



# Módulo de Regressão e Séries Temporais

## Parte 2

Mônica Barros, D.Sc.

Julho de 2007

monica@mbarros.com

1



## Quem sou eu?

### □ Mônica Barros

- Doutora em Séries Temporais – PUC-Rio
- Mestre em Estatística – University of Texas at Austin, EUA
- Bacharel em Matemática – University of Washington, Seattle, EUA
- Professora da PUC-Rio (Depto. De Eng. Elétrica)
- E-mails: monica@ele.puc-rio.br, monica@mbarros.com
- Home page: <http://www.mbarros.com>



monica@mbarros.com

2

## Programa do Curso



- Métodos de Amortecimento Exponencial
  - Modelos de médias móveis
  - Modelo de Brown
  - Modelo de Holt-Winters
  - Estimação dos parâmetros
  - Estatísticas de ajustes e análise dos resíduos
  - Exercícios

monica@mbarros.com

3

## Programa do Curso



- Modelagem ARIMA de Box & Jenkins sazonal e não sazonal
  - Função de autocorrelação e autocorrelação parcial
  - Modelo
  - Identificação de  $(p, q, d, P, Q, D)$
  - Estimação
  - Estatísticas de ajuste e análise dos resíduos
  - Exercícios

monica@mbarros.com

4



- Modelos de Regressão Dinâmica
  - Função de correlação cruzada
  - Modelo
  - Identificação/estimação
  - Estatísticas de ajustes e análise dos resíduos
  - Exercícios



## MÉTODOS DE AMORTECIMENTO EXPONENCIAL

(BROWN, HOLT & WINTERS)

## AMORTECIMENTO EXPONENCIAL



### NOTAÇÃO

- $Z_1, Z_2, \dots, Z_T$  é uma série temporal de tamanho  $T$
- $\hat{Z}_T(\tau)$  é a previsão de  $Z_{T+\tau}$  feita no instante  $T$ , ou seja, com uma antecedência de  $\tau$  instantes.
- $\tau$  é chamado de “horizonte de previsão”

## AMORTECIMENTO EXPONENCIAL



### □ Roteiro

- Modelos Constante, Linear, Quadrático
- Sazonalidade Aditiva e Multiplicativa
- Métodos de Estimação em cada uma destas combinações e o que precisa ser estimado em cada modelo.

## AMORTECIMENTO EXPONENCIAL



### MÉTODOS AUTOMÁTICOS GERAIS

#### □ MÉTODO INGÊNUO (OU "NAIVE")

$$\hat{Z}_T(\tau) = Z_T \text{ para } \tau = 1, 2, 3, \dots$$

- A previsão para qualquer instante futuro feita usando a série até o instante T é apenas o último valor observado.
- É claro que você não precisa de um "software" para ajustar isso e, em alguns casos, é o único "método" disponível.
- Um exemplo clássico é a previsão do preço de uma ação - geralmente a melhor previsão para o preço de amanhã é o preço de hoje.

monica@mbarros.com


9

## AMORTECIMENTO EXPONENCIAL



### Modelo Constante

- O modelo é:  $Z_t = a + e_t$
- onde  $e_t$  é um ruído com média zero e variância constante  $\sigma^2_e$ . Logo, a série oscila em torno de um nível médio constante ("a") que precisamos estimar.



monica@mbarros.com

10

## AMORTECIMENTO EXPONENCIAL



### Modelo Constante

- Como estimar o nível médio da série ("a")?
- Uma possibilidade é, a cada instante, usar como previsão a média das últimas N observações.
- Um dos problemas com este método é a escolha de N, o tamanho da janela a ser utilizado.
- Quanto maior o valor de N, mais "suave" é a previsão. Ao contrário, se N é pequeno, a previsão tende a ser meio "nervosa", isto é, oscila muito.
- Este método é chamado de médias móveis simples.

monica@mbarros.com

11

## AMORTECIMENTO EXPONENCIAL



### Modelo Constante

- Uma característica importante do método de médias móveis é: todas as observações usadas para o cálculo têm o mesmo peso (que é  $1/N$ ).
- Mas, na prática é razoável supor que as observações mais recentes sejam mais relevantes para a previsão dos próximos valores da série, e portanto deveriam receber um peso maior que as observações mais antigas. Esta idéia de pesar ou ponderar as observações de acordo com as suas "idades" leva aos diversos métodos de amortecimento exponencial.

