

# Processos Estocásticos

Airlane Pereira Alencar

11 de Março de 2019

# Índice

- 1 Definições
- 2 Série Temporal
- 3 Estacionariedade
- 4 Espectro
- 5 Referência

## Def 1:

Seja  $T$  um conjunto arbitrário. Um **processo estocástico** é uma família  $Z = \{Z(t), t \in T\}$  em que  $Z(t)$  é variável aleatória.

## Exemplo

$T = \mathbb{Z}$  e  $Z = \{Z_1, Z_2, \dots\}$

## Def 1:


Seja  $T$  um conjunto arbitrário. Um **processo estocástico** é uma família  $Z = \{Z(t), t \in T\}$  em que  $Z(t)$  é variável aleatória.

## Exemplo

$$T = \mathbb{Z} \text{ e } Z = \{Z_1, Z_2, \dots\}$$

# Família de variáveis aleatórias

Figura 1: Cada variável  $Z(t)$  é definida em  $(\omega, A, P)$  - Morettin e Tolo



Para cada  $\omega \in \Omega$  (espaço amostral) fixado, temos uma **série temporal**.

Uma série temporal é uma particular realização do processo estocástico.

Podemos entender um processo estocástico como uma família de trajetórias ao longo do tempo e observamos uma delas.

Em geral, vamos considerar um conjunto discreto de tempos:  $t_1, t_2, \dots$

# Definições: Caracterização do processo

## Def 2:

A função distribuição n-dimensional do processo estocástico  $Z = \{Z(t), t \in T\}$  é definido como

$$F(z_1, \dots, z_n; t_1, \dots, t_n) = P(Z(t_1) \leq z_1, \dots, Z(t_n) \leq z_n).$$

A partir das funções distribuição finito dimensionais, podemos obter os momentos produtos de ordem  $(r_1, \dots, r_n)$ , ou seja,

$$\begin{aligned} \mu(r_1, \dots, r_n; t_1, \dots, t_n) &= E(Z_1^{r_1} \dots Z_n^{r_n}) \\ &= \int \dots \int z_1^{r_1} \dots z_n^{r_n} f(z_1, \dots, z_n; t_1, \dots, t_n) dz_1 \dots dz_n \end{aligned}$$

## Precisaremos dos momentos: Média, Autocovariância, Variância

$$\begin{aligned}\mu_t &= E(Z_t) \\ &= \int z_t f(z_t) dz_t.\end{aligned}$$

$$\text{Cov}(Z_{t_1}, Z_{t_2}) = \gamma(t_1, t_2) = E(Z_{t_1} Z_{t_2}) - E(Z_{t_1})E(Z_{t_2}), t_1, t_2 \in T.$$

$$\text{Var}(Z_t) = \gamma(t, t) = E(Z_t^2) - [E(Z_t)]^2, t \in T.$$

e calcularemos a correlação

$$\text{Corr}(Z_{t_1}, Z_{t_2}) = \rho(t_1, t_2) = \frac{\text{Cov}(Z_{t_1}, Z_{t_2})}{\sqrt{\text{Var}(Z_{t_1}) \text{Var}(Z_{t_2})}}, t_1, t_2 \in T.$$

Se todos esses momentos variam ao longo do tempo, como



# Estacionariedade

## Def 3:

Um processo estocástico  $Z = \{Z(t), t \in T\}$  é dito **estritamente estacionário** se todas as distribuições finito dimensionais permanecem as mesmas sob translações no tempo, ou seja,

$$F(z_1, \dots, z_n; t_1 + \tau, \dots, t_n + \tau) = F(z_1, \dots, z_n; t_1, \dots, t_n),$$

para  $t_1, \dots, t_n, t_1 + \tau, \dots, t_n + \tau \in T$ .

Por exemplo,  $P(Z_1 \leq z_1, Z_2 \leq z_2) = P(Z_{11} \leq z_1, Z_{12} \leq z_2)$ .

