.10	0.100	neg
Pseudomonas aeruginosa	850.000	2.00	0.400	neg
Salmonella typhosa	1.000	0.40	0.008	neg
Salmonella schottmuelleri	10.000	0.80	0.090	neg
Bacillus anthracis	0.001	0.01	0.007	pos
Diplococcus pneumoniae	0.005	11.00	10.000	pos
Staphylococcus albus	0.007	0.10	0.001	pos
Staphylococcus aureus	0.030	0.03	0.001	pos
Streptococcus fecalis	1.000	1.00	0.100	pos
Streptococcus hemolyticus	0.001	14.00	10.000	pos
Streptococcus viridans	0.005	10.00	40.000	pos

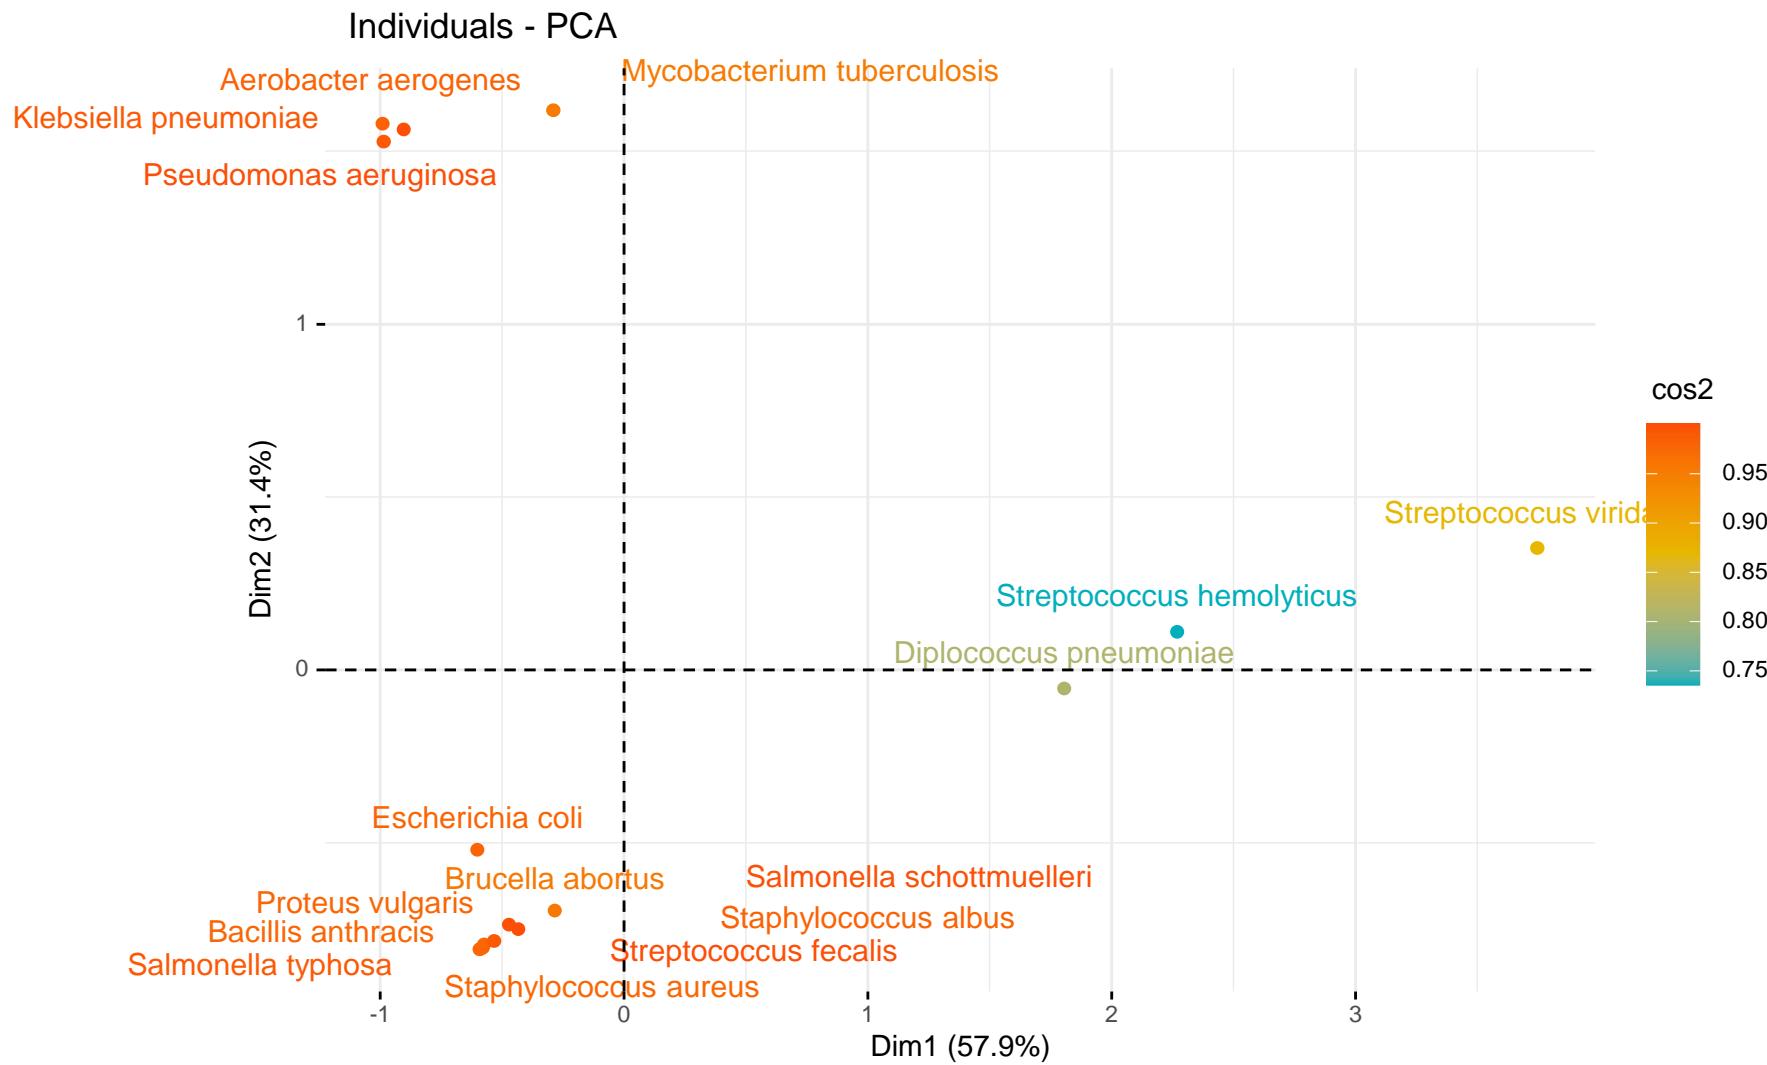
Exemple biologique simple



Exemple biologique simple

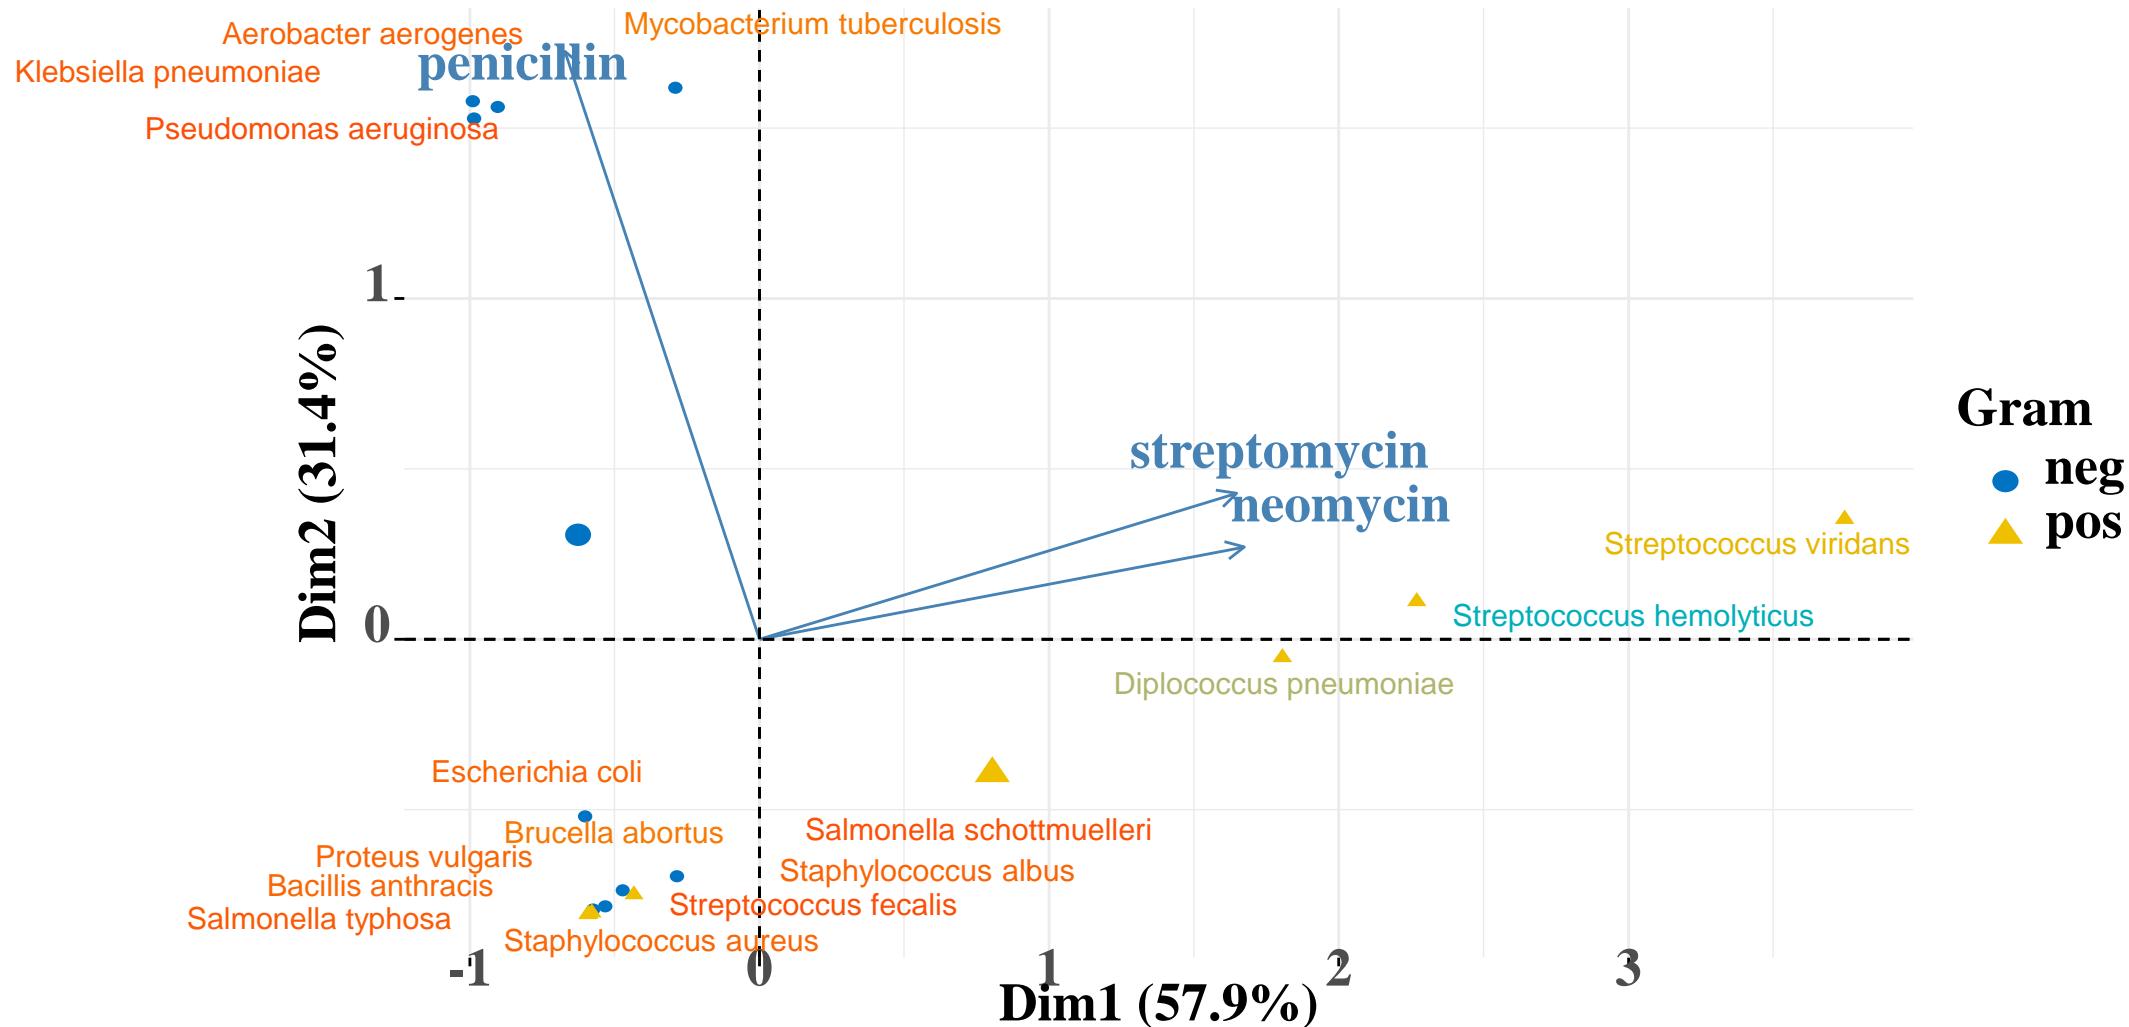


Exemple biologique simple



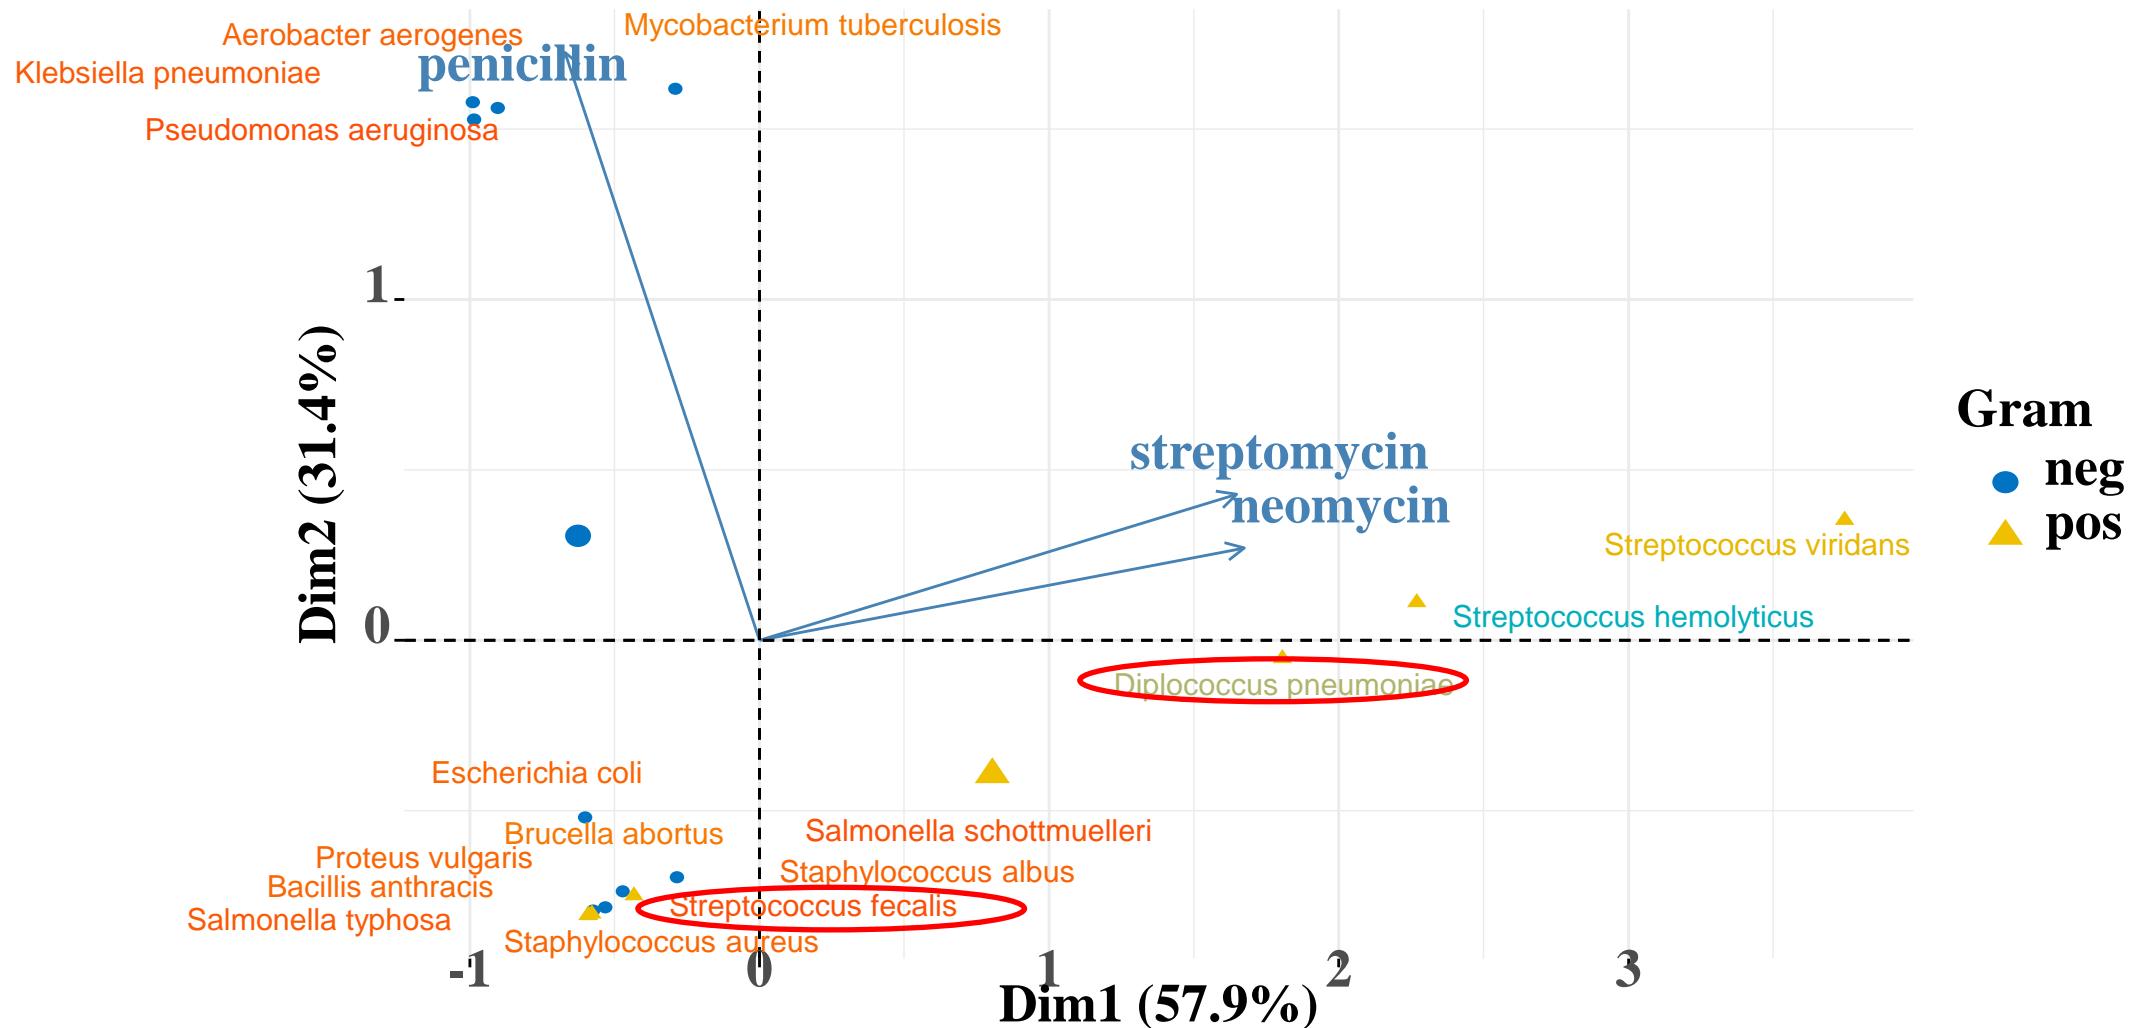
Exemple biologique simple

PCA - Biplot



Exemple biologique simple

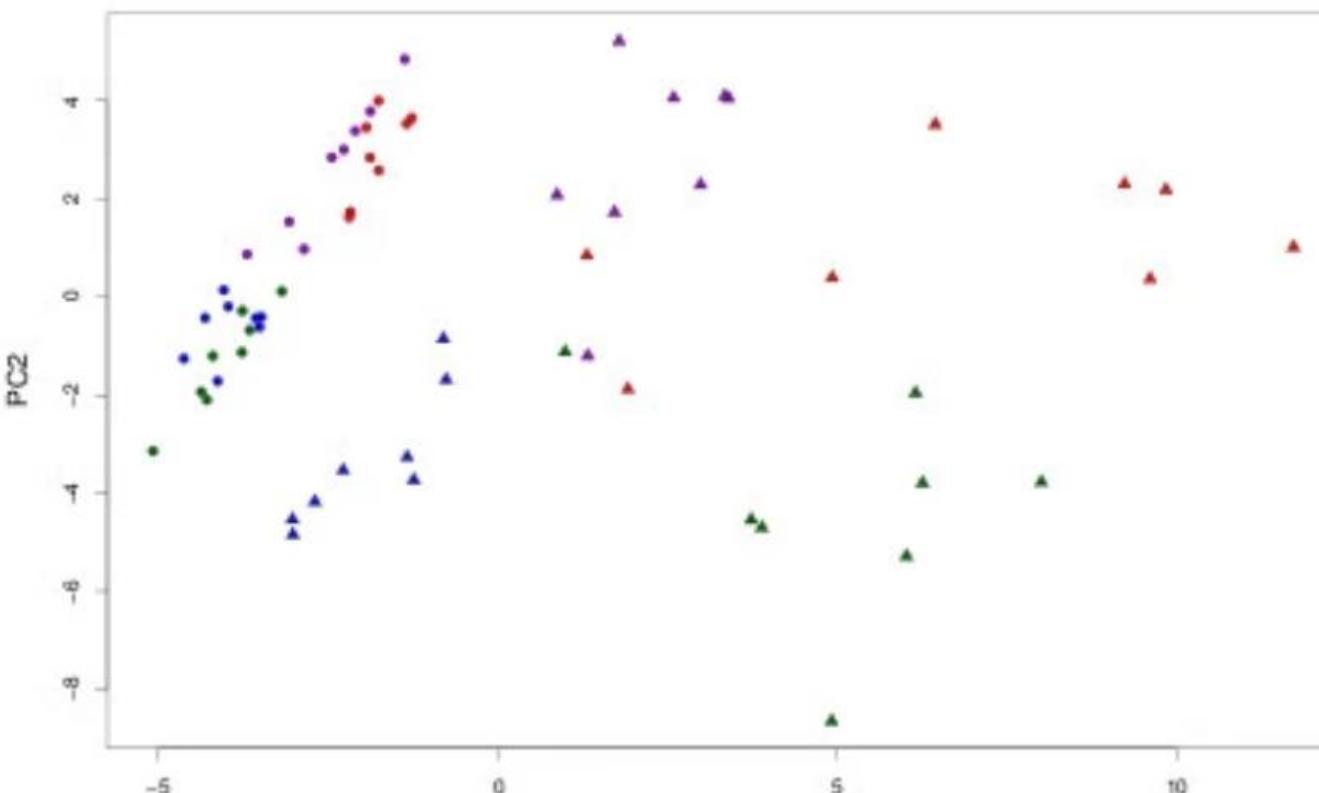
PCA - Biplot