monica@mbarros.com

12



### Modelo Constante

- O nível médio da série num certo instante é estimado como a média móvel de tamanho  $N$  usando as observações  $Z_T, Z_{T-1}, \dots, Z_{T-N+1}$ , isto é:

$$\hat{\alpha}(T) = M_T = \frac{Z_{T-N+1} + \dots + Z_{T-1} + Z_T}{N}$$

- Note que, se  $N = 1$ , apenas a última observação é usada, e o método se reduz ao **método ingênuo**. Por outro lado, se  $N = T$  (tamanho da série), temos o chamado "método conservador", em que todas as observações disponíveis são usadas na estimação do nível médio da série, e  $\hat{\alpha}(T) = \bar{Z}$ , média amostral da série.



### Modelo Constante

#### □ Escolha do tamanho da janela

- O tamanho da janela utilizada ( $N$ ) no método de médias móveis pode ser escolhido como o inteiro positivo que minimiza a soma de quadrados dos erros de previsão 1 passo à frente, isto é, escolhe-se  $N$  de forma a minimizar:

$$S(N) = \sum_{t=1}^T e_1^2(t)$$



### Modelo Constante

- O estimador do nível da série por médias móveis pode ser escrito como:

$$\hat{\alpha}(T) = M_T = \frac{Z_{T-N+1} + \dots + Z_{T-1} + Z_T}{N} = M_{T-1} + \frac{Z_T - Z_{T-N}}{N}$$

- Onde  $M_{T-1}$  é a média móvel de tamanho  $N$  calculada no instante anterior.
- Em outras palavras, o estimador do nível envolve uma informação "atual" (representada por  $Z_T$ , o último valor observado da série) e uma informação "passada" ( $M_{T-1}$  e  $Z_{T-N}$ ).



### Modelo Constante

- O método de amortecimento exponencial estende esta idéia de ponderação da informação presente e passada. Na equação anterior substitua  $Z_{T-N}$  por  $M_{T-1}$ . Isso nos leva ao seguinte estimador:

$$\hat{\alpha}(T) = M_{T-1} + \frac{Z_T - M_{T-1}}{N} = \left(\frac{1}{N}\right)Z_T + \left(1 - \frac{1}{N}\right)M_{T-1}$$

- Este novo estimador tem a forma:  
**(peso) \* (informação atual) +**  
**+(1 - peso) \* (informação passada).**

## AMORTECIMENTO EXPONENCIAL



### Modelo Constante

- Note que  $\hat{a}(T)$  é a previsão do nível da série efetuada no instante atual  $T$  e podemos reescrever esta última equação como:

$$\hat{a}(T) = \left(\frac{1}{N}\right)Z_T + \left(1 - \frac{1}{N}\right)M_{T-1} = \left(\frac{1}{N}\right)Z_T + \left(1 - \frac{1}{N}\right)\hat{a}(T-1)$$

- onde  $\hat{a}(T-1)$  é a média móvel de tamanho  $N$  calculada até (inclusive) a observação  $T-1$ , ou seja, é a estimativa prévia do nível da série. Em outras palavras: a previsão atual do nível (dada por  $\hat{a}(T)$ ) é baseada na ponderação do valor mais recente da série ( $Z_T$ ) e da última previsão para o nível ( $\hat{a}(T-1)$ ).

## AMORTECIMENTO EXPONENCIAL



### Modelo Constante

- Uma forma mais geral de definir um estimador que pondere as informações passadas e presentes é:

$$\hat{a}(T) = M_T = \alpha Z_T + (1 - \alpha)M_{T-1} = \alpha Z_T + (1 - \alpha)\hat{a}(T-1)$$

- onde  $\alpha \in [0, 1]$  é a **constante de amortecimento**, que controla a taxa de decaimento da informação ao longo do tempo.

## AMORTECIMENTO EXPONENCIAL




### Modelo Constante

- Por **substituições sucessivas** na última equação podemos concluir que:
- $M_T = \alpha Z_T + \alpha(1 - \alpha) Z_{T-1} + \alpha(1 - \alpha)^2 Z_{T-2} + \dots + \alpha(1 - \alpha)^{T-1} Z_1$
- Esta última equação mostra claramente como funciona o método de amortecimento exponencial:
  - cada estimativa do nível (dada por  $M_T$ ) é uma soma ponderada da observação atual ( $Z_T$ ) e das observações passadas. Os pesos decrescem exponencialmente, e a taxa de decaimento dos pesos depende da constante  $\alpha$ .