Assim, todos os momentos são constantes.

# Estacionariedade

## Def 4:

Um processo estocástico  $Z$  é dito **fracamente estacionário** ou **estacionário de segunda ordem** se

- $E(Z_t) = \mu, \forall t \in T$ ;
- $E(Z_t^2) < \infty, \forall t \in T$ ;
- $Cov(Z_{t_1}, Z_{t_2}) = g(|t_1 - t_2|)$ , ou seja, a covariância é função somente de  $|t_1 - t_2|$ .

Notação:  $\gamma(k)$ , para  $k = |t_1 - t_2|$ .

## Observações

- $Z$  pode ser estritamente estacionário mas só será fracamente estacionário se valer (2).
- Um processo  $Z$  tal que valha (2) é dito processo de segunda ordem

# Estacionariedade

## Def 4:

Um processo estocástico  $Z$  é dito **fracamente estacionário** ou **estacionário de segunda ordem** se

- $E(Z_t) = \mu, \forall t \in T$ ;
- $E(Z_t^2) < \infty, \forall t \in T$ ;
- $Cov(Z_{t_1}, Z_{t_2}) = g(|t_1 - t_2|)$ , ou seja, a covariância é função somente de  $|t_1 - t_2|$ .

Notação:  $\gamma(k)$ , para  $k = |t_1 - t_2|$ .

## Observações

- $Z$  pode ser estritamente estacionário mas só será fracamente estacionário se valer (2).
- Um processo  $Z$  tal que valha (2) é dito processo de segunda ordem.

# Exemplos

## Exemplo 1

$Z = \{Z_t, t \in T\}$  com  $Z_t$  variáveis aleatórias com

$$\begin{aligned} E(Z_t) &= 0, \forall t \in T, \\ \text{Var}(Z_t) &= \sigma^2 (< \infty) \forall t \in T, \end{aligned}$$

e  $Z_t$  são não correlacionados.

$Z$  é fracamente estacionário? E estritamente estacionário?

## Observação:

O processo com média zero, variância constante e não correlacionado é chamado de **Ruído Branco**.

## Exemplo 2

### Exemplo

$W_t = \frac{1}{3}(Z_{t-1} + Z_t + Z_{t+1})$  com  $Z_t$  definido no exemplo anterior.  
 $W_t$  é fracamente estacionário?

$$E(W_t) = 0$$

$$\gamma_h = \begin{cases} \frac{3\sigma^2}{9}, & |h| = 0 \\ \frac{2\sigma^2}{9}, & |h| = 1 \\ \frac{\sigma^2}{9}, & |h| = 2 \\ 0, & |h| > 2 \end{cases}$$

## Exemplo 3 - Passeio Aleatório

### Passeio Aleatório

Considere  $\{e_t, t \geq 1\}$  variáveis aleatórias iid com média  $\mu_e$  e variância  $\sigma_e^2$ , com  $\sigma_e^2 < \infty$ .

O processo  $X = (X_t)$  é tal que

$X_t = X_{t-1} + e_t$  com  $X_0 = 0$ . O processo  $X$  é fracamente estacionário?

# Processo Gaussiano

## Def

Um processo  $Z = \{Z(t), t \in T\}$  diz-se gaussiano se para qualquer subconjunto  $t_1, \dots, t_n$  de  $T$ , as variáveis aleatórias  $Z_{t_1}, \dots, Z_{t_n}$  têm distribuição normal n-variada.