Exemples biologique (1)

Independent Principal Component Analysis for biologically meaningful dimension reduction of large biological data sets

PCA



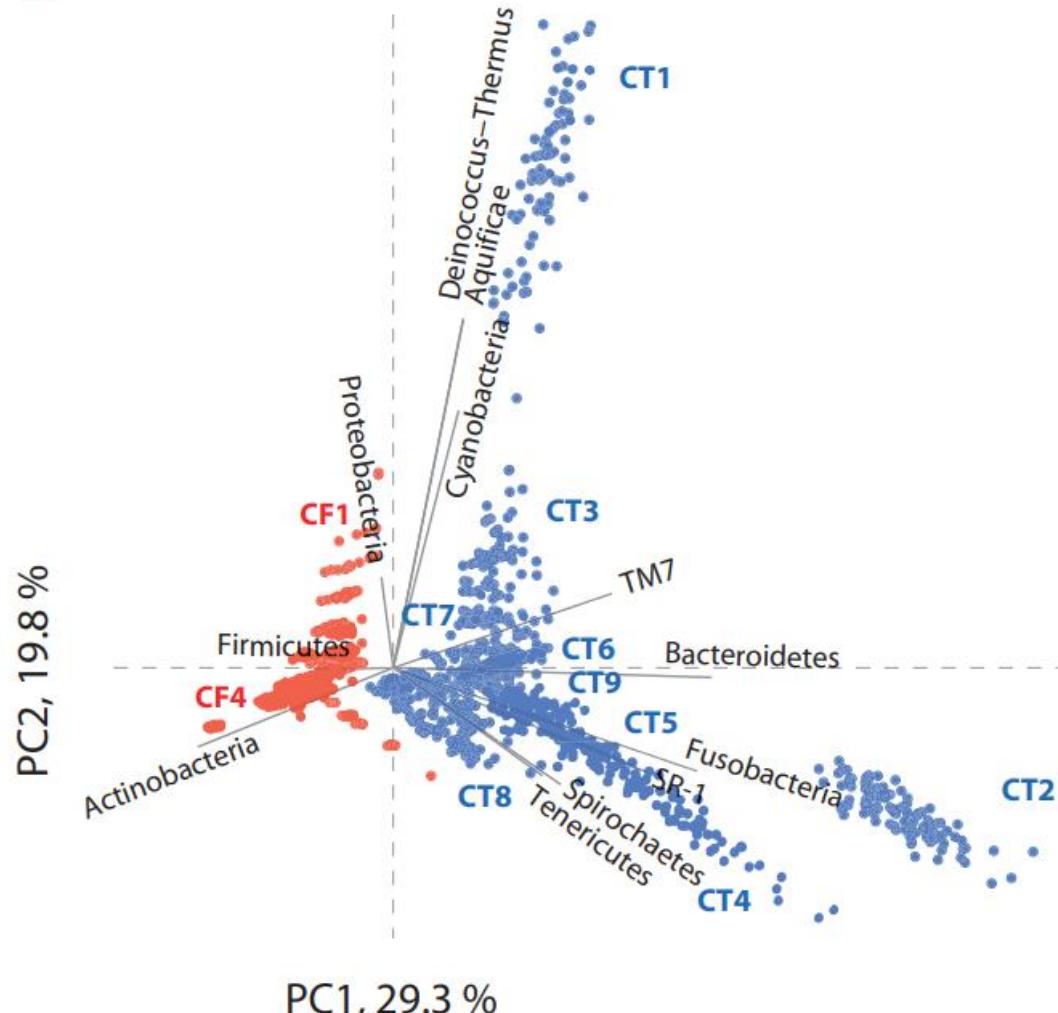
- Echantillons : rats ($n = 64$)
- Acétamophénol à différentes doses
- Analyse des données : étude transcriptomique



Exemples biologique (2)

Quantitative Analysis of the Human Airway Microbial Ecology Reveals a Pervasive Signature for Cystic Fibrosis

A



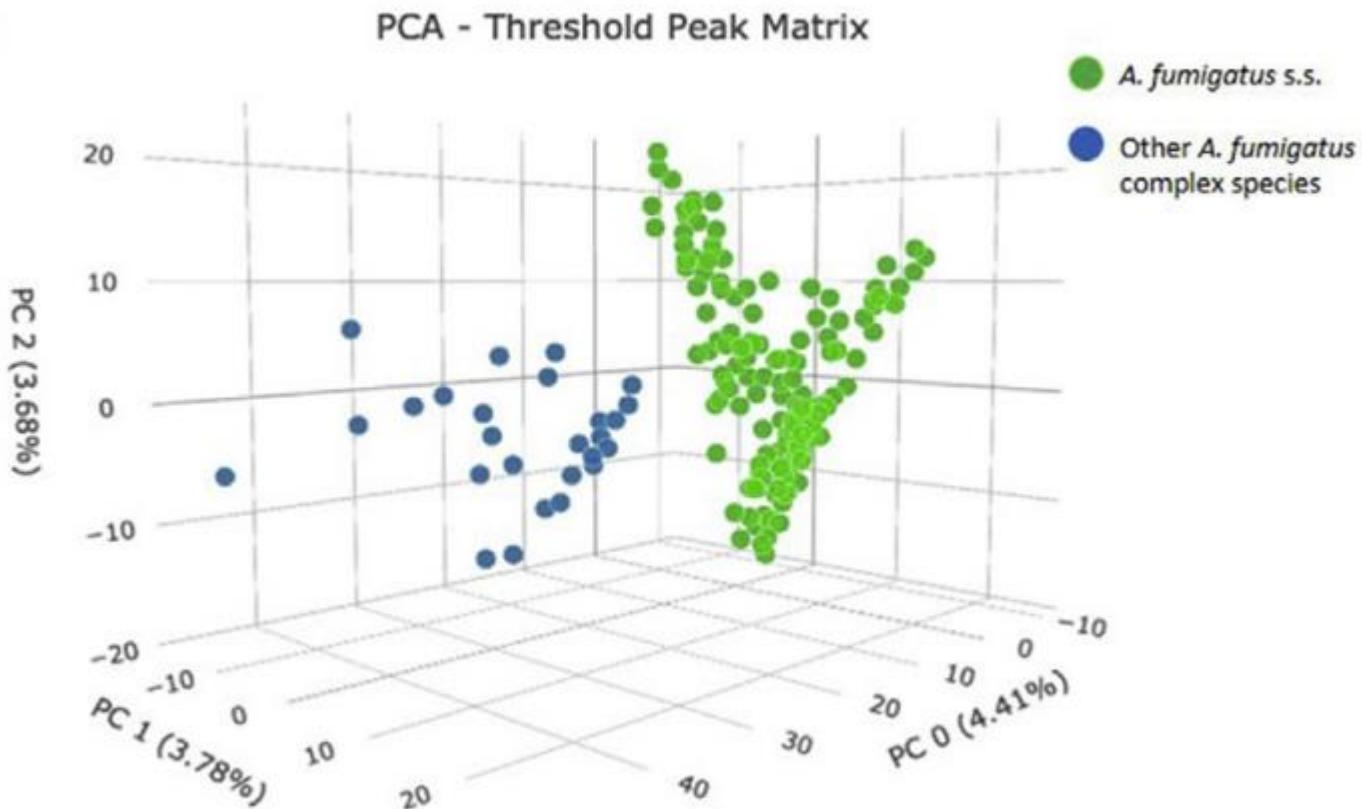
- Echantillons : crachats ($n = 25$)
 - patients sains ($n = 9$)
 - Patients mucoviscidose ($n = 16$)
- Analyse des données : NGS

Blainey PC, Milla CE, Cornfield DN, Quake SR. Quantitative analysis of the human airway microbial ecology reveals a pervasive signature for cystic fibrosis. *Sci Transl Med*. 2012;4(153):153ra130. doi:10.1126/scitranslmed.3004458

Exemples biologique (3)

Detection of azole resistance in *Aspergillus fumigatus* complex isolates using MALDI-TOF mass spectrometry

A



- Echantillons : souches de *A. fumigatus*
- Analyse des données : MALDI-TOF SM

Discrimination of *Aspergillus fumigatus* sensu stricto from the cryptic species of the *Aspergillus fumigatus* complex

Zvezdanova ME, Arroyo MJ, Méndez G, Candela A, Mancera L, Rodríguez JG, Serra JL, Jiménez R, Loza I, Castro C, López C, Muñoz P, Guinea J, Escribano P, Rodríguez-Sánchez B; ASPEIN group. Detection of azole resistance in *Aspergillus fumigatus* complex isolates using MALDI-TOF mass spectrometry. Clin Microbiol Infect. 2022 Feb;28(2):260-266. doi: 10.1016/j.cmi.2021.06.005. Epub 2021 Jun 17. PMID: 34147673.

