

Processus Aléatoires : généralités et exemples


O. Roustant
Janvier 2007

Master « *Modélisation mathématique et applications* »




Définition


- *Processus aléatoire, ou proc. stochastique* : famille de variables aléatoires $\{Z(x)\}_{x \in X}$
- « L'observable » : *réalisations, trajectoires*
- Un même processus, une infinité de réalisations



Exemples (2)


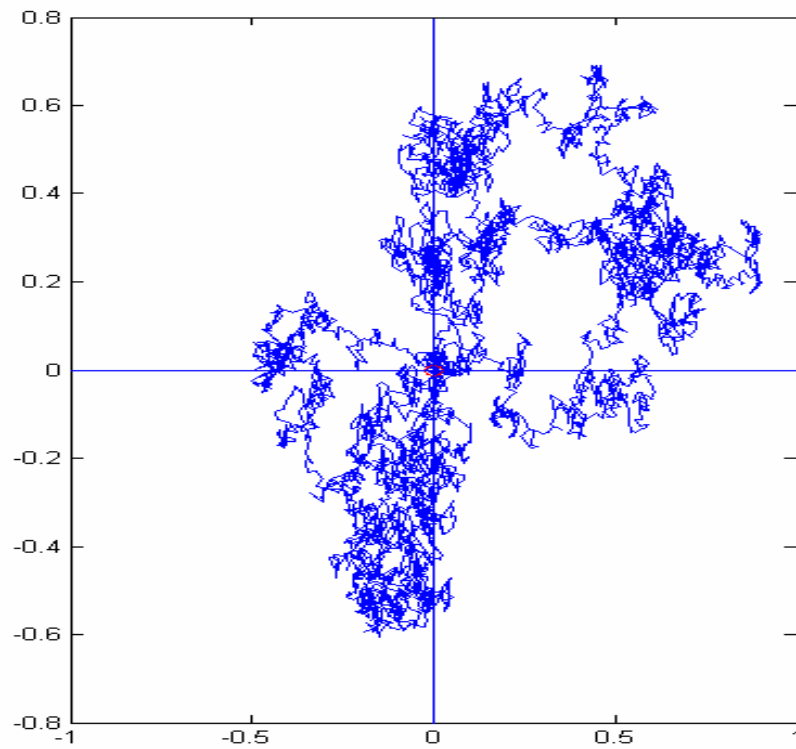
- Quelques réalisations d'un *mouvement brownien* en dimension 1...






Exemples (3)


- ... et en dimension 2





Exemples (4)


- Quelques réalisations d'un *processus gaussien*, avec trajectoires C^∞






Exemples (5)

- Le même, mais *conditionnel* à :
 $Z(x^{(1)}) = -0.5$ et $Z(x^{(2)}) = 0.5$





Processus du second ordre

- Un processus $(Z(x))$ est :
 - *centré* ssi pour tout x , $E(|Z(x)|) < +\infty$ et $E(Z(x)) = 0$
 - du *second ordre* ssi pour tout x , $E(Z(x)^2) < +\infty$
 - \Rightarrow p.t. x, y , $E(|Z(x)|) < +\infty$ et $\text{cov}(Z(x), Z(y)) < +\infty$

Rappel $\text{cov}(X, Y) = E((X - EX)(Y - EY))$ *covariance*

$\text{var}(X) = \text{cov}(X, X) = E((X - EX)^2)$ *variance*

$s(X) = \text{racine de } \text{var}(X)$ *écart-type*

$\text{corr}(X, Y) = \text{cov}(X, Y) / (s(X)s(Y))$ *corrélation*



Cadre géométrique

- (*Espace L^2*)

- L'espace vectoriel des v.a. qui ont un moment d'ordre 2 est un espace de Hilbert pour le produit scalaire $\langle X, Y \rangle = E(XY)$


- Si on se restreint aux v.a. centrées, $\langle X, Y \rangle = \text{cov}(X, Y)$



Stationnarité (1)

Le processus $(Z(x))$ est :


