

# Inférence statistique

## Séance 6

*Tests statistiques d'hypothèse:  
introduction, tests paramétriques*

Frédéric Sur

Mines Nancy

<https://members.loria.fr/FSur/>

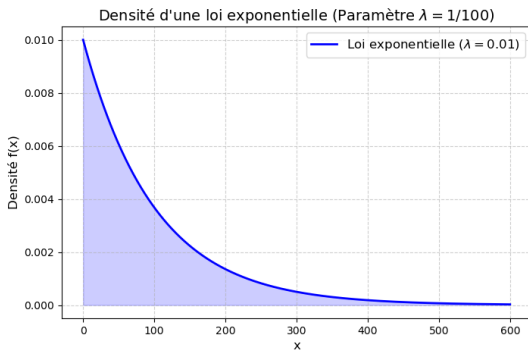
# Plan

- 1 Exemple introductif, vocabulaire
  - Hypothèse nulle, hypothèse alternative
  - Risques d'erreur
  - Région de rejet, région d'acceptation
- 2 Test statistique d'hypothèse
  - Démarche générale
  - $p$ -valeur
  - Exemple de mise en œuvre
- 3 Conclusion

## Cas d'étude : *Mean time between failures* (MTBF) (1)

**Exemple** : temps de défaillance d'une machine industrielle

→ des tables statistiques (observations sur un grand temps d'un grand nombre de machines identiques) permettent de modéliser la durée de temps entre deux pannes par une *loi exponentielle de paramètre  $\lambda$*



**Rappel** :  $1/\lambda$  est le temps moyen entre deux pannes (**100 heures**)

Exemples de réalisations : 39,0 - 191,1 - 156,7 - 5.2 - 157.7 - 47.2 ...

## Cas d'étude : *Mean time between failures* (MTBF) (2)

**Scénario** : un prestataire propose une « amélioration » de la machine pour 10k€ d'investissement

→ au bout de quelques semaines, on observe des pannes après 99, 150, 120, 35, 38, 230 heures.  
(moyenne : 112 heures)

**Question** : l'amélioration est-elle réelle ?

**Plus précisément** : de telles durées de fonctionnement sont-elles encore compatibles avec une loi exponentielle de moyenne  $1/\lambda = 100$  heures ?

# Notion d'hypothèse

**Hypothèse** : énoncé sur une caractéristique d'un problème

Les données expérimentales permettent-elles

- d'accepter l'hypothèse  $\mathcal{H}_0$  : la nouvelle durée moyenne de fonctionnement reste à 100 heures ?
- d'accepter l'hypothèse  $\mathcal{H}_1$  : la nouvelle durée moyenne de fonctionnement est supérieure à 100 heures ?

→ décision prise selon une observation (*réalisation d'un  $n$ -échantillon*)

→ la décision est prise avec une *incertitude*  
(on ne peut pas être certain à cause des *fluctuations d'échantillonnage*)

**Test d'hypothèse** : démarche construisant une règle de décision sur la réalisation d'une statistique basée sur un échantillon, permettant de faire un choix entre deux hypothèses avec risque d'erreur

# Hypothèses et modélisation statistique

→ phénomène modélisé par  $X$  une variable aléatoire dont la loi dépend d'un paramètre  $\theta$  **inconnu**.

*Exemple* : durée de fonctionnement,  $\theta$  durée moyenne entre deux pannes

→ des connaissances sur le problème permettent de faire une hypothèse  $\mathcal{H}_0$  sur  $\theta$

*Exemple* :  $\theta = \theta_0$ , où  $\theta_0 = 100$  heures

$\mathcal{H}_0$  est appelée **hypothèse nulle** (de référence)

→ on construit une **hypothèse alternative**  $\mathcal{H}_1$  à accepter si  $\mathcal{H}_0$  est réfutée.

