

PrivateTeacher  
*Cours Privés de Science*

*p - value*

*Interprétation*

Sommaire

Énoncé de l'exercice

Statistique de test

Loi de Student

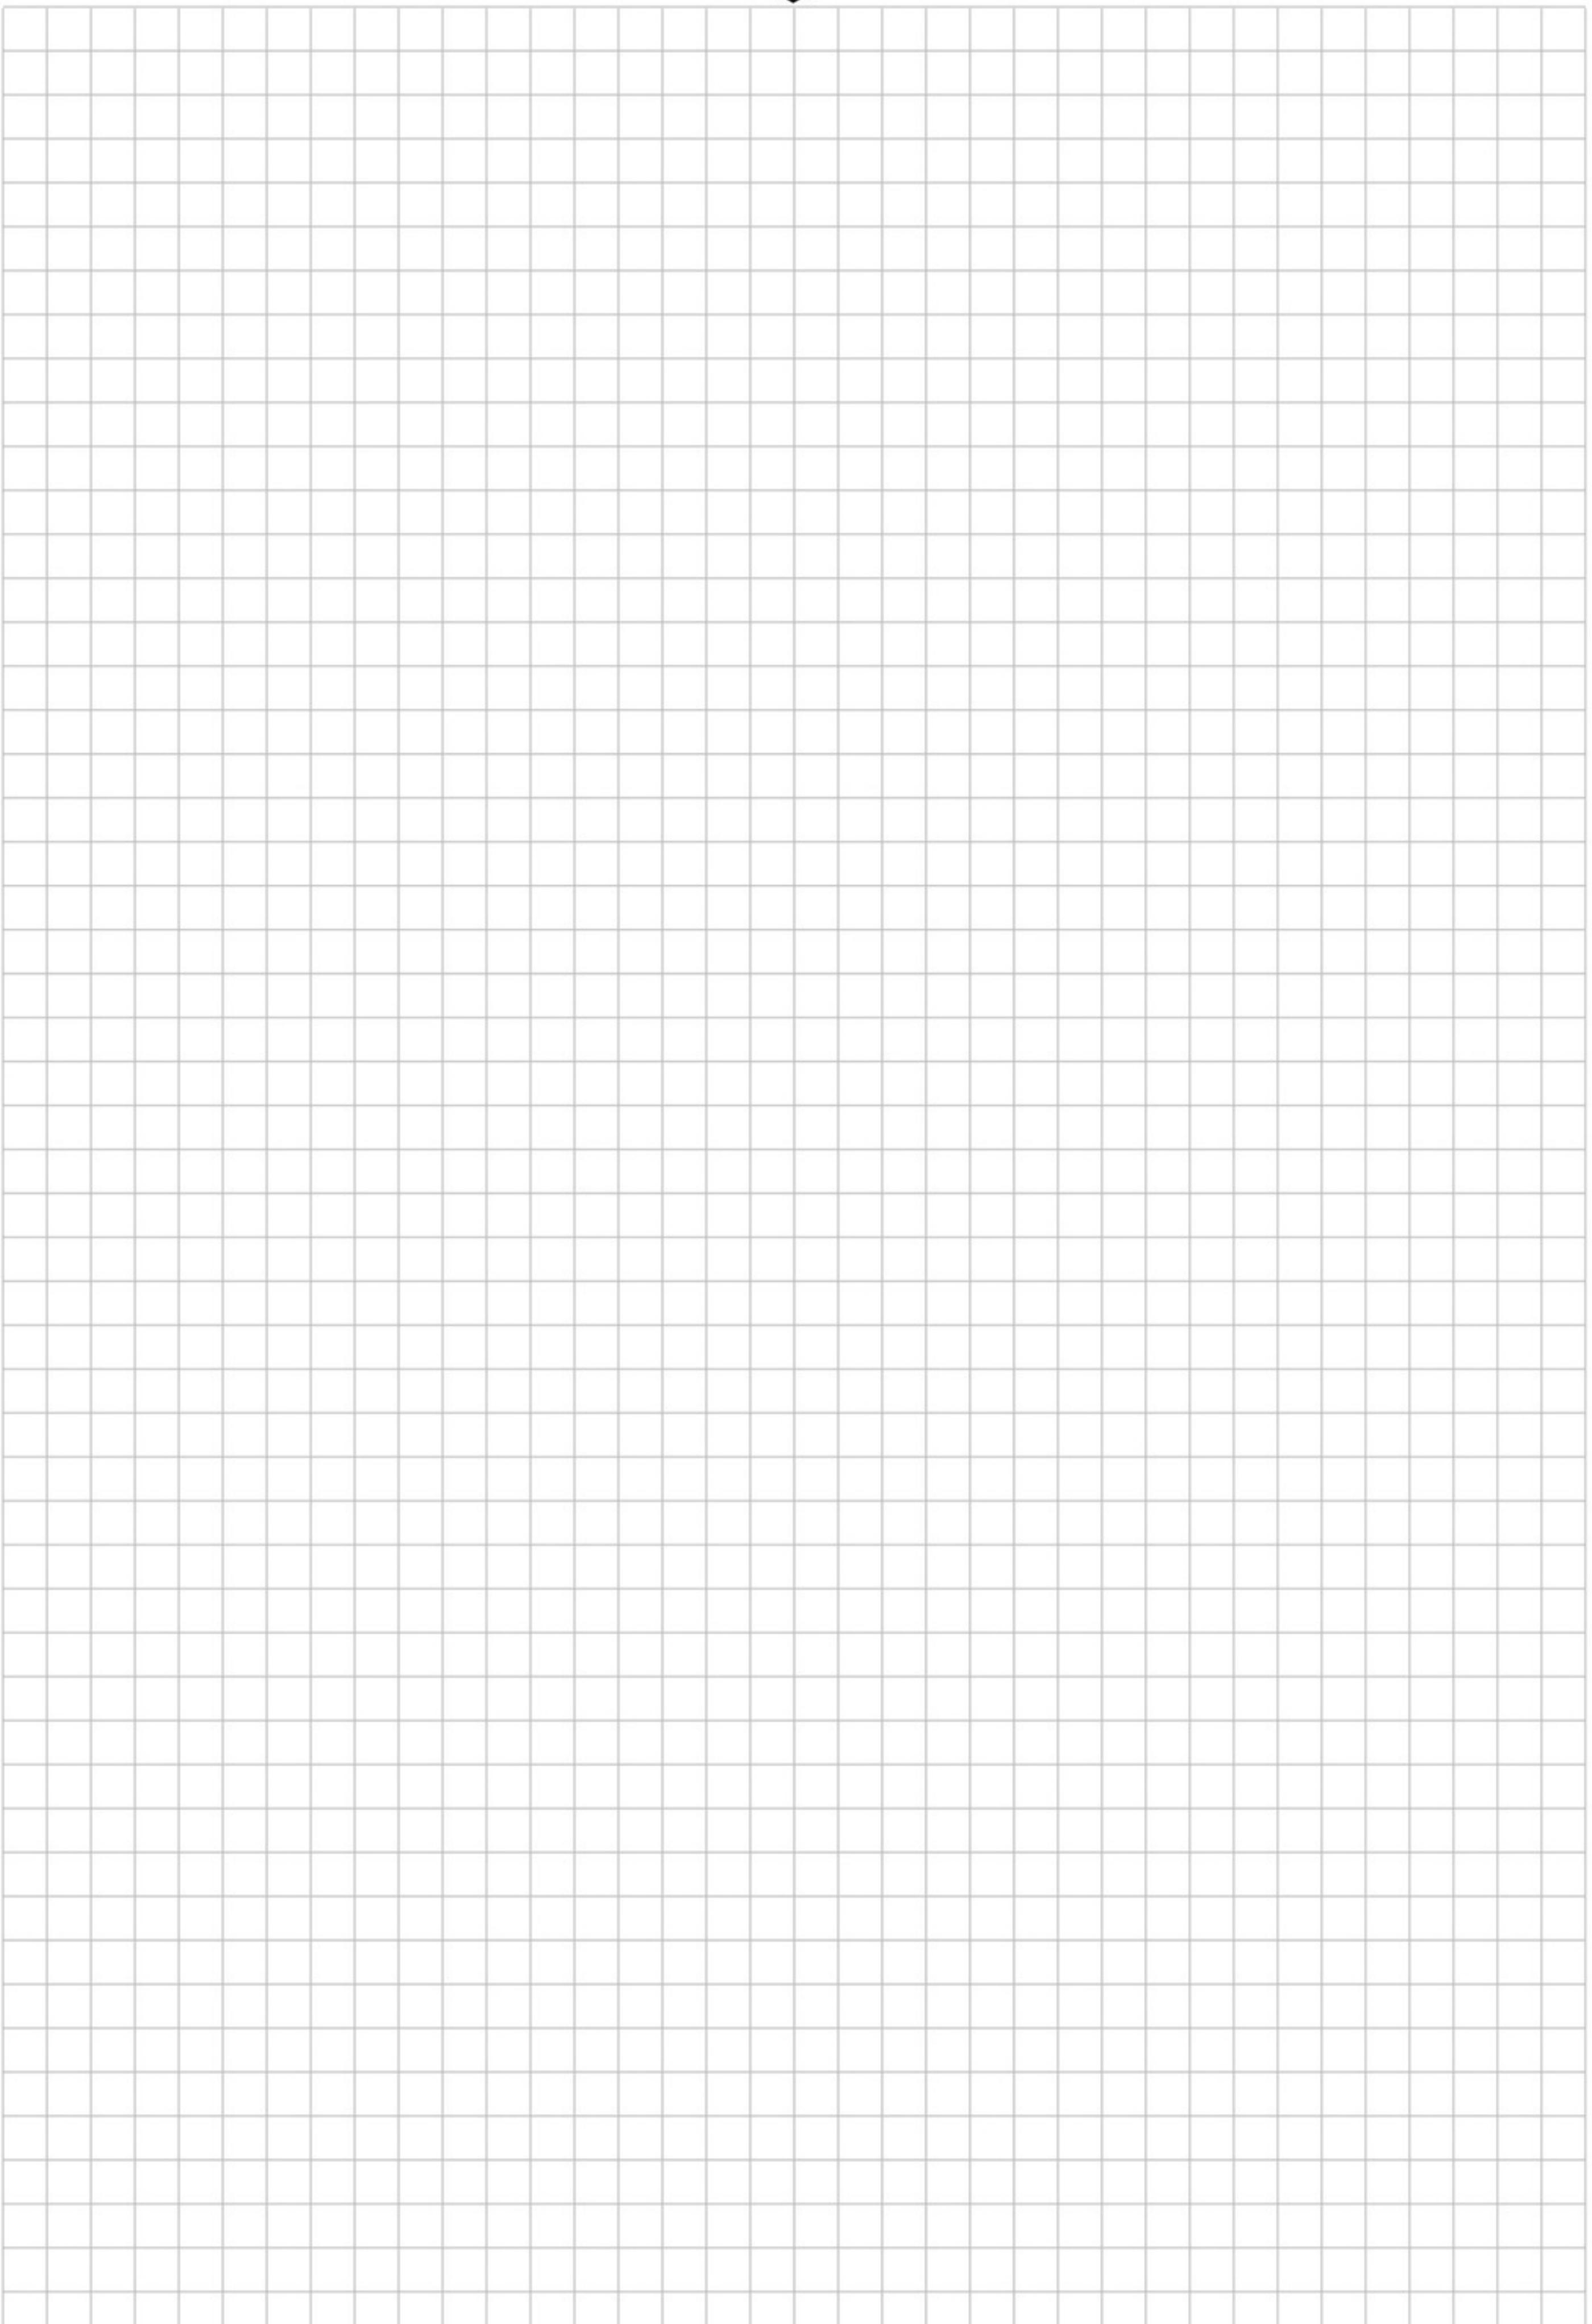
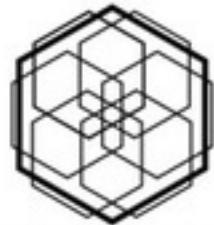
Valeur calculée

