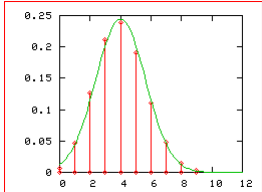


Lois et convergence : un bref résumé synthétique

<p>Loi binomiale (n tirages oui ou non)</p> <p>X = 1 si succès probabilité p X = 0 si échec probabilité q = 1 - p</p> <p>Pour X E(X) = p V(X) = p - p² = p(1-p) = pq</p> <p>Pour Z = ∑ X_i (nombre de 1 sur n) P(Z=k) = C_n^k p^k q^{n-k} E(Z) = np V(Z) = npq σ = √npq</p> <p>Pour la fréquence des succès E($\frac{Z}{n}$) = p V($\frac{Z}{n}$) = $\frac{pq}{n}$</p>	<p>Loi hypergéométrique (n tirages sans remise)</p> <p>N boules dont F noires, N-F blanches X = 1 si noire, n tirages sans remise</p> <p>Exemple 5 noires, 10 blanches, n=5 P(01010) = $\frac{10}{15} \frac{5}{14} \frac{9}{13} \frac{4}{12} \frac{8}{11} = P(11000)$</p> <p>P(X=x) = $\frac{C_F^x C_{N-F}^{n-x}}{C_N^n}$</p> <p>E(X) = p V(X) = npq $\frac{N-n}{N-1}$</p>	<p>Loi exponentielle (Durée de vie sans vieillissement)</p> <p>La probabilité de durer t au-delà de h = probabilité de durer t.</p> <p>Densité f(t) = λe^{-λt} Répartition P(t < x) = 1 - e^{-λx} Espérance E(t) = $\frac{1}{\lambda}$ Variance V(t) = $\frac{1}{\lambda^2}$ Écart type σ(t) = $\frac{1}{\lambda}$ Médiane $\frac{\ln 2}{\lambda}$</p>
<p>Loi de Poisson Évènement aléatoire E dans le temps ou l'espace</p> <p>Si ΔZ = portion de temps ou d'espace P(E) = pΔZ (P(E) proportionnel à ΔZ) X = nombre d'événements observés sur Z</p> <p>Si on pose m = pZ (P(E) sur Z) P(X=x sur Z) = $\frac{e^{-m} m^x}{x!}$</p> <p>E(X) = m V(X) = m</p> <p>De la loi binomiale à Poisson. Soit B(n,p) telle que np = 3 ou 4. Une succession d'épreuves rapides telle que sur Δt E se produise en moyenne 3 ou 4 fois. Quand n → ∞ et p → 0 (np → m)</p>	<p>Loi normale La moyenne (E(x)), la médiane et le mode (P(E) max) coïncident. De plus P(m-2σ < X < m+2σ) > 95%</p> <p>Densité de probabilité</p> $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}$ <p>Après changement de variable</p> $T = \frac{x-m}{\sigma} \quad f_x dx \text{ devient } \frac{1}{\sqrt{2\pi}} e^{-\frac{T^2}{2}} dT$ <p>Et $\int_{-\infty}^{+\infty} f(T) dT = 1$ d'après Gauss.</p> <p>Cas général loi N(m,σ) centrée en m Médiane = m Mode = m Écart type = σ P(T < x) donnée par des tables. Ne pas oublier que X = Tσ + m</p> <p>De la loi binomiale à la normale. Si n est grand et que p proche de ½. B(n,p) d'écart type σ moyenne np → N(np,σ)</p>  <p>Diagramme en bâtons de B(n,p) et graphe de N(np,σ)</p>	<p>Loi du KHI2 de Pearson</p> <p>Loi du χ² de Pearson On calcule X = ∑ $\frac{(O_i - E_i)^2}{E_i}$ O_i = valeur observée E_i = estimée Le nombre de degrés de liberté est égal au nombre n de données indépendantes diminué du nombre de relations liant ces données. (Par exemple n-1 si on veut évaluer une moyenne ou si la somme des variables = 100). Dans un tableau destiné à étudier le croisement de L modalités de A et de C modalités de B, le nombre de degrés de libertés est (L-1)(C-1). La table du khi 2 à k degrés de libertés nous indique quel seuil Q ne doit pas dépasser pour que l'adéquation soit bonne avec telle probabilité. Exemple si Q > 11.07 l'adéquation a 5% de chances d'être bonne. Ce test permet d'estimer l'adéquation de la population à une loi ou à une autre, l'homogénéité ou l'indépendance de 2 populations.</p>

Soit (X₁, X₂, ..., X_n) un échantillon de la loi de probabilité de la variable aléatoire X (écart type σ, moyenne m)

