
CHAPITRE XI

RÉCAPITULATION DES PRINCIPAUX RÉSUMÉS SYNOPTIQUES

Résumé du chapitre I (Statistique descriptive)	498
Résumé du chapitre II (Introduction aux probabilités).....	500
Résumé du chapitre III (Principales distributions théoriques)	502
Résumé du chapitre IV (Induction statistique sur moyenne et fréquence).....	504
Résumé du chapitre V (Introduction aux tests d'hypothèse)	506
Résumé du chapitre VI (L'ajustement linéaire).....	508
Résumé du chapitre VII (Comparaisons d'échantillons).....	510
Résumé du chapitre IV (Induction statistique - cas de la variance)	512



Index

Table des Matières

Statistique appliquée à la gestion

Dans l'étude d'un ensemble de n éléments, chaque élément est caractérisé par...

plusieurs caractères ou 1 seul caractère

qualitatif

un caractère peut être ou...

quantitatif

- = chaque élément possède ou non une qualité donnée;
- les différentes qualités envisagées sont appelées **modalités** (en nombre r).

- = à chaque élément j est associée une **mesure** x_j .
- La variable X désigne l'ensemble des valeurs prises par ce **caractère quantitatif**.
- Si à plusieurs éléments j (en nombre n_j) est associée la même mesure x_j , l'ensemble des couples (x_j, n_j) définit la distribution statistique de la variable X.
- La variable X peut être
 - **continue** (= susceptible de varier de façon continue)
 - ou **discrète** (= variant par «saut»).
 Les éléments peuvent être groupés en classes de valeurs (en nombre r).

- On définit autant de **partitions** que de caractères.
- Les **tableaux de contingence** sont les tableaux de distribution utilisés pour décrire un ensemble analysé à travers plusieurs caractères.

- Le tableau qui donne la liste des n éléments avec leurs modalités (pour les caractères qualitatifs) et leurs valeurs de X (pour les caractères quantitatifs) est un **tableau de données ponctuelles**.
- Le tableau qui donne:
 - soit les couples (x_j, n_j) pour les variables quantitatives,
 - les couples (i, n_j) pour les variables qualitatives,
 s'appelle un **tableau de distribution** et décrit la partition de l'ensemble selon le caractère étudié.

Observations faites à des dates différentes (ou sur des groupes différents)

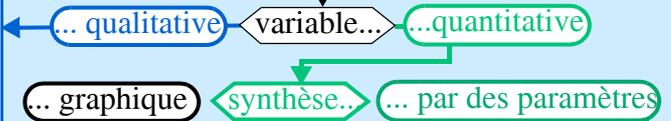
- **indice élémentaire**: $I(X)_{t_1/t_0} = \frac{x_{t_1}}{x_{t_0}} \times 100$
- **indice synthétique** pour résumer un ensemble d'indices élémentaires

		Indice	
		des prix	des quantités
Indice de Paasche de Laspeyres	L(p) _{t₁/t₀}	$\frac{\sum_{i=1}^n p_{i,t_1} q_{i,t_0}}{\sum_{j=1}^n p_{j,t_0} q_{j,t_0}}$	$\frac{\sum_{i=1}^n p_{i,t_0} q_{i,t_1}}{\sum_{j=1}^n p_{j,t_0} q_{j,t_0}}$
		$\frac{\sum_{i=1}^n p_{i,t_1} q_{i,t_1}}{\sum_{j=1}^n p_{j,t_0} q_{j,t_1}}$	$\frac{\sum_{i=1}^n p_{i,t_1} q_{i,t_1}}{\sum_{j=1}^n p_{j,t_1} q_{j,t_0}}$



Problème : synthétiser les informations relatives à un ensemble d'éléments examinés dans l'optique de

- Synthèse numérique: fréquences n_i/n
- Synthèse par l'image:
 - Diagramme à secteurs (rect. ou circ.)
 - Diagramme à barres
 - Courbe de Pareto



Variable discrète

Diagramme en bâtons

Courbe des fréquences cumulées

Graphique «boîtes à moustaches»

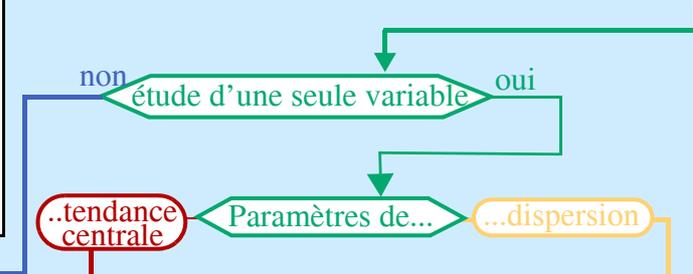
Courbe de Pareto

variable continue

Histogramme

Courbe de densité de probabilité

Fonction de répartition



- **Moyenne**:
 - $\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j$ (tableau de données ponctuelles)
 - $\bar{x} = \frac{1}{n} \sum_{i=1}^r n_i x_i = \sum_{i=1}^r f_i x_i$ (tableau de distribution)
 - $\bar{x} = \frac{1}{n} \sum_{i=1}^p n_i \cdot x_i$ (tableau de contingence)
- **Médiane**: M_e = valeur de X telle qu'il y ait autant d'observations ayant une valeur inférieure (ou égale) à M_e que d'observations ayant une valeur supérieure à M_e : $F(X \leq M_e) = 0,5$.
- **Quartile**: Q_1 tel que $F(X \leq Q_1) = 0,25$; Q_3 tel que $F(X \leq Q_3) = 0,75$; $Q_2 = M_e$
- **Mode**: M_0 = valeur de X dont la fréquence observée est maximale.

• **Variance**: $V(X)$ ou σ^2 :

		Tableau de	
		données ponctuelles	distribution
relation de	définition	$\frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2$	$\frac{1}{n} \sum_{i=1}^r n_i (x_i - \bar{x})^2$ $= \sum_{i=1}^r f_i (x_i - \bar{x})^2$
	calcul	$\frac{1}{n} \sum_{j=1}^n x_j^2 - \bar{x}^2$	$\frac{1}{n} \sum_{i=1}^r n_i x_i^2 - \bar{x}^2$ $= \sum_{i=1}^r f_i x_i^2 - \bar{x}^2$

- **Écart-type** $\sigma = \sqrt{\sigma^2}$
- **Coefficient de variation**: σ / \bar{x}
- **Intervalle interquartile**: $Q_3 - Q_1$

- Calcul de la **covariance** entre X et Y :
 - $COV(X, Y) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \cdot \bar{y}$ (tableau de données ponctuelles)
 - $COV(X, Y) = \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^q n_{ij} x_i y_j - \bar{x} \cdot \bar{y}$ (tableau de contingence)
- $Z = aX + bY \Rightarrow \begin{cases} \bar{z} = a\bar{x} + b\bar{y} \\ V(Z) = a^2 V(X) + b^2 V(Y) + 2ab COV(X, Y) \end{cases}$



Index

Table des Matières

Statistique appliquée à la gestion

Une **épreuve** est une expérience ou un processus dont le résultat est incertain. Une épreuve peut être.

... unique ou

Soit un ensemble physique de n éléments sur lequel sont définies 1 ou plusieurs **partitions** correspondant à des caractères qualitatifs ou quantitatifs (variable discrète, et classes de valeurs en cas de variable continue). Cet ensemble peut être décrit par un tableau de contingence (si 2 partitions ou plus).

Définition de l'**épreuve**: tirer au hasard un élément de l'ensemble.
Résultat de l'épreuve: constitué par l'ensemble des caractéristiques physiques observables sur l'élément tiré.

