

Mise à niveau

Vecteurs aléatoires, Vecteurs
Gaussiens, Théorème de Cochran
et applications

A. Godichon-Baggioni

I. Vecteurs aléatoires

VECTEURS ALÉATOIRES

Définition

- ▶ Un vecteur aléatoire $X = (X_1, \dots, X_d) \in \mathbb{R}^d$ est un vecteur dont toutes les composantes sont des variables aléatoires réelles.
- ▶ La fonction de répartition F_X de X est définie pour tout $t = (t_1, \dots, t_d)$ par

$$F_X(t_1, \dots, t_d) = \mathbb{P}[X_1 \leq t_1, \dots, X_d \leq t_d].$$

- ▶ Dans le cas où X est continue, i.e où X admet une densité f_X par rapport à la mesure de Lebesgue sur \mathbb{R}^d , on a

$$F_X(t) = \int_{-\infty}^{t_1} \dots \int_{-\infty}^{t_d} f_X(u_1, \dots, u_d) du_1, \dots, du_d$$

avec pour presque tout t

$$f_X(t) = \frac{\partial}{\partial t_1, \dots, \partial t_d} F_X(t).$$

DENSITÉ ET PROPRIÉTÉS

Proposition

- Toute densité de probabilité f_X vérifie pour tout $t \in \mathbb{R}^d$,
 $f_X(t) \geq 0$ et

$$\int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f_X(t_1, \dots, t_d) dt_1, \dots, dt_d = 1.$$

- Soit $\tilde{X} = (X_1, \dots, X_k)^T$ avec $k \leq d$, la densité marginale de \tilde{X} est définie pour tout $\tilde{t} = (t_1, \dots, t_k)$ par

$$f_{\tilde{X}}(\tilde{t}) = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f_X(t_1, \dots, t_k, u_{k+1}, \dots, u_d) du_{k+1} \dots, du_d.$$

Remarque : La connaissance des lois marginales de toutes les composantes de X ne suffit pas à déterminer sa loi.

VECTEURS ALÉATOIRES

Soit $X = \begin{pmatrix} X_1 \\ \dots \\ X_d \end{pmatrix} \in \mathbb{R}^d$ un vecteurs aléatoire tel que

$\mathbb{E} [X_j^2] < +\infty$. Pour tout i, j , la covariance entre X_i et X_j est définie par

$$\text{Cov} (X_i, X_j) = \mathbb{E} [(X_i - \mathbb{E} [X_i]) (X_j - \mathbb{E} [X_j])]$$

Remarque : Si X_i et X_j sont indépendantes, $\text{Cov} (X_i, X_j) = 0$ mais la réciproque est généralement fausse (sauf pour les vecteurs gaussiens).

ESPÉRANCE ET MATRICE DE COVARIANCE

Définition

Soit X un vecteur aléatoire de \mathbb{R}^d tel que pour tout i, \dots, d , $\mathbb{E}[X_i^2] < +\infty$. Le vecteur moyenne de X est défini par

$$\mathbb{E}[X] = \begin{pmatrix} \mathbb{E}[X_1] \\ \vdots \\ \mathbb{E}[X_d] \end{pmatrix}$$

et sa matrice de covariance est définie par

$$\begin{aligned} \text{Var}[X] &= \mathbb{E} \left[(X - \mathbb{E}[X]) (X - \mathbb{E}[X])^T \right] \\ &= \begin{pmatrix} \text{Var}[X_1] & \text{Cov}(X_1, X_2) & \dots & \text{Cov}(X_1, X_d) \\ \text{Cov}(X_2, X_1) & \text{Var}[X_2] & \dots & \text{Cov}(X_2, X_d) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_d, X_1) & \text{Cov}(X_d, X_2) & \dots & \text{Var}[X_d] \end{pmatrix} \end{aligned}$$

MATRICE DE COVARIANCE

Théorème

La matrice de covariance est une matrice symétrique semi-définie positive.

Théorème

Soit X un vecteur aléatoire de \mathbb{R}^d de moyenne m et de matrice de covariance C . Alors, si A est une matrice réelle $p \times d$, le vecteur aléatoire $AX \in \mathbb{R}^p$ a pour vecteur moyen Am et pour matrice de covariance ACA^T .

