



# Analyse en composantes principales

Comment faire de bonnes frites et comment être  
parcimonieu·x·se

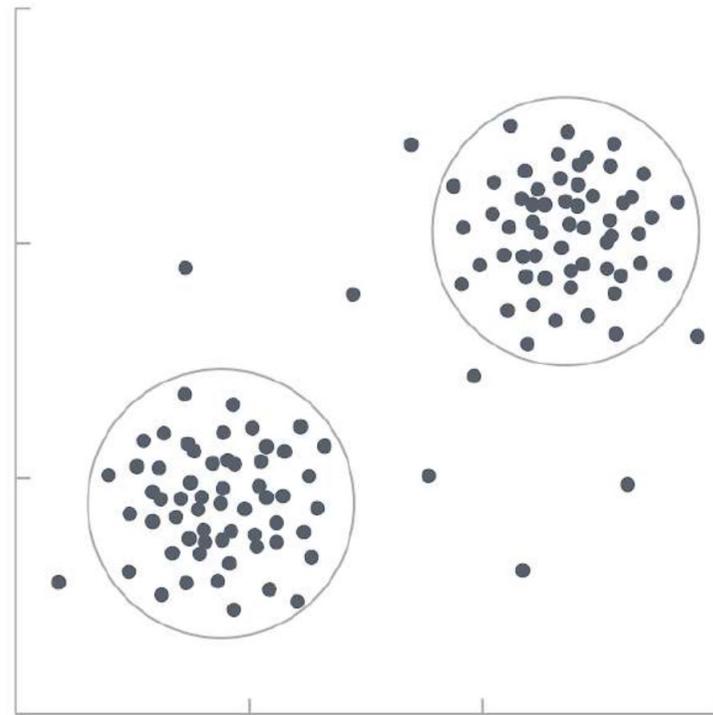
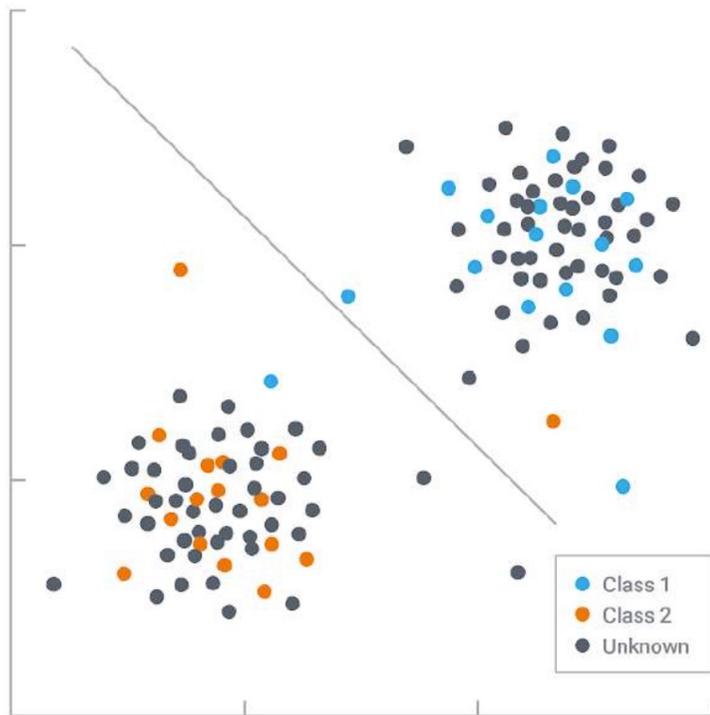


Quiz

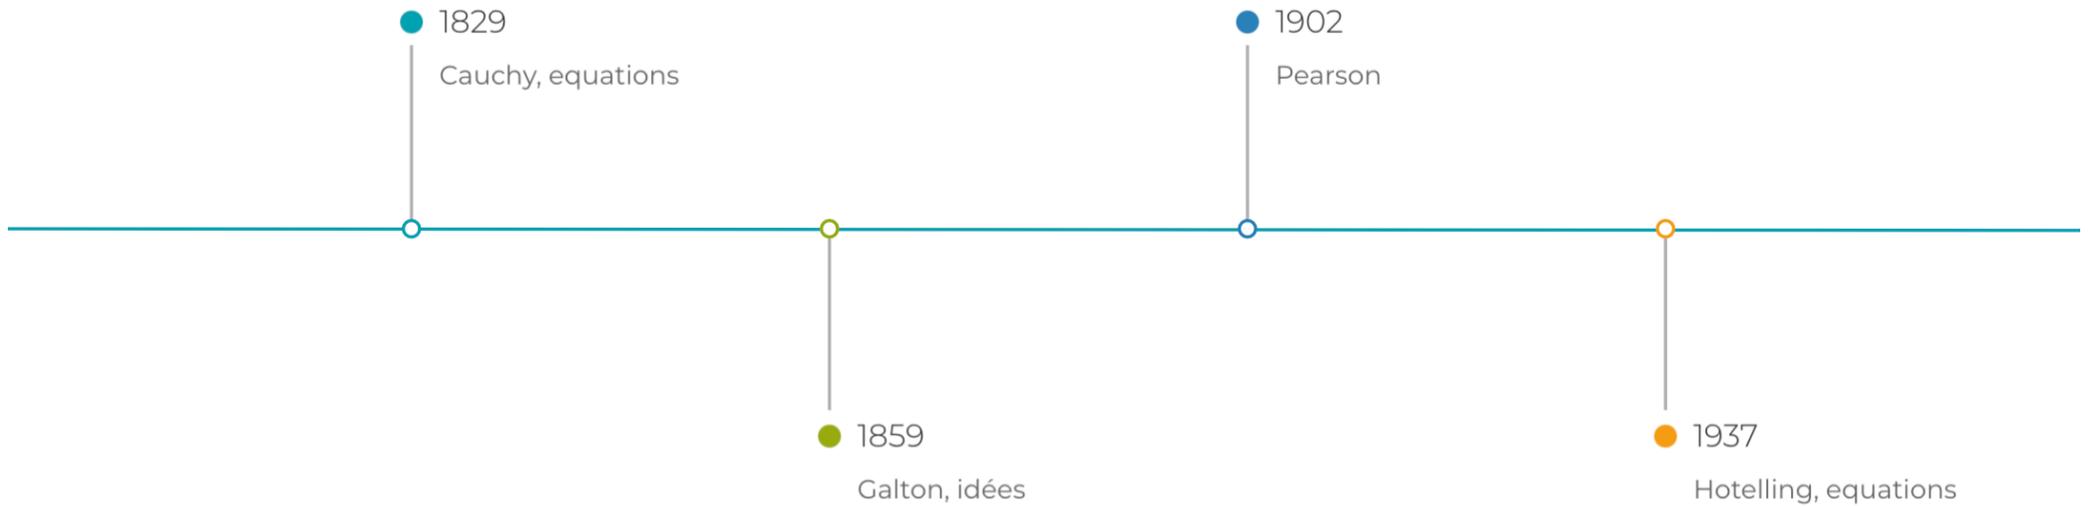
# Analyse non supervisée/exploratoire vs analyse supervisée