La **probabilité** $P(E)$ de l'événement E se définit correctement en cas de tirage aléatoire dans l'ensemble (\Rightarrow équiprobabilité de tirage de tous les éléments) comme:

$$P(E) = \frac{\text{Nombre de cas favorables}}{\text{Nombre de cas possibles}}$$

- Au vu du résultat de l'épreuve, on dit que l'**événement** E se produit ou non.
- E est défini par la réalisation d'un événement élémentaire ou par la « combinaison » de plusieurs événements élémentaires E_j .
- Les événements élémentaires correspondent à la réalisation de l'une des modalités de l'un des caractères retenus.
- Les « combinaisons » d'événements s'effectuent à partir des relations « **et** » et « **ou** »: $E = E_1 \text{ et } E_2$; $E = E_1 \text{ ou } E_2$ (E_1 et E_2 sont des modalités de caractères différents, pour que E ne soit pas impossible).
- On définit également $E = E_1/E_2$ comme la réalisation de l'événement E_1 , sachant que l'événement E_2 est déjà réalisé.

THÉORÈMES DE PROBABILITÉ

non exclusifs E_1 et E_2 sont exclusifs

Définition de l'**exclusivité** (ou incompatibilité) de E_1 et E_2 :
 $P(E_1 \text{ et } E_2) = 0$

$P(E_1 \text{ ou } E_2) = P(E_1) + P(E_2) - P(E_1 \text{ et } E_2)$
 (Théorème des **probabilités totales**)

dépendants E_1 et E_2 sont indépendants

Définition de l'**indépendance** entre E_1 et E_2 :
 $P(E_2/E_1) = P(E_2)$ ou $P(E_1/E_2) = P(E_1)$

$P(E_1 \text{ et } E_2) = P(E_1) \cdot P(E_2/E_1) = P(E_2) \cdot P(E_1/E_2)$
 (Théorème des **probabilités composées**)

$P(E_1/E_2) = P(E_1 \text{ et } E_2) / P(E_2)$
 $P(E_2/E_1) = P(E_1 \text{ et } E_2) / P(E_1)$

E_i et E_j (ou E_k) étant des modalités de 2 caractères

$$\neq: P(E_i/E_j) = \frac{P(E_j/E_i) \cdot P(E_i)}{\sum_{k=1}^r P(E_j/E_k) \cdot P(E_k)}$$

Théorème de Bayes

- Si E est l'événement $X = x_i$, et p_i sa probabilité de réalisation, l'ensemble des couples (x_i, p_i) définit la variable aléatoire X .
- Cette distribution des valeurs de X est résumable par des paramètres, les probabilités jouant le même rôle que les fréquences; la moyenne est appelée **espérance mathématique** et est notée $E(X)$.
- S'il existe une formule mathématique permettant de calculer p_i à partir de x_i , on parle de **modèle statistique**.

Les variables aléatoires X et Y sont indépendantes si les événements $X = x_i$ et $Y = y_j$ sont indépendants quels que soient i et j ; leur covariance $COV(X, Y)$ est alors nulle.



... constituée de plusieurs épreuves élémentaires

Ensemble physique n'existant pas; 3 causes:

- non-matérialité des éléments de l'ensemble: matérialisation par liste des résultats possibles (faire très attention à leur équiprobabilité et se ramener au cas de l'ensemble physique),
- référence au passé: $P(E) =$ fréquence observée sur le passé,
- probabilité subjective définie a priori comme la «chance» que l'on donne à la réalisation de E.

- À chaque **épreuve élémentaire**, on associe un ensemble d'événements élémentaires exclusifs. On définit donc une partition par épreuve élémentaire.
- L'**événement** est défini à partir d'une «combinaison» d'événements élémentaires (comme dans le cas d'une épreuve unique). Sa probabilité se calcule à partir des théorèmes de probabilités et des résultats à des problèmes de dénombrement.

Problèmes de dénombrement

- nombre P_n de **permutations** (nombre de *mots* différents de k lettres différentes, à partir d'un alphabet de $n = k$ lettres différentes): $P_n = k!$
- nombre A_n^k d'**arrangements** (nombre de *mots* différents de k lettres différentes, à partir d'un alphabet de n lettres différentes):

$$A_n^k = \frac{n!}{(n-k)!}$$

- nombre C_n^k de **combinaisons** (nombre de *groupes* différents de k lettres différentes, à partir d'un alphabet de n lettres différentes):

$$C_n^k = \frac{n!}{(n-k)! k!}$$

$$Y = k \cdot X \Rightarrow \begin{cases} E(Y) = k \cdot E(X) \\ V(Y) = k^2 \cdot V(X) \end{cases}$$

$$Z = aX + bY \Rightarrow \begin{cases} E(Z) = a \cdot E(X) + b \cdot E(Y) \\ V(Z) = a^2 V(X) + b^2 V(Y) + 2ab \text{COV}(X, Y) \end{cases}$$



Index

Table
des
Matières

Statistique appliquée à la gestion

LOI BINOMIALE $\mathcal{B}(n; p)$

FORME DE LA LOI

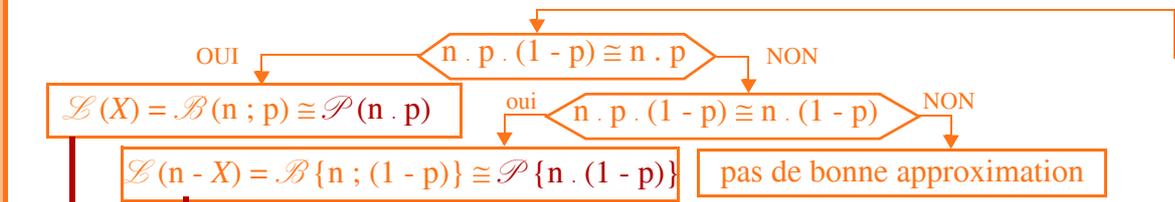
$$P(X = x) = C_n^x \cdot p^x \cdot (1 - p)^{n-x} = \frac{n!}{x! \cdot (n-x)!} \cdot p^x \cdot (1 - p)^{n-x}$$

$$P(f_n = f = \frac{x}{n}) \equiv P(X = x): \text{loi Binomiale en proportion}$$

PROPRIÉTÉS DE LA LOI

$E(X) = n \cdot p$	$V(X) = n \cdot p \cdot (1 - p)$	$\mathcal{L}(X_1) = \mathcal{B}(n_1; p)$ $\mathcal{L}(X_2) = \mathcal{B}(n_2; p) \quad \Rightarrow \mathcal{L}(X_1 + X_2) = \mathcal{B}(n_1 + n_2; p)$
$E(f_n) = p$	$V(f_n) = \frac{p \cdot (1 - p)}{n}$	

APPROXIMATION



LOI de POISSON $\mathcal{P}(\lambda)$

GÉNÉRATION ET SYMBOLES UTILISÉS

Génération { processus de Poisson
approximation d'une loi Binomiale
 λ : paramètre de Poisson

FORME DE LA LOI

$$P(X = x) = e^{-\lambda} \cdot \frac{\lambda^x}{x!}$$

PROPRIÉTÉS DE LA LOI

$E(X) = V(X) = \lambda$
 $\frac{P(X=x)}{P(X=x-1)} = \frac{\lambda}{x}$ } utilisées dans la reconnaissance empirique d'une loi de Poisson

$$\mathcal{L}(X_1) = \mathcal{P}(\lambda_1) \quad \Rightarrow \mathcal{L}(X_1 + X_2) = \mathcal{P}(\lambda_1 + \lambda_2)$$

$$\mathcal{L}(X_2) = \mathcal{P}(\lambda_2)$$

APPROXIMATION

$$\lambda > 20 \Rightarrow \mathcal{L}(X) = \mathcal{P}(\lambda) \approx \mathcal{N}(\lambda, \sqrt{\lambda})$$

LOI DE STUDENT $\mathcal{L}(X) = \mathcal{S}_v(\bar{x}, \sigma)$

- Symboles:
 - les mêmes que ceux de la loi Normale, plus v (= nombre de degrés de liberté),
 - loi continue tabulée utilisée pour l'estimation dans les petits échantillons.
- Approximation: $v > 30 \Rightarrow \mathcal{S}_v(\bar{x}, \sigma) \approx \mathcal{N}(\bar{x}, \sigma)$.
- Remarques sur les problèmes possibles: 5 données interviennent: $\alpha, \bar{x}, \sigma, x_{\alpha}, v$; la connaissance de 4 d'entre elles engendre celle de la 5^e.

