



IAG MASTER EM DESENVOLVIMENTO GERENCIAL 2006

Fundamentos de Economia de Energia
Mônica Barros, D.Sc.
Aula 2
24/08/2007

monica@mbarros.com

1

Uma visão gerencial da Estatística e Séries Temporais



■ Séries Temporais

- Conceitos
- Parâmetros
- Modelo Linear
- Modelos AR(1), AR(2), AR(p) e PAR(p)
- Modelos de Séries Temporais
- Estatísticas de “erros”

monica@mbarros.com

2

Série Temporal



- Conjunto de observações ordenadas no tempo.
- y_1, y_2, \dots, y_n – onde y_t é a carga no instante t .
- Existe dependência entre as cargas de diversos instantes.
- Isto nos permite usar cargas passadas para prever a carga futura.

monica@mbarros.com

3

Modelo

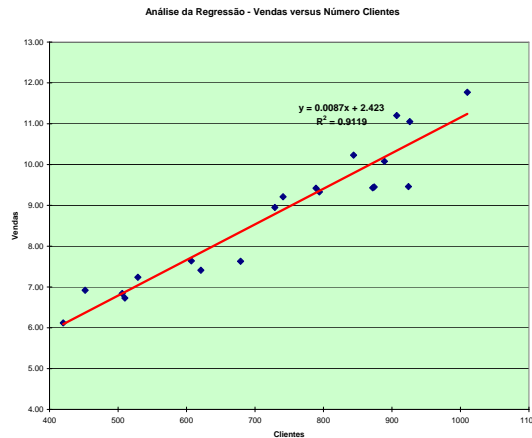


- É uma representação simplificada da realidade.
- Por exemplo, você observa duas variáveis X e Y e faz um gráfico dos n pontos $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$. O gráfico tem a “cara”:

monica@mbarros.com

4

Modelo



monica@mbarros.com

5

Modelo Linear



- Nesse exemplo a relação entre X e Y é, como o gráfico revela, aproximadamente linear.
- Nosso objetivo: achar reta que relaciona Y e X . Qual reta? Como encontrá-la?
- O método tradicional é chamado de mínimos quadrados.

monica@mbarros.com

6

Modelo Linear



■ Método de Mínimos Quadrados

- Como funciona? O objetivo é minimizar a soma dos quadrados dos “erros” (resíduos).
- Que “erros” são esses?
- Para cada ponto, o resíduo é o valor real menos o valor previsto pela reta.
- Pode-se notar que o resíduo vai depender de qual reta foi ajustada.

monica@mbarros.com

7

Modelo Linear



- Por exemplo, se ajustamos a reta $y = 3 + 2x$, se o valor de x_i é 2, então y_i ajustado pela reta é igual a 7. Se agora a reta é $y = 4 + 2x$, para $x_i = 2$ temos o y_i ajustado pela reta igual a 8.
- Imagine que o valor real de y_i seja 8.5 quando x_i é 2. Então, o resíduo gerado pela reta $3 + 2x$ é $8.5 - 7 = 1.5$ e pela reta $4 + 2x$ é $8.5 - 8 = 0.5$.

monica@mbarros.com

8



Modelo Linear

- Então, no que diz respeito a esse ponto ($x_i = 2$), a reta $4 + 2x$ foi melhor que a reta $3 + 2x$ pois gerou um resíduo menor.
- Em geral, dados n pares de pontos $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, você pode ajustar uma reta $y = b_0 + b_1 \cdot x$ a todos os pares.
- Note que os coeficientes b_0 e b_1 são os mesmos para todos os pares de pontos.



Modelo Linear

- O resíduo do i -ésimo par é:

$$\hat{e}_i = y_i - \hat{y}_i = \text{real}_i - \text{previsto}_i$$

- O método de mínimos quadrados procura obter a reta (ou seja, os coeficientes b_0 e b_1) tais que a soma dos quadrados dos resíduos seja minimizada.