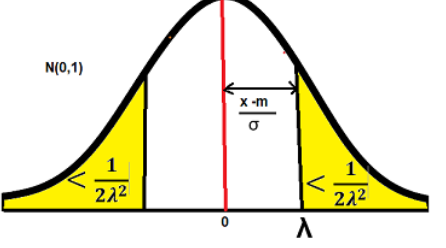
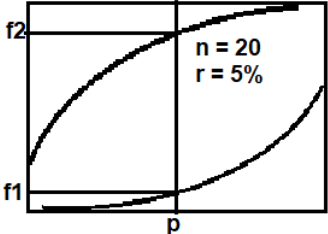
Soit la somme: S_n = X₁ + X₂ + ... + X_n On a

E(S_n) = nE(X) = nm	Var(S_n) = nVar(X) = nσ²	σ(S_n) = √nσ² = σ√n
--------------------------------------	--	---

Et soit $\bar{X} = \frac{S_n}{n}$ la moyenne

E(\bar{X}) = n $\frac{E(X)}{n} = E(X) = m$	V(\bar{X}) = $\frac{V(X)}{n} = \frac{\sigma^2}{n}$	σ(\bar{X}) = $\frac{\sigma}{\sqrt{n}}$
---	---	---

Les formules encadrées en rouge sont importantes car selon qu'on s'intéresse à un nombre d'éléments, une moyenne ou une fréquence on va utiliser l'espérance et l'écart type correspondant pour la convergence vers la loi normale.