# Propriedades da Função de Autocovariância

Seja  $X = \{X(t), t \in Z\}$  um processo estacionário real com tempo discreto com função de autocovariância denotada como

$$\gamma_\tau = \text{Cov}(X_t, X_{t+\tau}).$$

- $\gamma_0 > 0$ ;
- $\gamma_{-\tau} = \gamma_\tau$ ;
- $|\gamma_\tau| \leq \gamma_0$ ;
- $\gamma_\tau$  é não negativa definida no sentido que  $\forall a_j, a_k$

$$\sum_{j=1}^n \sum_{k=1}^n a_j a_k \gamma_{\tau_j - \tau_k} \geq 0.$$



# Propriedades da Função de Autocovariância

## Observação

- A função de autocorrelação do processo estocástico  $X = \{X(t), t \in Z\}$  é

$$\rho_\tau = \frac{\gamma_\tau}{\sqrt{\gamma_0}\sqrt{\gamma_0}} = \frac{\gamma_\tau}{\gamma_0}$$

$\hat{\rho}_\tau$  vai auxiliar a propormos modelos.

- Um exemplo de processo estocástico contínuo (tempo contínuo) é o movimento Browniano (MT p.33);
- A função de autocorrelação de um processo estocástico estacionário decai para 0;

# Estimação

$X = \{X(t), t \in Z\}$  processo estacionário

$$\hat{\mu} = \bar{X}$$

$$E(\bar{X}) = E\left(\frac{1}{N} \sum_{t=1}^N X_t\right) = \mu$$

$$\begin{aligned} \text{Var}(\bar{X}) &= \frac{1}{N^2} \text{Var}\left(\sum_{t=1}^N X_t\right) = \frac{1}{N^2} \sum_{t=1}^N \sum_{s=1}^N \text{Cov}(X_t, X_s) \\ &= \frac{1}{N^2} \sum_{k=-(N-1)}^{N-1} (N - |k|) \gamma_k = \frac{1}{N} \sum_{k=-(N-1)}^{N-1} \left(1 - \frac{|k|}{N}\right) \rho_k \\ &\xrightarrow{N \rightarrow \infty} 0 \end{aligned}$$

Para estacionário  $\sum_{k=-(N-1)}^{N-1} \left(1 - \frac{|k|}{N}\right) \rho_k$  é finita pois  $\rho_k \rightarrow 0$ .

# Estimação

$X = \{X(t), t \in Z\}$  processo estacionário !

- O estimador da função de autocovariância ( $\gamma_j$ ) é

$$\hat{\gamma}_j = c_j = \frac{1}{N} \sum_{t=1}^{N-j} [(X_t - \bar{X})(X_{t+j} - \bar{X})], \quad j = 0, 1, \dots, N-1.$$

- Estimador da função de autocorrelação  $\rho_j = \text{Corr}(X_t, X_{t+j}) = \frac{\gamma_j}{\gamma_0}$  é

$$\hat{\rho}_j = r_j = \frac{\hat{\gamma}_j}{\hat{\gamma}_0}, \quad j = 0, 1, \dots, N-1.$$

- No programa R: `acf( )`.

# Estimação

$X = \{X(t), t \in Z\}$  processo estacionário

Poderíamos considerar outro estimador para a covariância:

$$\hat{\gamma}_j = \frac{1}{N-j} \sum_{t=1}^{N-j} [(X_t - \bar{X})(X_{t+j} - \bar{X})], \quad j = 0, 1, \dots, N-1.$$

Esse estimador pode ter um viés um pouco menor, mas esse não é função não negativa definida como é  $\hat{\gamma}_j$ , logo esse último deve ser utilizado (Wei).

# Estimação

$X = \{X(t), t \in Z\}$  processo **Ruído Branco**

Para  $N$  grande,  $\hat{\rho}_j$  tem distribuição normal com média  $\rho_j$  e variância

$$\text{Var}(\hat{\rho}_j) = \frac{1}{N}.$$

Assim, podemos usar esse resultado para construir intervalos para verificar para cada lag  $j$ , se  $\rho_j = 0$  ou não.

Cada intervalo é  $0 \mp 1.96\sqrt{1/N}$  e se  $\hat{\rho}_j$  está fora do intervalo, então  $\rho_j$  é significativo.

Vide Property P1.1 p.30. e Teorema A.7 - Apêndice A de Shumway and Stoffer.