Modelo Linear

- Método de Mínimos Quadrados
- Ache b_0 e b_1 tais que a expressão:

$$\sum_{i=1}^n \hat{e}_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - b_0 - b_1 x_i)^2$$

- seja minimizada.
- Esta soma acima é chamada de Soma dos Quadrados dos Resíduos (às vezes, Soma dos Quadrados dos Erros).



Modelo Linear

- Erro versus Resíduo
- Erro = variável aleatória não observável, com média zero e variância constante σ^2 .
- Resíduo = estimador ("chute") para o erro. É observável, calculado como valor real – valor previsto pelo modelo.
- Isso causa alguma confusão, pois às vezes a gente chama de "erro" o que é, na verdade, o "resíduo".



Modelo Linear

- O modelo linear é:
- $y_i = b_0 + b_1 x_i + e_i$ para $i = 1, 2, \dots, n$
- Onde e_i é o erro, uma variável com média 0 e variância constante σ^2 .
- Os parâmetros do modelo são b_0 , b_1 e σ^2 , são constantes desconhecidas que devem ser estimadas.

monica@mbarros.com

13



Modelo AR(1)

- Parâmetro = tudo que precisa ser estimado para especificar completamente o modelo.
- Modelo AR(1)
- AR(1) = autoregressivo de ordem 1
- $y_t = \phi y_{t-1} + e_t$
 - y_t = carga no mês t
 - y_{t-1} = carga no mês t-1
 - e_t = erro no mês t

monica@mbarros.com

14



Modelo AR(1)

- Parâmetros: ϕ , σ^2 (variância do erro)
- Caso Particular: Passeio Aleatório (Random Walk)
- AR(1) com $\phi = 1 \Rightarrow y_t = y_{t-1} + e_t$
- Uso: mercado de ações
- Na média, preço da ação hoje = preço da ação ontem (não ajuda muito para ganhar dinheiro!!)

monica@mbarros.com

15



Random Walk

- O gráfico a seguir mostra um exemplo de um passeio aleatório em que $y_0 = 100$ e os erros são Normais com média zero e desvio padrão 2.
- Foram geradas 500 observações.
- Você poderia confundir o gráfico com a da evolução do preço de uma ação no tempo, não é mesmo?

monica@mbarros.com

16



Random Walk

Gráfico de uma "Random Walk"



monica@mbarros.com

17



Modelo AR(1)

Exemplo – efeito de σ^2

- $y_t = 1.05 \cdot y_{t-1} + e_t$
- Carga do mês $t = 105\%$ da carga do mês $t-1 +$ erro.
- Suponha que $y_{t-1} = 100$.
 - a) $\text{VAR}(e_t) = 1$
 - b) $\text{VAR}(e_t) = 100$
- Por exemplo, se fosse possível observar o erro poderíamos encontrar algo como:

monica@mbarros.com

18



Modelo AR(1)

- a) $e_t = 1.05$ – valor pequeno pois foi “tirado” de uma distribuição de prob. com média 0 e variância 1.
- b) $e_t = 10.32$ – valor grande porque a distribuição de prob. tem variância “grande” (100).
- Resultados:
 - a) $y_t = 105 + 1.05 = 106.05$
 - b) $y_t = 105 + 10.32 = 115.32$

monica@mbarros.com

19



Modelo AR(2)

- $y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + e_t$
- Onde:
 - e_t = erro no instante t com média 0 e variância σ^2
 - y_t = carga no instante t
 - y_{t-1} = carga no instante $t-1$
 - y_{t-2} = carga no instante $t-2$
- Parâmetros: ϕ_1 , ϕ_2 e σ^2 .

monica@mbarros.com

20



Modelo AR(p)

- Modelo Autoregressivo de ordem p
- $y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + e_t$
- A carga deste mês depende das cargas dos p últimos meses.
- Existem p + 1 parâmetros a serem estimados: os φ 's e a variância do erro.



