

Statistiques appliquées (L3 d'économie) - Cours de Patrick Sevestre - TD 2 - Corrigé

Marc Sangnier - marc.sangnier@ens-cachan.fr

29 octobre 2007

Exercice 1 - Lien entre salaire et formation

Remarques préliminaires

Le tableau présentant les données de l'énoncé nous fournit la loi du couple de variables aléatoires (niveau de formation; salaire). On remarque donc que la somme de l'ensemble des valeurs est logiquement égale à 1. Soit F la variable aléatoire représentant la formation et S celle représentant le salaire. Par ailleurs, on peut considérer que le salaire est une variable continue : on comprendra donc que les inégalités strictes ou larges importent peu dans la lecture d'un tel tableau. Il faut cependant toujours prendre garde à la façon dont les données sont présentées pour ne pas faire d'erreurs de lecture.

Question 1 - Calcul de probabilités

Probabilité d'avoir une formation inférieure ou égale au bac et un salaire compris entre 1200 et 2400 euros

$$\begin{aligned} & P((F \leq \text{Bac}) \cap (1200 \leq S \leq 2400)) \\ &= P((F < \text{Bac}) \cap (1200 \leq S \leq 1600)) + P((F < \text{Bac}) \cap (1600 \leq S \leq 2400)) \\ &+ P((F = \text{Bac}) \cap (1200 \leq S \leq 1600)) + P((F = \text{Bac}) \cap (1600 \leq S \leq 2400)) \\ &= 0,05 + 0,00 + 0,05 + 0,03 = 0,13 \end{aligned}$$

Probabilité d'avoir une formation supérieure à bac+3 et un salaire inférieur à 1600 euros

$$\begin{aligned} & P((F > \text{Bac} + 3) \cap (S < 1600)) \\ &= P((F > \text{Bac} + 3) \cap (S < 1200)) + P((F > \text{Bac} + 3) \cap (1200 \leq S < 1600)) = 0,03 + 0,05 = 0,08 \end{aligned}$$

Question 2 - Distributions marginales

Rappel : Distribution marginale

La distribution marginale d'une variable aléatoire X est obtenue par la somme des probabilités conditionnelles de la variable X sachant Y .

$$P(X = x_j) = \sum_{i=-\infty}^{+\infty} P((X = x_j) \cap (Y = y_i))$$

Distribution marginale des salaires

On utilise maintenant les centres de classe plutôt que les intervalles : $P(S = 1100) = P(1000 < S < 1200)$.

$$\begin{aligned} P(S = 1100) &= P((S = 1100) \cap (F = 10)) + P((S = 1100) \cap (F = 12)) \\ &+ P((S = 1100) \cap (F = 15)) + P((S = 1100) \cap (F = 18)) = 0,25 + 0,10 + 0,07 + 0,03 = 0,45 \end{aligned}$$

En calculant de la même façon pour les autres valeurs du salaire, on obtient :

| Salaire (S) | s=1100 | s=1400 | s=2000 | s=3000 |
|-------------|--------|--------|--------|--------|
| P(S=s) | 0,45 | 0,25 | 0,15 | 0,15 |

Distribution marginale de la formation

On procède de la même façon, prenons l'exemple de $F=\text{Bac}$

$$P(F = 12) = P((F = 12) \cap (S = 1100)) + P((F = 12) \cap (S = 1400)) \\ + P((F = 12) \cap (S = 2000)) + P((F = 12) \cap (S = 3000)) = 0,10 + 0,05 + 0,03 + 0,02 = 0,20$$

En calculant de la même façon pour les autres valeurs de la formation, on obtient :

| Formation (F) | f=10 | f=12 | f=15 | f=18 |
|---------------|------|------|------|------|
| $P(F=f)$ | 0,30 | 0,20 | 0,30 | 0,20 |

