

Métodos Qualitativos

**Análise de séries temporais:
Modelos de Box-Jenkins**
Profa. Dra. Liane Werner

Metodologia de Box-Jenkins

- Para os modelos de decomposição e os modelos de suavização exponencial é usual assumir que os erros t ($t = 1, \dots, T$) são não correlacionados,
- o que implica que as observações também não estão correlacionadas.
- Esta suposição raramente ocorre na prática.
- Correlação serial é esperada uma vez que os dados são coletados seqüencialmente no tempo.

2

Metodologia de Box-Jenkins

- Os modelos que capturam esta estrutura de correlação são uma classe especial de modelos
- chamados de modelos *Autoregressivos Integrados de Médias Móveis (ARIMA)*.
- Estes modelos apresentam uma variedade de diferentes estruturas de correlação,
- se esta estrutura de correlação for bem modelada, ele fornecerá boas previsões.

3

Metodologia de Box-Jenkins

- os modelos ARIMA foram popularizados por George Box e Gwilym Jenkins no início dos anos 70,
- e seus nomes tem sido usado como sinônimo destes modelos.
- Box e Jenkins colocaram de forma compreensiva a informação necessária para entender e usar os modelos ARIMA para séries temporais univariadas.

4

Conceitos Importantes

- Modelos Estocásticos:
 - a idéia de usar modelos matemáticos para descrever o comportamento de fenômenos físicos esta bem estabelecida.
 - Por exemplo, quando se lança um míssil é possível conhecer sua trajetória se sua direção e a velocidade são conhecidas. Ao precisar a trajetória, tem-se um modelo determinístico.
 - Fatores desconhecidos podem ocorrer - tal como a velocidade do vento que pode desviar o míssil de seu curso.

5

Conceitos Importantes

- Quando o comportamento de uma série temporal está sujeita a fatores desconhecidos, ou seja, a efeitos aleatórios,
- Pode-se encontrar um modelo que é obtido com base no cálculo de probabilidade. Tal modelo é chamado de estocástico.
- Um processo estocástico é caracterizado por uma família de variáveis aleatórias que descrevem a evolução de um fenômeno de interesse, neste caso a evolução temporal da série em estudo.

6


Conceitos Importantes

- *Modelo de Filtro Linear* :
 - Os modelos estocásticos são baseados na idéia de que séries temporais, em que valores sucessivos são altamente dependentes,
 - podem ser estimadas de séries provenientes de “choques” independentes ε_t .
 - Estes choques são aleatórios e provêm de uma distribuição fixa, usualmente assumida como Normal tendo média μ zero e variância σ_ε^2 .
 - A seqüência de variáveis aleatórias $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots$ é chamada de processo de ruído branco, ou simplesmente ruído branco.

7

Conceitos Importantes

- *Modelo de Filtro Linear* :
 - o ruído branco ε_t é transformado em Z_t pelo processo chamado filtro linear.
 - O filtro linear faz a soma ponderada das observações anteriores



$$Z_t = \mu + \psi(L)\varepsilon_t$$

onde: μ é o parâmetro que determina o nível da série;

L é o operador de defasagem, expresso por $L^k \varepsilon_t = \varepsilon_{t-k}$;

$\psi(L) = 1 + \psi_1 L + \psi_2 L^2 + \dots$ é o operador linear que transforma ε_t em Z_t .

8

Conceitos Importantes

- Modelos Estocásticos Estacionários:
 - é uma classe especial de processos estocásticos que assumem que o processo está em “equilíbrio”.
 - Em caso de estacionariedade, a distribuição de probabilidade para t_1, t_2, \dots, t_m deve ser a mesma distribuição de probabilidade para os tempos em qualquer tempo $t_{1+k}, t_{2+k}, \dots, t_{m+k}$, onde k é um deslocamento arbitrário ao longo do eixo do tempo.

9

Conceitos Importantes

- Modelos Estocásticos Estacionários:
 - a estacionariedade implica que não existe inclinação nos dados,
 - eles devem permanecer ao redor de uma linha horizontal ao longo do tempo.
 - Os dados flutuam ao redor de uma média constante, independente do tempo e
 - a variação das flutuações permanece essencialmente constante sobre o tempo.
- Modelos Não-Estacionários=> tendência ou variabilidade não constante.