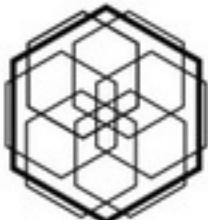
Test d'hypothèse

Seuil de significativité

La valeur-p

Interprétation





## Énoncé

Dans une grande entreprise américaine, le salaire annuel moyen des hommes possédant entre 3 et 5 années d'expérience est de 58'000\$. Les salaires (en milliers de dollars) d'un échantillon aléatoire de 10 femmes possédant entre 3 et 5 ans d'expérience sont les suivants :

54    57    61    51    49    56    60    52    45    66

Voici les résultats d'un test :

One Sample t-test

```
data: x
t = -1.4729, df = 9, p-value = 0.08744
alternative hypothesis : true mean is less than 58
95 percent confidence interval :
-Inf 58.70926
```

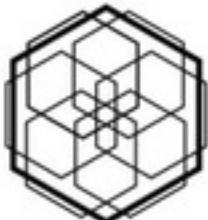
```
sample estimates :
mean of x
55.1
```

Y a-t-il suffisamment d'évidence pour attester que les femmes gagnent moins que les hommes en prenant un risque de 0.05 ?

## Réponse

La valeur-p est supérieure au risque de première espèce fixé à 5%. Nous ne pouvons donc pas rejeter **l'hypothèse nulle** qui indique que la moyenne du salaire des femmes est **supérieure ou égale à 58**. La réponse correcte est donc : Non, ces données ne fournissent pas suffisamment d'évidence pour attester que les femmes gagnent moins que les hommes.





# Statistique de test

Dans cet exercice, on cherche à comparer le salaire moyen des hommes  $\mu_h$  avec le salaire de quelques femmes choisies au hasard  $\hat{\mu}_f$

$\hat{\mu}_f$  est un estimateur car il provient d'un échantillon de femmes.

Ici, on cherche à comparer la moyenne d'une population  $\mu_h$  avec la moyenne estimée à partir d'un échantillon  $\hat{\mu}_f$

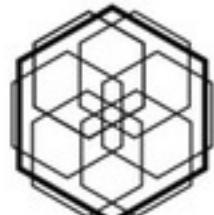
A cette fin, on utilise un nombre qui a été imaginé exprès pour ça.

Il s'agit de la statistique  $t$  qui mesure l'écart entre deux moyennes, l'une réelle  $\mu_h$ , l'autre estimée  $\hat{\mu}_f$ :