- *fortement stationnaire* ssi :
 - $(Z(x_1), \dots, Z(x_L))$ et $(Z(x_1+h), \dots, Z(x_L+h))$ ont la même loi, pour tous x_1, \dots, x_L et pour tout h
- *faiblement stationnaire* ssi :
 - $E(Z(x))$, $E(Z(x)^2)$ et $\text{cov}(Z(x), Z(x-h))$ sont finis et ne dépendent pas de x , pour tout x et pour tout h



Autocovariance, autocorrélation (1)


Pour un processus stationnaire d'ordre 2, on définit :

- La *fonction d'autocovariance* :
 - $\gamma(h) = \text{cov}(Z(x), Z(x-h))$
- La *fonction d'autocorrélation* :
 - $\rho(h) = \text{corr}(Z(x), Z(x-h))$



Autocovariance, autocorrélation (2)

- Propriétés :
 - $\rho(h) = \gamma(h) / \gamma(0)$
 - $\gamma(-h) = \gamma(h)$
 - $|\rho(h)| \leq 1$
- Interprétation géométrique :
 - $\rho(h)$ est le cosinus de l'angle formé par
 $Z(x)-m$ et $Z(x-h)-m$
où $m = E(Z(x)) = E(Z(x-h))$




Espérance conditionnelle (1)

- Définition dans L^2 (vision géométrique)
- *L'espérance conditionnelle (linéaire)* de X sachant Y , est une v.a. notée

$$E(X|Y_1, \dots, Y_k), \text{ (resp. } E_L(X|Y_1, \dots, Y_k))$$


qui est la meilleure approximation de X comme fonction (resp. comb. linéaire) de Y_1, \dots, Y_k au sens L^2 :

$$E(X|Y_1, \dots, Y_k) = \operatorname{argmin} (\|X - f(Y_1, \dots, Y_k)\|_{L^2})$$



Espérance conditionnelle (2)

- Il s'agit donc de projections orthogonales. Pour cette raison, on appelle souvent :
 - $E_L(X|Y)$ *régression linéaire* de X sur Y
 - $E(X|Y)$ *régression (non linéaire)* de X sur Y
- Cas particulier remarquable : si (X, Y) est un *vecteur gaussien*, les régressions linéaires et non linéaires coïncident



Espérance conditionnelle (3)

- Quelques propriétés
 - Linéarité : $E(aX+b|Y) = aE(X|Y) + b$
 - $EX = E(E(X|Y))$
 - $E(f(Y) | Y) = f(Y)$
 - $E(Xf(Y) | Y) = f(Y) E(X|Y)$
 - Si Z est relative à une information contenue dans Y , $E(X | Z) = E(E(X | Y) | Z)$
 - Si X et Y sont indépendants, $E(X|Y) = E(X)$
 - ...



Variance conditionnelle

- Définition :

$$\text{var}[f(X) | Y_1, \dots, Y_k] = E([X - E(X | Y_1, \dots, Y_k)]^2 | Y_1, \dots, Y_k)$$

- Propriété (Pythagore !):

$$\begin{aligned} \text{var}(f(X)) &= E(\text{var}[f(X) | Y_1, \dots, Y_k]) \\ &\quad + \text{var}(E(f(X) | Y_1, \dots, Y_k)) \end{aligned}$$



Loi conditionnelle

- On admet qu'il existe une probabilité P telle que pour toute fonction f ,

$$E[f(X) | Y_1, \dots, Y_k] = \int f(x) dP(x)$$

P est appelé *loi conditionnelle* de X sachant Y_1, \dots, Y_k , et notée $d\mu_{X|Y_1, \dots, Y_k}$

- En particulier,

- $E[X | Y_1, \dots, Y_k] = \int x d\mu_{X|Y_1, \dots, Y_k}(x)$




Processus gaussien (1)

- Rappel. La densité de la *loi normale d-dimensionnelle* est donnée par :

$$f_{\mu, \Sigma}(x_1, \dots, x_d) = \frac{1}{(2\pi)^{d/2} \sqrt{\det(\Sigma)}} \exp\left(-\frac{1}{2}(X - \mu)' \Sigma^{-1}(X - \mu)\right)$$

avec

- $X = (x_1, \dots, x_d)'$,
- μ un vecteur $d \times 1$, s'interprétant comme la moyenne
- Σ une matrice symétrique (définie) positive, s'interprétant comme la matrice de covariance



