

MODELOS MULTIVARIADOS

1. Introdução

- Interesse: modelos para uma série temporal vetorial \mathbf{X}_t , com n componentes $X_{1t}, X_{2t}, \dots, X_{nt}$, observadas em $t \in Z$.

Estudo de relações dinâmicas entre as séries componentes.

Notação: $\mathbf{X}_t = (X_{1t}, X_{2t}, \dots, X_{nt})'$, $t \in Z$ e X_{it} ou $X_{i,t}$, indistintamente, para a i -ésima componente, $i = 1, \dots, p$.

- **Exemplo 1.** Podemos pensar o vetor \mathbf{X}_t como constituído pelos retornos de n ativos financeiros de um fundo de investimentos no instante t e o objetivo é analisar o desempenho do fundo ao longo do tempo. Numa outra situação, um investidor pode ter uma carteira com

ações da Petrobrás, Banco do Brasil, Banespa e Banco Itaú e neste caso $n = 4$.

- vetor de médias (depende de t):

$$\boldsymbol{\mu}_t = E(\mathbf{X}_t) = (\mu_{1t}, \mu_{2t}, \dots, \mu_{nt})' \quad (1)$$

- matriz de covariâncias ($n \times n$, depende de t):

$$\begin{aligned} \Gamma(t + \tau, t) &= \\ &= E\{(\mathbf{X}_{t+\tau} - \boldsymbol{\mu}_{t+\tau})(\mathbf{X}_t - \boldsymbol{\mu}_t)'\} \end{aligned} \quad (2)$$

- $\gamma_{ij}(t + \tau, t)$, $i, j = 1, \dots, n$: componentes de $\Gamma(t + \tau, t)$:

$$\gamma_{ij}(t + \tau, t) = \text{Cov}\{X_{i,t+\tau}, X_{j,t}\}, \quad (3)$$

$i, j = 1, \dots, n$ é a covariância entre as séries $X_{i,t+\tau}$ e $X_{j,t}$.

- **Exemplo 1.**(cont.) $\mathbf{X}_t = (X_{1t}, \dots, X_{4t})'$, $\boldsymbol{\mu}_t = (\mu_{1t}, \dots, \mu_{4t})'$ é o vetor de médias e a matriz (2) ficará

$$\Gamma(t + \tau, t) =$$

$$\begin{bmatrix} \gamma_{11}(t + \tau, t) & \gamma_{12}(t + \tau, t) & \cdots & \gamma_{14}(t + \tau, t) \\ \gamma_{21}(t + \tau, t) & \gamma_{22}(t + \tau, t) & \cdots & \gamma_{24}(t + \tau, t) \\ \cdots & \cdots & \cdots & \cdots \\ \gamma_{41}(t + \tau, t) & \gamma_{42}(t + \tau, t) & \cdots & \gamma_{44}(t + \tau, t) \end{bmatrix}$$

2. Séries Estacionárias

- vetor de médias: não depende de t :

$$\boldsymbol{\mu} = E(\mathbf{X}_t) = (\mu_1, \dots, \mu_n)', \quad (4)$$

e, para $\tau \in \mathbb{Z}$,

$$\Gamma(\tau) = E\{(\mathbf{X}_{t+\tau} - \boldsymbol{\mu})(\mathbf{X}_t - \boldsymbol{\mu})'\} = [\gamma_{ij}(\tau)]_{i,j=1}^n. \quad (5)$$

Neste caso, $\gamma_{ii}(\tau)$ será a f.a.cov. da série estacionária X_{it} e $\gamma_{ij}(\tau)$ será a função de covariância cruzada (f.c.c.) de X_{it} e X_{jt} . Notemos que, em geral, $\gamma_{ij}(\tau) \neq \gamma_{ji}(\tau)$.

- No caso particular de $\tau = 0$ em (5) obtemos

$$\Gamma(0) = E\{(\mathbf{X}_t - \boldsymbol{\mu})(\mathbf{X}_t - \boldsymbol{\mu})'\}, \quad (6)$$

que é a *matriz de covariâncias contemporâneas*. Em particular,

$$\gamma_{ii}(0) = \text{Var}(X_{it}),$$

$$\gamma_{ij}(0) = \text{Cov}\{X_{it}, X_{jt}\}.$$

- O *coeficiente de correlação contemporâneo* entre X_{it} e X_{jt} é então dado por

$$\rho_{ij}(0) = \frac{\gamma_{ij}(0)}{[\gamma_{ii}(0)\gamma_{jj}(0)]^{1/2}}. \quad (7)$$

$$\rho_{ij}(0) = \rho_{ji}(0), \quad \rho_{ii}(0) = 1$$

$-1 \leq \rho_{ij}(0) \leq 1$, para todo $i, j = 1, \dots, n$,

logo $\rho(0) = [\rho_{ij}(0)]_{i,j=1}^n$ é uma matriz simétrica, com elementos na diagonal principal todos iguais a um.

- A *matriz de correlações* de lag τ é definida por

$$\rho(\tau) = \mathbf{D}^{-1}\Gamma(\tau)\mathbf{D}^{-1}, \quad (8)$$

sendo $\mathbf{D} = \text{diag}\{\sqrt{\gamma_{11}(0)}, \dots, \sqrt{\gamma_{nn}(0)}\}$.