$$t = \frac{\hat{\mu}_f - \mu_h}{\sqrt{\frac{s_f^2}{n_f}}}$$

La statistique de test "t" mesure l'écart entre deux moyennes

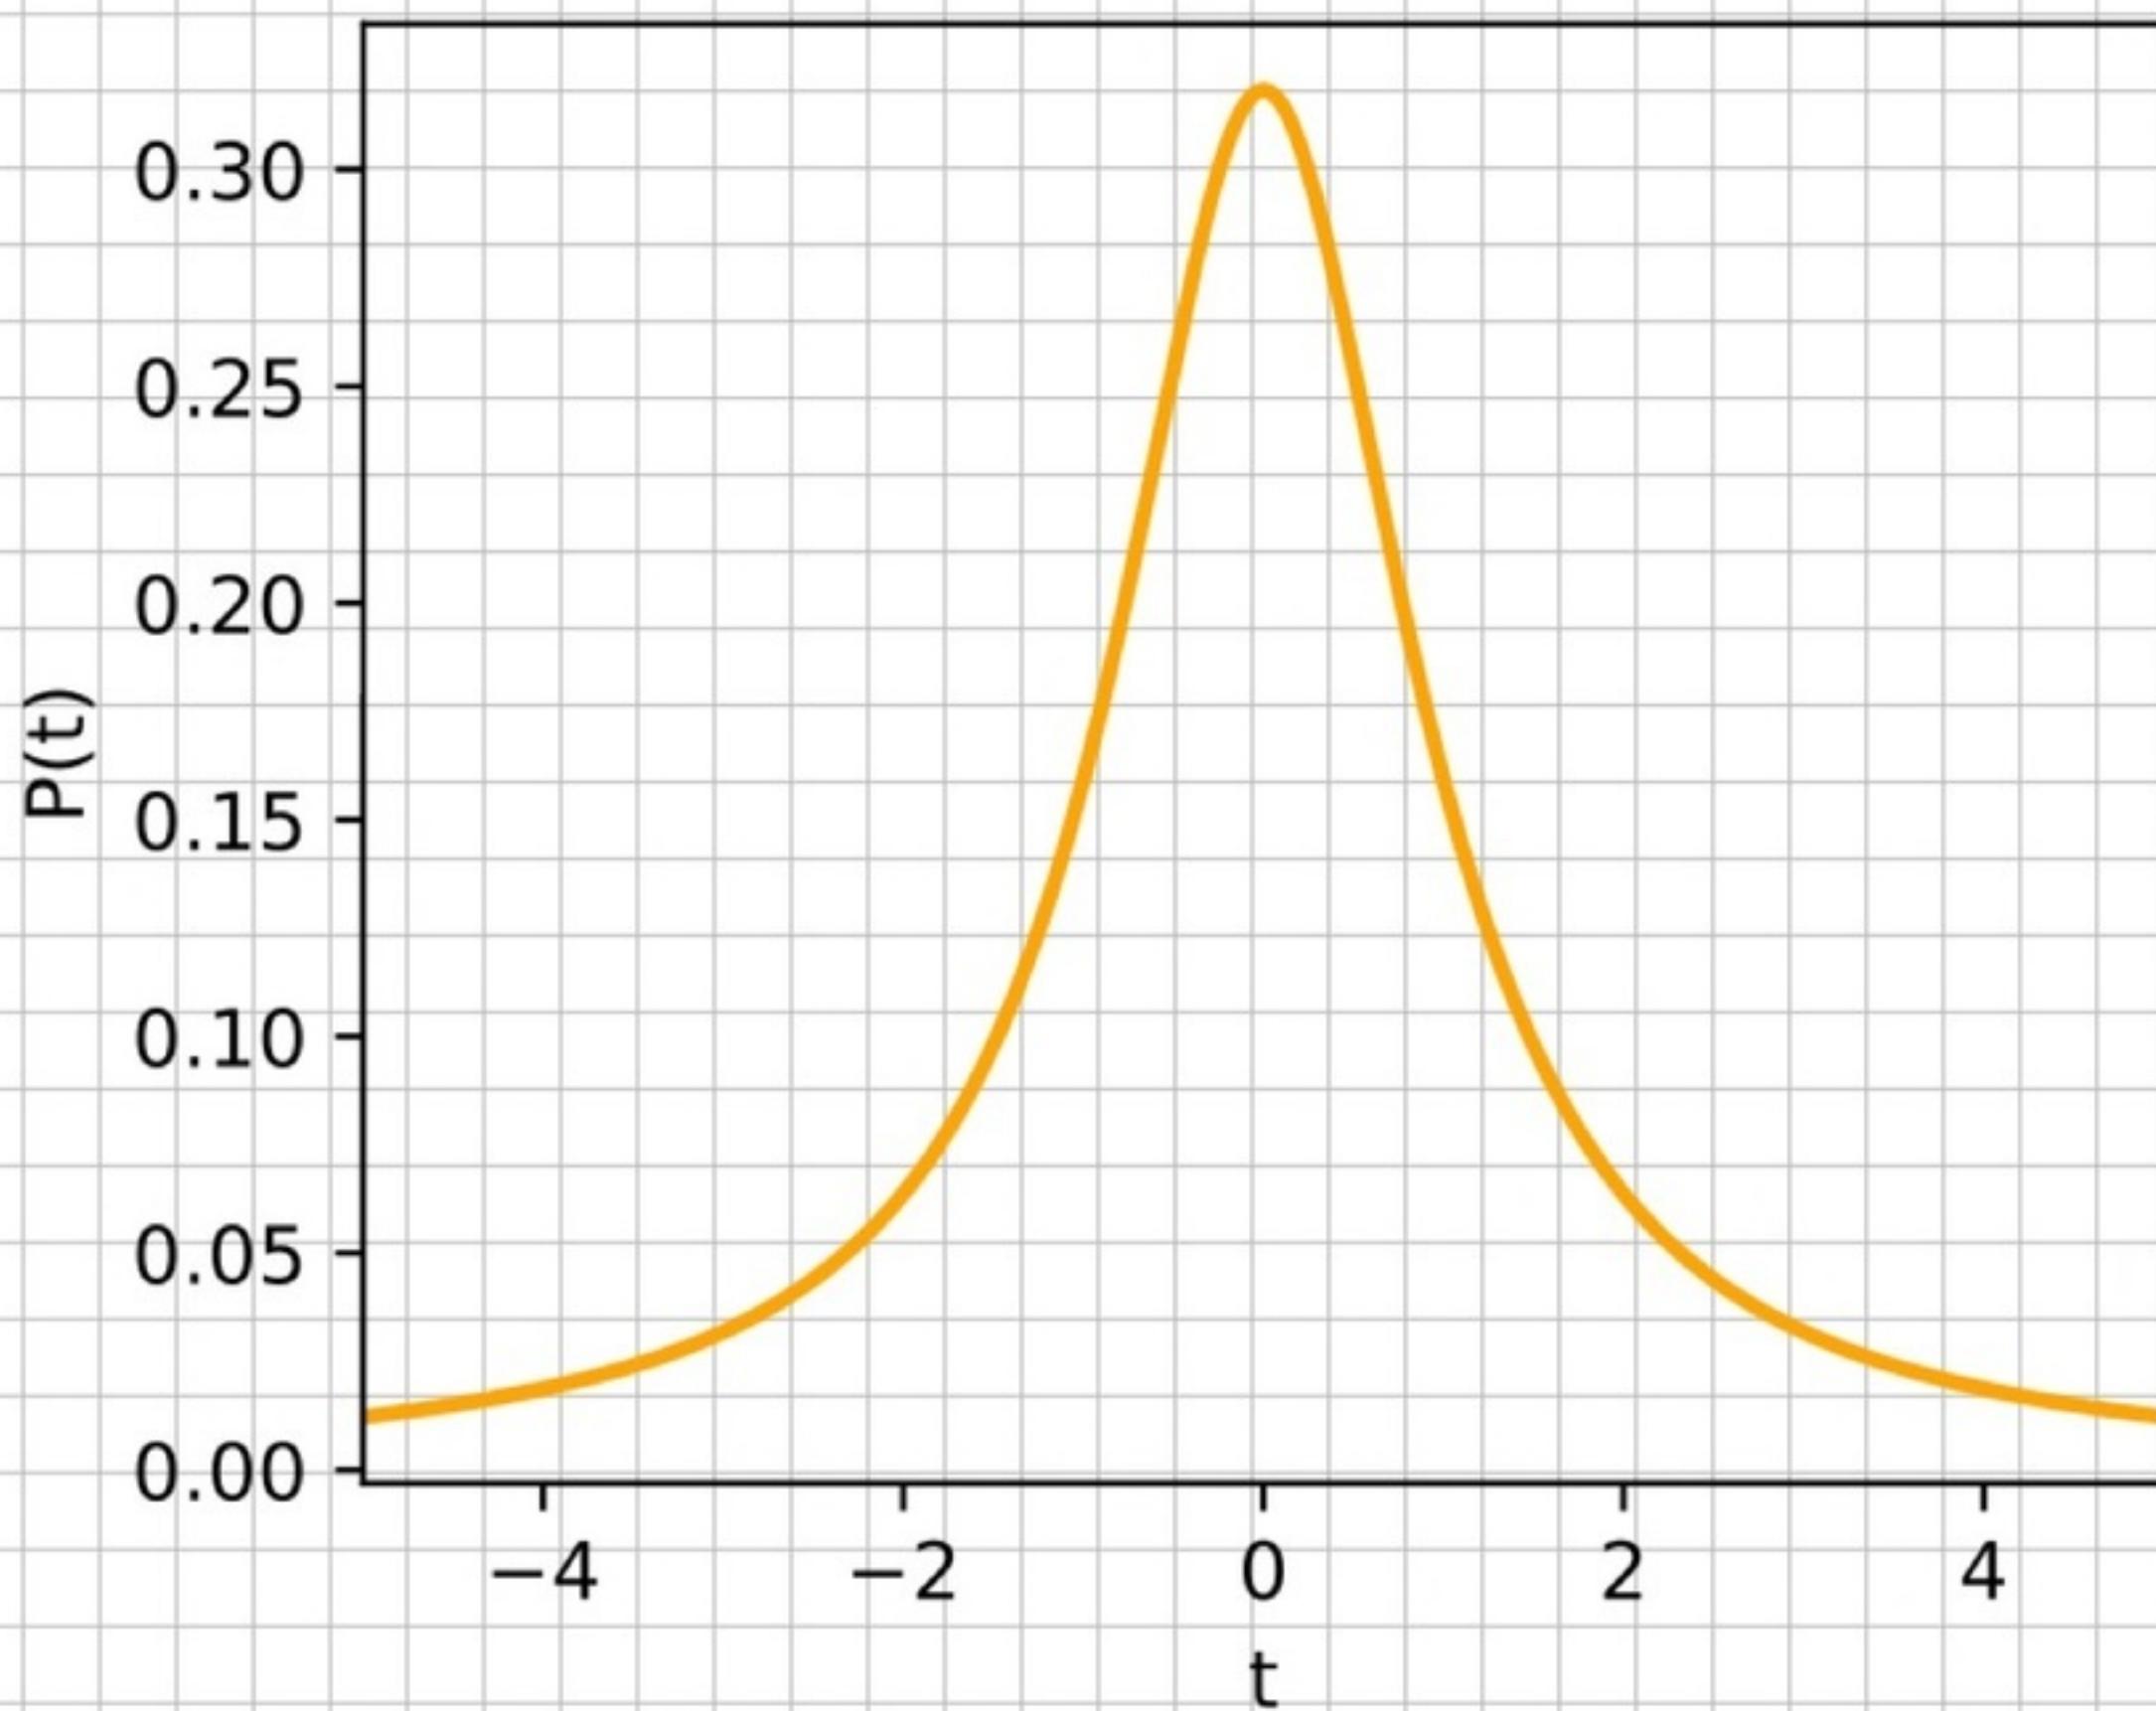




# Loi de Student

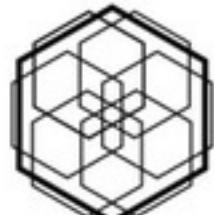
IL se trouve que la statistique t suit une distribution dite "loi de Student"

La loi de Student a la forme suivante :

