

# Revision

## Comment choisir un test statistique

### Questions à répondre:

- Combien des **échantillons (groups)** on a?
- Les échantillons sont:
  - **Dépendantes**/appariées?
    - (jumeaux/ données répétées/comparaison du partie gauche et droit d'un sujet/études appariées/deux tests diagnostiques ou méthodes de mesure qui observent les mêmes sujets)
  - **Indépendantes**?
- Quel est le **type des variables**?
- Combien des sujets?
  - Pour les **données qualitatives**:
    - Tableau de contingence: % des **cellules théoriques** < 5?
- Quelle est la nature des données?
  - Pour les **données quantitatives**:
    - **Distribution normale**?
    - **Variances égales/ inégales**?

## Precisions

- Ecart type = déviation standard
- Notations:
  - $s$  – déviation standard,
  - $S$  – déviation standard d' échantillonnage
    - $S = s * \sqrt{(n/(n-1))}$
- Echantillons:
  - Indépendants
  - Dépendants (appariées)
- Distribution gaussienne = normale

3

## Les hypothèses statistiques

- La création des hypothèses:
    - Certains **questions médicales** ont deux réponses opposées
      - on force beaucoup des questions dans ce format
    - Les réponses correspond aux deux **modèles** possibles de la réalité
    - Ce deux modèles sont nommées: **hypothèses**
      - L' hypothèse **nulle**:  $H_0$ 
        - **Il n'y a pas** un **différence** statistiquement significative **entre 2/>>=2 groups** (ex. un traitement [ibuprofène vs. placebo] ou un facteur de risque [présent vs. absent]) en ce qui concerne la **moyenne/ médiane/ variance/ fréquence ... d'une caractéristique** (ex résultat du traitement: la fréquence du guérison [oui vs. non] ou la moyenne de la température)
        - **Il n'y a pas** un **relation/lien/association/dépendance/corrélation** statistiquement significative **entre 2 caractéristiques/variables**: (ex. un **Facteur de risque** [présent vs. absent] – **une maladie** [oui vs. non] , ou un **traitement** [ibuprofène vs. placebo] – **le résultat du traitement** (ex: la fréquence du guérison [oui vs. non] ou la moyenne de la température))
      - L' hypothèse **alternative**:  $H_1$  (négation du  $H_0$ )
        - **Il y a** un **différence** statistiquement significative **entre 2/>>=2 groups** en ce qui concerne la **moyenne/ médiane/ variance/ fréquence ... d'une caractéristique**
        - **Il y a** un **relation/lien/association/dépendance/corrélation** statistiquement significative **entre 2 caractéristiques/variables**
- Les tests statistiques nous permet de faire la chois entre les deux possibilités ( $H_1$  /  $H_0$ )

4

## Les étapes d'un test statistique

- **Étape 1. Formuler les hypothèses statistiques:**
- **Étape 2. Décider sur une statistique appropriée du test (paramètre du test)**
- **Étape 3. Sélectionner le niveau de signification - la valeur alpha.  $\alpha = 0,05$**
- **Étape 4. Déterminer la valeur critique (v.c.) de la statistique du test**
  - on détermine - une région critique ou région de rejet (RR)
    - Lois t, Z:  $RR = (-\infty, -v.c.] \cup [v.c., +\infty)$
    - Lois F, Khi 2:  $RR = [v.c., +\infty)$
- **Étape 5. Calculer la valeur de la statistique / paramètre du test**
- **Étape 6. la décision statistique en fonction de la région critique :**
  - Si  $Z_0$  est dans RR (région du rejet/critique) on rejette  $H_0$  et on accepte  $H_1$ 
    - Il y a une différence/ Il y a une relation -statistiquement significative
  - Si  $Z_0$  est dans RnR (région de non rejet) on reste avec  $H_0$  (on peut pas rejeter  $H_0$ )
    - On ne peut pas dire qu' il y a une différence/ il y a une relation statistiquement significative
- **Étape 6'. La décision avec p-value**
  - La décision avec p-value.
  - Si  $p\text{-value} < \alpha (=0,05)$  on rejette  $H_0 \Rightarrow$  on accepte  $H_1$ 
    - Il y a une différence/ Il y a une relation -statistiquement significative
  - Si  $p\text{-value} \geq \alpha (=0,05) \Rightarrow$  on reste avec  $H_0$ 
    - On ne peut pas dire qu' Il y a une différence/ Il y a une relation -statistiquement significative

5


## Vérification de la condition de normalité des données

### Utilité:

- Importante pour appliquer des test paramétriques, avec condition de normalité:
  - Test Z pour les moyennes
  - Test t (Student)
  - Test ANOVA

