

Macroeconometria 1

Mestrado em Economia Monetária e Financeira

Mestrado em Economia

ISCTE-IUL, Dep. de Economia

MODELOS LINEARES (ARIMA)

Luís Filipe Martins

luis.martins@iscte.pt

<http://iscte.pt/~lfsm>

Departamento de Métodos Quantitativos,
ISCTE-IUL, Escola de Gestão

Lisboa, Setembro de 2009

1 Motivação

- (Parte 1: Análise Univariada) Evidência Empírica (*stylized fact*): As variáveis de natureza econômica apresentam dependência temporal (memória) a três níveis:
 - (a) A memória dissipa-se rapidamente (função geométrica) com o passado.
 - (b) A memória é longa (função hiperbólica), i.e., há dependência relativamente significativa até um passado longínquo.
 - (c) A memória é permanente e significativa.
- (Parte 2: Análise Multivariada - Ver VAR e Cointegração)

2 Introdução e Algumas Definições

- Objectivo: Modelar Time Series (séries cronológicas). *Exemplo*: Modelos ARIMA
 - Simplicidade.
 - Ajustamento e Previsão.
 - Lineares; Univariados e (Não)Estacionaridade.
- Time Series (ou processo estocástico), $\{Y_t\}_{t=1}^T = \{Y_1, Y_2, \dots, Y_T\}$ é uma sequência de variáveis aleatórias.
- Realização da Time Series, $\{y_t\}_{t=1}^T = \{y_1, y_2, \dots, y_T\}$ é o gráfico com as observações de uma variável time series.

Example 1 *taxa de desemprego, inflação, índice PSI-20, ...*

- Y_t é estritamente estacionário se a função distribuição conjunta de $\{Y_{t_1}, \dots, Y_{t_m}\}$ não muda com o tempo.
- Y_t é estacionário em covariância se para todo t e l , $E(Y_t) = \mu$ e $Cov(Y_t, Y_{t-l}) = \Gamma(l)$.
- estritamente estacionário \Rightarrow estacionário em covariância.
- O processo estocástico estacionário Y_t possui memória que se dissipa se $\Gamma(l) \rightarrow 0$ quando $l \rightarrow \infty$.
- Notação: Para Y_t univariado, $Cov(Y_t, Y_{t-l}) = \gamma_l$.
- Variância e Autocorrelação: $\gamma_0 = V(Y_t)$; $Corr(Y_t, Y_{t-l}) = \rho_l = \frac{\gamma_l}{\gamma_0}$.
- ρ_l é a função autocorrelação (FAC).
- Função de autocorrelação parcial (FACP): efeito que o passado do processo tem sobre o mesmo, *ceteris paribus*, i.e. coeficientes de correlação parcial através de uma autoregressão.
- Momentos Amostrais (equivalente aos momentos da população para uma amostra de dimensão T):

$$\bar{y} = \frac{1}{T} \sum_{t=1}^T y_t; \hat{\gamma}_l = \frac{1}{T} \sum_{t=l+1}^T (y_t - \bar{y})(y_{t-l} - \bar{y}).$$

- Operador Desfasamento (Lag), L :

$$LY_t = Y_{t-1}, LY_{t-1} = Y_{t-2}, \dots$$
$$L^2Y_t = L(Lx_t) = LY_{t-1} = Y_{t-2}; L^jY_t = Y_{t-j}.$$

- Primeiras Diferenças:

$$(1 - L)Y_t = Y_t - Y_{t-1} = \Delta Y_t;$$
$$L\Delta Y_t = \Delta LY_t = \Delta Y_{t-1} = Y_{t-1} - Y_{t-2}, \dots$$

3 Modelos ARMA

- Y_t é estacionário e sem componente sazonal.

3.1 White Noise (Ruido Branco)

- $Y_t \equiv \varepsilon_t \sim wn(0, \sigma_\varepsilon^2)$, o seu estudo justifica-se pela sua simplicidade e base de construção de modelos mais sofisticados.

- ε_t white noise gaussiano se $\varepsilon_t \sim i.i.d.N(0, \sigma_\varepsilon^2)$.

- Propriedades:

$$E(\varepsilon_t) = 0, V(\varepsilon_t) = \gamma_0 = \sigma_\varepsilon^2 < \infty, Cov(\varepsilon_t, \varepsilon_{t-l}) = \gamma_l = 0, l \neq 0.$$

- FAC: $\rho_0 = 1; \rho_l = 0, l \neq 0$.