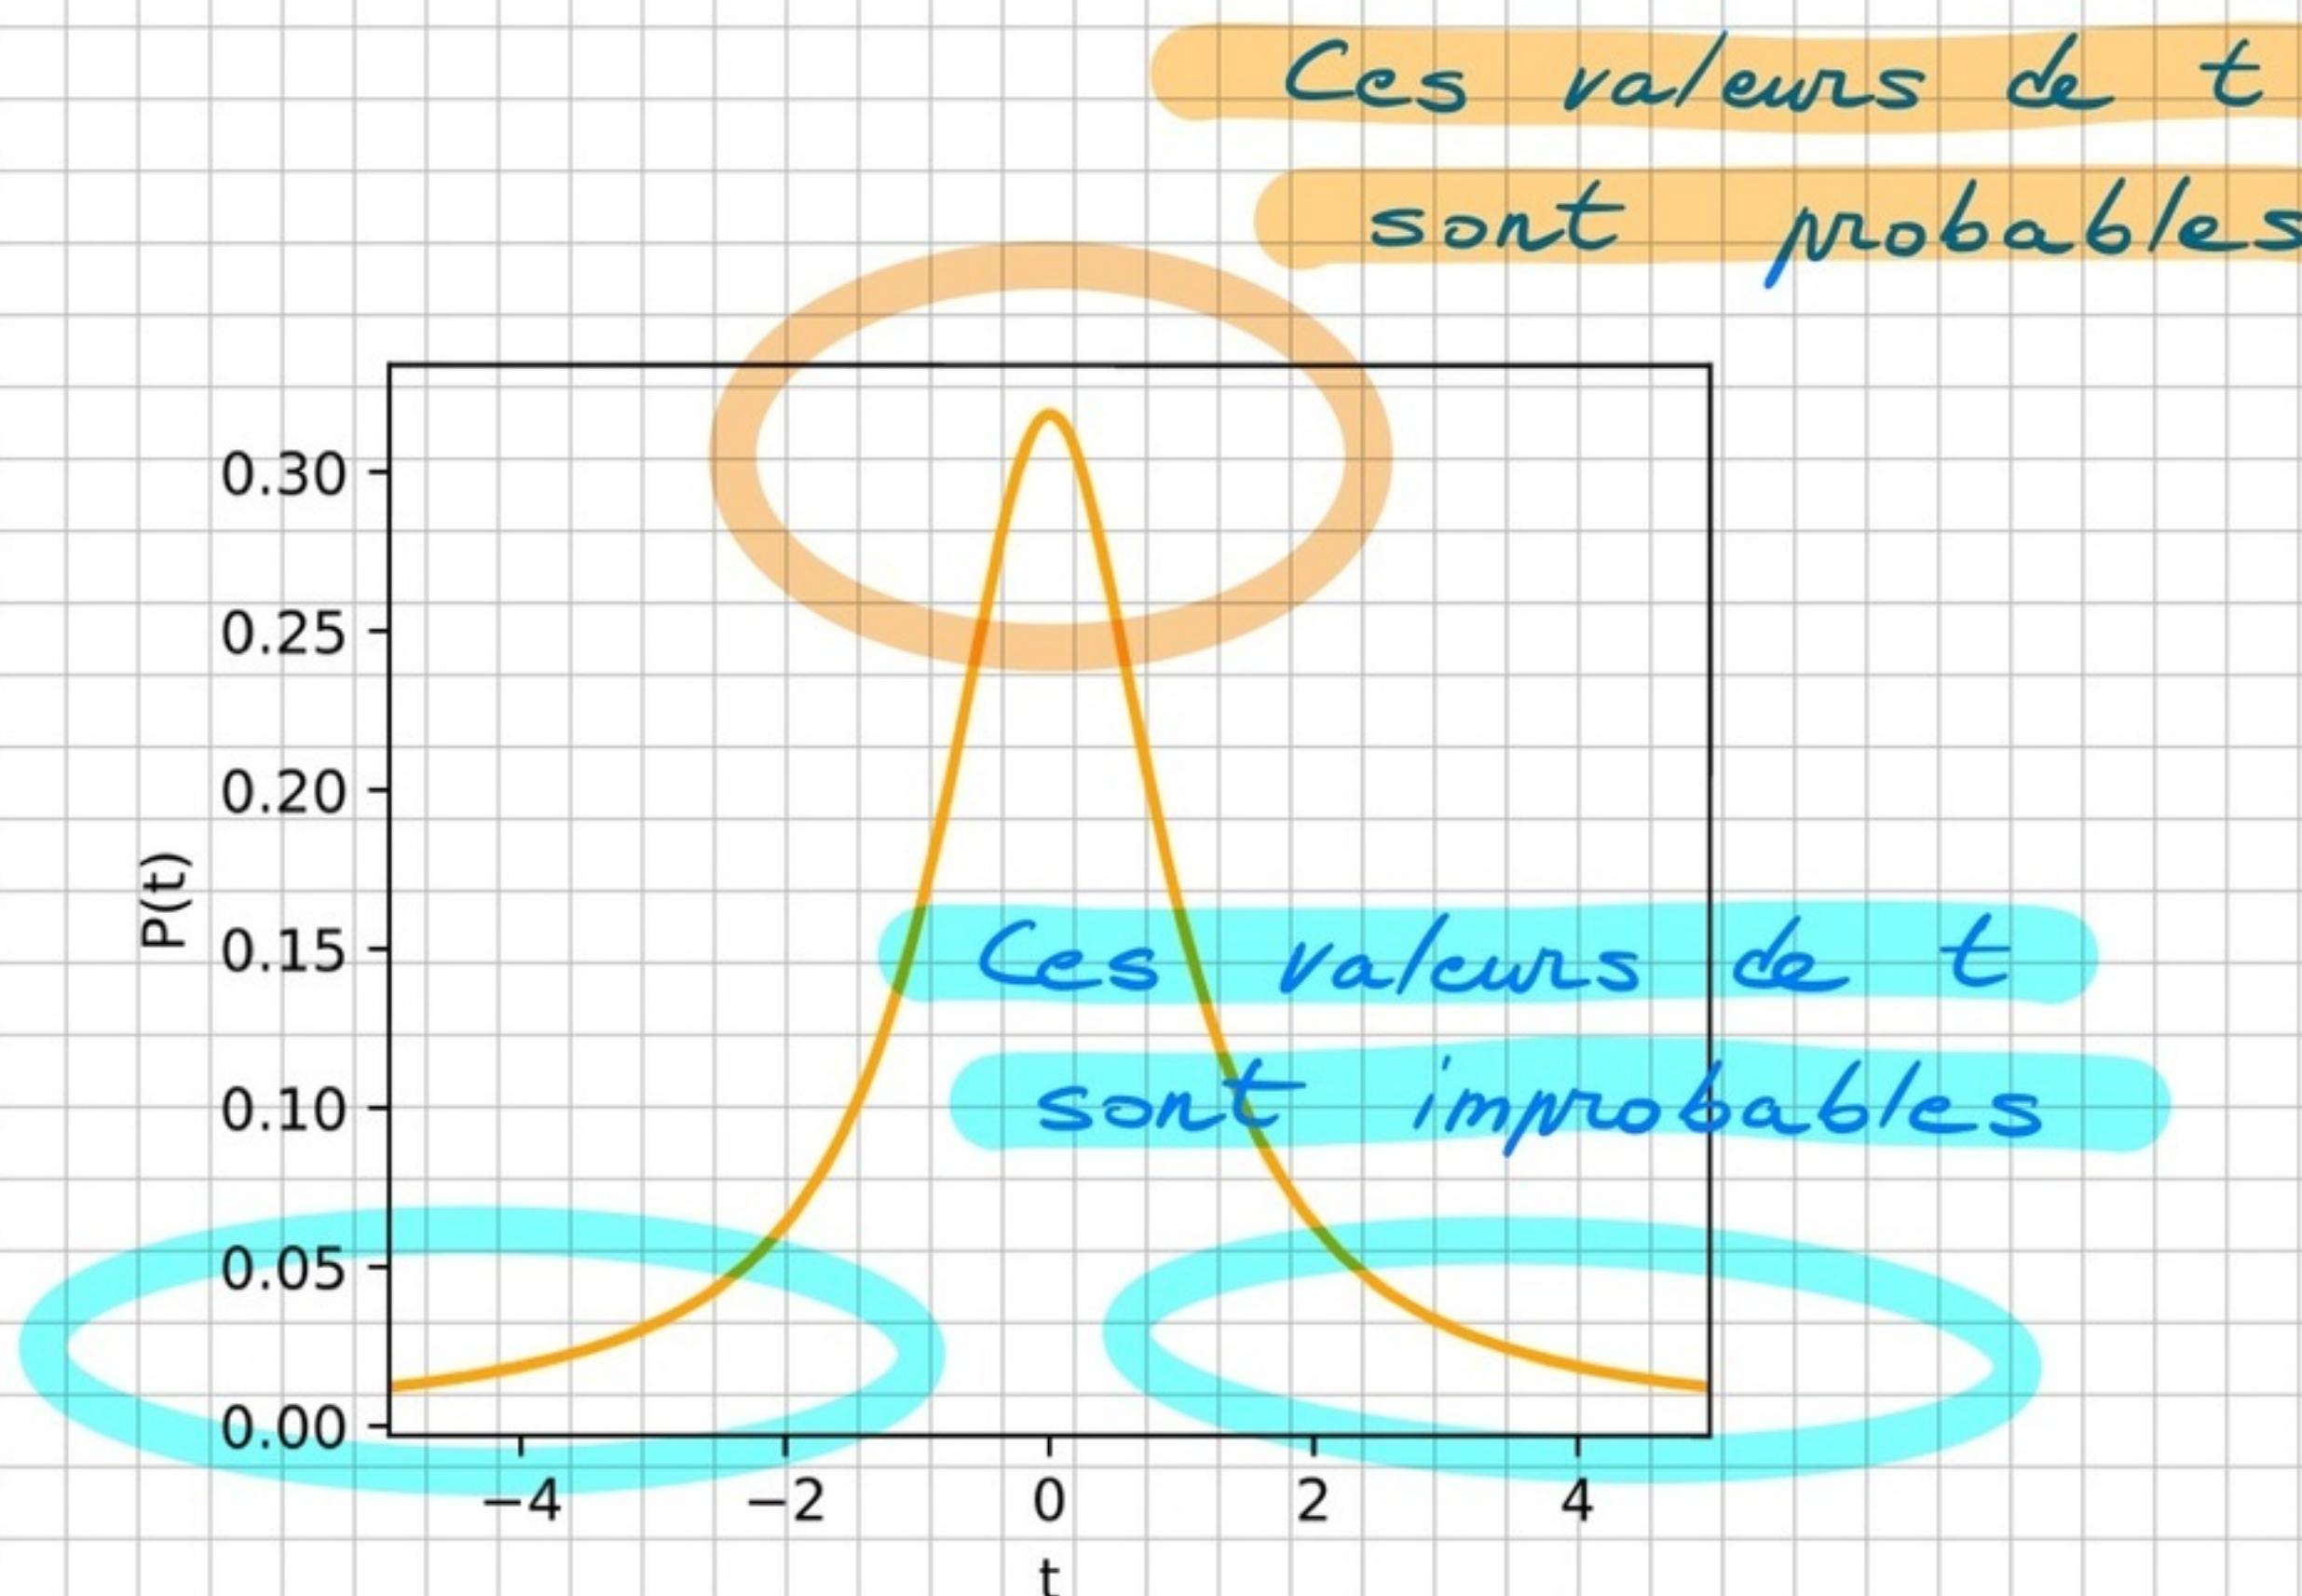


Cette distribution n'est pas une loi normale (gaussienne). Bien qu'elle soit, elle aussi, symétrique par rapport à l'axe  $x = 0$ , la loi de Student est plus épaisse aux extrémités.





L'intérêt de connaître la distribution de probabilité de la statistique de test "t" est de nous permettre de connaître la probabilité d'observer chacune des valeurs possible de t.



Tout le test d'hypothèse repose sur ce graphique

Voyons comment le logiciel l'utilise pour calculer le résultat ...