- Ou seja, denotando $\rho(\tau) = [\rho_{ij}(\tau)]_{i,j=1}^n$, temos

$$\rho_{ij}(\tau) = \frac{\gamma_{ij}(\tau)}{[\gamma_{ii}(0)\gamma_{jj}(0)]^{1/2}}, \quad (9)$$

que é o coeficiente de correlação entre $X_{i,t+\tau}$ e $X_{j,t}$.

- $\tau > 0$: coeficiente mede a dependência linear de X_{it} sobre X_{jt} , que ocorreu antes do instante $t + \tau$.

$\rho_{ij}(\tau) \neq 0$, $\tau > 0$, dizemos que X_{jt} é *antecedente* a X_{it} ou que X_{jt} *lidera* X_{it} no lag τ .

De modo análogo, $\rho_{ji}(\tau)$ mede a dependência linear de X_{jt} sobre X_{it} , $\tau > 0$.

- **Proposição 1.** As seguintes propriedades são válidas:

- (i) $\Gamma(\tau) = \Gamma'(-\tau)$.
- (ii) $|\gamma_{ij}(\tau)| \leq [\gamma_{ii}(0)\gamma_{jj}(0)]^{1/2}$, $i, j = 1, \dots, n$.
- (iii) $\gamma_{ii}(\tau)$ é uma função de auto-covariância, para todo i .

(iv) $\sum_{j,k=1}^m \mathbf{a}_j' \Gamma(j-k) \mathbf{a}_k \geq 0$, para quaisquer m e $\mathbf{a}_1, \dots, \mathbf{a}_m$ vetores de \mathbb{R}^n .

3. Estimação de Médias e Covariâncias

- $\{\mathbf{X}_t, t = 1, \dots, T\}$: observações do processo estacionário $\{\mathbf{X}_t, t \in Z\}$;
média μ pode ser estimada pelo vetor de médias amostrais

$$\bar{\mathbf{X}} = \frac{\sum_{t=1}^T \mathbf{X}_t}{T}. \quad (10)$$

Segue-se que a média μ_j de X_{jt} é estimada por $\sum_{t=1}^T X_{jt}/T$.

- Para estimar $\Gamma(\tau)$ usamos

$$\hat{\Gamma}(\tau) = \frac{1}{T} \sum_{t=1}^{T-\tau} (\mathbf{X}_{t+\tau} - \bar{\mathbf{X}})(\mathbf{X}_t - \bar{\mathbf{X}})', \quad 0 \leq \tau \leq T-1. \quad (11)$$

- A matriz de correlações pode ser estimada por

$$\hat{\rho}(\tau) = \hat{\mathbf{D}}' \hat{\Gamma} \hat{\mathbf{D}}^{-1}, \quad (12)$$

onde $\hat{\mathbf{D}}$ é a matriz diagonal $n \times n$ dos desvios padrões amostrais das séries individuais.

- **Exemplo 2.** X_{1t} : retornos diários da Petrobrás ;

X_{2t} : retornos diários do Ibovespa, de 3/1/95 a 27/12/2000, $T = 1498$;

$$\mathbf{X}_t = (X_{1t}, X_{2t})'$$

SCA: usa a notação

$$+ : \rho_{ij}(\tau) \geq 2/\sqrt{T},$$

$$- : \rho_{ij}(\tau) \leq -2/\sqrt{T},$$

$$\bullet : -2/\sqrt{T} < \rho_{ij}(\tau) < 2/\sqrt{T}.$$

$$\hat{\rho}(0) = \begin{bmatrix} 1,00 & 0,83 \\ 0,83 & 1,00 \end{bmatrix},$$

enquanto

$$\hat{\rho}(1) = \begin{bmatrix} 0,05 & 0,02 \\ 0,10 & 0,11 \end{bmatrix}.$$

Como $1/\sqrt{1498} = 0,02584$, o elemento $\rho_{12}(1)$ pode ser considerado estatisticamente nulo, de modo que a representação pictórica dessa matriz de correlações amostrais é

$$\begin{bmatrix} + & \cdot \\ + & + \end{bmatrix}.$$

Note que a correlação contemporânea entre as duas séries é 0,83.

- **Exemplo 3.** Consideremos, agora, a série bivariada, consistindo dos retornos

mensais do Ibovespa e da taxa de juros dos títulos C-Bond da dívida brasileira, ambas de julho de 1994 a agosto de 2001, $T = 86$.

Vemos que $\rho(\tau)$, $\tau = 1, 2, \dots, 4$, podem ser consideradas nulas, o que sugere que estamos na presença de um ruído branco bivariado. É fácil verificar que a correlação contemporânea entre as duas séries é negativa (-0,77).

4. Modelos VAR

- Dizemos que o processo \mathbf{X}_t , de ordem $n \times 1$, segue um modelo VAR(p) se

$$\mathbf{X}_t = \Phi_0 + \Phi_1 \mathbf{X}_{t-1} + \dots + \Phi_p \mathbf{X}_{t-p} + \mathbf{a}_t, \quad (13)$$

onde $\mathbf{a}_t \sim \text{RB}(\mathbf{0}, \Sigma)$, $\Phi_0 = (\phi_{10}, \dots, \phi_{n0})'$ é um vetor $n \times 1$ de constantes e Φ_k são

matrizes $n \times n$ constantes, com elementos $\phi_{ij}^{(k)}$, $i, j = 1, \dots, n$, $k = 1, \dots, p$.