*Exemple* :  $\mathcal{H}_1 : \theta > \theta_0$

→ à partir d'un  $n$ -échantillon de loi  $X$ , on calcule une **statistique de test**  $S$  estimant  $\theta$

*Exemple* :  $S$  moyenne empirique des temps de fonctionnement sans panne

→ on calcule la valeur  $s$  de  $S$  sur les observations dont on dispose

*Exemple* :  $s = \bar{\theta} = 112$  heures

## Test et risque

**Problème** : la différence entre  $\theta_0$  (100h) et  $\bar{\theta}$  (112h) peut s'expliquer simplement par les fluctuations d'échantillonnage (et pas par l'amélioration de la machine)

→ L'écart  $|\theta_0 - \bar{\theta}|$  est-il trop grand pour être dû aux fluctuations d'échantillonnage (cas 1), ou au contraire n'est pas incompatible avec la loi de  $X$  (cas 2)?

**Premier cas** : on rejette  $\mathcal{H}_0$ . On dit que l'écart est *significatif*

**Deuxième cas** : on ne rejette pas  $\mathcal{H}_0$ , car cette hypothèse n'est pas incohérente avec les données observées

→ la décision est prise avec risque de se tromper  
une autre réalisation de l'échantillon (une autre série d'observations) aurait peut-être conduit à inverser la décision

→ on introduit la probabilité  $\alpha$  de rejeter  $\mathcal{H}_0$  alors qu'elle est vraie.

Valeur typique :  $\alpha = 0.05$

on a 5 chances sur 100 d'observer un échantillon selon la loi de  $X$  pour lequel l'écart n'aurait pas été assez grand pour rejeter  $\mathcal{H}_0$

# Vocabulaire

*Hypothèse statistique* : affirmation sur une caractéristique d'une population

*Test d'hypothèse* : démarche construisant une règle de décision permettant de faire un choix entre deux hypothèses statistiques

*Hypothèse nulle*  $\mathcal{H}_0$  vs *hypothèse alternative*  $\mathcal{H}_1$

→ c'est  $\mathcal{H}_0$  qui est soumise au test (on la considère vraie, et on voit si on peut l'invalider)

*Test paramétrique* : on teste la valeur d'un paramètre  $\theta$

→ on verra aussi des tests non-paramétriques

Dans les tests paramétriques :

- hypothèse **simple** :  $H : \theta = \theta_0$
- hypothèse **composite** :  $H : \theta \in A$  ( $A$  : ensemble)  
(généralement  $\theta > \theta_0$ ,  $\theta < \theta_0$ ,  $\theta \neq \theta_0$ )

## Risques de première et deuxième espèce

Le test permet de décider entre deux hypothèses selon la réalisation d'un échantillon

→ il y a un risque d'erreur à choisir  $\mathcal{H}$  alors que  $\mathcal{H}'$  est vraie :  $P(\text{choisir } \mathcal{H} | \mathcal{H}')$

Décision	Vérité	
	$\mathcal{H}_0$	$\mathcal{H}_1$
$\mathcal{H}_0$	$1 - \alpha$	$\beta$
$\mathcal{H}_1$	$\alpha$	$1 - \beta$

$\alpha$  : *risque de première espèce*

$\beta$  : *risque de deuxième espèce*

$1 - \beta$  : *puissance du test*

$\alpha$  et  $\beta$  sont antagonistes

**Principe fondamental** : on cherche à maîtriser le risque de première espèce  $\alpha$ , car  $\mathcal{H}_0$  est critique

→ on veut limiter la probabilité de se tromper en rejetant  $\mathcal{H}_0$  alors qu'elle est vraie

## Région de rejet, région d'acceptation

$s$  : valeur de la statistique de test  $S$  sur les observations

On cherche une région de rejet  $W$  telle que :

si  $s \in W$ , alors on rejette  $\mathcal{H}_0$  (on accepte  $\mathcal{H}_1$ )

ou : si  $s \in \overline{W}$ , alors on accepte  $\mathcal{H}_0$  (on rejette  $\mathcal{H}_1$ )

$W$  déterminée telle que  $P(S \in W | H_0) = \alpha$

(ou « plus grande » région telle que  $P(S \in W | H_0) < \alpha$ )

**En pratique** :  $W$  choisie « intuitivement » en fonction de  $H_1$   
voir TD pour intro théorie de Neyman-Pearson

*Remarque* : léger abus de langage ici,  $W$  est normalement définie dans  $\mathbb{R}^n$ , voir polycopié

## Retour à l'exemple MTBF (1)

$\mathcal{H}_0 : 1/\lambda = 100$  heures

$\mathcal{H}_1 : 1/\lambda > 100$  heures

**Statistique de test** : il faut choisir une quantité capturant l'information pertinente, dont on sait établir la loi en fonction de celle de  $X$ .

