

Mathématiques pour les Sciences de la Vie

Probabilités – Statistique

Printemps 2022

S. Mousset

Université Claude Bernard Lyon I – France

Estimation

On souhaite connaître la distribution d'une variable dans la population (taille, poids, couleur de cheveux, . . .

Estimation

On souhaite connaître la distribution d'une variable dans la population (taille, poids, couleur de cheveux, . . .

Faut-il mesurer toute la population ?

Échantillon

Échantillon :

- Sous-ensemble de la population d'intérêt.

Échantillon

Échantillon :

- Sous-ensemble de la population d'intérêt.
- Taille de l'échantillon : nombre d'observations n .

Échantillon

Échantillon :

- Sous-ensemble de la population d'intérêt.
- Taille de l'échantillon : nombre d'observations n .
- Stratégie d'échantillonnage : comment obtenir les meilleures informations sur la population.

Échantillon

Échantillon :

- Représentatif de la population (non biaisé).

Échantillon

Échantillon :

- Représentatif de la population (non biaisé).
- Aléatoire simple (population de taille N , échantillon de taille n , probabilité identique pour tous d'être échantillonné : $\frac{n}{N}$).

Échantillon

Échantillon :

- Représentatif de la population (non biaisé).
- Aléatoire simple (population de taille N , échantillon de taille n , probabilité identique pour tous d'être échantillonné : $\frac{n}{N}$).
- Structuré : on possède une information sur une structuration en k classe de fréquences p_1, \dots, p_k , et on constitue l'échantillon en conséquence.

Échantillon

Échantillon :

- Représentatif de la population (non biaisé).
- Aléatoire simple (population de taille N , échantillon de taille n , probabilité identique pour tous d'être échantillonné : $\frac{n}{N}$).
- Structuré : on possède une information sur une structuration en k classe de fréquences p_1, \dots, p_k , et on constitue l'échantillon en conséquence.

Échantillon


Échantillon :

- Représentatif de la population (non biaisé).
- Aléatoire simple (population de taille N , échantillon de taille n , probabilité identique pour tous d'être échantillonné : $\frac{n}{N}$).
- Structuré : on possède une information sur une structuration en k classe de fréquences p_1, \dots, p_k , et on constitue l'échantillon en conséquence.

Nous nous intéresserons uniquement à l'échantillonnage aléatoire simple.

Notation

- Population : l'ensemble des individus.



Notation


- Population : l'ensemble des individus.
- Échantillon : sous-ensemble de la population choisi au hasard.

$$\begin{aligned} X &\sim \mathcal{D} \\ \mathbb{E}(X) &= \mu \\ \mathbb{V}(X) &= \sigma^2 \end{aligned}$$

Population


Notation

- Population : l'ensemble des individus.
- Échantillon : sous-ensemble de la population choisi au hasard.




Notation

- μ et σ sont la moyenne et la variance de la distribution de X . On ne peut les obtenir qu'en échantillonnant tout le monde.




Notation

- μ et σ sont la moyenne et la variance de la distribution de X . On ne peut les obtenir qu'en échantillonnant tout le monde.
- x_1, \dots, x_n sont les observations de X sur les n individus de l'échantillon.




Notation

- μ et σ sont la moyenne et la variance de la distribution de X . On ne peut les obtenir qu'en échantillonnant tout le monde.
- x_1, \dots, x_n sont les observations de X sur les n individus de l'échantillon.
- \bar{x} et s^2 sont les mesures de la moyenne et de la variance du caractère étudié dans l'échantillon.



Notation


- μ et σ sont la moyenne et la variance de la distribution de X . On ne peut les obtenir qu'en échantillonnant tout le monde.
- x_1, \dots, x_n sont les observations de X sur les n individus de l'échantillon.
- \bar{x} et s^2 sont les mesures de la moyenne et de la variance du caractère étudié dans l'échantillon.



Notation

- μ et σ sont la moyenne et la variance de la distribution de X . On ne peut les obtenir qu'en échantillonnant tout le monde.
- x_1, \dots, x_n sont les observations de X sur les n individus de l'échantillon.
- \bar{x} et s^2 sont les mesures de la moyenne et de la variance du caractère étudié dans l'échantillon.

On veut estimer μ et σ^2 à partir de l'échantillon.
Les **estimations** sont notées $\hat{\mu}$ et $\hat{\sigma}$.