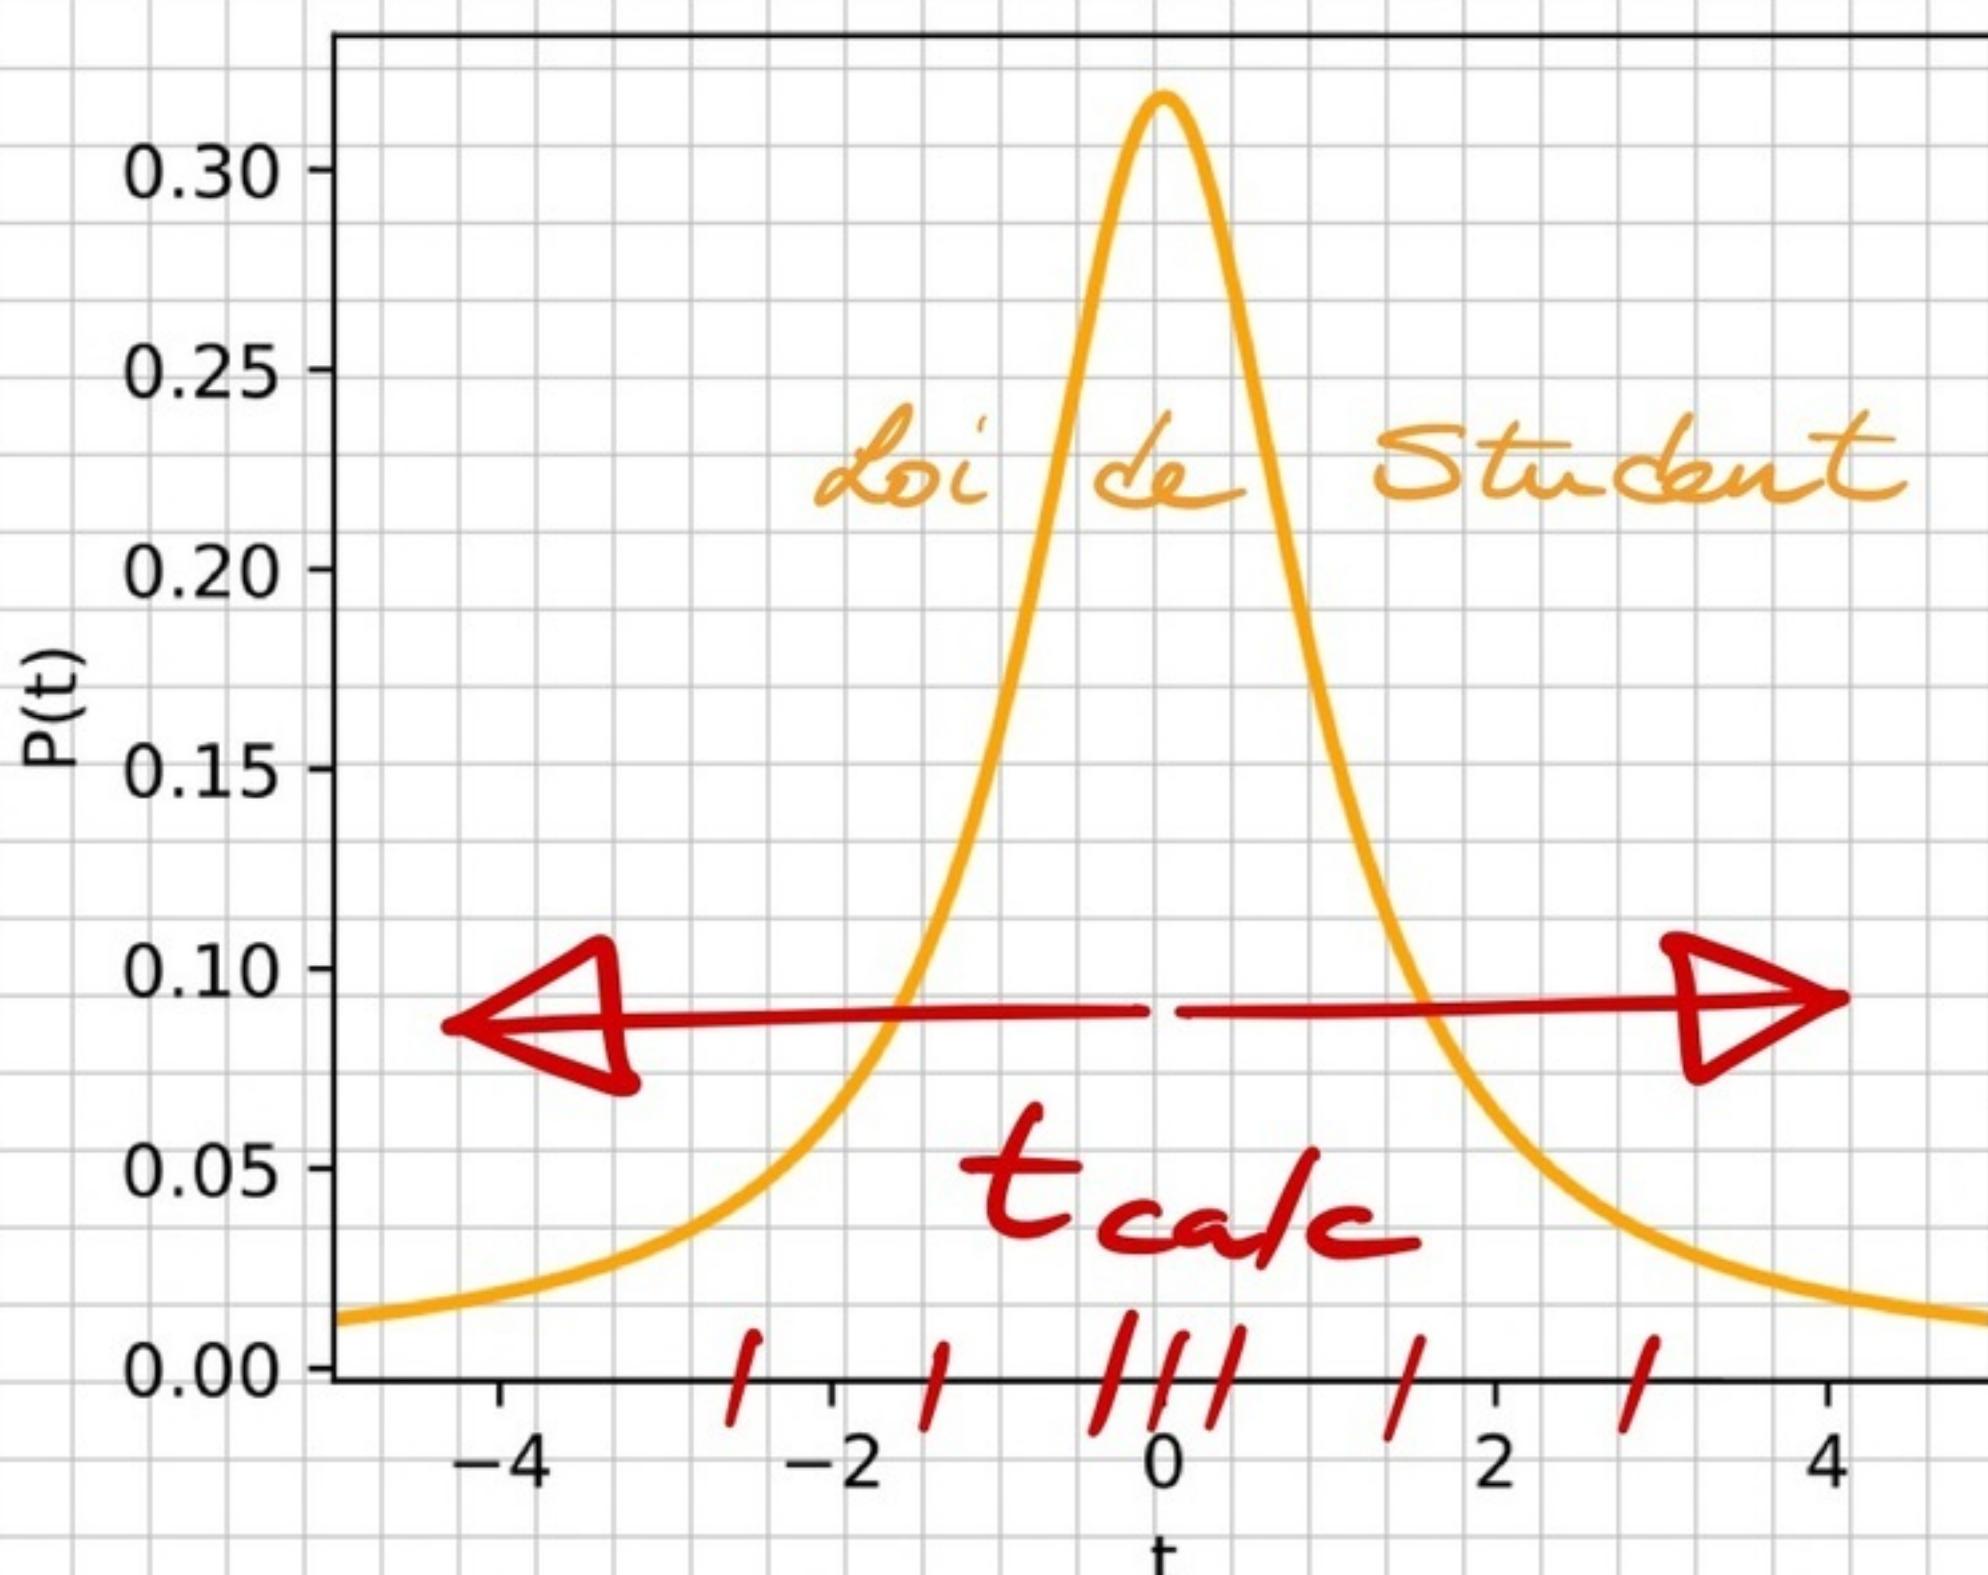


# Valeur calculée

Le logiciel de statistique commence par calculer la valeur de  $t$  dans notre cas particulier. On note cette valeur  $t_{\text{calc}}$

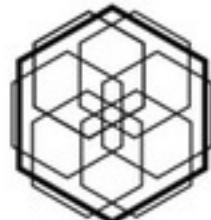
la statistique de test calculée  $t_{\text{calc}}$  prendra place quelque part sur la distribution de Student :

Probabilité d'observer  
↑ une valeur de  $t$   
en particulier.



toutes les valeurs possibles  
de la statistique  $t$  →





# Test d'hypothèse

On le voit, la valeur de  $t$  la plus probable est 0. Cette valeur correspond à l'hypothèse nulle  $H_0$ .

Elle signifie qu'il n'y a pas de différence entre les deux moyennes.

On note :

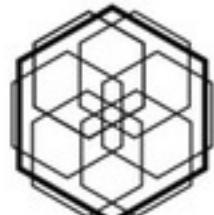
$$H_0 : \mu_h = \hat{\mu}_f$$

Un test d'hypothèse consiste à situer la valeur calculée  $t_{\text{calc}}$  au sein de la distribution de Student afin de déterminer si cette valeur est probable ou pas.

Si la valeur calculée de la statistique de test  $t_{\text{calc}}$  est probable, alors on détient un argument en faveur de  $H_0$ .