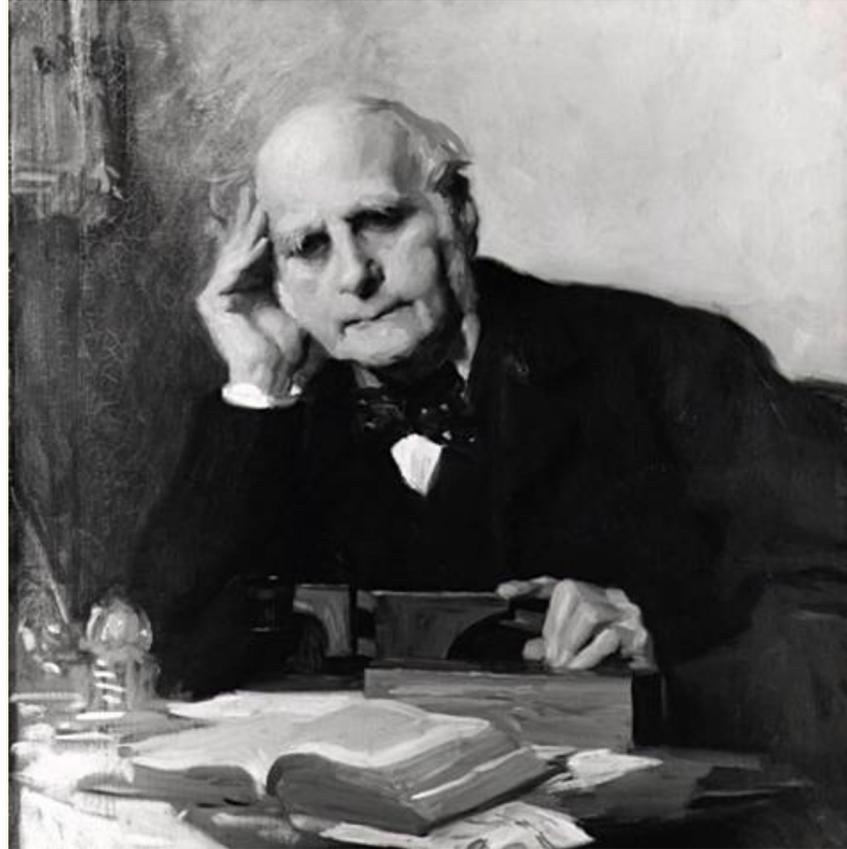
- Méthodes supervisées : une observation = caractéristiques / variables (p.ex : l'expression de gène) + une variable de réponse (p.ex. : survie).
- L'objectif est alors de prédire la réponse à l'aide des variables (par exemple, quels gènes prédisent le mieux ou sont associés à la survie des patients).
- Pour le moment, on explore (avec l'ACP et la CCA)

En image (merci Laura)