- Teorema da Decomposição de Wold (para os modelos ARMA):
 Y_t estacionário em covariância \Rightarrow

$$Y_t = \mu + \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j} = \mu + \varepsilon_t + \psi_1 \varepsilon_{t-1} + \psi_2 \varepsilon_{t-2} + \dots,$$

em que $\sum \psi_j^2 < \infty, \psi_0 = 1$.

3.2 Modelo Autoregressivo (AR)

- Y_t é uma combinação linear do seu passado:

$$AR(1) : Y_t = c + \phi Y_{t-1} + \varepsilon_t, \varepsilon_t \sim wn(0, \sigma_\varepsilon^2), t = 1, \dots, T.$$

- Parcimónio e capta a dependência/memória das séries. Para

$$c = 0,$$

$$\begin{aligned} Y_t &= \phi(\phi Y_{t-2} + \varepsilon_{t-1}) + \varepsilon_t = \dots \\ &= \phi^j Y_{t-j} + \varepsilon_t + \phi \varepsilon_{t-1} + \dots + \phi^{j-1} \varepsilon_{t-(j-1)} \\ &\equiv \phi^t Y_0 + \sum_{j=0}^{t-1} \phi^j \varepsilon_{t-j} = \phi^t Y_0 + \sum_{i=1}^t \phi^{t-i} \varepsilon_i. \end{aligned}$$

- Se $|\phi| < 1$ então " $\lim_{j \rightarrow \infty} \phi^j Y_{t-j} \rightarrow 0$ " e, por isso,

$$Y_t = \sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j} = \sum_{i=1}^{\infty} \phi^{t-i} \varepsilon_i.$$

- Portanto, para que o $AR(1)$ seja estacionário e de memória que se dissipa, $|\phi| < 1$. Neste caso,

$$E(Y_t) = 0; V(Y_t) = \gamma_0 = \frac{\sigma_\varepsilon^2}{1 - \phi^2}; \gamma_l = \phi^l \gamma_0; \rho_l = \phi^l.$$

- Nota: Se $|\phi| < 1$, $\frac{1}{1-\phi L} = 1 + \phi L + \phi^2 L^2 + \dots$
- FAC: Decaimento geométrico/exponencial \rightarrow Memória curta, $|\rho_l| \leq C r^{|l|}$, com $0 < r < 1, C > 0$.
- Mais geral,

$$\begin{aligned} AR(p) \quad : \quad Y_t &= c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \\ &\Leftrightarrow \phi(L) Y_t = c + \varepsilon_t. \end{aligned}$$

- Polinómio autoregressivo: $\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$
- Estacionaridade se as raízes de $\phi(L)$ estão fora do círculo

unitário, i.e., a(s) solução(ões) de $1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p = 0$. Condição necessária para estacionaridade: $\phi_1 + \phi_2 + \dots + \phi_p < 1$.

Example 2 $AR(2)$: $\phi_1 + \phi_2 < 1$, $\phi_2 - \phi_1 < 1$, $|\phi_2| < 1$, $\phi_1, \phi_2 \in \mathfrak{R}$.

- FAC: Premultiplicar as equações de Yule-Walker, $Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + \varepsilon_t$, por $Y_{t-j} - \mu$ e aplicar o valor esperado:

$$\begin{aligned}\gamma_l &= \phi_1 \gamma_{l-1} + \phi_2 \gamma_{l-2} + \dots + \phi_p \gamma_{l-p}, & l > 0 \\ \gamma_l &= \phi_1 \gamma_1 + \phi_2 \gamma_2 + \dots + \phi_p \gamma_p + \sigma^2, & l = 0 \text{ e} \\ \rho_l &= \phi_1 \rho_{l-1} + \phi_2 \rho_{l-2} + \dots + \phi_p \rho_{l-p},\end{aligned}$$

- FACP: 1 para $l = 0$; ϕ_j para $l = j = 1, \dots, p$ e 0 para $l > p$.