FONCTION CARACTÉRISTIQUE

Définition

Soit X un vecteur aléatoire de \mathbb{R}^d . Sa fonction caractéristique Φ_X est définie pour tout $u \in \mathbb{R}^d$ par

$$\Phi_X(u) = \mathbb{E} \left[e^{iu^T X} \right] = \mathbb{E} \left[e^{i(u_1 X_1 + \dots + u_d X_d)} \right].$$

INDÉPENDANCE

Définition

Soient $X \in \mathbb{R}^d$, $Y \in \mathbb{R}^{d'}$ deux vecteurs aléatoires. X et Y sont indépendants si pour tout $A \in \mathcal{B}(\mathbb{R}^d)$ et pour tout $B \in \mathcal{B}(\mathbb{R}^{d'})$

$$\mathbb{P}[(X, Y) \in A \times B] = \mathbb{P}[X \in A] \mathbb{P}[Y \in B].$$

CARACTÉRISATION

Proposition

Soient $X \in \mathbb{R}^d, Y \in \mathbb{R}^{d'}$ deux vecteurs aléatoires.

- ▶ X et Y sont indépendants si et seulement si pour tout $t = (t_1, t_2)$,

$$\Phi_{(X,Y)}(t) = \Phi_X(t_1) \Phi_Y(t_2).$$

- ▶ X et Y sont indépendants si et seulement si pour tout $t = (t_1, t_2)$,

$$f_{(X,Y)}(t) = f_X(t_1) f_Y(t_2).$$

II. Vecteurs aléatoires Gaussiens

VECTEURS ALÉATOIRES GAUSSIENS

Définition

Soit X un vecteur aléatoire de \mathbb{R}^d . X est un vecteur gaussien de \mathbb{R}^d si et seulement si toute combinaison linéaire de ses composantes est une variable aléatoire réelle gaussienne, i.e

$$\forall u \in \mathbb{R}^d, \quad u^T X \sim \mathcal{N}(m_u, \sigma_u^2).$$

Exemple : Un vecteur X dont les composantes X_i sont indépendantes et suivent une loi normale est un vecteur gaussien.

VECTEUR GAUSSIEN ET FONCTION CARACTÉRISTIQUE

Théorème

Soit X un vecteur aléatoire de \mathbb{R}^d . Les assertions suivantes sont équivalentes :

1. Le vecteur X est un vecteur gaussien de moyenne m et de matrice de covariance Γ .
2. La fonction caractéristique de X est donnée pour tout $u \in \mathbb{R}^d$ par

$$\Phi_X(u) = \mathbb{E} \left[e^{iu^T X} \right] = \exp \left(iu^T m - \frac{1}{2} u^T \Gamma u \right).$$

COROLLAIRES

Corollaire

Soit $X \sim \mathcal{N}(m, \Gamma)$ à valeurs dans \mathbb{R}^d . Soit A une matrice $p \times d$ et $b \in \mathbb{R}^p$, alors

$$AX + b \sim \mathcal{N}(Am + b, A\Gamma A^T)$$

Corollaire

Soit $X \sim \mathcal{N}(m, \Gamma)$, et Γ inversible, alors

$$\Gamma^{-1/2}(X - m) \sim \mathcal{N}(0, I_d).$$

DENSITÉ D'UN VECTEUR GAUSSIEN

Théorème

Soit $X \in \mathbb{R}^d$ avec $X \sim \mathcal{N}(m, \Gamma)$. X admet une densité par rapport à la mesure de Lebesgue de \mathbb{R}^d si et seulement si Γ est inversible. Dans ce cas, la densité de f est donnée pour tout $x \in \mathbb{R}^d$ par

$$f(x) = \frac{1}{\sqrt{(2\pi)^d |\det(\Gamma)|}} \exp\left(-\frac{1}{2}(x - m)^T \Gamma^{-1}(x - m)\right)$$

VECTEUR GAUSSIEN ET INDÉPENDANCE

Théorème

Pour tout vecteur gaussien X de \mathbb{R}^d , les propriétés suivantes sont équivalentes :

- ▶ *Les composantes X_1, \dots, X_d de X sont indépendantes.*
- ▶ *La matrice de covariance Γ de X est diagonale.*