Question 3 - Distribution conditionnelle

Rappel : Distribution conditionnelle

Soit A et B deux événements :

$$P(A \cap B) = P(A | B) * P(B) = P(B | A) * P(A)$$

Distribution des salaires conditionnelle à une formation strictement supérieure au bac

$$P(S = 1100 | F > 12) = \frac{P((S=1100) \cap (F>12))}{P(F>12)} = \frac{P((S=1100) \cap (F=15)) + P((S=1100) \cap (F=18))}{P(F=15) + P(F=18)} = \frac{0,07 + 0,03}{0,30 + 0,20} = \frac{0,10}{0,50} = 0,20$$

$$P(S = 1400 | F > 12) = \frac{P((S=1400) \cap (F>12))}{P(F>12)} = \frac{P((S=1400) \cap (F=15)) + P((S=1400) \cap (F=18))}{P(F=15) + P(F=18)} = \frac{0,10 + 0,05}{0,30 + 0,20} = \frac{0,15}{0,50} = 0,30$$

En poursuivant de la même façon, on obtient :

| Salaire (S) sachant $F>\text{Bac}$ | s=1100 | s=1400 | s=2000 | s=3000 |
|------------------------------------|--------|--------|--------|--------|
| $P(S = s F > 12)$ | 0,20 | 0,30 | 0,24 | 0,26 |

Question 4 - Salaires moyens

Rappel : Loi des espérances itérées

L'espérance non-conditionnelle est égale à l'espérance de l'espérance conditionnelle.

$$E(Y) = E_X(E(Y | X))$$

Salaire moyen pour chaque niveau de formation

On calcule ici $E(S | F = f)$ pour l'ensemble des valeurs de la formation.

$$E(S | F = 10) = \sum_s s * P(S = s | F = 10) \\ = 1100 * P(S = 1100 | F = 10) + 1400 * P(S = 1400 | F = 10) \\ + 2000 * P(S = 2000 | F = 10) + 3000 * P(S = 3000 | F = 10) \\ = 1100 * \frac{P((S=1100) \cap (F=10))}{P(F=10)} + 1400 * \frac{P((S=1400) \cap (F=10))}{P(F=10)} + 2000 * \frac{P((S=2000) \cap (F=10))}{P(F=10)} + 3000 * \frac{P((S=3000) \cap (F=10))}{P(F=10)} \\ = 1100 * \frac{0,25}{0,30} + 1400 * \frac{0,05}{0,30} + 2000 * \frac{0,00}{0,30} + 3000 * \frac{0,00}{0,30} = 1150$$

Le salaire moyen avec une formation inférieure au bac est donc de 1150 euros.

$$E(S | F = 12) = \sum_s s * P(S = s | F = 12) \\ = 1100 * P(S = 1100 | F = 12) + 1400 * P(S = 1400 | F = 12) \\ + 2000 * P(S = 2000 | F = 12) + 3000 * P(S = 3000 | F = 12) \\ = 1100 * \frac{P((S=1100) \cap (F=12))}{P(F=12)} + 1400 * \frac{P((S=1400) \cap (F=12))}{P(F=12)} + 2000 * \frac{P((S=2000) \cap (F=12))}{P(F=12)} + 3000 * \frac{P((S=3000) \cap (F=12))}{P(F=12)} \\ = 1100 * \frac{0,10}{0,20} + 1400 * \frac{0,05}{0,20} + 2000 * \frac{0,03}{0,20} + 3000 * \frac{0,02}{0,20} = 1500$$

Le salaire moyen avec une formation égale au bac est donc de 1500 euros.

De la même façon, il vient :

$$E(S | F = 15) = 1756,67$$

$$E(S | F = 18) = 2115$$

Salaire moyen global

On utilise ici la loi des espérances itérées.

$$\begin{aligned} E(S) &= E_F(E(S | F)) \\ &= E(S | F = 10) * P(F = 10) + E(S | F = 12) * P(F = 12) + E(S | F = 15) * P(F = 15) + E(S | F = 18) * P(F = 18) \end{aligned}$$

$$= 1150 * 0,30 + 1500 * 0,20 + 1756,67 * 0,30 + 2115 * 0,20 = 1595$$

Le salaire moyen global est donc de 1595 euros.

On peut obtenir directement ce résultat à partir de la loi marginale du salaire en calculant $E(S) = \sum_s s * P(S = s)$.

Question 5 - Variances des salaires

Rappel : Décomposition de la variance

La variance de X est égale à la moyenne des variances X sachant Y plus la variance des moyennes de X sachant Y.

$$V(X) = E_Y(V(X | Y)) + V_Y(E(X | Y))$$

Variance su salaire pour chaque niveau de formation

On calcule ici $V(S | F = f)$ pour l'ensemble des valeurs de la formation.

$$V(S | F = 10) = \sum_s [s - E(S | F = 10)]^2 * P(S = s | F = 10) = 12500$$

La variance des salaires pour une formation inférieure au bac est donc de 12500.

