

PROCESSOS LINEARES

1. **Teorema(Wold):** Todo processo estacionário de segunda ordem, puramente não-determinístico, pode ser escrito como

$$X_t = \mu + \sum_{j=0}^{\infty} \psi_j a_{t-j}, \quad \psi_0 = 1, \quad (1)$$

com $\{\varepsilon_t\}$ uma seqüência de v.a. não correlacionadas, de média zero e variância σ^2 constante (ruído branco)

- $E(X_t) = \mu$
- $\text{Var}(X_t) = \sigma^2 \sum_{j=0}^{\infty} \psi_j^2$
- $\gamma_k = \sigma^2 \sum_{j=0}^{\infty} \psi_j \psi_{j+k}, \quad \sum \psi_j^2 < \infty.$
- $\rho_k = \frac{\sum_{j=0}^{\infty} \psi_j \psi_{j+k}}{\sum_{j=0}^{\infty} \psi_j^2}$

2. Processos ARMA: São casos particulares de (1)

- $\psi_j = \phi^j \Rightarrow X_t = \phi X_{t-1} + \varepsilon_t, \sim \text{AR}(1),$
 $|\phi| < 1, \rho_k = \phi^k.$
- $\psi_1 = -\theta, \psi_j = 0, j > 1 \Rightarrow X_t = \varepsilon_t - \theta \varepsilon_{t-1} \sim \text{MA}(1), \rho_1 = (-\theta)/(1 + \theta^2),$
 $\rho_j = 0, j > 1.$
- $\psi_j = (\phi - \theta)\phi^{j-1} \rightarrow \text{ARMA}(1,1),$
 $\rho_1 = (1 - \phi\theta)/(1 + \theta^2 - 2\phi\theta), \rho_k = \phi\rho_{k-1},$
 $k > 1.$

3. Modelos Auto-regressivos

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

$$X_t - \mu = \sum_{j=1}^p \phi_j (X_{t-j} - \mu) + \varepsilon_t, \quad (2)$$

onde $\mu, \phi_1, \dots, \phi_p$ são parâmetros reais e $\varepsilon_t \sim \text{RB}(0, \sigma^2)$. Segue-se que $E(X_t) = \mu$ e se escrevermos o processo na forma

$$X_t = \phi_0 + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t,$$

então

$$\mu = E(X_t) = \frac{\phi_0}{1 - \phi_1 - \dots - \phi_p}.$$

- Definamos o operador retroativo B através de $B^s X_t = X_{t-s}, s \geq 1$. Então (2) pode ser escrita

$$\phi(B) \tilde{X}_t = \varepsilon_t, \quad (3)$$

onde $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é o operador auto-regressivo de ordem p e $\tilde{X}_t = X_t - \mu$. Suponha $\mu = 0$ no que segue.

- AR(1):

$$X_t = \phi X_{t-1} + \varepsilon_t. \quad (4)$$

Aqui, $\phi(B) = 1 - \phi B$, com auto-covariância:

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

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

$$\gamma_\tau = \frac{\sigma^2}{1 - \phi^2} \phi^{|\tau|}, \quad \tau \in \mathbb{Z}. \quad (5)$$

A função de auto-correlação é

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0} = \phi^{|\tau|}, \quad \tau \in \mathbb{Z}. \quad (6)$$

- Supondo o processo estacionário, multiplicando-se ambos os membros de (2) por $X_{t-\tau}$ e tomando valores esperados, obtemos

$$\sigma_X^2 = \frac{\sigma^2}{1 - \phi_1\rho_1 - \dots - \phi_p\rho_p}, \quad \tau = 0, \quad (7)$$

$$\gamma_\tau = \phi_1\gamma_{\tau-1} + \phi_2\gamma_{\tau-2} + \dots + \phi_p\gamma_{\tau-p}, \quad \tau > 0. \quad (8)$$

- A solução geral desta equação é dada por (Miller, 1969)

$$\gamma_\tau = A_1G_1^\tau + A_2G_2^\tau + \dots + A_pG_p^\tau, \quad (9)$$

onde os G_i 's satisfazem

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

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

- Estacionariedade:

Pode-se demonstrar (ver Box, Jenkins e Reinsel, 1994) que a *condição para que X_t seja estacionário é que todas as raízes de $\phi(B) = 0$ estejam fora do círculo unitário*. Em particular, para $p = 1$, $\phi(B) = 1 - \phi B = 0$ implica $B = \phi^{-1}$ e a condição enunciada acarreta $|\phi| < 1$.

