

# Premières notions de statistique statistiques descriptives, estimation, modèles et intervalles de confiance

Franck Picard

UMR CNRS-5558, Laboratoire de Biométrie et Biologie Evolutive


`franck.picard@univ-lyon1.fr`

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments

# Populations et caractères

- Les études statistiques s'appuient sur des **observations** mesurées sur des **populations** composées d'**individus** sur lesquelles on observe des **caractères**
- La notion d'**individus** devient statistique
- On mesure des **caractères**:
  - Qualitatifs (ni ordonnés ni ajoutés)
  - Ordinaux (ordonnés mais pas ajoutés)
  - Quantitatifs (numériques, discrets ou continus)



Animaux

- Génotype
- Taille
- Poids
- couleur des yeux

Galaxies

- luminosité
- vitesse
- densité

chromosomes


- longueur
- # de copies

cellules

- taille du noyau
- # de chromosomes
- taille

# Quand fait-on de la statistique ?

- Quand il est **impossible** ou **inutile** d'observer un caractère sur l'ensemble de la population.
- La **stratégie** statistique consiste à observer les caractères sur une **sous-population** en espérant tirer des observations des conclusions générales à la **population de référence**.
- La première étape consiste donc à identifier cette population d'intérêt (cible)



Animaux  
- Génotype  
- Taille  
- Poids  
- couleur des yeux

Galaxies  
- luminosité  
- vitesse  
- densité

chromosomes  
- longueur  
- # de copies

cellules  
- taille du noyau  
- # de chromosomes  
- taille

# La notion d'échantillon

- L'échantillonnage consiste à **choisir des individus** de la population générale suivant certaines **contraintes**
- Le résultat de la mesure d'un caractère sur  $n$  individus est un  $n$ -uplet  $(x_1, \dots, x_n)$ , que l'on appelle échantillon de taille  $n$ .
- Exemple:  $n = 3$  individus,  $x_i$  l'âge du  $i$ ème individu. Après mesure, on dispose d'un 3-échantillon  $(x_1, x_2, x_3) = (15, 18, 19)$ .

**Animaux**  
- Génotype  
- Taille  
- Poids  
- couleur des yeux

**Galaxies**  
- luminosité  
- vitesse  
- densité

**chromosomes**  
- longueur  
- # de copies

**cellules**  
- taille du noyau  
- # de chromosomes  
- taille

The diagram consists of four panels. The top-left panel shows a group of sheep with three white circles highlighting individual sheep. The top-right panel shows a field of galaxies with four white circles highlighting specific galaxies. The middle panel shows a set of colorful chromosomes with four white circles highlighting individual chromosomes. The bottom panel shows a microscopic view of cells with blue nuclei and red cytoplasm, with four white circles highlighting individual cells.

## Première étape de prise en main des données

- Lorsque l'on récolte des données pour les analyser une première étape est de formaliser les données disponibles
- On récolte 500 cocons de Bombyx mori. On en pèse 10 au hasard

Poids	0.64	0.65	0.73	0.60	0.65	0.77	0.82	0.64	0.66	0.72
-------	------	------	------	------	------	------	------	------	------	------

- La première étape de formalisation consiste à poser :  $n = 10$ , et  $x_i$  le poids du cocon  $i$ , tel que l'échantillon observé est

$$(x_1, \dots, x_n) = (0.64, 0.65, \dots, 0.72).$$

# Un échantillon est aléatoire

- L'échantillonnage étant une procédure aléatoire, un échantillon est par essence aléatoire
- Les résultats issus d'un échantillon sont également des **résultats aléatoires**
- Exemple: on tire  $(x_1, x_2, x_3) = (15, 18, 19)$ , si on retire un autre 3-échantillon  $(x'_1, x'_2, x'_3) = (17, 19, 16)$

**Animaux**

- Génotype
- Taille
- Poids
- couleur des yeux

**Galaxies**

- luminosité
- vitesse
- densité

**chromosomes**

- longueur
- # de copies

**cellules**

- taille du noyau
- # de chromosomes
- taille

# Statistiques descriptives et résumé des données

- Comment définir des indicateurs permettant de synthétiser l'information contenue dans l'échantillon ?
- UNE statistique est une fonction d'un échantillon permettant d'accéder à un certain type d'information.
  - La moyenne renseigne sur la position (barycentre au sens physique)
  - La variance renseigne sur la dispersion autour du barycentre
  - Les quantiles renseignent sur la répartition des individus suivant les valeurs observées.


Les échantillons étant aléatoires, les statistiques calculées à partir de ces échantillons seront aussi aléatoires

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique**
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments

# Distribution empirique associée à un échantillon

- C'est la distribution de probabilité sur l'ensemble des modalités qui affecte chaque observation du poids  $1/n$ .
- Si on note  $c_1, \dots, c_k$  les valeurs distinctes prises par les  $x_i$  et pour  $h = 1, \dots, k$ ,  $n_h = \sum_{i=1}^n \mathbf{1}_{\{x_i=c_h\}}$  l'effectif de la valeur  $c_h$ .
- C'est la loi de probabilité  $\hat{P}$  sur l'ensemble  $\{c_1, \dots, c_k\}$ , telle que :  $\hat{P}(c_h) = \frac{n_h}{n}$ .




## Distribution empirique de lois discrètes

- Lorsque nombre de valeurs différentes  $k$  est faible devant la taille de l'échantillon  $n$
- Le **diagramme en bâtons** consiste à représenter les valeurs différentes  $c_1, \dots, c_k$  en abscisse, avec au-dessus de chacune une barre verticale de longueur égale à sa fréquence expérimentale  $\hat{P}(c_h)$ .
- Pour des échantillons qualitatifs, on utilise aussi des représentations en **camembert** (pie-chart), ou en **barre**.
- Elles consistent à diviser un disque ou un rectangle proportionnellement aux différentes fréquences.
- Pour explorer différentes représentations graphiques <http://pbil.univ-lyon1.fr/R/pdf/lang04.pdf>.

## Construction du diagramme en batons

- Le balanin de la châtaigne *Curculio elephas* est un insecte parasite de la châtaigne. On a récolté des châtaignes et compté le nombre de parasites dans chacun des fruits

nb parasites	0	1	2	3	4	5	6	7	8	9	10	11
nb de chataignes	1043	172	78	15	10	7	2	1	0	0	0	1



## Distribution empirique de lois continues et histogrammes


- On choisit  $k$  classes et des intervalles  $[a_0, a_1], ]a_1, a_2], \dots, ]a_{k-1}, a_k]$  pour regrouper les données en paquets.
- On calcule pour chaque  $]a_{h-1}, a_h]$  la fréquence correspondante

$$\hat{P}(]a_{h-1}, a_h]) = \frac{1}{n} \sum_{i=1}^n 1\{x_i \in ]a_{h-1}, a_h]\}$$

- L'histogramme représente ces fréquences rapportées à la longueur des intervalles


## Attention aux représentations visuelles

- Les histogrammes sont avant tout un outil visuel de représentation de la variabilité des données
- Ils dépendent de paramètres, notamment le nombre de pas de l'histogramme
- Si on a un échantillon de taille  $n$ , c'est souvent  $\sqrt{n}$  pas qui donne "la meilleure" représentation.