On peut calculer l'écart-type des ces salaires : $\sigma(S | F = 10) = \sqrt{V(S | F = 10)} = 111,80$

L'écart-type des salaires pour une formation inférieure au bac est donc de 111,80 euros.

$$\begin{aligned} V(S | F = 12) &= \sum_s [s - E(S | F = 12)]^2 * P(S = s | F = 12) \\ &= (1100 - 1500)^2 * P(S = 1100 | F = 12) + (1400 - 1500)^2 * P(S = 1400 | F = 12) \\ &+ (2000 - 1500)^2 * P(S = 2000 | F = 12) + (3000 - 1500)^2 * P(S = 3000 | F = 12) \\ &= (-400)^2 * \frac{0,10}{0,20} + (-100)^2 * \frac{0,05}{0,20} + 500^2 * \frac{0,03}{0,20} + 1500^2 * \frac{0,02}{0,20} = 345000 \end{aligned}$$

La variance des salaires pour une formation de niveau bac est donc de 345000.

L'écart-type est ici de 587,37 euros.

$$V(S | F = 15) = \sum_s [s - E(S | F = 15)]^2 * P(S = s | F = 15) = 416455,56$$

La variance des salaires pour une formation de niveau bac+1, bac+2 ou bac+3 est donc de 416455,56.

L'écart-type est ici de 645,33 euros.

$$\begin{aligned} V(S | F = 18) &= \sum_s [s - E(S | F = 18)]^2 * P(S = s | F = 18) \\ &= (1100 - 2115)^2 * P(S = 1100 | F = 18) + (1400 - 2115)^2 * P(S = 1400 | F = 18) \\ &+ (2000 - 2115)^2 * P(S = 2000 | F = 18) + (3000 - 2115)^2 * P(S = 3000 | F = 18) \\ &= (-1015)^2 * 0,15 + (-715)^2 * 0,25 + (-115)^2 * 0,20 + 885^2 * 0,40 = 598275 \end{aligned}$$

La variance des salaires pour une formation supérieure à bac+3 est donc de 598275.

L'écart-type est ici de 773,48 euros.

Variance globale du salaire

On utilise ici la formule de décomposition de la variance.

$$V(S) = E_F(V(S | F)) + V_F(E(S | F))$$

Calculons tout d'abord $E_F(V(S | F))$

$$E_F(V(S | F)) = \sum_f [V(S | F = f)] * P(F = f) = 317341,67$$

Calculons maintenant $V_F(E(S | F))$

$$\begin{aligned} V_F(E(S | F)) &= \sum_f [E(S | F = f) - E(S)]^2 * P(F = f) \\ &= [E(S | F = 10) - E(S)]^2 * P(F = 10) + [E(S | F = 12) - E(S)]^2 * P(F = 12) \\ &+ [E(S | F = 15) - E(S)]^2 * P(F = 15) + [E(S | F = 18) - E(S)]^2 * P(F = 18) \\ &= [1150 - 1595]^2 * 0,30 + [1500 - 1595]^2 * 0,20 + [1756,67 - 1595]^2 * 0,30 + [2115 - 1595]^2 * 0,20 \\ &= (-445)^2 * 0,30 + (-95)^2 * 0,20 + 161,67^2 * 0,30 + 520^2 * 0,20 = 123133,33 \end{aligned}$$

On peut maintenant calculer la variance des salaires $V(S)$

$$V(S) = E_F(V(S | F)) + V_F(E(S | F)) = 317341,67 + 123133,33 = 440475$$

La variance globale du salaire est donc de 440475.

L'écart-type des salaires est donc de 663,68.

Ce résultat peut être obtenu directement en calculant $V(S) = E(S^2) - E(S)^2$.