## AMORTECIMENTO EXPONENCIAL



### Modelo Linear



$$Z_t = a_1 + a_2 t + \varepsilon_t$$

Onde:  $E\{\varepsilon_t\} = 0$   
 $Var\{\varepsilon_t\} = \sigma_\varepsilon^2$

- Desta expressão (e usando as propriedades da média e variância) segue que:

$$E(Z_t) = a_1 + a_2 t \quad VAR(Z_t) = \sigma^2 = VAR(\varepsilon_t)$$



## Modelo Linear

- Estimação de parâmetros
- Neste modelo é necessário estimar **três parâmetros**:  $a_1$  (coeficiente linear da série),  $a_2$  (coeficiente angular da reta, ou seja, a taxa de crescimento da série) e  $\sigma_e^2$  (a variância da série).
- A previsão  $\tau$  passos à frente obtida no instante T é:

$$\hat{Z}_T(\tau) = E\{Z_{T+\tau} | Z_T\} = E\{a_1 + a_2(T + \tau) + \varepsilon_{T+\tau} | Z_T\} = \hat{a}_1(T) + \hat{a}_2(T)(T + \tau)$$



## Modelo Linear

- **Estimadores pelo Método de Médias Móveis Duplas**
  - Defina a média móvel dupla de tamanho N como:

$$M_T^{[2]} = \frac{M_T + M_{T-1} + \dots + M_{T-N+1}}{N}$$

- Onde  $M_T$  é a média móvel (simples) de tamanho N calculada usando todas as observações até o instante T (inclusive).
- **Por que usar médias móveis duplas?**
- Se os dados exibem uma tendência linear, o uso de médias móveis simples para a previsão dos valores da série induz a erros sistemáticos, pois a média móvel simples segue a tendência com um certo atraso, e este efeito é amplificado quando tentamos prever valores futuros. O método de médias móveis duplas procura diminuir este efeito sistemático.



## Modelo Linear

- **Estimadores pelo Método de Médias Móveis Duplas**

$$\hat{a}_1(T) = M_T + (M_T - M_T^{[2]}) - T \cdot \hat{a}_2(T) = 2 \cdot M_T - M_T^{[2]} - T \cdot \hat{a}_2(T)$$

$$\hat{a}_2(T) = \frac{2}{(N-1)} \{M_T - M_T^{[2]}\}$$

- Acima, N é o tamanho da janela usada na média móvel simples e dupla. O estimador  $\hat{a}_1(T)$  é encontrado corrigindo-se a média móvel simples ( $M_T$ ) pela diferença entre ela e a média móvel dupla. Se, na verdade, não existisse uma tendência linear, o fator de correção seria pequeno.



## Modelo Linear


- **Equação de previsão  $\tau$  passos à frente no instante T**

$$\begin{aligned} \hat{Z}_{T+\tau} &= \hat{a}_1(T) + \hat{a}_2(T)(T + \tau) = 2 \cdot M_T - M_T^{[2]} - T \cdot \hat{a}_2(T) + T \cdot \hat{a}_2(T) + \tau \cdot \hat{a}_2(T) = \\ &= 2 \cdot M_T - M_T^{[2]} + \tau \cdot \hat{a}_2(T) = 2 \cdot M_T - M_T^{[2]} + \tau \cdot \left\{ \frac{2}{N-1} \{M_T - M_T^{[2]}\} \right\} \end{aligned}$$

- **Vantagens e Desvantagens deste método**
  - a implementação é trivial;
  - os estimadores obtidos pelo método não são muito influenciados por "outliers";
  - a escolha do número ótimo de "lags" a serem usados nas médias móveis simples e duplas não é trivial.



## Modelo Quadrático



$$Z_t = a_1 + a_2t + a_3t^2 + \varepsilon_t$$

Onde:

$$E\{\varepsilon_t\} = 0$$

$$Var\{\varepsilon_t\} = \sigma_\varepsilon^2$$

- Estimação dos parâmetros  $a_1$ ,  $a_2$  e  $a_3$  por médias móveis triplas.