Processus gaussien (2)

- En fait, la densité est définie uniquement en fonction des 2 premiers moments, comme en dim. 1:

- *Dans le cas d'indépendance,*


$$f_{(X_1, \dots, X_d)}(x_1, \dots, x_d) = f_{(X_1)}(x_1) * \dots * f_{(X_d)}(x_d)$$

- *Dans le cas général,* on exige que la loi d'un vecteur gaussien centré et réduit

$$(\Sigma^{1/2})^{-1}(X - \mu)$$

soit la même que dans le cas de l'indépendance

Conséquence immédiate : orthogonalité \Rightarrow indépendance




Processus gaussien (3)

- Un processus $(Z(x))$ est *gaussien* ssi
 - pour tous x_1, \dots, x_n , la loi du vecteur $(Z(x_1), \dots, Z(x_n))$ est gaussienne

ou, de façon équivalente, ssi :

- pour tous x_1, \dots, x_n , la loi de toute combinaison linéaire de $(Z(x_1), \dots, Z(x_n))$ est gaussienne




Processus gaussien (4)

- Pour un processus gaussien:
 - Faiblement stationnaire \Rightarrow stationnaire
 - Orthogonalité \Rightarrow indépendance
 - E cond. Linéaire = E conditionnelle
 - Les lois conditionnelles sont gaussiennes :

Si $X=[X_1; X_2]$ est gaussien, de moyenne $[m_1; m_2]$, et de matrice de covariance $S = [S_{11} \ S_{12}; S_{21} \ S_{22}]$, alors $X_1|X_2$ est gaussien, avec :

$$E(X_1|X_2) = m_1 + S_{12}(S_{22})^{-1}(X_2 - m_2)$$

$$\text{Cov}(X_1|X_2) = S_{11} - S_{12}(S_{22})^{-1} S_{21}$$




Processus gaussien (5)

- Comment simuler un processus gaussien ?
- On utilise la *décomposition de Choleski* : toute matrice symétrique définie positive admet la décomposition (unique)

$$S = L * L'$$


avec L matrice triangulaire inférieure

- Puis on remarque que si E est de loi normale $N(0, I_n)$, alors L.E est de loi $N(0, S)$



Mouvement brownien (1)

- Définition 1 : on appelle *mouvement brownien* (B_t) tout processus vérifiant :
 - (B_t) est un *processus à accroissements indépendants et stationnaires (PAIS)* : pour tout instant t et tout horizon h , l'accroissement $(B_{t+h}-B_t)$ est indépendant des variables B_s , $s \leq t$, et de loi indépendante de t
 - Les trajectoires sont continues



Mouvement brownien (2)

- Définition 2 : on appelle *mouvement brownien standard* (W_t) , ou *processus de Wiener*, un processus défini par :
 - $W_0 = 0$
 - (W_t) est un processus gaussien
 - (W_t) est centré, et $\text{cov}(W_s, W_t) = \min(s, t)$
 - Les trajectoires sont continues



Mouvement brownien (3)

- Il est facile de voir que tout processus de Wiener est un mouvement brownien
- Réciproquement (plus difficile), si (B_t) est un mouvement brownien, alors il existe a , b et $\sigma > 0$, tels que

$$B_t = a + bt + \sigma W_t$$

où W_t est un processus de Wiener




Mouvement brownien (4)

- Simulation : en discret, il s'agit d'une *marche au hasard*

$$W_{nh} = W_0 + \varepsilon_1 + \dots + \varepsilon_n$$


- Donc simulation par intégration d'un bruit blanc gaussien



Mouvement brownien (5)

- *Mouvement brownien multi-dimensionnel* : il s'agit d'un processus dont les coordonnées sont des mouvements browniens (standard) indépendants

$$\mathbf{W}_t = (W_{1,t}, \dots, W_{d,t})$$




Pont brownien (1)