Question 6 - Indépendance

Rappel : Indépendance

Si X et Y sont deux variables aléatoires indépendantes, alors $cov(X; Y) = 0$

Rappel : Logique

$$p \Rightarrow q \Leftrightarrow (\text{non} - q) \Rightarrow (\text{non} - p)$$

Rappel : Covariance

$$cov(X; Y) = E[(X - E(X)) * (Y - E(Y))] = E(XY) - E(X)E(Y)$$

Covariance du salaire (S) et de la formation (F)

$$cov(S; F) = E[(S - E(S)) * (F - E(F))]$$

Il nous faut tout d'abord calculer $E(F)$

On procède comme dans la question 4 en utilisant $E(F) = E_S[E(F | S)]$

$$E(F | S = 1100) = 10 * \frac{P((F=10) \cap (S=1100))}{P(S=1100)} + 12 * \frac{P((F=12) \cap (S=1100))}{P(S=1100)} + 15 * \frac{P((F=15) \cap (S=1100))}{P(S=1100)} + 18 * \frac{P((F=18) \cap (S=1100))}{P(S=1100)}$$

$$= 10 * \frac{0,25}{0,45} + 12 * \frac{0,10}{0,45} + 15 * \frac{0,07}{0,145} + 18 * \frac{0,03}{0,45} = 11,75$$

$$E(F | S = 1400) = 10 * \frac{P((F=10) \cap (S=1400))}{P(S=1400)} + 12 * \frac{P((F=12) \cap (S=1400))}{P(S=1400)} + 15 * \frac{P((F=15) \cap (S=1400))}{P(S=1400)} + 18 * \frac{P((F=18) \cap (S=1400))}{P(S=1400)}$$

$$= 10 * \frac{0,05}{0,25} + 12 * \frac{0,05}{0,25} + 15 * \frac{0,10}{0,25} + 18 * \frac{0,05}{0,25} = 14$$

$$E(F | S = 2000) = 15,2$$

$$E(F | S = 3000) = 16,2$$

$$E(F) = 11,75 * 0,45 + 14 * 0,25 + 15,2 * 0,15 + 16,2 * 0,15 = 13,50$$

On peut maintenant calculer $cov(S; F)$

$$\begin{aligned} cov(S; F) &= [1100 - E(S)][10 - E(F)] * P((S = 1100) \cap (F = 10)) + [1400 - E(S)][10 - E(F)] * P((S = 1400) \cap (F = 10)) \\ &+ [2000 - E(S)][10 - E(F)] * P((S = 2000) \cap (F = 10)) + [3000 - E(S)][10 - E(F)] * P((S = 3000) \cap (F = 10)) \\ &+ [1100 - E(S)][12 - E(F)] * P((S = 1100) \cap (F = 12)) + [1400 - E(S)][12 - E(F)] * P((S = 1400) \cap (F = 12)) \\ &+ [2000 - E(S)][12 - E(F)] * P((S = 2000) \cap (F = 12)) + [3000 - E(S)][12 - E(F)] * P((S = 3000) \cap (F = 12)) \\ &+ [1100 - E(S)][15 - E(F)] * P((S = 1100) \cap (F = 15)) + [1400 - E(S)][15 - E(F)] * P((S = 1400) \cap (F = 15)) \\ &+ [2000 - E(S)][15 - E(F)] * P((S = 2000) \cap (F = 15)) + [3000 - E(S)][15 - E(F)] * P((S = 3000) \cap (F = 15)) \\ &+ [1100 - E(S)][18 - E(F)] * P((S = 1100) \cap (F = 18)) + [1400 - E(S)][18 - E(F)] * P((S = 1400) \cap (F = 18)) \\ &+ [2000 - E(S)][18 - E(F)] * P((S = 2000) \cap (F = 18)) + [3000 - E(S)][18 - E(F)] * P((S = 3000) \cap (F = 18)) \\ &= (-495) * (-3,5) * 0,25 + (-195) * (-3,5) * 0,05 + 405 * (-3,5) * 0,00 + 1405 * (-3,5) * 0,00 \\ &+ (-495) * (-1,5) * 0,10 + (-195) * (-1,5) * 0,05 + 405 * (-1,5) * 0,03 + 1405 * (-1,5) * 0,02 \\ &+ (-495) * 1,5 * 0,07 + (-195) * 1,5 * 0,10 + 405 * 1,5 * 0,08 + 1405 * 1,5 * 0,05 \\ &+ (-495) * 4,5 * 0,03 + (-195) * 4,5 * 0,05 + 405 * 4,5 * 0,04 + 1405 * 4,5 * 0,08 \\ &= 1036,5 \end{aligned}$$

On a donc $cov(S; F) \neq 0$

Le salaire n'est donc pas indépendant du niveau de formation.