## Comparaison visuelle de distributions

- Les histogrammes peuvent être utilisés pour comparer visuellement des distributions
- On peut comparer des distributions empiriques entre elles
- On peut aussi comparer une distribution empirique avec une distribution théorique
- Exemple du nombre de balanins sur les chataignes et la loi de Poisson.



Loi empirique du nombre de balanins par chataigne et loi de Poisson théorique de paramètre  $\lambda = 0.34$ .

## La fonction de répartition empirique


- On appelle statistiques d'ordre de l'échantillon  $(x_1, \dots, x_n)$ , les valeurs  $x_{(1)}, \dots, x_{(n)}$  égales aux  $x_i$  rangées par ordre croissant.

$$x_{(1)} = \min_{i=1, \dots, n} \{x_i\} \leq x_{(2)} \leq \dots \leq x_{(n)} = \max_{i=1, \dots, n} \{x_i\} .$$

- La fonction de répartition empirique est la proportion d'éléments de l'échantillon qui sont inférieurs ou égaux à  $x$ .
- Elle est notée  $\hat{F}(x)$ . C'est une fonction de l'ensemble des valeurs prises par  $\mathbf{x}$  dans  $[0, 1]$ , qui vaut :


$$\begin{aligned} \hat{F}(x) &= 0 && \text{pour } x \leq x_{(1)} \\ \hat{F}(x) &= i/n && \text{pour } x_{(i)} \leq x \leq x_{(i+1)} \\ \hat{F}(x) &= 1 && \text{pour } x \geq x_{(n)} \end{aligned}$$

# La fonction de répartition empirique



# Comparaison visuelle de distributions par la fonction de répartition

- Il peut être plus clair (visuellement) d'utiliser la fonction de répartition pour comparer deux échantillons
- On étudie le taux de survie d'un insecte pendant son développement embryonnaire.
- On considère deux sites d'études (noir et rouge sur le graphique)
- 80% des larves du site S1 ont un taux de survie  $< 0.5$  contre 100% du site S2.



Noir :  $\hat{F}$  pour la survie sur le site S1,  
Rouge pour S2.

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques**
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments

## La moyenne empirique et centre de gravité

- Si l'échantillon est noté  $(x_1, \dots, x_n)$ , sa moyenne empirique est :

$$\bar{x} = \frac{1}{n}(x_1 + \dots + x_n).$$

- Elle respecte une propriété d'**associativité**: la moyenne empirique de deux échantillons réunis de tailles respectives  $n_x$  et  $n_{x'}$ , de moyennes respectives  $\bar{x}$  et  $\bar{x}'$  sera le nouveau barycentre:

$$\overline{xx'} = \frac{n_x \bar{x} + n_{x'} \bar{x}'}{n_x + n_{x'}}$$

- Un des désavantages de la moyenne est qu'elle est très **sensible aux valeurs extrêmes** (aberrantes)
- Le **centrage** des données consiste à retrancher la moyenne empirique à toutes les valeurs de l'échantillon qui devient centré  $(x_1 - \bar{x}, \dots, x_n - \bar{x})$

## La variance empirique et la dispersion

- C'est un indicateur qui permet de quantifier la **dispersion** d'un échantillon autour de sa moyenne.
- La variance empirique de l'échantillon est notée  $s^2$ ,:

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


- L'écart-type ( $s$ ) a l'avantage de s'exprimer, comme la moyenne, dans la même unité que les données.
- On utilise parfois des indicateurs construits à partir de  $\bar{x}$  et  $s^2$ :
  - le rapport signal sur bruit  $\bar{x}^2/s^2$  qui normalise l'intensité du signal par rapport à sa dispersion
  - le coefficient de variation  $s/\bar{x}$  qui quantifie le degré de variabilité rapporté à la localisation de la distribution

# La réduction des données

- Après centrage des données, on peut également les réduire :

$$\left( \frac{x_1 - \bar{x}}{s}, \dots, \frac{x_n - \bar{x}}{s} \right)$$

- On obtient ainsi un nouvel échantillon dont la moyenne est nulle et la variance égale à 1, ces nouvelles données n'ont plus d'unité.
- On peut donc comparer deux échantillons réduits



# Outline


- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité**
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments

## De la fonction de répartition empirique aux quantiles

- La fonction de répartition  $\widehat{F}(x)$  renseigne sur la proportion de points de l'échantillon qui sont inférieurs ou égaux à l'élément  $x$ . C'est une valeur entre 0 et 1.
- On peut se poser la question inverse: quelle serait la valeur de  $x$  pour laquelle on aurait  $u\%$  des individus sous cette valeur ? C'est une valeur entre  $x_{(1)}$  et  $x_{(n)}$ .
- Les quantiles permettent d'extraire des valeurs caractéristiques des distributions (extrêmes, médianes).

Les quantiles permettent de placer les autres valeurs par rapport à celles ci en terme de centralité ou d'exceptionnalité.

# Quantiles Empiriques



## Quantiles empiriques

- La fonction quantile empirique de l'échantillon est la fonction  $\hat{Q}$  qui, pour tout  $i = 1, \dots, n$ , vaut  $x_{(i)}$  sur l'intervalle  $]\frac{i-1}{n}, \frac{i}{n}]$ .

$$\forall u \in \left] \frac{i-1}{n}, \frac{i}{n} \right] , \quad \hat{Q}(u) = x_{(i)} .$$

- Pour certaines valeurs de  $u$ , on donne un nom particulier aux quantiles  $\hat{Q}(u)$  (médiane, quartiles, déciles)
- La médiane est une valeur centrale de l'échantillon : il y a autant de valeurs qui lui sont inférieures que supérieures.
- Si l'échantillon est dissymétrique, avec une distribution très étalée vers la droite, la médiane pourra être nettement plus petite que la moyenne.
- Contrairement à la moyenne, la médiane est insensible aux valeurs aberrantes.

## Exemple de détection de valeurs aberrantes

- Dans deux types de forêts on a mesuré les hauteurs de 12 arbres choisis au hasard et indépendemment. On souhaite savoir si la taille des arbres dépend du type de forêt.