- On appelle *pont brownien* le processus (P_t) défini sur $[0,1]$ par :

$$P_t = W_t - t.W_1$$

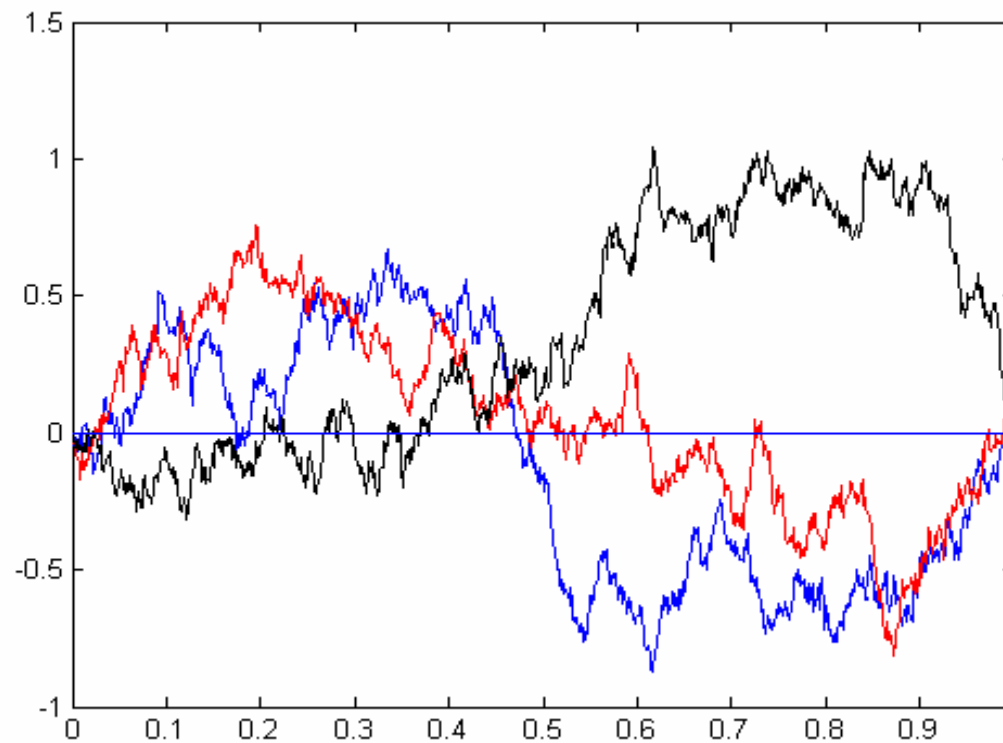
où (W_t) est un mouvement brownien standard.


- Le processus est contraint de passer par 0 aux bords \Rightarrow interpolation



Pont brownien (2)

- Quelques réalisations :





Pont brownien (3)

- Quelques propriétés
 - (P_t) est un processus gaussien
 - P_t est de loi $N(0, t(1-t))$
 - $\text{cov}(P_s, P_t) = \min(s, t) - st$



Modèle de krigeage (1)

- $y(x) = \mu + Z(x)$

μ : moyenne de $y(x)$, constante

$Z(x)$: processus gaussien stationnaire centré,
de matrice de covariance $\sigma^2 R$, avec
 $R(x, x+h)$ « décroissant » / h

Exemples :

- $R(x, y) = \exp(-[\theta_1 |x_1 - y_1|^{p(1)} + \dots + \theta_d |x_d - y_d|^{p(d)}])$
où $p(1), \dots, p(d) \in [1, 2]$
- Si $p(i) = 2$, les réalisations sont de classe C^∞



Modèle de krigeage (2)

- Simulation : il s'agit d'un processus gaussien particulier...
- Simulation du processus conditionnel : c'est encore un processus gaussien




Modèle de krigeage (3)

- Prédiction : dans le cas où μ , σ et R sont connus,

$$\begin{aligned} Y_{\text{pred}}(x) &= E[y(x)|y(x^{(1)}), \dots, y(x^{(n)})] \\ &= \mu + r'R^{-1}(y(x^{(1)}) - \mu, \dots, y(x^{(n)}) - \mu)' \end{aligned}$$

avec $r = (R(x, x^{(1)}), \dots, R(x, x^{(n)}))'$

- En pratique, on remplace μ , σ et R par leurs estimations (à suivre...)



Modèle de krigeage (4)

- Exemple en dimension 1, avec $\theta = 30$

