

### 3. Idées fondamentales de la statistique

# Modèles statistiques

On étudie une **population** (ensemble d'individus ou d'éléments) à partir d'un **échantillon** (sous-ensemble).

- **modèle statistique** :  $X$  = la quantité étudiée (variable aléatoire); la loi  $F$  de  $X$  est supposée connue sauf un nombre fini de paramètres  $\theta$
- **échantillon** (doit être représentatif de la population) : “données”  $x_1, \dots, x_n$ , souvent supposées comme étant une réalisation de  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} F$  (**indépendantes et identiquement distribuées**) ou  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} f$
- **statistique** : une fonction  $T_n = h(X_1, \dots, X_n)$  des variables aléatoires  $X_1, \dots, X_n$
- **estimateur** : une statistique utilisée pour estimer certains paramètres de  $F$
- **Notations** :

$$T_n = h(X_1, \dots, X_n)$$

est la statistique (variable aléatoire)

$$t_n = h(x_1, \dots, x_n)$$

est la **réalisation** de  $T_n$  au moyen des  $x_i$

$$\hat{\theta} \text{ ou } \hat{\theta}_n$$

est un **estimateur** d'un paramètre  $\theta$

## Remarques

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$  et  $x_1, \dots, x_n$  une réalisation correspondante. Alors


- $\hat{\mu}_n = \bar{X}_n$  est un estimateur de  $\mu$ , dont la valeur observée est  $\bar{x}_n$
- $\hat{\sigma}^2 = n^{-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ , est un estimateur de  $\sigma^2$ , dont la valeur observée est  $n^{-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$

**Remarques :**

- une statistique  $T_n$  étant fonction des variables aléatoires  $X_1, \dots, X_n$ , c'est elle-même une variable aléatoire !
- La loi de  $T_n$  dépend de la loi des  $X_i$ , et est appelée **distribution d'échantillonnage de  $T_n$**
- Si on ne peut pas déduire la loi de  $T_n$  de celle des  $X_i$ , on doit se contenter parfois de connaître  $\mathbb{E}(T_n)$  et  $\text{var}(T_n)$ , ou, si  $T_n$  est liée à  $\bar{X}_n$ , l'approximer à l'aide de  $\mathbb{E}(X)$  et  $\text{var}(X)$  et le théorème central limite

# Loi d'échantillonnage

Histogramme de 1000 réalisations de  $\bar{X}_n = \frac{1}{10}(X_1 + \dots + X_{10})$  où les  $X_i \stackrel{\text{iid}}{\sim} \exp(1)$



# Problèmes attaqués par la statistique

On suppose un **modèle** (c'est à dire une famille de distributions  $f(x; \theta)$ ) et on souhaite

- **estimer** les paramètres  $\theta$  de ce modèle
- poser des questions au sujet de la valeur de ces paramètres, par exemple **tester** si  $\theta = 0$
- **prédire** les valeurs des observations futures

Il existe plusieurs méthodes pour estimer les paramètres d'un modèle. On va décrire les suivantes :

- **méthode des moments** (simple)
- **méthode du maximum de vraisemblance** (souvent utilisée car optimale dans beaucoup de situations)

## 3.1 Estimation de paramètres

# Méthode des moments

- Supposons que l'échantillon tiré soit représentatif de la population
- Pour obtenir des estimateurs pour les paramètres inconnus de la population, on égalise les "moments" de l'échantillon ("empirique") à ceux de la population ("théorique")
- $k$ ème moment
  - Population ("théorique") :  $m_k = \mathbb{E}_\theta(X^k) = m_k(\theta)$ . Comme la loi de  $X$  dépend de  $\theta$ ,  $m_k = m_k(\theta)$
  - Echantillon ("empirique") :  $\widehat{m}_k = \frac{1}{n} \sum_{i=1}^n X_i^k$
  - L'estimateur des moments s'obtient on égalisant  $m_k$  et  $\widehat{m}_k$ , ce qui donne des équation(s) pour  $\theta \in \mathbb{R}^p$
  - Par exemple  $m_1(\theta) = \mathbb{E}_\theta(X) = \sum_{i=1}^n X_i/n$
- On a donc besoin d'autant de moments (supposés finies !) que de paramètres inconnus

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} U(0, \theta)$ . Estimer  $\theta$ .