<p>X nombre d'éléments de caractère λ $X =$ somme de N variables de Bernoulli</p>	<p>\bar{X} est la moyenne de X dans des échantillons de taille N</p>	<p>f fréquence de λ dans l'échantillon si $x = \sum X_i$ (bernouilli) $f = \frac{X}{N}$</p>
<p>$E(X) = Np$ $\sigma(X) = \sqrt{Npq}$</p>	<p>$E(\bar{X}) = m$ (moyenne ds la population) $\sigma(\bar{X}) = \frac{\sigma}{\sqrt{N}}$</p>	<p>$E(f) = \frac{E(X)}{N} = \frac{Np}{N} = p$ $\sigma(f) = \frac{\sigma(X)}{N} = \frac{\sqrt{Npq}}{N} = \sqrt{\frac{pq}{N}}$</p>
<p>Loi normale $N(m, \sigma)$ X suit la loi $N(m, \sigma)$ $T = \frac{X-m}{\sigma}$ suit $N(0,1)$ $r\%$ risque de l'estimation</p>	<p>Pour $N(0,1)$ les tables donnent A tel que $P(T \in [-A, A]) \geq 1 - r\%$ en fonction de $1 - \frac{r}{2}\%$. Pour $r = 5\%$ cela donne $1 - \frac{r}{2}\% = 0,9750$ et $A = 1.96$ et donc $P(-1,96 < T < 1,96) \geq 95\%$ On en déduit qu'au risque de 5% $m - 1,96\sigma < X < m + 1,96\sigma$ au risque de 1% $m - 2,53\sigma < X < m + 2,53\sigma$</p>	
<p>$P\left(\frac{ X-m }{\sigma} \geq \lambda\right) \leq \frac{1}{\lambda^2}$ Variable centrée Bienaymé - Tchebychev P (écart / moyenne) majorée $P(X-m \geq k) \leq \frac{\sigma^2}{k^2}$ $(k = \lambda\sigma)$ Variable quelconque</p>		<p>Comment choisir n de $B(n, p)$ pour que la fréquence du caractère observé soit telle qu'elle ne s'écarte pas plus de 5% de la fréquence effective au risque de 1%. Pour les fréquences $m(f) = p$ $\sigma(f) = \sqrt{\frac{pq}{n}}$ On a $P\left(\frac{ X-m }{\sigma} \geq \lambda\right) = P(f - p \geq \sigma\lambda) < \frac{1}{\lambda^2} = 1\%$ d'où $\lambda = 10$ et $\sigma\lambda = 5\% = 10 \sqrt{\frac{pq}{n}}$ d'où on tire n quand on connaît p</p>
<p>Grands nombres Suite X_i de variables de même loi, espérance, variance alors la moyenne de X_i converge en probabilité vers $E(x)$.</p>	<p>$m =$ moyenne dans l'échantillon, S écart type de la moyenne, σ de l'échantillon Dans $P(m - E(x) \geq \epsilon) \leq \frac{S^2}{\epsilon^2}$ on remplace S par sa valeur $\frac{\sigma}{\sqrt{n}}$ puis on passe aux complémentaires $P(m - E(x) \leq \epsilon) \geq 1 - \frac{\sigma^2}{n\epsilon^2}$. Cette probabilité tend vers 1 donc quand n grand la moyenne de l'échantillon tend vers $E(X)$ dans la population. Et la fréquence d'un caractère tend vers sa probabilité dans la population.</p>	
<p>Limite centrale. On prélève n valeurs x_1, \dots, x_n de moyenne m tandis que dans la population $E(x) = M$ et $\sigma(X) = \sigma$ autrement dit $\sigma(m) = \frac{\sigma}{\sqrt{n}}$ alors la variable $Z = \frac{m - M}{\sigma(m)}$ tend vers $N(0,1)$</p>	<p>En particulier $B(n, p)$ converge vers $N(np, \sqrt{npq})$ lorsque $n \rightarrow \infty$ (Moivre - Laplace). Par exemple X suit la loi $B(500, 0,8)$ moyenne 400 et écart type $\sqrt{80}$ 500 est assez grand pour qu'on estime que $Y = \frac{X-400}{\sqrt{80}}$ suit $N(0,1)$ La moyenne m de X a pour moyenne 0,8 et pour écart type $\frac{\sigma}{\sqrt{n}} = \frac{\sqrt{npq}}{\sqrt{n}} = 0,4$. $Z = \frac{m - 0,8}{0,4}$ suit $N(0,1)$ ce qui permet de chercher dans les tables un encadrement de Z au risque de 5% ou 1%. Et d'en déduire un encadrement de m.</p>	
<p>Pour x : $M = 800$, $\sigma = 60$ Moyenne m de x dans un échantillon de 100 ?</p>	<p>$E(m) = 800$, $\sigma(m) = \frac{\sigma}{\sqrt{N}} = \frac{60}{10} = 6$. $\rightarrow \frac{m-800}{6}$ suit une loi $N(0,1)$ On peut dire que $800 - 1.96(6) < m < 800 + 1.96(6)$ au risque de 5%.</p>	
<p>On connaît la fréquence de λ dans la population $P(\lambda) = p$ Fréquence dans un échantillon de taille N ?</p>	<p>On a $E(f) = p$ et $\sigma(f) = \sqrt{\frac{pq}{N}}$ Si N est grand f suit une loi $N(p, \sqrt{\frac{pq}{N}})$ et donc $Z = \frac{f-p}{\sqrt{\frac{pq}{N}}}$ suit une loi $N(0,1)$ d'où on peut trouver un encadrement de f au risque de 5%, 1% ou autre.</p>	
<p>Autre méthode</p>		<p>Une famille de paires de courbes (ou de tables) paramétrées par la taille N de l'échantillon et le risque de l'encadrement. On trace la droite $x = p$ (proportion dans la population). Elle coupe les courbes en 2 points d'ordonnée f_1 et f_2. On peut dire que $f_1 < f < f_2$ au risque de $r\%$.</p>
<p>On connaît la fréquence et on nous demande la taille de l'échantillon pour précision de 5% au risque de 1%</p>	<p>On a toujours $Z = \frac{f-p}{\sqrt{\frac{pq}{N}}}$ suit une loi $N(0,1)$. De l'encadrement $-2,58 < Z < +2,58$ on déduit $p - 2,58 \sqrt{\frac{pq}{N}} < f < p + 2,58 \sqrt{\frac{pq}{N}}$ Et $2,58 \sqrt{\frac{pq}{N}}$ doit être égal à 5% de p (écart maxi toléré) d'où on déduit n.</p>	