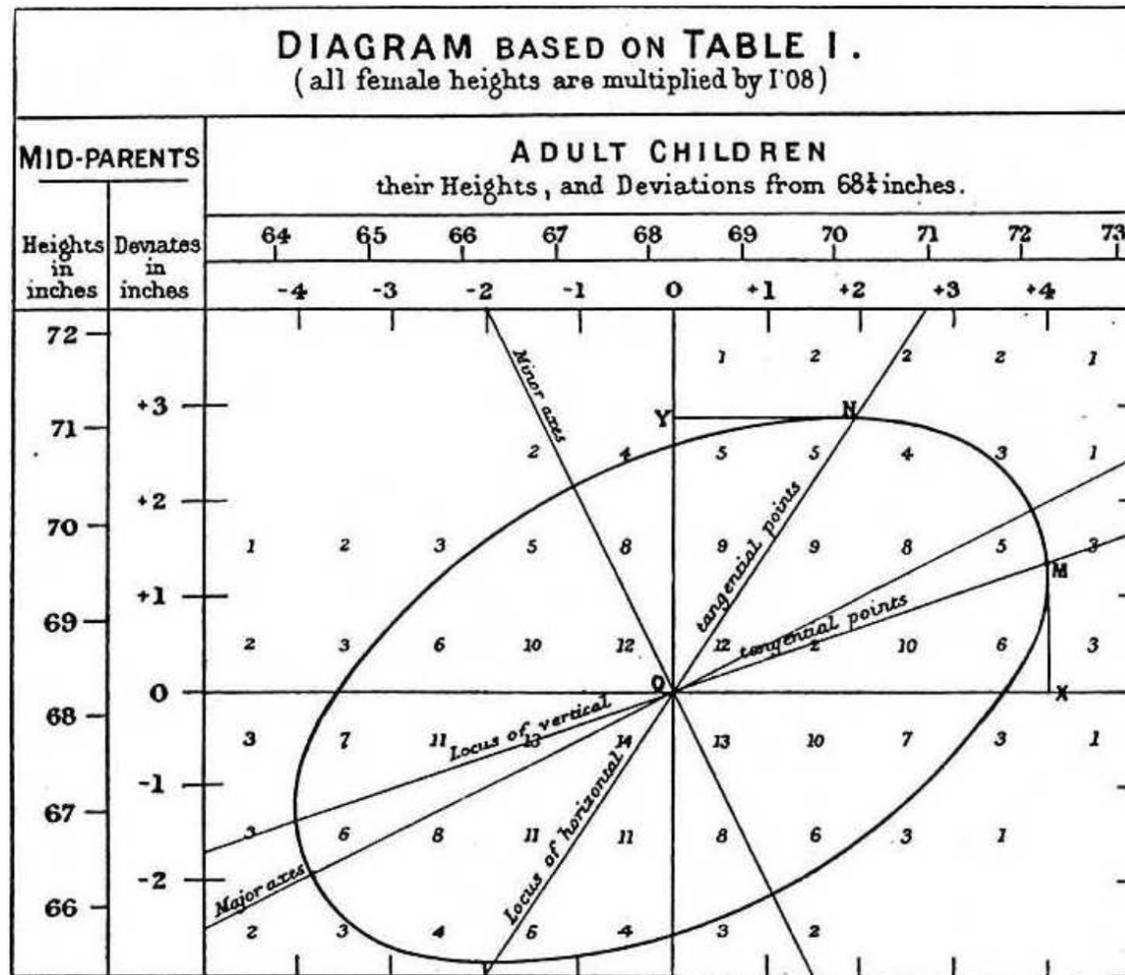


# Un peu d'histoire

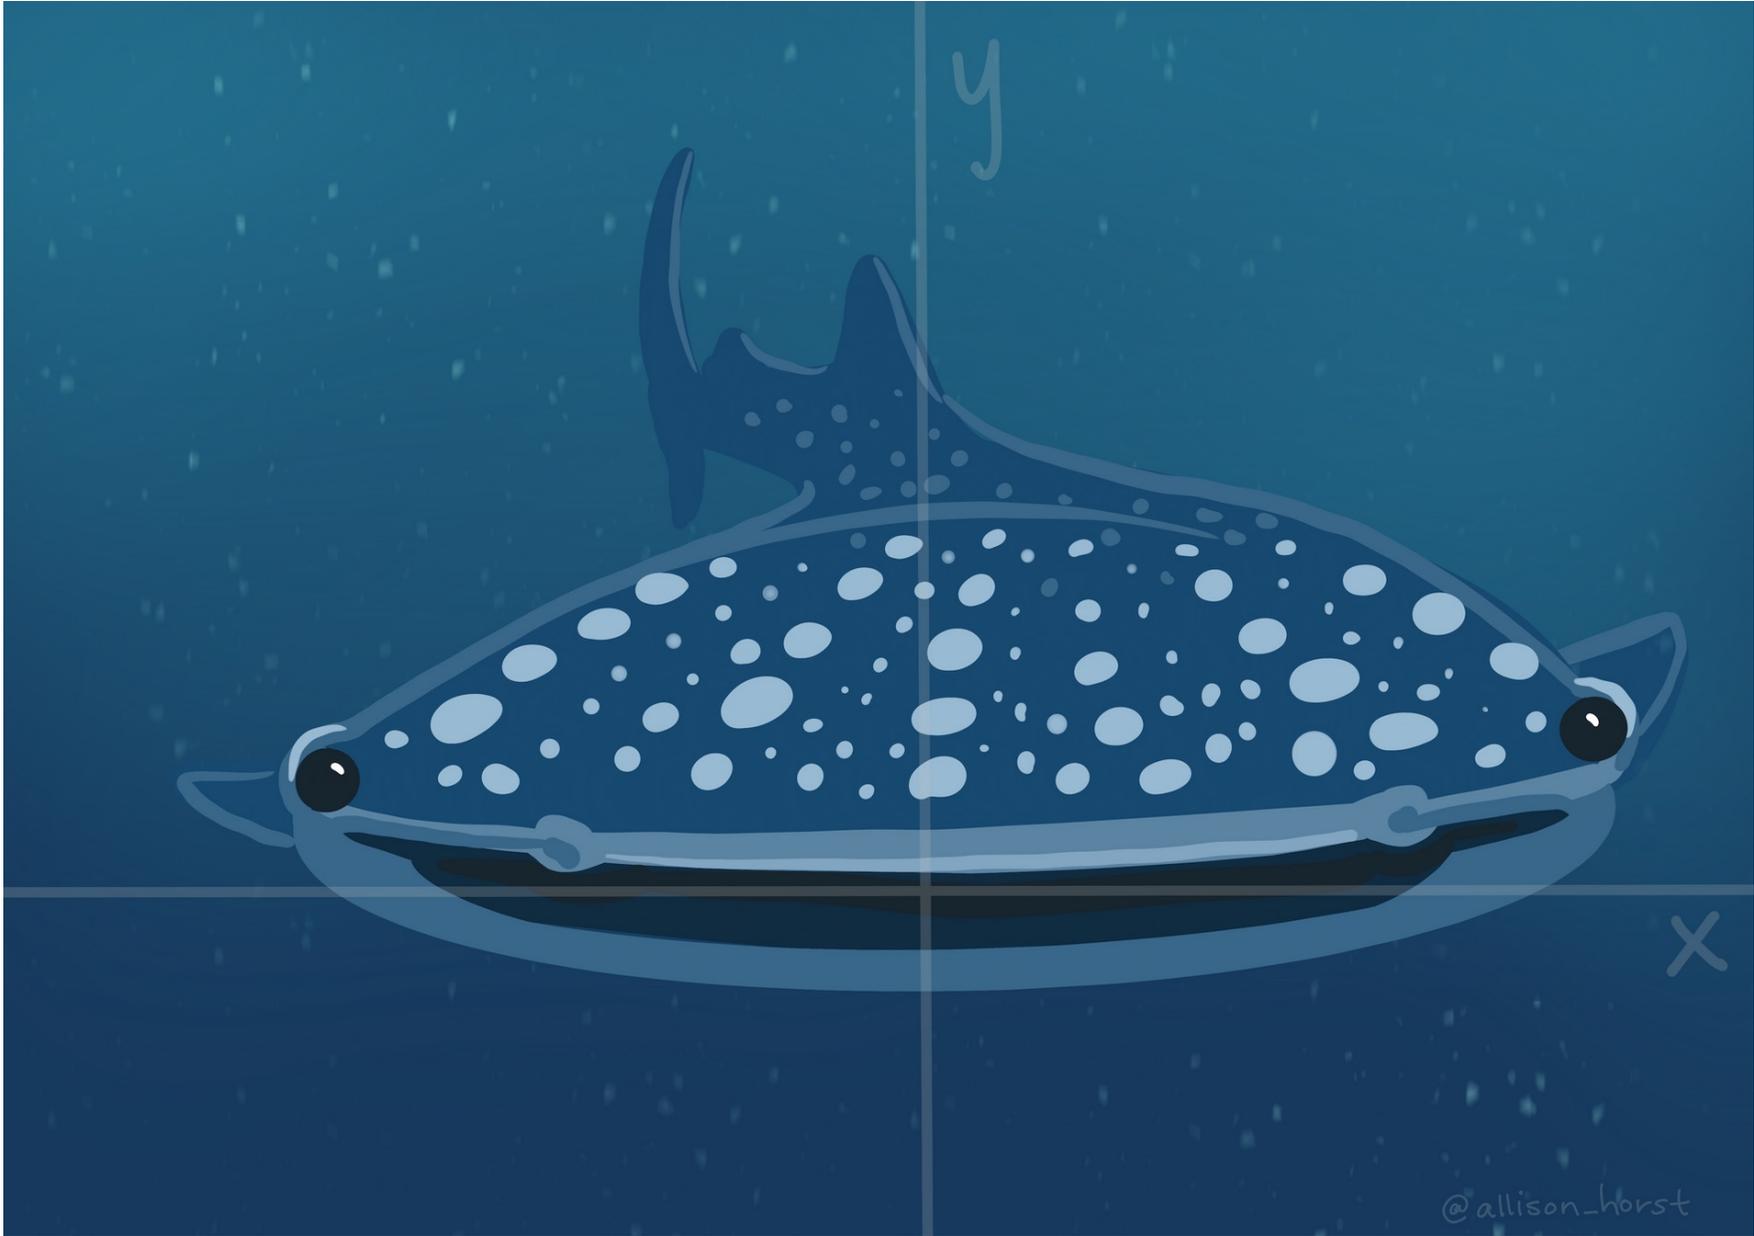




Sir Francis Galton



from Galton 1859



@allison\_horst

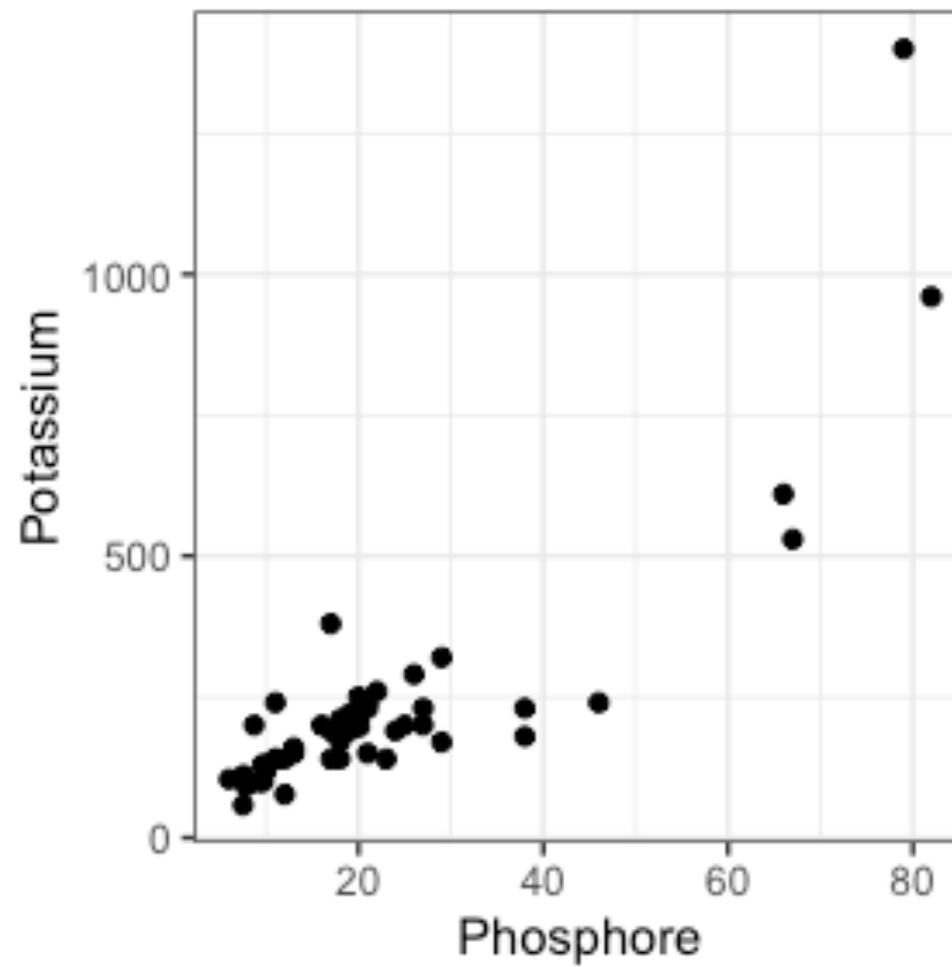


@allison\_horst

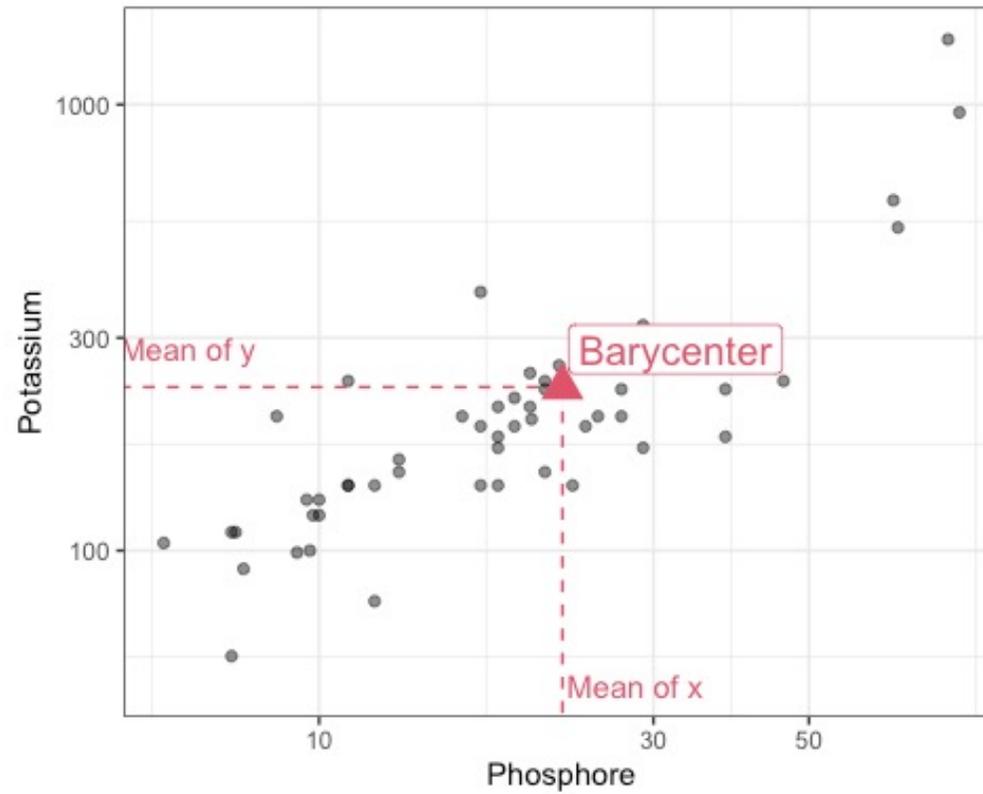


# Covariance et corrélation

Sur des fruits



# Barycentre (rappel)



# Covariance (rappel)

Un point est-il proche ou loin du barycentre ? Rectangle !

$$(x_i - \bar{x}) \times (y_i - \bar{y})$$

La covariance est (presque) l'aire moyenne :

$$\text{cov}(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \times (y_i - \bar{y})$$

# Coefficient de corrélation

La covariance varie entre  $-\infty$  et  $+\infty$ .

La corrélation est, par définition, une mesure de lien linéaire entre -1 et +1:

- -1 est une relation linéaire négative parfaite,
- 0 correspond à un lien nul,