Plan

Partie I : L'Analyse en Composantes Principales (ACP)

Partie II : Clustering



Clustering

Rassembler les objets en groupes ou clusters :

(i) **homogènes** : notion de similarité au sein d'un groupe ou cluster

(ii) **séparés** : notion de différence ou dissimilarités entre les groupes ou clusters

Un cluster est une collection objets similaires au sein du même cluster mais dissimilaires aux objets appartenant aux autres clusters

Un exemple biologique

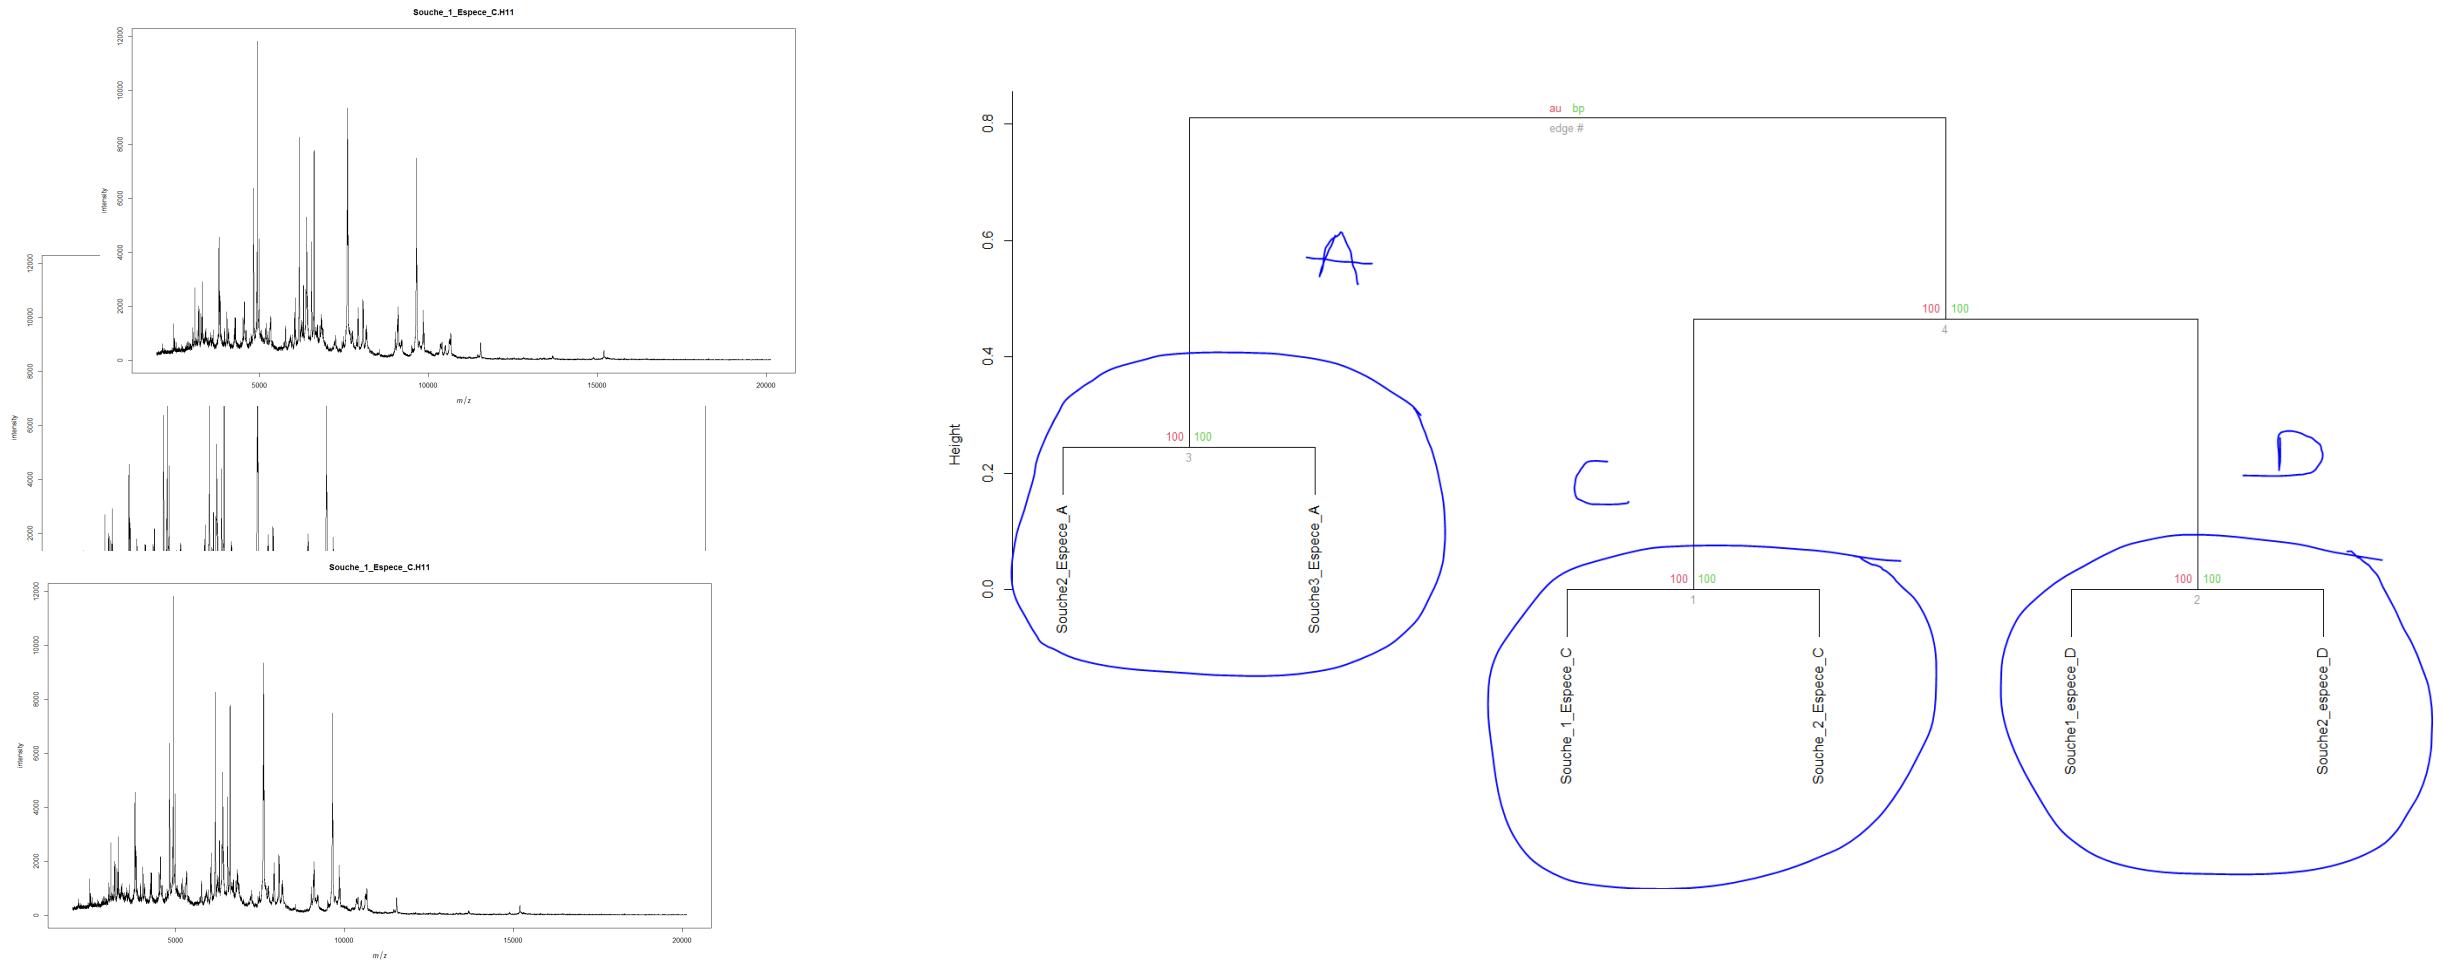
On dispose de souches bactériennes analysées en spectrométrie de masse de type MALDI-TOF

Les 6 souches ont été caractérisée génétiquement en trois espèces distinctes (espèces : A, C et D)

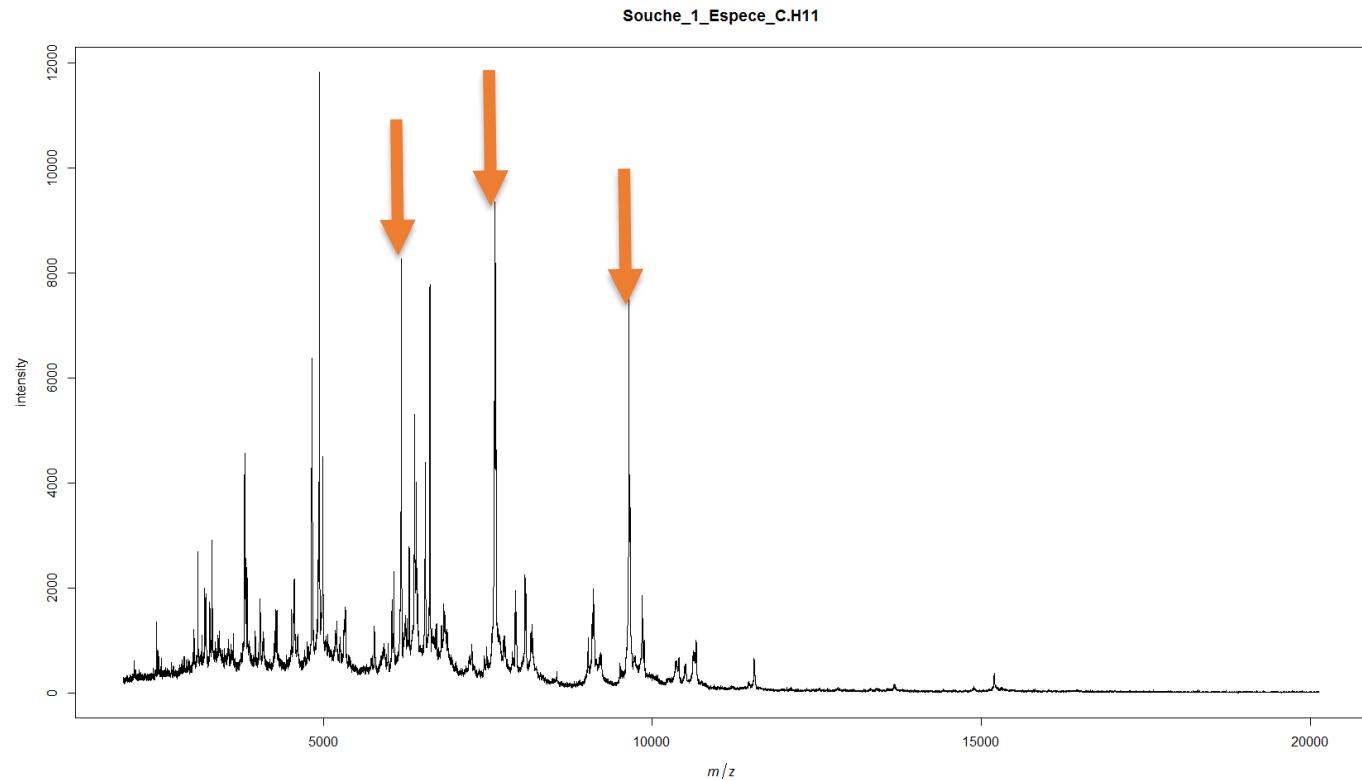
Problématique : existe-t-il une relation entre la spectrométrie de masse et la génétique pour l'identification de ces souches ?