- Se \mathbf{I}_n é a matriz identidade de ordem n , o modelo (13) pode ser escrito na forma

$$\Phi(B)\mathbf{X}_t = \Phi_0 + \mathbf{a}_t, \quad (14)$$

onde $\Phi(B) = \mathbf{I}_n - \Phi_1 B - \dots - \Phi_p B^p$ é o operador auto-regressivo vetorial de ordem p , ou ainda, um polinômio matricial $n \times n$ em B . O elemento genérico de $\Phi(B)$ é $[\delta_{ij} - \phi_{ij}^{(1)} B - \dots - \phi_{ij}^{(p)} B^p]$, para $i, j = 1, \dots, n$ e $\delta_{ij} = 1$, se $i \neq j$ e igual a zero, caso contrário.

- VAR(1):

$$\mathbf{X}_t = \Phi_0 + \Phi \mathbf{X}_{t-1} + \mathbf{a}_t. \quad (15)$$

caso especial: $n = 2$ e (15) reduz-se a

$$\begin{aligned} X_{1t} &= \phi_{10} + \phi_{11}X_{1,t-1} + \phi_{12}X_{2,t-1} + a_{1t}, \\ X_{2t} &= \phi_{20} + \phi_{21}X_{1,t-1} + \phi_{22}X_{2,t-1} + a_{2t} \end{aligned} \quad (16)$$

- $\phi_{12} = 0 \rightarrow X_{1t}$ não dependerá de $X_{2,t-1}$;

$\phi_{21} = 0 \rightarrow X_{2,t}$ não dependerá de $X_{1,t-1}$.

$\phi_{12} = 0$ e $\phi_{21} \neq 0$: existe uma relação linear unidirecional de X_{1t} para X_{2t} .

$\phi_{12} = \phi_{21} = 0$ dizemos que não existe relação linear entre as séries, ou que elas são *não-acopladas*.

$\phi_{12} \neq 0$, $\phi_{21} \neq 0$, dizemos que existe uma relação de *feedback* entre as duas séries.

Note também que se $\sigma_{12} = 0$ em Σ , não existe relação linear contemporânea entre X_{1t} e X_{2t} .

- O processo \mathbf{X}_t em (15) será estacionário se a média for constante e $E(\mathbf{X}_{t+\tau}\mathbf{X}'_t)$

independente de t . Neste caso, se $\boldsymbol{\mu} = E(\mathbf{X}_t)$, teremos

$$\boldsymbol{\mu} = (\mathbf{I}_n - \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}_0.$$

Segue-se que o modelo poderá ser escrito na forma

$$\mathbf{X}_t - \boldsymbol{\mu} = \boldsymbol{\Phi}(\mathbf{X}_{t-1} - \boldsymbol{\mu}) + \mathbf{a}_t,$$

ou ainda, se $\tilde{\mathbf{X}}_t = \mathbf{X}_t - \boldsymbol{\mu}$,

$$\tilde{\mathbf{X}}_t = \boldsymbol{\Phi} \tilde{\mathbf{X}}_{t-1} + \mathbf{a}_t. \quad (17)$$

- Assim como no caso de um AR(1) univariado, obtemos de (17) que

$$\tilde{\mathbf{X}}_t = \mathbf{a}_t + \boldsymbol{\Phi} \mathbf{a}_{t-1} + \boldsymbol{\Phi}^2 \mathbf{a}_{t-2} + \dots, \quad (18)$$

ou seja, temos a representação $MA(\infty)$ do modelo. Também, é fácil ver que $\text{Cov}(\mathbf{a}_t, \mathbf{X}_{t-1}) = \mathbf{0}$ e $\text{Cov}(\mathbf{a}_t, \mathbf{X}_t) = \Sigma$.

- **Proposição 2.** O processo \mathbf{X}_t seguindo um modelo VAR(1) será estacionário se todas as soluções de

$$|\mathbf{I}_n - \Phi z| = 0 \quad (19)$$

estiverem fora do círculo unitário.

Como as soluções de (19) são inversas dos autovalores de Φ , uma condição equivalente é que todos os auto-valores de Φ sejam menores do que um, em módulo. Ou ainda, $|\mathbf{I}_n - \Phi z| \neq 0, |z| \leq 1$.

- **Exemplo 4.** No caso de um VAR(1) bivariado, temos que (19) fica

$$\begin{bmatrix} 1 - \phi_{11}z & -\phi_{22}z \\ -\phi_{21}z & 1 - \phi_{22}z \end{bmatrix}$$

$$= (1 - \phi_{11}z)(1 - \phi_{22}z) - \phi_{12}\phi_{21}z^2 = 0,$$

ou seja, obtemos a equação

$$1 - \text{tr}(\Phi)z - |\Phi|z^2 = 0,$$

onde $\text{tr}(\Phi) = \phi_{11} + \phi_{22}$ indica o traço de Φ . Logo as duas séries são (conjuntamente) estacionárias se as soluções desta equação de segundo grau estiverem fora do círculo unitário. Por exemplo, se

$$\Phi = \begin{bmatrix} 0,5 & 0,3 \\ -0,6 & -0,1 \end{bmatrix},$$

então $\text{tr}(\Phi) = 0,4$, $|\Phi| = 0,13$ e as raízes da equação terão módulos maiores do que um.

