

Exercices de biostatistique

Rappel: pour visualiser la formule associée aux résultats obtenus, il vous suffit d'aller cliquer sur la case concernée(uniquement dans excel et non avec "Adobe Acrobat") !!

Intervalles de confiance

Exercice 1

Calculez l'intervalle de confiance de la prévalence d'une maladie pour laquelle 200 cas ont été diagnostiqués dans 1000 individus pris au hasard ? Répétez si on a 1 cas sur 5.

Grand échantillon

$$p \text{ estimé} = 200/1000 = 0.2$$

$$P\{pe-1,96*\sqrt{pe*qe/n} < p < pe+1,96*\sqrt{pe*qe/n}\} = 0.95$$

$$pi \quad 0,17520774$$

$$ps \quad 0,22479226$$

Petit échantillon

Chercher p tel que la probabilité d'avoir 1 cas ou moins = 0.025 => ps

$$\begin{aligned} B(0)+B(1) = 0.025 & \Rightarrow (1-p)^4*(1+4p) = 0.025 \\ & \Rightarrow ps \quad 0,71642019 \\ & \quad \text{expr} \quad 0,02499926 \end{aligned}$$

Chercher p tel que la probabilité d'avoir 1 cas ou plus = 0,025 => pi

$$\begin{aligned} B(0) = 0.975 & \Rightarrow (1-p)^5 = 0.975 \\ & \Rightarrow (1-p) = 0,975^{0.2} \\ & \Rightarrow p = 1 - (0.975^{0.2}) = \quad 0,00505076 \end{aligned}$$

Exercice 2

Calculez l'intervalle de confiance de la moyenne d'une distribution de Poisson si k observé est 1. Comment procéderiez vous si k=2 ?

Chercher μ tel que $P(k=0) + P(k=1) = 0.025 \Rightarrow \mu s$

$$\begin{aligned} \exp(-\mu s)*(1+\mu s)=0.025 & \Rightarrow \mu s \quad 5,57168473 \\ & \Rightarrow \text{expr} \quad 0,02499912 \end{aligned}$$

Chercher μ tel que $P(k=1) + P(k=2) + \dots = 0.025 \Leftrightarrow P(k=0) = 0.975$

$$\exp(-\mu l) = 0,975 \quad \Rightarrow \quad \mu l \quad 0,02531781$$

Pour k=2, meme raisonnement:

$$P(k=0 | \mu s) + P(k=1 | \mu s) + P(k=2 | \mu s) = 0.025$$

$$P(k=0 | \mu l) + P(k=1 | \mu l) = 0.975$$

Exercice 3

On sait que, chez la vache, au moment du part, la calcémie tombe à la valeur moyenne de 7.6 mgr % (déviation standard: 1.4), ce qui donne parfois lieu à des accidents hypocalcémiques (fièvre de lait). Dans le but de prévenir ces accidents, on a préconisé l'emploi d'un produit, le tachystérol, qui mobilise le calcium osseux; celui-ci, administré à 100 vaches, une semaine avant le vêlage, a fait remonter la calcémie (moyenne) à 8.3 mgr %. Ce produit est-il vraiment efficace pour relever la calcémie ? Dans quelles limites pouvait-on attendre la calcémie si le traitement n'est pas efficace (c'est à dire, sous l'hypothèse nulle) ?

On peut reformuler le problème en se demandant: quelle est la probabilité d'obtenir une moyenne sur 100 vaches de 8.3 mgr % si ces vaches proviennent d'une population de moyenne 7.6 mgr % et de déviation standard 1.4 mgr % ?

Le raisonnement est bien entendu que si cette probabilité est anormalement petite, on aura tendance à considérer que l'échantillon ne provient pas de cette population (mais d'une population dans laquelle la moyenne est > 7.6 mgr %), ce qui signifie que le tachystérol a un effet.

On peut employer un test classique de z:

$$z = (X_m - \mu_m) / \sigma_m = (X_m - \mu) / (\sigma / \text{racine}(100))$$

où l'indice m indique que les paramètres correspondants sont les paramètres de la distribution des moyennes.

On obtient:

$$z = (8.3 - 7.6) / (1.4 / 10) = 5$$

ce qui correspond à une probabilité de : $P(z > 5) = 2,871E-07$

Clairement, l'amélioration est très significative, et on rejette l'hypothèse nulle.