Type 1	23.4	24.4	24.6	24.9	25	26.2	26.3	26.8	26.8	26.9	27
Type 2	22.5	22.9	23.74	24.0	24.4	24.5	25.3	26	26.4	26.7	32


- On note  $x_i^1$  la taille de l'arbre  $i$  mesuré dans la forêt de type 1.
- On compare les statistiques descriptives des deux types de forêt:

	Moyenne	Ecart-type	Médiane
Type 1	25.66	1.24	26.2
Type 2	25.31	2.60	24.5
Type 2(sans $x_{12}^2$ )	24.85	1.52	24.5

# Quantiles et boxplots

- La représentation en boxplot repose sur l'hypothèse que seules quelques valeurs des quantiles peuvent être utilisées pour synthétiser l'information contenue dans une distribution
- L'intervalle de base des quantile est l'inter-quartile range
- Comparer des distributions s'avère être facilité par cette représentation qui permet de visualiser directement l'étendue de la distribution empirique.


# Boxplots



## Quantiles et exceptionnalité


- La notion de quantile est centrale pour comprendre de nombreuses démarches statistiques car les quantiles renseignent sur la **répartition des d'individus** à droite et à gauche du quantile (ex: salaire médian)
- Exemple : si j'ai une nouvelle observation  $x_{n+1}$ , comment la 'placer' par rapport aux autres  $(x_1, \dots, x_n)$  ?
  - si  $x_{n+1} > \widehat{q}(0.99999)$  alors  $x_{n+1}$  est "très" exceptionnelle **par rapport à la distribution empirique**
  - si  $x_{n+1} > q(0.99999)$  alors  $x_{n+1}$  est "très" exceptionnelle **par rapport à ce qu'aurait prédit un modèle** (cf. tests)

# Calculs utiles sur les quantiles (pour la suite)




$$\begin{aligned}\mathbb{P}(Z \leq q_{1-\alpha}) &= F(q_{1-\alpha}) \\ &= 1-\alpha\end{aligned}$$

$$\begin{aligned}\mathbb{P}(Z \geq q_{1-\alpha}) &= 1-F(q_{1-\alpha}) \\ &= \alpha.\end{aligned}$$



$$\begin{aligned}\mathbb{P}(Z \in [q_{\alpha/2}, q_{1-\alpha/2}]) &= 1 - \left[ \mathbb{P}(Z \leq q_{\alpha/2}) + \mathbb{P}(Z \geq q_{1-\alpha/2}) \right] \\ &= 1 - \left[ \alpha/2 + 1 - 1 + \alpha/2 \right] \\ &= 1-\alpha\end{aligned}$$

## A garder en mémoire



Lien avec les tests (exceptionnalité) et avec les intervalles de confiance

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire**
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments

## Pourquoi des modèles ?

- Le résultat d'une expérience n'est pas strictement prévisible, il est donc aléatoire.
- On modélise les données comme la **réalisation de variables aléatoires**.
- Les outils probabilistes/statistiques permettent d'extraire la part de l'information qui est reproductible
- La démarche statistique suppose qu'un échantillon **ne renseigne que partiellement** sur l'ensemble de la population d'intérêt

Les modèles probabilistes permettent de prendre des décisions sur des bases probabilistes par la formalisation un risque (erreur)

# Variables aléatoires et vecteurs aléatoires

- Une variable aléatoire  $X$  est une **fonction** d'une expérience aléatoire.
- Une réalisation  $x$  d'une variable aléatoire  $X$  est la valeur de la variable après avoir effectué l'expérience.
- **on considère que les données sont des réalisations de variables aléatoires:**  $(x_1, \dots, x_n)$ ,  $n$  réalisations de  $(X_1, \dots, X_n)$
- La loi jointe des observations est:

$$\mathbb{P}(X_1 = x_1, \dots, X_n = x_n)$$

▶ Rappels Variables Aléatoires

# Echantillon Indépendant et Identiquement distribué (i.i.d.)

- On considère un  $n$  échantillon aléatoire  $\mathbf{X}$  (vecteur de taille  $n$ ).
- La notion d'échantillon iid est centrale et repose sur les hypothèses:
  - Les  $X_i$  sont indépendants entre eux
  - Les  $X_i$  sont tous de même distribution
- Dans ce cadre, le  $n$  échantillon aléatoire correspond à  $n$  répétitions indépendantes de la **même distribution**.
- La loi jointe d'un  $n$ -échantillon est donc:

$$\begin{aligned}\mathbb{P}(X_1 = x_1, \dots, X_n = x_n) &= \mathbb{P}(X_1 = x_1) \times \dots \times \mathbb{P}(X_n = x_n) \\ &= \prod_i \mathbb{P}(X_i = x_i)\end{aligned}$$

## Moments d'un Echantillon i.i.d.

- les  $X_i$  ont tous la même loi donc la même espérance:

$$\forall i \in \{1, \dots, n\}, \mathbb{E}(X_i) = \mu$$

- L'espérance de  $\mathbf{X}$  est donc un vecteur de taille  $n$ :

$$\mathbb{E}(\mathbf{X}) = [\mathbb{E}(X_1), \dots, \mathbb{E}(X_n)] = \mu \times [1, \dots, 1]$$

- Variance: les  $X_i$  ont la même variance:

$$\forall i \in \{1, \dots, n\}, \mathbb{V}(X_i) = \sigma^2$$

- Covariance: les  $X_i$  sont indépendants, donc

$$\forall i \in \{1, \dots, n\}, \forall j \in \{1, \dots, n\} \text{ cov}(X_i, X_j) = 0.$$

- Matrice de Variance/Covariance  $\mathbb{V}(\mathbf{X})$  ( $n \times n$ ):  $\mathbb{V}(X_1), \dots, \mathbb{V}(X_n)$  est sur la diagonale et  $\text{cov}(X_i, X_j)$  sur les termes extra-diagonaux
- Exemple de données pour lesquelles l'hypothèse iid n'est pas valide: données temporelles, spatiales, familiales, etc

## Retour sur les tailles d'arbres

- On note  $x_i^1$  la taille de l'arbre  $i$  mesuré dans la forêt de type 1, (resp.  $x_i^2$ ).
- On suppose que  $x_i^1$  est la réalisation d'une variable aléatoire  $X_i^1$ .
- On peut supposer que les tailles des arbres sont indépendantes les unes des autres: on suppose que les  $X_i^1$  sont indépendants.
- On peut également supposer que la distribution empirique des  $x^i$  peut être approchée par une même loi.


Type 1	23.4	24.4	24.6	24.9	25	26.2	26.3	26.8	26.8	26.9	27
Type 2	22.5	22.9	23.74	24.0	24.4	24.5	25.3	26	26.4	26.7	32

# Modèle statistique et modèles de distribution

- C'est souvent l'étape la plus difficile !!! Comment choisir le modèle ?
- La première étape c'est toujours d'étudier les statistiques descriptives et les distributions empiriques pour déterminer quel type de distribution conviendrait
- Comment choisir la distribution ?
  - la nature du caractère étudié (qualitatif, ordinaux, quantitatifs)
  - les connaissances que l'on a du phénomène (valeurs supports)
  - la taille de l'échantillon
- Le modèle comporte souvent des hypothèses (notamment l'indépendance) qu'il est impératif de vérifier
- Les paramètres d'un modèle doivent toujours être interprétés.
- Dans la suite on notera  $F_\theta$  le modèle de distribution paramétré par  $\theta$  (notation générique).

