

Se por outro lado (U_1, U_2, \dots) é IID então mostremos que $X_n = U_1 + \dots + U_n$ tem incrementos independentes e estacionários. De facto, dados $n > m$ temos que

$$X_n - X_m = U_{m+1} + \dots + U_n.$$

Tome-se quaisquer $n_1 < n_2 < \dots < n_k$. Uma vez que U_1, U_2, \dots são IID segue que os incrementos

$$X_{n_2} - X_{n_1}, X_{n_3} - X_{n_2}, \dots, X_{n_k} - X_{n_{k-1}}$$

são independentes. A estacionariedade prova-se de maneira semelhante. \square

Num processo estacionário $\{X_t : t \in T\}$ com incrementos independentes e estacionários, se sabemos a função de densidade de probabilidade de X_t para todo $t \in T$ então podemos determinar a função de densidade conjunta f_{t_1, \dots, t_n} de qualquer vector aleatório $(X_{t_1}, \dots, X_{t_n})$.

Proposição 6.10. *Seja $X = \{X_t : t \in T\}$ um processo estacionário com incrementos independentes e estacionários tal que $X_0 = 0$ e X_t tem função densidade de probabilidade f_t para todo $t \in T$. Se $t_i \in T$, $i = 1, \dots, n$, tal que*

$$0 < t_1 < t_2 < \dots < t_n$$

então

$$f_{t_1, t_2, \dots, t_n}(x_1, x_2, \dots, x_n) = f_{t_1}(x_1) f_{t_2 - t_1}(x_2 - x_1) \cdots f_{t_n - t_{n-1}}(x_n - x_{n-1}).$$

Demonstração. Seja $U_1 = X_{t_1}$ e $U_i = X_{t_i} - X_{t_{i-1}}$ para $i = 2, \dots, n$. Então

$$(X_{t_1}, X_{t_2}, \dots, X_{t_n}) = (U_1, U_1 + U_2, \dots, U_1 + U_2 + \dots + U_n).$$

Segue de o processo ter incrementos estacionários e independentes que as variáveis aleatórias U_1, U_2, \dots, U_n são independentes e têm funções de densidade marginais $f_{t_1}, f_{t_2 - t_1}, \dots, f_{t_n - t_{n-1}}$. Logo,

$$f_{U_1, \dots, U_n}(x_1, \dots, x_n) = f_{t_1}(x_1) f_{t_2 - t_1}(x_2) \cdots f_{t_n - t_{n-1}}(x_n).$$

Seja $X = (X_{t_1}, X_{t_2}, \dots, X_{t_n})$, $U = (U_1, \dots, U_n)$ e considere a função $h : \mathbb{R}^n \rightarrow \mathbb{R}^n$ definida por

$$h(x_1, \dots, x_n) = (x_1, x_1 + x_2, \dots, x_1 + x_2 + \dots + x_n).$$

Segue do teorema da mudança de variável que,

$$\begin{aligned}
\int_{\mathbb{R}^n} g dp_X &= \int_{\mathbb{R}^n} g \circ h dp_U \\
&= \int_{\mathbb{R}^n} g \circ h \cdot f_U dm_n \\
&= \int_{\mathbb{R}^n} g(x_1, x_1 + x_2, \dots, x_1 + \dots + x_n) f_U(x_1, \dots, x_n) dm_n \\
&= \int_{\mathbb{R}^n} g(x_1, \dots, x_n) f_U(x_1, x_2 - x_1, \dots, x_n - x_{n-1}) dm_n
\end{aligned}$$

Como a função g é arbitrária concluímos que

$$\frac{dp_X}{dm_n}(x_1, \dots, x_n) = f_U(x_1, x_2 - x_1, \dots, x_n - x_{n-1}).$$

□

Proposição 6.11. *Seja $X = \{X_t : t \in T\}$ um processo estocástico com incrementos independentes e estacionários tal que $X_0 = 0$ e $E(X_t^2) < \infty$ para todo $t \in T$. Então existem constantes $\mu \in \mathbb{R}$ e $\sigma \geq 0$ tal que*

1. $E(X_t) = \mu t$ para $t \in T$.
2. $\text{Cov}(X_s, X_t) = \sigma^2 \min\{s, t\}$ para todo $t, s \in T^2$.

Demonstração.