Types de données

Type de données	non regroupées	regroupées en k classes
Données	$x_1 \dots x_n$	$x_1 \dots x_k$
Effectifs	$n_1 = \dots = n_n = 1$	$n_1, \dots, n_k. n = \sum_{i=1}^k n_i$
Moyenne \bar{x}	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$	$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i$
Variance s^2	$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i \right)^2$	$s^2 = \frac{1}{n} \sum_{i=1}^k n_i x_i^2 - \left(\frac{1}{n} \sum_{i=1}^k n_i x_i \right)^2$

Exemple

- Population : Étudiants inscrits en MathSV
- Variable : Taille du prénom
- On a accès aux prénoms des 437 étudiants
- On connaît donc $\mu = 5.9$ et $\sigma^2 = 2.62$
- On calcule \bar{x} et s^2 sur un échantillon de 40 étudiants.
- $\bar{x} = 5.8462$ et $s^2 = 3.8225$.

x_i	n_i
3	1
4	10
5	11
6	3
7	7
8	4
9	2
13	1

Avec vos calculatrices TI

```
{3,4,5,6,7,8,9,10}→L1  
{3 4 5 6 7 8 9 ...  
{1,4,11,7,6,6,2,  
3}→L2  
{1 4 11 7 6 6 2...
```

```
Stats 1-Var  
 $\bar{x}=6,35$   
 $\Sigma x=254$   
 $\Sigma x^2=1740$   
 $S_x=1,805262961$   
 $\sigma_x=1,782554347$   
↓n=40
```

L1	L2	L3	1
1	1	-----	
2	11		
3	6		
4	6		
5	2		

L1()=3

```
VARIBLES VAR-Y=  
1:Fenêtre...  
2:Zoom...  
3:BDG...  
4:Image...  
5:Statistiques...  
6:Table...  
7:Chaîne...
```

```
EDIT TESTS  
1:Stats 1-Var  
2:Stats 2-Var  
3:Méd-Méd  
4:RégLin(ax+b)  
5:RégQuad  
6:RégCubique  
7:RégQuatre
```

```
 $\Sigma$  EQ TEST PTS  
1:n  
2: $\bar{x}$   
3: $S_x$   
4: $\sigma_x$   
5:g  
6: $S_y$   
7: $\sigma_y$ 
```

```
Stats 1-Var (L1,  
L2)
```

```
 $\Sigma x=254$   
 $\Sigma x^2=1740$   
 $S_x=1,805262961$   
 $\sigma_x=1,782554347$   
↓n=40  
 $\sigma_x^2$   
3.1775
```

Avec vos calculatrices TI

```
{3,4,5,6,7,8,9,10}→L1  
{3 4 5 6 7 8 9 ...  
{1,4,11,7,6,6,2,  
3}→L2  
{1 4 11 7 6 6 2...
```

```
Stats 1-Var  
x̄=6.35  
Σx=254  
Σx²=1740  
Sx=1.805262961  
σx=1.782554347  
↓n=40
```

L1	L2	L3	1
1	1	-----	
11	11		
6	6		
6	6		
2	2		

L1()=3

```
VAR-  
1:Fenêtre...  
2:Zoom...  
3:BDG...  
4:Image...  
5:Statistiques...  
6:Table...  
7:Chaîne...
```

```
EDIT TESTS  
1:Stats 1-Var  
2:Stats 2-Var  
3:Méd-Méd  
4:RégLin(ax+b)  
5:RégQuad  
6:RégCubique  
7:RégQuatre
```

```
Σ EQ TEST PTS  
1:n  
2:x̄  
3:Sx  
4:σx  
5:g  
6:Sy  
7:σy
```

```
Stats 1-Var (L1,  
L2)
```

```
Σx=254  
Σx²=1740  
Sx=1.805262961  
σx=1.782554347  
↓n=40  
σx²  
3.1775
```

L'écart-type de l'échantillon est nommé σx .

Avec vos calculatrices casio

Entrer les données

MENU **2**

Faire les calculs

MENU **2** **F2** **F6** **▼** **F2** **2** **EXE**
EXIT **F1**

Accéder aux résultats

MENU **1**
VARS **F3** **F1**
F1 **EXE**
F2 **EXE**
F5 **σ^2** **EXE**

	List 1	List 2	List 3	List 4
SUB				
1	3	1		
2	4	4		
3	5	11		
4	6	7		

GRPH CALC TEST INTR DIST

	List 1	List 2	List 3	List 4
SUB				
1	3	1		
2	4	4		
3	5	11		
4	6	7		

1VAR 2VAR REG SET

1Var XList :List1
1Var Freq :List2
2Var XList :List1
2Var YList :List2
2Var Freq :1
1 LIST

1 variable
 \bar{x} =6.35
 Σx =254
 Σx^2 =1740
 σx =1.78255434
 σx^2 =1.80526296
n =40