# Le cadre des modèles paramétrique

- Deux stratégies possibles:
  - pas d'hypothèse sur  $F$
  - On suppose que  $F$  appartient à une famille de lois connue
- En général ces lois dépendent d'un nombre fini de paramètres qui deviennent les seules inconnues du problème
- Supposons que l'on sache identifier les paramètres d'intérêt



## Retour sur les tailles d'arbres

- On note  $x_i^1$  la taille de l'arbre  $i$  mesuré dans la forêt de type 1, (resp.  $x_i^2$ ).
- On suppose que  $x_i^1$  est la réalisation d'une variable aléatoire  $X_i^1$ .
- On peut supposer que les tailles des arbres sont indépendantes les unes des autres: on suppose que les  $X_i^1$  sont indépendants.
- On peut également supposer que la distribution empirique des  $x^i$  peut être approchée par une même loi, telle que:

$$\forall i \in \{1, \dots, n_1\}, X_i^1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$$

$$\forall i \in \{1, \dots, n_2\}, X_i^2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$$

- Etant donné qu'on a deux types de forêt, comment interpréter le modèle tel que  $\mu_1 = \mu_2$  et celui tel que  $\sigma_1 = \sigma_2$  ?

## Exemple de modèle pour données de comptage

- En période d'épizootie de péripneumonie contagieuse bovine (PPCCB), on s'intéresse au nombre de troupeaux infectés dans les départements français.
- On effectue un relevé et on obtient:

Département	Nb de troupeaux infectés
01	120
02	200
...	

- On définit  $x_i$  le nombre observé de troupeaux infectés dans le département  $i$ .
- On suppose que  $x_i$  est la réalisation d'une variable aléatoire  $X_i$ . On suppose que les  $X_i$  sont indépendants (est-ce réaliste ?)
- On suppose que les  $X_i$  sont iid, de même loi  $X_i \sim \mathcal{P}(\lambda)$ .  
Interprétation de  $\lambda$  ?

## Exemple de modèle pour des observations qualitatives-1

- On s'intéresse à la fréquence des hétérozygotes dans deux populations. Le gène d'intérêt comporte deux allèles "A" et "a".
- On génotype plusieurs individus non apparentés dans les deux populations:

pop1	"AA"	"Aa"	"Aa"	"AA"	"Aa"	"aA"
pop2	"Aa"	"aa"	"AA"	"Aa"	"aa"	"aa"

- On note  $x_i^1$  la variable qui vaut 1 si l'individu  $i$  dans la population 1 est hétérozygote, 0 sinon.
- On suppose que  $x_i^1$  est la réalisation de  $X_i^1$ . Les individus étant non apparentés, on suppose que les  $X_i^1$  sont indépendants de loi

$$\forall i \in \{1, \dots, n_1\}, X_i^1 \sim \mathcal{B}(p_1)$$

## Exemple de modèle pour des observations qualitatives-2

- A partir des mêmes données on peut poser un autre modèle
- Supposons que l'on s'intéresse à la fréquence des génotypes
- On note  $x_i^1$  la variable telle que:

$$x_i^1 = \begin{cases} 0 & \text{si } x_i^1 = \text{"AA"} \\ 1 & \text{si } x_i^1 = \text{"Aa"} \\ 2 & \text{si } x_i^1 = \text{"aa"} \end{cases}$$

- On suppose que  $x_i^1$  est la réalisation de  $X_i^1$ . Les individus étant non apparentés, on suppose que les  $X_i^1$  sont indépendants de loi

$$\forall i \in \{1, \dots, n_1\}, X_i^1 \sim \mathcal{M}(1, p_{AA}^1, p_{Aa}^1, p_{aa}^1),$$

- La loi multinomiale généralise la loi Binomiale à plus de deux modalités, avec  $p_{AA} + p_{Aa} + p_{aa} = 1$ . [▶ Modèle multinomial](#)

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés**
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments

## La somme des carrés et la notion de distance-dispersion

- L'interprétation géométrique des indicateurs statistique est un élément central de nombreuses méthodologies
- On peut considérer que  $(x_1, \dots, x_n)$  est un vecteur de taille  $n$  noté  $\mathbf{x}$
- On peut s'interroger sur la distance des observations (éléments de  $\mathbf{x}$ ) à une valeur  $m$

$$d^2(\mathbf{x}, m) = \|\mathbf{x} - m\|^2 = \sum_{i=1}^n (x_i - m)^2$$

- La somme des carrés quantifie la distance de chaque point de l'échantillon à une valeur de localisation
- $\bar{x}$  est la valeur de  $m$  qui minimise cette distance (centre de gravité)

$$d^2(\mathbf{x}, \bar{x}) = \min_m \|\mathbf{x} - m\|^2$$

## Distance au modèle

- Une fois le modèle choisi, il faut confronter le modèle aux données
- La première étape consiste souvent à estimer le paramètre d'espérance (position)
- On considère un modèle de distribution tel que  $X_i \sim F$  d'espérance


$$\mathbb{E}(\mathbf{X}) = \mu$$

- On cherche donc la quantité  $m$  qui minimise la somme des carrés:

$$d^2(\mathbf{X}, m) = \|\mathbf{X} - m\|^2 = \sum_{i=1}^n (X_i - m)^2$$

- L'idée centrale de la démarche est de considérer que les données sont figées et que c'est le modèle qui bouge

# Notion de distance au modèle



## Exemples d'estimation par moindres-carrés

- On a posé un modèle gaussien sur la taille des arbres tel que

$$X_i^1 \sim \mathcal{N}(\mu_1, \sigma_1^2).$$

- On souhaite estimer  $\mu_1$  par moindres carrés:

Type 1	23.4	24.4	24.6	24.9	25	26.2	26.3	26.8	26.8	26.9	27
--------	------	------	------	------	----	------	------	------	------	------	----

$$\begin{aligned} d^2(\mathbf{x}, \mu_1) &= (x_1^1 - \mu_1)^2 + (x_2^1 - \mu_1)^2 \dots + (x_{12}^1 - \mu_1)^2 \\ &= (23.4 - \mu_1)^2 + (24.4 - \mu_1)^2 \dots + (27 - \mu_1)^2 \end{aligned}$$