1. Define-se a função $g(t) = E(X_t)$. Note-se que dados $t, s \in T$ tal que $t + s \in T$, as variáveis aleatórias $X_{t+s} - X_s$ e $X_t - X_0$ são identicamente distribuídas. Logo,

$$\begin{aligned}
g(t + s) &= E(X_{t+s}) = E(X_{t+s} - X_s + X_s) \\
&= E(X_{t+s} - X_s) + E(X_s) \\
&= E(X_t - X_0) + E(X_s) \\
&= E(X_t) + E(X_s) \\
&= g(t) + g(s).
\end{aligned}$$

Portanto, g é uma função aditiva. É possível provar que as únicas funções aditivas e limitadas em intervalos limitados são as funções lineares $g(t) = \mu t$ para algum $\mu \in \mathbb{R}$ (ver [1]). Logo, $E(X_t) = \mu t$.

2. Demonstração análoga à anterior.

□

Exercício 54. *Seja $X = \{X_t : t \in T\}$ um processo estocástico com incrementos independentes e estacionários tal que $X_0 = 0$ e $E(X_t^2) < \infty$ para todo $t \in T$. Mostre que existe uma constante positiva σ tal que*

$$\text{Var}(X_t - X_s) = \sigma^2 |t - s|.$$

6.4 Processo de Markov

Um processo de Markov é um processo estocástico em que o futuro é independente do passado quando se conhece o presente.

Definição 6.10. Um processo estocástico $X = \{X_t : t \in T\}$ é um **processo de Markov** se satisfizer a **propriedade de Markov**,

$$P(X_t \in B | X_{t_1}, \dots, X_{t_n}) = P(X_t \in B | X_{t_n}),$$

sempre que $t_1 < t_2 < \dots < t_n < t \in T$ e para todo o Boreliano B de \mathbb{R} .

Observação 6.12. Note-se que $P(X \in B | Y) = P(X^{-1}(B) | \sigma(Y))$ é a probabilidade condicionada do acontecimento $\{X \in B\}$ dado a informação de Y , como foi definida anteriormente.

Exemplo 6.13 (Passeio aleatório é um processo de Markov). Considere-se o passeio aleatório

$$S_n = X_1 + \dots + X_n,$$

onde X_1, X_2, \dots são variáveis aleatórias IID tais que $X_i \in \{-1, 1\}$. Uma vez que

$$S_{n+1} = S_n + X_{n+1},$$

onde X_{n+1} é independente de S_i , $i = 1, \dots, n$ temos que

$$\begin{aligned} P(S_{n+1} = s | S_1 = s_1, \dots, S_n = s_n) &= P(S_n + X_{n+1} = s | S_1 = s_1, \dots, S_n = s_n) \\ &= P(X_{n+1} = s - s_n | S_1 = s_1, \dots, S_n = s_n) \\ &= P(X_{n+1} = s - s_n). \end{aligned}$$

Por outro lado,

$$\begin{aligned} P(S_{n+1} = s | S_n = s_n) &= P(S_n + X_{n+1} = s | S_n = s_n) \\ &= P(X_{n+1} = s - s_n | S_n = s_n) \\ &= P(X_{n+1} = s - s_n). \end{aligned}$$

Logo,

$$P(S_{n+1} = s | S_1 = s_1, \dots, S_n = s_n) = P(S_{n+1} = s | S_n = s_n)$$

de onde se pode verificar com facilidade a propriedade de Markov.

Generalizando o exemplo anterior obtem-se o seguinte resultado.

Proposição 6.14. *Um processo estocástico $X = \{X_t : t \in T\}$ de incrementos independentes com $T = [0, \infty[$ ou $T = \{0, 1, 2, \dots\}$ é um processo de Markov.*

Demonstração. Deixa-se como exercício. \square

Exemplo 6.15. No entanto existem processos não Markovianos, como é o caso do **processo autoregressivo de ordem 2**, designado por AR(2),

$$Y_n = a_1 Y_{n-1} + a_2 Y_{n-2} + X_n,$$

onde X_n é uma sucessão de variáveis IID.

Quando o conjunto de estados do processo de Markov X é finito ou numerável então diz-se que X é uma **cadeia de Markov**. Note-se que dependendo da natureza do conjunto dos parâmetros, uma cadeia de Markov pode ser a **tempo discreto ou contínuo**. Quando o conjunto de estados e dos parâmetros é um intervalo diz-se que X é um **processo de difusão**.