4. Processos de Médias Móveis

- Dizemos que $\{X_t, t \in Z\}$ é um processo de médias móveis de ordem q , denotado por MA(q), se satisfizer à equação de diferenças

$$X_t = \mu + \varepsilon_t - \theta_1\varepsilon_{t-1} - \dots - \theta_q\varepsilon_{t-q}, \quad (10)$$

onde $\mu, \theta_1, \dots, \theta_q$ são constantes reais e $\varepsilon_t \sim \text{RB}(0, \sigma^2)$.

- Segue-se que X_t é estacionário, de média μ e como o ε_t são não correlacionados, podemos obter facilmente a variância do processo,

$$\sigma_X^2 = \sigma^2(1 + \theta_1^2 + \dots + \theta_q^2). \quad (11)$$

- Auto-covariância:

$$\gamma_\tau = \begin{cases} \sigma^2(-\theta_\tau + \theta_1\theta_{\tau+1} + \dots + \theta_q\theta_{q-\tau}), & \tau = 1, \dots, q \\ 0, & \tau > q \\ \gamma_{-\tau}, & \tau < 0. \end{cases} \quad (12)$$

- Auto-correlação:

$$\rho_\tau = \begin{cases} \frac{-\theta_\tau + \theta_1\theta_{\tau+1} + \dots + \theta_q\theta_{q-\tau}}{1 + \theta_1^2 + \dots + \theta_q^2}, & \text{se } \tau = 1, \dots, q \\ 0, & \text{se } \tau > q \\ \rho_{-\tau}, & \text{se } \tau < 0. \end{cases} \quad (13)$$

Observamos, então, que a f.a.c.v.(ou a f.a.c.) de um processo MA(q) anula-se para $|\tau| > q$.

- Em particular, para um processo MA(1),

$$X_t = \varepsilon_t - \theta\varepsilon_{t-1}, \quad (14)$$

obtemos

$$\text{Var}(X_t) = \sigma_X^2 = \sigma^2(1 + \theta^2),$$

$$\rho_\tau = \begin{cases} \frac{-\theta}{1+\theta^2}, & \text{se } \tau = \pm 1 \\ 0, & \text{se } |\tau| > 1. \end{cases} \quad (15)$$

- Definindo-se o operador de médias móveis de ordem q por

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

o processo (10) pode ser escrito

$$X_t = \theta(B)\varepsilon_t. \quad (16)$$

de onde, formalmente, segue

$$\varepsilon_t = (1 - \theta B)^{-1} X_t = (1 + \theta B + \theta^2 B^2 + \dots) X_t,$$

ou seja, temos

$$X_t = -\theta X_{t-1} - \theta^2 X_{t-2} - \dots + \varepsilon_t, \quad (17)$$

se $|\theta| < 1$, para que a série do lado direito de (17) convirja. Nesta equação, temos X_t escrito como um processo autorregressivo de ordem infinita. Dizemos que $|\theta| < 1$ é uma *condição de invertibilidade* para o processo MA(1).

- De modo geral, o processo (10) poderá ser escrito na forma

$$X_t = \sum_{j=1}^{\infty} \pi_j X_{t-j} + \varepsilon_t, \quad (18)$$

se a seguinte condição de invertibilidade estiver satisfeita: *todas as raízes de $\theta(B) = 0$ devem estar fora do círculo unitário.*

A relação (28) pode ser escrita

$$\pi(B)X_t = \varepsilon_t, \quad (19)$$

onde $\pi(B) = 1 - \pi_1 B - \pi_2 B^2 - \dots$, de modo que $\pi(B) = \theta(B)^{-1}$. Portanto, os coeficientes π_j podem ser obtidos da identidade $\theta(B)\pi(B) = 1$.

5. Processos Auto-regressivos e de Médias Móveis

- Um processo auto-regressivo e de médias móveis, de ordem (p, q) , denotado por ARMA(p,q), é definido por

$$X_t - \mu = \sum_{j=1}^p \phi_j (X_{t-j} - \mu) + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j}, \quad (20)$$

onde $\varepsilon_t \sim \text{RB}(0, \sigma^2)$. Segue-se que a média do processo é μ . Usando os operadores auto-regressivo e de médias móveis,

definidos anteriormente, podemos escrever (20) na forma

$$\phi(B)\tilde{X}_t = \theta(B)\varepsilon_t, \quad (21)$$

onde $\tilde{X}_t = X_t - \mu$. Suponha que, a partir de agora, $\mu = 0$.

