

TEXTO PARA DISCUSSÃO Nº 464

**Análise de Intervenção via Estimação
Clássica e Bayesiana de Fatores
de Desconto: Uma Aplicação
para o Índice da Produção
Industrial no Brasil**

Elcyon Caiado Rocha Lima^{*}
Ricardo Sandes Ehlers^{**}

Rio de Janeiro, março de 1997

^{*} Da Diretoria de Pesquisa do IPEA e da Universidade Santa Úrsula.

^{**} Da Diretoria de Pesquisa do IPEA e da Universidade Federal Fluminense.



O IPEA é uma fundação pública vinculada ao Ministério do Planejamento e Orçamento, cujas finalidades são: auxiliar o ministro na elaboração e no acompanhamento da política econômica e prover atividades de pesquisa econômica aplicada nas áreas fiscal, financeira, externa e de desenvolvimento setorial.

Presidente

Fernando Rezende

Diretoria

Claudio Monteiro Considera

Luís Fernando Tironi

Gustavo Maia Gomes

Mariano de Matos Macedo

Luiz Antonio de Souza Cordeiro

Murilo Lôbo

TEXTO PARA DISCUSSÃO tem o objetivo de divulgar resultados de estudos desenvolvidos direta ou indiretamente pelo IPEA, bem como trabalhos considerados de relevância para disseminação pelo Instituto, para informar profissionais especializados e colher sugestões.

ISSN 1415-4765

SERVIÇO EDITORIAL

Rio de Janeiro – RJ

Av. Presidente Antônio Carlos, 51 – 14º andar – CEP 20020-010

Telefax: (021) 220-5533

E-mail: editrj@ipea.gov.br

Brasília – DF

SBS Q. 1 Bl. J, Ed. BNDES – 10º andar – CEP 70076-900

Telefax: (061) 315-5314

E-mail: editbsb@ipea.gov.br

© IPEA, 1998

É permitida a reprodução deste texto, desde que obrigatoriamente citada a fonte. Reproduções para fins comerciais são rigorosamente proibidas.

SUMÁRIO

RESUMO

ABSTRACT

1 - INTRODUÇÃO	9
2 - O MODELO UNIVARIADO ESTRUTURAL, O FILTRO DE KALMAN E O USO DE FATORES DE DESCONTO	10
2.1 - O Modelo sem Fatores de Desconto	10
2.2 - O Filtro de Kalman	11
2.3 - Os Fatores de Desconto	12
2.4 - Análise de Intervenção e os Fatores de Desconto Utilizado no Modelo	12
3 - ESCOLHA DOS FATORES DE DESCONTOS	13
3.1 - Especificação Subjetiva dos Fatores de Desconto	13
3.2 - Estimação de Fatores de Desconto	13
4 - AMOSTRAGEM PONDERADA-REAMOSTRAGEM	14
5 - RESULTADO	15
ANEXO	17
BIBLIOGRAFIA	26

RESUMO

Neste artigo especificamos um modelo de univariado estrutural, que decompõe séries de tempo em componentes não-observáveis, para o índice da produção industrial e comparamos os resultados obtidos para os componentes e sazonal, quando os de desconto, inclusive os dos períodos com quebras estruturais (Plano Cruzado e Plano Collor), são estimados através de métodos clássicos e bayesianos (Amostragem Ponderada-Reamostragem).

Os principais resultados encontrados são: **a)** os componentes do índice da produção industrial não são significativamente diferentes quando se utiliza um procedimento estimação clássico ou bayesiano dos fatores de desconto. Este resultado decorre do formato da verossimilhança, que apresenta um pico elevado numa pequena região do espaço dos possíveis valores dos fatores de fatores de desconto; **b)** o procedimento bayesiano de se fixar subjetivamente os fatores de desconto pode implicar um afastamento substancial entre a distribuição a priori do desconto e a verossimilhança; e **c)** os fatores sazonais estimados não são substancialmente diferentes dos obtidos através do método X11- Arima.

