

# GC – Probabilités et Statistique

<http://moodle.epfl.ch/course/view.php?id=14271>

## Cours 1

- Notions de base
- Représentations graphiques
- Résumés numériques
- Le matériel d'aujourd'hui **ne sera pas examiné**  
**explicitement**, il est fourni à titre d'information (seulement)

# Population

- La **population** est l'ensemble des éléments qui forment le champ d'analyse d'une étude particulière
  - Dans une étude sur les thérapies du cancer du sein, la population pourrait être l'ensemble des personnes souffrant du cancer du sein
  - Dans une étude sur l'effet de la lumière sur la plante *Arabidopsis thaliana*, la population pourrait être l'ensemble des plantes *Arabidopsis thaliana*
  - (Formuler vos propres exemples)
- Ne s'applique pas seulement aux êtres humains
- La population est constituée des **individus** ou **unités statistiques**

# Variables (I)

- En statistique, *les caractéristiques qui varient* parmi les individus de la population sont appelées **variables**
- Les **modalités** d'une variable consistent en l'ensemble des *valeurs possibles*
- Variables de différentes sortes :
  - **Variables qualitatives** : les modalités sont des mots ou 'étiquettes' que l'on appelle des *catégories*  
*Exemples* : couleur des yeux ('bleu', 'brun', 'vert') ; le programme de télé préféré
  - **Variables quantitatives** : les modalités sont des valeurs numériques  
*Exemples* : âge, nombre de membres d'une famille, le poids

## Variables (II)

- **Variables qualitatives** peuvent être classées comme :
  - Échelle *nominale* – les catégories ne sont pas naturellement ordonnées (p.ex. couleur des yeux, sexe)
    - *Même si* les modalités sont exprimés comme des codes numériques (p.ex. sexe = '0' pour 'mâle', = '1' pour 'femelle')
  - Échelle *ordinale* – les catégories peuvent être ordonnées (p.ex. 'toujours', 'de temps en temps', 'jamais')
- **Variables quantitatives** sont distinguées :
  - Variables *discrètes* – les valeurs possibles peuvent être énumérées sous la forme d'une *liste de chiffres* (le plus souvent : les entiers nonnegatifs 0, 1, 2, ...)
  - Variables *continues* – l'ensemble des valeurs possibles est constitué par *un (ou plusieurs) intervalle(s)*

## Observations et données

- Les résultats observés d'une ou de plusieurs variables pour quelques individus d'une population constituent les **observations**; p.ex. :
  - le sexe, le poids, la taille et le périmètre crânien des nouveau-nés dans un hôpital particulier
  - la survie, la classification histologique et le stade TNM pour des tumeurs du sein
- Un jeu de données générique :

Individus	Variables					
	$X_1$	$X_2$	...	$X_j$	...	$X_p$
$i_1$	$x_{11}$	$x_{12}$	...	$x_{1j}$	...	$x_{1p}$
$i_2$	$x_{21}$	$x_{22}$	...	$x_{2j}$	...	$x_{2p}$
...						
$i_i$	$x_{i1}$	$x_{i2}$	...	$x_{ij}$	...	$x_{ip}$
...						
$i_n$	$x_{n1}$	$x_{n2}$	...	$x_{nj}$	...	$x_{np}$

# Analyse exploratoire des données

- Autrement dit 'la statistique descriptive', on *explore* les données avant l'analyse formelle
- Les données sont examinées pour évaluer leur qualité, ensuite 'nettoyées' s'il le faut, ainsi que visualisées afin de fournir une impression de l'ensemble des résultats
- Nous allons examiner *deux types* de résumés :
  - résumés graphiques
  - résumés numériques
- Nécessaire à utiliser un logiciel statistique (tel que R)

# Représentations graphiques des données : histogramme

- **L'histogramme** est un type (spécial) de *diagramme en barres*
- Il vous permet de visualiser *la répartition des valeurs* pour une variable numérique
- Lorsque dessiné avec une échelle de **densité** :
  - **la surface** (PAS la hauteur) de chaque barre est *la proportion* des observations dans l'intervalle
  - *la hauteur* représente *la densité*
- **La surface (l'aire sous la courbe) totale est 100% (ou 1)**

## Quelques formes d'histogramme



*étirée à gauche*



*étirée à droite*



*symétrique*

# Résumés numériques

- **Variables qualitatives :** tableau des fréquences
- **Variables quantitatives :**
  - mesures de *tendance centrale*
  - mesures de *dispersion*

# Mesures de tendance centrale : la moyenne

- **La moyenne (arithmétique)**  $\bar{x}$  est égale à la somme des valeurs observées, divisée par leur nombre total  $n$  :


$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

- La moyenne est une mesure appropriée pour une distribution (histogramme) qui est assez *symétrique*
- Puisque toutes les valeurs contribuent *également*, la moyenne est *sensible* à la présence d'observations abérrantes
- La moyenne est le point où l'histogramme s'équilibre