10

Etapas para a construção dos modelos Box-Jenkins

- A construção dos modelos Box-Jenkins, é baseada em um ciclo iterativo,
- no qual a escolha do modelo é feita com base nos próprios dados.
- São três etapas para construção do modelo:
 - (i) identificação;
 - (ii) estimação e
 - (iii) verificação.
- Makridakis et al. (1998) esquematizaram as etapas para a construção de modelos

11

Etapas para a construção dos modelos Box-Jenkins




Fonte: Makridakis et al. (1998)

12

Preparação dos dados

Examinando a estacionariedade da série

- Para detectar se uma série é estacionária ou não, sugere-se o uso do **time plot** (gráfico de linha onde é plotada a variável em estudo contra o tempo).
- Se a série temporal é plotada e não existe evidência de mudanças na média sobre o tempo, então diz-se que a série é estacionária na média.
- Se o gráfico não mostra mudança na variação ao longo do tempo, então diz-se que a série é estacionária na variância




13

Preparação dos dados

Examinando a estacionariedade da série

- Se uma série apresenta uma certa inclinação ao longo do tempo ou então uma mudança de nível é por que a série é não-estacionária na média.




14

Preparação dos dados

Examinando a estacionariedade da série

- Uma série é não-estacionária na variância, quando esta não se mantém constante ao longo do tempo.



15

Preparação dos dados

Examinando a estacionariedade da série

- A forma analítica não é a única maneira de se detectar a estacionariedade de uma série,
- existem testes estatísticos, chamados de teste de raiz unitária, que verificam se uma série é ou não estacionária.
- O teste de raiz unitária mais usado é o teste de Dickey-Fuller.
- Maiores detalhes sobre o teste podem ser pesquisados em:
 - MAKRIDAKIS, S., WHEELWRIGHT, S. C. & HYNDMAN, R. J. **Forecasting. Methods and Applications**. Third Edition. John Wiley & Sons. New York, 1998.
 - ENDERS, W. **Applied Econometric Time Series**. John Wiley & Sons. New York, 1995.

16

Preparação dos dados Removendo a não estacionariedade

- Caso ainda não sejam estacionárias, será necessário transformá-las.
- A transformação mais comum consiste em tomar diferenças sucessivas da série original, até obter uma série estacionária.
- A primeira diferença de Z_t é: $\Delta Z_t = Z_t - Z_{t-1}$,
- A segunda diferença é por:

$$\Delta^2 Z_t = \Delta [\Delta Z_t] = \Delta [Z_t - Z_{t-1}] = Z_t - 2Z_{t-1} - Z_{t-2}$$
- Em geral tomar uma ou duas diferenças é suficiente para que a série se torne estacionária.

17

Preparação dos dados Removendo a não estacionariedade

- Quando a série é sazonal e não estacionária é apropriado tomar as diferenças para o período de sazonalidade.
- Assim, dados mensais devem apresentar um padrão anual de sazonalidade, neste caso a estação de sazonalidade s é 12.
- As diferenças sazonais para dados mensais é dada por:

$$\Delta Z_t = Z_t - Z_{t-12}$$

18


Estacionariedade - Exercício

- O arquivo TEQ8_series.xls contém 5 planilhas.
- Em cada planilha uma série temporal,
- Construa os gráficos de tempo para cada série e
- verifique se cada uma das séries apresentam estacionariedade ou não.
- No caso da serie ser não-estacionária, verificar se é em relação ao nível ou a variância. Remova a estacionariedade, caso seja necessário.
- Após resolução



19

Etapas para a construção dos modelos Box-Jenkins



identificação

Fonte: Makridakis et al. (1998)