Coefficient de corrélation linéaire

On peut calculer le coefficient de corrélation linéaire de S et F.

$$r(S; F) = \frac{\text{cov}(S; F)}{\sigma(S) \cdot \sigma(F)}$$

On calcule tout d'abord l'écart-type de F :

$$\sigma(F) = \sqrt{V(F)}$$

Avec $V(F) = (10 - 13, 5)^2 * 0,3 + (12 - 13, 5)^2 * 0,2 + (15 - 13, 5)^2 * 0,30 + (18 - 13, 5)^2 * 0,2 = 8,85$

Donc $\sigma(F) = \sqrt{8,85} = 2,97$

Or $\sigma(S) = 688,85$

D'où $r(S; F) = \frac{1036,5}{2,97 * 688,85} = 0,51$

Exercice 2 - Loi Normale bivariée

Notations

$(V; R) \rightarrow N(m_V; m_R; \sigma_V^2; \sigma_R^2; \rho)$ où ρ est le coefficient de corrélation linéaire.

$$\rho = \frac{\text{cov}(V; R)}{\sigma_V \cdot \sigma_R}$$

Ici, on fait apparaître la variance dans les notations des paramètres de la loi Normale et non plus l'écart-type.

$$V(X) = \sigma_X^2 \text{ et } \sigma_X = \sqrt{V(X)}$$

Question a - Distribution marginale des ventes

$$V \rightarrow N(m_V; \sigma_V^2)$$

Les ventes suivent une loi Normale d'espérances m_V et de variance σ_V^2 .

Question b - Distribution conditionnelle des ventes

$$(V | r) \rightarrow N[A + Br; \sigma_V^2(1 - \rho^2)]$$

$$\text{Avec : } A = m_V - Bm_R \text{ et } B = \frac{\text{cov}(V; R)}{\sigma_R^2}$$

Donc, avec une écriture plus lourde : $(V | R) \rightarrow N[m_V + \frac{\text{cov}(V; R)}{\sigma_R^2}(r - m_R); \sigma_V^2(1 - \rho^2)]$

Question c - Espérance conditionnelle des ventes

$$E(V | r) = A + Br = m_V + \frac{\text{cov}(V; R)}{\sigma_R^2}(r - m_R)$$

Exercice 3 - Loi Normale multivariée

$$X_n \rightarrow N(m; \Sigma)$$

Où X_n est un vecteur aléatoire de dimension n et m le vecteur des espérances, également de dimension n .

Σ est la matrice des variances-covariances. Elle est donc symétrique, régulière et définie positive. Il existe donc une matrice orthogonale S (Rappel : une matrice S est dite orthogonale si elle est telle que $S^{-1} = {}^t S$) telle que $S^{-1} \Sigma S = D$, où D est une matrice diagonale d'éléments λ_i , $1 \leq i \leq n$.

On peut donc définir un vecteur aléatoire Z de la façon suivante :

$$Z = {}^t (X - m) \Sigma^{-1} (X - m) = {}^t (X - m) S D^{-1} S^{-1} (X - m)$$

$$\text{Posons } Y = S^{-1} (X - m) = {}^t S (X - m)$$

Y suit donc une loi Normale centrée, dont la matrice des variances-covariances est $D = S^{-1} \Sigma S$.

Les composantes du vecteur Y , c'est à dire les variables aléatoires Y_i , sont donc indépendantes (puisque la matrice D est diagonale).

Par conséquent : $Y_i \rightarrow N(0; \sqrt{\lambda_i})$

Il vient donc : $Z = {}^t Y D^{-1} Y$

Ce qui peut s'écrire : $Z = \sum_{i=1}^n \frac{Y_i^2}{\lambda_i}$ qui est la somme des carrés de n variables aléatoires normales indépendantes centrées et réduites. Cette somme suit donc une loi du Khi-deux à n degrés de liberté.

$$Z \rightarrow \chi_n^2$$

Exercice 4 - Inégalité de Tchebychev (I)

Rappel : Inégalité de Markov

Si X est une variable aléatoire positive dont l'espérance existe, alors :
 $\forall \lambda > 0, P[X \geq \lambda E(X)] \leq \frac{1}{\lambda}$ ou $P(X \geq \lambda) \leq \frac{E(X)}{\lambda}$