<p>Loi du khi 2. Adéquation à une loi Homogénéité de 2 popul. Indépendance de 2 popul.</p>	<p>La population est répartie en k classes. Par exemple on lance un dé 90 fois et n(i) est le nombre de fois où on obtient la face i. (6 classes).</p> <p>On calcule $Q = \sum_{i=1}^6 \frac{(oi-ei)^2}{ei}$ avec oi valeur observée n(i) et ei effectifs théorique (ici normalement 90 / 6 = 15 pour chaque classe).</p> <p>Le degré de liberté est le nombre de classes diminué du nombre de relation entre les classes. Ici K-1 puisque par exemple n(6)=90-n(1)-n(2)-n(3)-n(4)-n(5).</p> <p>Ensuite la table à 5 degrés de liberté nous donne les valeurs V que Q ne doit pas dépasser pour que l'adéquation ait 1 - r% de chances d'être mauvaise , Par exemple si la table donne V =11,07 et P = 0,05 cela signifie que si Q > 11,07 l'adéquation a 95% de chances d'être mauvaise.</p>
<p>Estimateurs T de θ $\theta = p, M, \sigma$ de la population à partir de n , f, m et V d'un échantillon. Sans biais si $\lim (T) = \theta$</p>	<p>Échantillon d'effectif n de fréquence f, de moyenne m, de variance V. f estimateur sans biais de p (proportion du caractère dans la population) m estimateur sans biais de M (moyenne de la variable aléatoire dans la population)</p> <p>$S^2 = \frac{n}{n-1} V$ est un estimateur sans biais de σ^2 et donc $S = \sqrt{\sum \frac{(Xi - m)^2}{n-1}}$ estimateur de σ</p>
<p>Loi de Student Déterminer l'intervalle de confiance de l'espérance E d'une loi normale dont on ne connaît pas la variance.</p>	<p>Normalement $Z = \frac{m-E}{\frac{\sigma}{\sqrt{n}}}$ suit une loi normale centrée réduite mais on ne connaît pas σ (qui suit une loi du Khi2). La loi de Student donne pour un degré de liberté donné k et pour un risque r le nombre $S_{r/2}^k$ tel que $P(Z > S_{r/2}^k) < r/2$ or cela équivaut (symétrie de la loi et de la courbe densité par rapport à 0) à $P(m - \frac{\sigma}{\sqrt{n}} S_{r/2}^k \leq E \leq m + \frac{\sigma}{\sqrt{n}} S_{r/2}^k) > 1-r$ où on remplace σ par son estimateur sans biais S</p>
<p>Comparaison d'une moyenne m à une norme ou un seuil m_0. Si N est assez grand pour une moyenne on utilise $N(m_0, \frac{\sigma}{\sqrt{N}})$ Faute de connaître σ on utilise son estimateur sans biais S</p>	<p>On mesure 100 fois une longueur qui devrait être m_0. On connaît l'écart type σ des mesures m. Au risque de 5% ces mesures ont convenables si $m_0 - 1,96 \frac{\sigma}{\sqrt{100}} \leq m \leq m_0 + 1,96 \frac{\sigma}{\sqrt{100}}$</p> <p>Si σ est inconnu on le remplace par son estimateur S et on utilise Student à n-1 degrés de liberté pour trouver l'encadrement $m_0 - \frac{\sigma}{\sqrt{n}} S_{r/2}^k \leq m \leq m_0 + \frac{\sigma}{\sqrt{n}} S_{r/2}^k$</p> <p>Si N grand Student approchée par $N(m_0, \frac{\sigma}{\sqrt{n}})$</p> <p>On mesure 100 fois x. Peut-on dire que la moyenne m de x ne dépasse pas un seuil m_0 au risque de 1%? On estime $\sigma = S$ grâce à l'échantillon. Pour N = 100 inutile d'utiliser Student, on utilise N(0,1) pour la variable centrée $\frac{m-m_0}{\frac{S}{\sqrt{100}}}$.</p> <p>Hypothèse acceptable si $P(m > m_0) < 1\%$ soit $\frac{m-m_0}{\frac{S}{\sqrt{100}}} \leq 2,33$ soit $m < m_0 + 2,33 \frac{S}{\sqrt{100}}$</p>
<p>Comparaison d'une fréquence f à une norme un à un seuil p_0 On utilise $N(P_0, \sqrt{\frac{p_0(1-p_0)}{N}})$</p>	<p>N = 100 et le caractère λ est constaté 12 fois (f constatée = 0,12). Peut-on admettre que $p = 1/6$ au risque de 5% (comparaison à $p_0 = 1/6 = 0,17$). Si l'on admet que la population suit une loi B(100 ; 0,17) on peut l'approcher par la loi normale N(0,17 ; 0,0375) et au risque de 5% on devrait avoir $0,17 - 1,96(0,0375) < f < 0,17 + 1,96(0,0375)$ soit $0,096 < f < 0,24$ et comme $f = 0,12$ l'hypothèse est admissible.</p>
<p>Comparaison de 2 échantillons.</p>	<p>Si Xi famille de variables aléatoires indépendantes chacune suivant une loi normale de moyenne m_i et d'écart type σ_i. Alors $\sum Xi$ suit $N(\sum m_i, \sqrt{\sum \sigma_i^2})$.</p>
<p>Tendance et dispersion</p>	<p>On mesure une variable statistique x au sein d'une population. X prend 10 valeurs croissantes de X_0 à X_9 On range les individus selon la valeur de X dans des classes appelées X_0 à X_9 d'effectifs N_0 à N_9 regroupant 100 individus. La moyenne de X est $\sum \frac{Xi Ni}{100}$ Le mode est la valeur dont la classe a le plus grand effectif par exemple X_3. La médiane C'est la classe X_p dans laquelle l'effectif cumulé $N_0 + N_1 + \dots + N_p$ atteint la moitié de l'effectif global ici 50 . De la même façon les quartiles, déciles, etc. sont les classes où l'effectif cumulé atteint 1/4, 1/10 de l'effectif global La variance et l'écart type mesurent la dispersion de la série</p>