Souche_1_Especie_C	27/06/2020 12:09	Dossier de fichiers
Souche_2_Especie_C	27/06/2020 12:02	Dossier de fichiers
Souche1_espece_D	27/06/2020 12:02	Dossier de fichiers
Souche2_Especie_A	27/06/2020 11:59	Dossier de fichiers
Souche2_espece_D	27/06/2020 12:08	Dossier de fichiers
Souche3_Especie_A	27/06/2020 11:59	Dossier de fichiers

Comment réaliser un clustering

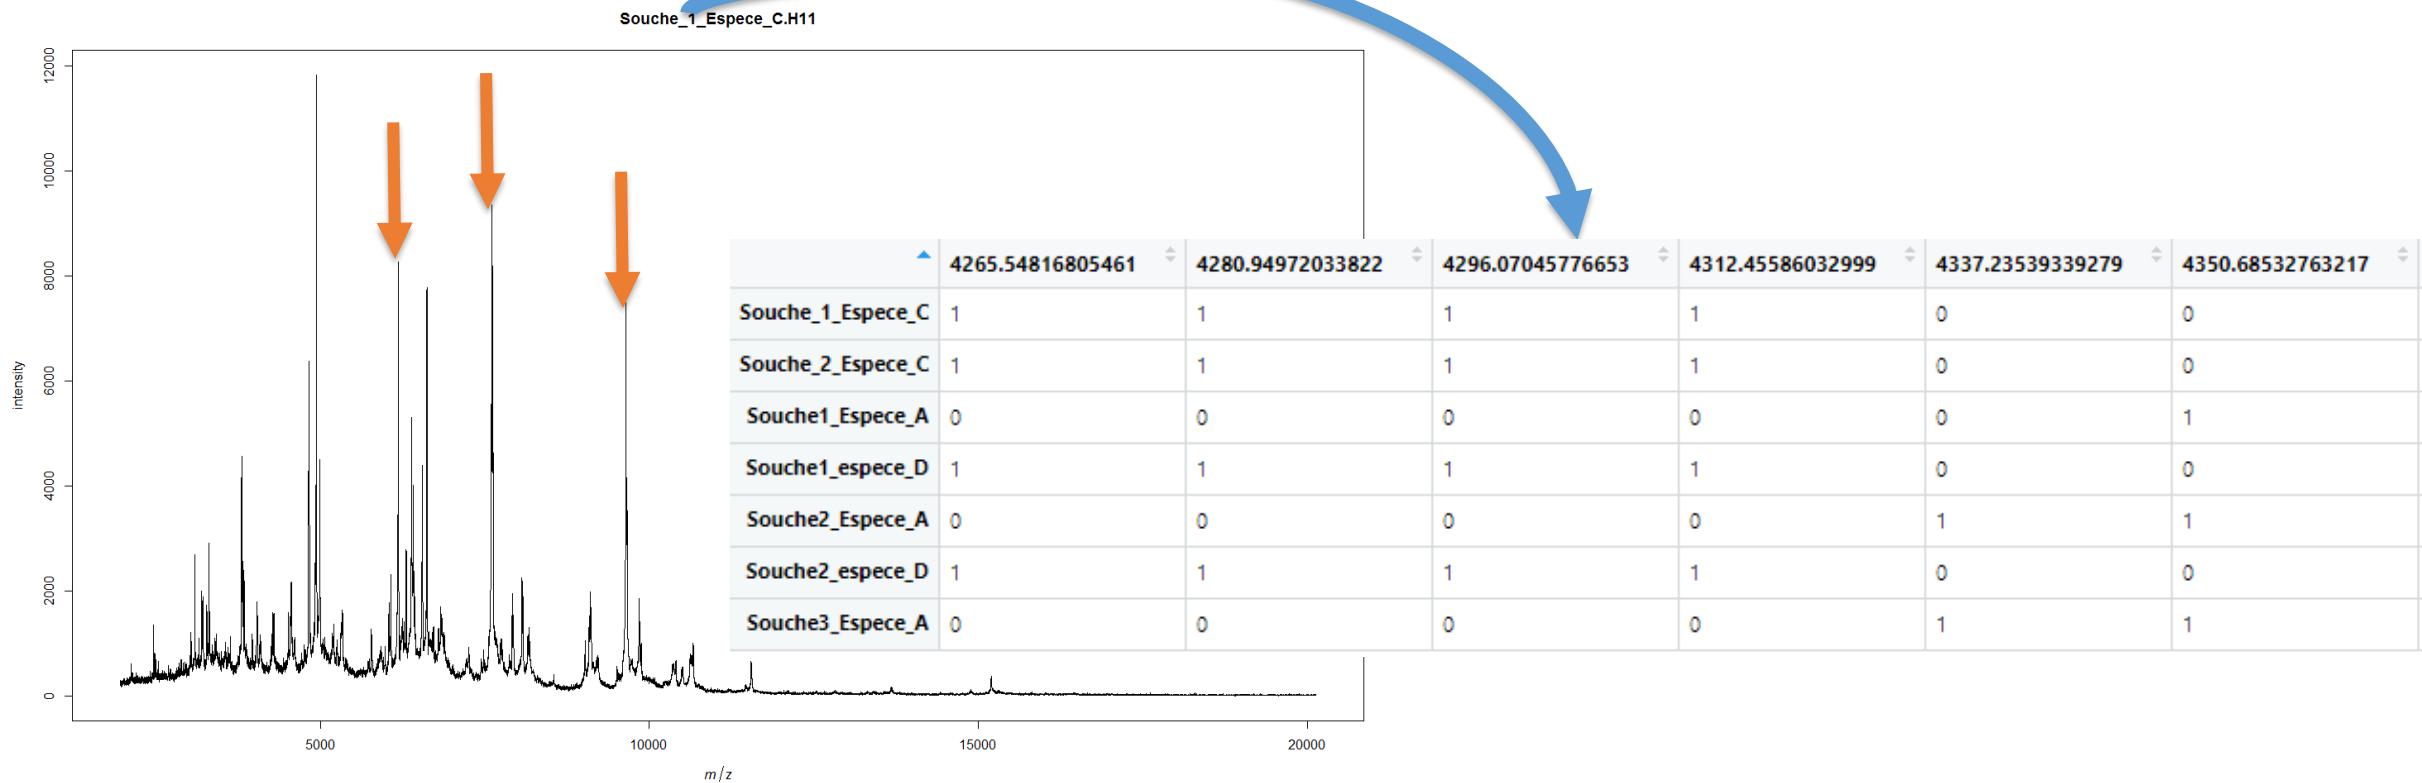


Comment réaliser un clustering



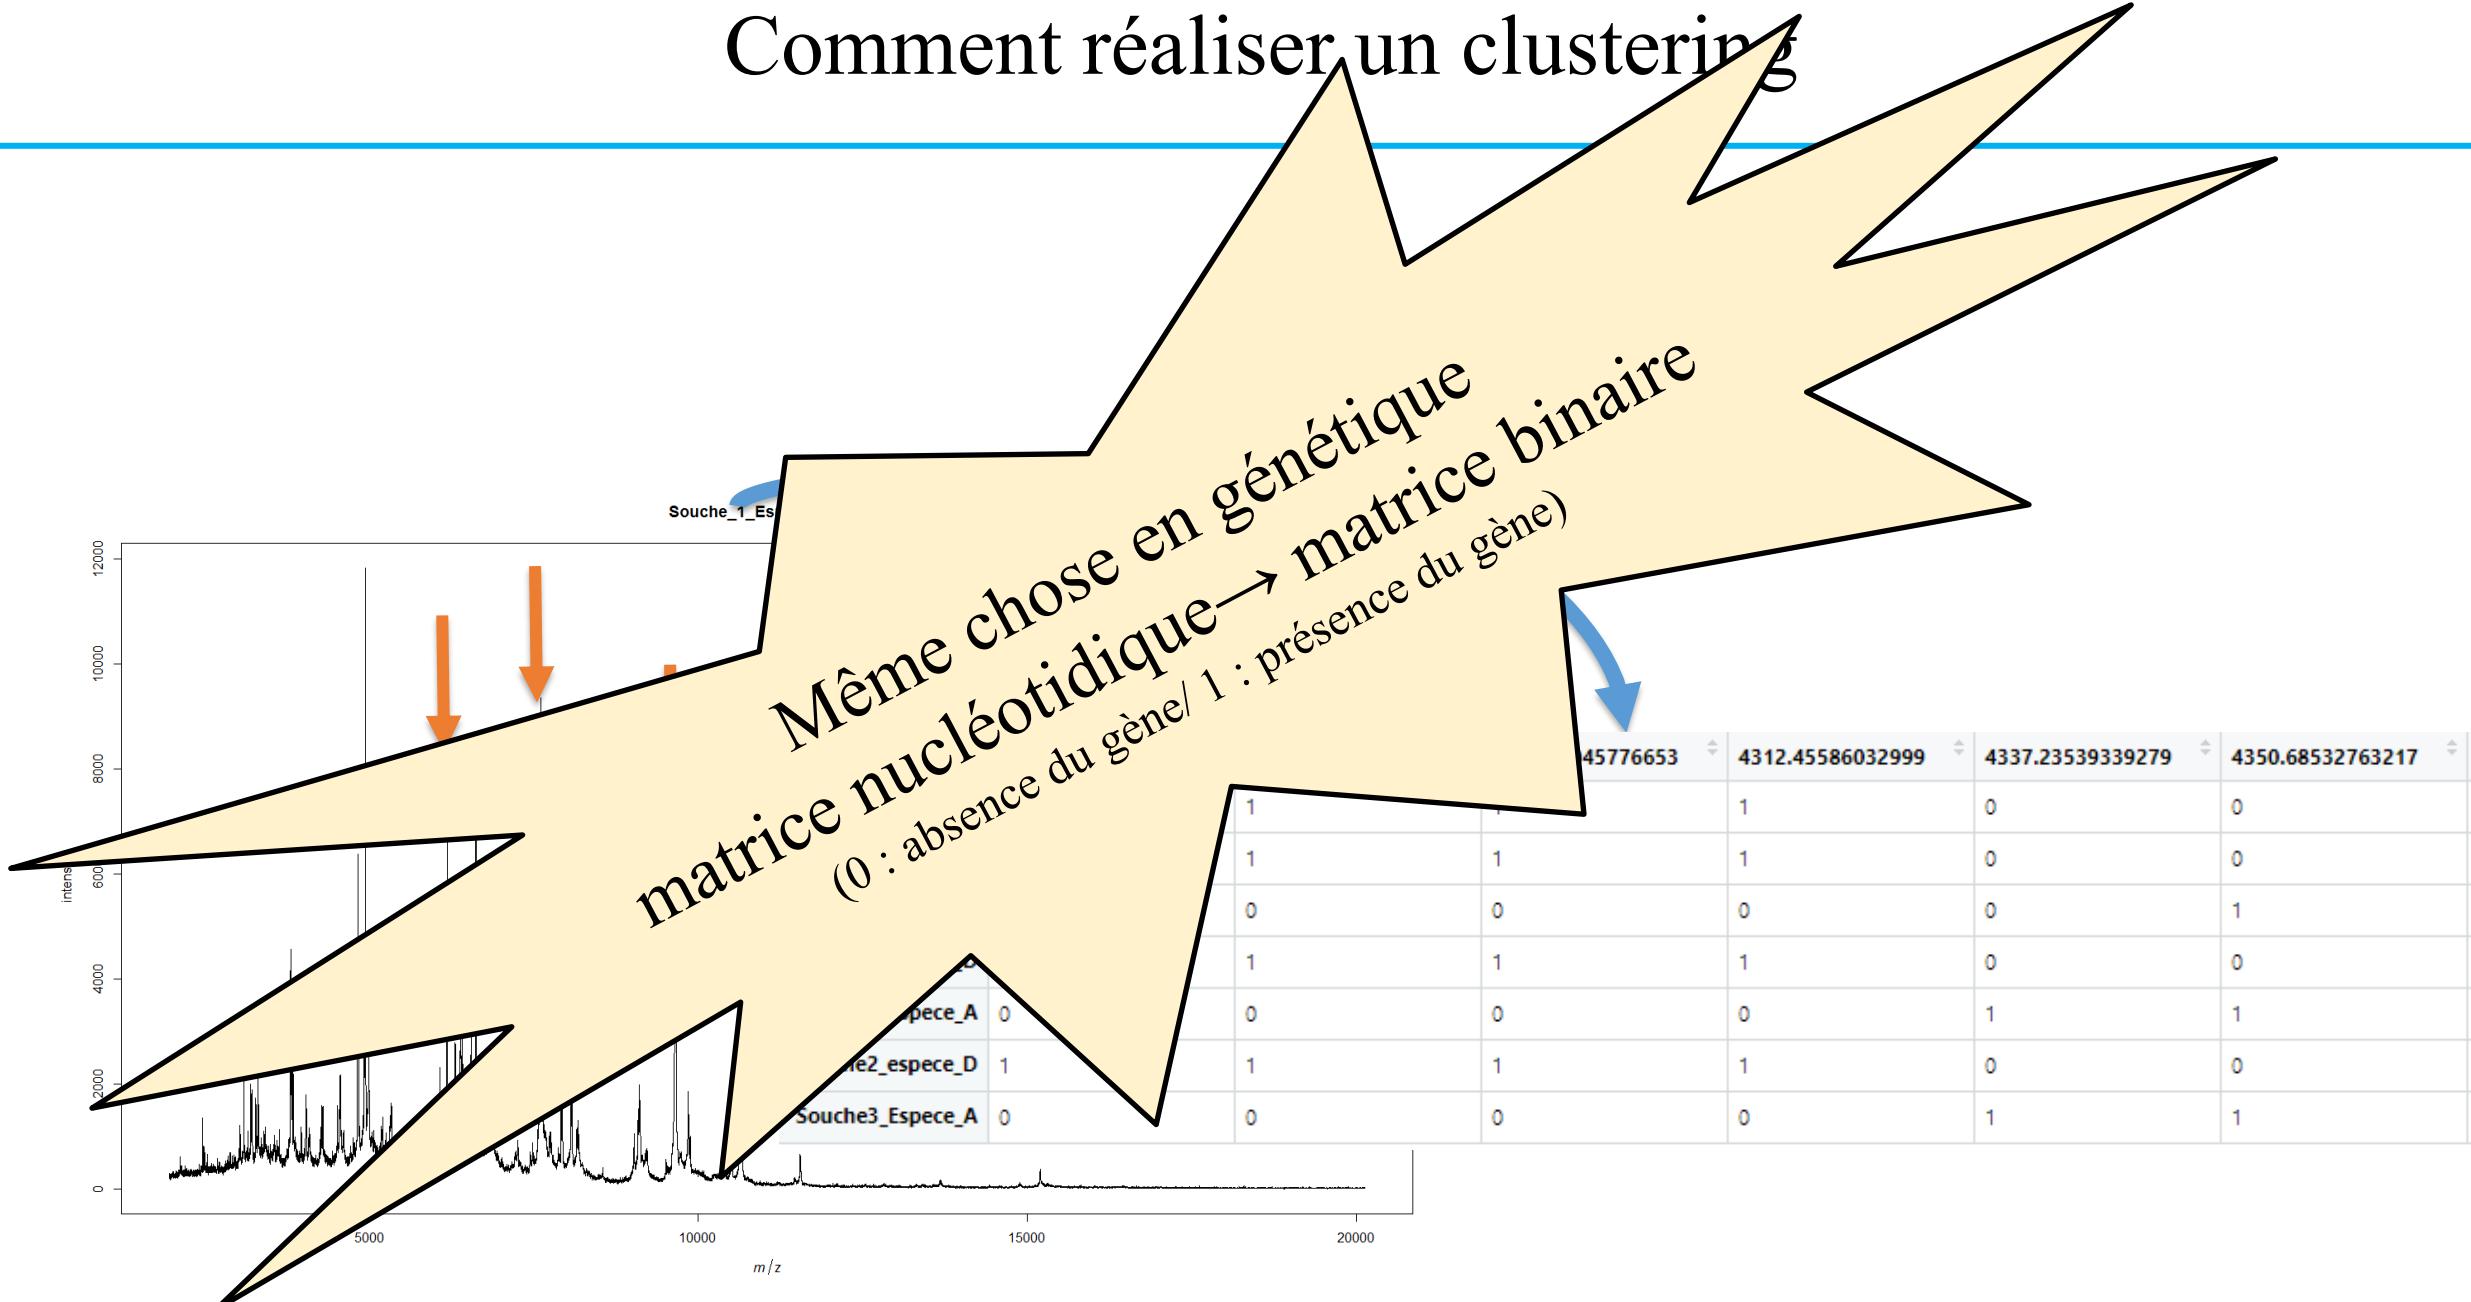
Transformation du spectre en matrice binaire (0 : absence du pic/ 1: présence du pic)

Comment réaliser un clustering



Transformation du spectre en matrice binaire (0 : absence du pic/ 1: présence du pic)