- Matriz de Covariâncias:

$$\Gamma(0) = \Sigma + \Phi\Sigma\Phi' + \Phi^2\Sigma(\Phi^2)' + \dots$$

$$= \sum_{j=0}^{\infty} \Phi^j \Sigma (\Phi^j)', \quad \Phi_0 = \mathbf{I}_n.$$

Se pós-multiplicarmos (17) por $\tilde{\mathbf{X}}'_{t-\tau}$ teremos

$$E(\tilde{\mathbf{X}}_t \tilde{\mathbf{X}}'_{t-\tau}) = \Phi E(\tilde{\mathbf{X}}_{t-1} \tilde{\mathbf{X}}'_{t-\tau}) + E(\mathbf{a}_t \tilde{\mathbf{X}}'_{t-\tau}).$$

Fazendo $\tau = 0$ obtemos

$$\Gamma(0) = \Phi \Gamma(-1) + \Sigma = \Phi \Gamma(1)' + \Sigma.$$

- **Proposição 3.** Para o modelo VAR(p) dado em (14) temos os seguintes resultados:
 - (i) O processo \mathbf{X}_t será estacionário se as soluções de

$$|\mathbf{I}_n - \Phi_1 B - \dots - \Phi_p B^p| = 0$$

estiverem fora do círculo unitário.

(ii) Se \mathbf{X}_t for estacionário,

$$\boldsymbol{\mu} = E(\mathbf{X}_t) = (\mathbf{I}_n - \Phi_1 B - \dots - \Phi_p B^p)^{-1} \Phi_0.$$

(iii) Escrevendo (14) na forma

$$\tilde{\mathbf{X}}_t = \Phi_1 \tilde{\mathbf{X}}_{t-1} + \dots + \Phi_p \tilde{\mathbf{X}}_{t-p} + \mathbf{a}_t,$$

com $\tilde{\mathbf{X}}_t = \mathbf{X}_t - \boldsymbol{\mu}$ e multiplicando esta equação por $\tilde{\mathbf{X}}'_{t-\tau}$ obtemos

$$\Gamma(\tau) = \Phi_1 \Gamma(\tau-1) + \dots + \Phi_p \Gamma(\tau-p), \quad \tau > 0,$$

que são as equações de Yule-Walker no caso de um modelo VAR(p).

5. Construção de Modelos VAR

- Uma maneira de identificar a ordem p de um modelo VAR(p) consiste em ajustar seqüencialmente modelos auto-regressivos vetoriais de ordens $1, 2, \dots, k$ e testar a significância dos coeficientes (matrizes). Considere, pois, os modelos

$$\begin{aligned} \mathbf{X}_t &= \Phi_0^{(1)} + \Phi_1^{(1)}\mathbf{X}_{t-1} + \mathbf{a}_t^{(1)}, \\ \mathbf{X}_t &= \Phi_0^{(2)} + \Phi_1^{(2)}\mathbf{X}_{t-1} + \Phi_2^{(2)}\mathbf{X}_{t-2} + \mathbf{a}_t^{(2)}, \\ \dots &\quad \dots \\ \mathbf{X}_t &= \Phi_0^{(k)} + \Phi_1^{(k)}\mathbf{X}_{t-1} + \dots + \Phi_k^{(k)}\mathbf{X}_{t-k} + \mathbf{a}_t^{(k)}. \end{aligned} \tag{20}$$

Os parâmetros podem ser estimados por MQ ordinários, que fornecem estimadores consistentes e eficientes. Testamos, então,

$$\begin{aligned} H_0 &: \Phi_k^{(k)} = \mathbf{0}, \\ H_1 &: \Phi_k^{(k)} \neq \mathbf{0}, k = 1, 2, \dots \end{aligned} \tag{21}$$

O teste da razão de verossimilhanças é baseado nas estimativas das matrizes de covariâncias dos resíduos dos modelos ajustados. Para a k -ésima equação, considere

$$\hat{\mathbf{a}}_t^{(k)} = \mathbf{X}_t - \hat{\Phi}_0^{(k)} - \hat{\Phi}_1^{(k)} \mathbf{X}_{t-1} - \dots - \hat{\Phi}_k^{(k)} \mathbf{X}_{t-k}.$$

A matriz de covariância dos resíduos, que estima Σ , é dada então por

$$\hat{\Sigma}_k = \frac{1}{T-k} \sum_{t=k+1}^T \hat{\mathbf{a}}_t^{(k)} (\hat{\mathbf{a}}_t^{(k)})', \quad k \geq 0, \quad (22)$$

onde para $k = 0$, $\hat{\mathbf{a}}_t^{(0)} = \mathbf{X}_t - \bar{\mathbf{X}}$. A estatística da RV para o teste (21) é dada por

$$RV(k) = (T-k) \ln \frac{|\hat{\Sigma}_{k-1}|}{|\hat{\Sigma}_k|}, \quad (23)$$

que tem distribuição qui-quadrado com n^2 graus de liberdade, $\chi^2(n^2)$.