- +1 est une relation linéaire positive parfaite.

# Corrélation de Pearson

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

... en bref...

$$\text{cor}(x, y) = \frac{\text{cov}(x, y)}{\text{sd}(x)\text{sd}(y)}$$

# “Exercices”

Covariance :

```
cov (fruits$Potassium,  
      fruits$Phosphore)  
#> [1] 3315.292
```

Corrélation :

```
cor (fruits$Potassium,  
      fruits$Phosphore)  
#> [1] 0.8587945
```

# Corrélation de Spearman's

Notée  $\rho$ . Sur les rangs !

- $r_x$  les rangs de  $x$ ,
- $r_y$  les rangs de  $y$ .

$$\rho(x, y) = \text{cor}(r_x, r_y)$$

Propriétés :

- Robuste aux valeurs exceptionnelles,
- Invariante par transformation monotone (p.ex. : log, square-root),
- Ne supporte pas les ex-aequos

# Corrélation de Kendall

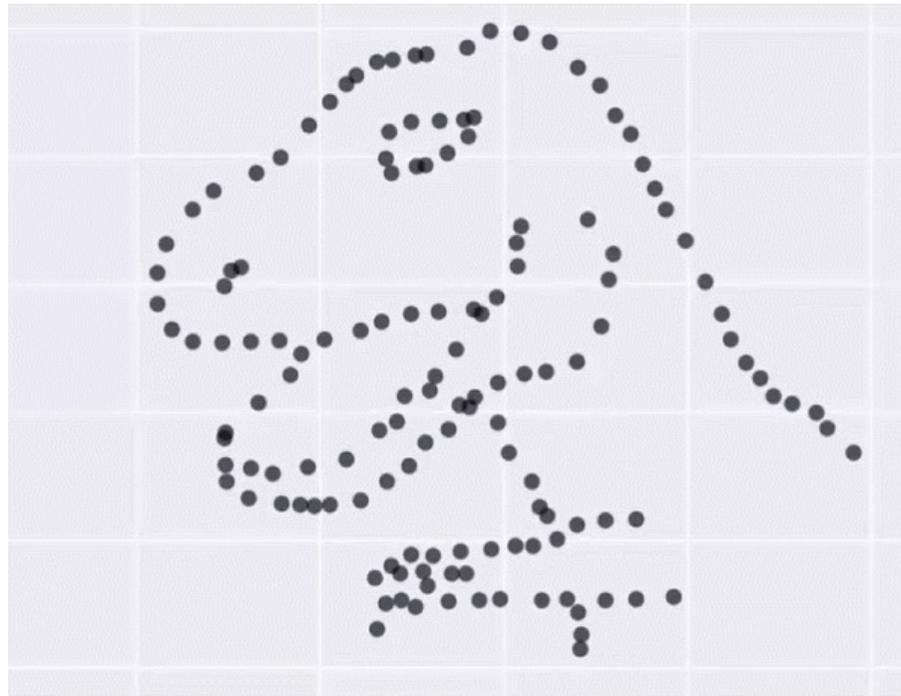
Paires de points : sur des sujets  $i$  et  $j$ .