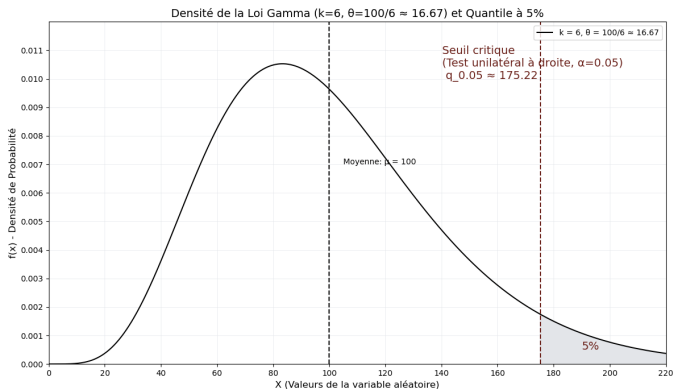
ici :  $S = \frac{1}{6} (X_1 + \dots + X_6) \sim \Gamma(6, 1/(6\lambda))$

**Question** : quelle région de rejet  $W$  ?

→ vue l'hypothèse  $\mathcal{H}_1$ , on va chercher  $W$  sous la forme  $[s_0, +\infty[$ , avec  $s_0$  à déterminer. C'est un *test unilatéral à droite*.

Ici, on cherche à répondre à la question : quelle valeur  $s_0$  est telle qu'observer une réalisation de  $S$  plus grande que  $s_0$  a une probabilité  $\alpha$  sous  $\mathcal{H}_0$  ?

## Retour à l'exemple MTBF (2)



$s_0$  t.q.  $P(S > s_0 | \mathcal{H}_0) = 0.05$ , soit  $P(S < s_0 | \mathcal{H}_0) = 0.95$

D'où  $s_0 = F_{\lambda}^{-1}(0.95)$  avec  $F_{\lambda}$  fonction de répartition de  $\Gamma(6, 1/(6\lambda))$

On trouve numériquement (ici  $\lambda = 1/100$ ) :  $s_0 = 175,2$

**Observation** :  $(99 + 150 + 120 + 35 + 38 + 230)/6 = 112$

**Conclusion** : on ne peut pas rejeter l'hypothèse  $\mathcal{H}_0$

## Et la puissance du test ?

**Rappel** :  $\beta$  est la proba d'accepter  $\mathcal{H}_0$  alors que  $\mathcal{H}_1$  est vraie.

$\beta = P(S < s_0 | \mathcal{H}_1)$  dépend de  $\lambda$  t.q.  $1/\lambda > 100$  : on ne peut pas calculer *une* puissance de test

→ on trace la *courbe de puissance*

$$\pi(\lambda) = 1 - \beta(\lambda) = 1 - F_\lambda(175, 2)$$

(voir discussion en TD)

**Remarque importante** : sans connaître  $\beta$ , il n'est pas vraiment raisonnable de conclure qu'on accepte  $\mathcal{H}_0$  car on ne maîtrise pas le risque d'erreur (qui peut être grand).

→ on se contente de dire qu'on rejette  $\mathcal{H}_0$  si  $s \in W$  ; et qu'on ne peut pas rejeter  $\mathcal{H}_0$  si  $s \in \overline{W}$ .