- C'est une fonction de  $\mu_1$ . Pour trouver le  $\hat{\mu}_1$  qui minimise ce critère, on dérive et on annule la dérivée. On trouve bien la moyenne empirique:

$$\hat{\mu}_1(\mathbf{x}) = \bar{\mathbf{x}} = 25.66$$

# Un estimateur est une variable aléatoire

Ech	1	2	3	4	5	6	7	8	9	10	$\hat{\mu}$
1	23.4	24.4	24.6	24.9	25	26.2	26.3	26.8	26.8	26.9	25.53
2	25.51	24.14	28.16	26.42	22.40	24.71	23.04	26.26	24.78	26.03	25.14
3	27.02	24.90	24.57	25.68	26.87	29.23	24.91	24.87	24.41	27.44	25.99
4	25.80	24.76	25.82	26.97	26.71	25.74	25.18	25.90	24.00	26.59	25.75
⋮											
⋮											

- Si on répétait la mesure sur 10 autres arbres du même type de forêt, alors on obtiendrait des estimations différentes.
- Pour un échantillon donné, nous n'avons qu'une réalisation de l'estimateur

## Pourquoi s'intéresse-t-on à la loi de l'estimateur ?

- Si on ne disposait pas d'un modèle, on pourrait quand même accéder à  $\bar{x}$
- Intuitivement on se demande toujours si cette estimation est précise ou non.
- Exemple: si le taux d'incidence de la grippe dépasse un pourcentage, on lance une campagne de vaccination
- L'idée sous jacente est de s'interroger sur le nombre d'individus nécessaires pour obtenir une estimation précise

## Paramètre / Estimateur / Estimation

- $\mu$  est le paramètre de la loi  $F$  qui a été choisie pour décrire les observations
- $\hat{\mu}(\mathbf{x}) = \bar{x}$  est une estimation: sa valeur dépend de l'échantillon  $\mathbf{x}$
- $\hat{\mu}(\mathbf{X}) = \bar{X}$  est un estimateur. C'est une statistique qui est une fonction de  $\mathbf{X}$
- $\bar{X}$  est une variable aléatoire dont la loi est définie par le modèle  $F$
- On peut donc caractériser un estimateur par son espérance  $\mathbb{E}(\hat{\mu}(\mathbf{X}))$  et sa variance  $\mathbb{V}(\hat{\mu}(\mathbf{X}))$

## Estimateur de l'espérance dans le cas Gaussien

- On observe  $\mathbf{x}$  et on suppose qu'il constitue une réalisation d'un  $n$ -échantillon iid  $\mathbf{X}$ , avec  $X_i \sim \mathcal{N}(\mu, \sigma^2)$
- On estime  $\mu$  par  $\bar{X}$ :

$$\hat{\mu}(\mathbf{X}) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

- L'espérance de l'estimateur de l'espérance:

$$\mathbb{E}(\hat{\mu}(\mathbf{X})) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) = \frac{1}{n} (n \times \mu) = \mu$$

- La variance de l'estimateur de l'espérance (avec l'hypothèse iid)

$$\mathbb{V}(\hat{\mu}(\mathbf{X})) = \frac{1}{n^2} \sum_{i=1}^n \mathbb{V}(X_i) = \frac{1}{n^2} (n \times \sigma^2) = \frac{\sigma^2}{n}$$

# Interprétation

- $\frac{\sigma^2}{n}$  est la variance de l'estimateur  $\hat{\mu}(\mathbf{X})$  de l'espérance  $\mu$
- Plus  $n$  augmente, plus on est précis dans la caractérisation du paramètre  $\mu$
- La loi de  $\hat{\mu}(\mathbf{X})$  est donnée par le modèle (somme de Gaussiennes iid)

$$\hat{\mu}(\mathbf{X}) = \bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$$

- On peut aussi considérer sa version centrée réduite:

$$\frac{\hat{\mu}(\mathbf{X}) - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$$

## Qu'est ce qu'un bon estimateur?

- On considère un paramètre  $\theta$  qui caractérise une loi de probabilité  $F_\theta$
- On observe  $\mathbf{x}$  une réalisation de  $\mathbf{X}$  et on suppose que  $X_i \sim F_\theta$
- On construit un estimateur  $\hat{\theta}(\mathbf{X})$  de  $\theta$
- On définit le **bias** et la **variance** de l'estimateur :

$$B(\theta, \hat{\theta}(\mathbf{X})) = \mathbb{E}_\theta(\hat{\theta}(\mathbf{X})) - \theta, \quad V(\theta, \hat{\theta}(\mathbf{X})) = \mathbb{E}_\theta \left( [\hat{\theta}(\mathbf{X}) - \mathbb{E}_\theta(\hat{\theta}(\mathbf{X}))]^2 \right)$$

- On peut également définir les carrés moyens comme un **Risque** pour un estimateur:

$$R(\theta, \hat{\theta}(\mathbf{X})) = \mathbb{E}_\theta(\hat{\theta}(\mathbf{X}) - \theta)^2 = B^2(\theta, \hat{\theta}(\mathbf{X})) + V(\theta, \hat{\theta}(\mathbf{X}))$$

- Un bon estimateur sera caractérisé par un faible risque (biais faible ou nul et variance minimale).

# Le Théorème Limite Central


- Si les  $X_i$  sont des variables aléatoires iid, si leur espérance  $\mu$ , et leur variance  $\sigma^2$  existent alors

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$$

- Interprétation: même si les observations ne sont pas modélisées par une loi Gaussienne, l'estimateur de l'espérance fondé sur  $\bar{X}$  pourra être considéré comme gaussien si le nombre d'observations est suffisant.

Utiliser les moments empiriques + le TLC permet de construire un estimateur et d'avoir sa loi asymptotique !

# Le Théorème Limite Central



## Exemple dans le cas Bernoulli-1

- On observe  $(x_1, \dots, x_n)$  et on suppose que cet échantillon constitue une réalisation de  $n$  variables aléatoires indépendantes et identiquement distribuées (iid)  $(X_1, \dots, X_n)$ , avec  $X_i \sim \mathcal{B}(p)$
- La loi de  $Y$  le nombre de succès observés sur  $n$  expériences:

$$Y = \sum_{i=1}^n X_i \sim \mathcal{B}(n, p)$$

- On choisit  $\hat{p}(\mathbf{X}) = \bar{X}$  comme estimateur de la probabilité de succès  $p$
- On peut caractériser son espérance et sa variance:

$$\mathbb{E}(\hat{p}(\mathbf{X})) = p \quad \mathbb{V}(\hat{p}(\mathbf{X})) = \frac{p(1-p)}{n}$$

## Exemple dans le cas Bernoulli-2

- Le TCL est un théorème **asymptotique**, quand le nombre d'observations est suffisant ( $np > 5$ ).