# Assimetria e Curtose

$X = \{X(t), t \in Z\}$  processo estacionário

- Coeficiente de Assimetria:  $A(X) = E\left(\frac{(X-\mu)^3}{\sigma^3}\right)$

$$\hat{A} = \frac{1}{(N-1)\hat{\sigma}^3} \sum_{t=1}^N (X_t - \bar{X})^3;$$

- Curtose de X:  $K(X) = E\left(\frac{(X-\mu)^4}{\sigma^4}\right)$

$$\hat{K} = \frac{1}{(N-1)\hat{\sigma}^4} \sum_{t=1}^N (X_t - \bar{X})^4;$$

- Se tivermos um processo estacionário gaussiano e N for grande, então

$$\hat{A} \sim N(0, 6/N) \text{ e } \hat{K} \sim N(3, 24/N)$$

- Estudar o teste Jarque-Bera apresentado no Apêndice D de Morettin e Toloí (2006).

# Espectro

O espectro também caracteriza o processo estacionário, como a FAC. Para  $X = \{X(t), t \in \mathbb{Z}\}$ , processo estacionário, suponha que valha:

$$\int_{-\infty}^{\infty} |\gamma(\tau)| d\tau < \infty$$

Então, o **espectro** ou **f. densidade espectral** é a TF da FAC

$$f(\lambda) = \frac{1}{2\pi} \sum_{-\infty}^{\infty} \gamma_k e^{-i\lambda k}, \quad -\pi < \lambda < \pi$$

A transformada inversa é

$$\gamma_k = \int_{-\pi}^{\pi} f(\lambda) e^{+i\lambda k} d\lambda, \quad k = 0, 1, \dots$$

Para  $\tau = 0$ , temos a decomposição da variância

$$\gamma(0) = \int_{-\pi}^{\pi} f(\lambda) d\lambda$$

# Propriedades da densidade espectral

## Teorema 1

O espectro  $f(\lambda) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \gamma_k e^{-i\lambda k}$ , é limitado, não negativo, uniformemente contínuo, par e periódico de período  $2\pi$ .

- $|f(\lambda)| = \frac{1}{2\pi} |\sum \gamma_k e^{i\lambda k}| \leq \frac{1}{2\pi} \sum |\gamma_k| < \infty$ ;
- Não negativo, só quando mostrarmos que a esperança do periodograma (não negativo) converge para  $f(\lambda)$ ;
- Uniformemente contínuo

$$|f(\lambda + \omega) - f(\lambda)| \leq \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} |e^{-i(\lambda+\omega)k} - e^{-i\lambda k}| |\gamma_k| = \frac{1}{2} \sum_{k=-\infty}^{\infty} |e^{-i\lambda k}| |e^{-i\omega k} - 1| |\gamma_k| \xrightarrow{\omega \rightarrow 0} 0$$



# Propriedades do Espectro

$$f(\lambda) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \gamma_k e^{-i\lambda k}$$

- $\gamma_k = \gamma_{-k}$  (estac) e para  $u = -k$ :

$$f(\lambda) = \frac{1}{2\pi} \sum_{u=-\infty}^{\infty} \gamma_u e^{+iuk} = f(-\lambda)$$

- $f(\lambda)$  tem período  $2\pi$ , pois  $e^{-i\lambda k} = \cos(\lambda k) - i\text{sen}(\lambda k)$  tb tem.

Para  $t = \mathbb{R}$

$$f(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \gamma(\tau) e^{-i\lambda\tau} d\tau$$

$f(\lambda)$  tem as mesmas propriedades, exceto que não tem período  $2\pi$ .