# Plan

- 1 Exemple introductif, vocabulaire
  - Hypothèse nulle, hypothèse alternative
  - Risques d'erreur
  - Région de rejet, région d'acceptation
- 2 Test statistique d'hypothèse
  - Démarche générale
  - $p$ -valeur
  - Exemple de mise en œuvre
- 3 Conclusion

## Démarche de test : résumé

- 1 choix des deux hypothèses  $\mathcal{H}_0$  et  $\mathcal{H}_1$  ;
- 2 choix de la statistique de test  $S$  ;
- 3 définition de l'allure de la région critique  $W$  en fonction de  $\mathcal{H}_1$   
→ revient à choisir un intervalle  $I$   
(test unilatéral à gauche, à droite, ou test bilatéral)
- 4 calcul de la région critique en fonction de  $\alpha$  ;
- 5 calcul (si possible) de la puissance  $1 - \beta$  du test ;
- 6 calcul de la valeur  $s$  prise par la statistique de test ;
- 7 décision : rejet de  $\mathcal{H}_0$  si  $s \in W$ .

**Remarque** : seules les étapes 6 et 7 nécessitent les observations.

## Point de vue de Fisher

Test basé sur une *statistique de test*  $S$  et sur  $W$

Différents choix possibles pour  $S$  ou pour l'allure de  $W$

→ ces choix peuvent conduire à des tests de puissance différente pour les mêmes hypothèses  $\mathcal{H}_0 / \mathcal{H}_1$

La loi sous  $\mathcal{H}_0$  doit être connue (pour trouver  $W$ ), mais la loi sous  $\mathcal{H}_1$  (donc la puissance) est souvent inconnue.

D'où le **point de vue de Fisher** sur les tests : on se contente de calculer  $P(\text{rejet de } \mathcal{H}_0 | \mathcal{H}_0)$ , qui quantifie la proba d'erreur de rejeter  $\mathcal{H}_0$  à tort.

C'est la  **$p$ -valeur**.

## $p$ -valeur ou valeur $p$ ( $p$ -value)

### Exemple d'un test à droite

$p$ -valeur :  $P(S > s | \mathcal{H}_0)$

Remarque :

$s_0$  : seuil de décision au risque  $\alpha$   
alors :

$$s > s_0 \Leftrightarrow P(S > s | \mathcal{H}_0) < \alpha$$




car  $P(S > s_0 | \mathcal{H}_0) = \alpha$

→ les logiciels calculent la  $p$ -valeur, qui doit être inférieure à  $\alpha$  pour rejeter  $\mathcal{H}_0$ .

### Exemple MTBF

$p$ -valeur =  $P(S > 112 | \mathcal{H}_0) = 0,157$

on ne peut pas rejeter  $\mathcal{H}_0$



Par Adrian69 CC BY-SA 4.0

<https://commons.wikimedia.org/w/index.php?curid=67559628>

<u>P-VALUE</u>	<u>INTERPRETATION</u>
0.001	HIGHLY SIGNIFICANT
0.01	
0.02	
0.03	
0.04	SIGNIFICANT
0.049	
0.050	OH CRAP. REDO CALCULATIONS.
0.051	ON THE EDGE OF SIGNIFICANCE
0.06	
0.07	HIGHLY SUGGESTIVE, SIGNIFICANT AT THE $P < 0.10$ LEVEL
0.08	
0.09	
0.099	HEY, LOOK AT THIS INTERESTING SUBGROUP ANALYSIS
$\geq 0.1$	

*If all else fails, use “significant at a  $p > 0.05$  level” and hope no one notices.*

## Un dernier exemple

Vous travaillez au sein du service achat d'une entreprise d'électronique. Un fournisseur vous livre des composants de durées de vie égale à 1000 heures selon le contrat.

Pour vérifier la durée de vie des composants, vous en prélevez 10 et testez leur durée de vie. Vous trouvez un nombre d'heures de : 950, 1100, 1070, 920, 1010, 880, 910, 1010, 910, 880.

Devez-vous accepter le lot ?

## Quelle modélisation statistique ?

Durée de vie : v.a.  $X$  de loi normale de moyenne  $m$  et d'écart-type  $\sigma$ .

On va faire un test sur la moyenne d'une loi normale de variance inconnue (voir poly)

On choisit le risque de première espèce :  $\alpha = 0,05$ .