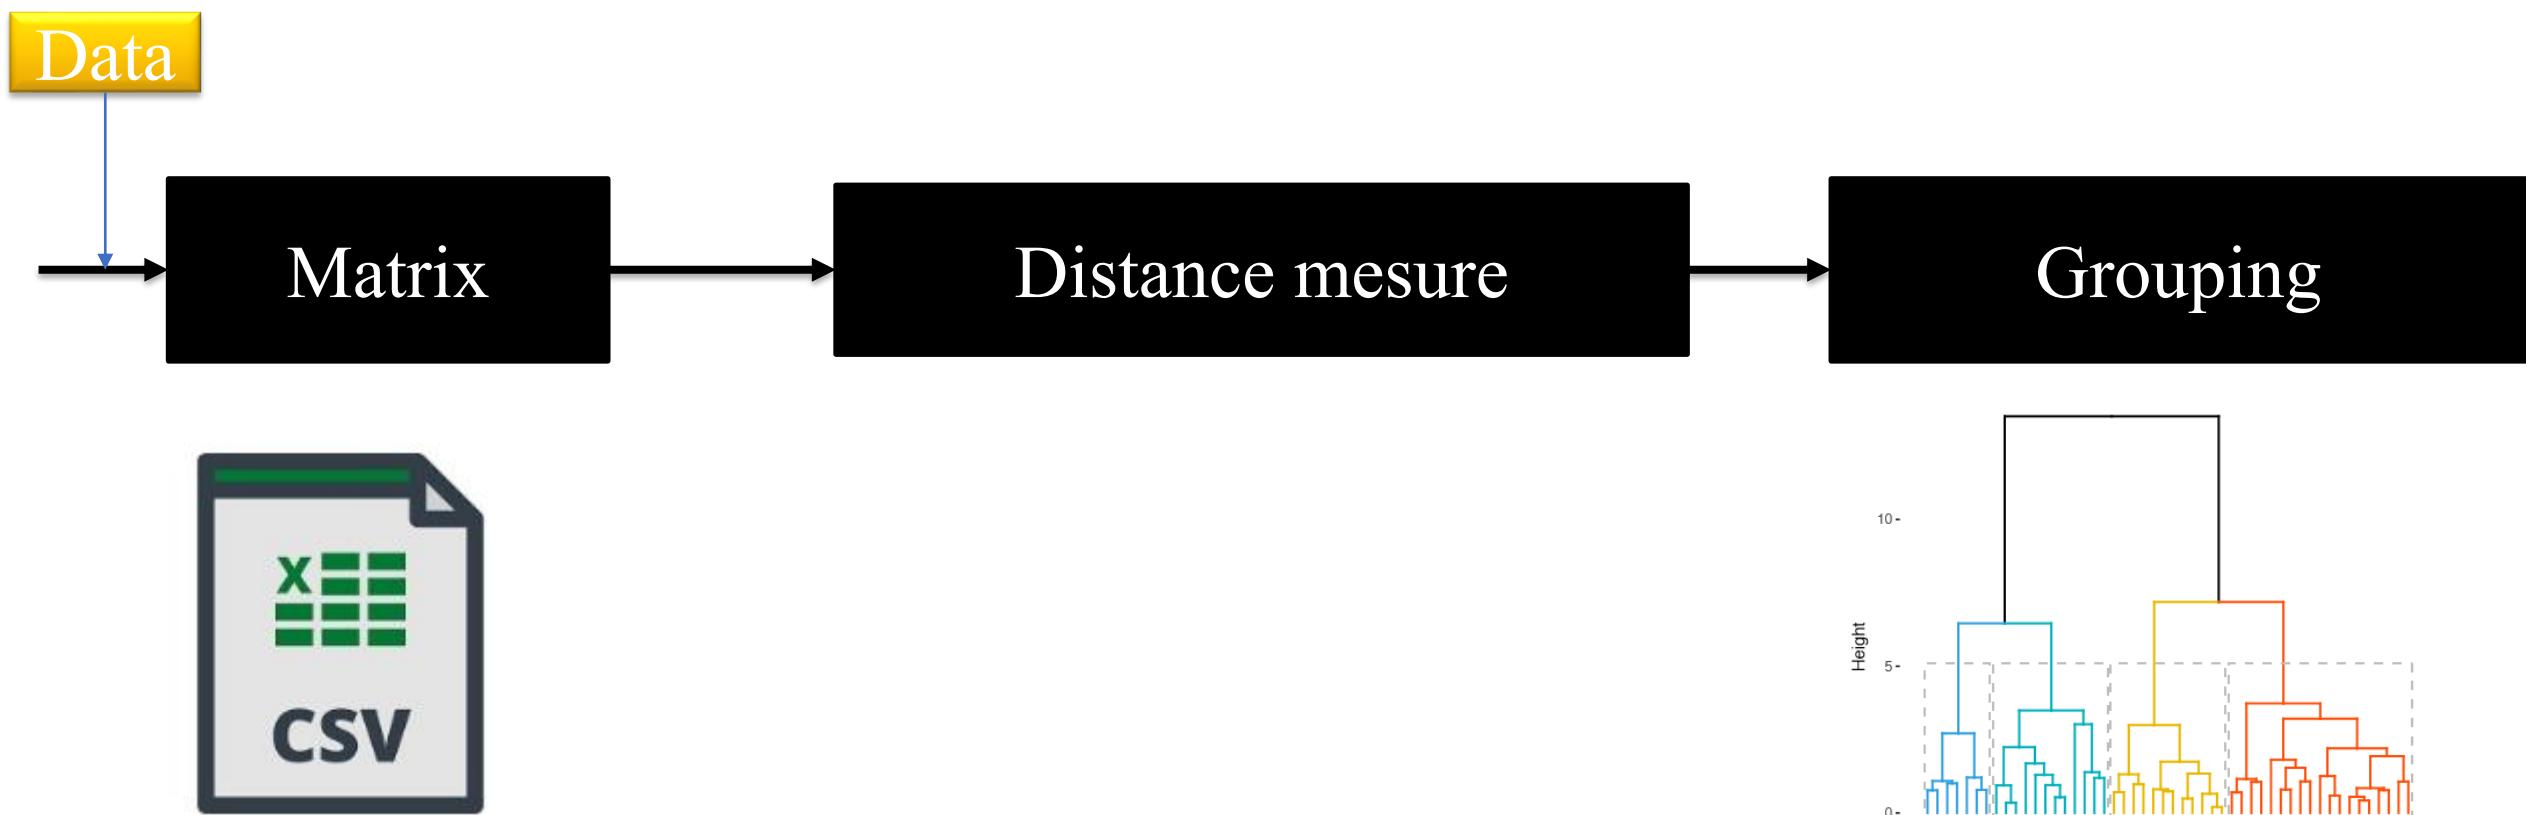
Comment réaliser un clustering



Transformation du spectre en matrice binaire (0 : absence du pic/ 1: présence du pic)

Mode opératoire

- Pipeline



Mode opératoire



- File .csv (comma delimited)

name	bike	natation	long_running	short_running
PAUL	11.8	18.9	20.9	
JULIETTE	13.4	67.0	28.1	30.7
AGATHE	6.6	23.2	27.3	32.8
PIERRE	8.9		24.9	41.7
MICHEL	10.3	10.8	20.0	18.9
FLORE	30.3	23.7	24.2	13.9
JEAN	11.2	20.7	27.9	

Wrong data

Bad name

Mode opératoire



- File .csv (comma delimited)

name	bike	natation	long_running	short_running
PAUL	11.8	18.9	20.9	NA
JULIETTE	13.4	67.0	28.1	30.7
AGATHE	6.6	23.2	27.3	32.8
PIERRE	8.9	NA	24.9	41.7
MICHEL	10.3	10.8	20.0	18.9
FLORE	30.3	23.7	24.2	13.9
JEAN	11.2	20.7	27.9	NA

Observation

Variables

Mode opératoire



Matrice de distance

- Euclidean distance :

$$d_{euc}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

- Manhattan distance :

$$d_{man}(x, y) = \sum_{i=1}^n |(x_i - y_i)|$$

- Pearson correlation distance

$$d_{cor}(x, y) = 1 - \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Degré de relation linéaire entre deux profils

- Kendall correlation distance

$$d_{kend}(x, y) = 1 - \frac{n_c - n_d}{\frac{1}{2}n(n - 1)}$$

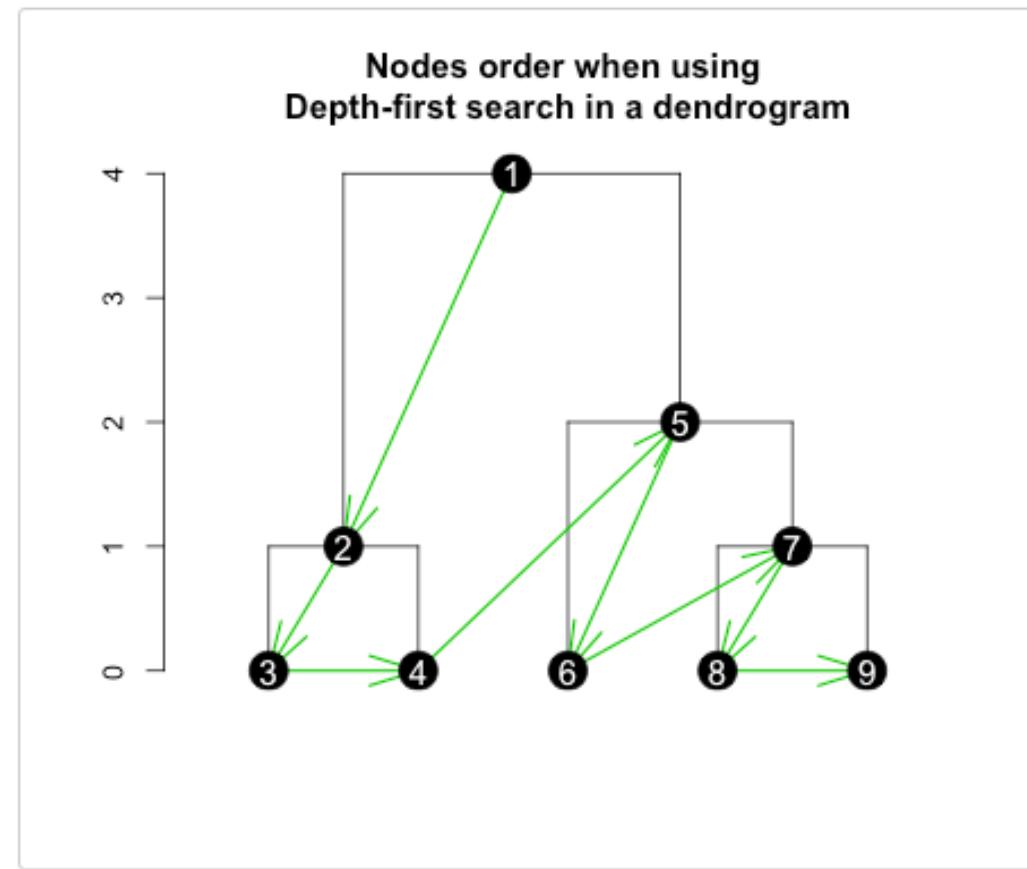
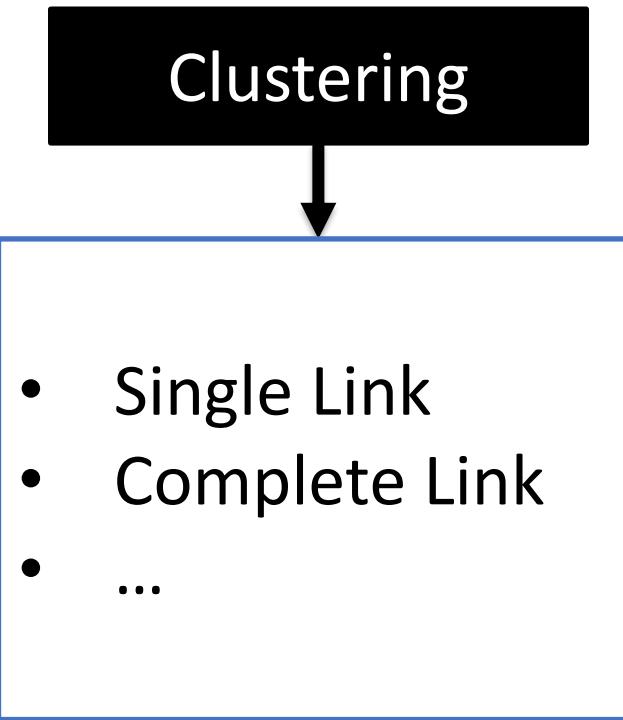
- n_c : total number of concordant pairs
- n_d : total number of discordant pairs
- n : size of x and y

Mode opératoire



- Quelle distance choisir ?

gene expression data analysis ► correlation based distance
gene presence or peak presence ► binary method

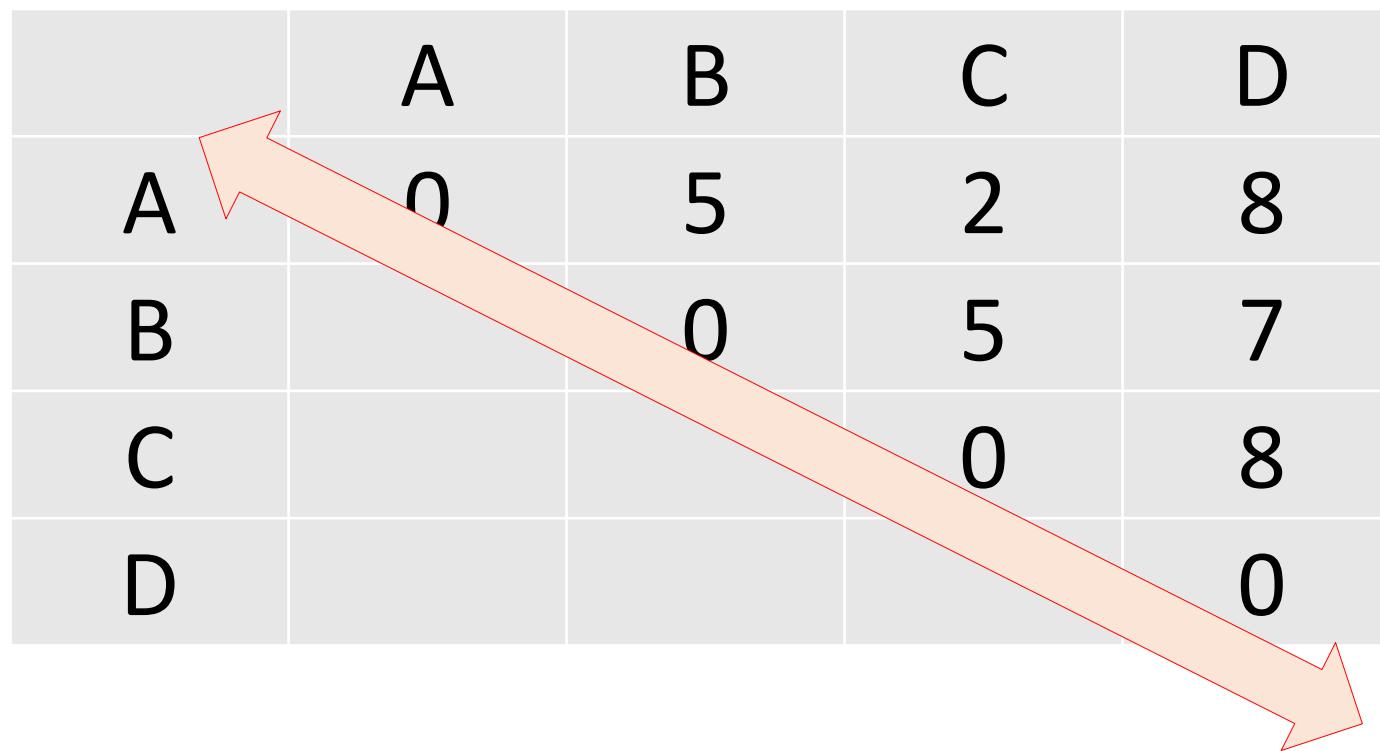




	A	B	C	D
Gene_X	0	0	1	0
Gene_Y	0	0	1	1
Gene_Z	0	0	0	1
Gene_T	0	0	1	1
Gene_...