Corollaire

Soit X un vecteur gaussien, alors pour tout $i \neq j$, X_i et X_j sont indépendantes si et seulement si

$$\text{Cov}(X_i, X_j) = 0.$$

III. Convergences

CONVERGENCE EN LOI

Définition

Soit (X_n) une suite de vecteurs aléatoires. On dit que (X_n) converge en loi vers le vecteur aléatoire X si pour tout point de continuité t de F_X on a

$$F_{X_n}(t) \xrightarrow{n \rightarrow +\infty} F_X(t).$$

Proposition

(X_n) converge en loi vers le vecteur aléatoire X si et seulement si pour toute fonction continue bornée h ,

$$\mathbb{E}[h(X_n)] \xrightarrow{n \rightarrow +\infty} \mathbb{E}[h(X)].$$

CONVERGENCE EN PROBABILITÉ

Soit (X_n) une suite de vecteurs aléatoires à valeurs dans \mathbb{R}^d que l'on munit d'une norme $\|\cdot\|$.

Définition

La suite (X_n) converge en probabilité vers un vecteur aléatoire X si pour tout $\epsilon > 0$,

$$\mathbb{P} [\|X_n - X\| > \epsilon] \xrightarrow{n \rightarrow +\infty} 0.$$

Remarque : Comme toutes les normes sont équivalentes dans \mathbb{R}^d , alors si la suite (X_n) converge pour une norme $\|\cdot\|$, alors elle converge aussi pour une norme $\|\cdot\|'$.

Définition

La suite (X_n) converge presque sûrement vers un vecteur aléatoire X si

$$\mathbb{P} \left[\left\{ \omega, \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega) \right\} \right] \xrightarrow{n \rightarrow +\infty} 0.$$

Remarque : Si pour tout $\epsilon > 0$,

$$\sum_{n \geq 1} \mathbb{P} [\|X_n - X\| > \epsilon] < +\infty$$

alors (X_n) converge presque sûrement vers X .

LIEN ENTRE LES MODES DE CONVERGENCE

$$X_n \xrightarrow[n \rightarrow +\infty]{p.s.} X \implies X_n \xrightarrow[n \rightarrow +\infty]{\mathbb{P}} X \implies X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X$$

$$X_n \xrightarrow[n \rightarrow +\infty]{L^2} X \implies X_n \xrightarrow[n \rightarrow +\infty]{\mathbb{P}} X \implies X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X$$

IV. Théorèmes asymptotiques

THÉORÈME DE CONTINUITÉ

Théorème (Théorème de continuité)

Soit $g : D \rightarrow \mathbb{R}^{d'}$ une fonction continue sur un ouvert $D \subset \mathbb{R}^d$ et soit X un vecteur aléatoire à valeurs dans D . Soit (X_n) une suite de vecteurs aléatoires à valeurs dans \mathbb{R}^d . Si (X_n) converge vers X , alors $g(X_n)$ hérite du mode de convergence de (X_n) , i.e

$$X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X \implies g(X_n) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} g(X)$$

$$X_n \xrightarrow[n \rightarrow +\infty]{\mathbb{P}} X \implies g(X_n) \xrightarrow[n \rightarrow +\infty]{\mathbb{P}} g(X)$$

$$X_n \xrightarrow[n \rightarrow +\infty]{p.s} X \implies g(X_n) \xrightarrow[n \rightarrow +\infty]{p.s} g(X)$$

THÉORÈME DE SLUTSKY

Théorème

Soit (X_n) une suite de vecteurs aléatoires convergeant en loi vers X et (Y_n) une suite de vecteurs aléatoires convergeant en probabilité vers un vecteur constant c . Alors

$$X_n + Y_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X + c$$

et

$$X_n Y_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} Xc \quad \text{et} \quad Y_n X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} cX$$

Remarque : Les résultats précédents sous entendent bien évidemment que les dimensions de X et c sont "adaptées".