## Método de Amortecimento de Brown

Uso: Séries não sazonais sem tendência

- (i) SIMPLES (Modelo Constante)

$$Z_t = a + \varepsilon_t$$

$$\varepsilon_t \begin{cases} \rightarrow E\{\varepsilon_t\} = 0 \\ \rightarrow Var\{\varepsilon_t\} = \sigma_\varepsilon^2 \end{cases}$$



EQUAÇÃO DE PREVISÃO:  $\hat{Z}_T(\tau) = \hat{a}(T)$

onde o estimador do parâmetro “a” no instante T é obtido por amortecimento exponencial.

Idéia Geral:

“ESTIMADOR EM T = (α). PRESENTE + (1-α).PASSADO”

$$\hat{a}(T) = \alpha Z_T + (1 - \alpha)\hat{a}(T-1)$$

$$= \hat{a}(T-1) + \alpha \hat{\varepsilon}_T(1) \text{ onde } \hat{\varepsilon}_T(1) = Z_T - \hat{Z}_{T-1}(1)$$

(Erro de Previsão 1 passo à frente)



- Valores de  $\alpha$  próximos de 1 dão um peso maior às variações mais recentes nos dados, enquanto valores de  $\alpha$  próximos de zero têm um efeito de maior amortecimento e refletem uma menor sensibilidade aos dados atuais.

- Não existe um procedimento formal para escolher  $\alpha$ . Em geral  $\alpha$  é escolhido através da minimização do erro de previsão um passo à frente.
- O método de Brown é equivalente a um modelo ARIMA(0,1,1) sem constante.

## AMORTECIMENTO EXPONENCIAL



### (ii) DUPLO (Modelo Linear)

$$Z_t = a_1 + a_2 t + \varepsilon_t; \quad \varepsilon_t \begin{cases} E\{\varepsilon_t\} = 0 \\ \text{Var}\{\varepsilon_t\} = \sigma_\varepsilon^2 \end{cases}$$

EQUAÇÃO DE PREVISÃO:  $\hat{Z}_T(\tau) = \hat{a}_1(T) + \hat{a}_2(T)[T + \tau]$

□ Se, além da média, a tendência também varia ao longo do tempo, é necessário ajustar um modelo de amortecimento de ordem mais alta para “seguir” a tendência variante no tempo.

monica@mbarros.com

29

## AMORTECIMENTO EXPONENCIAL



- Os estimadores de  $\hat{a}_1(T)$  e  $\hat{a}_2(T)$  são obtidos por amortecimento exponencial, isto é, têm a forma: “ $\alpha$ .PRESENTE +  $(1-\alpha)$ .PASSADO”
- Neste modelo os estimadores são dados por:

$$\hat{a}_1(T) = 2 S_T - S_T^{[2]}$$

$$\hat{a}_2(T) = \frac{\alpha}{1-\alpha} \{S_T - S_T^{[2]}\}$$

□ e

$$S_T = \alpha Z_T + (1-\alpha) S_{T-1}$$

$$S_T^{[2]} = \alpha S_T + (1-\alpha) S_{T-1}^{[2]}$$

- Onde  $S_T$  é o estimador amortecido da série temporal.

monica@mbarros.com

30

## AMORTECIMENTO EXPONENCIAL



### (iii) TRIPLO (Modelo Quadrático)

$$\text{MODELO: } Z_t = a_1 + a_2 t + a_3 t^2 + \varepsilon_t; \quad \varepsilon_t \begin{cases} E\{\varepsilon_t\} = 0 \\ \text{Var}\{\varepsilon_t\} = \sigma_\varepsilon^2 \end{cases}$$

