

MAE 5871: Análise Espectral de Séries Temporais

Pedro A. Morettin

Instituto de Matemática e Estatística
Universidade de São Paulo
pam@ime.usp.br
<http://www.ime.usp.br/~pam>

Aula 3

26 de agosto de 2021

Sumário

- 1 Processos estacionários
- 2 Função de autocovariância
- 3 Processos estocásticos complexos
- 4 Exemplos de processos estocásticos

Definições

1. No caso de processos estocásticos, uma suposição normalmente feita é a de estacionariedade. Intuitivamente, um processo estocástico $\{X(t), t \in \mathcal{T}\}$ é estacionário se ele se desenvolve no tempo, de modo que a escolha de uma origem dos tempos não seja importante. Em outras palavras, as características probabilísticas de $X(t + \tau)$, para todo $\tau \in \mathcal{T}$, são as mesmas de $X(t)$.
2. Duas formas de estacionariedade: fraca (ou ampla ou, ainda, de segunda ordem) e forte (ou estrita).
3. Um processo estocástico $\{X(t), t \in \mathcal{T}\}$ diz-se **estritamente estacionário** se todas as suas distribuições finito dimensionais permanecem as mesmas sob translações do tempo, ou seja,

$$F(x_1, \dots, x_n; t_1 + \tau, \dots, t_n + \tau) = F(x_1, \dots, x_n; t_1, \dots, t_n), \quad (1)$$

para quaisquer t_1, \dots, t_n, τ de \mathcal{T} .

Definições

1. Isto significa, em particular, que todas as distribuições unidimensionais são invariantes sob translações do tempo; supondo-se que momentos de primeira e segunda ordem existam, a média $\mu(t)$ e a variância $\sigma^2(t)$ são constantes, isto é,

$$E\{X(t)\} = \mu(t) = \mu, \quad \text{para todo } t \in \mathcal{T}, \quad (2)$$

$$\text{Var}\{X(t)\} = \sigma^2(t) = \sigma^2, \quad \text{para todo } t \in \mathcal{T}. \quad (3)$$

2. Do mesmo modo, todas as distribuições bidimensionais dependem de diferenças de tempos. De fato, para $t_1, t_2 \in \mathcal{T}$, $\gamma(t_1, t_2) = \gamma(t_1 + t, t_2 + t)$ e fazendo $t = -t_2$, temos que

$$\gamma(t_1, t_2) = \gamma(t_1 - t_2, 0) = \text{Cov}\{X(t_1 - t_2), X(0)\}. \quad (4)$$

3. Na realidade, a covariância (4) é uma função de $|t_1 - t_2|$ e para isso basta fazer $t = -t_1$ acima.

Segue-se que podemos escrever a **função de autocovariância** de um processo estacionário forte ou estrito como

$$\gamma(\tau) = \text{Cov}\{X(t), X(t + \tau)\} = \text{Cov}\{X(0), X(\tau)\} \quad (5)$$

para $t, \tau \in \mathcal{T}$.

Definições

1. Genericamente, de (1), segue-se que os momentos de ordem n de $X(t)$, se existirem, dependem apenas das diferenças $t_j - t_1$, e são funções de $n - 1$ argumentos.
2. É possível que momentos não existam, por exemplo, o caso de um processo de Cauchy, em que a média e variância não são finitas.
3. Como dissemos anteriormente, estaremos interessados em caracterizar os processos estocásticos por um número pequeno de funções de distribuição ou de momentos. Se nos restringirmos a momentos de primeira e segunda ordens, somos levados à seguinte definição:
4. Um processo estocástico $\{X(t), t \in \mathcal{T}\}$ diz-se **fracamente estacionário** (ou estacionário de segunda ordem) se e somente se

i) $E\{X(t)\} = \mu(t) = \mu$, constante, para todo $t \in \mathcal{T}$;

ii) $E\{X^2(t)\} < \infty$, para todo $t \in \mathcal{T}$;

iii) $\gamma(t_1, t_2) = Cov\{X(t_1), X(t_2)\}$ é uma função apenas de $|t_1 - t_2|$.