- Um modelo freqüentemente usado é o ARMA(1,1), ou seja,

$$X_t = \phi X_{t-1} + \varepsilon_t - \theta \varepsilon_{t-1}. \quad (22)$$

É fácil ver, por substituições sucessivas, que podemos escrever

$$X_t = \psi(B)\varepsilon_t,$$

onde $\psi_j = \phi^{j-1}(\phi - \theta)$, $j \geq 1$. A condição de estacionariedade é a mesma que para um processo AR(1), ou seja, $|\phi| < 1$.

Do mesmo modo, a condição de invertibilidade $|\theta| < 1$ vale aqui e implica que podemos escrever o processo na forma (18), com pesos $\pi_j = \theta^{j-1}(\phi - \theta), j \geq 1$.

- Para um processo ARMA(p,q) genérico a condição de estacionariedade é a mesma que para processos AR(p), ou seja, as raízes de $\phi(B) = 0$ devem estar fora do círculo unitário, e a condição de invertibilidade é a mesma que para processos MA(q), ou seja, as raízes de $\theta(B) = 0$ devem estar fora do círculo unitário.
- Auto-covariância:

$$\gamma_\tau = \phi_1 \gamma_{\tau-1} + \phi_2 \gamma_{\tau-2} + \dots + \phi_p \gamma_{\tau-p}, \quad \tau > q. \quad (23)$$

A conclusão é que as auto-covariâncias (e, portanto, as auto-correlações, que

satisfazem equação similar) de lags $1, 2, \dots, q$ serão afetadas pelos parâmetros de médias móveis, mas para $\tau > q$, as mesmas comportam-se como nos modelos auto-regressivos.

- Para o caso do modelo (22), obtemos facilmente

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{(1 - \phi\theta)(\phi - \theta)}{1 + \theta^2 - 2\phi\theta}$$

e, para $\tau > 1$,

$$\rho_\tau = \phi\rho_{\tau-1}.$$

6. Construção de Modelos ARMA

- uso das fac e facp para identificação
- Estimação:

- (i) Estimadores de momentos
- (ii) Estimadores de Mínimos Quadrados (EMQ)
- (iii) Estimadores de Máxima Verossimilhança (EMV)
 - Condicionais
 - Exatos

- Diagnóstico:

- (i) análise de resíduos.
- (ii) Estatística de Box-Pierce-Ljung:

$$Q(m) = T(T + 2) \sum_{i=1}^m \frac{1}{T-i} r_i^2$$

Sob H_0 : a_t é ruído branco,

$Q(m)$ distribuição $\chi^2(m - p - q)$.

- $AIC(p, q) = \log \hat{\sigma}^2 + 2(p + q)/T$ (Akaike, 1974)
- $BIC(p, q) = \log \hat{\sigma}^2 + (p + q) \log T/T$ (Schwarz, 1978)

7. Processos Não-Estacionários

- Muitas séries financeiras são não estacionárias: exibem médias e/ou variâncias variando no tempo.
- Transformações log e raiz quadrada estabilizam variância
- Há, basicamente, duas formas de gerar processos não-estacionários e que sejam não-explosivos.

(a) Incluir em (1) uma tendência determinística, como por exemplo

$$X_t = \beta_0 + \beta_1 t + \psi(B)\varepsilon_t, \quad (24)$$

obtendo-se um processo “trend-stationary” .

(b) Considerar um PLG com raíz unitária, da forma

$$(1 - B)X_t = \delta + \psi(B)\varepsilon_t, \quad (25)$$

com $\psi(1) \neq 0$. Este modelo, obviamente, descreve variações de X_t e como $\psi(1) = \sum_{j=0}^{\infty} \psi_j \neq 0$, o processo é não-estacionário.