### Modalités de vérification (ici, conditions de normalité:


- des graphiques (les meilleures) modalités)
  - Histogramme (symétrique, comme un chapeau)
  - Boite à moustaches (symétrique autour de la médiane)
  - Le graphique des quantiles (voir diapositive suivant)
- des statistiques descriptives (pas très fiables)
  - Si la moyenne est  $\approx$  médiane
  - Si le coefficient de l'aplatissement  $\approx 0$  / appartient à  $[-1, 1]$  (kurtosis)
  - Si le coefficient de symétrie  $\approx 0$  / appartient à  $[-1, 1]$  (skewness)
- des tests de normalité: (ne sont pas recommandées)
  - Test de Kolmogorov-Smirnov ( $p < 0,05$  - non normale,  $p > 0,05$  ~normale)
  - Test de Shapiro-Wilk ( $p < 0,05$  - non normale,  $p > 0,05$  ~normale)




6

## Comparaison des données normale/non normale distribuées

• **Normale**  
 moyenne  $\approx$  médiane  
 ( $= -0,03$   $= 0,015$ )  
 c. asymétrie = 0,11  
 appartient à  $[-1, 1]$ ,  $\approx 0$   
 c. aplatissement =  $-0,09$   
 appartient à  $[-1, 1]$ ,  $\approx 0$   
 Shapiro-Wilk test  
 $p = 0,99 > 0,05$



• **Non normale**  
 moyenne  $\neq$  médiane  
 ( $= 1,57$   $= 0,98$ )  
 c. asymétrie = 5,59  
 $> 1$ ,  $<> 0$   
 c. aplatissement = 40,63  
 $> 1$ ,  $<> 0$   
 Shapiro-Wilk test  
 $p \approx 0 < 0,05$



## La normalité des données

- Test de normalité des données :
  - Test de Kolmogorov-Smirnov
  - Si  $< 50$  sujets le test Shapiro-Wilk
- $H_0$  = aucune différence statistiquement significative entre la distribution observée et la distribution normale
- $H_1$  = aucune différence statistiquement significative entre la distribution observée et la distribution normale
- $p < 0,05$  on rejette l'hypothèse nulle, les données ne sont pas normalement distribuées
- $p > 0,05$  on ne rejette pas l'hypothèse nulle, on n'a pas des motifs pour considérer les données anormales – on peut considérer les données normalement distribuées (dans certaines conditions)

## Récapitulatif des tests utilisés

### Tests pour variables quantitatives - comparer la moyenne des deux échantillons

| Type variable  | Nb sujets                     | Nature des données  | Statistique comparée    | Test utilisé                                 | Paramètre du test   | Région du rejet - test bidirection      |
|--|-------------------------------|---|-------------------------|--|---|---|
| <b>Deux échantillons indépendants</b> Pour l'examen écrit je ne demande pas les choses en gris |                               |   |                         |  |   |   |
| Quantitative   | $n_1, n_2 \geq 30$            | Normale distribuées, Variances dans la population <b>connues</b> inégales   | Différence des moyennes | Test Z pour la différence entre les moyennes | $Z = \frac{m_1 - m_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$  | $(-\infty, -v.c.] \cup [v.c., +\infty)$ |
|  | $n_1, n_2 \geq 30$            | Normale distribuées, Variances dans la population <b>connues</b> égales     | Différence des moyennes | Test Z pour la différence entre les moyennes | $Z = \frac{m_1 - m_2}{\sqrt{\frac{\sigma^2}{n_1} + \frac{\sigma^2}{n_2}}}$  | $(-\infty, -v.c.] \cup [v.c., +\infty)$ |
|  | $n_1, n_2 \geq$<br>ou $< 30$  | Normale distribuées, Variances dans la population <b>inconnues</b> inégales | Différence des moyennes | Test t ( Student) $n_1 + n_2 - 2$ d.d.l.     | $t = \frac{m_1 - m_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$  | $(-\infty, -v.c.] \cup [v.c., +\infty)$ |
|  | $n_1, n_2 \geq$<br>ou $< 30$  | Normale distribuées, Variances dans la population <b>inconnues</b> égales   | Différence des moyennes | Test t ( Student) $n_1 + n_2 - 2$ d.d.l.     | $t = \frac{m_1 - m_2}{\sqrt{\frac{s^2}{n_1} + \frac{s^2}{n_2}}}$<br>$s^2 = \frac{(n_1 - 1) \times S_1^2 + (n_2 - 1) \times S_2^2}{n_1 + n_2 - 2}$ | $(-\infty, -v.c.] \cup [v.c., +\infty)$ |
| <b>Deux échantillons dépendants (appariés)</b>   |                               |   |                         |  |   |   |
| Quantitative   | $n_1 = n_2 \geq$<br>ou $< 30$ | Normale distribuées,  | Moyenne des différences | Test t ( Student) $n - 1$ d.d.l.             | $t = \frac{d}{\frac{S}{\sqrt{n}}}$  | $(-\infty, -v.c.] \cup [v.c., +\infty)$ |