# Exemplos

- $X_t$  é RB, então  $f(\lambda) = \frac{\gamma_0}{2\pi}$
- $W_t = \frac{1}{3}(Z_{t-1} + Z_t + Z_{t+1})$  com  $Z_t \sim RB$

$$\gamma_h = \begin{cases} \frac{3\sigma^2}{9}, & |h| = 0 \\ \frac{2\sigma^2}{9}, & |h| = 1 \\ \frac{\sigma^2}{9}, & |h| = 2 \\ 0, & |h| > 2 \end{cases}$$


$$e^{-i\lambda k} + e^{i\lambda k} = 2\cos(\lambda k)$$

$$\begin{aligned} f(\lambda) &= \frac{1}{2\pi} \sum_{-\infty}^{\infty} \gamma_k e^{-i\lambda k} = \frac{1}{2\pi} \left[ \frac{3\sigma^2}{9} + \frac{2\sigma^2}{9} 2\cos(\lambda) + \frac{\sigma^2}{9} 2\cos(2\lambda) \right] \\ &= \frac{1}{2\pi} \frac{\sigma^2}{9} [3 + 4\cos(\lambda) + 2\cos(2\lambda)] \end{aligned}$$

# Exemplos

- $W_t = \frac{1}{3}(Z_{t-1} + Z_t + Z_{t+1})$  com  $Z_t \sim RB$

$$\begin{aligned}
 f(\lambda) &= \frac{1}{2\pi} \sum_{-\infty}^{\infty} \gamma_k e^{-i\lambda k} = \frac{1}{2\pi} \left[ \frac{3\sigma^2}{9} + \frac{2\sigma^2}{9} 2 \cos(\lambda) + \frac{\sigma^2}{9} 2 \cos(2\lambda) \right] \\
 &= \frac{1}{2\pi} \frac{\sigma^2}{9} [3 + 4 \cos(\lambda) + 2 \cos(2\lambda)]
 \end{aligned}$$



curve((1/9)\*(1/(2\*pi))\*(3+4\*cos(x)+2\*cos(2\*x)), 0, pi)

## Correlação entre 2 Processos

De modo análogo ao coeficiente de correlação entre 2 variáveis aleatórias, podemos estudar a correlação entre duas séries (estacionárias).

### Def

A função de **covariância cruzada** de  $\{X(t), t \in Z\}$  e  $\{Y(t), t \in Z\}$  é dada por

$$\gamma_{XY}(s, t) = E[(X_s - E(X_s))(Y_t - E(Y_t))].$$

É importante estudar a relação linear entre séries somente se ambas forem estacionárias.

Leiam sobre correlação espúria.

## Função de Correlação Cruzada

Os processos  $X_t$  e  $Y_t$  estacionários são conjuntamente estacionárias se a covariância cruzada depende apenas de  $h = |t - s|$ , ou seja,

$$\gamma_{XY}(s, t) = \gamma(h).$$

Note que  $\gamma_{XY}(h)$  não precisa ser simétrica:

$$\begin{aligned}\gamma_{XY}(h) &= E[(X_{t+h} - E(X_{t+h}))(Y_t - E(Y_t))] \\ &= E[(Y_{t-h} - E(Y_{t-h}))(X_t - E(X_t))] = \gamma_{YX}(-h).\end{aligned}$$

A partir da função de covariância cruzada calculamos a função de correlação cruzada.

# Função de Correlação Cruzada

## Estimadores

$$\hat{\gamma}_{XY}(h) = \frac{1}{n} \sum_{t=1}^{n-h} (x_{t+h} - \bar{x})(y_t - \bar{y}), \quad \hat{\gamma}_{XY}(-h) = \hat{\gamma}_{YX}(h)$$

$$\hat{\rho}_{XY}(h) = \frac{\hat{\gamma}_{XY}(h)}{\sqrt{\hat{\gamma}_X(0)\hat{\gamma}_Y(0)}}$$

Para  $N$  grande e sob independência,  $\hat{\rho}_{XY}(h)$  tem dist. normal com média 0 e variância  $1/N$ , se algum dos processos é ruído branco independente (Teo A.8 - SS).

# Referências

## All Time series analysis

- Morettin e Tolo
- Shumway and Stoffer
- Wei