Modelo PAR(p)

- PAR(p) = Modelo Autoregressivo Periódico de ordem p.
- Contexto: Newave
- Modelos para previsão de vazões.
- Um modelo AR diferente para cada mês. Restrição do Newave - p máximo = 6 meses. (p = ordem do modelo).

Modelo de Séries Temporais



- Resíduo no instante t:
- $\hat{e}_t = \text{real} - \text{previsto no instante t}$
- Por exemplo, para dez/06, é o real de dezembro de 2006 menos o valor previsto para o mesmo mês. Só vai poder ser calculado quando o valor real de 12/2006 estiver disponível!

Modelo de Séries Temporais




- Mas posso olhar para os resíduos “in sample” (dentro da amostra) no período em que o modelo foi ajustado.
- Por exemplo, suponha que o modelo foi ajustado no período jan/03 a abr/06. Neste período todo posso fazer a comparação entre o valor real e o ajustado pelo modelo (“fitted value”), calculando o resíduo a cada instante.
- Um exemplo está na próxima figura.

Modelo de Séries Temporais



- O gráfico a seguir mostra uma série de carga real (em preto) e ajustada por um modelo (em vermelho).




25

Modelo de Séries Temporais



- Período de ajuste (in sample)
- Período de previsão (out of sample)
- No gráfico anterior, o período de ajuste vai de janeiro de 1994 a dezembro de 2005, e o período de previsão é o ano de 2006.



26

Modelo de Séries Temporais



- Você ajustaria o seguinte modelo:
 - In sample = 12 meses,
 - Out of sample = 24 meses?
- Não! E o contrário? Sim, desde que a série não fosse muito mal comportada.
- Em resumo – previsão de séries temporais não é futurologia! Você precisa de dados passados para fazer previsão!

Estatísticas de “Erros”



- Estatística de “erros” (resíduos)

Mês	Real	Previsto	Resíduo
1	y_1	\hat{y}_1	$\hat{e}_1 = y_1 - \hat{y}_1$
2	y_2	\hat{y}_2	$\hat{e}_2 = y_2 - \hat{y}_2$
...
n	y_n	\hat{y}_n	$\hat{e}_n = y_n - \hat{y}_n$

- MAPE = erro absoluto médio percentual
- “erro” percentual no instante i:
 - $(y_i - \hat{y}_i) / y_i$
- “erro” percentual absoluto no instante i:
 - $|y_i - \hat{y}_i| / y_i$

Estatísticas de “Erros”



- “Erro” absoluto percentual absoluto no instante i :

- $| (y_i - \hat{y}_i) / y_i | = | (\text{real} - \text{previsto}) / \text{real} |$

- MAPE = média destes erros absolutos percentuais

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| = \frac{1}{n} \sum_{i=1}^n \left| \frac{\text{real}_i - \text{previsto}_i}{\text{real}_i} \right|$$

- Vantagem: fácil de entender - a escala é %
- Desvantagem: Se o valor real é pequeno, qualquer discrepância na previsão faz o MAPE “explodir”.

monica@mbarros.com

29

Estatísticas de “Erros”



- MAD = mean absolute deviation = desvio absoluto médio

$$MAD = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| = \frac{1}{n} \sum_{i=1}^n |\text{real}_i - \text{previsto}_i|$$

- O MAD está nas mesmas unidades que a sua série.
- Por que o módulo?
- Para evitar soma = 0 quando um erro é grande e positivo e outro é grande e negativo!

monica@mbarros.com

30

Estatísticas de “Erros”



- EQM = erro quadrático médio

$$EQM = \frac{1}{n} \sum_{i=1}^n \hat{e}_i^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \frac{1}{n} \sum_{i=1}^n (\text{real}_i - \text{previsto}_i)^2$$

- RMSE = root mean squared erro = raiz do EQM

$$RMSE = \sqrt{EQM} = \sqrt{\frac{1}{n} \sum_{i=1}^n \hat{e}_i^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{real}_i - \text{previsto}_i)^2}$$