(ou  $n, n_1, n_2$  - nombre des sujets;  $m, m_1, m_2$  - moyennes;  $s, s_1, s_2$  - déviations standard descriptive de l'échantillon;  $S, S_1, S_2$  - déviation standard d'échantillonnage;  
 $S = \sqrt{\frac{\sum s_i^2}{n}}$ ;  $s = \sqrt{\frac{\sum (s_i - \bar{s})^2}{n-1}}$ ;  $\sigma, \sigma_1, \sigma_2$  - déviation standard dans la population; pour  $\alpha=0,05, Z_{\alpha/2}=1,96$ ; d.d.l. - degrés de liberté; v.c. - valeur critique)

## Récapitulatif des tests utilisés

### Tests statistiques pour comparer deux échantillons, variables quantitatives non normale distribuées

| Tests statistiques pour comparer deux échantillons indépendants |                                 |  |   |   |  |
|---|---------------------------------|--|---|---|--|
| Type variable   | Nature des données              | Statistique comparée   | Test utilisé  | Paramètre du test   | Région du rejet                                  |
| Quantitative ou qualitative ordinale                            | Données non normale distribuées | -médiane (si les distributions sont similaires) - la distribution des rangs /moyenne des rangs | Test Mann Whitney U   | obsSR <sub>a</sub> somme rangs group a, obsSR <sub>b</sub> somme rangs group b, $U_a = n_1 \times n_2 \times \frac{(n_1+1)}{2}$ obsSR <sub>a</sub> , $U_b = n_1 \times n_2 \times \frac{(n_2+1)}{2}$ obsSR <sub>b</sub> | Min (U <sub>a</sub> , U <sub>b</sub> )<br>≤ v.c. |
|   |                                 |  | Etapes:<br>Tableaux avec toutes les valeurs des deux échantillons<br>Ordonnées en ascendant<br>Numéroter du plus petit a le plus grand<br>Donner un rang. (Valeurs identiques, le rang = moyenne de la numérotation)<br>Calculez la somme des rangs pour group A et B |   |  |
| Tests statistiques pour deux échantillons dépendants/ appariés  |                                 |  |   |   |  |
| Quantitative ou qualitative ordinale                            | Données non normale distribuées | -médiane (si les distributions sont similaires) - la distribution des rangs                    | Test Wilcoxon pour échantillons appariés  | W <sub>-</sub> somme rangs négatifs<br>W <sub>+</sub> somme rangs positifs  | Min (W <sub>-</sub> , W <sub>+</sub> )<br>≤ v.c. |

## Récapitulatif des tests utilisés

| Tests statistiques pour deux échantillons <u>indépendants</u> , variables qualitatives dichotomiques |  |                    |                      |   |   |   |
|--|--|--------------------|----------------------|---|---|---|
| Type variable  | Nb sujets  | Nature des données | Statistique comparée | Test utilisé  | Paramètre du test   | Région du rejet   |
| Qualitative dichotomique   | $n_1 p_1 > 10$ ,<br>$n_2 p_2 > 10$ ,<br>$n_1(1-p_1) > 10$ ,<br>$n_2(1-p_2) > 10$ |                    | fréquences           | Test Z *<br>Equivalent au test Chi carrée ci dessous (Chi carrée est recommandé): | $z = \frac{p_1 - p_2}{\sqrt{p(1-p) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}$<br>$p = \frac{p_1 n_1 + p_2 n_2}{n_1 + n_2}$ | $(-\infty, -Z_{\alpha/2}] \cup [Z_{\alpha/2}, +\infty)$ |
|  | <20% cellules du tableau théorique sont <5                                       |                    | fréquences           | Test Chi carrée *<br>$v = (L-1) * (C-1) = 1$ d.d.l.                               | $\chi^2 = \sum_{i=1}^L \frac{(f_i^o - f_i^t)^2}{f_i^t}$   | $[\chi_{v, \alpha}^2, +\infty)$                         |
|  | >20% cellules du tableau théorique sont <5                                       |                    | fréquences           | Test exact Fisher   | - (test non paramétrique)   | -   |
| Tests statistiques pour deux échantillons <u>dépendants</u> , variables qualitatives dichotomiques   |  |                    |                      |   |   |   |
| Qualitative dichotomique   | $b+c > 25$   |                    | fréquences           | Test Chi carrée<br>$v=1$ d.d.l.   | $\chi_{1, ad}^2 = \frac{(b-c - 0,5)^2}{b+c}$  | $[\chi_{v, \alpha}^2, +\infty)$                         |

\* On préfère pour ce cours (et l'examen) le test Chi carrée pour comparer les fréquences, au lieu du test Z pour comparer les fréquences