Si le traitement n'est pas efficace, $\mu = 7.6$, et on s'attend à trouver 95 % des moyennes calculées sur des échantillons de taille 100 dans les limites:

$$P(\mu - 1.96 * \sigma / 10 < X_m < \mu + 1.96 * \sigma / 10) = 95 \%$$

soit,

$$P(7,3256 < X_m < 7,8744) = 95\%$$

La valeur observée (8.3) tombe nettement en dehors de cet intervalle (de confiance): l'hypothèse nulle, qui a conduit à cet intervalle, est donc rejetée.

Exercice 4

On a mesuré l'épaisseur du lard dorsal chez 10 porcs.

On demande de calculer les limites de l'intervalle de confiance de μ , la vraie valeur de la moyenne de la population.

Peut-on conclure que l'épaisseur du lard dorsal dans cette lignée est différente de celle rencontrée dans la population utilisée plus haut ?

L'intervalle de confiance de la vraie moyenne μ se calcule en partant de :

$$t = (X_m - \mu) / (s / \text{racine}(n)) \quad \text{où } t \text{ a } (n-1) \text{ degrés de liberté}$$

Par conséquent,

$$\mu = X_m + t * s / \text{racine}(n)$$

On ne connaît pas la valeur de t qui résoud cette équation, mais on peut prendre une valeur (négative) de t telle que μ n'a alors que 2.5 % de chance d'être inférieure à:

$$\mu = X_m + t_1 * s / \text{racine}(n)$$

et on peut prendre une valeur positive de t telle que μ n'a alors que 2.5 % de chances d'être supérieur à:

$$\mu = X_m + t_2 * s / \text{racine}(n)$$

Il est clair, par symétrie de la distribution de t, que $t_1 = -t_2$, et par conséquent:

$$P (X_m - t_2 * s / \text{racine}(n) < \mu < X_m + t_2 * s / \text{racine}(n)) = 95\%$$

La valeur correspondante de t_2 se trouve dans la table avec $(n-1)$ degrés de liberté, qui fournit:

$$t_2 = \quad \quad \quad \mathbf{2,26215889}$$

Par ailleurs, n vaut 10 et

$$s = \quad \quad \quad \mathbf{5,16935414}$$

$$X_m = \quad \quad \quad \mathbf{38,5}$$

L'intervalle de confiance correspondant est donc:

$$\mathbf{P (34,802 < \mu < 42,198) = 95\%}$$

Si on considère l'échantillon constitué par les porcs XI à XX, on obtient une moyenne de:

$$X_m = \quad \quad \quad \mathbf{39,3}$$

Cette moyenne tombe dans l'intervalle de confiance: il n'y a pas de raison d'après ces résultats de douter que cet échantillon provient de la même population que celle dont est issu le premier échantillon.

Exercice 5

Si, pour une dilution donnée, on a obtenu expérimentalement une concentration en microorganismes de 1 par unité de volume, quelles sont les limites entre lesquelles on peut attendre la concentration à cette dilution dans la population (au seuil 95%) ?

La concentration suit une distribution de Poisson, et la moyenne expérimentale (calculée sur les données) est $\mu = 1$.

Il est bien entendu possible que la vraie moyenne soit en réalité plus grande ou plus petite que cette moyenne expérimentale, et que l'on ait obtenu $\mu = 1$ que par fluctuation statistique. On peut chercher les valeurs de moyennes μ_1 et μ_2 qui sont telles que la valeur observée (ou une valeur plus extrême de μ) n'a qu'une probabilité de 2.5 % de se produire. Au vu des données, l'intervalle $[\mu_1; \mu_2]$ est donc constitué de valeurs de μ pour lesquelles la valeur observée a plus de 5% de chances de se produire: il s'agit de l'intervalle de confiance de μ .

1) Pour calculer μ_1 (limite inférieure), on veut qu'obtenir 1 ou plus que 1 n'ait que 2.5% de chance de se produire, ou, de manière équivalente, que 0 organisme ait 97.5 % de chances d'arriver.

Employant la distribution de Poisson, on peut donc écrire:

$$\Rightarrow \quad \begin{aligned} P(0) &= 0.975 = \exp(-\mu_1) * (\mu_1^0) / (0!) = \exp(-\mu_1) \\ \mu_1 &= -\ln(0.975) = \quad \quad \quad \mathbf{0,02531781} \end{aligned}$$

2) Pour calculer μ_2 (limite supérieure), on veut qu'obtenir 1 ou moins que 1 n'ait que 2.5% de chance de se produire.

$$\begin{aligned} \Rightarrow \quad & P(0) + P(1) = 0.025 = \exp(-\mu_2) * [(\mu_2^0) / 0! + (\mu_2^1) / 1!] \\ \Rightarrow \quad & 0.025 = \exp(-\mu_2) * (1 + \mu_2) \end{aligned}$$

La résolution de cette équation fournit:

$$\mu^2 = 5,57165919$$

(on peut vérifier ce résultat en introduisant la valeur trouvée dans l'équation précédente).