- Não-estacionariedade na média : nível médio não constante pode ser modelado de várias maneiras: polinômios no tempo, modelos ARIMA.
- Tendência polinomial determinística

$$X_t = \mu_t + \varepsilon_t = \sum_{j=0}^d \beta_j t^j + \psi(B)a_t \quad (26)$$

e como $E(\varepsilon_t) = 0$,

(i) $E(X_t) = E(\mu_t) = \sum_{j=0}^d \beta_j t^j$

(ii) $d = 1 \Rightarrow X_t = \beta_0 + \beta_1 t + a_t, \quad a_t \sim \text{RB}$

(iii) Tomando-se uma diferença,

$$X_t - X_{t-1} = \beta_1 + a_t - a_{t-1} \quad \sim \text{ARMA}(1, 1)$$

com $\phi = \theta = 1$, portanto **modelo não-estacionário e não-invertível**.

(iv) Se $W_t = X_t - X_{t-1} = (1 - B)X_t = \Delta X_t$,

$$W_t = \Delta X_t = \beta_1 + \Delta a_t \sim \text{MA}(1),$$

estacionário, não-invertível

(v) Em geral, se (26) vale com $\varepsilon_t \sim \text{ARMA}(p, q)$,

$$\Delta^d X_t = (1 - B)^d X_t = \theta_0 + n_t, \quad \theta_0 = d! \beta_d,$$

com $\phi(B)n_t = \Delta^d \theta(B)a_t$.

Ou seja, a parte de médias móveis de $\Delta^d X_t$ conterá o fator $\Delta^d = (1 - B)^d$ e terá d raízes unitárias.

• Processos Integrados

(i) Uma maneira alternativa de gerar processos não-estacionários é considerar modelos ARMA cuja parte AR não satisfaz condições de estacionariedade. Por exemplo,

$$X_t = \phi X_{t-1} + a_t, \quad \phi > 1. \quad (27)$$

Se $X_0 = x_0$, a equação de diferença (27) tem solução

$$X_t = x_0\phi^t + \sum_{i=0}^t \phi^i a_{t-i}. \quad (28)$$

(ii) $\text{Var}(X_t) = \sigma^2 \frac{\phi^{2(t+1)} - 1}{\phi^2 - 1}$, crescente com t .

(iii) Em geral, X_t terá uma tendência na média e variância e X_t diz-se **explosivo**.

(iv) $\phi < 1 \Rightarrow X_t$ estacionário

$\phi > 1 \Rightarrow X_t$ explosivo

$\phi = 1 \Rightarrow ?$

Neste caso temos um **Passeio Casual**.

$$X_t = X_{t-1} + a_t$$

Incluindo-se uma constante,

$$X_t = \theta_0 + X_{t-1} + a_t,$$

um Passeio Casual com Drift.

(v) Se processo começa em $t = 0$,

$$X_t = x_0 + t\theta_0 + \sum_{i=0}^t a_{t-i}$$

(vi) $\mu_t = x_0 + t\theta_0$

$$\gamma_0(t) = t\sigma^2$$

$$\gamma_k(t) = (t - k)\sigma^2$$

$$\rho_k(t) = \frac{t-k}{t}$$

Logo, se t grande, $\rho_k(t) \approx 1$: seqüência suave mas **não-estacionária**

(vii) Passeio casual: exemplo de *processo integrado*

$$\Delta X_t = \theta_0 + a_t$$

(viii) Se $\Delta^d X_t$ é estacionário, dizemos que $X_t \sim I(d)$: **integrado de ordem d**

- **Modelos ARIMA (p,d,q)**

(i) Se $\Delta^d X_t \sim \text{ARMA}(p,q)$ dizemos que X_t segue um modelo ARIMA(p,d,q):

$$\phi(B)\Delta^d X_t = \theta_0 + \theta(B)a_t. \quad (29)$$

Ou, de modo equivalente,

$$\phi(B)W_t = \theta_0 + \theta(B)a_t, \quad \text{com } W_t = \Delta^d X_t$$

(ii) $W_t = \Delta^d X_t \iff X_t = S^d W_t,$

onde S é o operador **soma** ou **integral**:

$$S = (1 - B)^{-1} = \Delta^{-1}$$

Ou seja, X_t pode ser obtido somando-se ou integrando-se o processo estacionário W_t d vezes, donde o nome **processo integrado** para X_t .

(iii) Inclusão de θ_0 : introduz tendência determinística
Modelo **sem** θ_0 : tendências estocásticas.