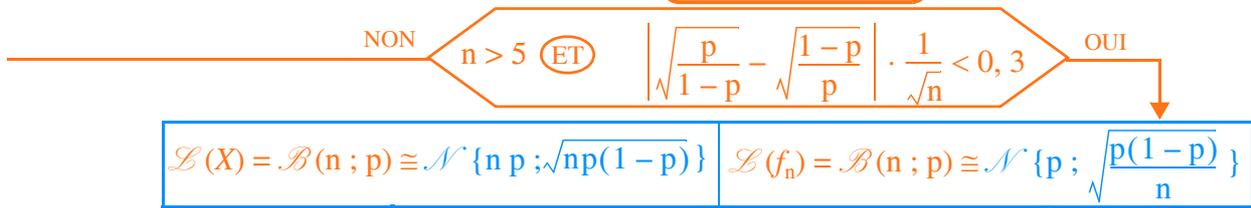


LOI BINOMIALE $\mathcal{B}(n; p)$

GÉNÉRATION ET SYMBOLES UTILISÉS

- 1 n = nombre d'épreuves indépendantes de même type
- 1 p = probabilité de réalisation de l'événement étudié, au cours de l'une quelconque des épreuves
- 1 X = variable aléatoire définie comme le nombre observable de réalisations de l'événement étudié au cours des n épreuves ($0 \leq X \leq n$)
- \Rightarrow variable aléatoire $n - X$ = nombre observable de non-réalisations de l'événement étudié au cours des n épreuves ($0 \leq n - X \leq n$)
- 1 $f_n = X/n$ = variable aléatoire définie comme la fréquence observable d'épreuves conduisant à la réalisation de l'événement ($0 \leq f_n \leq 1$)
- ix = nombre de réalisations de l'événement étudié au cours des n épreuves
- $if = x/n$ = fréquence observée de réalisation de l'événement étudié au cours des n épreuves

APPROXIMATION



LOI NORMALE: $\mathcal{L}(X) = \mathcal{N}(\bar{x}, \sigma)$

GÉNÉRATION ET SYMBOLES UTILISÉS

- X = variable aléatoire continue de moyenne \bar{x} et d'écart-type σ ; $-\infty < X < +\infty$
- effet d'un très grand nombre de causes indépendantes, à effets additifs, chacune d'entre elles ayant un effet négligeable par rapport à l'ensemble des autres.
- $T = \frac{X - \bar{x}}{\sigma}$; variable centrée réduite associée à X ; de moyenne $\bar{t} = 0$ et d'écart-type = 1

FORME DE LA LOI

$$P(X < x_\alpha) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{x_\alpha} e^{-\left(\frac{x-\bar{x}}{\sigma}\right)^2/2} dx = \alpha; \text{ loi tabulée.}$$

- $\bar{x} = M_e = M_o$; courbe symétrique par rapport à un axe perpendiculaire à \bar{x}
- $\left. \begin{matrix} \mathcal{L}(X_1) = \mathcal{N}(\bar{x}_1; \sigma_1) \\ \mathcal{L}(X_2) = \mathcal{N}(\bar{x}_2; \sigma_2) \end{matrix} \right\} \Rightarrow \mathcal{L}(X) = \mathcal{L}(X_1 \pm X_2) = \mathcal{N}([\bar{x}_1 \pm \bar{x}_2]; \sqrt{\sigma_1^2 + \sigma_2^2})$; généralisable à la somme d'un nombre quelconque de variables suivant une loi Normale.
- Théorème de la limite centrale:

$$Y = \sum_{i=1}^n X_i \Rightarrow \mathcal{L}(Y) = \mathcal{N}(m; \sigma), \text{ avec } m = \sum_{i=1}^n \bar{x}_i \text{ et } \sigma^2 = \sum_{i=1}^n \sigma_i^2 \text{ si } n \geq 30.$$
- loi remplacée par la loi de Student lorsque σ est estimé (cf. chapitre IV)
- Remarques sur les problèmes possibles: 4 données interviennent: $\alpha, \bar{x}, \sigma, x_\alpha$; la connaissance de 3 d'entre elles engendre celle de la 4^e.



Index

Table des Matières

Statistique appliquée à la gestion

Un **échantillon** de n éléments se définit comme l'un des sous-ensembles possibles tiré d'une population-mère de N éléments

		VARIABLES	
		ALÉATOIRES	CERTAINES
CARACTÈRES	QUANTITATIFS	$X,$ $m_n,$ s_n	 $\sigma^{*2} = V(m_n)$
	QUALITATIFS	f_n	 $\sigma^{*2} = V(f_n)$

