

# Chapitre 14

## Vecteurs gaussiens

Un vecteur aléatoire est une application de  $\Omega$  dans  $\mathbb{R}^n$ :

$$\begin{aligned} X : \Omega &\rightarrow \mathbb{R}^n \\ \omega &\mapsto (X_1(\omega), \dots, X_n(\omega)) \end{aligned}$$

où chaque composante est une variable aléatoire sur  $\Omega$

On a alors

- $F_X(x_1, \dots, x_n) = \mathbb{P}(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$
- $F_{X_i}(x_i) = \mathbb{P}(X_i \leq x_i)$
- $F_{X_i}(x_i) = F_X(+\infty, \dots, x_i, \dots, +\infty)$ , et
- $F_X(x_1, x_2, \dots, x_n) = F_{X_1}(x_1)F_{X_2}(x_2)\dots F_{X_n}(x_n)$  si  $X_1, \dots, X_n$  sont indépendantes

# Définition

Un vecteur aléatoire  $X : \Omega \rightarrow \mathbb{R}^n$  est dit gaussien (ou normal) si il peut s'écrire  $X = \mu + AZ$ :

$$\begin{pmatrix} X_1 \\ \cdot \\ \cdot \\ \cdot \\ X_n \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \cdot \\ \cdot \\ \cdot \\ \mu_n \end{pmatrix} + \begin{pmatrix} \alpha_{11} & \dots & \alpha_{1m} \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \alpha_{n1} & \dots & \alpha_{nm} \end{pmatrix} \begin{pmatrix} Z_1 \\ \cdot \\ \cdot \\ \cdot \\ Z_m \end{pmatrix}$$

où  $Z_1, \dots, Z_m$  sont des variables gaussiennes (normales) centrées réduites indépendantes.

Autrement dit, les composantes d'un vecteur gaussien sont des combinaisons linéaires des variables normales  $Z_1, \dots, Z_m$  :

$$X_i = \mu_i + a_{i1}Z_1 + \dots + a_{im}Z_m$$

Si  $n = m$  et la matrice  $A$  est inversible, on dit que  $X$  est non-sigulier.

### Exemple 1

$$\begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} Z_1 \\ Z_2 \end{pmatrix}$$

avec  $Z_1 \perp Z_2$  et  $Z_1, Z_2 \sim \mathcal{N}(0, 1)$

Alors  $X = (X_1, X_2)$  est un vecteur gaussien non-singulier avec :  
 $X_1 = \mu_1 + Z_1 + Z_2$  et  $X_2 = \mu_2 + Z_1 - Z_2$

### Exemple 2

$$\begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} 1 \\ 1 \end{pmatrix} (Z_1), \text{ avec } Z_1 \sim \mathcal{N}(0, 1)$$

Alors  $X = (X_1, X_2) = (\mu_1 + Z_1, \mu_2 + Z_1)$  est un vecteur gaussien singulier

# Espérance et Variance d'un vecteur gaussien

Rappelons qu'une variable gaussienne (normale)  $\mu, \sigma$  est caractérisée par deux paramètres : la moyenne  $\mu$  et l'écart-type  $\sigma$  (ou la variance  $\sigma^2$ ).

De manière analogue, un vecteur gaussien est caractérisé pas le vecteur  $\mathbb{E}(X)$  et la matrice de variance-covariance :

$$\begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) & \cdot & \cdot & \cdot & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \text{Var}(X_2) & \cdot & \cdot & \cdot & \text{Cov}(X_2, X_n) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \text{Cov}(X_n, X_1) & \cdot & \cdot & \cdot & \cdot & \text{Var}(X_n) \end{pmatrix}$$

Remarque : cette matrice est symétrique puisque  
 $\overline{\text{Cov}(X_i, X_j)} = \text{Cov}(X_j, X_i)$

## Proposition

Soit  $X = \mu + AZ$  un vecteur gaussien. Alors

- $\mathbb{E}(X) = \mu$  (c'est à dire  $\mathbb{E}(X_i) = \mu_i, i = 1, \dots, n$ ) et
- la matrice de variance-covariance de  $X$  vaut  $\Gamma = AA^T$