$p_1, p_2$  – fréquences;  $n_1, n_2$  – nombre des sujets; L et C – nombres des lignes et des colonnes dans le tableau de contingence,  $f^o$  – fréquence observée,  $f^t$  – fréquence théorique; d.d.l. – degrés de liberté;

Pour l'examen écrit je ne demande pas les choses en gris

## Récapitulatif des tests utilisés

| Tests statistiques pour plus des deux échantillons (groups) indépendants |  |  |                      |   |   |                                   |
|--|--|--|----------------------|---|---|-----------------------------------|
| Type variable  | Nb sujets                                  | Nature des données                                     | Statistique comparée | Test utilisé  | Paramètre du test                                       | Région du rejet                   |
| Qualitative  | <20% cellules du tableau théorique sont <5 |  | Fréquence            | Test Chi carrée<br>$v = (L-1) * (C-1)$ d.d.l.   | $\chi^2 = \sum_{i=1}^L \frac{(f_i^o - f_i^t)^2}{f_i^t}$ | $[\chi_{v, \alpha}^2, +\infty)$   |
|  | >20% cellules du tableau théorique sont <5 |  | fréquence            | Test exact Fisher   | -   | -                                 |
| Quantitative   |  | Normale distribuées, Variance des échantillons égaux   | moyenne              | Test ANOVA<br>$v1 = \text{nb. groups} - 1$<br>$v2 = \text{nb. obs.} - \text{nb groups}$ | $F = \frac{MCG}{MCE}$                                   | $[F_{v_1, v_2, \alpha}, +\infty)$ |
|  |  | Normale distribuées, Variance des échantillons inégaux | moyenne              | ANOVA de Welch ou Brown Forsyth   |   |                                   |
|  |  | Non normale distribuées                                | médiane              | test Kruskal Wallis   | -   | -                                 |

L et C – nombres des lignes et des colonnes dans le tableau de contingence,  $f^o$  – fréquence observée,  $f^t$  – fréquence théorique; d.d.l. – degrés de liberté;

$MCEG = [n1 * (m1-mt)^2 + n2 * (m2-mt)^2 + n3 * (m3-mt)^2 + ...] / (p-1)$   
 $MCDG = [(n1-1) * DS1^2 + (n2-1) * DS2^2 + (n3-1) * DS3^2 + ...] / (n-p)$

n – nombre total d'observations,  $n1, n2, n3$  – le nombre d'observations par group, p – nombre des groups  
mt – la moyenne des toutes les observations,  $m1, m2, m3, ...$  les moyennes par groups,  $DS1, DS2, DS3, ...$  déviations standard d'échantillonnage des groups

## Récapitulatif des tests utilisés

| Tests statistiques pour comparer les variances entre deux échantillons   |           |                             |                      |   |  |                                   |
|--|-----------|-----------------------------|----------------------|---|--|-----------------------------------|
| Type variable  | Nb sujets | Nature des données          | Statistique comparée | Test utilisé  | Paramètre du test  | Région du rejet                   |
| Quantitative   |           | Données normale distribuées | variances            | Test F,<br>$v_1 = n_1$ d.d.l.<br>$v_2 = n_2$ d.d.l. | $F = \begin{cases} \frac{S_2^2}{S_1^2} \text{ pour } S_2^2 > S_1^2 \\ \frac{S_1^2}{S_2^2} \text{ pour } S_1^2 > S_2^2 \end{cases}$ | $[F_{v_1, v_2, \alpha}, +\infty)$ |
| Tests statistiques pour comparer les variances entre > deux échantillons |           |                             |                      |   |  |                                   |
| Quantitative   |           |                             | variances            | Test Bartlet ou Test Levene                         |  |                                   |

(ou  $n_1, n_2$  - nombre des sujets;  $m_1, m_2$  - moyennes;  $s_1, s_2$  - déviations standard descriptive de l'échantillon;  $S_1, S_2$  - déviation standard d'échantillonnage;  
 $S = \frac{n}{\sqrt{n-1}} s$ ;  $s = \sqrt{\frac{n-1}{n}} S$ ; d.d.l. - degrés de liberté)

13

## Equivalences entre tests paramétriques et non paramétriques

| Données   | Nombre échantillons      | Tests paramétriques  | Tests non paramétriques  |
|---|--------------------------|--|--|
| qualitatives                                    |                          | Chi deux   | exact Fisher   |
| Quantitatives<br>(ou qualitatives<br>ordinales) | 2 indépendants           | Student (t) pour échantillons indépendants   | Mann Whitney U (Wilcoxon somme des rangs<br>Mann Whitney Wilcoxon) |
|   | 2 appariées (dépendants) | Student (t) pour échantillons appariées  | Wilcoxon rangs signées (Wilcoxon pour échantillons appariées)      |
|   | > 2 indépendants         | ANOVA (pour variances égales) ou ANOVA de Welch ou Brown Forsyth (pour variances inégales) | Kruskal Wallis   |
|   |                          | Pour données normale distribuées   | Pour données non normale distribuées                               |