Definições

1. A partir de agora, estaremos interessados principalmente nessa classe de processos, que denominaremos simplesmente de **processos estacionários**.
2. Note-se que, se $X(t)$ for estritamente estacionário, ele não necessita ser fracamente estacionário, pois a condição (ii) da definição 2.2 pode não estar satisfeita. Um processo tal que (ii) esteja satisfeita diz-se um **processo de segunda ordem**.
3. Um processo estocástico real $\{X(t), t \in \mathcal{T}\}$ diz-se **gaussiano** se, para qualquer conjunto t_1, \dots, t_n de \mathcal{T} , as v.a. $X(t_1), X(t_2), \dots, X(t_n)$ têm uma distribuição normal n -variada.
4. Como um processo gaussiano, com variância finita, é determinado pelas médias e covariâncias, se ele for estacionário de segunda ordem, então será estritamente estacionário.

Definições

1. No que segue usaremos a seguinte notação:
se o parâmetro t (tempo) for discreto, isto é, $t \in \mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$, o processo será escrito $\{X_t, t \in \mathbb{Z}\}$, ao passo que se t for contínuo, isto é, $t \in \mathbb{R}$, o processo será indicado por $\{X(t), t \in \mathbb{R}\}$.
2. A mesma convenção aplica-se aos momentos. Por exemplo, a função de autocovariância de um processo estacionário com tempo discreto será denotada por γ_τ , ao passo que a de um processo com tempo contínuo será denotada por $\gamma(\tau)$.

Propriedades da facv

1. Seja $\{X_t, t \in \mathbb{Z}\}$ um processo estacionário real, com tempo discreto, de média zero e função de autocovariância (facv) $\gamma_\tau = E\{X_t X_{t+\tau}\}$.
2. **Proposição 1.** A facv γ_τ satisfaz as seguintes propriedades:

- i) $\gamma_0 > 0$,
- ii) $\gamma_{-\tau} = \gamma_\tau$,
- iii) $|\gamma_\tau| \leq \gamma_0$,
- iv) γ_τ é não negativa definida, no sentido em que

$$\sum_{j=1}^n \sum_{k=1}^n a_j a_k \gamma_{\tau_j - \tau_k} \geq 0, \quad (6)$$

para quaisquer números reais a_1, \dots, a_n , e τ_1, \dots, τ_n de \mathbb{Z} .

3. A prova é fácil; ver o texto. Tipicamente, a facv de um processo estacionário tende a zero, para $|\tau| \rightarrow \infty$. Veja a Figura 1.




Figura 1: Comportamento típico da função de autocovariância de um processo estacionário.

Função de autocorrelação

A **função de autocorrelação** (f.a.c.) do processo é definida por

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0}, \quad \tau \in \mathbb{Z}, \quad (7)$$

e tem as propriedades de γ_τ , sendo que $\rho_0 = 1$.

Continuidade da facv

1. A continuidade de um processo estocástico tem que ser definida de maneira apropriada.
2. Seja $\{X(t), t \in \mathbb{R}\}$ um processo de segunda ordem. Dizemos que $X(t)$ é **contínuo em média quadrática no ponto t_0** se e somente se

$$\lim_{t \rightarrow t_0} E\{|X(t) - X(t_0)|^2\} = 0. \quad (8)$$

Escreveremos $X(t) \rightarrow X(t_0)$ m.q ou $X(t) \xrightarrow{m,q} X(t_0)$.

3. A continuidade em m.q. de $X(t)$ está relacionada com a continuidade da f.a.c.v. $\gamma(\tau)$.

Continuidade da facv

1. **Proposição 2.** A continuidade de $\gamma(\tau)$ para $\tau = 0$ implica a continuidade de $\gamma(\tau)$ para todo τ .