- Outra maneira de identificar a ordem de um VAR é usar algum critério de informação, tais como:

$$\begin{aligned} \text{AIC}(k) &= \ln(|\hat{\Sigma}_k|) + 2kn^2/T \text{ (Akaike)}, \\ \text{BIC}(k) &= \ln(|\hat{\Sigma}_k|) + kn^2 \ln(T)/T \text{ (Schwarz)}, \\ \text{HQC}(k) &= \ln(|\hat{\Sigma}_k|) + kn^2 \ln(\ln(T))/T \text{ (Hannan-Quinn)} \end{aligned}$$

- Estimação

Identificado o valor de p e supondo $\mathbf{a}_t \sim \mathcal{N}(\mathbf{0}, \Sigma)$, podemos estimar os coeficientes por máxima verossimilhança. Neste caso, os estimadores de MQ são equivalentes a estimadores de MV condicionais.

No caso de um VAR(1), os EMV condicionais são obtidos maximizando-se

$$\begin{aligned} \ell = & -\frac{n(T+1)}{2} \ln(2\pi) + \frac{(T-1)}{2} \ln |\Sigma^{-1}| \\ & -\frac{1}{2} \sum_{t=2}^T (\mathbf{X}_t - \Phi \mathbf{X}_{t-1})' \Sigma^{-1} (\mathbf{X}_t - \Phi \mathbf{X}_{t-1}), \end{aligned}$$

obtendo-se

$$\begin{aligned} \hat{\Phi} &= \left[\sum_{t=2}^T \mathbf{X}_t \mathbf{X}_{t-1}' \right] \left[\sum_{t=2}^T \mathbf{X}_{t-1} \mathbf{X}_{t-1}' \right]^{-1}, \\ \hat{\Sigma} &= \frac{1}{T} \sum_{t=1}^T \hat{\mathbf{a}}_t (\hat{\mathbf{a}}_t)', \\ \hat{\mathbf{a}}_t &= \mathbf{X}_t - \hat{\Phi} \mathbf{X}_{t-1}. \end{aligned}$$

No caso geral de um VAR(p), os EMV condicionais são obtidos por métodos de maximização numérica.

- Diagnóstico

Para testar se o modelo é adequado, usamos os resíduos para construir a versão

multivariada da estatística de Box-Ljung-Pierce, dada por

$$Q(m) = T^2 \sum_{\tau=1}^m \frac{1}{T - \tau} \text{tr}(\hat{\Gamma}(\tau)' \hat{\Gamma}(0)^{-1} \hat{\Gamma}(\tau) \hat{\Gamma}(0)^{-1}), \quad (24)$$

que sob H_0 : a série \mathbf{a}_t é ruído branco, tem distribuição $\chi^2(n^2(m - p))$. Para que o número de graus de liberdade seja positivo, m deve ser maior do que p .

- Previsão

Considere o VAR(1) dado em (17) e suponha que o parâmetro Φ seja conhecido. A previsão de origem T e horizonte h é dada por

$$\hat{\mathbf{X}}_T(h) = \Phi \hat{\mathbf{X}}_T(h - 1),$$

da qual segue

$$\hat{\mathbf{X}}_T(h) = \mathbf{\Phi}^h \mathbf{X}_T, \quad h = 1, 2, \dots \quad (25)$$

Como

$$\mathbf{X}_{t+h} = \mathbf{\Phi} \mathbf{X}_{T+h-1} + \mathbf{a}_{T+h},$$

temos que o erro de previsão h passos a frente é dado por

$$\mathbf{e}_T(h) = \mathbf{X}_{t+h} - \hat{\mathbf{X}}_T(h) = \sum_{j=0}^{h-1} \mathbf{\Phi}^j \mathbf{a}_{T+h-j}, \quad (26)$$

de modo que o erro quadrático médio do previsor (25) fica

$$\Sigma(h) = \text{EQMP}(h) = \sum_{j=0}^{h-1} \mathbf{\Phi}^j \Sigma (\mathbf{\Phi}^j)'. \quad (27)$$

Considerando, agora, o modelo VAR(p), com parâmetros supostos conhecidos, \mathbf{a}_t uma seqüência i.i.d. e $\mathcal{F}_t = \{\mathbf{X}_s : s \leq t\}$, obtemos

$$E(\mathbf{X}_{t+h}|\mathcal{F}_t) = \Phi_0 + \Phi_1 E(\mathbf{X}_{t+h-1}|\mathcal{F}_t) + \dots + \\ + \Phi_p E(\mathbf{X}_{t+h-p}|\mathcal{F}_t),$$

pois $E(\mathbf{a}_{t+h}|\mathcal{F}_t) = 0$, para todo $h > 0$.

Para $h = 1$ obtemos

$$\hat{\mathbf{X}}_t(1) = \Phi_0 + \Phi_1 \mathbf{X}_t + \dots + \Phi_p \mathbf{X}_{t-p+1},$$

e para $h = 2$ temos

$$\hat{\mathbf{X}}_t(2) = \Phi_0 + \Phi_1 \hat{\mathbf{X}}_t(1) + \Phi_2 \mathbf{X}_t + \dots + \Phi_p \mathbf{X}_{t-p+2},$$

de modo que as previsões podem ser obtidas recursivamente.