- Paire Concordante :  $(x_i < x_j \text{ et } y_i < y_j)$  OU  $(x_i > x_j \text{ et } y_i > y_j)$
- Paire Discordante :  $(x_i < x_j \text{ et } y_i > y_j)$  OU  $(x_i > x_j \text{ et } y_i < y_j)$

$$\tau(x, y) = \frac{n_C - n_D}{n_0},$$

avec  $n_C$  le nombre de paires concordantes,  $n_D$  le nombre de paires discordantes et  $n_0$  le nombre total.

Beware of naked numbers!

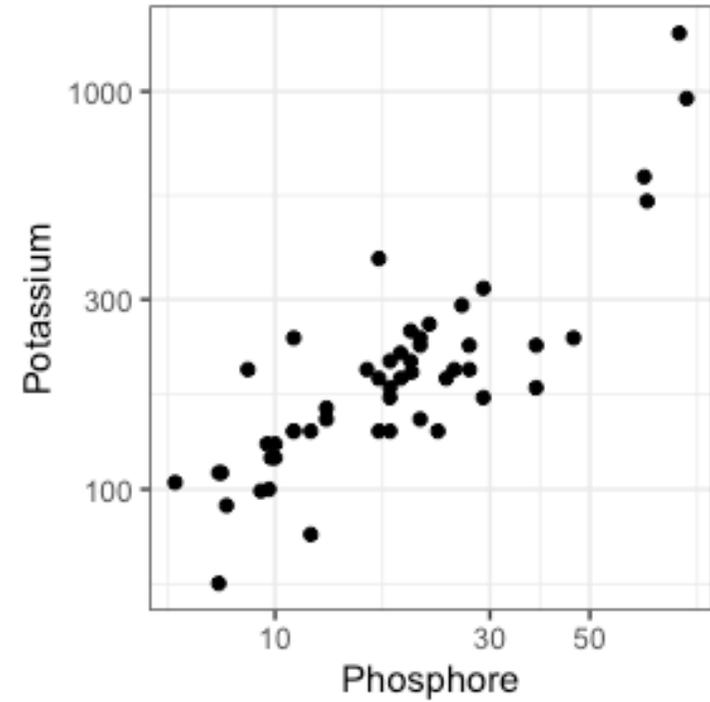


Datasaurus

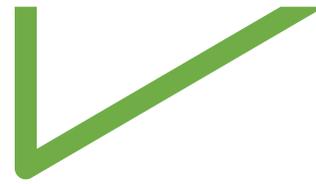
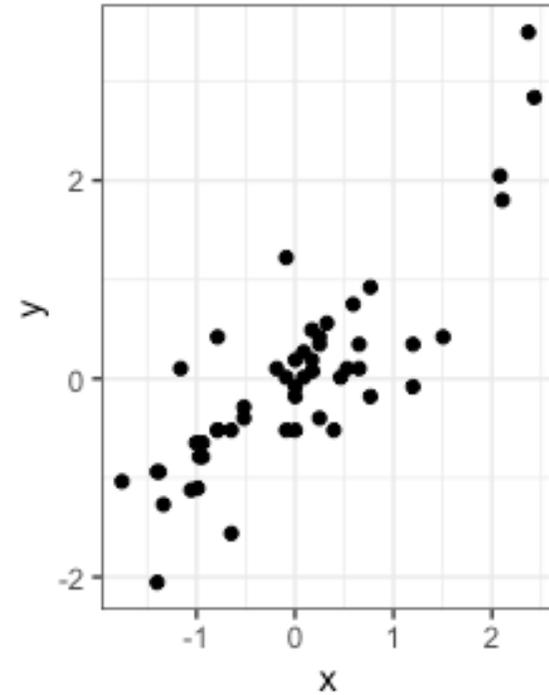


ACP en deux dimensions

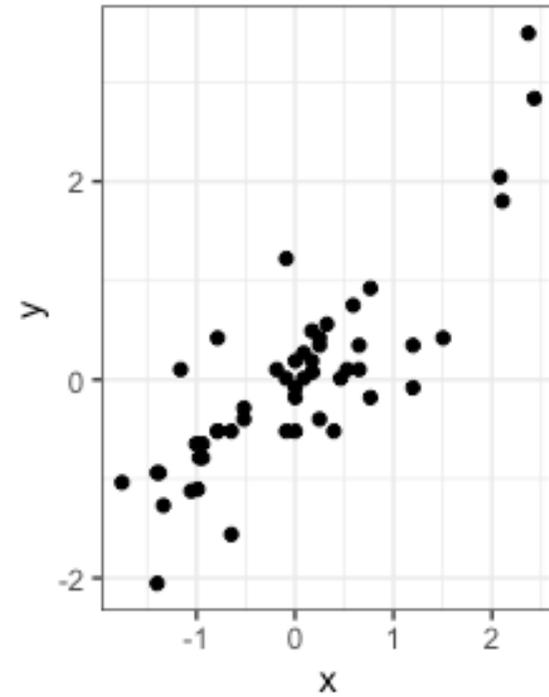
Sur les fruits



Pour me rendre  
la vie plus facile



J'ai fait quoi ?

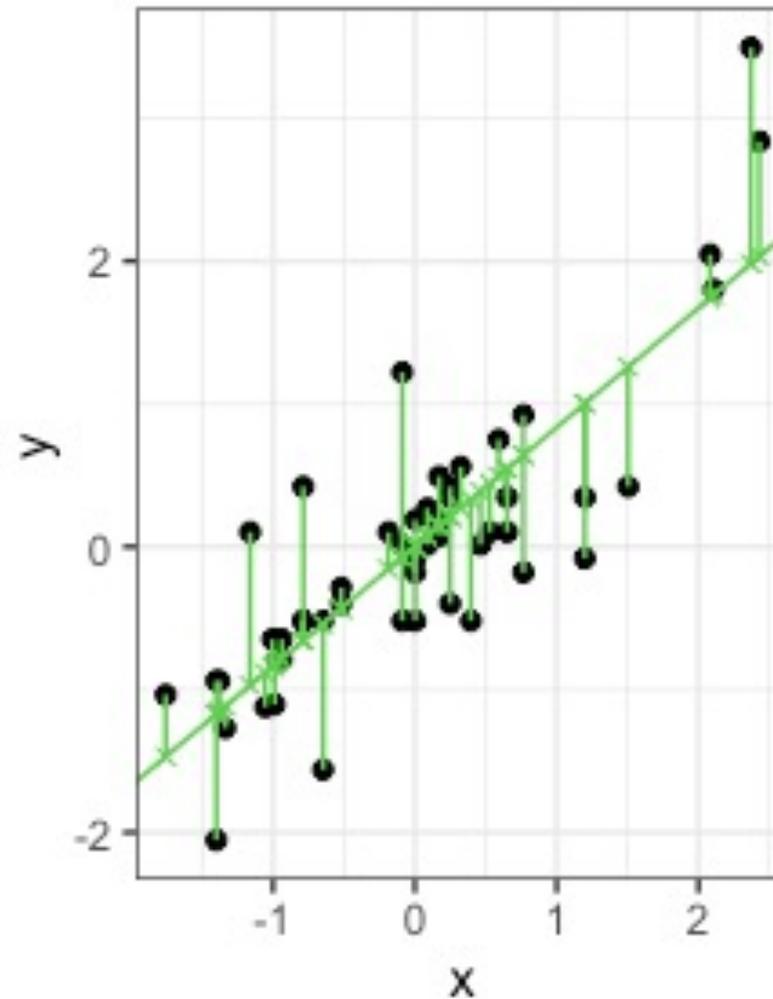


## Régression linéaire

Modèle :  $y = ax + b$

$a = \frac{\text{cov}(x,y)}{\text{var}(x)}$  est la pente de la droite,

$b = \bar{y} - a\bar{x}$  est l'ordonnée à l'origine.