## Mesures de tendance centrale : la médiane

- **La médiane** ( $med(x)$ ) est le point qui partage la distribution d'une série (ordonnée) d'observations en *deux parties égales*
- La  $((n + 1)/2)$ <sup>ème</sup> plus grande valeur parmi  $x_1, \dots, x_n$  définit la médiane
- Si le nombre d'observations  $n$  est *pair*, la médiane peut prendre n'importe quelle valeur située entre la  $(\frac{n}{2})$ <sup>ème</sup> observation et la  $(\frac{n+2}{2})$ <sup>ème</sup> observation – normalement on prend la valeur moyenne de ces deux comme valeur de la médiane
- La médiane *n'est pas sensible* à la présence de valeurs aberrantes, car elle 'ne tient pas compte' de la quasi-totalité des valeurs
- La médiane est donc généralement un résumé plus approprié pour les distributions *asymétriques*

## Position relative de la moyenne et de la médiane



# PAUSE

## Mesures de dispersion : Variance et l'écart-type

- **La variance**  $s^2$  d'une variable est la moyenne\* des carrés des écarts de la moyenne :

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$


- **L'écart-type**  $s$  d'une variable est *la racine carrée de la variance* :

$$s = \sqrt{s^2}$$

- \*Pour des raisons 'techniques', au lieu de diviser par le nombre de valeurs  $n$ , en générale on divise par  $n - 1$
- L'écart-type  $s$  est une mesure de dispersion appropriée lorsqu'on utilise *la moyenne* pour la tendance centrale

## Quantiles

- Le **quantile (empirique)**  $\hat{q}(p)$  est la valeur telle qu'*une proportion p des observations soit au plus*  $\hat{q}(p)$



## Mesures de dispersion : IQ

- Les quantiles  $\hat{q}(25\%)$ , la médiane, et  $\hat{q}(75\%)$  divisent un ensemble d'observations en *quatre parties égales* (dont chacune contient 25% des observations)
- Ces quantiles spéciaux sont appelés les **quartiles**
- La distance entre les quartiles  $\hat{q}(25\%) = Q_1$  et  $\hat{q}(75\%) = Q_3$  est **l'intervalle interquartile (IQ)** :

$$IQ = Q_3 - Q_1$$

- L'*IQ* donne une mesure de dispersion lorsqu'on mesure le centre en utilisant la *médiane*


## Mesures de dispersion : MAD

- La médiane des écarts de la médiane ('median absolute deviation', ou **MAD**) est obtenue comme le suit :
  - 1 trouver la médiane  $med(x)$  des observations  $x_i$ ,  $i = 1, \dots, n$
  - 2 calculer les écarts  $|x_i - med(x)|$
  - 3 trouver la médiane des écarts calculés (l'étape 2 ci-dessus)
- Donc, analogue à l'écart-type
- Le *MAD* est bien *plus résistante* que l'écart-type  $s$
- Le *MAD* donne une autre mesure de dispersion quand on utilise la médiane

## Résumé à 5 valeurs et boxplot

- L'information essentielle dans une distribution est rapidement transmise au moyen du **résumé à 5 valeurs** :
  - 1 le minimum
  - 2  $\hat{q}(25\%) (= Q_1)$
  - 3 la médiane
  - 4  $\hat{q}(75\%) (= Q_3)$
  - 5 le maximum
- Le **boxplot** (la ‘boîte à moustaches’) représente graphiquement ces valeurs
- (**À noter** : le résumé à 5 valeurs dans PP est *différent*; google ‘5-number summary’)

# Boxplot



# Étapes pour créer un boxplot

- 1 Ordonner les valeurs
- 2 Calculer le résumé à 5 valeurs
- 3 Identifier des observations potentiellement aberrantes en calculant  $d = 1.5 \times (Q_3 - Q_1)$  et en cherchant des valeurs


$$x_i < e_{inf} = Q_1 - d \quad \text{et} \quad x_i > e_{sup} = Q_3 + d$$

- 4 Esquisser le graphique :
  - faire le boîte ( $Q_1, Q_3$ )
  - mettre un trait dans la boîte au niveau de la médiane
  - ajouter des petits traits ('whiskers' ou 'moustaches') pour les extrêmes et les connecter à la boîte
  - s'il existe des observations aberrantes, les signifier en utilisant des étoiles

# Résistance

- La **résistance** s'adresse à *l'insensibilité au 'mauvais comportement' des données*
- Une analyse ou un résumé est **résistant/e** si *un changement arbitraire dans n'importe quelle partie des données ne produit pas un grand changement* des résultats de l'analyse ou du résumé
- La résistance d'un résumé est *souhaitable* : on ne veut pas avoir des conclusions très fragiles
- *Exemple* : revenu 'typique' avec ou sans Mark Zuckerberg
- La médiane est bien résistante ; la moyenne n'est pas résistante

## Résistance de la moyenne et de la médiane (1)



*médiane*      ↑  
                    ↑  
*moyenne (originale)*

## Résistance de la moyenne et de la médiane (2)