ABSTRACT

It is specified an univariate structural model, that decomposes time series in non-observable components, for the Brazilian's index of industrial production. We compare the estimates for the trend and seasonal factors when two different estimation methods, of the discount factors, are used: a classical and a bayesian (Sampling and Re-sampling) method. To detect periods with structural breaks we monitor the series using the bayesian procedure suggested by West (1988). The interventions, for the periods with structural breaks, are carried on imposing a different discount factor for these periods.

The main results are: a) the trend and seasonal components of the index of industrial production are not significantly different when the classical or bayesian methods of estimation of the discount factors are used. This results depends heavily on the shape of the likelihood that has a peak in a small region of the set of possible values for the discounts; b) fixing subjectively the discount factors can result in a substancial departure of the prior distribution of the discount factors from the likelihood; c) the estimated seasonal factors are not very different from those obtained employing the X11-Arima method.

1 - INTRODUÇÃO

Neste artigo especificamos um modelo univariado estrutural¹ — que decompõe séries de tempo em componentes não-observáveis — para o índice da produção industrial e comparamos os resultados obtidos para os componentes tendência e sazonal, quando os fatores de desconto, inclusive os dos períodos com quebras estruturais (Plano Cruzado e Plano Collor), são estimados através de métodos clássicos e bayesianos (Amostragem Ponderada-Reamostragem).

O grupo de acompanhamento conjuntural do IPEA (GAC) utiliza, há algum tempo, um modelo similar nas suas previsões do índice da produção industrial. O modelo do GAC passou a adotar, recentemente, estimativas clássicas dos fatores de desconto [Ehlers (1996)]. No entanto estes, nos períodos de quebra estrutural, não são verdadeiramente estimados e sim obtidos através de uma busca, em uma certa grade de valores, com o objetivo de se maximizar a verossimilhança preditiva.

Os fatores de desconto, que determinam o grau de variabilidade dos parâmetros do modelo ao longo do tempo, têm sido tipicamente adotados por pesquisadores ligados à abordagem bayesiana e têm a grande vantagem de permitir uma interpretação intuitiva, baseada no grau de perda de validade da informação, na estimação de cada componente. Além disto, tornam mais fácil e intuitiva a análise de intervenção no modelo.

No entanto, a utilização de um modelo univariado estrutural, com fatores de desconto, não significa, necessariamente, que o método de estimação seja bayesiano. É perfeitamente possível, como mencionado anteriormente, utilizar-se métodos de estimação clássica de fatores de desconto. No método de estimação clássico os fatores de desconto são considerados parâmetros e no método bayesiano são variáveis aleatórias com uma certa distribuição.

Até recentemente, os cálculos estatísticos baseados no Teorema de Bayes, inerentes aos métodos de estimação bayesianos, com exceção dos casos mais simples, eram extremamente difíceis devido às integrações numéricas requeridas. Na prática, tem sido feita uma escolha totalmente subjetiva dos fatores de desconto. Presentemente, no entanto, a utilização de uma abordagem Amostragem Ponderada-Reamostragem, na inferência bayesiana, tem simplificado bastante a realização de integrações numéricas e permitido a estimação bayesiana dos fatores de desconto. Neste artigo utilizamos a abordagem Amostragem Ponderada-Reamostragem na estimação bayesiana de fatores de desconto [Smith e Gelfand (1992)].

¹ Os modelos univariados estruturais pertencem à classe de modelos lineares com parâmetros variando e West e Harrison (1989) é a referência básica da abordagem bayesiana e Harvey (1989) da abordagem clássica.

Os principais resultados encontrados são: **a)** os componentes do índice da produção industrial não são significativamente diferentes quando se utiliza um procedimento de estimação clássico ou bayesiano dos fatores de desconto. Este resultado decorre do formato da verossimilhança, que apresenta um pico elevado numa pequena região do espaço dos possíveis valores dos fatores de desconto; **b)** o procedimento bayesiano de se fixar subjetivamente os fatores de desconto pode implicar um afastamento substancial entre a distribuição a priori do desconto e a verossimilhança; e **c)** os fatores sazonais estimados não são substancialmente diferentes dos obtidos através do método X11— Arima.