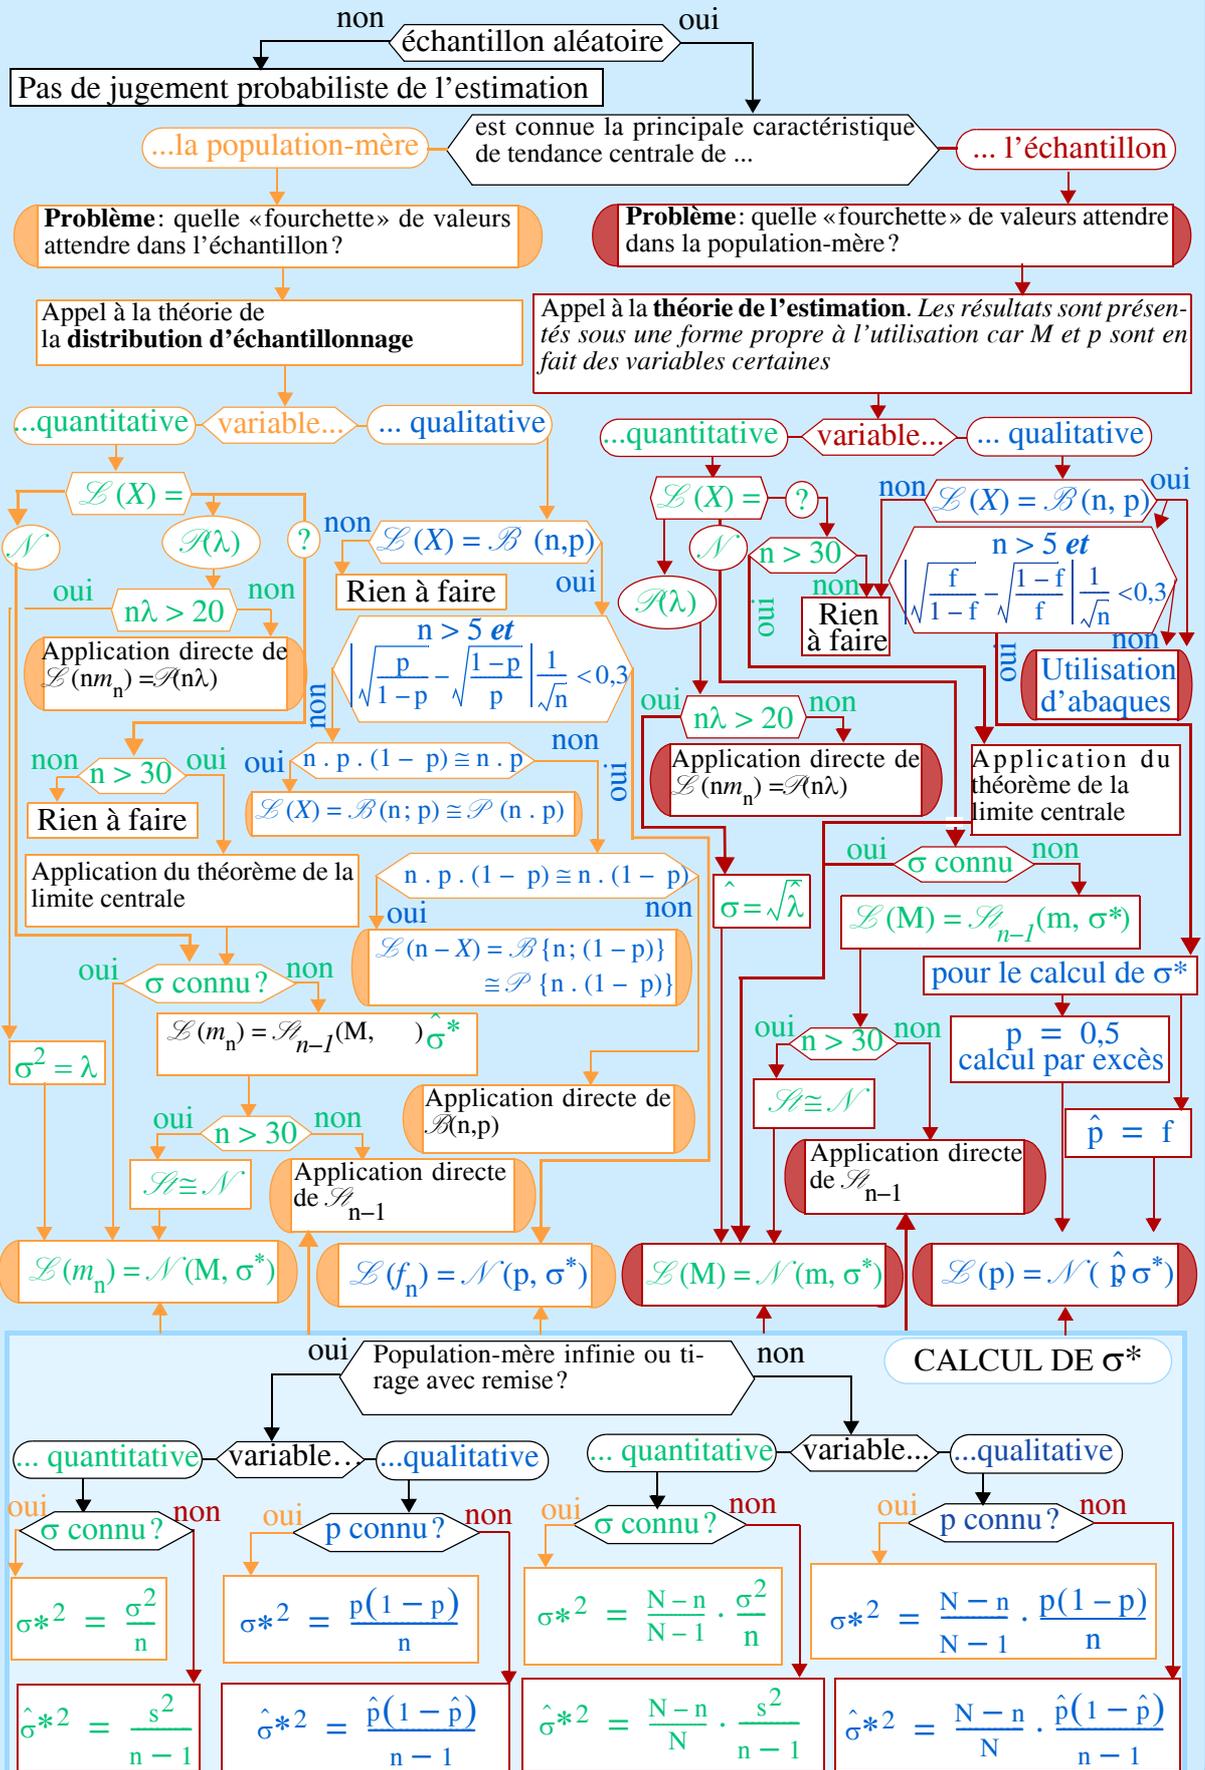
Un **tirage** est dit **exhaustif** lorsque l'on prélève les éléments simultanément, ou successivement sans remise de l'élément qui vient d'être tiré dans la population-mère.

- Un **échantillon aléatoire** est composé d'éléments tirés «au hasard» dans la population-mère, c'est-à-dire ayant tous la même probabilité a priori d'appartenir à l'échantillon; cette égalité de chance suppose un recensement préalable (= **base de sondage**) de la population-mère.
- Les sondages aléatoires sont à un degré (utilisation de table de nombres au hasard, tirage systématique) ou à plusieurs degrés.
- Les **échantillons empiriques** (méthodes des quotas...) sont utilisés en l'absence de base de sondage et, en toute rigueur, ne permettent pas de jugement en probabilité.

- Il existe C_N^n échantillons différents de taille n , tirés d'une population de taille N . Chacun est caractérisable par des paramètres.
- La **distribution d'échantillonnage** d'un paramètre donné (ex. : \bar{x}) est la distribution statistique de ce paramètre dans tous les échantillons possibles de taille n , ce qui permet de définir la variable aléatoire \bar{x}_n (ou m_n) lorsque le tirage est aléatoire.
- Cette distribution d'échantillonnage du paramètre étudié peut à son tour être caractérisée par des paramètres, comme toute distribution statistique.
- Il ne faut pas confondre, pour une variable quantitative, la variance de la population-mère (σ^2), la variance observée sur un échantillon donné (s^2) et la variance de la distribution d'échantillonnage des moyennes observables dans un échantillon (σ^{*2}).

- L'**estimateur** $\hat{\theta}_n$ est une approximation d'un paramètre inconnu θ de la population-mère, à partir des données d'un échantillon aléatoire de taille n .
- Une **estimation ponctuelle** est la valeur prise par un estimateur dans un échantillon particulier.
- Principales **qualités d'un estimateur**:

- sans biais : $E(\hat{\theta}_n) = \theta$	= estimateur absolument correct	= estimateur efficace
- convergent : $V(\hat{\theta}_n) \rightarrow 0$ si $n \rightarrow N$		
- à variance $V(\hat{\theta}_n)$ minimale dans les échantillons de taille n		
- Principales estimations à utiliser: $\hat{p} = f; \hat{M} = m; \hat{\sigma}^2 = \frac{ns^2}{n-1}$