Prova: Usando a desigualdade de Schwarz para duas v.a., temos

$$|E\{[X(\tau + h) - X(\tau)][X(0)]\}|^2 \leq E\{|X(\tau + h) - X(\tau)|^2\}E\{|X(0)|^2\},$$

que desenvolvida resulta

$$|\gamma(\tau + h) - \gamma(\tau)|^2 \leq 2\gamma(0)[\gamma(0) - \gamma(h)]$$

e se $\gamma(\tau)$ for contínua na origem vem que, para $h \rightarrow 0$, o primeiro termo tende a zero e $\gamma(\tau)$ é contínua para todo τ . \square

Continuidade da facv

1. **Proposição 4.** Se $\gamma(\tau)$ for contínua, então $X(t)$ é contínuo em média quadrática.
2. Prova: Temos que

$$E\{|X(t+h) - X(t)|^2\} = 2\gamma(0) - 2\gamma(h)$$

e, para $h \rightarrow 0$, obtemos o resultado. □

3. A continuidade de um processo em m.q. não implica que as trajetórias do processo sejam contínuas. Um exemplo ocorre com o processo de Poisson.

Ergodicidade

1. Um conceito importante, mas difícil, é o de **ergodicidade**. Esperamos que, se a série temporal for suficientemente longa, a média amostral seja uma boa aproximação da média no *ensemble*, o mesmo valendo para outros parâmetros.
2. Formalmente, dizemos que X_t é **ergódico com respeito à média** $\mu = E\{X_t\}$ se

$$\frac{1}{m} \sum_{t=1}^m X(t, \omega) \xrightarrow{m.g.} \mu,$$

quando $m \rightarrow \infty$.

3. Ainda, X_t é **ergódico com respeito à autocovariância** γ_τ se

$$\frac{1}{m - \tau} \sum_{t=1}^{m-\tau} X(t, \omega) X(t + \tau, \omega) \xrightarrow{m.g.} \gamma_\tau,$$

quando $m \rightarrow \infty$.

ergodicidade

1. **Proposição 5.** O processo $\{X_t, t \in \mathbb{Z}\}$ é ergódico com respeito à média μ se e somente se

$$\lim_{m \rightarrow \infty} \frac{1}{m+1} \sum_{\tau=0}^m \gamma_{\tau} = 0.$$

2. Uma condição suficiente para que X_t seja ergódico com respeito a μ é

$$\lim_{\tau \rightarrow \infty} \gamma_{\tau} = 0,$$

e isso é satisfeito se as v.a.'s do processo separadas por τ são não correlacionadas, quando τ cresce.

3. Sejam t e τ_0 fixos e defina

$$\gamma_1(\tau) = E\{[X_{t+\tau_0+\tau} X_{t+\tau} - \gamma_{\tau_0}][X_{t+\tau_0} X_t - \gamma_{\tau_0}]\}.$$

Se X_t for estritamente ou fracamente estacionário, $\gamma_1(\tau)$ não depende de t . Então, temos o resultado seguinte.

Ergodicidade

1. **Proposição 6.** *O processo $\{X_t, t \in \mathbb{Z}\}$ é ergódico com respeito a γ_τ se e somente se*

$$\lim_{m \rightarrow \infty} \frac{1}{m+1} \sum_{\tau=0}^m \gamma_1(\tau) = 0.$$

2. Uma condição suficiente para que X_t seja ergódico com respeito a γ_τ é que

$$\lim_{\tau \rightarrow \infty} \gamma_1(\tau) = 0.$$

3. Também nesse caso, essa condição estará satisfeita se valores do processo suficientemente separados no tempo forem não correlacionados.

Processos complexos

1. Em algumas situações é conveniente considerar processos estocásticos complexos, isto é, temos uma família $\{X(t), t \in \mathcal{T}\}$, onde para cada $t \in \mathcal{T}$, $X(t)$ é uma v.a. complexa. Ou seja, podemos escrever

$$X(t) = Y(t) + iZ(t),$$

em que $Y(t)$ e $Z(t)$ são processos estocásticos reais.