- Vantagem sobre EQM => mesma escala que os dados.

monica@mbarros.com

31

Estatísticas de “Erros”



- Erro “puro”:

$$e_i = y_i - \hat{y}_i$$

- Vantagem: mesma escala que os dados.
- Desvantagem: não dá para sair somando! Se você fizer isso corre o risco de achar que seu modelo é bom quando não é, pois erros de sinais opostos poderão se cancelar.

monica@mbarros.com

32

Estatísticas de “Erros”

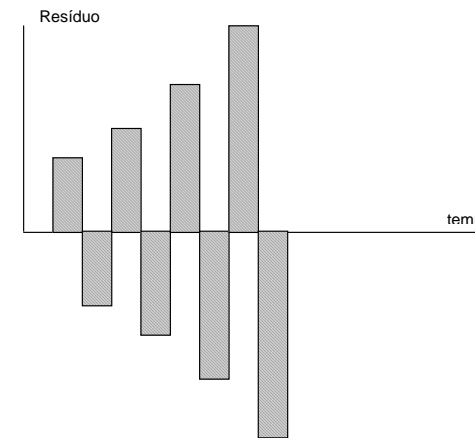


- O que fazer com tudo isso?
- O que é desejável? Se o modelo é bom, resíduo não tem padrão, não tem estrutura.
- Faça gráficos dos resíduos “puros” ou MAPE, ou MAD ou EQM, ou RMSE.
- Que tipo de gráficos?
 - Por exemplo, gráfico dos “erros” ao longo do tempo. Serve para responder como o seu modelo se comportou no “in sample” e verificar a existência de possíveis padrões.

monica@mbarros.com

33

Estatísticas de “Erros”

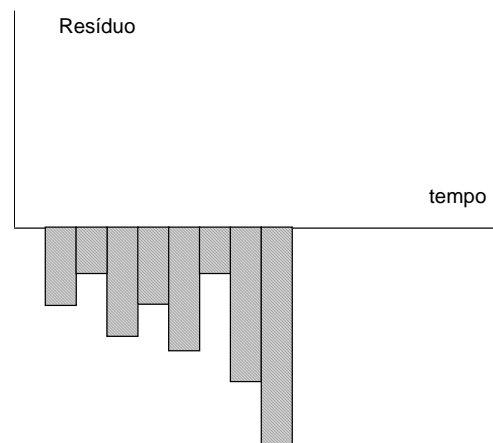


- Isto é tudo que eu não quero.
- Por que?
- Resíduo com um padrão claro.

monica@mbarros.com

34

Estatísticas de “Erros”



Também não quero um padrão desses – todos os resíduos são negativos, indicando que a minha previsão esteve sempre ACIMA do real


monica@mbarros.com

35

Estatísticas de “Erros”



- Gráfico dos “erros” versus o horizonte de previsão.
 - Serve para responder se as previsões se deterioram rápido ou não.



monica@mbarros.com

36

Estatísticas de “Erros”



- Gráfico da Autocorrelação dos erros
- Correlação entre os erros em diversos instantes
- ACF = autocorrelation function
- Gráfico da ACF versus lag (defasagem) é também chamado de correlograma.
- O que você não quer?
- Que exista correlação entre resíduos em instantes diferentes.

monica@mbarros.com

37

Estatísticas de “Erros”



- Por que você não quer que o gráfico da ACF dos resíduos mostre padrões?
- Porque se existe dependência temporal na série, toda esta dependência teria que ser, idealmente, capturada pelo modelo, não deveria ter sobrado nada nos resíduos!

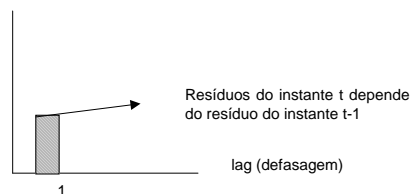
monica@mbarros.com

38

Estatísticas de “Erros”



■ Casos comuns...