\bar{x} 40
 σx^2 6.35
 σx^2 3.1775
n \bar{x} Σx Σx^2 σx

Avec vos calculatrices casio

Entrer les données

MENU **2**

Faire les calculs

MENU **2** **F2** **F6** **▼** **F2** **2** **EXE**
EXIT **F1**

Accéder aux résultats

MENU **1**
VARS **F3** **F1**
F1 **EXE**
F2 **EXE**
F5 **σx^2** **EXE**

	List 1	List 2	List 3	List 4
SUB				
1	3	1		
2	4	4		
3	5	11		
4	6	7		

GRPH CALC TEST INTR DIST

	List 1	List 2	List 3	List 4
SUB				
1	3	1		
2	4	4		
3	5	11		
4	6	7		

1VAR 2VAR REG SET

```
1Var XList :List1
1Var Freq  :List2
2Var XList :List1
2Var YList :List2
2Var Freq  :1
1 LIST
```

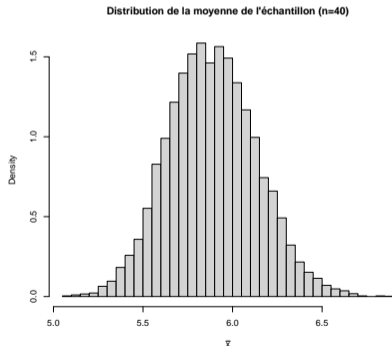
```
1 variable
x̄ =6.35
Σx =254
Σx² =1740
σx =1.78255434
sx =1.80526296
n =40
```

```
σx² =3.1775
n x Σx Σx² σx
```

L'écart-type de l'échantillon est nommé σx .


Distribution de \bar{x}

- \bar{x} est une V.A.
- La distribution de \bar{x} tend vers la loi normale.
- La moyenne de \bar{x} est μ
- La variance de \bar{x} est $\sigma_{\bar{x}}^2 = \frac{\sigma^2}{n}$
- \bar{x} est un estimateur non biaisé de μ : $\hat{\mu} = \bar{x}$.




Distribution de \bar{x}

- \bar{x} est une V.A.
- La distribution de \bar{x} tend vers la loi normale.
- La moyenne de \bar{x} est μ
- La variance de \bar{x} est $\sigma_{\bar{x}}^2 = \frac{\sigma^2}{n}$
- \bar{x} est un estimateur non biaisé de μ : $\hat{\mu} = \bar{x}$.



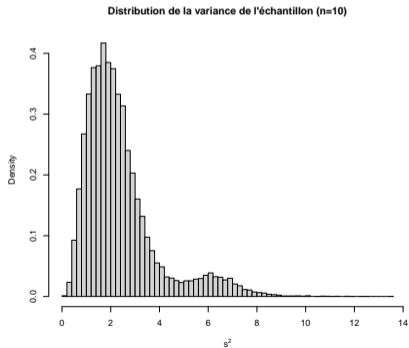
Distribution de \bar{x}

- \bar{x} est une V.A.
- La distribution de \bar{x} tend vers la loi normale.
- La moyenne de \bar{x} est μ
- La variance de \bar{x} est $\sigma_{\bar{x}}^2 = \frac{\sigma^2}{n}$
- \bar{x} est un estimateur non biaisé de μ : $\hat{\mu} = \bar{x}$.




Distribution de s^2

- s^2 est une V.A.




Distribution de s^2

- s^2 est une V.A.



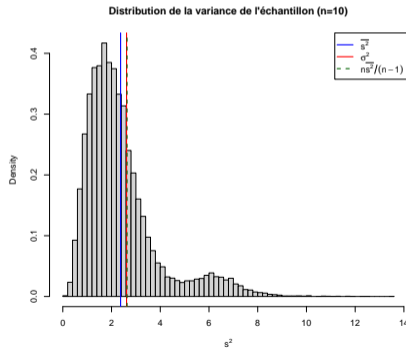
Distribution de s^2

- s^2 est une V.A.
- La moyenne de s^2 est différente de σ^2




Distribution de s^2

- s^2 est une V.A.
- La moyenne de s^2 est différente de σ^2
- On peut montrer que
$$\mathbb{E}(s^2) = \frac{n-1}{n}\sigma^2$$



Distribution de s^2


- s^2 est une V.A.
- La moyenne de s^2 est différente de σ^2
- On peut montrer que $\mathbb{E}(s^2) = \frac{n-1}{n}\sigma^2$
- Un estimateur non biaisé de σ^2 est $\hat{\sigma}^2 = \frac{n}{n-1}s^2$



Comment estimer σ^2 (cas où μ est connue)


- Supposons que la moyenne μ est connue. On calcule

$$\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$



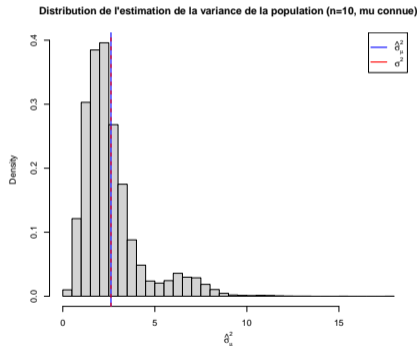
Comment estimer σ^2 (cas où μ est connue)

- Supposons que la moyenne μ est connue. On calcule
$$\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$
- On peut montrer que $\mathbb{E}(\hat{\sigma}_\mu^2) = \sigma^2$




Comment estimer σ^2 (cas où μ est connue)

- Supposons que la moyenne μ est connue. On calcule
$$\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$
- On peut montrer que $\mathbb{E}(\hat{\sigma}_\mu^2) = \sigma^2$
- Le plus souvent on veut estimer μ et σ^2 .