6.5 Processo de Wiener

O processo de Wiener é um processo de difusão usado para modelar o **movimento Browniano**, isto é, o movimento descrito por uma partícula imersa num líquido quando esta colide com as moléculas do líquido. O processo de Wiener é também amplamente utilizado em matemática financeira.

Definição 6.11. Um processo estocástico a tempo contínuo $W = \{W_t : t \in [0, \infty[\}$ diz-se um **processo de Wiener** sse:

1. $W_0 = 0$, P -q.c.
2. as trajectórias $t \mapsto W_t$ são contínuas P -q.c.
3. para quaisquer $0 < t_1 < \dots < t_n$ o vector aleatório $(W_{t_1}, \dots, W_{t_n})$ tem função de densidade conjunta,

$$f_{t_1, \dots, t_n}(x_1, \dots, x_n) = p_{t_1}(x_1) p_{t_2 - t_1}(x_2 - x_1) \cdots p_{t_n - t_{n-1}}(x_n - x_{n-1}),$$

onde

$$p_t(x) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}},$$

é a função de densidade da distribuição Gaussiana.

Exercício 55. Mostre que a função de densidade de W_t é

$$f_t(x) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}},$$

e calcule $E(W_t)$ e $\text{Var}(W_t)$.

Proposição 6.16. Para quaisquer $0 \leq s < t$ o incremento $W_t - W_s$ tem distribuição normal com valor esperado 0 e variância $t - s$.

Demonstração. Segue da terceira condição da definição do processo de Wiener que a função de densidade conjunta de (W_s, W_t) é

$$f_{s,t}(x, y) = p_s(x)p_{t-s}(y - x).$$

Logo,

$$\begin{aligned} P(W_t - W_s \leq z) &= \int_{\{y-x \leq z\}} p_s(x)p_{t-s}(y - x) dx dy \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{z+x} p_s(x)p_{t-s}(y - x) dy dx \\ &= \int_{-\infty}^z \int_{-\infty}^{+\infty} p_s(x)p_{t-s}(y) dx dy \\ &= \int_{-\infty}^z p_{t-s}(y) dy \end{aligned}$$

Logo,

$$f_{t-s}(y) = \frac{1}{\sqrt{2\pi(t-s)}} e^{-\frac{y^2}{2(t-s)}}$$

□

Proposição 6.17. Um processo de Wiener tem incrementos independentes.

Demonstração. Para quaisquer $0 < t_1 < t_2 < \dots < t_n$ queremos mostrar que os incrementos,

$$W_{t_1} - W_0, W_{t_2} - W_{t_1}, \dots, W_{t_n} - W_{t_{n-1}}$$

são independentes. É possível demonstrar que se X_1, \dots, X_n são variáveis aleatórias que seguem uma distribuição normal então são independentes sse não são correlacionadas, ou seja, $\text{Cov}(X_i, X_j) = 0$ para todo $i \neq j$. Portanto, como o valor esperado dos incrementos é nulo, é suficiente mostrar que,

$$E[(W_u - W_t)(W_s - W_r)] = 0, \quad t \leq u \leq r \leq s.$$

Mas para $s \leq t$ temos que,

$$\begin{aligned} E(W_s W_t) &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x y p_s(x) p_{t-s}(y - x) dx dy \\ &= \int_{-\infty}^{+\infty} x p_s(x) \left(\int_{-\infty}^{+\infty} y p_{t-s}(y - x) dy \right) dx \\ &= \int_{-\infty}^{+\infty} x^2 p_s(x) dx = s. \end{aligned}$$

Logo,

$$\begin{aligned} E[(W_u - W_t)(W_s - W_r)] &= E(W_u W_s) - E(W_u W_r) - E(W_t W_s) + E(W_t W_r) \\ &= u - u - t + t = 0 \end{aligned}$$

□

Segue das proposições anteriores que,

Corolário 6.18. *Um processo de Wiener tem incrementos independentes e estacionários.*

Exercício 56. Mostre que um processo de Wiener é estacionário em média, mas não tem covariâncias estacionárias.

Referências

- [1] Robert B. Ash, Catherine A. Doléans-Dade, *Probability and Measure Theory*. Academic Press 2nd Edition, 1999.
- [2] Daniel Müller, *Probabilidade e processos estocásticos: uma abordagem rigorosa com vista aos modelos em finanças*. Coimbra, Almedina, 2011.