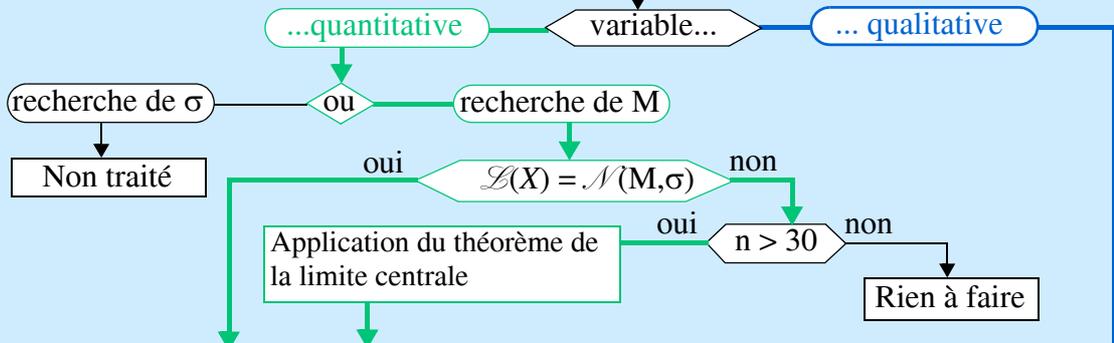


Index

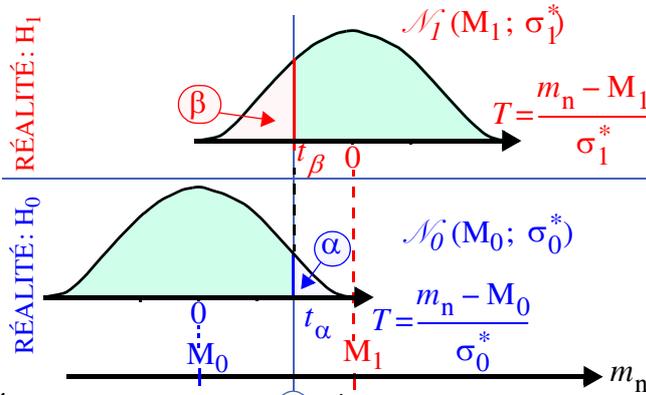
Table des Matières

Statistique appliquée à la gestion

problème: Décider de la valeur d'un paramètre de la population-mère, à choisir entre 2 hypothèses, à partir des observations faites sur un échantillon



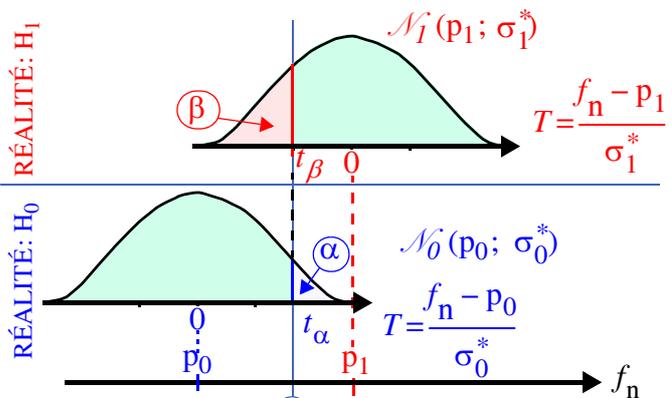
Variables aléatoires	Variables certaines
X	N
m_n	σ_0 ou σ_1 M_0 ou M_1 n m s^2



DÉCISION: ACCEPTER H_0 (à gauche de π) DÉCISION: ACCEPTER H_1 (à droite de π)

- Ici H_0 est associé à la moyenne la plus faible; la figure est à adapter au cas inverse
- Double problème de distribution d'échantillonnage, chaque problème étant caractérisé par 5 paramètres, dont 2 communs:
 - le premier, où interviennent: $M_0, \sigma_0, \alpha, n, \pi$,
 - le second, où interviennent: $M_1, \sigma_1, \beta, n, \pi$.
- si $\sigma = \sigma_0 = \sigma_1 = ?$, alors estimation de σ ($\hat{\sigma}^2 = \frac{n \cdot s^2}{n-1}$) et la loi Normale est remplacée par la loi de Student à $v = n - 1$ degrés de liberté.

Variables aléatoires	Variables certaines
$L(X) = \mathcal{B} \cong \mathcal{N}$	N
$L(f_n) = \mathcal{B} \cong \mathcal{N}$	p_0 ou p_1 n f



DÉCISION: ACCEPTER H_0 (à gauche de π) DÉCISION: ACCEPTER H_1 (à droite de π)

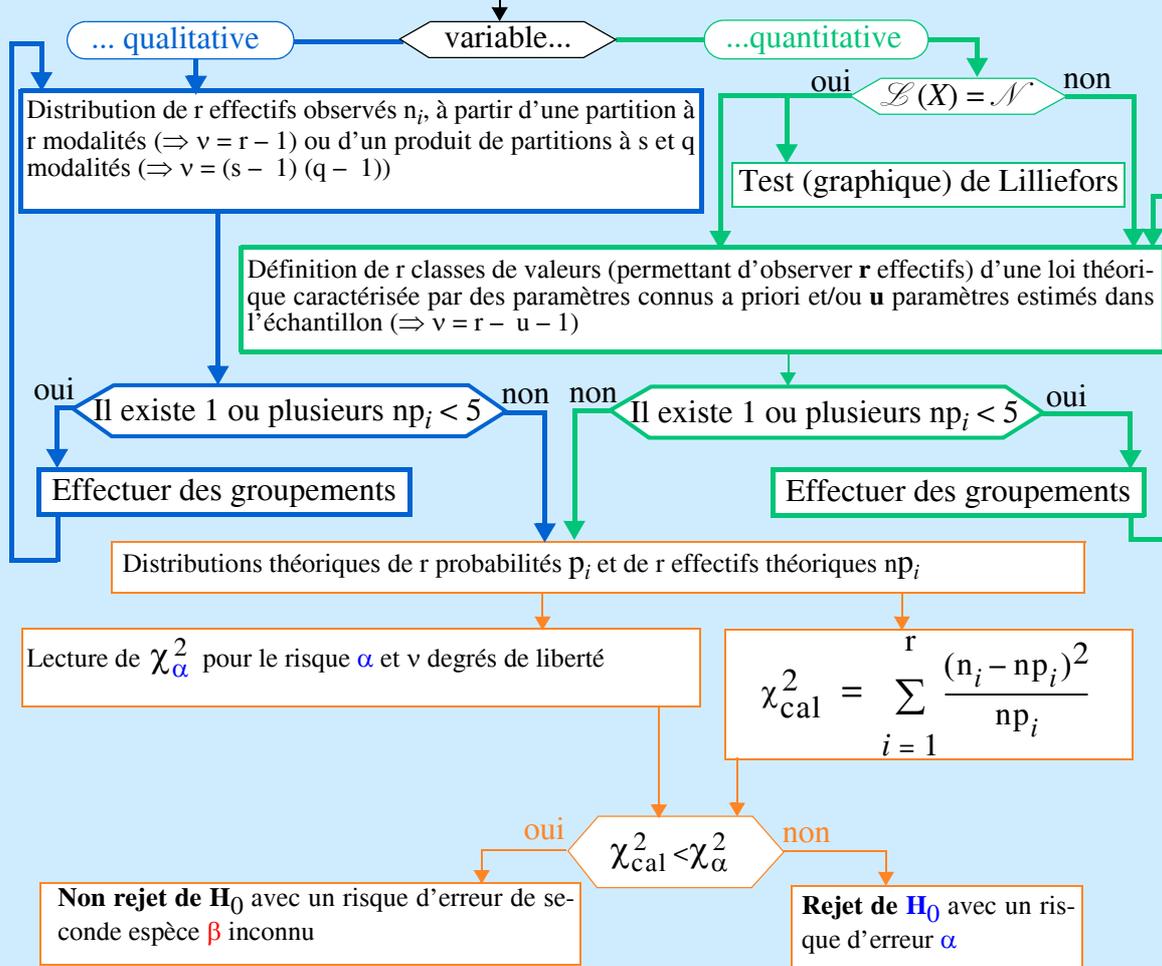
- Ici H_0 est associé à la proportion la plus faible; la figure est à adapter au cas inverse
- Double problème de distribution d'échantillonnage, chaque problème étant caractérisé par 4 paramètres, dont 2 communs:
 - le premier, où interviennent: p_0, α, n, π ,
 - le second, où interviennent: p_1, β, n, π .