14

### Intervalle de confiance

| Type variable | Nombre échantillons | Estimateur ponctuel                          | Conditions application  | Formule  |
|---------------|---------------------|--|---|--|
| qualitative   | une                 | fréquence: f                                 | grands échantillons: $nf \geq 10$ et $nq \geq 10$   | $\left( f - Z_{\frac{1-\alpha}{2}} ES; f + Z_{\frac{1-\alpha}{2}} ES \right)$ $ES = \sqrt{\frac{f(1-f)}{n}}$   |
|               | une                 | fréquence: f                                 | petits échantillons: $nf < 10$ ou $nq < 10$   | on ne va pas calculée  |
|               | deux                | différence entre les fréquences: $f_1 - f_2$ | grands échantillons: $f_1 n_1 \geq 10, (1-f_1)n_1 \geq 10, f_2 n_2 \geq 10, (1-f_2)n_2 \geq 10$ | $ES = \sqrt{\frac{f_1 \times (1-f_1)}{n_1} + \frac{f_2 \times (1-f_2)}{n_2}}$<br>$\left( (f_1 - f_2) - Z_{\frac{1-\alpha}{2}} ES; (f_1 - f_2) + Z_{\frac{1-\alpha}{2}} ES \right)$                             |
|               | deux                | différence entre les fréquences:             | petits échantillons: $np < 10$ ou $nq < 10$   | on va pas calculée   |
| quantitative  | un                  | moyenne: m                                   | grands échantillons: $n \geq 30, \sigma$ - connue   | $\left[ m - Z_{\frac{1-\alpha}{2}} ES; m + Z_{\frac{1-\alpha}{2}} ES \right]$ $ES = \frac{\sigma}{\sqrt{n}}$   |
|               | un                  | moyenne: m                                   | grands échantillons: $n \geq 30, \sigma$ - non connue   | $\left[ m - t_{n-1, \frac{1-\alpha}{2}} ES; m + t_{n-1, \frac{1-\alpha}{2}} ES \right]$ $ES = \frac{S}{\sqrt{n}}$  |
|               | un                  | moyenne: m                                   | petits échantillons: $n < 30, \sigma$ - non connue  | $\left[ m - t_{n-1, \frac{1-\alpha}{2}} ES; m + t_{n-1, \frac{1-\alpha}{2}} ES \right]$ $ES = \frac{S}{\sqrt{n}}$  |
|               | deux                | différence entre les moyennes: $m_1 - m_2$   | variances égales  | $ES = \sqrt{\frac{(n_1 - 1) \times s_1^2 + (n_2 - 1) \times s_2^2}{n_1 + n_2 - 2}}$<br>$\left( (m_1 - m_2) - t_{n_1+n_2-2, \frac{1-\alpha}{2}} ES; (m_1 - m_2) + t_{n_1+n_2-2, \frac{1-\alpha}{2}} ES \right)$ |


15 (ou  $n, n_1, n_2$  - nombre des sujets;  $f, f_1, f_2$  - fréquence observée;  $q = 1 - f, m, m_1, m_2$  - moyennes;  $s, s_1, s_2$  - déviations standard descriptive de l'échantillon;  $S$  - déviation standard d'échantillonnage;  $S = \sqrt{\frac{\sum (x_i - m)^2}{n-1}}$ ;  $s = \sqrt{\frac{\sum (x_i - m)^2}{n}}$ ;  $\sigma$  - déviation standard dans la population; ES=erreur standard; pour  $\alpha=0.05, Z_{\alpha/2}=1.96$ )

### Evaluation graphique : diagramme de dispersion (nuage des points/scatter)


**Evaluer la linearite**, et l'importance de la corrélation:

Si les points semble suggérer un droite - la relation est peut être linéaire

Si les points semble suggérer des tendances qui ne sont pas linéaires, la relation est peut être non linéaire (exponentielle, quadratique)



Si la relation est plus probable linéaire, on peut évaluer d'une manière subjective la corrélation linéaire. Plus les points se rapprochent à un droite de tendance, plus la corrélation est forte, plus les points sont distants, plus la corrélation est faible






### Evaluation graphique : diagramme de dispersion

#### (nuage des points/scatter)

But : évaluation visuelle de la relation entre deux variables quantitatives

L'utilisation des cadrans pour identifier **la tendance/sens/direction** directe/inversement proportionnelle :

- i) presque toutes les points sont dans les cadrans I et III  $\Rightarrow$  tendance croissante/ pente ascendante/ pente positive/ lien (direct) proportionnel
- ii) presque toutes les points sont dans les cadrans II et IV  $\Rightarrow$  tendance décroissante / pente descendante/ pente négative/ lien inversement proportionnelle
- iii) les points sont distribués uniformément dans tous les cadrans  $\Rightarrow$  aucune tendance