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ . Estimer  $\mu$  et  $\sigma^2$ .

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} U(0, \theta)$ . Estimer  $\theta$ .

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ . Estimer  $\mu$  et  $\sigma^2$ .

# Méthode du maximum de vraisemblance

**Définition:** Soient  $x_1, \dots, x_n$  des données supposées être une réalisation d'un échantillon aléatoire  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} f(x; \theta)$ . La **vraisemblance** pour  $\theta$  est la fonction

$$L(\theta) = f(x_1; \theta) \times f(x_2; \theta) \times \cdots \times f(x_n; \theta) = \prod_{i=1}^n f(x_i; \theta).$$

$f$  est la fonction de densité ou de masse (on suppose qu'elle existe)

**Définition:** L'**estimateur du maximum de vraisemblance** (maximum likelihood)  $\hat{\theta}_{\text{ML}}$  d'un paramètre  $\theta$  est celui qui maximise la fonction de vraisemblance parmi tous les  $\theta$  possibles :

$$L(\hat{\theta}_{\text{ML}}) \geq L(\theta) \quad \text{pour tout } \theta$$

Il est plus facile de maximiser  $\ell(\theta) := \log L(\theta)$ , souvent en résolvant  $d\ell(\theta)/d\theta = 0$ , et vérifiant qu'il s'agit bien d'un maximum (par exemple si la deuxième dérivée est négative  $d^2\ell(\theta)/d\theta^2 < 0$ )

**Exemple**  $x_1, \dots, x_n$  réalisations d'une loi  $\exp(\lambda)$  avec  $\lambda > 0$ . Estimer  $\lambda$

## Exemple : maximum de vraisemblance

**Exemple** Supposons que  $x_1, \dots, x_n$  soient des réalisations i.i.d. d'une loi exponentielle,

$$f(x; \lambda) = \lambda e^{-\lambda x}, \quad x \geq 0, \quad \lambda > 0.$$

Trouver  $\hat{\lambda}_{ML}$ .

## Erreur quadratique moyenne

**Définition:** L'**erreur quadratique moyenne** de l'estimateur  $\hat{\theta}$  de  $\theta$  est

$$\text{EQM}_\theta(\hat{\theta}) = \mathbb{E}_\theta\{(\hat{\theta} - \theta)^2\} = \dots = \text{Var}_\theta(\hat{\theta}) + [b_\theta(\hat{\theta})]^2,$$

où  $b_\theta(\hat{\theta}) = \mathbb{E}_\theta(\hat{\theta}) - \theta$  est le **biais** de  $\hat{\theta}$

- La distribution de  $\hat{\theta}$  dépend de celle des  $X_i$  et donc de  $\theta$
- Si  $\hat{\theta}$  et  $\hat{\theta}'$  sont deux estimateurs du même paramètre  $\theta$  et  $\text{EQM}_\theta(\hat{\theta}) \leq \text{EQM}_\theta(\hat{\theta}')$ , on préfère  $\hat{\theta}$
- si  $b_\theta(\hat{\theta}) < 0$ , alors  $\hat{\theta}$  sous-estime  $\theta$
- si  $b_\theta(\hat{\theta}) > 0$ , alors  $\hat{\theta}$  sur-estime  $\theta$
- si  $b_\theta(\hat{\theta}) \equiv 0$ , alors  $\hat{\theta}$  est **non biaisé**, et  $\text{EQM}_\theta(\hat{\theta}) = \text{var}(\hat{\theta})$

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ . La médiane  $M_n$  et la moyenne  $\bar{X}_n$  sont (à peu près) non-biaisés pour  $\mu$  mais  $\text{var}(M_n) > \text{var}(\bar{X}_n)$ . Lequel des estimateurs  $\bar{X}_n$  et  $M_n$  de  $\mu$  est préférable ? Et si des valeurs aberrantes peuvent apparaître ?