Problème: choisir, à partir de données fournies par un échantillon, la population-mère, d'où l'échantillon est tiré, parmi 2 possibles. Chaque population-mère est caractérisée par une valeur différente d'un paramètre donné ou par une distribution statistique.

		DÉCISION	
		H_0 est retenue	H_0 est rejetée au profit de H_1
RÉALITÉ	H_0	Choix <i>correct</i> avec une probabilité $(1 - \alpha)$	Choix <i>erroné</i> (= erreur de première espèce), avec une probabilité α (= risque de première espèce)
	H_1	Choix <i>erroné</i> (= erreur de seconde espèce), avec une probabilité β (= risque de seconde espèce)	Choix <i>correct</i> avec une probabilité $(1 - \beta)$

Problème: Peut-on, avec un risque d'erreur α , rejeter l'hypothèse H_0 selon laquelle une distribution observée est tirée d'une population-mère caractérisée par une distribution théorique, donnée ou estimée?



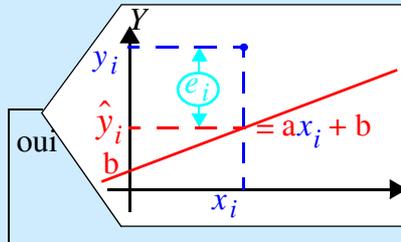


Index

Table
des
Matières

Etude simultanée de 2 caractères quantitatifs \Rightarrow observation de n couples (x_i, y_i) ou de triplets (x_i, y_i, n_{ij}) , avec dépendance causale de X sur Y postulée pour des motifs d'ordre extra-statistique.

non oui
les n observations sont considérées comme constituant un échantillon



la dépendance causale se traduit par la liaison : $y_i = ax_i + b + e_i$ (régression linéaire de Y en X) où X et Y peuvent éventuellement avoir subi préalablement une transformation (élévation à une puissance, logarithme...)

non

Régression non linéaire : non traité

Problème : recherche d'une valeur pour a et b (car une infinité de droites peuvent prétendre, chacune d'entre elles, résumer correctement le nuage de points).

Un critère de choix possible peut être de trouver le couple (a, b) qui rend minimum $\sum_{i=1}^n e_i^2 \Rightarrow$

méthode des moindres carrés :

Résultats analytiques

$$a = \frac{\text{COV}(X, Y)}{V(X)} \quad \text{avec}$$

$$b = \bar{y} - a\bar{x}$$

tableau de données ponctuelles :

$$\begin{aligned} \text{COV}(X, Y) &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}) \\ &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y} \end{aligned}$$

tableau de contingence :

$$\begin{aligned} \text{COV}(X, Y) &= \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^q n_{ij} (x_i - \bar{x})(y_j - \bar{y}) \\ &= \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^q n_{ij} x_i y_j - \bar{x} \cdot \bar{y} \end{aligned}$$

Problème : analyse de la «qualité» de la liaison linéaire

• variance totale = variance-résiduelle + variance expliquée : $V(Y) \equiv \sigma_y^2 = \sigma_r^2 + \sigma_e^2$

• Variance résiduelle : $\sigma_r^2 = \frac{1}{n} \sum_{i=1}^n e_i^2 = \frac{1}{n} \sum_{i=1}^n [y_i - (ax_i + b)]^2 = (1 - r^2) \sigma_y^2$

• Coefficient de détermination : $r^2 = \frac{[\text{COV}(X, Y)]^2}{V(X) \cdot V(Y)} = \frac{\sigma_e^2}{\sigma_y^2}$

• Coefficient de corrélation : $r = \frac{\text{COV}(X, Y)}{\sqrt{V(X) \cdot V(Y)}} = \frac{\frac{1}{n} \sum x_i \cdot y_i - \bar{x}\bar{y}}{\sqrt{\left(\frac{1}{n} \sum x_i^2 - \bar{x}^2\right) \left(\frac{1}{n} \sum y_i^2 - \bar{y}^2\right)}}$

• Graphique des résidus standardisés e_i / σ_r en fonction des x_i , pour détecter d'éventuelles erreurs de spécification et/ou des points aberrants.



Une première série de 4 hypothèses :

- - variables mesurées sans erreur
 - - absence de biais systématique: $E(\varepsilon_i) = 0$
 - - absence de liaison entre les écarts :
 - $COV(\varepsilon_i, \varepsilon_j) = 0$, pour tout couple i, j
 - - dispersion identique autour de y_i :
 - $V(\varepsilon_i) = \sigma$, pour tout i ,
- permet d'affirmer que :

$$- \hat{\alpha} = a \text{ et } \hat{\beta} = b ;$$

$$- \hat{\sigma}^2 = \frac{\sum e_i^2}{n-2} = \frac{n}{n-2}(1-r^2)V(Y)$$

$$- \hat{\rho}^2 = 1 - \frac{(1-r^2)(n-1)}{n-2} : \text{ estimateur correct}$$

Variables aléatoires	Variables certaines
ε_i	N $y_i = \alpha x_i + \beta + \varepsilon_i$ ρ^2 n $y_i = ax_i + b + e_i$ r^2
a_n	
b_n	
r_n^2	

estimateurs absolument corrects et efficaces

L'hypothèse selon laquelle $\mathcal{L}(\varepsilon_i) = \mathcal{N}(0, \sigma)$ permet de fournir des estimations par intervalle de confiance. Appel à la **théorie de l'estimation**. Les résultats sont présentés sous une forme propre à l'utilisation car α et β sont en fait des variables certaines

- $\mathcal{L}(\alpha) = \mathcal{N}_{n-2}(a, \hat{\sigma}_{a_n})$ avec $\hat{\sigma}_{a_n} = \frac{\hat{\sigma}^2}{n \sum_{i=1}^{n-1} (x_i - \bar{x})^2} = \frac{\sqrt{(1-r^2)V(Y)}}{\sqrt{(n-2)V(X)}}$
- $\mathcal{L}(\beta) = \mathcal{N}_{n-2}(b, \hat{\sigma}_{b_n})$ avec $\hat{\sigma}_{b_n} = \frac{\hat{\sigma}^2 \sum_{i=1}^{n-1} x_i^2}{n \sum_{i=1}^{n-1} (x_i - \bar{x})^2} = \frac{\sqrt{(1-r^2)V(Y)[V(X) + \bar{x}^2]}}{\sqrt{(n-2)V(X)}}$

- $\mathcal{L}(\hat{y}_j) = \mathcal{N}_{n-2}(a \cdot x_j + b, \hat{\sigma}_j)$ avec

$$\hat{\sigma}_j = \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_j - \bar{x})^2}{\sum_{i=1}^{n-1} (x_i - \bar{x})^2}} = \frac{\sqrt{(1-r^2)V(Y)[(1+n)V(X) + (x_j - \bar{x})^2]}}{\sqrt{(n-2)V(X)}}$$

- $P\left(\frac{-1 + e^{[2(r-t_{\alpha \cdot s})]}}{1 + e^{[2(r-t_{\alpha \cdot s})]}} < \rho < \frac{-1 + e^{[2(r+t_{\alpha \cdot s})]}}{1 + e^{[2(r+t_{\alpha \cdot s})]}}\right) = 1-2\alpha$, avec $s = \sqrt{\frac{1}{n-1} + \frac{4-r^2}{2(n-1)^2}}$ et $n > 11$