Comment estimer σ^2 (cas où μ est connue)

- Supposons que la moyenne μ est connue. On calcule
$$\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$
- On peut montrer que $\mathbb{E}(\hat{\sigma}_\mu^2) = \sigma^2$
- Le plus souvent on veut estimer μ et σ^2 .




$\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$ est un estimateur non biaisé de σ^2 .

Comment estimer σ^2 (cas où μ est inconnue)

- On calcule

$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{j=1}^n x_j \right)^2 .$$

Distribution de l'estimation de la variance de la population (n=10, mu estimée)



Comment estimer σ^2 (cas où μ est inconnue)


- On calcule

$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{j=1}^n x_j \right)^2.$$

- On peut montrer que

$$\mathbb{E}(s^2) = \frac{n-1}{n} \sigma^2.$$

Distribution de l'estimation de la variance de la population (n=10, mu estimée)



Comment estimer σ^2 (cas où μ est inconnue)

- On calcule


$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{j=1}^n x_j \right)^2.$$

- On peut montrer que

$$\mathbb{E}(s^2) = \frac{n-1}{n} \sigma^2.$$

- Finalement, on pose $\hat{\sigma}_{\bar{x}}^2 = \frac{n}{n-1} s^2$
et $\mathbb{E}(\hat{\sigma}_{\bar{x}}^2) = \sigma^2$

Distribution de l'estimation de la variance de la population (n=10, mu estimée)



Comment estimer σ^2 (cas où μ est inconnue)

- On calcule


$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{j=1}^n x_j \right)^2.$$

- On peut montrer que

$$\mathbb{E}(s^2) = \frac{n-1}{n} \sigma^2.$$

- Finalement, on pose $\hat{\sigma}_{\bar{x}}^2 = \frac{n}{n-1} s^2$
et $\mathbb{E}(\hat{\sigma}_{\bar{x}}^2) = \sigma^2$

$\hat{\sigma}_{\bar{x}}^2 = \frac{n}{n-1} s^2$ est un estimateur non biaisé de σ^2 .




Distribution d'échantillonnage

- L'échantillon est composé de n observations X_1, \dots, X_n indépendantes et de même distribution $\mathcal{D}(\mu, \sigma^2)$.
- La moyenne $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ est une variable aléatoire. $\mathbb{E}(\bar{X}) = \mu$,
 $\mathbb{V}(\bar{X}) = \frac{\sigma^2}{n}$
- La distribution de \bar{X} est la **distribution d'échantillonnage**.
- La distribution de \bar{X} dépend de celle des X_i .
- Les fractiles de la distribution de \bar{X} permettent d'établir des intervalles de prédiction (sur la valeur de \bar{X}).
- Nous sommes intéressés par l'estimation de μ : on parle d'intervalles de confiance.

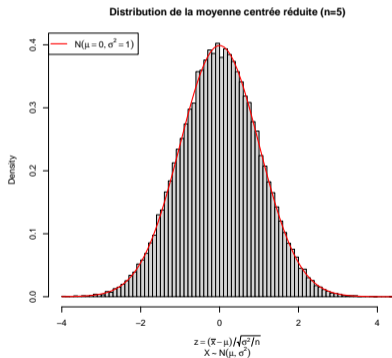
$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est connue.

- \bar{X} est la moyenne de n VA. distribuées normalement $X_i \sim \mathcal{N}(\mu, \sigma^2)$.




$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est connue.

- \bar{X} est la moyenne de n VA. distribuées normalement $X_i \sim \mathcal{N}(\mu, \sigma^2)$.
- Donc \bar{x} suit aussi une loi normale $N\left(\mu, \frac{\sigma^2}{n}\right)$
- $z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(\mu = 0, \sigma^2 = 1)$.




$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est connue.

- \bar{X} est la moyenne de n VA. distribuées normalement $X_i \sim \mathcal{N}(\mu, \sigma^2)$.
- Donc \bar{x} suit aussi une loi normale $N\left(\mu, \frac{\sigma^2}{n}\right)$
- $z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(\mu = 0, \sigma^2 = 1)$.
- Les fractiles de $\mathcal{N}(\mu = 0, \sigma^2 = 1)$ sont obtenus avec la table de l'écart-réduit.