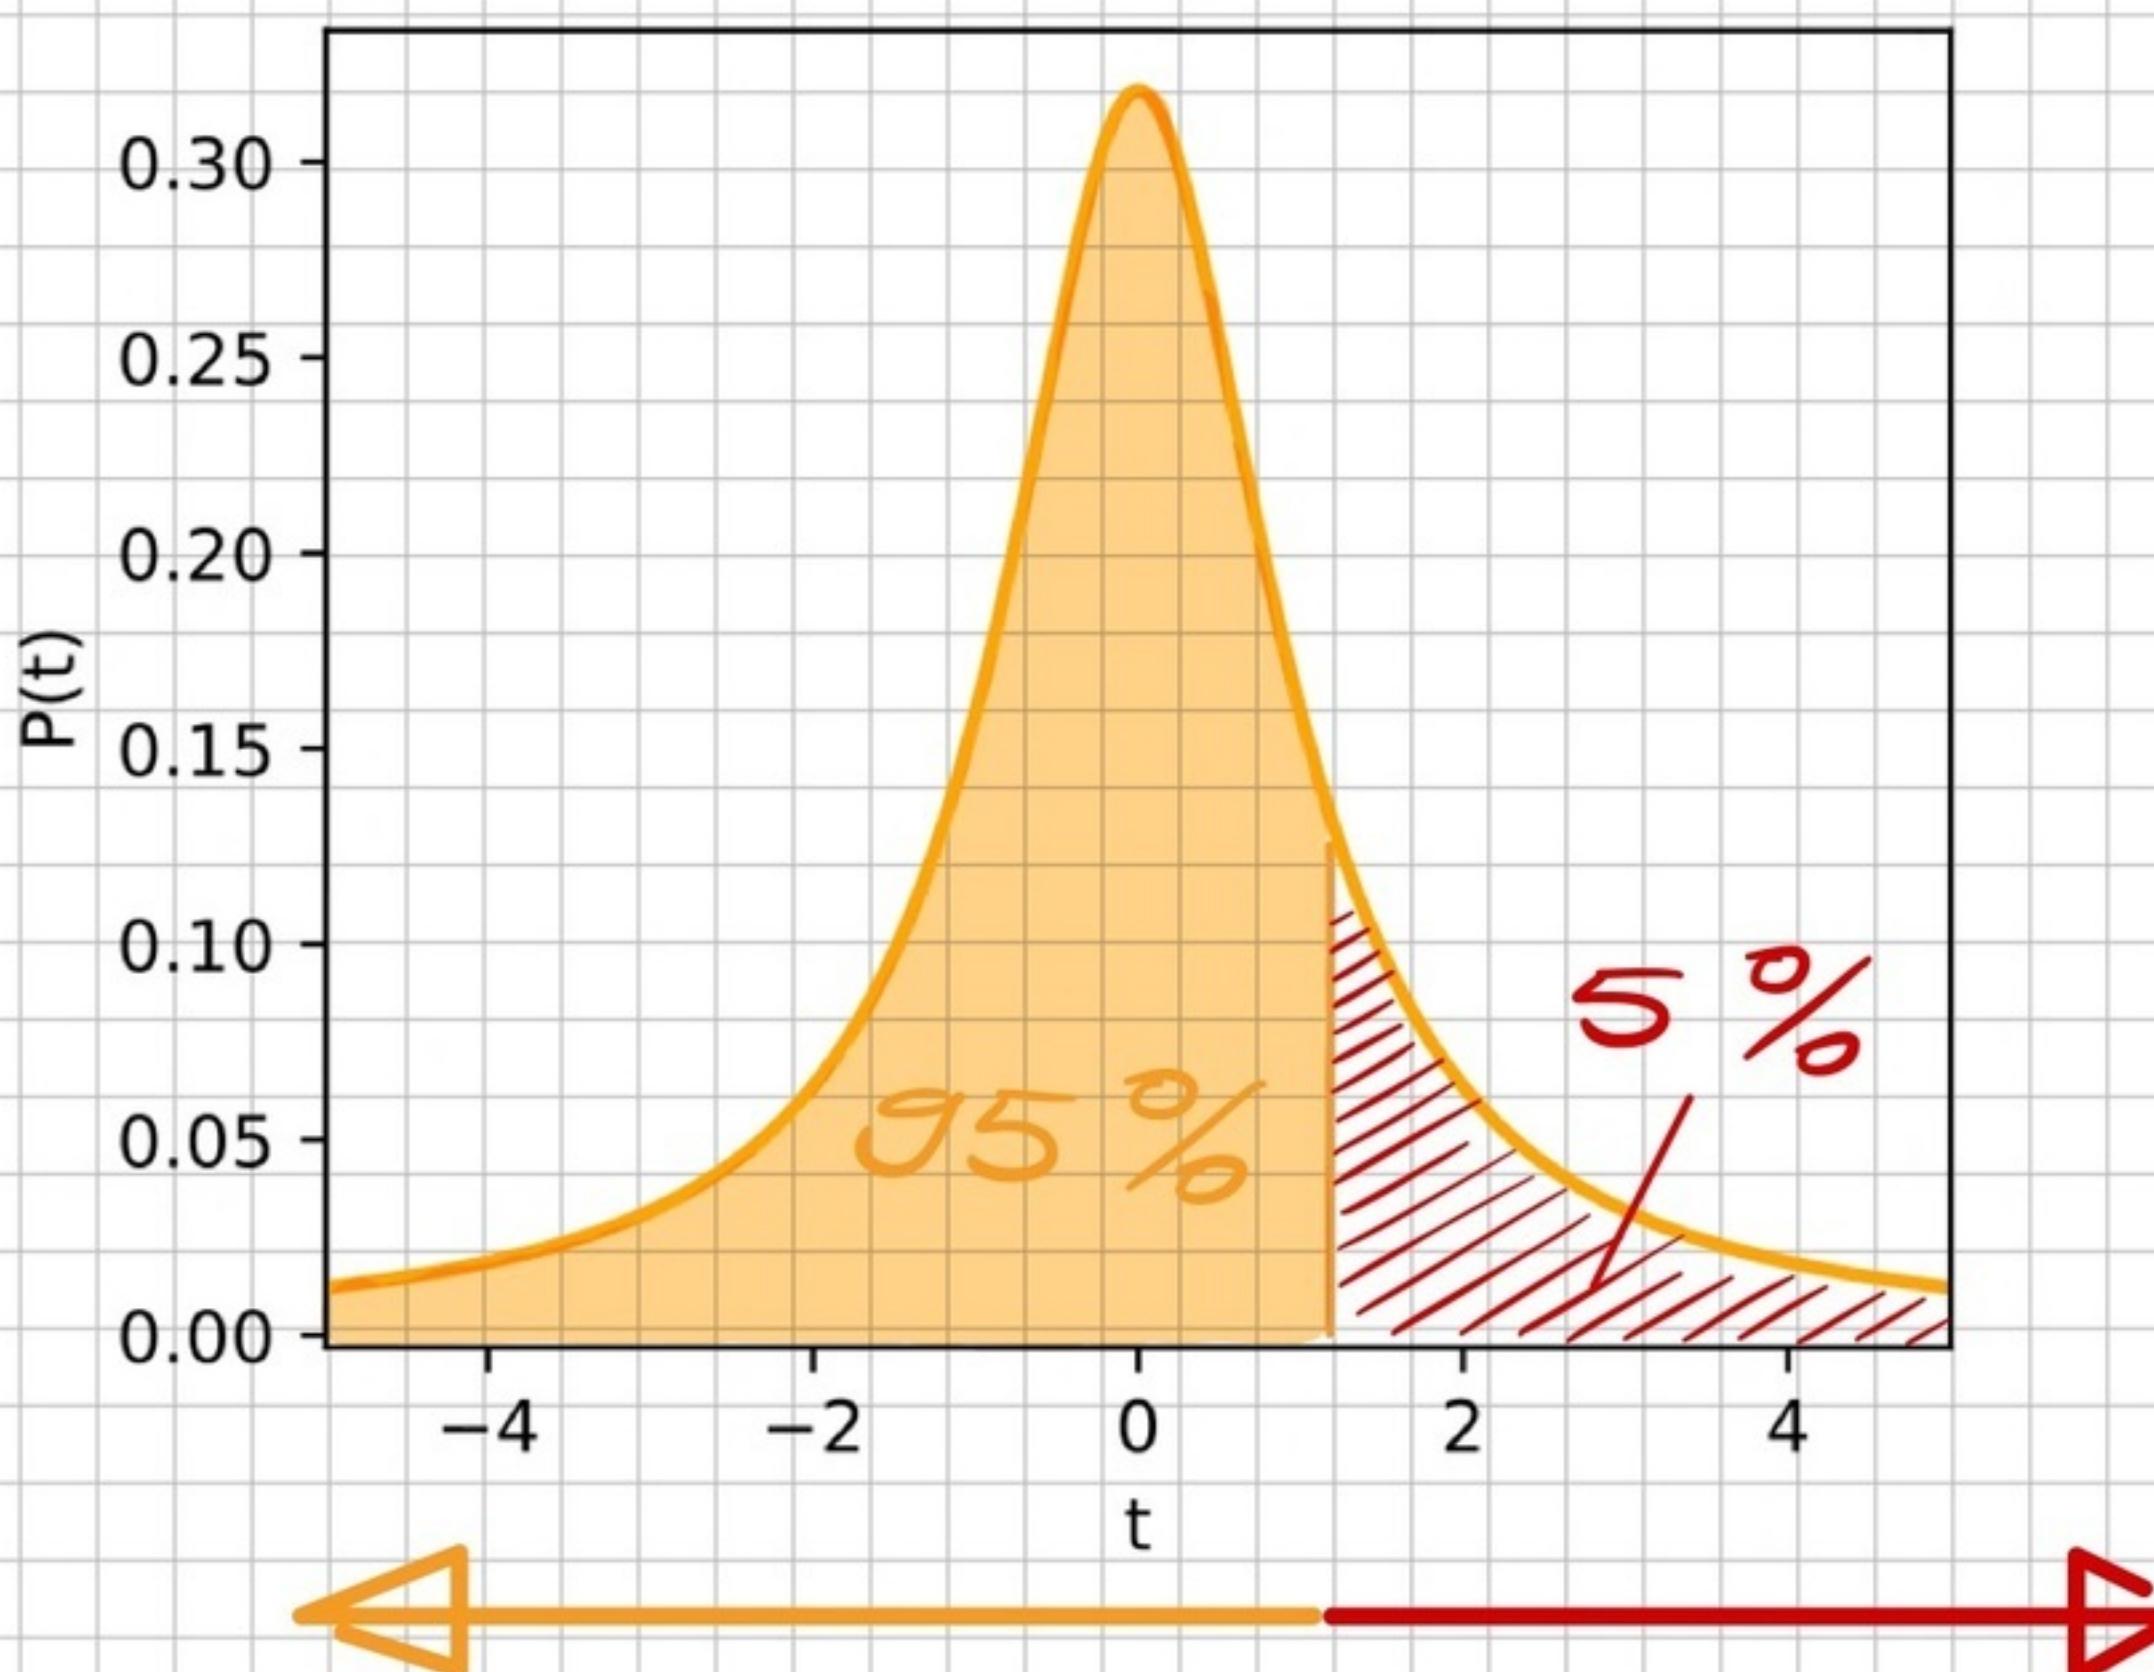
Si la valeur calculée de la statistique de test  $t_{\text{calc}}$  est improbable, alors on détient un argument en faveur de  $H_1$ .