Grâce au TCL on peut supposer:

$$\frac{\hat{p}(\mathbf{X}) - p}{\sqrt{p(1-p)}} \times \sqrt{n} \sim \mathcal{N}(0, 1)$$

## Estimateur de la variance dans le cas Gaussien

- On observe  $\mathbf{x}$  et on suppose qu'il constitue une réalisation d'un  $n$ -échantillon iid  $\mathbf{X}$ , avec  $X_i \sim \mathcal{N}(\mu, \sigma^2)$
- On estime  $\sigma^2$  par  $S_n^2(\mathbf{X}) = \overline{X^2} - \bar{X}^2$ . C'est un ▶ estimateur de type moment
- C'est un estimateur biaisé:  $\mathbb{E}(S_n^2(\mathbf{X})) = \frac{n-1}{n}\sigma^2$
- On peut considérer un autre estimateur (sans biais)

$$S_{n-1}^2(\mathbf{X}) = \frac{1}{n-1} \sum_i (X_i - \bar{X})^2$$

- La loi de  $S_{n-1}^2(\mathbf{X})$  est une ▶ loi du chi2 (somme de Gaussiennes iid au carré)

$$S_{n-1}^2(\mathbf{X}) \sim \sigma^2 \chi^2(n-1)$$

## Pour la culture (et la suite)

- Il existe différentes techniques d'estimation, la technique des moindres-carrés n'est qu'un exemple
- On peut citer la technique du maximum de vraisemblance qui est une des plus utilisées
- Les estimateurs de type moment qui consistent à identifier moments théoriques et empiriques
- L'estimation robuste qui permet de limiter l'influence des outliers

▶ maximum de vraisemblance

▶ estimateur de type moment

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur**
- 8 Compléments

## Limite de l'estimation ponctuelle

- Les données récoltées permettent d'obtenir *une* estimation d'un paramètre (par exemple une estimation de l'espérance de la taille d'individus).
- On sait que la valeur observée de l'estimateur change en fonction des données.
- Cette estimation s'appelle *estimation ponctuelle*. Quelles conclusions peut-on en tirer ?
- On préfère raisonner en terme d'intervalle avec un risque que le vrai paramètre ne soit pas compris dans l'intervalle considéré
- On cherche un ensemble de valeurs que l'on peut raisonnablement attribuer au paramètre.

## Construction de l'intervalle

- Considérons l'estimation du paramètre d'espérance  $\mu$  d'une loi gaussienne à partir d'un échantillon  $\mathbf{X}$ .
- On souhaite quantifier la probabilité que le paramètre  $\mu$  tombe dans un intervalle au vu des données:

$$\mathbb{P}\{\mu \in [A(\mathbf{X}), B(\mathbf{X})]\}$$

- On souhaiterait ensuite contrôler cette probabilité, en fixant un risque  $\alpha$  que le "vrai" paramètre n'appartienne pas à l'intervalle:

$$\mathbb{P}\{\mu \in [A(\mathbf{X}), B(\mathbf{X})]\} = 1 - \alpha$$

- L'intervalle considéré est un **intervalle aléatoire** dont les bornes varient d'un échantillon à un autre.

## Vers les intervalles de confiance

- Pour déterminer les bornes de l'intervalle, on va considérer la loi de l'estimateur du paramètre:

$$\frac{\widehat{\mu}(\mathbf{X}) - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$$

- Etant donné la loi de l'estimateur, on connaît ses quantiles. On note souvent  $u_\alpha$  le quantile d'ordre  $\alpha$  de la loi gaussienne centrée réduite.
- En supposant  $\sigma$  connue, on a donc:

$$\mathbb{P} \left\{ \frac{\widehat{\mu}(\mathbf{X}) - \mu}{\sigma/\sqrt{n}} \in [u_{\alpha/2}; u_{1-\alpha/2}] \right\} = 1 - \alpha$$

- On peut donc construire un intervalle de confiance de  $\mu$  à partir de l'intervalle de dispersion de son estimateur

## Intervalle de confiance pour le paramètre d'espérance à variance connue

- A partir de l'intervalle de dispersion de  $\hat{\mu}(\mathbf{X})$ :

$$\mathbb{P} \left\{ \frac{\hat{\mu}(\mathbf{X}) - \mu}{\sigma/\sqrt{n}} \in [u_{\alpha/2}; u_{1-\alpha/2}] \right\} = 1 - \alpha$$

- On peut donc construire un intervalle de confiance de  $\mu$ :

$$\hat{\mu}(\mathbf{X}) - u_{1-\alpha/2} \times \frac{\sigma}{\sqrt{n}} \leq \mu \leq \hat{\mu}(\mathbf{X}) - u_{\alpha/2} \times \frac{\sigma}{\sqrt{n}}$$

- Pour les **distributions symétriques**:  $u_{\alpha/2} = -u_{1-\alpha/2}$ .
- Les bornes de l'intervalle sont donc:

$$A(\mathbf{X}) = \hat{\mu}(\mathbf{X}) - u_{1-\alpha/2} \times \frac{\sigma}{\sqrt{n}}$$

$$B(\mathbf{X}) = \hat{\mu}(\mathbf{X}) + u_{1-\alpha/2} \times \frac{\sigma}{\sqrt{n}}$$

## Intervalle de confiance pour le paramètre d'espérance à variance inconnue

- Si la variance est inconnue, on doit l'estimer avec  $S^2(\mathbf{X})$ .
- Dans ce cas les fluctuations de l'estimateur autour de son espérance n'ont plus la même loi:

$$\frac{\hat{\mu}(\mathbf{X}) - \mu}{S(\mathbf{X})} \sqrt{n} \sim \mathcal{T}(n-1)$$

- Les bornes de l'intervalle sont donc modifiées et utilisent les quantiles de la [loi de Student](#) :

$$A(\mathbf{X}) = \hat{\mu}(\mathbf{X}) - t_{1-\alpha/2, n-1} \times \frac{S(\mathbf{X})}{\sqrt{n}}$$
$$B(\mathbf{X}) = \hat{\mu}(\mathbf{X}) + t_{1-\alpha/2, n-1} \times \frac{S(\mathbf{X})}{\sqrt{n}}$$

## Application aux tailles d'arbres

Type 1	23.4	24.4	24.6	24.9	25	26.2	26.3	26.8	26.8	26.9	27
Type 2	22.5	22.9	23.74	24.0	24.4	24.5	25.3	26	26.4	26.7	.