2 - O MODELO UNIVARIADO ESTRUTURAL , O FILTRO DE KALMAN E O USO DE FATORES DE DESCONTO

Nesta seção apresentamos o modelo univariado estrutural, na sua versão mais completa, na qual a tendência local tem uma taxa de crescimento estocástica. Adotamos a seguinte notação: Y_t = série observada; μ_t = tendência local; γ_t = fator sazonal; e β_t = taxa de crescimento.

2.1 - O Modelo sem Fatores de Desconto

O modelo univariado estrutural com taxa de crescimento e sem adoção explícita de fatores de desconto:

$$Y_t = \mu_t + \gamma_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma^2)$$

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t, \quad \eta_t \sim N(0, W_{1t})$$

$$\beta_t = \beta_{t-1} + \xi_t, \quad \xi_t \sim N(0, W_{2t})$$

$$\begin{bmatrix} \gamma_{j,t} \\ \gamma_{j,t}^* \end{bmatrix} = \begin{bmatrix} \cos 2\pi j / s & \sin 2\pi j / s \\ -\sin 2\pi j / s & \cos 2\pi j / s \end{bmatrix} \begin{bmatrix} \gamma_{j,t-1} \\ \gamma_{j,t-1}^* \end{bmatrix} + \begin{bmatrix} \omega_{j,t} \\ \omega_{j,t}^* \end{bmatrix} \quad j=1, \dots, s/2-1$$

e $\gamma_{j,t} = -\gamma_{j,t-1} + \omega_{jt}$ para $j = s/2$.

O modelo acima pode ser descrito, em uma forma bem sucinta, por :

$$y_t = X \theta_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma^2) \quad \text{equação da medida}$$

$$\theta_t = T \theta_{t-1} + v_t, \quad v_t \sim N(0, W_t) \quad \text{equação de transição}$$

onde:

$$\theta_t = (\mu_t; \beta_t; \lambda_{1,t}; \lambda_{1,t}^*; \lambda_{2,t}; \lambda_{2,t}^*; \dots; \lambda_{(s/2)-1,t}; \lambda_{(s/2)-1,t}^*; \lambda_{(s/2),t})'$$

$$X_t = (1; 0; 1; 0; 1; 0; \dots; 1; 0; 1)$$

$$v_t = (\eta_t; \xi_t; \omega_{1t}; \omega_{1t}^*; \omega_{2t}; \omega_{2t}^*; \dots; \omega_{(s/2)-1t}; \omega_{(s/2)-1t}^*; \omega_{(s/2)t})'$$

As hipóteses básicas são:

$$\begin{bmatrix} \varepsilon_t \\ v_t \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} \sigma^2 & 0 \\ 0 & W_t \end{bmatrix} \right)$$

e $E(\theta_0 \varepsilon'_t) = E(\theta_0 v'_t) = 0 \quad \forall t$.

2.2 - O Filtro de Kalman

Seja $I_t = \{y_t, \dots, y_1\}$. Então a informação a posteriori sobre θ , no tempo $t-1$, é resumida por uma distribuição normal:

$$\theta_{t-1} | I_{t-1} \sim N(m_{t-1}, \Sigma_{t-1}).$$

A aplicação direta das equações de transição leva a uma distribuição a priori normal para θ no instante t :

$$\theta_t | I_{t-1} \sim N(a_t, R_t)$$

onde: $a_t = T m_{t-1}$ e $R_t = T \Sigma_{t-1} T' + W_t$.

A previsão 1 passo à frente de y_t também é uma combinação linear de variáveis normalmente distribuídas e, portanto:

$$y_t | I_{t-1} \sim N(f_t, q_t)$$

onde: $f_t = X_t a_t$ e $q_t = X_t R_t X_t' + \sigma^2$.