20

Seleção do modelo

Função de autocorrelação

- Outra implicação, da estacionariedade, que tem importante interpretação em termos do comportamento da série temporal
- é o fato que a autocovariância entre quaisquer duas observações depende somente do número de períodos de tempo que separam eles.
- A covariância entre Z_t e Z_{t+k} é chamada de autocovariância de defasagem (ou lag) k

$$\gamma_k = \text{cov}(Z_t, Z_{t+k}) = E[(Z_t - \mu)(Z_{t+k} - \mu)]$$

21

Seleção do modelo

Função de autocorrelação

- como a autocorrelação é função da autocovariância, em séries estacionárias,
- esta também dependerá apenas do número de defasagem entre duas observações

$$\rho_k = \frac{E[(Z_t - \mu)(Z_{t+k} - \mu)]}{\sqrt{E[(Z_t - \mu)^2]E[(Z_{t+k} - \mu)^2]}} = \frac{E[(Z_t - \mu)(Z_{t+k} - \mu)]}{\sigma_Z^2}$$

Cabe ressaltar que para $k = 0$ o valor de ρ_k será sempre igual a um.

22

Seleção do modelo

Função de autocorrelação


- O coeficiente de autocorrelação ρ_k , que mede a correlação entre observações distantes k períodos de tempo.
- Assim ρ_1 indica como valores sucessivos de Z_t se relacionam, ρ_2 indica como os valores a cada dois períodos se relacionam e assim por diante.
- Juntas, as autocorrelações de defasagem $1, 2, \dots$, constituem a função de autocorrelação ou ACF.
- O gráfico da função de autocorrelação é chamado de correlograma.

23

Seleção do modelo

Função de autocorrelação

Correlograma para o modelo: $Z_t = 0,8 Z_{t-1} + \varepsilon_t$



24

Seleção do modelo

Função de autocorrelação

- Função de autocorrelação amostral
- Ao analisar uma série temporal é preciso obter estimativas para os valores da correlações ρ_k .
- Utiliza-se então o coeficiente de autocorrelação amostral:

$$r_k = \frac{\sum_{t=k+1}^T (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^T (Z_t - \bar{Z})^2} \quad \text{com } k = 0, 1, 2, \dots, T$$

onde: $\bar{Z} = \frac{1}{T} \sum_{t=1}^T Z_t$

25

Seleção do modelo

Função de autocorrelação

- Nos correlogramas amostrais são traçados limites paralelos ao eixo do número de defasagens k ,
- tais limites correspondem a $\pm 2\sigma_{r_k}$, que são úteis para verificar se as autocorrelações são significativamente diferente de zero.
- Além disto, a forma da ACF amostral irá auxiliar na especificação de um modelo em particular.

desvio padrão do coeficiente de autocorrelação amostral

26

Seleção do modelo

Função de autocorrelação

- Função de autocorrelação parcial
- Autocorrelações parciais são usadas para medir o grau de associação entre Z_t e Z_{t-k} , quando os efeitos das outras defasagens (de 1, 2, ..., $k-1$) são removidos.
- O coeficiente de autocorrelação parcial é apresentada por ϕ_{kk} .
- Juntas, as autocorrelações parciais de defasegem 1,2,..., constituem a função de autocorrelação parcial ou PACF.
- O gráfico da função de autocorrelação parcial é chamado de correlograma parcial.

27

Seleção do modelo

Função de autocorrelação

- Autocorrelação e Autoc. Parcial e a Sazonalidade
- Caso os dados sejam observados em períodos mensais e se o padrão de sazonalidade é consistente,
- o coeficiente de autocorrelação de defasagens 12 deverá ser grande, indicando a existência de sazonalidade.
- A sazonalidade pode ser encontrada pela identificação de coeficientes de autocorrelação altos ou coeficientes de autocorrelação parciais altos para defasagens de sazonalidade.
- No caso de dados mensais para defasagens múltiplas de 12.


28

Função de autocorrelação - Exercício

- Copie para o SPSS, cada série do arquivo TEQ8_series.xls (a série sem influência da estacionariedade)
- Construa as ACF e PACF para cada série.

29

Etapas para a construção dos modelos Box-Jenkins



Fonte: Makidrakis et al. (1998)

30

Métodos Qualitativos

*Análise de séries temporais:
Modelos de Box-Jenkins
Profa. Dra. Liane Werner*