- **Modelagem ARIMA**

- determine d
- modele $W_t = \Delta^d X_t$ como um modelo ARMA

Exemplos

- (1) “UK Spread” $\sim I(1)$
- (2) “Dollar/Sterling Exchange Rate” \sim
Passeio Casual Sem Drift
- (3) “FTA (Financial Times-Actuaries) All Share” (Stock Index)
 $P_t \rightarrow \log(P_t) = X_t \rightarrow \Delta X_t \sim \text{AR}(3)$
- (4) Ibovespa mensal : ruído branco.

(5) Petrobrás diário: AR(9)

(6) ICV-São Paulo: ARIMA (1,1,0)

• Previsão Com Modelos ARIMA

(i) Queremos prever X_{T+h} , tendo-se observações até o instante T , usando o modelo ARIMA. Seja

$$\varphi(B) = \phi(B)\Delta^d$$

$$= (1 - \alpha_1 B - \alpha_2 B^2 - \dots - \alpha_{p+d} B^{p+d})$$

(ii) $\hat{X}_T(h)$ = previsão de X_{T+h} de EQMM:

$$\hat{X}_T(h) = E(\alpha_1 X_{T+h-1} + \dots + \alpha_{p+d} X_{T+h-p-d}$$

$$+ \theta_0 + a_{T+h} - \theta_1 a_{T+h-1} - \dots - \theta_q a_{T+h-q} \mid X_T, X_{T-1}, \dots)$$

$$(iii) \quad E(X_{T+j}|X_T, X_{T-1}, \dots) = \begin{cases} X_{T+j}, & \text{se } j \leq 0 \\ \hat{X}_T(h), & \text{se } j > 0 \end{cases}$$

$$E(a_{T+j}|X_T, X_{T-1}, \dots) = \begin{cases} a_{T+j}, & \text{se } j \leq 0 \\ 0, & \text{se } j > 0 \end{cases}$$

(iv) Logo, para calcular previsões temos que:

(a) substituir esperanças passadas ($j \leq 0$) por valores conhecidos, X_{T+j} e a_{T+j} ;

(b) substituir esperanças futuras ($j > 0$) por previsões $\hat{X}_T(h)$ e 0.

(v) **Exemplo:** $(1 - \phi_1 B - \phi_2 B^2)X_t = \theta_0 + a_t$.

Temos

$$X_{T+h} = \theta_0 + \phi_1 X_{T+h-1} + \phi_2 X_{T+h-2} + a_{T+h}$$

$$h = 1 \rightarrow \hat{X}_T(1) = \theta_0 + \phi_1 X_T + \phi_2 X_{T-1},$$

$$h = 2 \rightarrow \hat{X}_T(2) = \theta_0 + \phi_1 \hat{X}_T(1) +$$

$$\phi_2 X_T,$$

$$h > 2 \rightarrow \hat{X}_T(h) = \theta_0 + \phi_1 \hat{X}_T(h-1) + \phi_2 \hat{X}_T(h-2).$$

(vi) **erro de previsão**

$$e_{T,h} = X_{T,h} - \hat{X}_T(h) =$$

$$a_{T+h} + \psi_1 a_{T+h-1} + \dots + \psi_{h-1} a_{T+1}$$

Os pesos ψ_j vêm de $\psi(B) = \varphi^{-1}(B)\theta(B)$.

(vii) **Variância do erro de previsão**

$$\text{Var}(e_{T,h}) = \sigma^2(1 + \psi_1^2 + \dots + \psi_{h-1}^2). \quad (30)$$

(viii) Como $e_{T,1} = X_{T+1} - f_{T,1} = a_{T+1}$, os erros de previsões a um passo são não-correlacionados

- (ix) A variância em (30) tem que ser estimada, estimando-se a variância residual e os pesos ψ_j .
- (x) Esta variância estimada pode ser usada para construir intervalos de confiança para X_{T+h} , supondo-se que os erros sejam normais. Obtemos

$$\left[\hat{X}_T(h) - u_\gamma \hat{\sigma} \left[1 + \sum_{j=1}^h \hat{\psi}_j^2 \right]^{1/2}, \hat{X}_T(h) + u_\gamma \hat{\sigma} \left[1 + \sum_{j=1}^{h-1} \hat{\psi}_j^2 \right]^{1/2} \right]. \quad (31)$$