3.3 Modelo Médias Móveis (MA)

- Y_t é uma função linear dos choques do presente e passado.
- Processo médias móveis de primeira ordem:

$$MA(1) : Y_t = \mu + \varepsilon_t - \theta \varepsilon_{t-1}, \varepsilon_t \sim wn(0, \sigma_\varepsilon^2), t = 1, \dots, T.$$

- Propriedades:

$$\begin{aligned}E(Y_t) &= \mu; V(Y_t) = \gamma_0 = \sigma_\varepsilon^2(1 + \theta^2); \\ \gamma_1 &= -\theta \sigma_\varepsilon^2; \gamma_l = 0, l > 1 \\ \rho_1 &= -\frac{\theta}{1 + \theta^2}; \rho_l = 0, l > 1.\end{aligned}$$

- Conclusão: $MA(1)$ é estacionário para qualquer valor real de μ, θ e tem memória curta (até ao lag 1). A FAC é zero para $l > 1$.
- Se $|\theta| < 1$, o $MA(1)$ é invertível e corresponderá a um $AR(\infty)$, $Y_t = \varepsilon_t - \theta Y_{t-1} - \theta^2 Y_{t-2} + \dots$. Portanto, a FACP tem um decaimento exponencial para zero.
- Invertibilidade: Raiz do polinómio médias móveis $\theta(L) = 1 - \theta L$ está fora do círculo unitário.
- Mais geral,

$$MA(q) : Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \Leftrightarrow Y_t = \mu + \theta(L) \varepsilon_t.$$

$$\theta(L) = 1 - \theta_1 L - \dots - \theta_q L^q.$$

- FAC zero para $l > q$; FACP tem um decaimento exponencial para zero se $\theta(L)$ é invertível.

3.4 Modelo ARMA

- Combina AR e MA .

$$ARMA(p, q) : \phi(L)Y_t = c + \theta(L)\varepsilon_t.$$

- $ARMA(1, 1) : Y_t = \phi Y_{t-1} + \varepsilon_t - \theta \varepsilon_{t-1}$, tem FAC $\rho_1 = \frac{(1-\phi\theta)(\phi-\theta)}{1+\theta^2-2\phi\theta}$, $\rho_l = \phi \rho_{l-1}$.

| Modelo | FAC | FACP |
|--------|---|---|
| AR | decaimento exponencial ou de amortecimento sinusoidal | zero para $l > p$ |
| MA | zero para $l > q$ | decaimento exponencial ou de amortecimento sinusoidal |
| $ARMA$ | decaimento exponencial ou de amortecimento sinusoidal | decaimento exponencial ou de amortecimento sinusoidal |

4 Modelos ARIMA e SARIMA

4.1 ARIMA

- Y_t é não estacionário e sem componente sazonal.
- Definição: $Y_t \sim I(0)$ se o processo Y_t é estacionário. O processo Y_t é $I(d)$ se são necessárias d primeiras diferenças para o tornar estacionário: $Y_t \sim I(d) : \Delta^d Y_t \sim I(0)$. O processo $I(d)$ diz-se que tem d raízes unitárias (no seu polinómio autoregressivo).
- Muitas variáveis económicas e financeiras são não estacionárias. Apresentam uma tendência. Estocástica ou Determinística? Aqui, é estocástica. Normalmente, $d = 1$; alguns exemplos de $d = 2$.

Example 3 $AR(1)$, $Y_t = \alpha + \rho Y_{t-1} + \varepsilon_t$ é estacionário se $|\rho| < 1 : \Delta Y_t = (\rho - 1) \left(Y_{t-1} - \frac{\alpha}{1-\rho} \right) + \varepsilon_t$. Se $\rho = 1$, $\Delta Y_t = \varepsilon_t$.

Example 4 *Passeio Aleatório sem deriva*: $Y_t = Y_{t-1} + \varepsilon_t \Leftrightarrow Y_t = Y_0 + \sum_{j=1}^t \varepsilon_j$.

Example 5 *Passeio Aleatório com deriva*: $Y_t = \alpha + Y_{t-1} + \varepsilon_t \Leftrightarrow \Delta Y_t = \alpha + \varepsilon_t \Leftrightarrow Y_t = Y_0 + \alpha t + \sum_{j=1}^t \varepsilon_j$.

- FAC de Y_t não decai para zero pois o efeito de um choque é permanente. Na verdade, a FAC teórica não existe. MAS a FAC de $\Delta^d Y_t$ decai para zero. Memória infinita.
- Conclusão: o processo Y_t é um $ARIMA(p, d, q)$ se, não sendo estacionário em níveis, torna-se estacionário após d diferenças. Por exemplo, o processo $ARIMA(p, 1, q)$ é estacionário nas primeiras diferenças pois remove a tendência estocástica.
- Concretamente,

$$ARIMA(p, d, q) : \phi(L)\Delta^d Y_t = c + \theta(L)\varepsilon_t.$$

- Identificação de p, q : FAC e FACP do processo $\Delta^d Y_t$.
- Identificação de d : Testes de raízes unitárias (ver apontamentos sobre raízes unitárias) ...
- Condições de Estacionaridade e Invertabilidade de $\Delta^d Y_t$: Raízes dos polinómios $\phi(L)$ e $\theta(L)$.