L'intervalle cherché:

$$P (0,02532 < \mu < 5,57166) = 95\%$$

Exercice 6

On a mesuré (en mm) l'épaisseur du lard dorsal chez 10 porcs et on a obtenu les résultats suivants: 47, 38 , 39 , 32 , 34 , 37 , 31 , 43 , 41 , 43. On demande de calculer les limites de l'intervalle de confiance de la moyenne de population et sa vraie valeur.

	<u>Données</u>	
	47	2209
	38	1444
	39	1521
	32	1024
	34	1156
	37	1369
	31	961
	43	1849
	41	1681
	43	1849
Somme	385	15063
Somme ²	148225	
Moyenne	38,5	
n	10	
S ²	26,7222222	
S	5,16935414	

La formule à utiliser pour trouver les limites de l'intervalle de confiance est la suivante:

$$\mu = \bar{x} \pm t_{0,05}^{n-1} \frac{S}{\sqrt{n}} \quad \text{où} \quad \frac{S}{\sqrt{n}} \quad \text{est l'erreur standard de l'échantillon et est égale à : } 1,63469331$$

Il s'agit d'un test bilatéral, il faut donc chercher la valeur de t correspondante dans la table t 0,05, c'est à dire : 2,26215889

Limite inf.moyenne popul.: 34,802064
Limite sup.moyenne popul.: 42,197936

Exercice 7

D'une distribution normale dont on connaît la variance(=25), on prélève 64 observations au hasard et la moyenne de ces observations =11,1. Testez l'hypothèse que la vraie moyenne est égale à 10.

Ici la variance étant connue, il faut utiliser la statistique z et non t !

n: 64
sigma²: 25
sigma: 5
Moy.échant.: 11,1

Pour un intervalle de confiance de 95 %, on aura un z correspondant de: 1,95996108

Limite sup.: 12,3249757
Limite inf.: 9,87502432

La vraie moyenne pourrait être de 10 vu que cette valeur est bien comprise entre les limites de notre intervalle de confiance!

Exercice 8

Dans une région, on a pesé 68 veaux de 2 semaines et de ces pesées, on a extrait les valeurs suivantes: Moyenne= 73,33 et déviation standard= 6,39.
Montrez que si tous les veaux de cet âge avaient été pesés, la moyenne de ces mesures aurait 95 chances sur 100 de tomber dans les limites 71,77 et 74,89?

n: 68
Moy.échant.: 73,33
S: 6,39

La valeur de t correspondante pour un intervalle de confiance de 95 %: 1,9960089

Limite sup.: 74,8767099
Limite inf.: 71,7832901

Exercice 9

La distribution des numérations globulaires de porcelets âgés de 2 semaines peut être considérée comme normale avec une moyenne de population égale à 7000 et une déviation standard de population de 1200 (en 1000/mm³). Quelle est la probabilité d'une numération supérieure à 10600 ? 21 porcelets ont reçu un régime spécial, enrichi en fer. La numération globulaire moyenne a été de 9400 et la variance de 1960000, soit S=1400. Le régime a-t-il modifié la numération globulaire moyenne ? A-t-il modifié la variation des numérations ?

a) Moy.pop.: 7000
Dév.st.pop.: 1200
X 10600
Z 3
P(>10600) 0,00134997

b) n: 21
Moy.échant.: 9400
S²: 1960000
S: 1400
I.C.: 95%

H0: le régime n'a pas d'effet et donc la moyenne de population est égale à la moyenne de l'échantillon, les différences observées sont dues à des fluctuations statistiques.

Limite inf.: 8886,75152

Limite sup.: 9913,24848

L'hypothèse nulle est donc rejetée puisque 7000 n'est pas compris dans cet intervalle de confiance et donc le régime a bien un effet sur la numération globulaire.

Une autre façon de procéder aurait également pu être de faire comme suit:

Z= 9,16515139 Ce qui est beaucoup plus grand que 1,96 (valeur seuil pour 95%) et donc l'hypothèse nulle est rejetée!

c) H0: La variance de population est égale à la variance de l'échantillon.

$\frac{\sum x^2}{\sigma^2}$ est distribué comme un χ^2 avec 20 ddl

$\frac{S^2(n-1)}{\sigma^2}$ 27,2222222 Ce qui est inférieur à la valeur théorique pour un χ^2 ayant un seuil de 5% et 20 ddl(31,41) et donc H0 est acceptée.

Vérification: 31,4104204