Démonstration : On a

$$X_i = \mu_i + a_{i1}Z_1 + \dots + a_{im}Z_m = \mu_i + \sum_{j=1}^m a_{ij}Z_j$$

$$\Rightarrow \mathbb{E}(X_i) = \mu_i + \sum_{j=1}^m a_{ij}\mathbb{E}(Z_j) = \mu_i \text{ car } Z_j \sim \mathcal{N}(0, 1),$$

$$\text{Var}(X_i) = \text{Var}\left(\mu_i + \sum_{j=1}^m a_{ij}Z_j\right) = \sum_{j=1}^m a_{ij}^2 \text{Var}(Z_j) \text{ (les } Z_j \text{ sont } \perp)$$

Comme  $Z_j \sim \mathcal{N}(0, 1) \forall j$

$$\text{Var}(X_i) = \sum_{j=1}^m a_{ij}^2 = (a_{i1} \ a_{i2} \dots \ a_{im}) \begin{pmatrix} a_{i1} \\ a_{i2} \\ \cdot \\ \cdot \\ a_{im} \end{pmatrix} = A_i \cdot A_i^T$$

Pour  $i \neq k$ ,

$$\begin{aligned} \text{Cov}(X_i, X_k) &= \text{Cov} \left( \mu_i + \sum_{j=1}^m a_{ij} Z_j, \mu_k + \sum_{l=1}^m a_{kl} Z_l \right) = \\ &= \mathbb{E} \left[ \left( \mu_i + \sum_{j=1}^m a_{ij} Z_j \right) \left( \mu_k + \sum_{l=1}^m a_{kl} Z_l \right) \right] - \mathbb{E} \left( \mu_i + \sum_{j=1}^m a_{ij} Z_j \right) \mathbb{E} \left( \mu_k + \sum_{l=1}^m a_{kl} Z_l \right) \\ &= \mu_i \mu_k + \sum_{j=1}^m a_{ij} a_{kj} \underbrace{\mathbb{E}(Z_j^2)}_{=1} - \mu_i \mu_k = \sum_{j=1}^m a_{ij} a_{kj} \end{aligned}$$

Ainsi,

$$\text{Cov}(X_i, X_k) = \sum_{j=1}^m a_{ij} a_{kj} = (a_{i1} \ a_{i2} \dots \ a_{im}) \begin{pmatrix} a_{k1} \\ a_{k2} \\ \vdots \\ a_{km} \end{pmatrix} = A_i \cdot A_k^T$$

et

$$\Gamma = \begin{pmatrix} A_1 A_1^T & \dots & A_1 A_n^T \\ A_2 A_1^T & \dots & A_2 A_n^T \\ \vdots & & \vdots \\ \vdots & & \vdots \\ A_n A_1^T & \dots & A_n A_n^T \end{pmatrix} = \begin{pmatrix} \text{---} A_1 \text{---} \\ \text{---} A_2 \text{---} \\ \vdots \\ \vdots \\ \text{---} A_n \text{---} \end{pmatrix} \begin{pmatrix} | & | & \dots & | \\ A_1 & A_2 & \dots & A_n \\ | & | & \dots & | \end{pmatrix} = A \cdot A^T$$

# Exemple

- $m = n = 1$ ,  $X = \mu + aZ$ ,  $Z \sim \mathcal{N}(0, 1)$   
 $\Rightarrow \mathbb{E}(X) = \mu$ ,  $\text{Var}(X) = a^2 \Rightarrow X \sim \mathcal{N}(\mu, a^2)$
- $m = n = 2$

$$\begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} Z_1 \\ Z_2 \end{pmatrix}$$

$$\Rightarrow \mathbb{E}(X) = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}, \Gamma = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} a_{11} & a_{21} \\ a_{12} & a_{22} \end{pmatrix}$$

$$\Rightarrow \text{Var}(X_1) = a_{11}^2 + a_{12}^2, \text{Var}(X_2) = a_{21}^2 + a_{22}^2$$

$$\text{et } \text{Covar}(X_1, X_2) = a_{11}a_{21} + a_{12}a_{22}$$

- $m = 1, n = 2$

$$\begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} a_{11} \\ a_{21} \end{pmatrix} ( Z_1 )$$

$$X_1 = \mu_1 + a_{11}Z_1, X_2 = \mu_2 + a_{21}Z_1$$

$$\Rightarrow \mathbb{E}(X) = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$$