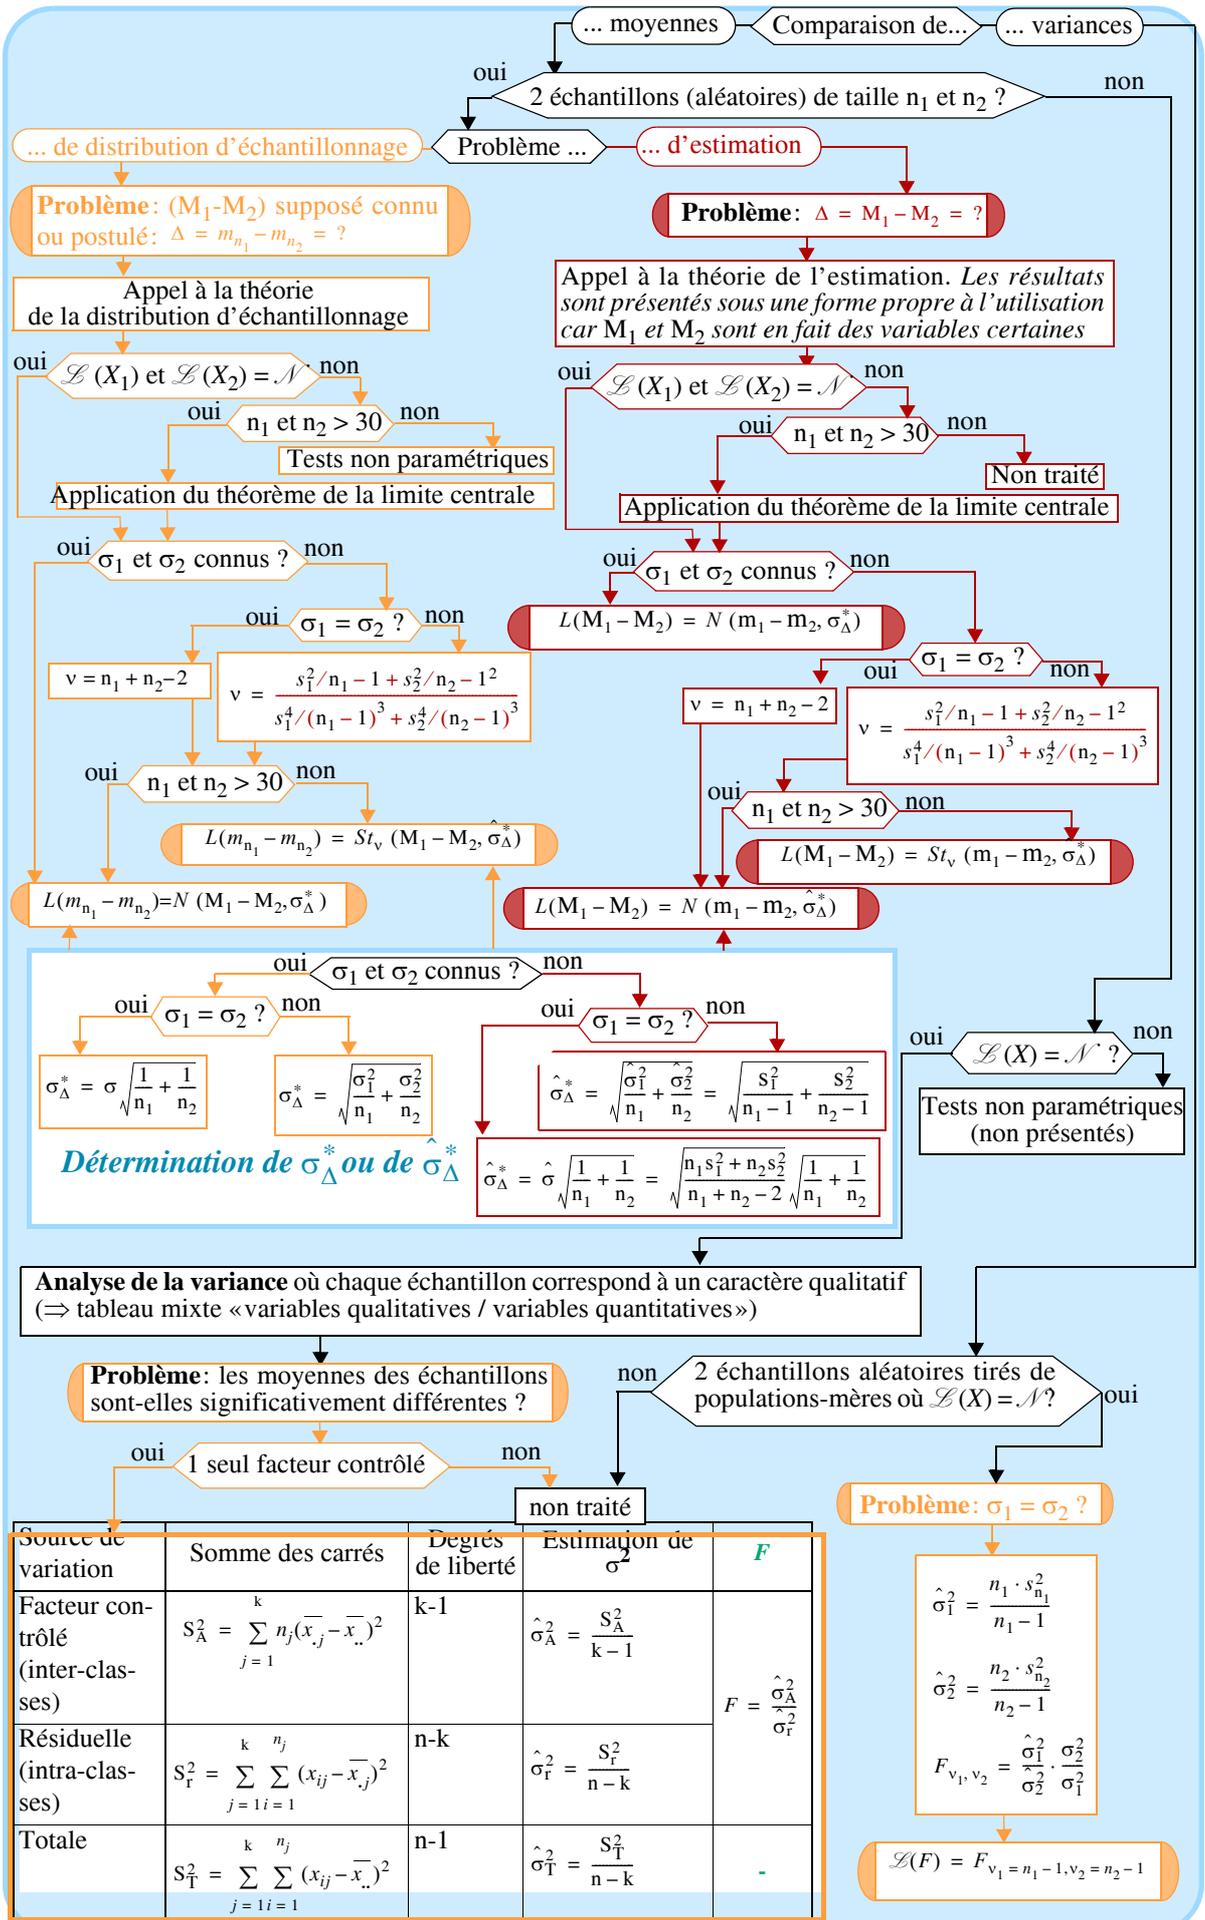
- ρ^2 est significativement différent de 0 si la pente α l'est aussi.



