






PrivateTeacher
Cours Privés de Science

Test de Student et valeur- p Corrigé Détaillé

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 52'200\$. 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 greater than 52.2

95 percent confidence interval:

51.49074 Inf

sample estimates:

mean of x

55.1


Question

Y a-t-il suffisamment d'évidence pour attester que les femmes gagnent plus 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** selon laquelle **le salaire des femmes est identique à celui des hommes**. La réponse est donc : Non, les données ne fournissent pas suffisamment d'évidence pour attester que les femmes gagnent significativement plus que les hommes.





Statistique de test

Dans cet exercice, on cherche à comparer le salaire moyen des hommes μ_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 μ_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 μ_h , l'autre estimée $\hat{\mu}_f$:

$$t = \frac{\hat{\mu}_f - \mu_h}{\frac{\sigma_f}{\sqrt{n_f}}} \quad \mu - \mu_0$$

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.

Ces valeurs de t sont probables



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_{calc}

la statistique de test calculée t_{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_{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_{calc} est probable, alors on détient un argument en faveur de H_0


Si la valeur calculée de la statistique de test t_{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



H_0 est raisonnable

Ces valeurs de t
sont improbables




H_0 est déraisonnable

Zone d'acceptation

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_{calc}


Cette probabilité se nomme : valeur-p

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



Valeur-p > 5%


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



Valeur-p < 5%

$\Rightarrow t_{calc}$ 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
favor de H_0

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

$\Leftrightarrow$

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

À 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 "