Neste caso, o erro de previsão de horizonte h é dado por

$$\mathbf{e}_T(h) = \sum_{j=0}^{h-1} \Psi_j \mathbf{a}_{T+h-j}, \quad (28)$$

onde as matrizes Ψ_j são obtidas recursivamente por

$$\Psi_j = \sum_{k=1}^{p-1} \Psi_{j-k} \Phi_k, \quad (29)$$

com $\Psi_0 = \mathbf{I}_n$ e $\Phi_j = 0, j > p$. Segue-se que a matriz de EQM de previsão fica

$$\Sigma(h) = \sum_{j=0}^{p-1} \Psi_j \Sigma \Psi_j'. \quad (30)$$

- Quando os parâmetros do modelo VAR(p) são estimados, o melhor preditor de X_{T+h} é agora dado por

$$\tilde{X}_T(h) = \hat{\Phi}_0 + \hat{\Phi}_1 \tilde{X}_T(h-1) + \dots + \hat{\Phi}_p \tilde{X}_T(h-p), \quad h > 1. \quad (31)$$

Neste caso, a matriz de EQM de previsão torna-se

$$\hat{\Sigma}(h) = \Sigma(h) + EQM(\mathbf{X}_{T+h} - \tilde{X}_T(h)). \quad (32)$$

Na prática, o segundo termo em (32) é ignorado e $\hat{\Sigma}(h)$ é calculada por

$$\hat{\Sigma}(h) = \sum_{j=0}^{h-1} \hat{\Psi}_j \hat{\Sigma} \hat{\Psi}_j', \quad (33)$$

com $\hat{\Psi}_j = \sum_{k=1}^{p-1} \hat{\Psi}_{j-k} \hat{\Phi}_k$. Lütkepohl (1991) dá uma aproximação para o segundo membro de (32).

- **Exemplo 5.** Retornemos ao exemplo 4 e ajustemos um modelo VAR(p) à série X_t , onde:

X_{1t} : retornos diários do Ibovespa,

X_{2t} : retornos diários da Petrobrás, $T = 1498$.

Na Tabela 7.3 temos os resultados de ajustes de modelos auto-regressivos até ordem 8. Usando os valores de (23) ou dos AIC correspondentes, selecionamos a ordem $p = 6$. A tabela foi obtida usando-se o SCA.

Tabela 7.3 - Estatísticas resultantes de ajustes de modelos VAR(p), $p = 1, \dots, 8$, para os retornos diários do Ibovespa e Petrobrás.

- **EVIEWS:** fornece o modelo VAR(6):

$$X_{1t} = 0,1018X_{1,t-1} - 0,1113X_{1,t-6} +$$

$$+ 0,0790X_{2,t-3} + a_{1t},$$

$$X_{2t} = -0,1348X_{1,t-6} + 0,1111X_{2,t-1} - \\ -0,0973X_{2,t-3} + a_{2,t}.$$

retornos diários da Petrobrás: influenciados por valores passados dos retornos diários do Ibovespa, ou seja, dependem de preços do mercado financeiro;

retornos do Ibovespa: influenciados por valores defasados dos retornos da Petrobrás, o que é razoável, dado que as ações da Petrobrás fazem parte do índice.

Seque-se que há uma relação de “feedback” entre as duas séries.

O coeficiente de correlação entre as duas séries é 0,83, o que mostra uma relação contemporânea forte.

6. Causalidade de Granger

- Para sistemas temporais, Granger (1969) define causalidade em termos de *previsibilidade*: a variável X causa a variável Y , com respeito a um dado universo de informação (que inclui X e Y), se o presente de Y pode ser previsto mais eficientemente usando valores passados de X , do que não usando esse passado, toda e qualquer outra informação disponível (incluindo valores passados de Y) sendo usada em ambos os casos. A definição não requer que o sistema seja linear; se o for, as previsões serão lineares.
- Seja $\{A_t, t = 0, \pm 1, \pm 2, \dots\}$ o conjunto de informação relevante até (e incluindo) o instante t , contendo pelo menos X_t, Y_t . Defina $\bar{A}_t = \{A_s : s < t\}$, $\overline{\bar{A}}_t = \{A_s : s \leq t\}$, e definições análogas para \bar{X}_t, \bar{Y}_t , etc. Seja $P_t(Y|B)$ o preditor de EQM

mínimo de Y_t , usando o conjunto de informação B e $\sigma^2(Y|B)$ o correspondente EQM do preditor.

• **Definição 1.** Dizemos que:

(a) $X_t \rightarrow Y_t$: X_t *causa* Y_t no sentido de Granger se

$$\sigma^2(Y_t|\bar{A}_t) < \sigma^2(Y_t|\bar{A}_t - \bar{X}_t).$$

Ou seja, Y_t pode ser melhor prevista usando toda a informação disponível, incluindo o passado de Y_t e X_t .

Dizemos também que X_t é *exógena* ou *antecedente* a Y_t .

(b) $X_t \Rightarrow Y_t$: X_t *causa instantaneamente* Y_t no sentido de Granger se:

$$\sigma^2(Y_t|A_t, \bar{\bar{X}}_t) < \sigma^2(Y_t|\bar{A}_t)$$

Ou seja, o valor presente de Y_t é melhor previsto se o valor presente de X_t for incluído.

(c) Há *feedback*, e escrevemos $X_t \leftrightarrow Y_t$, se X_t causa Y_t e Y_t causa X_t .

(d) Há *causalidade unidirecional* de X_t para Y_t se $X_t \rightarrow Y_t$ e *não há feedback*.