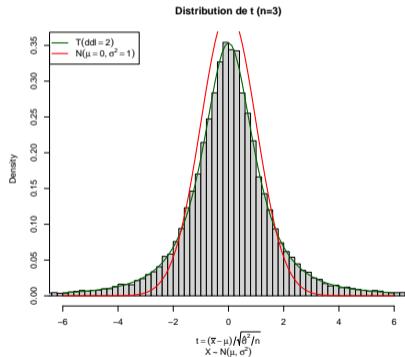
$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est inconnue.

- \bar{X} est la moyenne de n VA. iid
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$.




$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est inconnue.

- \bar{X} est la moyenne de n VA. iid
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$.
- $t = \frac{\bar{X} - \mu}{\sqrt{\hat{\sigma}^2/n}} = \frac{\bar{X} - \mu}{\sqrt{s^2/n-1}} \sim \mathcal{T}(n - 1 \text{ddl})$.




$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est inconnue.

- \bar{X} est la moyenne de n VA. iid
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$.
- $t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} = \frac{\bar{X} - \mu}{\sqrt{\frac{s^2}{n-1}}} \sim \mathcal{T}(n - 1 \text{ddl})$.
- $\mathcal{T}(n - 1 \text{ddl})$ est la loi de Student à $n - 1$ degrés de liberté.



$X_i \sim \mathcal{N}(\mu, \sigma^2)$ et σ^2 est inconnue.

- \bar{X} est la moyenne de n VA. iid
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$.
- $t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} = \frac{\bar{X} - \mu}{\sqrt{\frac{s^2}{n-1}}} \sim \mathcal{T}(n - 1 \text{ddl})$.
- $\mathcal{T}(n - 1 \text{ddl})$ est la loi de Student à $n - 1$ degrés de liberté.
- $\mathcal{T}(n - 1 \text{ddl}) \rightarrow \mathcal{N}(0, 1)$ lorsque n est grand.



Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$
- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$


Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.




Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.




Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.




Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.




Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.




Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.




Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.



Loi de t de Student

- Si X_0, \dots, X_n iid $\mathcal{N}(0, 1)$,
 $X^2 = \sum_{i=1}^n X_i^2$ alors
 $t = \frac{X_0}{\sqrt{X^2/n}} \sim \mathcal{T}(n \text{ ddl})$

- En ce qui nous concerne si
 $X_i \sim \mathcal{N}(\mu, \sigma^2)$

$$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$$

- Lorsque n croît
 $\mathcal{T}(n \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$.
- Les fractiles de t sont donnés par la table de la loi de Student.

Table de t .


La table donne, pour une probabilité α et un nombre de degrés de liberté (d.d.l.) donnés, la valeur x telle que la probabilité que t égale ou dépasse x en valeur absolue vaut α .

d.d.l.	α	0.90	0.50	0.30	0.20	0.10	0.05	0.02	0.01	0.001
1	0.158	1.000	1.963	3.078	6.314	12.706	31.821	63.657	636.619	
2	0.142	0.816	1.386	1.886	2.920	4.303	6.965	9.925	31.599	
3	0.137	0.765	1.250	1.638	2.353	3.182	4.541	5.841	12.924	
4	0.134	0.741	1.190	1.533	2.132	2.776	3.747	4.804	8.610	
5	0.132	0.727	1.156	1.476	2.015	2.571	3.365	4.032	6.869	
6	0.131	0.718	1.134	1.440	1.943	2.447	3.143	3.707	5.959	
7	0.130	0.711	1.119	1.415	1.895	2.365	2.998	3.499	5.408	
8	0.130	0.706	1.108	1.397	1.860	2.306	2.896	3.355	5.041	
9	0.129	0.703	1.100	1.383	1.833	2.262	2.821	3.250	4.781	
10	0.129	0.700	1.093	1.372	1.812	2.228	2.764	3.169	4.587	
11	0.129	0.697	1.088	1.363	1.796	2.201	2.718	3.106	4.437	
12	0.128	0.695	1.083	1.356	1.782	2.179	2.681	3.055	4.318	
13	0.128	0.694	1.079	1.350	1.771	2.160	2.650	3.012	4.221	
14	0.128	0.692	1.076	1.345	1.761	2.145	2.624	2.977	4.140	
15	0.128	0.691	1.074	1.341	1.753	2.131	2.602	2.947	4.073	
16	0.128	0.690	1.071	1.337	1.746	2.120	2.583	2.921	4.015	
17	0.128	0.689	1.069	1.333	1.740	2.110	2.567	2.898	3.965	
18	0.127	0.688	1.067	1.330	1.734	2.101	2.552	2.878	3.922	
19	0.127	0.688	1.066	1.328	1.729	2.093	2.539	2.861	3.883	
20	0.127	0.687	1.064	1.325	1.725	2.086	2.528	2.845	3.850	
21	0.127	0.686	1.063	1.323	1.721	2.080	2.518	2.831	3.819	
22	0.127	0.686	1.061	1.321	1.717	2.074	2.508	2.819	3.792	
23	0.127	0.685	1.060	1.319	1.714	2.069	2.500	2.807	3.768	
24	0.127	0.685	1.059	1.318	1.711	2.064	2.492	2.797	3.745	
25	0.127	0.684	1.058	1.316	1.708	2.060	2.485	2.787	3.725	
26	0.127	0.684	1.058	1.315	1.706	2.056	2.479	2.779	3.707	
27	0.127	0.684	1.057	1.314	1.703	2.052	2.473	2.771	3.690	
28	0.127	0.683	1.056	1.313	1.701	2.048	2.467	2.763	3.674	
29	0.127	0.683	1.055	1.311	1.699	2.045	2.462	2.756	3.659	
30	0.127	0.683	1.055	1.310	1.697	2.042	2.457	2.750	3.646	
∞	0.126	0.674	1.036	1.282	1.645	1.960	2.326	2.576	3.291	