# Biais et variance

High bias, low variability



Low bias, high variability



High bias, high variability



The ideal: low bias, low variability



- $\theta$  = “bulle centrale”, supposée être la vraie valeur
- fléchettes rouges = réalisations de  $\hat{\theta}$  qui estime  $\theta$

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ ,  $\hat{\mu} = \bar{X}_n$ , et  $\hat{\sigma}_n^2 = n^{-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ . On admet que  $\text{var}_{\mu, \sigma^2}(\sum_{i=1}^n (X_i - \bar{X}_n)^2) = 2\sigma^4(n-1)$ . Trouver le biais et la variance de  $\hat{\mu}$ . Trouver les valeurs de  $a$  qui minimisent le biais, la variance, et la EQM, pour  $\hat{\sigma}^a := a\hat{\sigma}_n^2$ .

## Biais et variance : exemple

**Exemple** Soient  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ ,  $\hat{\mu} = \bar{X}_n$ , et  $\hat{\sigma}_n^2 = n^{-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ . On admet que  $\text{var}_{\mu, \sigma^2}(\sum_{i=1}^n (X_i - \bar{X}_n)^2) = 2\sigma^4(n-1)$ . Trouver le biais et la variance de  $\hat{\mu}$ . Trouver les valeurs de  $a$  qui minimisent le biais, la variance, et la EQM, pour  $\hat{\sigma}^a := a\hat{\sigma}_n^2$ .



## Retour sur le maximum de vraisemblance

- Soient  $x_1, \dots, x_n$  des données supposées être une réalisation d'un échantillon aléatoire  $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} f(x; \theta)$  (densité / masse). La **vraisemblance** pour  $\theta$  est la fonction


$$L(\theta) = f(x_1; \theta) \times f(x_2; \theta) \times \dots \times f(x_n; \theta) = \prod_{i=1}^n f(x_i; \theta).$$

- $\hat{\theta}_{\text{ML}}$  satisfait

$$L(\hat{\theta}_{\text{ML}}) \geq L(\theta) \quad \text{pour tout } \theta$$

- Interprétation** : dans le cas discret, on maximise  $\text{Pr}_\theta(X_1 = x_1, \dots, X_n = x_n)$
- Il est plus facile de maximiser  $\ell(\theta) := \log L(\theta)$ , souvent en résolvant  $d\ell(\theta)/d\theta = 0$ , et vérifiant qu'il s'agit bien d'un maximum

## La vraisemblance est une fonction aléatoire



Fonctions de vraisemblances correspondant à 50 échantillons de taille  $n = 40$ . La vraie valeur est  $\theta = 0$  et les 50 maxima sont en rouge.

## Distribution asymptotique/approximative de $\hat{\theta}_{ML}$

- Dans des modèles "réguliers" (normal, exponentiel, Poisson, ...) on a  $\ell'(\hat{\theta}_{ML}) = 0$
- Comme  $\ell(\theta)$  est une somme de variables aléatoires iid, le théorème central limite s'applique
- Grâce à la méthode delta  $\hat{\theta}_{ML} \stackrel{\text{app}}{\sim} \mathcal{N}(\theta, 1/I_n(\theta))$  avec **l'information de Fisher**

$$I_n(\theta) = -\mathbb{E}_\theta(\ell''(\theta)) = \mathbb{E}_\theta(J_n(\theta)), \quad J_n(\theta) = -\ell''(\theta)$$

$1/I_n(\theta)$  est la **variance asymptotique** de  $\hat{\theta}_{ML}$ ,  $I_n(\theta)$  est la courbure

- **L'information observée** est  $J_n(\hat{\theta}_{ML})$
- **Attention !** Certains modèles, tel que  $U[0, \theta]$ , ne sont pas réguliers

**Exemple**  $x_1, \dots, x_n$  réalisations d'une loi  $\exp(\lambda)$  avec densité  $\lambda e^{-\lambda x} I(x \geq 0)$ ,  $\lambda > 0$

## Exemple

**Exemple**  $x_1, \dots, x_n$  réalisations d'une loi  $\exp(\lambda)$  avec densité  $\lambda e^{-\lambda x} I(x \geq 0)$ ,  $\lambda > 0$