- É fácil ver que se $X_t \Rightarrow Y_t$, então $Y_t \Rightarrow X_t$. Portanto usualmente dizemos que há causalidade instantânea entre X_t e Y_t .

- Há várias propostas para operacionalizar as definições anteriores:

Pierce e Haugh (1977) propõem ajustar modelos ARIMA a transformações adequadas de ambas as séries e depois estabelecer padrões de causalidade entre os resíduos por meio de correlações cruzadas. Veja também Layton (1984).

Hsiao (1979) sugere ajustar modelos auto-regressivos via AIC.

No caso de mais de duas séries, Boudjellaba et al. (1992) sugerem ajustar modelos VARMA às séries.

Uma resenha desses procedimentos é feita por Cunha (1997).

- Trataremos do assunto por meio da representação VAR da série multivariada \mathbf{X}_t , de ordem $n \times 1$. A representação MA do processo é dada por

$$\mathbf{X}_t = \boldsymbol{\mu} + \boldsymbol{\Psi}(B)\mathbf{a}_t, \quad \boldsymbol{\Psi}_0 = \mathbf{I}_n. \quad (34)$$

Suponha que

$$\mathbf{X}_t = \begin{bmatrix} \mathbf{Y}_t \\ \mathbf{Z}_t \end{bmatrix},$$

onde \mathbf{Y}_t é um vetor $r \times 1$ e \mathbf{Z}_t é um vetor $s \times 1$, $r + s = n$. Então podemos escrever

$$\mathbf{X}_t = \begin{bmatrix} \mathbf{Y}_t \\ \mathbf{Z}_t \end{bmatrix} = \begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix} + \begin{bmatrix} \boldsymbol{\Psi}_{11}(B) & \boldsymbol{\Psi}_{12}(B) \\ \boldsymbol{\Psi}_{21}(B) & \boldsymbol{\Psi}_{22}(B) \end{bmatrix} \begin{bmatrix} \mathbf{a}_{1t} \\ \mathbf{a}_{2t} \end{bmatrix}, \quad (35)$$

particionando $\boldsymbol{\mu}$, $\boldsymbol{\Psi}(B)$ e \mathbf{a}_t de acordo com a partição de \mathbf{X}_t . Se houver causalidade unidirecional de \mathbf{Y}_t para \mathbf{Z}_t , isto é, se \mathbf{Z}_t for melhor prevista pelo presente e passado de \mathbf{Y}_t , mas não o contrário, deveremos ter $\boldsymbol{\Psi}_{12}(B) = 0$ e obteremos

$$\begin{aligned} \mathbf{Y}_t &= \boldsymbol{\mu}_1 + \boldsymbol{\Psi}_{11}(B)\mathbf{a}_{1t}, \\ \mathbf{Z}_t &= \boldsymbol{\mu}_2 + \boldsymbol{\Psi}_{21}(B)\mathbf{a}_{1t} + \boldsymbol{\Psi}_{22}(B)\mathbf{a}_{2t}. \end{aligned}$$

- Na realidade, é possível demonstrar o seguinte resultado, que é uma caracterização de não-causalidade de Granger.

Note que $\Psi(B) = \mathbf{I}_n + \Psi_1 B + \Psi_2 B^2 + \dots$
e

$$\Psi_i = \begin{bmatrix} \Psi_{11,i} & \Psi_{12,i} \\ \Psi_{21,i} & \Psi_{22,i} \end{bmatrix}, \quad i = 1, 2, \dots$$

- **Proposição 4.** O previsor ótimo de \mathbf{Y}_t baseado em $\overline{\overline{\mathbf{X}}}_t$ é igual ao previsor ótimo de \mathbf{Y}_t baseado em $\overline{\overline{\mathbf{Y}}}_t$ se e somente se $\Psi_{12,i} = \mathbf{0}$, $i = 1, 2, \dots$
- Do ponto de vista prático, convém considerar o modelo VAR de ordem finita, ou seja,

$$\mathbf{X}_t = \begin{bmatrix} \mathbf{Y}_t \\ \mathbf{Z}_t \end{bmatrix} = \begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix} + \begin{bmatrix} \Phi_{11,1} & \Phi_{12,1} \\ \Phi_{21,1} & \Phi_{22,1} \end{bmatrix} \begin{bmatrix} \mathbf{Y}_{t-1} \\ \mathbf{Z}_{t-1} \end{bmatrix} + \begin{bmatrix} \Phi_{11,p} & \Phi_{12,p} \\ \Phi_{21,p} & \Phi_{22,p} \end{bmatrix} \begin{bmatrix} \mathbf{Y}_{t-p} \\ \mathbf{Z}_{t-p} \end{bmatrix} + \begin{bmatrix} \mathbf{a}_{1t} \\ \mathbf{a}_{2t} \end{bmatrix}, \quad (36)$$

e a condição da Proposição 4 estará satisfeita se e somente se $\Phi_{12,i} = \mathbf{0}$, $i = 1, 2, \dots, p$. Ou

seja, se \mathbf{X}_t seguir um modelo VAR(p), com matriz de covariâncias não-singular, então \mathbf{Z}_t não causa \mathbf{Y}_t se e somente se $\Phi_{12,i} = \mathbf{0}$, $i = 1, 2, \dots, p$.