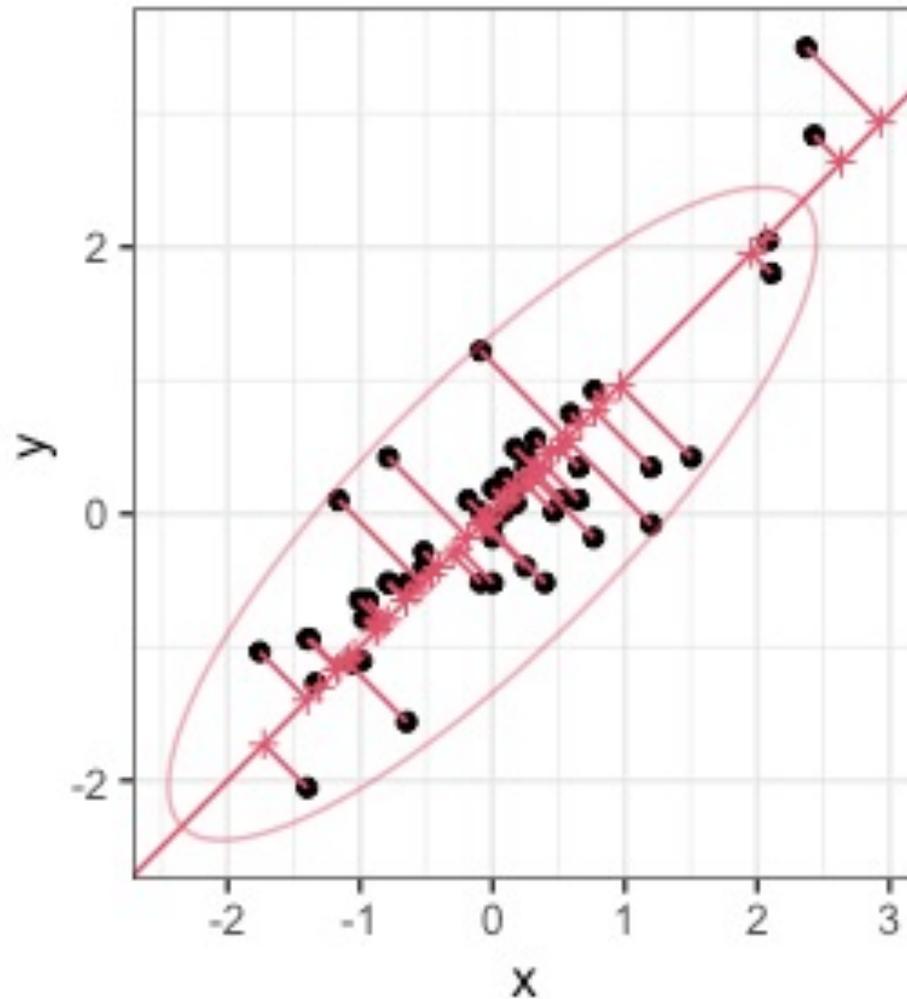
## Première composante principale

$$PC_1 = a_1x + a_2y$$

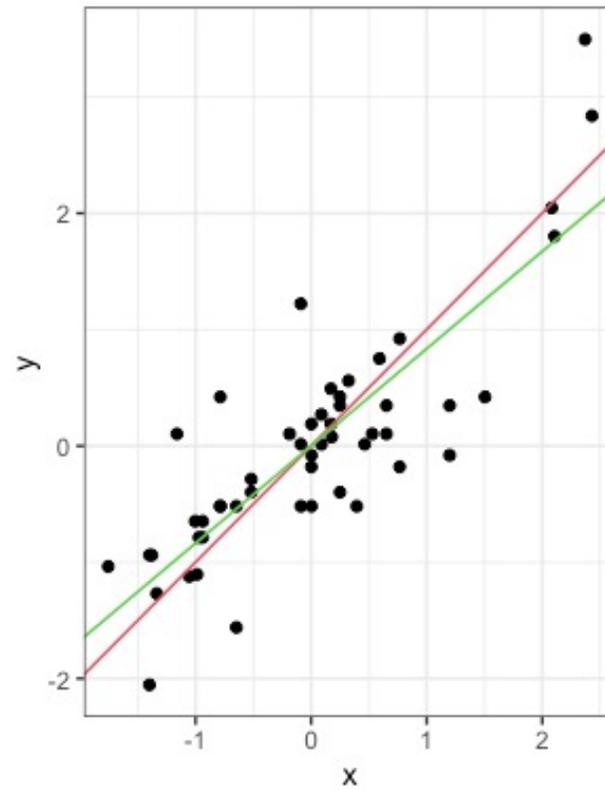
$a_1$  et  $a_2$  sont les poids

$PC_1$  est la première composante principale

$a_1$  et  $a_2$  sont calculés de telle sorte que  $PC_1$  a la plus grande variance **ET**  
 $a_1^2 + a_2^2 = 1$



Les deux sur le même graphe



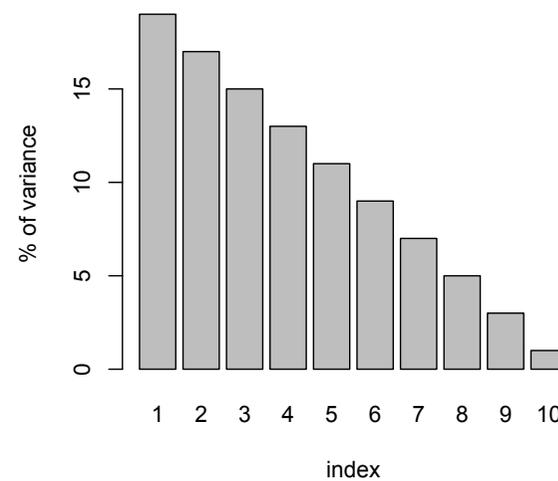
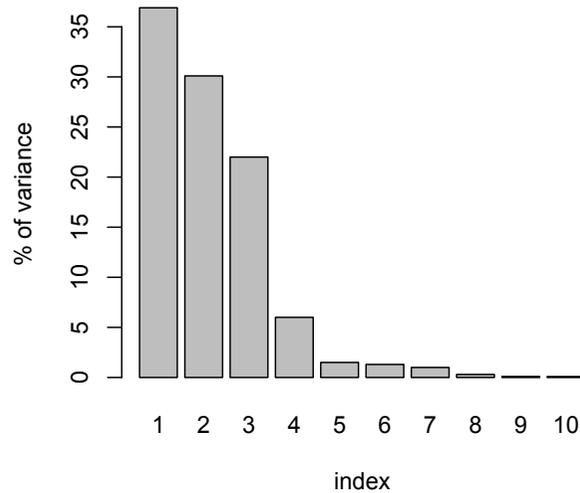
Généralités

# Combien de composantes principales

- Il y a au plus  $\min(n-1, p)$  PCs
- Exemple :  $p = 200$  gènes et  $n = 30$  échantillons  $\rightarrow$  au plus 29 composantes principales
- Que souhaitez-vous faire avec l'ACP ?
  - Visualisation ? Plutôt une poignée de composantes
  - Capturer un certain pourcentage de variabilité ?
  - Capturer la plus grande partie de la variabilité ?