17

### Corrélations

| Type des variables    | Nature des données      | Coefficient de corrélation | Formule du coefficient  |
|-----------------------|-------------------------|----------------------------|---|
| quantitative          | normale distribuées     | Pearson (r)                | $COV(X,Y) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$ $r = \frac{COV(X,Y)}{S_X \cdot S_Y}$ |
| quantitative          | non normale distribuées | Spearman ( $\rho$ - rho)   | $\rho = r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}, \text{ ou } d_i = R_{x_i} - R_{y_i}$             |
| qualitative ordinales | -                       | Spearman ( $\rho$ - rho)   | $\rho = r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}, \text{ ou } d_i = R_{x_i} - R_{y_i}$             |

$X_i, Y_i$  – sont les valeurs des deux séries des données.  $\bar{X}$  et  $\bar{Y}$  sont les moyennes des deux séries.  $R_{x_i}$  et  $R_{y_i}$  sont les rangs des valeurs  $X_i$  et  $Y_i$  après leurs rangement dans ordre croissante.  $n$  – nombre des observations.  $S_x$  et  $S_y$  sont les déviations standard d'échantillonnage.  $COV(X,Y)$  – la covariance

18

### Covariance $COV(X,Y)$ : **Corrélation linéaire Pearson - interprétations**

- $> 0$  tendance croissante/ pente ascendante/ lien direct proportionnel/ covariance positive
- $< 0$  tendance décroissante/ pente descendante/ lien inversement proportionnel/ covariance négative
- $\cong 0 \Rightarrow$  aucune tendance

**r** (coefficient de corrélation Pearson):

montre la direction et l'intensité de la corrélation;

Interprétation du direction/sens/tendance:

- $> 0$  tendance croissante/ pente ascendante/ lien direct proportionnel/ corrélation positive
- $< 0$  tendance décroissante/ pente descendante/ lien inversement proportionnel/ corrélation négative
- $\cong 0 \Rightarrow$  aucune tendance
- plus **r** ou  $COV(X,Y)$  est grand (en valeur absolue) plus la relation est forte
- plus **r** ou  $COV(X,Y)$  est proche de 0, plus la relation est faible

### Le coefficient Pearson - interprétation

**Interprétation de l'intensité/force/degré/importance de la corrélation linéaire avec les règles empiriques de Colton** [Colton T. *Statistics in Medicine*. Little Brown and Company, New York, NY 1974] (**on préfère le mot corrélation ici, même si association/lien/relation peut être utilisé**)

(-0.25 et 0,25)

=> une relation **négligeable** ou **aucune** corrélation linéaire entre les variables

[0.25 et 0.50) ou [-0.25 et -0.50)

=> un degré de corrélation **faible/acceptable**

[0.50 et 0.75) ou [-0.50 et -0.75)

=> un degré de corrélation **modérée à bonne**

[0.75 et 1] ou [-0.75 et -1]

=> une **très bonne à excellente** corrélation

Il y a autre divisions possibles aussi.

Ces règles doit être utilisée avec soins. Elle sont pour donner une idée, mais pour chaque problème, l'intensité de la relation est relative au domaine. Pour certain situations les valeurs en dessous de 0,8 peut être faibles.

### Régression linéaire simple

- **Interprétation**

- La droite de régression  $Y(X)$ :  $Y = b_0 + b_1 X$

$b_0$  = est l'ordonnée à l'origine – la valeur du  $Y$  quand  $X$  est égal à 0  
(d'habitude cette information n'est pas utile pour les médecins, elle présente une situation qui en réalité est impossible)

$b_1$  = la pente de la droite de régression.

**Interprétation de  $b_1$  - du coefficient de la variable  $X$**

**chaque unité de mesure de la variable indépendante -  $X$  en plus augmente en moyenne la variable dépendante -  $Y$  avec la valeur du coefficient de la variable indépendante  $X$  -  $b_1$**

### Régression linéaire multiple - Quantification de l'importance de la relation pour plusieurs variables

- L'équation du **régression linéaire multiple**:
- Variable dépendante = coefficient\_1 \* variable\_1 + coefficient\_2 \* variable\_2 + ... + coefficient\_n \* variable\_n + coefficient\_0
- Ex: triglycérides (mg/dL) = 23,10 \* obésité (oui/non) + 1,14 \* cholestérol (mg/dL)
- **L'interprétation du coefficient ajusté (adjusted – en anglais)** pour des variables **Qualitatives dichotomiques** (ex. obésité):
  - l'augmentation de la variable dépendante – les triglycérides en moyenne (ici il est de 23,1 mg/dL) pour ceux qui ont le facteur présent (être obèse - la variable indépendante) comparée à ceux qui n'ont pas le facteur (ne sont pas obèses), si on tient les autres variables constantes / si on ajuste les autres variables / si on contrôle les autres variables) (ici – le cholestérol)
  - ceux qui ont le facteur présent (être obèse - la variable indépendante) ont la variable dépendante – les triglycérides en moyenne plus grand avec 23,1 mg/dL comparée à ceux qui n'ont pas le facteur (ne sont pas obèses), si on tient les autres variables constantes / si on ajuste les autres variables / si on contrôle les autres variables) (ici – le cholestérol)