2. Nesse caso, $X(t)$ estará especificado se conhecermos as funções de distribuição das $2n$ v.a.'s reais $Y(t_1), \dots, Y(t_n), Z(t_1), \dots, Z(t_n)$, para qualquer conjunto de instantes de tempo t_1, \dots, t_n de \mathcal{T} .
3. Definimos a média de $X(t)$ por

$$E\{X(t)\} = E\{Y(t)\} + iE\{Z(t)\}, \quad (9)$$

e a variância por

$$\text{Var}\{X(t)\} = E\{|X(t) - E\{X(t)\}|^2\}. \quad (10)$$

Vemos, pois, que a média é um número complexo, mas a variância é um número real.

Processos complexos

1. A f.a.c.v. de $X(t)$ é definida por

$$\gamma(t_1, t_2) = E\{[X(t_1) - E\{X(t_1)\}][\overline{X(t_2) - E\{X(t_2)\}}]\}, \quad (11)$$

para $t_1, t_2 \in \mathcal{T}$.

2. Se o processo complexo $X(t)$ for estacionário, então (9) e (10) serão constantes (a primeira complexa e a segunda real), e a f.a.c.v. (11) dependerá apenas de $|t_1 - t_2|$, de modo que podemos escrever

$$\gamma(\tau) = E\{X(t + \tau)\overline{X(t)}\}, \quad (12)$$

supondo a média zero. As propriedades de $\gamma(\tau)$, dadas pela Proposição 1, no caso real, são facilmente adaptadas para o caso complexo.

Sequência aleatória

1. Consideremos $\{X_n, n = 1, 2, \dots\}$ uma sequência de v.a. definidas no mesmo espaço amostral Ω . Aqui, $\mathcal{T} = \{1, 2, \dots\}$, e temos um processo com parâmetro discreto, ou uma **sequência aleatória**. Para todo $n \geq 1$, podemos escrever

$$P\{X_1 = a_1, \dots, X_n = a_n\} = \quad (13)$$

$$= P\{X_1 = a_1\}P\{X_2 = a_2|X_1 = a_1\} \dots P\{X_n = a_n|X_1 = a_1, \dots, X_{n-1} = a_{n-1}\}. \quad (14)$$

2. Em (14), os a_j s representam estados do processo, e o espaço dos estados pode ser tomado como o conjunto dos reais. O caso mais simples é aquele em que temos uma sequência $\{X_n, n \geq 1\}$ de v.a. **mutuamente independentes** e, nesse caso, (14) fica

$$P\{X_1 = a_1, \dots, X_n = a_n\} = P\{X_1 = a_1\} \dots P\{X_n = a_n\}. \quad (15)$$

Ruído branco

1. Se as v.a. X_1, X_2, \dots tiverem todas a mesma distribuição, teremos, então, uma sequência de v.a. independentes e identicamente distribuídas (**i.i.d.**). Nesse caso, o processo X_n é estacionário. Se $E\{X_n\} = \mu$, $\text{Var}\{X_n\} = \sigma^2$, para todo $n \geq 1$, então

$$\gamma_\tau = \text{Cov}\{X_n, X_{n+\tau}\} = \begin{cases} \sigma^2, & \text{se } \tau = 0, \\ 0, & \text{se } \tau \neq 0. \end{cases} \quad (16)$$

2. Segue-se que $\rho_\tau = 1$, para $\tau = 0$, e $\rho_\tau = 0$, caso contrário.

Ruído branco

1. Dizemos que $\{\varepsilon_t, t \in \mathbb{Z}\}$ é **um ruído branco com tempo discreto** se as v.a. ε_t têm média zero, variância σ^2 e são não correlacionadas, isto é, $\text{Cov}\{\varepsilon_t, \varepsilon_s\} = 0, t \neq s$.
 2. Esse processo é estacionário e a f.a.c.v. de ε_t é dada por (16), com $\sigma^2 = \sigma_\varepsilon^2$.
 3. Obviamente, se as v.a. ε_t são independentes, elas também serão não correlacionadas. Uma sequência de v.a. *i.i.d.*, como definida acima, é chamada **processo puramente aleatório**.
- Notação:

$$\varepsilon_t \sim RB(0, \sigma_\varepsilon^2).$$

Passeio Aleatório

1. Considere uma sequência aleatória $\{\varepsilon_t, t \geq 1\}$, de v.a. i.i.d. $(\mu_\varepsilon, \sigma_\varepsilon^2)$. Defina a sequência

$$X_t = \varepsilon_1 + \dots + \varepsilon_t. \quad (17)$$

2. Segue-se que $E(X_t) = t\mu_\varepsilon$ e $Var(X_t) = t\sigma_\varepsilon^2$, ou seja, ambas dependem de t .
3. Não é difícil mostrar que

$$\gamma_X(t_1, t_2) = \sigma_\varepsilon^2 \min(t_1, t_2)$$

e, portanto, a autocovariância de X_t depende de t_1 e t_2 .

4. O processo (17) é chamado **passeio aleatório**, e à medida que o tempo passa, X_t tende a oscilar ao redor de $t\mu_\varepsilon$ com amplitude crescente. O processo é claramente não estacionário.
5. Observe que $X_t = X_{t-1} + \varepsilon_t$; logo, dado o valor de X_{t-1} , o valor de X_t dependerá apenas de ε_t . Como $\varepsilon_t = X_t - X_{t-1}$, esse processo apresenta **incrementos independentes**.

Processo de Poisson

1. Suponha que estejamos interessados no número de eventos de certo tipo que ocorrem num intervalo de tempo $(0, t]$. Por exemplo, podemos contar o número de chamadas telefônicas que chegam a uma central de atendimentos nesse intervalo, ou o número de partículas radioativas registradas por um contador Geiger etc. O intervalo $(0, t]$ não necessita ser um intervalo de tempo. Podemos estar interessados no número de defeitos de um fio a cada 100 m, ou no número de acidentes em um trecho de uma rodovia.
2. Denotando por $\{N(t), t \geq 0\}$ o número de eventos em $(0, t]$, dizemos que esse é um **processo de Poisson com intensidade λ** se as condições seguintes forem satisfeitas:

(i) $N(0) = 0$;

(ii) para todas as escolhas de $t_0 < t_1 < \dots < t_n$ em $(0, \infty)$, as v.a.'s $N(t_1) - N(t_0), \dots, N(t_n) - N(t_{n-1})$ são independentes;

(iii) para qualquer escolha de t_1, t_2 e τ positivos, as v.a.'s $N(t_2 + \tau) - N(t_1 + \tau)$ e $N(t_2) - N(t_1)$ têm a mesma distribuição;

(iv) para todos s, t , $s < t$, a v.a. $N(t) - N(s)$ tem uma distribuição de Poisson com média $\lambda(t - s)$, ou seja,

$$P\{N(t) - N(s) = k\} = \frac{e^{-\lambda(t-s)}[\lambda(t-s)]^k}{k!}, \quad (18)$$

para $k = 0, 1, 2, \dots$

Processo de Poisson

Segue-se que $E\{N(t) - N(s)\} = \text{Var}\{N(t) - N(s)\} = \lambda(t - s)$. O parâmetro λ dá a taxa de ocorrência de eventos por unidade de tempo (ou outra medida). A Figura 2 ilustra uma trajetória típica de um processo de Poisson, que não é estacionário, mas tem *incrementos independentes e estacionários*. Temos que $\mu(t) = V(t) = \lambda t$ e $\gamma(t_1, t_2) = \lambda(t_1 \wedge t_2)$, com $t_1 \wedge t_2$ representando o mínimo entre t_1 e t_2 .




Figura 2. Trajetória típica de um processo de Poisson.