# The elbow rule

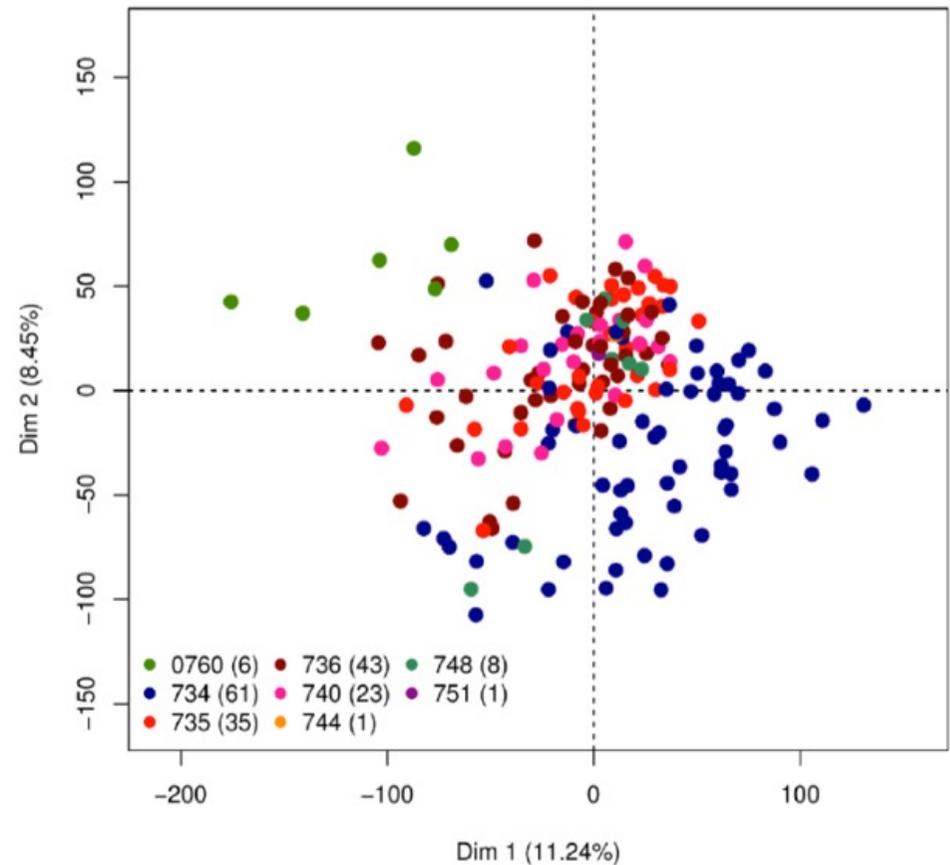
- Always useful to have a look at the plot of the fraction of total variance explained by each component.
- *Scree* graph (Cattell, 1966) : Look at the plot of the percentage of variance  $l_k$  against  $k$  and decide which value of  $k$  defines an '*elbow*' in the graph (subjective). In practice, rarely easy to choose.



# La carte des observations/patient·e·s

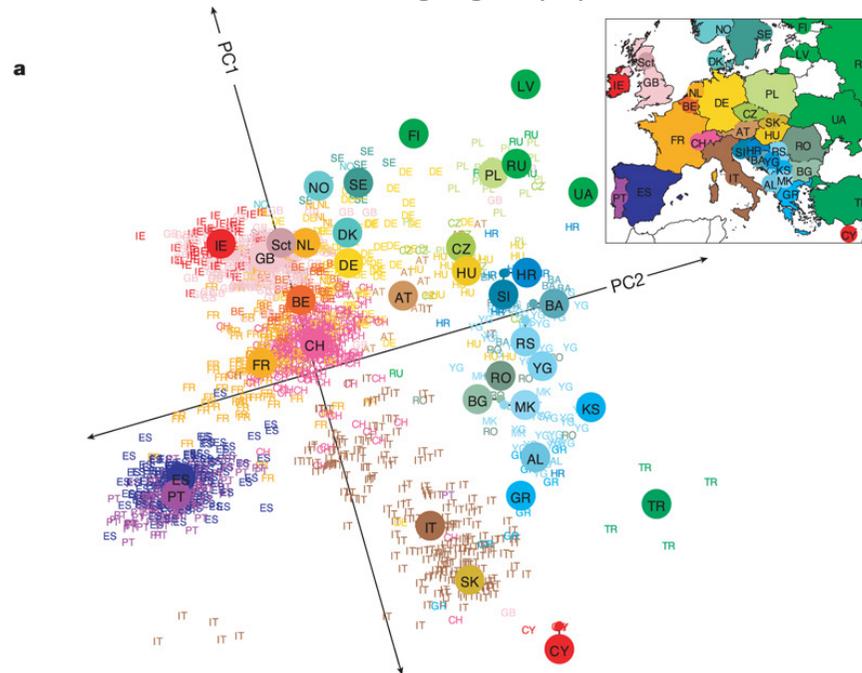
- Example: TCGA gene expression data set: Tumor samples colored by batch and projected on the first and the second PCs.

PCA allows to discover that the main source of variance is batch effect on this dataset



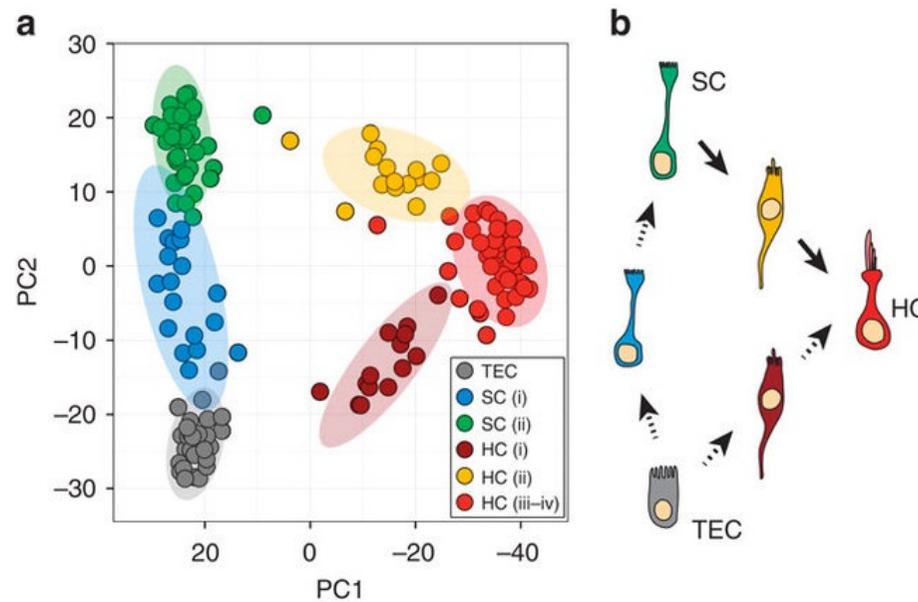
# La carte des observations/individus

- Example: A dataset of genotypes measured on a SNP array: the projection of individuals on the first and the second PCs highlights **population structure** within Europe.