Exemple : Une variable aléatoire suivant une loi de t avec 10 degrés de liberté a une probabilité $\alpha = 0.05$ d'être égale ou supérieure à 2.228 en valeur absolue.


$X \sim \mathcal{D}(\mu, \sigma^2)$ quelconque mais n est grand : utilisation du TCL

- \bar{X} est la moyenne de n VA. iid d'espérance μ et de variance σ^2 .




$X \sim \mathcal{D}(\mu, \sigma^2)$ quelconque mais n est grand : utilisation du TCL

- \bar{X} est la moyenne de n VA. iid d'espérance μ et de variance σ^2 .
- Le TCL dit que $\bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$.




$X \sim \mathcal{D}(\mu, \sigma^2)$ quelconque mais n est grand : utilisation du TCL

- \bar{X} est la moyenne de n VA. iid d'espérance μ et de variance σ^2 .
- Le TCL dit que $\bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$.
- Donc $Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1)$.



$X \sim \mathcal{D}(\mu, \sigma^2)$ quelconque mais n est grand : utilisation du TCL

- \bar{X} est la moyenne de n VA. iid d'espérance μ et de variance σ^2 .
- Le TCL dit que $\bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$.
- Donc $Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1)$.
- $T = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$ Comme n est grand $\mathcal{T}(n - 1 \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$



Distribution d'échantillonnage de la moyenne \bar{X} : synthèse

	σ^2	$n < 30$	$n \geq 30$
$X_i \sim \mathcal{N}(\mu, \sigma^2)$	connue		$z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1)$
	estimée	$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl})$	$\mathcal{T}(n - 1 \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$
$X_i \sim \mathcal{D}(\mu, \sigma^2)$ quelconque	connue	on ne sait pas	$z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1)$
	estimée	on ne sait pas	$t = \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \sim \mathcal{T}(n - 1 \text{ ddl}) \rightarrow \mathcal{N}(0, 1)$

Intervalle de prédiction (dit aussi de pari ou de fluctuation)

- Les fractiles des distributions d'échantillonnage permettent d'établir des intervalles de prédiction pour la valeur de \bar{X} .
- Ces intervalles de prédiction dépendent de μ , σ^2 et n .
- La lecture des fractiles se fait dans la table de l'écart-réduit (pour $\mathcal{N}(0, 1)$) ou celle de la loi de Student ($\mathcal{T}(k \text{ ddl})$)

Intervalle de prédiction : Exemple

On considère $n = 500$ lancers indépendants d'un dé à 6 faces équilibré. X_i est le résultat du i ème lancer. On veut un intervalle de prédiction pour \bar{X} :

$$\mathbb{E}(X_i) = \frac{1}{6} \sum_{i=1}^6 i = \frac{7}{2}, \quad \mathbb{V}(X_i) = \frac{1}{6} \sum_{i=1}^6 i^2 - \left(\frac{21}{6}\right)^2 = \frac{35}{12}$$

Un intervalle de prédiction au risque α pour \bar{X} est donné par la table de l'écart-réduit :

$$\mathbb{P} \left(-\varepsilon_\alpha < \frac{\bar{X} - \frac{7}{2}}{\sqrt{\frac{35/12}{500}}} < \varepsilon_\alpha \right) = 1 - \alpha$$

Intervalle de prédiction : Exemple

Si on souhaite prendre un risque $\alpha = 0.001$, la valeur à utiliser est $\varepsilon_{\alpha=0.001} = 3.29053$. On obtient alors :

$$\mathbb{P} \left(\frac{7}{2} - 3.29053 \sqrt{\frac{35/12}{500}} < \bar{X} < \frac{7}{2} + 3.29053 \sqrt{\frac{35/12}{500}} \right) = 0.999$$

soit finalement

$$\mathbb{P} (3.249 < \bar{X} < 3.751) = 0.999$$

Ce qui signifie que la somme des résultats des 500 lancers sera comprise entre 1624 et 1876 avec une probabilité de 0.999.