Processo de Wiener

1. O movimento de uma partícula imersa num líquido foi analisada pelo botânico inglês Robert Brown, em 1827. O fenômeno foi estudado por A. Einstein em 1905 e depois por N. Wiener e P. Lévy. Outros nomes usados para esse processo são **Movimento Browniano** e **processo de Wiener-Lévy**.
2. Seja $\{X(t), t \geq 0\}$ a posição da partícula após t unidades de tempo. O processo diz-se um **processo de Wiener** se:
 - (i) $X(0) = 0$;
 - (ii) para todo $t > 0$, $X(t) \sim N(0, t)$;
 - (iii) o processo tem incrementos estacionários e independentes, no sentido de (ii) e (iii) do exemplo anterior

Processo de Wiener

1. Para esse processo, $\mu(t) = 0$ e deixamos a cargo do leitor provar que $\gamma(t_1, t_2) = t_1 \wedge t_2$.
2. Também, o processo é gaussiano. De fato, como

$$\begin{bmatrix} X(t_1) \\ X(t_2) \\ \vdots \\ X(t_n) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ 1 & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ 1 & 1 & 1 & \cdots & 1 \end{bmatrix} \begin{bmatrix} X(t_1) \\ X(t_2) - X(t_1) \\ \vdots \\ X(t_n) - X(t_{n-1}) \end{bmatrix}$$

e como $X(t_1), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})$ são v.a.'s gaussianas independentes, então $X(t_1), \dots, X(t_n)$ tem uma distribuição gaussiana n -variada.

3. Uma realização típica de um processo de Wiener é dada na Figura 3. A aparência é de uma curva serrilhada, e pode-se provar que, embora as trajetórias de um processo de Wiener sejam contínuas quase certamente, elas não têm derivadas em qualquer ponto.

Processo de Wiener



Processo autorregressivo

Dizemos que $\{X_t, t \in \mathbb{Z}\}$ é um **processo autorregressivo de ordem p** e escrevemos $X_t \sim AR(p)$, se satisfizer à equação de diferenças

$$X_t - \mu = \phi_1(X_{t-1} - \mu) + \phi_2(X_{t-2} - \mu) + \dots + \phi_p(X_{t-p} - \mu) + \varepsilon_t, \quad (19)$$

onde $\mu, \phi_1, \dots, \phi_p$ são parâmetros reais e $\varepsilon_t \sim RB(0, \sigma^2)$.

Processo autorregressivo

Vamos definir o operador retroativo B , por $B^s X_t = X_{t-s}$, se $s \geq 1$. Então, (19) pode ser escrita

$$\phi(B)\tilde{X}_t = \varepsilon_t, \quad (20)$$

na qual $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é o operador autorregressivo de ordem p e $\tilde{X}_t = X_t - \mu$. Suponha $\mu = 0$ de agora em diante.

Processo AR(1)

1. Um caso particular importante é o processo $AR(1)$,

$$X_t = \phi X_{t-1} + \varepsilon_t. \quad (21)$$

2. Aqui, $\phi(B) = 1 - \phi B$. Por substituições sucessivas, obtemos

$$X_t = \sum_{j=0}^r \phi^j \varepsilon_{t-j} + \phi^{r+1} X_{t-r-1}.$$

3. Se X_t for estacionário, com variância finita σ_X^2 , então

$$E[X_t - \sum_{j=0}^r \phi^j \varepsilon_{t-j}]^2 = \phi^{2r+2} E\{X_{t-r-1}^2\} = \phi^{2r+2} \sigma_X^2.$$

4. Se $|\phi| < 1$, $\phi^{2(r+1)} \rightarrow 0$, quando $r \rightarrow \infty$, portanto, sob essa suposição, podemos escrever

$$X_t = \sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j}, \quad (22)$$

onde a convergência é em média quadrática.