THÉORÈMES LIMITES

Théorème (Loi des grands nombres)

Soient X_1, \dots, X_n une suite de vecteurs aléatoires indépendants et identiquement distribués tel que $\mathbb{E} [\|X_1\|] < +\infty$. Alors

$$\bar{X}_n \xrightarrow[n \rightarrow +\infty]{p.s.} \mathbb{E} [X_1].$$

Théorème (Théorème Central Limite)

Soient X_1, \dots, X_n une suite de vecteurs aléatoires indépendants et identiquement distribuées tel que $\mathbb{E} [\|X_1\|^2] < +\infty$. Alors

$$\sqrt{n} (\bar{X}_n - \mathbb{E} [X_1]) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N} (0, \text{Var} [X_1]).$$

DELTA MÉTHODE

Théorème

Soit (X_n) une suite de vecteurs aléatoires, X un vecteur aléatoire, v_n une suite de réels telle que $\lim_{n \rightarrow +\infty} v_n = +\infty$ et m un vecteur tel que

$$v_n (X_n - m) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X.$$

Soit $g = (g_1, \dots, g_{d'}) : D \rightarrow \mathbb{R}^{d'}$ avec $m \in D \subset \mathbb{R}^d$ une fonction continuellement différentiable, alors

$$v_n (g(X_n) - g(m)) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} J_g(m)X$$

où $J_g(m) = \left(\frac{\partial}{\partial m_i} g_j(m) \right)_{i,j}$ est la matrice Jacobienne de g en m .

CAS PARTICULIER

Soit (X_n) une suite d'estimateurs de m asymptotiquement normaux, i.e il existe une matrice $\Sigma \in \mathcal{M}_d(\mathbb{R})$ tel que

$$\sqrt{n}(X_n - m) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, \Sigma).$$

Soit $g = (g_1, \dots, g_{d'}) : D \rightarrow \mathbb{R}^{d'}$ avec $m \in D \subset \mathbb{R}^d$ une fonction continuellement différentiable, alors

$$\sqrt{n}(g(X_n) - g(m)) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, J_g(m)\Sigma J_g(m)^T).$$

V. Théorème de Cochran et applications

THÉORÈME DE COCHRAN

Théorème (Théorème de Cochran)

Soit X un vecteur aléatoire de \mathbb{R}^n suivant une loi $\mathcal{N}(m, \sigma^2 I_n)$ avec $\sigma^2 > 0$. Soit $\mathbb{R}^n = E_1 \oplus E_2 \oplus \dots \oplus E_p$ une décomposition de \mathbb{R}^n en somme directe de p sous-espaces vectoriels orthogonaux de dimensions respectives d_1, \dots, d_p . Soit P_k le projecteur orthogonal sur E_k et $Y_k = P_k X$ la projection orthogonale de X sur E_k .

1. Les projections Y_1, \dots, Y_p sont des vecteurs gaussiens indépendants et $Y_k \sim \mathcal{N}(P_k m, \sigma^2 P_k)$.
2. Les variables aléatoires $\|Y_1 - P_1 m\|^2, \dots, \|Y_p - P_p m\|^2$ sont indépendantes et

$$\frac{\|Y_k - P_k m\|^2}{\sigma^2} \sim \chi_{d_k}^2$$

COROLLAIRE

Corollaire

Soient X_1, \dots, X_n des variables aléatoires indépendantes et identiquement distribuées avec $X_1 \sim \mathcal{N}(m, \sigma^2)$. On a alors

1. $\bar{X}_n \sim \mathcal{N}\left(m, \frac{\sigma^2}{n}\right)$.
2. $\frac{n-1}{\sigma^2} S_n^2 \sim \chi_{n-1}^2$.
3. \bar{X}_n et S_n^2 sont indépendantes.

AUTRES RÉSULTATS

Proposition

Soient Z, Z_p, Z_q trois variables aléatoires telles que

1. $Z = Z_p + Z_q$
2. $Z_p \sim \chi_p^2$ et $Z_q \sim \chi_q^2$
3. Z_p et Z_q sont indépendantes

alors $Z \sim \chi_{p+q}$.

TEST DU KHI DEUX

Corollaire (Test du Khi deux d'ajustement)

Soit X une variable aléatoire à valeurs dans $\{a_1, \dots, a_K\}$ avec $\mathbb{P}[X = a_k] = p_k > 0$. Soient X_1, \dots, X_n des variables aléatoires i.i.d de même loi que X . Soit $E_k = \sum_{i=1}^n \mathbf{1}_{X_i = a_k}$. On a alors

$$\sum_{k=1}^K \frac{(E_k - np_k)^2}{np_k} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi_{K-1}^2.$$