## Variables aléatoires discrètes

### Esperance, variance et écart type

- **Esperance mathématique** ou la moyenne théorique d'une v.a. X

$$E(X) = \sum_{i=1}^n x_i \Pr(X = x_i)$$

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

**Exemple:** avec le traitement

- X: 0 1 2 3 4

Pr 0,008 0,076 0,256 0,411 0,24

$$E(X) = 0 \times 0,008 + 1 \times 0,076 + 2 \times 0,265 + 3 \times 0,411 + 4 \times 0,24 = 1,31$$

- **Variance** de X:

$$V(X) = \sum_{i=1}^n [x_i - E(X)]^2 * \Pr(x_i) \quad \sim \quad \sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{n}$$

- **Ecart-type** (deviation standard) de X

$$\sigma(X) = \sqrt{V(X)} = V(X)^{1/2}$$

23

## Tableau récapitulatif

| Événements                                   | Définitions  | Notations              | Calcul des probabilités  |
|--|--|------------------------|--|
| Événement contraire d'un événement A         | l'événement constitué par tous les événements élémentaires qui ne sont pas dans A.   | $\bar{A}$              | Propriété :<br>$\Pr(\bar{A}) = 1 - \Pr(A)$                       |
| Événement "A et B" ou intersection de A et B | l'événement "A et B" est constitué par tous les événements élémentaires se trouvant à la fois dans A et dans B.              | $A \cap B$             |  |
| Événement "A ou B" ou réunion de A et B      | l'événement "A ou B" est constitué par tous les événements élémentaires se trouvant dans l'un au moins des événements A ou B | $A \cup B$             | Propriété :<br>$\Pr(A \cup B) = \Pr(A) + \Pr(B) - \Pr(A \cap B)$ |
| Événements incompatibles                     | ils ne peuvent pas être réalisés simultanément.  | $A \cap B = \emptyset$ | $\Pr(A \cap B) = 0$  |
| Événements indépendants                      | Deux événements sont indépendants si la survenance d'un événement n'affecte pas l'apparition d'un deuxième événement.        |                        | $\Pr(A \cap B) = \Pr(A) \times \Pr(B)$                           |

24

## Probabilité conditionnelle

- A et B évènements,  $P(A) \neq 0$ .
- Notation:  $\Pr(B | A)$  : probabilité conditionnelle de B, sachant que l'évènement A est réalisé
- Formule de calcul:  $\Pr(B | A) = \Pr(A \cap B) / \Pr(A)$

Ex.

1) la probabilité d'avoir un cancer colorectal sachant que le test Hémocult est positif, est une probabilité conditionnelle:

$\Pr(\text{cancer colorectal} | \text{test Hémocult Positif})$

2) la probabilité d'avoir un cancer oral sachant que le test de bleuissement avec toluidine est positif

$\Pr(\text{cancer oral} | \text{bleuissement avec toluidine Positif})$

3) la probabilité d'un homme d'avoir

$\text{PAS} > 140 \text{ mmHg}: \Pr(\text{PAS} > 140 | \text{Homme})$



Rajeevan M, Rao UK, Joshua E, Rajasekhar ST, Kumar R. Assessment of oral mucosa in normal, precancer and cancer using chemiluminescent illumination, toluidine blue supravital staining and oral exfoliative cytology. J Oral Maxillofac Pathol. 2012;64(1):125-9. <http://dx.doi.org/10.4103/0975-2875.105870>.

## Probabilité conditionnelle et l'indépendance

- A, B évènements **indépendantes**:

$$\Pr(B | A) = \Pr(B) = \Pr(B | \text{non } A)$$

- A et B évènements **dépendantes**:

$$\Pr(B | A) \neq \Pr(B) \neq \Pr(B | \text{non } A)$$

$$\Pr(A \cap B) \neq \Pr(A) \times \Pr(B)$$

### Probabilité conditionnelle - applications

Ex.: enquête des possibles facteurs de risque du cancer de poumon  
 Dans un échantillon de 2000 sujets, on a 1000 fumeurs parmi lesquelles 130 sujets souffrent de cancer du poumon et 1000 non fumeurs parmi lesquelles 10 sujets souffrent de cancer du poumon