Processo AR(1)

1. Logo, a condição $|\phi| < 1$ é suficiente para X_t ser estacionário.
2. Multiplicando ambos os membros de (21) por $X_{t-\tau}$ e tomando a esperança, obtemos

$$\gamma_\tau = \phi \gamma_{\tau-1} = \dots = \phi^\tau \gamma_0.$$

3. Mas, de (22), obtemos

$$\gamma_0 = \sigma_X^2 = \sigma^2 \sum_{j=0}^{\infty} \phi^{2j} = \frac{\sigma^2}{1 - \phi^2}, \quad (23)$$

do que segue

$$\gamma_\tau = \frac{\sigma^2}{1 - \phi^2} \phi^\tau, \quad \tau \geq 0.$$


4. Como γ_τ é simétrica, podemos escrever finalmente a f.a.c.v. de um processo AR(1) como

$$\gamma_\tau = \frac{\sigma^2}{1 - \phi^2} \phi^{|\tau|}, \quad \tau \in \mathbb{Z}. \quad (24)$$


Processo AR(1)

A f.a.c. de X_t é obtida de (23) e (24), ou seja,

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0} = \phi^{|\tau|}, \quad \tau \in \mathbb{Z}. \quad (25)$$



(a)



(b)

Figura 4: Função de autocorrelação de um AR(1). (a) $\phi = 0,8$ (b) $\phi = -0,8$.

AR estacionário

1. Pode-se demonstrar (Box et al., 1994) que a **condição para que X_t seja estacionário é que todas as raízes de $\phi(B) = 0$ estejam fora do círculo unitário.**
2. Em particular, para $p = 1$, $\phi(B) = 1 - \phi B = 0$ implica $B = \phi^{-1}$, e a condição enunciada acarreta $|\phi| < 1$.
3. A facv de um processo AR(p) é dada por

$$\gamma_\tau = \phi_1 \gamma_{\tau-1} + \phi_2 \gamma_{\tau-2} + \dots + \phi_p \gamma_{\tau-p}, \quad \text{para } \tau > 0. \quad (26)$$

4. A mesma equação de diferenças é satisfeita por ρ_τ , bastando dividir todos os termos de (26) por γ_0 .

Equações de Yule-Walker

1. A solução geral dessa equação é dada por

$$\gamma_\tau = A_1 G_1^\tau + A_2 G_2^\tau + \dots + A_p G_p^\tau, \quad (27)$$

onde os G_i s satisfazem

$$\phi(B) = \prod_{i=1}^p (1 - G_i B).$$

2. Como as raízes de $\phi(B) = 0$ devem estar fora do círculo unitário, devemos ter que $|G_i| < 1$, para todo $i = 1, \dots, p$.
3. Se fizermos $\tau = 1, 2, \dots, p$ em (27), obtemos

$$\Gamma_p \phi_p = \gamma_p, \quad (28)$$

onde temos $\Gamma_p = [\gamma_{ij}]$, $\gamma_{ij} = \gamma_{|i-j|}$, $i, j = 1, \dots, p$, $\phi_p = (\phi_1, \dots, \phi_p)'$ e $\gamma_p = (\gamma_1, \dots, \gamma_p)'$.

O conjunto de equações (28), chamadas de **equações de Yule-Walker**, pode ser utilizado para obter estimadores dos parâmetros ϕ_j 's, substituindo-se as f.a.c.vs por suas estimativas. Esses estimadores são chamados **estimadores de Yule-Walker**.

facv de AR(p)

Uma análise de (27) nos permite concluir que a f.a.c.v. de um processo autorregressivo de ordem p é uma mistura de exponenciais (correspondentes às raízes G_i reais) e/ou senóides (correspondentes a pares de raízes complexas conjugadas) amortecidas.




Figura 6: Função de autocorrelação de um modelo $AR(2)$.

(a) $\phi_1 = 0,5$, $\phi_2 = 0,3$ (b) $\phi_1 = -0,5$, $\phi_2 = 0,3$.

Referências

Morettin, P. A. (2014). *Ondas e Ondaletas*. Segunda edição. São Paulo: EDUSP.

Morettin, P. A. and Toloï, C. M. C. (2018). *Análise de Séries Temporais*. Terceira Edição. Blucher.

Percival, D. and Walden, A. (1993). *Spectral Analysis for Physical Applications*. Cambridge.