Rappel : Inégalité de Bienaymé-Tchebychev

En appliquant l'inégalité de Markov à la variable aléatoire $X - E(X)$ pour $k = 2$, on obtient :
 $\forall \varepsilon > 0, P(|X - E(X)| \geq \varepsilon) \leq \frac{V(X)}{\varepsilon^2}$

Exercice

On veut montrer, en utilisant l'inégalité de Bienaymé-Tchebychev que : $\forall \varepsilon > 0, \lim_{n \rightarrow +\infty} P(|Z_n - X| < \varepsilon) = 1$

$$Z_n = X + Y_n \iff Z_n - X = Y_n$$

Montrons donc que $\forall \varepsilon > 0, \lim_{n \rightarrow +\infty} P(|Y_n| > \varepsilon) = 0$

D'après l'énoncé : $E(Y_n) = 0$

On peut écrire l'inégalité de Bienaymé-Tchebychev pour Y_n :

$$\forall \varepsilon > 0, P(|Y_n - E(Y_n)| \geq \varepsilon) \leq \frac{V(Y_n)}{\varepsilon^2}$$

Or, d'après l'énoncé : $E(Y_n) = 0$ et $V(Y_n) = \frac{1}{n}$, donc $\lim_{n \rightarrow +\infty} V(Y_n) = 0$

Or, on sait qu'une probabilité est toujours supérieure ou égale à 0. On peut donc écrire, que lorsque n tend vers l'infini :

$$0 \leq P(|Y_n| \geq \varepsilon) \leq 0$$

$P(|Y_n| \geq \varepsilon)$ converge donc vers 0 lorsque n tend vers l'infini.

Donc, $\forall \varepsilon > 0, \lim_{n \rightarrow +\infty} P(|Y_n| > \varepsilon) = 0$, ce qui est ce que nous voulions démontrer.

Z_n converge donc en probabilité vers X .

Exercice 5 - Inégalité de Tchebychev (II)

On peut écrire l'inégalité de Bienaymé-Tchebychev pour X :

$$\forall \varepsilon > 0, P(|X - m| \geq \varepsilon) \leq \frac{\sigma^2}{\varepsilon^2}$$

Posons $\varepsilon = \lambda\sigma$.

$$P(|X - m| \geq \lambda\sigma) \leq \frac{1}{\lambda^2} \iff 1 - P(|X - m| < \lambda\sigma) \leq \frac{1}{\lambda^2}$$

$$\iff P(|X - m| < \lambda\sigma) \geq 1 - \frac{1}{\lambda^2}, \text{ c'est à dire ce que nous voulions démontrer.}$$

Exercice 6 - Notions de convergence

Convergence en probabilité

On dit que la suite de variables aléatoires (X_n) converge en probabilité vers une variable aléatoire X , si $\forall \varepsilon > 0$:

$$P(|X_n - X| < \varepsilon) \rightarrow 1 \text{ quand } n \rightarrow +\infty$$

ou, de façon équivalente :

$$P(|X_n - X| > \varepsilon) \rightarrow 0 \text{ quand } n \rightarrow +\infty$$

Convergence en loi

On dit que la suite de variables aléatoires (X_n) de fonction de répartition $F_n(\cdot)$ converge en loi vers une variable aléatoire X de fonction de répartition $F(\cdot)$ si la suite $F_n(x)$ converge vers $F(x)$ en tout point x où $F(\cdot)$ est continue.

$\forall x/F(\cdot)$ est continue en x :

$$\lim_{n \rightarrow +\infty} |F_n(x) - F(x)| = 0$$

Convergence presque sûre

On dit que la suite de variables aléatoires (X_n) converge presque sûrement vers une variable aléatoire X , si $\forall \varepsilon > 0$:

$$\lim_{n \rightarrow +\infty} P(|X_i - X| > \varepsilon, \forall i \geq n) = 0$$

Convergence en moyenne quadratique

On dit que la suite de variables aléatoires (X_n) converge en moyenne quadratique vers une variable aléatoire X , si :

$$\lim_{n \rightarrow +\infty} E(\|X_n - X\|^2) = 0$$

Liens entre les différentes convergences

Convergence Presque Sûre \Rightarrow Convergence en Probabilité \Rightarrow Convergence en Loi