EQUAÇÃO DE PREVISÃO:

$$\hat{Z}_T(\tau) = \hat{a}_1(T) + \hat{a}_2(T)[T + \tau] + \hat{a}_3(T) \cdot [T + \tau]^2$$

monica@mbarros.com

31

## AMORTECIMENTO EXPONENCIAL



- OS ESTIMADORES DE  $\hat{a}_1(T)$ ,  $\hat{a}_2(T)$ ,  $\hat{a}_3(T)$  POR AMORTECIMENTO EXPONENCIAL PARA ESTE MODELO SÃO DADOS POR:

$$\hat{a}_1(T) = 3 S_T - 3 S_T^{[2]} + S_T^{[3]}$$

$$\hat{a}_2(T) = \left( \frac{\alpha}{1-\alpha} \right)^2 \{S_T - 2 S_T^{[2]} + S_T^{[3]}\}$$

$$\hat{a}_3(T) = \left( \frac{\alpha}{2(1-\alpha)^2} \right) \{ (6-5\alpha) S_T - 2(5-4\alpha) S_T^{[2]} + (4-3\alpha) S_T^{[3]} \}$$

□ onde

$$\begin{cases} S_T = \alpha Z_T + (1-\alpha) S_{T-1} \\ S_T^{[2]} = \alpha S_T + (1-\alpha) S_{T-1}^{[2]} \\ S_T^{[3]} = \alpha S_T^{[2]} + (1-\alpha) S_{T-1}^{[3]} \end{cases}$$

monica@mbarros.com

32

## AMORTECIMENTO EXPONENCIAL



### □ Método de Brown

- Simples – tendência constante
- Duplo – tendência linear
- Triplo – tendência quadrática
- Em todos os casos, APENAS UMA constante de amortecimento

## AMORTECIMENTO EXPONENCIAL



### □ Método de Holt (2 hiperparâmetros)

MODELO:  $Z_t = a_1 + a_2 t + \varepsilon_t$

$E\{\varepsilon_t\} = 0$   
 $Var\{\varepsilon_t\} = \sigma_\varepsilon^2$

### □ Tendência Linear

- Ao contrário do método de Brown, aqui existem dois hiperparâmetros, um para a evolução do nível e outro para a evolução da tendência.

## AMORTECIMENTO EXPONENCIAL



$$\text{EQUAÇÃO DE PREVISÃO} = \hat{Z}_T(\tau) = \hat{a}_1(T) + \tau \cdot \hat{a}_2(T)$$



SE NÃO HÁ DESLOCAMENTO  
DA ORIGEM  $(T + \tau)$

## AMORTECIMENTO EXPONENCIAL



### □ Método de Holt

□ ESTIMADORES DE  $\hat{a}_1(T)$  E  $\hat{a}_2(T)$

□ ENCONTRADOS VIA AMORTECIMENTO EXPONENCIAL COM  
DUAS CONSTANTES  $\alpha$  E  $\beta$

$$\hat{a}_1(T) = \alpha \cdot Z_T + (1 - \alpha) \cdot [\hat{a}_1(T - 1) + \hat{a}_2(T - 1)]$$

$$\hat{a}_2(T) = \beta [\hat{a}_1(T) - \hat{a}_1(T - 1)] + (1 - \beta) \hat{a}_2(T - 1)$$



## AMORTECIMENTO EXPONENCIAL



### (i) MODELO MULTIPLICATIVO

$$\text{TENDÊNCIA} = a_1 + a_2 t$$

FATOR SAZONAL :  $C_t$ ; ou seja  $C_1, C_2, \dots, C_L$

ONDE L É O COMPRIMENTO DA SAZONALIDADE

$$\text{MODELO: } Z_t = (a_1 + a_2 t) \cdot C_t + \varepsilon_t$$

NORMALIZAÇÃO:  $\sum_{i=1}^L C_i = L$  (FATOR SAZONAL NORMALIZADO)

## AMORTECIMENTO EXPONENCIAL



EQUAÇÃO DE PREVISÃO:

$$Z_T(\tau) = [\hat{a}_1(T) + \tau \cdot \hat{a}_2(T)] \cdot C_{m(T+\tau)}^{(T)}$$

ONDE  $m(T+\tau)$

É O MÊS CORRESPONDENTE AO INSTANTE  $T+\tau$

ORIGEM DESLOCADA PARA INSTANTE T

## AMORTECIMENTO EXPONENCIAL



### (ii) MODELO ADITIVO

$$\text{MODELO: } Z_t = (a_1 + a_2 t) + C_t + \varepsilon_t$$

NESTE CASO:  $\sum_{i=1}^L C_i = 0$ , a soma dos fatores sazonais aditivos é zero

EQUAÇÃO DE PREVISÃO:

$$Z_T(\tau) = [\hat{a}_1(T) + \tau \cdot \hat{a}_2(T)] + C_{m(T+\tau)}^{(T)}$$

## AMORTECIMENTO EXPONENCIAL



### □ Modelo Holt-Winters Multiplicativo

$$Z_t = (a_1 + a_2 t) \cdot C_{m(t)} + \varepsilon_t; \quad \begin{array}{l} \nearrow E\{\varepsilon_t\} = 0 \\ \searrow \text{Var}\{\varepsilon_t\} = \sigma_\varepsilon^2 \end{array}$$

□ Série tem tendência linear e sazonalidade MULTIPLICATIVA.