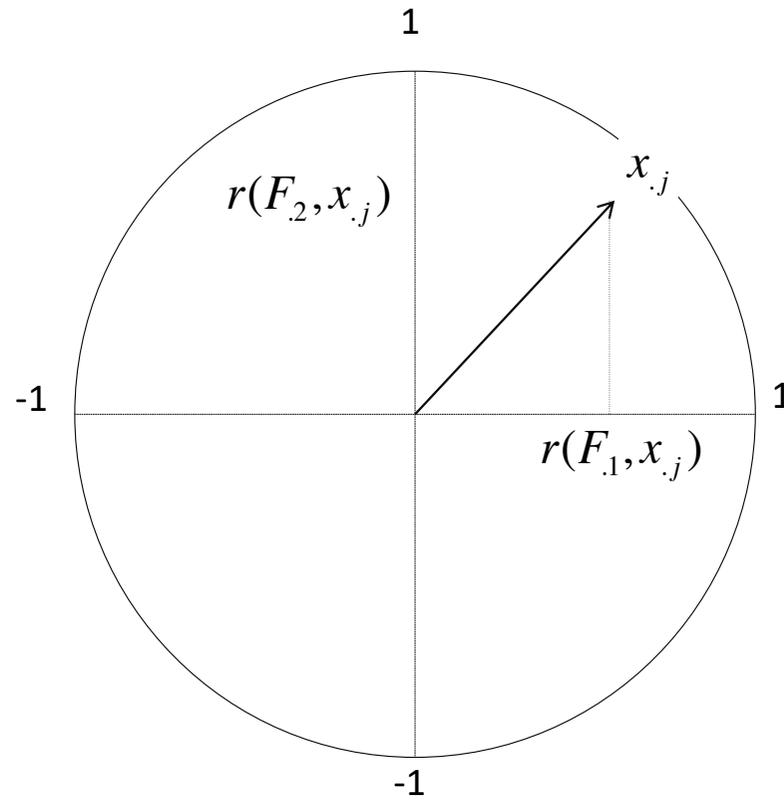


# La carte des observations/cellules

- Example: RNA-Seq single cell data for single cells of the inner ear: the projection of samples on first and the second PCs reflects **cell types**.

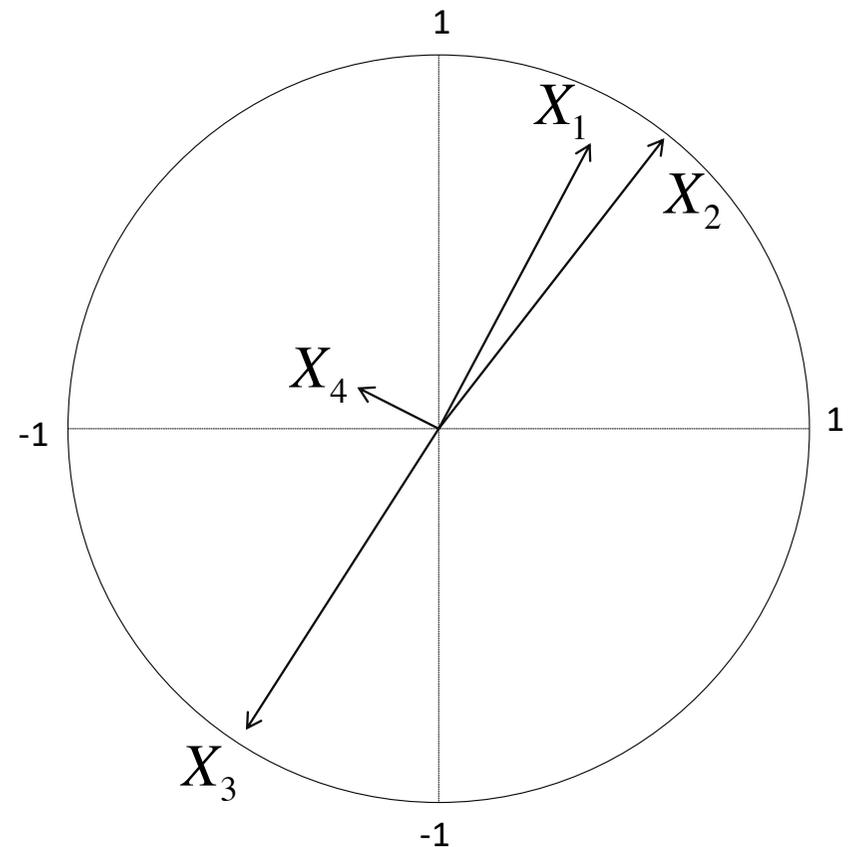


# Le cercle des corrélations



# Interprétation des composantes à partir des variables

- Une flèche proche du cercle indique que la variable est bien représentée par les CPs ( $X_1, X_2, X_3$ ).
- Une flèche proche de 0 ne peut pas participer à l'interprétation de la variabilité capturée par les CPs ( $X_4$ ).
- Deux flèches proches du cercle et proches entre elles sont très corrélées positivement ( $X_1, X_2$ ).
- Deux flèches qui sont à l'opposé l'une de l'autre tout en restant proche du cercle sont très corrélées négativement ( $X_1, X_3$  or  $X_2, X_3$ ).





# ACP en pratique

Sur les données fruits parce que c'est plus facile

Un peu de théorie

# Intuition

- La première composante principale est une nouvelle variable qui est la plus corrélée possible à toutes les autres variables

$$\arg \max_{\mathbf{U}} \sum_{j=1}^J \text{cor}(\mathbf{X}_j, \mathbf{U})^2$$



Un petit rappel : la décomposition en valeurs singulières

$$\mathbf{X} = \mathbf{U}\mathbf{\Delta}\mathbf{V}^\top$$

$$\begin{cases} \mathbf{X}\mathbf{X}^\top \mathbf{u} = \delta^2 \mathbf{u} \\ \mathbf{X}^\top \mathbf{X} \mathbf{v} = \delta^2 \mathbf{v} \end{cases} \quad \begin{cases} \mathbf{X}^\top \mathbf{u} = \delta \mathbf{v} \\ \mathbf{X} \mathbf{v} = \delta \mathbf{u} \end{cases}$$

# Méthode de la puissance itérée

$$\mathbf{v}^{(k+1)} \leftarrow \frac{1}{\|\mathbf{A}\mathbf{v}^{(k)}\|_2} \mathbf{A}\mathbf{v}^{(k)}$$

A essayer en premier lieu sur les données simulées très simples !

Comment obtenir la deuxième composante ?  
Par déflation

$$\tilde{\mathbf{A}} \leftarrow \mathbf{A} - \lambda \mathbf{v} \mathbf{v}^T$$

A essayer en premier lieu sur les données simulées très simples !