Intervalle de confiance

- Contrairement à l'intervalle de prédiction, on cherche à **inférer une connaissance à propos de la distribution dans la population** à partir d'un résultat sur un échantillon.
- Un intervalle de confiance de la moyenne μ au risque α est un intervalle dans lequel la moyenne μ (qui reste inconnue) se trouve avec une probabilité $1 - \alpha$.

$$\mathbb{P}(b_{\text{inf}} < \mu < b_{\text{sup}}) = 1 - \alpha$$

- L'intervalle de confiance résulte d'une expérience sur un échantillon : ses bornes b_{inf} et b_{sup} sont donc des variables aléatoires.

Relation intervalle de prédiction / intervalle de confiance

- Distribution d'échantillonnage, et fractiles de cette distribution

$$\frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1) \quad \text{donc} \quad \mathbb{P}\left(-\varepsilon_\alpha < \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} < \varepsilon_\alpha\right) = 1 - \alpha$$

Relation intervalle de prédiction / intervalle de confiance

- Distribution d'échantillonnage, et fractiles de cette distribution

$$\frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1) \quad \text{donc} \quad \mathbb{P} \left(-\varepsilon_\alpha < \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} < \varepsilon_\alpha \right) = 1 - \alpha$$

- Intervalle de prédiction de \bar{X} au risque α

$$\mathbb{P} \left(\mu - \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} < \bar{X} < \mu + \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} \right) = 1 - \alpha$$

Relation intervalle de prédiction / intervalle de confiance

- Distribution d'échantillonnage, et fractiles de cette distribution

$$\frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim \mathcal{N}(0, 1) \quad \text{donc} \quad \mathbb{P} \left(-\varepsilon_\alpha < \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} < \varepsilon_\alpha \right) = 1 - \alpha$$

- Intervalle de prédiction de \bar{X} au risque α

$$\mathbb{P} \left(\mu - \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} < \bar{X} < \mu + \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} \right) = 1 - \alpha$$

- Intervalle de confiance de la moyenne μ au risque α


$$\mathbb{P} \left(\bar{X} - \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} < \mu < \bar{X} + \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} \right) = 1 - \alpha$$

Relation intervalle de prédiction / intervalle de confiance

Simulations : $n = 15$, $X_i \sim \mathcal{N}(\mu = 170, \sigma^2 = 64)$


Relation intervalle de prédiction / intervalle de confiance

Simulations : $n = 15$, $X_i \sim \mathcal{N}(\mu = 170, \sigma^2 = 64)$



Relation intervalle de prédiction / intervalle de confiance

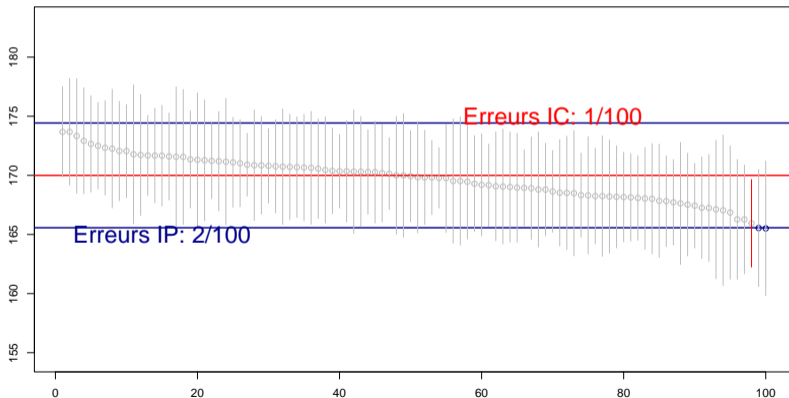
Simulations : $n = 15$, $X_i \sim \mathcal{N}(\mu = 170, \sigma^2 = 64)$



Risque 0.1


Relation intervalle de prédiction / intervalle de confiance

Simulations : $n = 15$, $X_i \sim \mathcal{N}(\mu = 170, \sigma^2 = 64)$



Relation intervalle de prédiction / intervalle de confiance


Simulations : $n = 15$, $X_i \sim \mathcal{N}(\mu = 170, \sigma^2 = 64)$



Risque 0.01

Relation intervalle de prédiction / intervalle de confiance

Simulations : $n = 15$, $X_i \sim \mathcal{N}(\mu = 170, \sigma^2 = 64)$



Intervalle de confiance : Exemple

À l'issue de $n = 500$ lancers de dé, on a obtenu une moyenne $\bar{x} = 3.834$. La somme des lancers était $\sum_{i=1}^{500} X_i = 1917$ et la somme des carrés des lancers était $\sum_{i=1}^{500} X_i^2 = 8959$. Peut-on en conclure que le dé est déséquilibré ?