4.2 SARIMA

- Y_t tem componente sazonal e é/não é estacionário ($d = 0$ versus $d > 0$) : $SARIMA(p, d, q) \times (P, D, Q)_S$:

$$\phi(L)\Phi(L^S) (1 - L^S)^D (1 - L)^d Y_t = c + \theta(L)\Theta(L^S)\varepsilon_t,$$

$$\begin{aligned}\Phi(L^S) &= 1 - \Phi_S L^S - \Phi_{2S} L^{2S} - \dots - \Phi_{PS} L^{PS} \\ \Theta(L^S) &= 1 - \Theta_S L^S - \Theta_{2S} L^{2S} - \dots - \Theta_{PS} L^{PS}.\end{aligned}$$

Example 6 $SARIMA(0, 1, 1) \times (0, 1, 1)_3$

- S define a frequência dos dados: Dados mensais para $S = 12, \dots$
- Identificação de d, D : Testes de raízes unitárias simples e sazonais ...
- Ao processo $(1 - L^S)^D (1 - L)^d Y_t$:
 - Identificação de P, Q : FAC e FACP nos lags sazonais, $S, 2S, 3S, \dots$
 - Identificação de p, q : FAC e FACP nos lags não sazonais.

5 Metodologia de Box-Jenkins

- Na prática, temos um método: Transformar os dados (log estabiliza a variância; diferenças estacionariza a série;...), identificação do processo (d,p,q,...), estimação dos parâmetros, inferência/testes, previsão in-sample e out-of-sample.
- PASSO 1: Transformar os dados
 - Estabilizar a variância (transformação de Box-Cox) e estacionar a série (d, D).
- PASSO 2: Identificação do processo
 - Identificação de p, q, P, Q pela comparação entre as FAC e FACP Empíricas e as FAC e FACP Teóricas.

- FAC Empírica (correlograma):

$$\hat{\mu} = \frac{1}{T} \sum_{t=1}^T y_t; \hat{\gamma}_0 = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{\mu})^2$$

$$\hat{\gamma}_l = \frac{1}{T} \sum_{t=l+1}^T (y_t - \hat{\mu})(y_{t-l} - \hat{\mu}); \hat{\rho}_l = \frac{\hat{\gamma}_l}{\hat{\gamma}_0}.$$

- Bandas da FAC Empírica: $\pm \frac{2}{\sqrt{T}}$ porque $\sqrt{T}\hat{\rho} \xrightarrow[H_0]{d} N(0, 1)$.
- FACP Empírica: Estimação *AR*!
- Estratégia: Específico para Geral (Down-Top).
- PASSO 3: Estimação
 - OLS, MLE, ...

- PASSO 4: Inferência/Testes de Diagnóstico
 - Testes sobre os parâmetros do modelo, ...
 - Resíduos Ruido Branco? Testes de Autocorrelação aos resíduos do modelo (DW, BP, LB, ...), ...
 - Critérios de Seleção de modelos (AIC, BIC, ...), ...
- PASSO 5: Previsão
 - In-sample e Out-of-sample ...
 - Representação $AR \rightarrow$ Valor esperado condicional: $\hat{y}_{t+k} = E(y_{t+k}|y_t, y_{t-1}, \dots)$. Eg: $AR(p)$:

$$\hat{y}_{t+k} = c + \phi_1 E(y_{t+k-1}|y_t, y_{t-1}, \dots) + \phi_2 E(y_{t+k-2}|y_t, y_{t-1}, \dots) + \dots + \phi_p E(y_{t+k-p}|y_t, y_{t-1}, \dots).$$

Note-se que, por exemplo, $E(y_t|y_t, y_{t-1}, \dots) = y_t$ mas que $E(y_{t+1}|y_t, y_{t-1}, \dots) \equiv \hat{y}_{t+1} \neq y_{t+1}$.

- Erro de previsão In-sample: $e_t = y_t - \hat{y}_t$.
- Performance do modelo: Minimizar medidas

$$RMSE, MAE, MAPE, U, \dots$$