	Moyenne	Ecart-type	nb obs	$t_{1-\alpha/2, n-1}$	$A(\mathbf{X})$	$B(\mathbf{X})$
Type 1	25.66	1.24	11	2.23	24.82	26.49
Type 2	24.64	1.43	10	2.26	23.62	25.66

- On obtient deux intervalles de confiance au niveau  $\alpha = 5\%$

$$IC_{1-\alpha}(\mu_1) = [24.82, 26.49] \quad IC_{1-\alpha}(\mu_2) = [23.62, 25.66]$$

- Est ce que :

$$\mathbb{P}\{\mu_1 \in [24.82, 26.46]\} = 1 - \alpha ?$$

## Intervalle de confiance pour une proportion

- Dans le modèle de Bernoulli, pour avoir accès aux quantiles, on utilise en général l'approximation gaussienne grâce au TCL:

$$\frac{\hat{p}(\mathbf{X}) - p}{\sqrt{p(1-p)}} \times \sqrt{n} \sim \mathcal{N}(0, 1)$$

- Cette approximation donne les bornes de l'intervalle de confiance d'une proportion tel que:  $\mathbb{P}\{p \in [A(\mathbf{X}), B(\mathbf{X})]\} = 1 - \alpha$
- Avec l'approximation gaussienne, on a:

$$A(\mathbf{X}) = \hat{p}(\mathbf{X}) - u_{1-\alpha/2} \sqrt{\frac{\hat{p}(\mathbf{X})(1 - \hat{p}(\mathbf{X}))}{n}}$$

$$B(\mathbf{X}) = \hat{p}(\mathbf{X}) + u_{1-\alpha/2} \sqrt{\frac{\hat{p}(\mathbf{X})(1 - \hat{p}(\mathbf{X}))}{n}}$$

- On a estimé la variance de l'estimateur par

$$\frac{\hat{p}(\mathbf{X})(1 - \hat{p}(\mathbf{X}))}{n}$$

# Outline

- 1 Notion d'échantillon
- 2 La distribution empirique
- 3 Les moments empiriques
- 4 Notion de quantiles et exceptionalité
- 5 Modélisation Aléatoire
- 6 Estimation par Moindre-Carrés
- 7 Intervalle de confiance d'un estimateur
- 8 Compléments**

## Variables aléatoires discrètes

- Les valeurs prises ( $X(\Omega)$ ) par les variables sont discrètes (comptages, modalités,...)
- Leur loi est complètement déterminée par  $\mathbb{P}(X = k)$  pour tous les  $k$  dans  $X(\Omega)$ , avec

$$\sum_{k \in X(\Omega)} \mathbb{P}(X = k) = 1$$

- On note  $F$  la fonction de répartition de  $X$  définie par

$$F_X(k) = \mathbb{P}\{X \leq k\}$$

- L'espérance et la variance des lois discrètes sont définies par

$$\mathbb{E}(X) = \sum_{k \in X(\Omega)} k \mathbb{P}(X = k), \quad \mathbb{V}(X) = \sum_{k \in X(\Omega)} (k - \mathbb{E}(X))^2 \mathbb{P}(X = k)$$

- Exemples: loi de Bernoulli, Binomiale, de Poisson, Géométrique

## Variables aléatoires continues

- Les valeurs prises ( $X(\Omega)$ ) par les variables appartiennent à des ensembles continus : la probabilité d'un point est nulle !
- On raisonnera plutôt par intervalle :  $\mathbb{P}(X \in [a, b]) = \mathbb{P}(a \leq X \leq b)$
- La loi d'une variable continue est définie par sa densité  $f \geq 0$  ou par sa fonction de répartition  $F$ :

$$\int_{X(\Omega)} f(x)dx = 1, \quad F(t) = \mathbb{P}(X \leq t)$$

- L'espérance et la variance des lois continues sont définies par

$$\mathbb{E}(X) = \int_{X(\Omega)} xf(x)dx, \quad \mathbb{V}(X) = \int_{X(\Omega)} (x - \mathbb{E}(X))^2 f(x)dx$$

- Exemples: loi normale, exponentielle, gamma, Cauchy (pas d'espérance)

## Les tables de la loi (normale et autres !)

- C'est un outil de base qui donne les quantiles et la fonction de répartition ( $\Phi$ ) de la loi normale **centrée réduite**
- Si on considère une variable  $X \sim \mathcal{N}(\mu, \sigma^2)$ , on se ramènera toujours à la loi centrée réduite

$$Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1)$$

- Si on souhaite calculer :  $\mathbb{P}\{X \leq x\}$

$$\mathbb{P}\left\{\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right\} = \mathbb{P}\left\{Z \leq \frac{x - \mu}{\sigma}\right\} = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

- Il existe des tables pour beaucoup de lois usuelles (Fisher,  $\chi^2$ ...)

## La loi du chi2 et loi des sommes de carrés

- C'est la loi du carré de variables gaussiennes: si  $X_i \sim \mathcal{N}(0, 1)$  alors  $X_i^2 \sim \chi^2(1)$
- Si on considère  $(X_1, \dots, X_k)$  iid de même loi  $\mathcal{N}(0, \sigma^2)$  alors

$$S^2 = \sum_i X_i^2 \sim \sigma^2 \chi^2(k), \quad \mathbb{E}(S^2) = k, \quad \mathbb{V}(S^2) = 2k$$

- Si on considère un vecteur aléatoire gaussien iid  $\mathbf{X}$ , la loi du  $\chi^2$  est la loi de la norme  $\|\mathbf{X}\|^2$
- $k$  est appelé le degré de liberté (ddl, dF) : c'est le nombre de composantes **indépendantes** de  $S^2$

## Moments d'une loi

- On considère un modèle  $\mathcal{M}_\theta$  de loi  $F_\theta$  avec  $\theta \in \mathbb{R}^d$  par exemple
- Les moments **théoriques** caractérisent totalement la loi  $F_\theta$ , et sont définis par:

$$\mathbb{E}_\theta(X^\ell) = \int x^\ell f_\theta(x) dx, \quad \mathbb{E}_\theta(X^\ell) = \sum x^\ell \mathbb{P}_\theta(X = x)$$

- Si on considère que  $\theta$  paramétrise la loi de  $X$  alors on peut trouver une relation entre  $\theta$  et  $(\mathbb{E}_\theta(X^\ell))_\ell$
- Exemple dans le cas gaussien  $\theta = (\mu, \sigma^2)$ :

$$\mathbb{E}_\theta(X^1) = \mu, \quad \mathbb{E}_\theta(X^2) = \sigma^2 + (\mathbb{E}_\theta(X^1))^2$$

- En inversant le système on peut relier les moments aux paramètres

## Moments empiriques / Moments théoriques

- Les moments **théoriques** caractérisent totalement une loi, et sont définis par:

$$\mathbb{E}_\theta(X^k) = \int x^k f_\theta(x) dx, \quad \mathbb{E}_\theta(X^k) = \sum x^k \mathbb{P}_\theta(X = x)$$

Exemples : l'espérance  $\mu$  et la variance  $\sigma^2$

- Les moments **empiriques** sont des fonctions des observations:

$$m_k(x_1, \dots, x_n) = \frac{1}{n} \sum_i x_i^k = \bar{x}^k$$

Exemples : la moyenne  $\bar{x}$  et la variance empirique  $s^2$

## De l'intérêt du modèle

- Comment relier les moments empiriques et théoriques?