Index

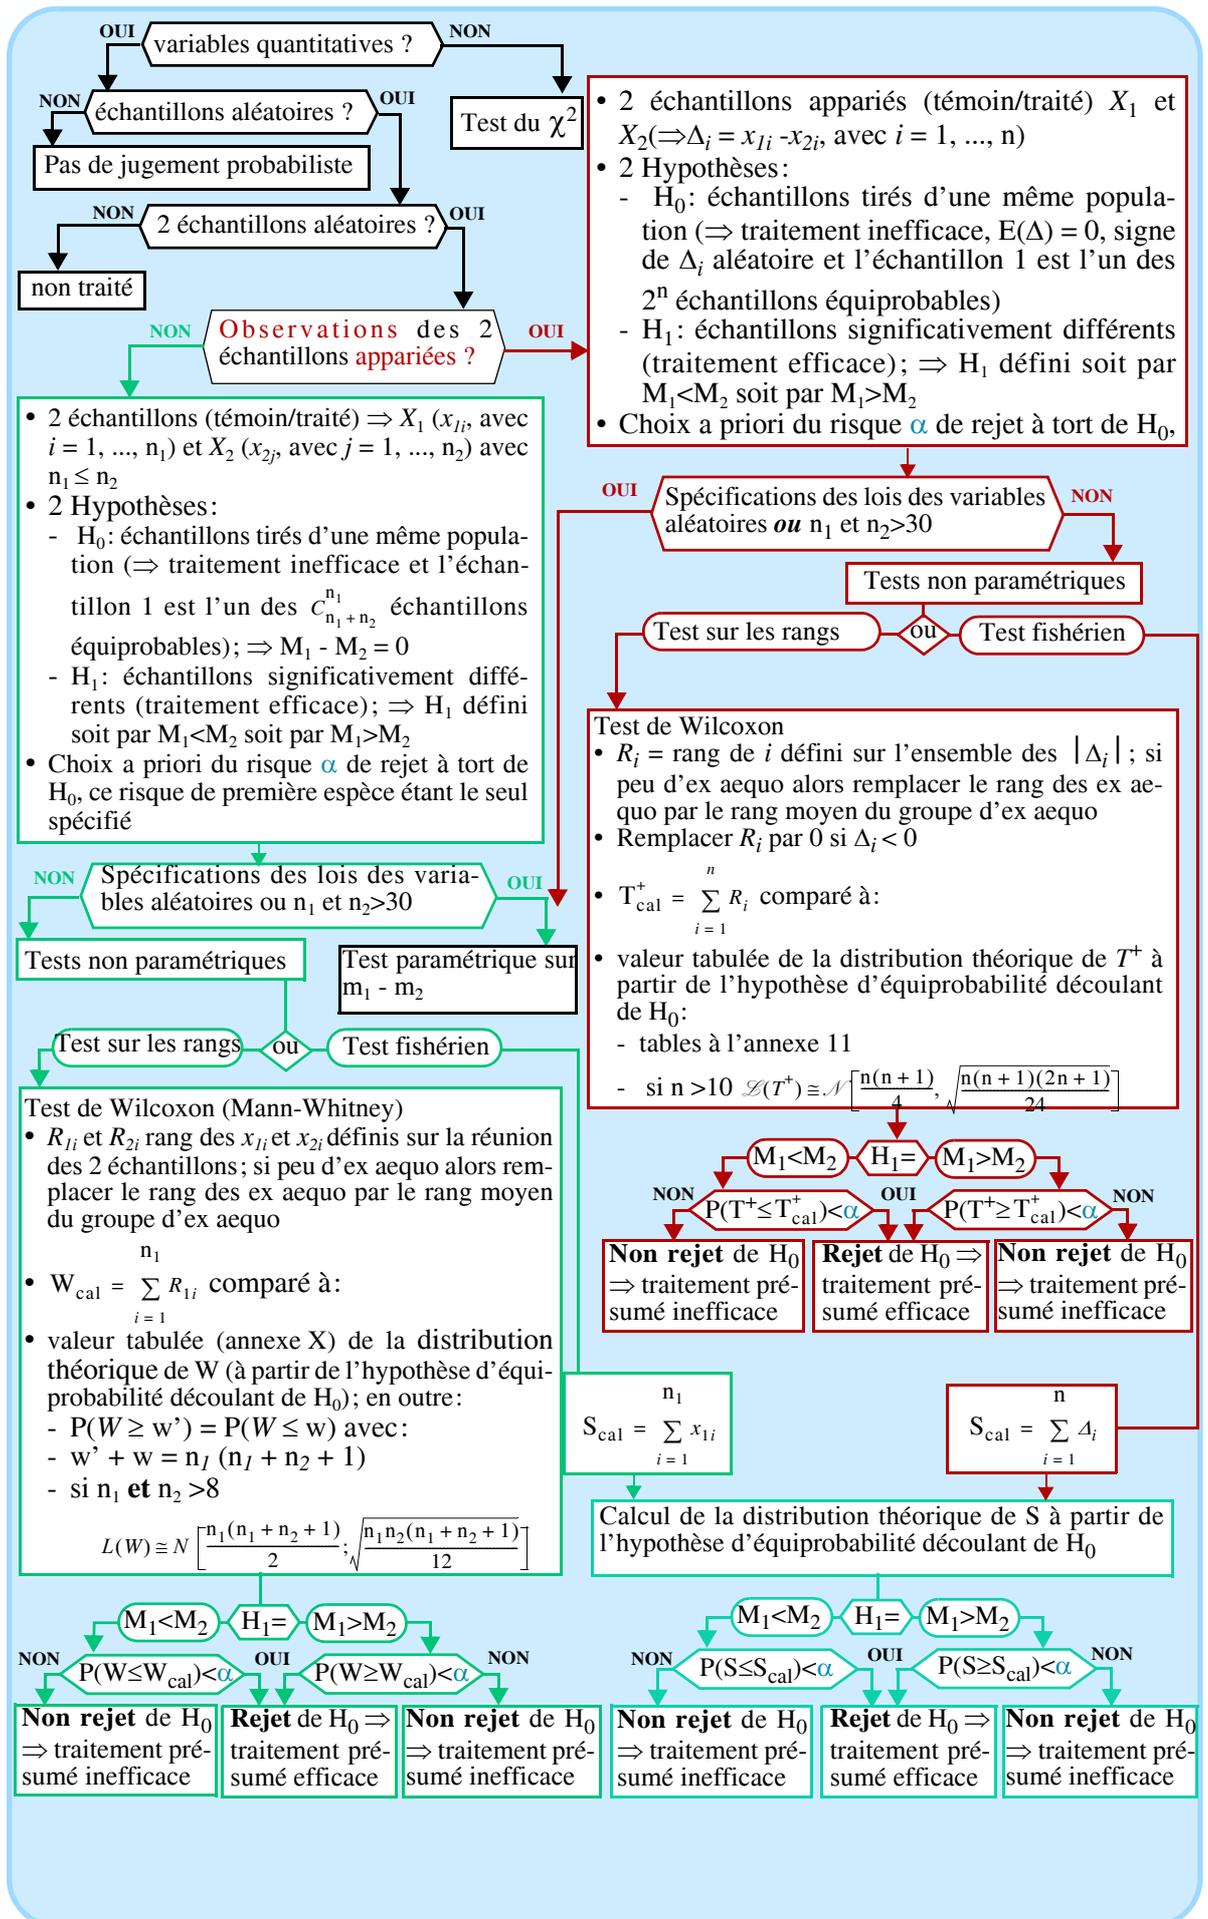
Table des Matières

Statistique appliquée à la gestion



RÉSUMÉ DU CHAPITRE VII - COMPARAISON D'ÉCHANTILLONS

TESTS NON PARAMÉTRIQUES





Index

Table des Matières

Statistique appliquée à la gestion