	A	B	C	D
A	0	5	2	8
B		0	5	7
C			0	8
D				0



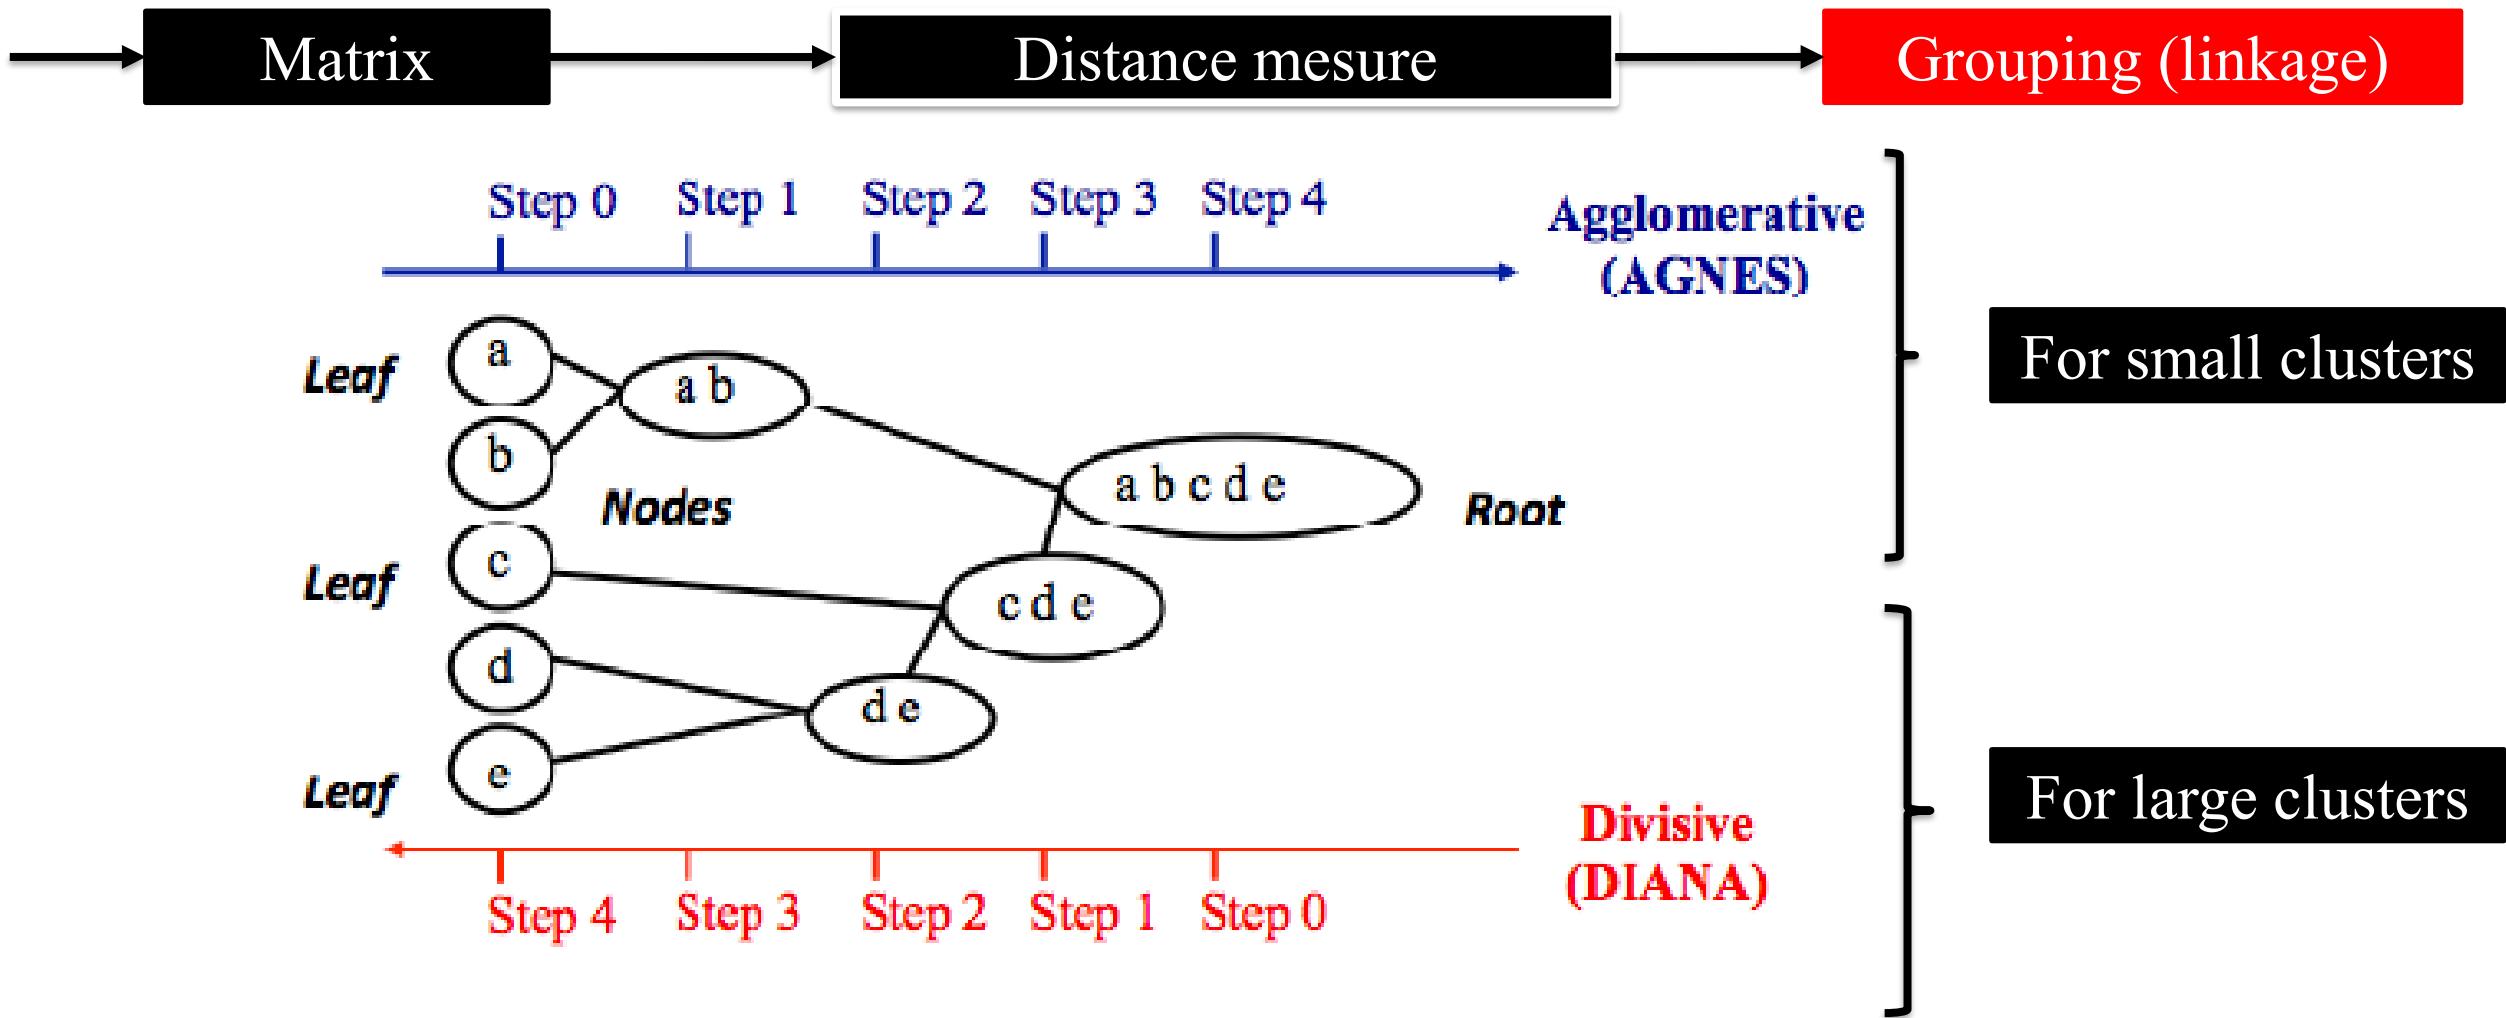


	A	B	C	D
A	0	5	2	8
B		0	4	1
C			0	2
D				0



	A	B	C	D
A	0	5	2	8
B		0	4	1
C			0	2
D				0

Hierarchcial clustering (HCA)





- **Maximum or *complete linkage*:** The distance between two clusters is defined as the maximum value of all pairwise distances between the elements in cluster 1 and the elements in cluster 2. It tends to produce more compact clusters.
- **Minimum or *single linkage*:** The distance between two clusters is defined as the minimum value of all pairwise distances between the elements in cluster 1 and the elements in cluster 2. It tends to produce long, “loose” clusters.
- **Mean or *average linkage*:** The distance between two clusters is defined as the average distance between the elements in cluster 1 and the elements in cluster 2 = **UPGMA**
- **Centroid linkage:** The distance between two clusters is defined as the distance between the centroid for cluster 1 (a mean vector of length p variables) and the centroid for cluster 2 = **UPGMC**
- **Ward’s minimum variance method:** It minimizes the total within-cluster variance. At each step the pair of clusters with minimum between-cluster distance are merged.



- **Maximum or *complete linkage*:** The distance between two clusters is defined as the maximum value of all pairwise distances between the elements in cluster 1 and the elements in cluster 2. It tends to produce more compact clusters.
- **Minimum or *single linkage*:** The distance between two clusters is defined as the minimum value of all pairwise distances between the elements in cluster 1 and the elements in cluster 2. It tends to produce long, “loose” clusters.
- **Mean or *average linkage*:** The distance between two clusters is defined as the average distance between the elements in cluster 1 and the elements in cluster 2 = **UPGMA**
- **Centroid linkage:** The distance between two clusters is defined as the distance between the centroid for cluster 1 (a mean vector of length p variables) and the centroid for cluster 2 = **UPGMC**
- **Ward's minimum variance method:** It minimizes the total within-cluster variance. At each step the pair of clusters with minimum between-cluster distance are merged.

Evaluer la solidité de l'arbre

Cophenetic distance

- The linking of objects in the cluster tree should have a strong correlation with the distances between objects in the original distance matrix
- >0,75: acceptable correlation