## HOLT- WINTERS MULTIPLICATIVO



□ Onde:

$a_1$  : NÍVEL

$a_2$ : INCLINAÇÃO

$m(t)$ : MÊS (TRIMESTRE OU SEMANA)  
CORRESPONDENTE AO INSTANTE “t”

$C_{m(t)}$ : FATOR SAZONAL CORRESPONDENTE AO  
“MÊS” “t”

□ RESTRIÇÃO DE NORMALIZAÇÃO:  $\sum_{i=1}^L C_i = L$

□ ONDE L É O COMPRIMENTO DO PERÍODO SAZONAL (por exemplo, 12 no caso de dados mensais).

## HOLT- WINTERS MULTIPLICATIVO



PREVISÃO:

$$\hat{Z}_T(\tau) = [(\hat{a}_1(T) + \hat{a}_2(T) \cdot \tau) \cdot \hat{C}_{m(T+\tau)}(T)]$$

□ Obtida substituindo-se cada componente (nível, tendência, fator sazonal) por seu estimador.

ATUALIZAÇÃO “ON-LINE” DOS PARÂMETROS:

□ O **nível estimado** é função da última observação, fator sazonal estimado e estimativas anteriores do nível e tendência.

$$\hat{a}_1(T) = \alpha \left( \frac{Z_T}{\hat{C}_{m(T)}(T-1)} \right) + (1-\alpha) \{ \hat{a}_1(T-1) + \hat{a}_2(T-1) \}$$

## HOLT- WINTERS MULTIPLICATIVO



□ ATUALIZAÇÃO “ON-LINE” DOS PARÂMETROS

$$\hat{a}_2(T) = \beta \cdot [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-\beta) \cdot \hat{a}_2(T-1)$$

□ A **taxa de crescimento estimada** é função dos níveis estimados em T e T-1 e da taxa de crescimento estimada anteriormente.

□ A **constante de amortecimento ( $\beta$ )** é diferente daquela usada para a atualização do nível.

## HOLT- WINTERS MULTIPLICATIVO



□ ATUALIZAÇÃO “ON-LINE” DOS PARÂMETROS

$$\hat{C}_{m(T)}(T) = \gamma \left( \frac{Z_T}{\hat{a}_1(T)} \right) + (1-\gamma) \hat{C}_{m(T)}(T-1)$$

□ O **fator sazonal correspondente ao “mês” T** é função do fator sazonal correspondente ao mesmo mês no “ano” anterior e também da última observação.

$$\hat{C}_J(T) = \hat{C}_J(T-1); \quad J = 1, 2, \dots, L; \quad J \neq m(t)$$

□ **Logo, o fator sazonal correspondente a um certo “mês” só é atualizado uma vez por ano, ao recebermos o dado referente àquele “mês”.**

□ As constantes de amortecimento do modelo são  $\alpha$ ,  $\beta$  e  $\gamma$ , restritas ao intervalo  $[0, 1]$ .



### Resumo

#### Método de Brown

- ❑ Séries não sazonais
- ❑ Tendência: constante, linear ou quadrática (1, 2 ou 2 parâmetros)
- ❑ Apenas 1 hiperparâmetro ( $\alpha$ )



### Resumo

#### Método de Holt com 2 parâmetros

- ❑ Séries não sazonais
- ❑ Tendência Linear (2 PARÂMETROS,  $a_1$  e  $a_2$ )
- ❑ Usa 2 HIPERPARÂMETROS (constantes de amortecimento)  $\alpha$  e  $\beta$



### Resumo

#### Método de Holt e Winters Multiplicativo

- ❑ Modelo Sazonal Multiplicativo com Tendência Linear
- ❑ Tem  $L+2$  parâmetros (onde  $L$  é o comprimento do período sazonal)
- ⇒ Usa 3 hiperparâmetros ( $\alpha$ ,  $\beta$  e  $\gamma$ ).