- Atenção: A autocorrelação é sempre um número entre -1 e $+1$
 - No gráfico anterior:
 - Resíduo grande e positivo no instante t leva a um resíduo grande e positivo no instante $t+1$


monica@mbarros.com

39

Estatísticas de “Erros”



■ Outros Padrões:

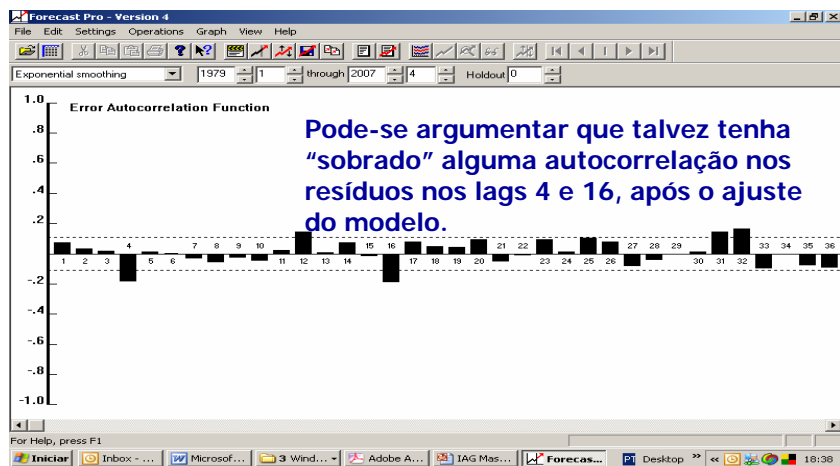


- Resíduos nos instantes t e $t-12$ têm dependência.

monica@mbarros.com

40

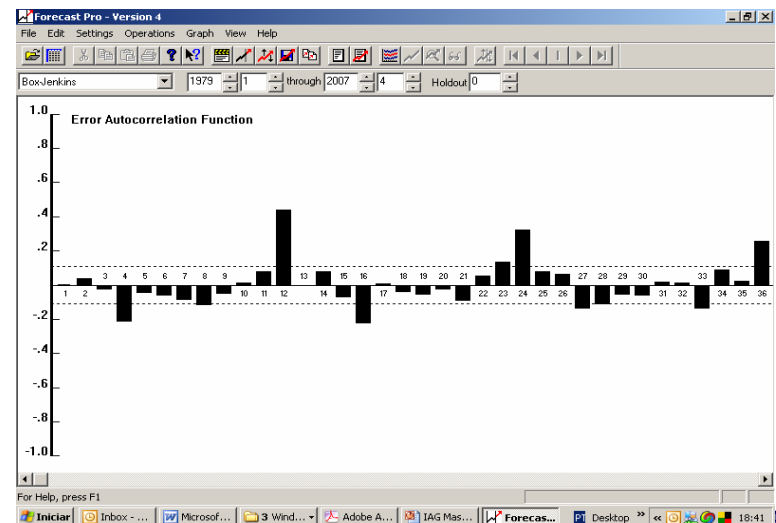
Estatísticas de “Erros”



monica@mbarros.com

41

Estatísticas de “Erros”



monica@mbarros.com

44

Estatísticas de “Erros”



- Neste caso, e sabendo que os dados são mensais, certamente esquecemos de “algo” na concepção do modelo.
- Note as fortíssimas autocorrelações dos erros.
- Certamente “sobrou” estrutura nos erros – isso não é bom.


monica@mbarros.com

43

Estatísticas de “Erros”



■ Outros Padrões:



- Resíduos nos instantes t e $t-12$ têm dependência.

monica@mbarros.com

44



Estatísticas de “Erros”

- Em resumo...
- Se o modelo é bom o ruído é branco, o resíduo não tem estrutura.
- Se houver padrões no resíduo fique esperto!