- Uma caracterização de não-existência de causalidade instantânea é dada pela proposição seguinte. A prova é dada em Lütkepohl (1991).

Proposição 5. Se \mathbf{X}_t for como em (36), com matriz de covariâncias não singular, então *não existe causalidade instantânea* entre \mathbf{Y}_t e \mathbf{Z}_t se e somente se $E(\mathbf{a}_{1t}\mathbf{a}'_{2t}) = 0$.

- A equação (36) pode ser escrita como:

$$\mathbf{Y}_t = \mu_1 + \sum_{i=1}^p \Phi_{11,i} \mathbf{Y}_{t-i} + \sum_{i=1}^p \Phi_{12,i} \mathbf{Z}_{t-i} + \mathbf{a}_{1t}, \quad (37)$$

$$\mathbf{Z}_t = \mu_2 + \sum_{i=1}^p \Phi_{21,i} \mathbf{Y}_{t-i} + \sum_{i=1}^p \Phi_{22,i} \mathbf{Z}_{t-i} + \mathbf{a}_{2t}. \quad (38)$$

Suponha, também, a matriz Σ particionada como

$$\Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix},$$

sendo que $\Sigma_{ij} = E(\mathbf{a}_{it}\mathbf{a}'_{jt})$, $i, j = 1, 2$. Então:

(i) \mathbf{Z}_t não causa $\mathbf{Y}_t \leftrightarrow \Phi_{12,i} = 0$, para todo i ;

(ii) \mathbf{Y}_t não causa $\mathbf{Z}_t \leftrightarrow \Phi_{21,i} = 0$, para todo i .

- **Proposição 6** (i) \mathbf{Z}_t não causa $\mathbf{Y}_t \leftrightarrow |\Sigma_{11}| = |\Sigma_1|$, onde $\Sigma_1 = E(\mathbf{c}_{1t}\mathbf{c}'_{1t})$ é obtida da regressão restrita

$$\mathbf{Y}_t = \nu_1 + \sum_{i=1}^p \mathbf{A}_i \mathbf{Y}_{t-i} + \mathbf{c}_{1t}. \quad (39)$$

(ii) \mathbf{Y}_t não causa $\mathbf{Z}_t \leftrightarrow |\Sigma_{22}| = |\Sigma_2|$, onde $\Sigma_2 = E(\mathbf{c}_{2t}\mathbf{c}'_{2t})$ é obtida da regressão restrita

$$\mathbf{Z}_t = \boldsymbol{\nu}_2 + \sum_{i=1}^p \mathbf{C}_i \mathbf{Z}_{t-i} + \mathbf{c}_{2t}. \quad (40)$$

As regressões (37)-(40) podem ser estimadas por MQO e a partir dos resíduos de MQ as matrizes de covariâncias envolvidas são estimadas por:

$$\hat{\boldsymbol{\Sigma}}_i = (T - p)^{-1} \sum_{t=p+1}^T \hat{\mathbf{c}}_{it} \hat{\mathbf{c}}'_{it},$$

$$\hat{\boldsymbol{\Sigma}}_{ii} = (T - p)^{-1} \sum_{t=p+1}^T \hat{\mathbf{a}}_{it} \hat{\mathbf{a}}'_{it}, \quad i = 1, 2.$$

- Os testes e respectivas estatísticas da razão de verossimilhanças são dados por:

(i) $H_{01} : \boldsymbol{\Phi}_{12,i} = \mathbf{0}$, para todo i (\mathbf{Z}_t não causa \mathbf{Y}_t),

$$RV_1 = (T - p)[\log |\hat{\boldsymbol{\Sigma}}_1| - \log |\hat{\boldsymbol{\Sigma}}_{11}|] \sim \chi^2(prs).$$

(ii) $H_{02} : \Phi_{21,i} = 0$, para todo i (\mathbf{Y}_t não causa \mathbf{Z}_t),

$$RV_2 = (T - p)[\log |\hat{\Sigma}_2| - \log |\hat{\Sigma}_{22}|] \sim \chi^2(prs).$$

- **Exemplo 6.** Para o exemplo 5, vemos que $X_{1t} \rightarrow X_{2t}$, ou seja, retornos diários do Ibovespa causam, no sentido de Granger, retornos diários da Petrobrás. Também, $X_{2t} \rightarrow X_{1t}$. Logo, há “feedback” entre as duas séries de retornos.

Exemplo 7. Um modelo VAR(1) para as séries de retornos diários do Banespa (X_{1t}) e da Petrobrás (X_{2t}) é dado por

$$X_{1t} = 0,122X_{1,t-1} + a_{1t},$$

$$X_{2t} = 0,333X_{1,t-1} + 0,081X_{2,t-1} + a_{2t},$$

sendo $\begin{bmatrix} 1 & 0,007 \\ 0,007 & 1 \end{bmatrix}$ a matriz de correlação estimada. Vemos que Banespa causa Petrobrás, mas não o contrário.

Escrevendo o modelo na forma estrutural, obtemos

$$X_{2t} = 0,005X_{1t} + 0,332X_{1,t-1} + 0,081X_{2,t-1} + b_{2t}, \quad (41)$$

o que mostra que provavelmente não há causalidade instantânea entre as séries, dada a magnitude do coeficiente de X_{1t} . Mas um teste formal teria que ser feito.