- ❑ Exemplo (Série não sazonal)
- ❑ PIB brasileiro – 1947 a 2006 em R\$ de 2006
- ❑ Fonte: IPEADATA
- ❑ Produza previsões usando amortecimento exponencial para os anos 2007-2015 usando o Forecast Pro e interprete os resultados gerados.

# AMORTECIMENTO EXPONENCIAL



## Gráfico da Série



monica@mbarros.com

53

# AMORTECIMENTO EXPONENCIAL



## Resultados do ajuste – Método de Holt

Forecast Model for PIB\_RS\_2006  
Holt exponential smoothing: Linear trend, No seasonality  
Confidence limits proportional to level

Component	Smoothing Weight	Final Value
Level	1.00000	2.3228e+006
Trend	0.15558	57200.

Within-Sample Statistics

Sample size	60	Number of parameters	2
Mean	1.021e+006	Standard deviation	6.939e+005
R-square	0.997	Adjusted R-square	0.9969
Durbin-Watson	1.639	* Ljung-Box(18)	=32.85 P=0.9826
Forecast error	3.851e+004	BIC	4.054e+004
MAPE	0.02365	RMSE	3.786e+004
MAD	2.647e+004		

É praticamente o valor da série no último ponto (PIB de 2006)

Com este valor de  $\alpha$ , todo o peso concentrado na última observação.


monica@mbarros.com

54

# AMORTECIMENTO EXPONENCIAL



## Valores ajustados e previsões



monica@mbarros.com

55

# AMORTECIMENTO EXPONENCIAL



## Previsões até 2015

Date	2.5 Lower	Forecast	97.5 Upper
2007	2,199,020	2,380,018	2,561,016
2008	2,160,619	2,437,218	2,713,817
2009	2,147,642	2,494,418	2,841,194
2010	2,146,648	2,551,618	2,956,587
2011	2,153,025	2,608,818	3,064,611
2012	2,164,526	2,666,017	3,167,509
2013	2,179,857	2,723,217	3,266,578
2014	2,198,191	2,780,417	3,362,643
2015	2,218,962	2,837,617	3,456,272

monica@mbarros.com

56

## AMORTECIMENTO EXPONENCIAL



- ❑ Exemplo – Série Sazonal
- ❑ Consumo total de energia elétrica – Brasil (GWh), janeiro de 1979 a abril de 2007.
- ❑ Fonte: Banco Central (a partir de dados da Eletrobrás).
- ❑ Produza previsões usando amortecimento exponencial para os anos 2007-2008 usando o Forecast Pro e interprete os resultados gerados.


monica@mbarros.com

57

## AMORTECIMENTO EXPONENCIAL



- ❑ Gráfico da Série



monica@mbarros.com

58

## AMORTECIMENTO EXPONENCIAL



- ❑ Modelo Holt-Winters ajustado automaticamente usando toda a série

Forecast Model for total  
Multiplicative Winters: Linear trend, Multiplicative seasonality  
Confidence limits proportional to indexes and level

Component	Smoothing Weight	Final Value
Level	0.64243	32243.
Trend	0.00346	68.993
Seasonal	0.09153	

#### Seasonal Indexes

Season	Index	Index	Index
January - March	1.00565	0.99213	0.99107
April - June	1.01700	0.99705	0.99392
July - September	0.98228	1.00100	1.01062
October - December	1.00382	1.01319	0.99286

#### Within-Sample Statistics

Sample size 340	Number of parameters 3
Mean 1.871e+004	Standard deviation 6141
R-square 0.9909	Adjusted R-square 0.9908
Durbin-Watson 1.734	Ljung-Box(18)=21.81 P=0.7596
Forecast error 588.4	BIC 601
MAPE 0.01904	RMSE 585.8
MAD 352.8	