# Seuil de significativité

C'est à nous de fixer le seuil de ce que l'on considère comme "probable". On choisit souvent 95 %



Ces valeurs de  $t$   
sont probables

$\Leftrightarrow$   
 $H_0$  est raisonnable

Zone d'acceptation

Ces valeurs de  $t$   
sont improbables

$\Leftrightarrow$   
 $H_0$  est déraisonnable

Zone de rejet



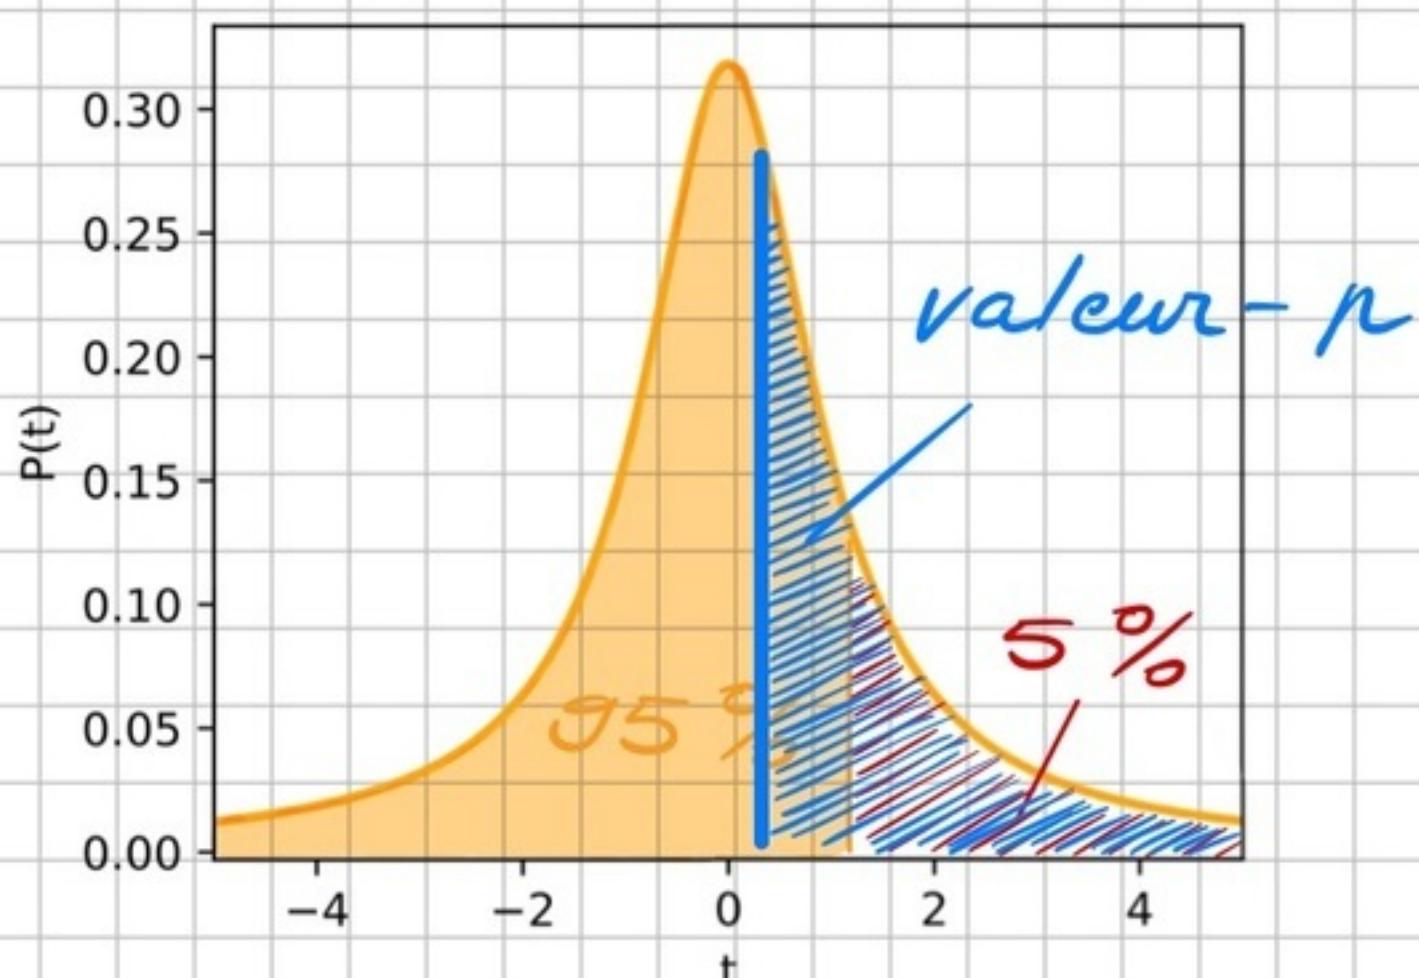


# La valeur-p

Une fois le seuil fixé, le logiciel calcule la probabilité d'observer une valeur de  $t$  plus grande ou égale à la valeur de  $t$  calculée  $t_{\text{calc}}$

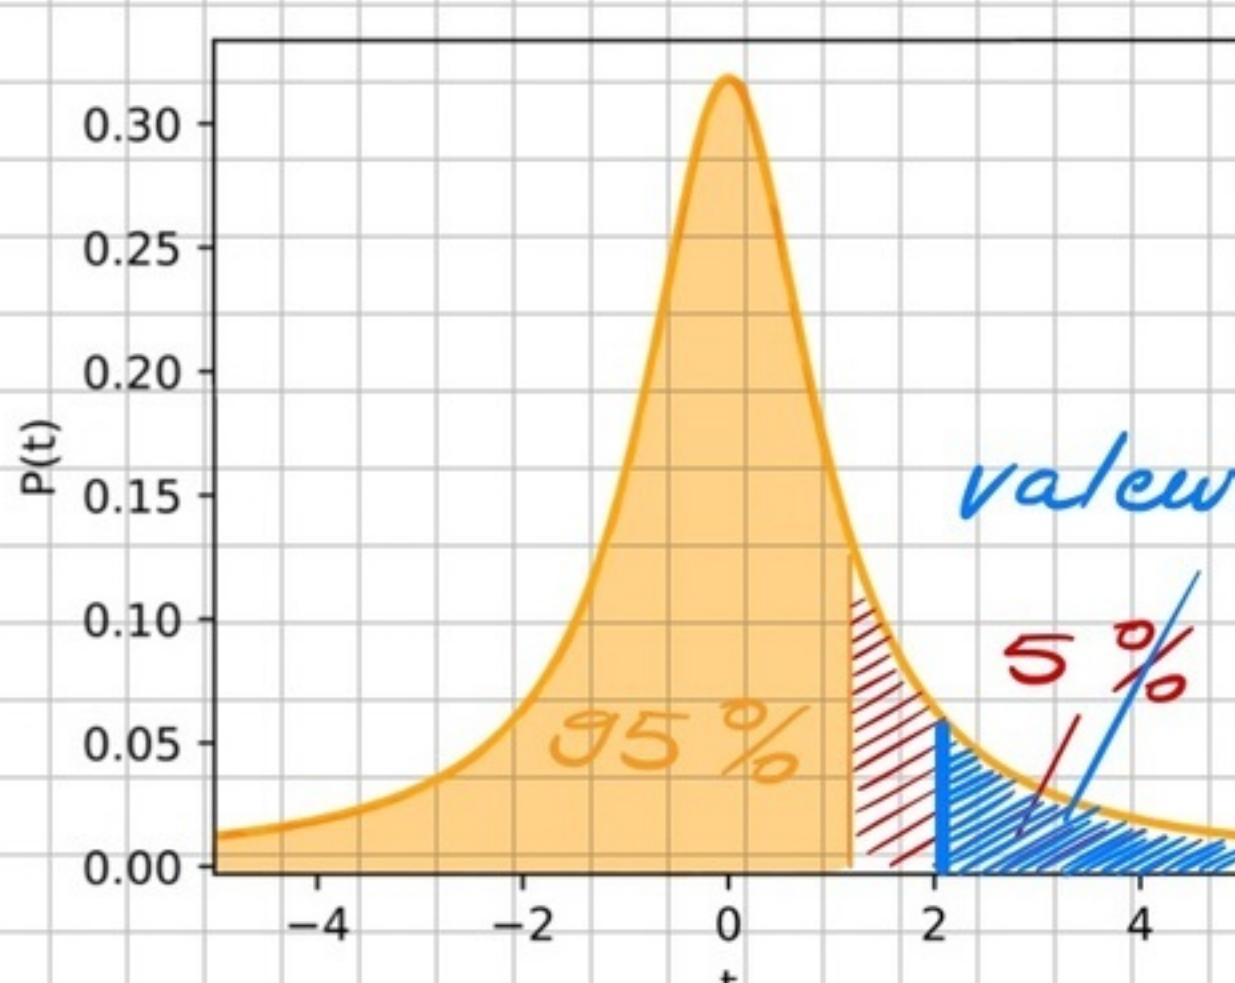
Cette probabilité se nomme : valeur- $p$

$$\text{valeur-}p = P(t \geq t_{\text{calc}})$$



Valeur- $p > 5 \%$

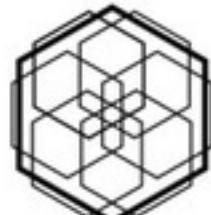
$\Rightarrow t_{\text{calc}}$  probable  
 $\Rightarrow H_0$  raisonnable



Valeur- $p < 5 \%$

$\Rightarrow t_{\text{calc}}$  peu probable  
 $\Rightarrow H_0$  déraisonnable





# Interprétation

Ainsi lorsque le logiciel nous retourne  
 $p\text{-value} = 0.087 (> 0.05)$   
cela signifie que la valeur calculée  
de  $t$ ,  $t_{\text{calc}} = -1,47$  est probable.

Il s'agit donc d'une indication en  
faveur de  $H_0$

$$H_0 : \bar{\mu}_f = \mu_h$$

$\Leftrightarrow$

L'estimation du salaire moyen  
des femmes est égale au salaire  
moyen des hommes.

A la question : "y a-t-il suffisamment  
d'évidence pour attester que les femmes  
gagnent moins que les hommes"

on répondra donc : "Non, il n'y a pas  
suffisamment d'évidence"