**Le risque relatif d'avoir le cancer de poumon = ?**

**Solution:** on considère les événements

$A = \{\text{sujet fumeur}\}$  et  $B = \{\text{sujet atteints de cancer du poumon}\}$

$$\Pr(B | A) = 130/1000 = 0,130 \quad \Pr(B | \bar{A}) = 10/1000 = 0,010$$

$$RR = \frac{\Pr(B | A)}{\Pr(B | \bar{A})} = \frac{0,130}{0,010} = 13$$

=>un sujet qui est fumeur a un risque d'avoir le cancer du poumon de 13 fois plus grand qu'un sujet qui n'est pas fumeur

### Probabilité conditionnelle - applications

|       | M+  | M-  | Total |
|-------|-----|-----|-------|
| T+    | a   | b   | a+b   |
| T-    | c   | d   | c+d   |
| Total | a+c | b+d | n     |

$$Se = \Pr(T^+ | M^+) = a / (a + c)$$

$$Sp = \Pr(T^- | M^-) = d / (b + d)$$

$$VPP = \Pr(M^+ | T^+) = a / (a + b)$$

$$VPN = \Pr(M^- | T^-) = d / (c + d)$$


## Le choix du type du graphique en fonction des types des variables et but

- Pour faire la **choix**, comptez **combien des variables** sont et quel **est le type**.

- **Description d'une seule variable**


- **Qualitative**

- camembert (sectoriel – **Pie**)
- **Column** (si les noms des catégories ne sont pas très longues)
- **Bar** (si les noms des catégories sont très longues)



- **Quantitative**

- **Histogramme**, graphique des moyennes, **box and whiskers** (boite à moustaches), graphique des quantiles




## Le choix du type du graphique en fonction des types des variables et but

- **La relation entre deux variables**


- **Qualitative**

- **Column** (Clustered Column/ Stacked Column/ 100% Stacked column), ou **Bar** (Clustered Bar / Stacked Bar / 100% Stacked Bar )



- **Quantitative**

- **Scatter** (nouage des points)




## Le choix du type du graphique en fonction des types des variables et but

- **La relation entre deux variables**

- *Une variable quantitative en fonction d'une variable qualitative*


- **Si les données sont normale distribuées**

- Graphique des moyennes (avec deviation standard)
      - Graphique Colonnes avec barre d' erreur



- **Si les données sont normale distribuées**


- Graphique box plot ou whiskers/boite a moustaches (boite a moustaches)



## Le choix du type du graphique en fonction des types des variables et but

- **L'évolution dans le temps d'une variable qualitative ou quantitative**

- **Line (Ligne)**



- **La relation entre trois variables quantitatives**

- **Bubble** (nouage des sphères)
  - Nouage des points tridimensionnel

- **Une variable qualitative en fonction des intervalles d'une variable quantitative**

- **Area** (Surface)

## Mesures de symétrie: (skewness)

### Coefficient d'asymétrie ( $\alpha_3$ ):

degré d'asymétrie d'une distribution

la direction de cette asymétrie (positive ou négative);

$\alpha_3 \approx 0 \Rightarrow$  une distribution symétrique.


$\alpha_3 > 0 \Rightarrow$  distribution est plus allongée vers la droite – asymétrie positive

$\alpha_3 < 0 \Rightarrow$  distribution est plus allongée vers la gauche – asymétrie négative

$\alpha_3$  (-0,5 – 0,5) approximative symétrique

$\alpha_3$  (-1 – -0,5) ou (0,5 – 1) modérée asymétrique

$\alpha_3 < -1$  ou  $> 1$  asymétrie importante




## Le coefficient d'aplatissement (Kurtosis)

### Le coefficient d'aplatissement ( $\alpha_4$ ):

l'angle de la courbe du milieu d'une distribution

par rapport à une distribution normale (gaussienne)

- $\alpha_4 \approx 0 \Rightarrow$  l'angle normal  $\Rightarrow$  distribution mesokurtique
- $\alpha_4 > 0 \Rightarrow$  l'angle aigu  $\Rightarrow$  distribution leptokurtique - centre élevée
- $\alpha_4 < 0 \Rightarrow$  la pente aplati  $\Rightarrow$  distribution platykurtique – centre plus bas



## Statistique descriptive

### Mesures de tendance centrale:

- ✓ Moyenne
- ✓ Médiane
- ✓ Mode

### Mesures de dispersion:

- ✓ Amplitude (entendue)
- ✓ **Intervalle interquartile**
- ✓ moyenne des écarts de la moyenne
- ✓ moyenne des écarts de la médiane
- ✓ Variance
- ✓ **Déviatiion standard (écart-type)**
- ✓ Coefficient de variation
- ✓ Erreur standard

### Mesures de symétrie/aplatissement:

- ✓ Coefficient **d'asymétrie** (skewness)
- ✓ Coefficient **d'aplatissement** (Kurtosis)

### Mesures de position:

- ✓ **Quartiles**
- ✓ Déciles
- ✓ Percentiles

Bon success!!!