monica@mbarros.com

59

## AMORTECIMENTO EXPONENCIAL



- ❑ Valores ajustados e previsões




monica@mbarros.com

60

## AMORTECIMENTO EXPONENCIAL



- "Zoom" nos valores ajustados e previsões



monica@mbarros.com

61

## AMORTECIMENTO EXPONENCIAL



- Previsões até 2008

Date	2.5 Lower	Forecast	97.5 Upper
2007-05	30,433	32,216	34,000
2007-06	30,066	32,184	34,301
2007-07	29,482	31,874	34,267
2007-08	29,882	32,551	35,220
2007-09	30,015	32,934	35,853
2007-10	29,645	32,781	35,917
2007-11	29,805	33,157	36,509
2007-12	29,029	32,560	36,092
2008-01	29,326	33,049	36,772
2008-02	28,785	32,673	36,562
2008-03	28,654	32,707	36,759
2008-04	29,402	33,633	37,863
2008-05	28,666	33,042	37,417
2008-06	28,485	33,007	37,528
2008-07	28,031	32,688	37,344
2008-08	28,575	33,380	38,185
2008-09	28,822	33,770	38,718
2008-10	28,533	33,612	38,692
2008-11	28,781	33,996	39,211
2008-12	28,050	33,382	38,715


monica@mbarros.com

62

## AMORTECIMENTO EXPONENCIAL



- Valores ajustados e previsões



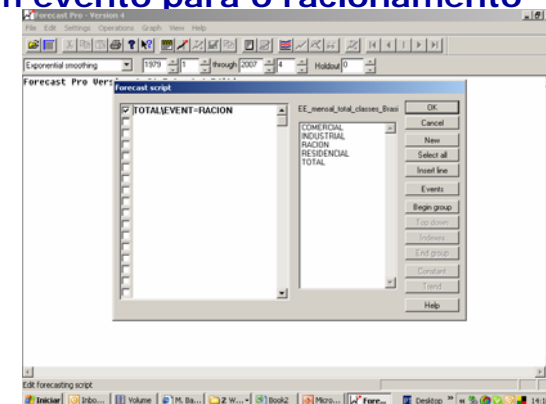
monica@mbarros.com

63

## AMORTECIMENTO EXPONENCIAL



- Modelo Holt-Winters ajustado automaticamente usando toda a série e com evento para o racionamento



64

# AMORTECIMENTO EXPONENCIAL



## Resultados

Forecast Model for total  
 Multiplicative Winters: Linear trend, Multiplicative seasonality  
 Multiplicative adjustment for events in RACION  
 Confidence limits proportional to indexes and level

Component	Smoothing Weight	Final Value
Level	0.41831	31358.
Trend	0.00223	66.930
Seasonal	0.02928	
Events	0.65794	

### Seasonal Indexes

Seasonal Indexes			
January - March	1.00646	0.98977	0.98678
April - June	1.01220	0.99449	0.99374
July - September	0.98564	1.00379	1.01259
October - December	1.00550	1.01577	0.99389

### Event code

Event code	Index
1	0.88372

### Within-Sample Statistics

Sample size 340	Number of parameters 4
Mean 1.871e+004	Standard deviation 6141
R-square 0.9925	Adjusted R-square 0.9924
Durbin-Watson 1.815	Ljung-Box(18)=18.07 P=0.5492
Forecast error 535.2	BIC 550.6
MAPE 0.0176	RMSE 532
MAD 326.5	


monica@mbarros.com

65

# AMORTECIMENTO EXPONENCIAL



## "Zoom" nos valores ajustados e previsões



monica@mbarros.com

66

# AMORTECIMENTO EXPONENCIAL



## Previsões até 2008

Date	2.5 Lower	Forecast	97.5 Upper
2007-05	29,639	31,252	32,864
2007-06	29,548	31,295	33,042
2007-07	29,244	31,106	32,967
2007-08	29,743	31,745	33,748
2007-09	29,965	32,092	34,218
2007-10	29,707	31,934	34,161
2007-11	29,987	32,329	34,670
2007-12	29,282	31,699	34,116
2008-01	29,644	32,167	34,690
2008-02	29,103	31,700	34,297
2008-03	28,990	31,670	34,350
2008-04	29,767	32,554	35,340
2008-05	29,196	32,050	34,904
2008-06	29,161	32,093	35,025
2008-07	28,895	31,897	34,899
2008-08	29,460	32,552	35,643
2008-09	29,732	32,905	36,078
2008-10	29,501	32,742	35,983
2008-11	29,824	33,144	36,465
2008-12	29,122	32,497	35,871

monica@mbarros.com

67