$$\Gamma = \begin{pmatrix} a_{11} \\ a_{21} \end{pmatrix} ( a_{11} \quad a_{21} ) = \begin{pmatrix} a_{11}^2 & a_{11}a_{21} \\ a_{11}a_{21} & a_{21}^2 \end{pmatrix}$$

$$\Rightarrow \text{Var}(X_1) = a_{11}^2, \text{Var}(X_2) = a_{21}^2$$

$$\text{et } \text{Covar}(X_1, X_2) = a_{11}a_{21}$$

- $m = 2, n = 1$

$$\begin{pmatrix} X_1 \end{pmatrix} = \begin{pmatrix} \mu_1 \end{pmatrix} + \begin{pmatrix} a_{11} & a_{12} \end{pmatrix} \begin{pmatrix} Z_1 \\ Z_2 \end{pmatrix}$$

$$X_1 = \mu_1 + a_{11}Z_1 + a_{12}Z_2$$

$$\Rightarrow \mathbb{E}(X_1) = \mu_1 \text{ et } \Gamma = \begin{pmatrix} a_{11} & a_{12} \end{pmatrix} \begin{pmatrix} a_{11} \\ a_{12} \end{pmatrix} = a_{11}^2 + a_{12}^2$$

$$\Rightarrow \text{Var}(X_1) = a_{11}^2 + a_{12}^2$$

# Indépendance

## Proposition

Soient  $X : \Omega \rightarrow \mathbb{R}^N$  et  $Y : \Omega \rightarrow \mathbb{R}^M$  tels que  $Z = (X, Y) = (X_1, \dots, X_N, Y_1, \dots, Y_M)$  est un vecteur gaussien.

Alors  $X$  et  $Y$  sont indépendants si et seulement si ils sont non corrélés ( $\text{Cov}(X_i, Y_j) = 0, i = 1, \dots, n; j = 1, \dots, m$ )

Exemple :  $n = 1, m = 1$ . Soit  $V = (X, Y)$  un vecteur gaussien non singulier, i.e. :

$$\begin{aligned} X &= \mu_1 + a_{11}Z_1 + a_{12}Z_2 \\ Y &= \mu_2 + a_{21}Z_1 + a_{22}Z_2 \end{aligned}, Z_1 \perp Z_2 \text{ et } A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \text{ inversible}$$

Alors  $X$  et  $Y$  indépendants  $\Leftrightarrow \text{Cov}(X, Y) = 0$

$$\Leftrightarrow a_{11}a_{21} + a_{12}a_{22} = 0$$

Soit

$$X \sim \mathcal{N}(0, 1), W = \begin{cases} 1 & , 1/2 \\ -1 & , 1/2 \end{cases}, Y = WX$$

Le vecteur  $(X, Y)$  n'est pas gaussien même si les deux composantes sont gaussiennes :  $X \sim \mathcal{N}(0, 1)$ ,  $Y \sim \mathcal{N}(0, 1)$ .  
En effet, on a vu (chap 12) que  $\text{Cov}(X, Y) = 0$  mais  $X$  et  $Y$  ne sont pas indépendants, donc  $(X, Y)$  ne peut pas être gaussien

# Densité d'un vecteur gaussien

Si  $X = (X_1, \dots, X_n)$  ( $X = \mu + AZ$ ) est un vecteur gaussien non singulier de matrice de variance-covariance  $\Gamma$  alors il admet une densité donnée par:

$$f_x(y) = \frac{1}{(2\Pi)^{n/2}} \cdot \frac{1}{\sqrt{\det(\Gamma)}} e^{-\frac{1}{2}(y-\mu)^T \Gamma^{-1}(y-\mu)}$$

où  $y = (y_1, \dots, y_n)^T$  et  $\Gamma = AA^T$

Si  $n = 1$ , on a  $\Gamma = \sigma^2$  et on retrouve la densité d'une variable gaussienne

Si  $n = 2$ , avec  $X, Y \sim \mathcal{N}(0, 1)$  et  $\text{Cov}(X, Y) = \rho$  alors

$$f_{X,Y}(x, y) = \frac{1}{2\Pi\sqrt{1-\rho^2}} \cdot e^{-(x^2-2\rho xy+y^2)/(2(1-\rho^2))}$$

## Proposition

Soient  $X : \Omega \rightarrow \mathbb{R}^N$  et  $Y : \Omega \rightarrow \mathbb{R}^M$  tels que  $Z = (X, Y)$  est un vecteur gaussien. Alors  $\mathbb{E}(Y | X)$  est égale à la régression linéaire (MPL) de  $Y$  sur  $\{X_1, \dots, X_N\}$ .