on suppose que la loi empirique des observations  $(x_1, \dots, x_n)$  peut être approchée par la loi théorique de  $(X_1, \dots, X_n)$  sous le modèle  $\mathcal{M}_\theta$

- Quelles seraient les propriétés des moments empiriques sous  $\mathcal{M}_\theta$  ?

$$M_k(X_1, \dots, X_n) = \frac{1}{n} \sum_i X_i^k$$

- Sous  $\mathcal{M}_\theta$  les moments empiriques sont des variables aléatoires !
- Exemple :  $M_1(X_1, \dots, X_n) = \bar{X}$ ,  $S^2 = \overline{X^2} - M_1^2(X_1, \dots, X_n)$

La loi de  $M_k(X_1, \dots, X_n)$  est déterminée par le modèle  $\mathcal{M}_\theta$

## Le modèle multinomial

- On note  $N = (N_1, \dots, N_k)$  un vecteur de comptages aléatoires t.q.  
 $\sum_k N_k = n$ .
- On dit que  $N \sim \mathcal{M}(n, p_1, \dots, p_k)$  si, pour  $\sum_{j=1}^k p_j = 1$ , et  
 $\sum_{j=1}^k n_j = n$

$$\mathbb{P}\{N_1 = n_1, \dots, N_k = n_k\} = \frac{n! p_1^{n_1} \dots p_k^{n_k}}{n_1! \dots n_k!},$$

- Cette loi modélise  $n$  tirages consécutifs avec remise dans une urne à  $k$  catégories  $n_1$  boules de type 1, ...  $n_k$  boules de type  $k$ , avec des boules de type  $j$  en proportion  $p_j$  dans l'urne.
- Du fait de la contrainte  $\sum_{j=1}^k n_j = n$ , les comptages de différentes catégories ne sont pas indépendants !

$$\text{cov}(N_j, N_{j'}) = -p_j p_{j'}$$

## Notion de vraisemblance

- On appelle vraisemblance du modèle  $\mathcal{M}_\theta$  au vu de l'observation  $(x_1, \dots, x_n)$  la fonction de densité ayant servi à définir le modèle,

$$\mathcal{L}_x(\mathcal{M}_\theta) = \mathbb{P}_{\mathcal{M}_\theta}(x_1, \dots, x_n)$$

- C'est une fonction de l'échantillon  $\mathbf{x}$  et de  $\theta$ . La démarche statistique consiste à considérer que c'est une fonction de  $\theta$ , les données  $\mathbf{x}$  étant considérées comme "fixées"
- Dans le cas d'un échantillon i.i.d. la vraisemblance devient:

$$\mathcal{L}_x(\theta) = \mathbb{P}_\theta(x_1, \dots, x_n) \stackrel{iid}{=} \prod_{i=1}^n \mathbb{P}_\theta(x_i; \theta)$$

## Exemple dans le cas Binomial

- On considère un échantillon de 20 patients dans lequel 5 malades sont observés
- $p$  le pourcentage de malades dans la population
- Dans un modèle Binomial  $\mathbb{P}(X = k) = C_n^k p^k (1 - p)^{n-k}$
- La vraisemblance de l'échantillon :

$$\mathcal{L}(\mathbf{x}; p) = C_{20}^5 p^5 (1 - p)^{20-5}$$

- $\mathcal{L}(\mathbf{x}; p = 0.1) = 0.03$ ,  $\mathcal{L}(\mathbf{x}; p = 0.25) = 0.2$
- La probabilité jointe de l'échantillon est plus élevée quand la valeur du paramètre est 0.25.

# Probabilités ou Statistiques ?

- La démarche est théorique, n'a besoin d'aucune "réalité"
- La démarche est déductive : on fait des hypothèses et on démontre des théorèmes mathématiques
- Fixe  $\theta$  et étudie  $\mathbb{P}_\theta(\mathbf{x})$
- La démarche est liée aux observations  $\mathbf{x}$
- La démarche est inductive : elle part des  $\mathbf{x}$  et remonte à la loi qui les a engendrées
- Dispose de  $\mathbf{x}$  (fixe!), et étudie  $\theta$  avec  $\mathcal{L}_\mathbf{x}(\theta)$

On parle de **probabilité d'une observation**

On parle de **vraisemblance d'un modèle**

## L'estimateur du maximum de vraisemblance

- Si on considère le modèle  $\mathcal{M}_\theta$ , plusieurs valeurs de  $\theta$  sont possibles
- Lorsqu'on dispose d'observations, on peut alors chercher le "meilleur modèle", celui dont la vraisemblance est la meilleure:

$$\hat{\theta}(\mathbf{x}) = \arg \max_{\theta \in \Theta} \{\mathcal{L}_x(\theta)\}$$

- La maximisation de la vraisemblance nécessite la résolution de l'équation:

$$\frac{\partial \log \mathcal{L}_x(\theta)}{\partial \theta} = 0$$

- L'estimateur du maximum de vraisemblance  $\hat{\theta}(\mathbf{x})$  est la solution de cette équation

## Exemple dans le cas Gaussien

- On observe  $(x_1, \dots, x_n)$  et on suppose que cet échantillon constitue une réalisations de  $n$  variables aléatoires indépendantes et identiquement distribuées (iid)  $(X_1, \dots, X_n)$ , avec  $X_i \sim \mathcal{N}(\mu, \sigma^2)$
- La vraisemblance du modèle est définie par

$$\mathbb{P}_{\mathcal{M}_\theta}(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \mu, \sigma^2) = \frac{1}{\sigma^n \sqrt{2\pi}} \exp\left(-\frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}\right)$$

- L'estimateur du maximum de vraisemblance de l'espérance  $\hat{\mu}^{\text{MV}}$  est obtenu en résolvant l'équation

$$\frac{\partial \log \mathbb{P}_{\mathcal{M}_\theta}(x_1, \dots, x_n)}{\partial \mu} = 0$$

- Dans le cas Gaussien  $\hat{\mu}^{\text{MV}} = \bar{X}$  !

# Loi de Student

- Si  $U$  est une variable aléatoire telle que  $U \sim \mathcal{N}(0, 1)$ , et  $V$  est une variable aléatoire telle que  $U \sim \chi^2(n)$ . On suppose que  $U$  et  $V$  sont indépendantes
- La variable aléatoire  $T = U/\sqrt{V/n}$  est distribuée suivant une loi de Student à  $n$  degrés de libertés:

$$T \sim \mathcal{T}(n)$$

- Les moments de cette loi sont:

$$\mathbb{E}(T) = 0, \quad \mathbb{V}(T) = n/(n-2)$$