$$\mathbb{P} \left(-\varepsilon_\alpha < \frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} < \varepsilon_\alpha \right) = 1 - \alpha \Leftrightarrow \mathbb{P} \left(-\varepsilon_\alpha < \frac{\mu - \bar{X}}{\sqrt{\frac{\hat{\sigma}^2}{n}}} < \varepsilon_\alpha \right) = 1 - \alpha$$

$$\mathbb{P} \left(\bar{X} - \varepsilon_\alpha \sqrt{\frac{\hat{\sigma}^2}{n}} < \mu < \bar{X} + \varepsilon_\alpha \sqrt{\frac{\hat{\sigma}^2}{n}} \right) = 1 - \alpha$$

Intervalle de confiance : Exemple

Dans le cas qui nous concerne, on a $\bar{X} = \frac{1917}{500} = 3.834$ et $\hat{\sigma}^2 = \frac{500}{499} \left(\frac{1}{500} \times 8959 - 3.834^2 \right) = 3.2248938$.

Si on considère un intervalle de confiance au risque $\alpha = 0.001$, on obtient :

$$\mathbb{P} \left(3.834 - 3.29053 \sqrt{\frac{3.2248938}{500}} < \mu < 3.834 + 3.29053 \sqrt{\frac{3.2248938}{500}} \right) = 0.999$$

soit finalement

$$\mathbb{P}(3.57 < \mu < 4.098) = 0.999$$

La valeur théorique de $\mu = 3.5$ pour un dé équilibré ne fait pas partie de l'intervalle de confiance au risque 0.001.

Intervalle de confiance de la moyenne μ : synthèse

Dist. de X_i	σ^2	$n < 30$	$n \geq 30$
$\mathcal{D}(\mu, \sigma^2)$	connue	on ne sait pas	$\mathbb{P}\left(\bar{X} - \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} < \mu < \bar{X} + \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}}\right) = 1 - \alpha$
	estimée ¹	on ne sait pas	$\mathbb{P}\left(\bar{X} - \varepsilon_\alpha \sqrt{\frac{\hat{\sigma}^2}{n}} < \mu < \bar{X} + \varepsilon_\alpha \sqrt{\frac{\hat{\sigma}^2}{n}}\right) = 1 - \alpha$
$\mathcal{N}(\mu, \sigma^2)$	connue	$\mathbb{P}\left(\bar{X} - \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}} < \mu < \bar{X} + \varepsilon_\alpha \sqrt{\frac{\sigma^2}{n}}\right) = 1 - \alpha$	
	estimée	$\mathbb{P}\left(\bar{X} - t_{\alpha, n-1 \text{ ddl}} \sqrt{\frac{\hat{\sigma}^2}{n}} < \mu < \bar{X} + t_{\alpha, n-1 \text{ ddl}} \sqrt{\frac{\hat{\sigma}^2}{n}}\right) = 1 - \alpha$	

1. Le résultat donné ici tient compte de la convergence $\mathcal{T}(n - 1 \text{ ddl}) \rightarrow \mathcal{N}(0,1)$

Avec vos calculatrices TI ou casio

On reprend l'exemple du dé : $n = 500$, $\sum X = 1917$, $\sum X^2 = 8959$ soit $\bar{X} = 3.834$ et $\sqrt{s^2} = 1.794$.

On a un grand échantillon et une distribution quelconque. C'est un IC de type "z".

```
EDIT CALC MENU
1:Z-Test...
2:T-Test...
3:2-CompZTest...
4:2-CompTTest...
5:1-PropZTest...
6:2-PropZTest...
7:ZIntConf...
```

On accède au menu stat.
[MENU][2]
On choisit INTR, puis Z, puis 1-s
[F4][F1][F1]

```
ZIntConf
Entr:Val stats
σ:1.794
x̄:3.834
n:500
Niveau-C: .999
Calculs
```

```
Interv Z 1 échant
Data : Variable
C-Level : 0.999
σ : 1.794
x̄ : 3.834
n : 500
Save Res: None ↓
```

```
ZIntConf
(3.57, 4.098)
x̄=3.834
n=500
```

```
Interv Z 1 échant
Left = 3.57000065
Right = 4.09799935
x̄ = 3.834
n = 500
```

Conclusions.

- Nous avons estimé la moyenne μ de la population grâce à un échantillon.
- D'autres paramètres (σ^2) peuvent être estimés de la même façon.
- Un estimateur $\hat{\mu}$ est une variable aléatoire.
- Les bornes d'un intervalle de confiance sont des variables aléatoires (contrairement à celles d'un intervalle de prédiction).
- Un intervalle de confiance de μ au risque α contient la moyenne μ avec une probabilité $1 - \alpha$.
- Il existe aussi des intervalles de confiance unilatéraux.
- Les intervalles de confiance sont à la base des tests d'hypothèse de conformité.