En particulier si  $N = 1$  et  $\text{Var}(X) \neq 0$

$$\mathbb{E}(Y | X) = \mathbb{E}(Y) + \frac{\text{cov}(X, Y)}{\text{Var}(X)}(X - \mathbb{E}(X))$$

# Rappel sur les régressions linéaires

La régression de  $Y$  sur  $X_1, \dots, X_N$  est la combinaison linéaire de  $1, X_1, \dots, X_N$  :  $\tilde{Y} = a_0 + a_1 X_1 + \dots + a_N X_N$  telle que la distance entre  $Y$  et  $\tilde{Y}$  (définie comme  $\mathbb{E}((Y - \tilde{Y})^2)$ ) soit minimale

## Utilisation :

- $Y$  est une variable non observable et  $X_1, \dots, X_N$  sont des variables observables  $\rightarrow$  déduire la valeur de  $Y$  le plus précisément possible à partir de l'observation de  $X_1, \dots, X_N$
- $Y$  est une quantité complexe dépendant de plusieurs facteurs et on veut la représenter comme une fonction linéaire de quelques facteurs explicatifs  $X_1, \dots, X_N$ . Par exemple,  $Y$  est la valeur d'une option et les facteurs explicatifs sont le taux de croissance américain et le rendement de l'action à la période précédente

# La différence avec l'espérance conditionnelle

L'espérance conditionnelle  $\mathbb{E}(X | Y)$  est la projection de  $Y$  sur l'espace de **toutes** les fonctions de  $X$  ( $\mathbb{E}(Y | X) = h(X)$ ).

La régression linéaire est la projection de  $Y$  sur l'espace des **fonctions affines** de  $X$  :  $\tilde{Y} = a_0 + a_1X_1 + \dots + a_NX_N$

Cette différence disparaît dans le cas gaussien : l'espérance conditionnelle est égale à la régression linéaire

# Exemple

Soient  $U$  et  $X$  deux v.a. gaussienne indépendantes :

$$U \sim \mathcal{N}(\mu_u, \sigma_u), X \sim \mathcal{N}(\mu_x, \sigma_x), U \perp X$$

On pose  $Z = X - \frac{1}{2b}(U - \mu_u)$ . Calculer  $\mathbb{E}(U | Z = \bar{z})$ .

(la notation  $\mathbb{E}(U | Z = \bar{z})$  signifie qu'on doit calculer  $\mathbb{E}(U | Z)$  et remplacer  $Z$  par  $\bar{z}$ )

Le couple  $(U, Z)$  est gaussien parce que  $U$  et  $Z$  sont des combinaisons affines de loi normales centrales centrées réduites indépendant  $G_X = \frac{X - \mu_x}{\sigma_x}$  et  $G_U = \frac{U - \mu_u}{\sigma_u}$  :

$$\begin{pmatrix} U \\ Z \end{pmatrix} = \begin{pmatrix} \mu_u \\ \mu_x \end{pmatrix} + \begin{pmatrix} \sigma_u & 0 \\ -\frac{\sigma_u}{2b} & \sigma_x \end{pmatrix} \begin{pmatrix} G_U \\ G_X \end{pmatrix}$$

$$(Z = \mu_x + \sigma_x G_X - \frac{1}{2b} \sigma_u G_U)$$

$$\Gamma = AA^T = \begin{pmatrix} \sigma_U^2 & -\sigma_U^2/2b \\ -\sigma_U^2/2b & \sigma_X^2 + \sigma_U^2/4b^2 \end{pmatrix}$$

Donc

$$\begin{aligned} \mathbb{E}(U | Z) &= \mathbb{E}(U) + \frac{\text{Cov}(U, Z)}{\text{Var}(Z)}(Z - \mathbb{E}(Z)) \\ &= \mu_U - \frac{\sigma_U^2/2b}{\sigma_X^2 + \sigma_U^2/4b^2}(Z - \mu_X) \\ \Rightarrow \mathbb{E}(U | Z = \bar{z}) &= \mu_U - \frac{\sigma_U^2/2b}{\sigma_X^2 + \sigma_U^2/4b^2}(\bar{z} - \mu_X) \end{aligned}$$