À partir de l'échantillon de taille  $n = 10$ , on calcule :

- Moyenne de l'échantillon ( $\bar{x}$ ) :

$$\bar{x} = \frac{\sum x_i}{n} = 964 \text{ heures}$$

- Écart-type de l'échantillon ( $\bar{s}$ ) :

$$\bar{s} = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n - 1}} \approx 78,9 \text{ heures}$$

## Hypothèses et région critique

- $H_0 : \mu = \mu_0 = 1000$  (le lot est conforme)
- $H_1 : \mu < 1000$  (le lot est non conforme)

→ nous réalisons un test de Student ( $t$ -test) unilatéral à gauche pour vérifier si la moyenne du lot est significativement inférieure au seuil contractuel.

Choix de la forme de la région de rejet de  $\mathcal{H}_0 : ] - \infty, \bar{x}_0]$

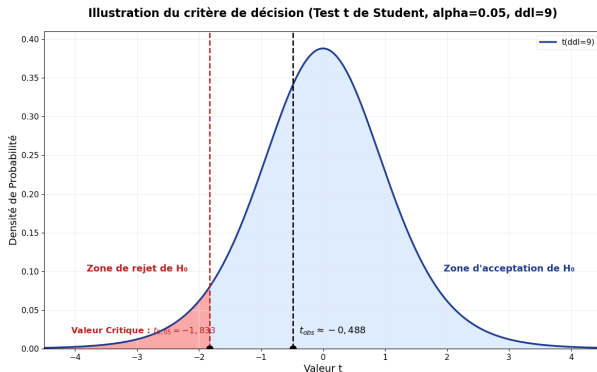
$\bar{x}_0$  déterminé par  $P(\bar{X} < \bar{x}_0 | \mathcal{H}_0) = \alpha$

ou, de manière équivalente : on cherche  $t_{\text{critique}}$  t.q.

$$P\left(\frac{\bar{X} - \mu_0}{\bar{s}/\sqrt{n}} < t_{\text{critique}}\right) = \alpha$$

où  $T_9 = (\bar{X} - \mu_0)(\bar{s}/\sqrt{n})$  (statistique de test) suit la loi de Student à 9 d.d.l.

# Statistique de test



## Critère de décision :

Pour un seuil de signification  $\alpha = 0,05$  et un nombre de degrés de liberté  $n - 1 = 9$ , la valeur critique dans la table de Student est :

$$t_{\text{critique}} = -1,833$$

## Décision

La valeur  $t_{\text{obs}}$  observée est calculée par la formule :

$$t_{\text{obs}} = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{964 - 1000}{78,9/\sqrt{10}} \approx -1,443$$

### Conclusion

$t_{\text{obs}} > t_{\text{critique}}$  ( $-1,433 > -1,833$ ), donc nous **ne pouvons pas rejeter l'hypothèse nulle**  $H_0$ .

→ il n'y a pas assez de preuves pour affirmer que le lot est non conforme, malgré une moyenne inférieure à 1000 heures

$p$ -valeur :  $P(T_9 < t_{\text{obs}}) = 0,0915\dots$

exemple de calculateur en ligne : <https://www.statpowers.com/>

# Plan

- 1 Exemple introductif, vocabulaire
  - Hypothèse nulle, hypothèse alternative
  - Risques d'erreur
  - Région de rejet, région d'acceptation
- 2 Test statistique d'hypothèse
  - Démarche générale
  - $p$ -valeur
  - Exemple de mise en œuvre
- 3 Conclusion

# Conclusion

**Test statistique d'hypothèse** : démarche rigoureuse permettant de prendre une décision, à un certain niveau de confiance, à partir d'observations, sous une modélisation statistique.

**Aujourd'hui en TD** : tests d'hypothèse paramétriques

**Deux séances suivantes** : quelques problèmes statistiques et les tests d'hypothèse adaptés

*Message de service 1* : notes de cours + sujets TD dans les casiers, pensez à les apporter à chaque séance.

*Message de service 2* : séance de soutien 17h-18h et 18h-19h mercredi 6 mai.