Após observar-se y_t , esta informação é incorporada ao modelo combinando-a com a priori. Pode-se mostrar que:

$$\theta_t | I_t \sim N(m_t, \Sigma_t)$$

onde:

$$m_t = a_t + A_t e_t$$

$$\Sigma_t = R_t - A_t A_t' q_t$$

$$A_t = R_t X_t' / q_t \text{ (ganho do filtro) e}$$

$$e_t = y_t - f_t \text{ é o erro de previsão.}$$

2.3 - Os Fatores de Desconto

A idéia de que o conteúdo informativo de uma observação decai com sua idade é bem intuitiva. Brown (1962) desenvolveu a técnica de regressão exponencialmente ponderada utilizando um único fator de desconto. Ameen e Harrison (1985) e Harrison e Johnston (1984) estenderam a idéia de Brown permitindo vários fatores de desconto (um para cada componente).

O *fator de desconto* é o parâmetro básico que controla o grau de “envelhecimento” do conteúdo informativo de uma observação. Por exemplo, podemos quantificar o “envelhecimento” da informação sobre o parâmetro μ_t como um aumento de 5% na sua variância a priori (no tempo t), isto é:

$$\text{Var}(\mu_t | I_{t-1}) = (1+\delta) \text{Var}(\mu_{t-1} | I_{t-1})$$

com $\delta = 0.05$. Por outro lado, informação é em geral medida em termos de *precisão* (o inverso da variância) e podemos escrever:

$$\text{Precisão}(\mu_t | I_{t-1}) = (1+\delta)^{-1} \text{Precisão}(\mu_{t-1} | I_{t-1}).$$

Nesta escala, o *fator de desconto* $\lambda = (1+\delta)^{-1}$ varia entre 0 e 1 e $\delta = 5\%$ implica $\lambda \approx 0.95$. Vale notar que os fatores de desconto não dependem da escala em que as observações são medidas. A mesma abordagem é adotada para especificar o fator de desconto do componente sazonal.

Se $\lambda = 1$ não existe qualquer alteração ao longo do tempo dos componentes do modelo e quanto menor for λ maior será a alteração destes componentes ao longo do tempo e maior será a perda de informação contida em observações mais antigas [para maiores detalhes ver Ameen e Harrison (1985) e Harrison e Johnston (1984)].

2.4 - Análise de Intervenção e os Fatores de Desconto Utilizados no Modelo

Neste trabalho utilizamos um modelo univariado estrutural sem taxa de crescimento e com fatores sazonais. Procuramos também lidar com a possibilidade de quebras de padrão na série devido ao Plano Cruzado e ao Plano Collor. Deste modo adotamos, para todos os períodos com a exceção de 86.04 (Plano Cruzado) e 90.04 (Plano Collor), uma matriz de fatores de desconto diagonal, com um fator de desconto para o componente tendência e outro para o

componente sazonal. Em 86.04, admitimos que os fatores de desconto pudessem diferir daqueles dos demais meses. O mesmo procedimento foi adotado para 90.04.

Desta forma o nosso modelo possui seis fatores de desconto a serem estimados: para a tendência e para o componente sazonal nos períodos sem intervenção e dois (um para cada componente do modelo) para cada um dos meses em que se intervem no modelo (86.04 e 90.04).

3 - ESCOLHA DOS FATORES DE DESCONTOS

3.1 - Especificação Subjetiva dos Fatores de Desconto

Utilizando a noção de perda de informação ao longo do tempo, Harrison e Johnston (1984) propõem especificar o fator de desconto como:

$$\lambda = (3n - 1) / (3n + 1)$$

onde n é o número de períodos necessários para que se perca metade da informação. Esta abordagem não foi utilizada neste trabalho.

3.2 - Estimação de Fatores de Desconto

Utilizaremos, nesta seção, a seguinte notação:

- a) modelo para os dados - $p(y | \theta, \lambda)$;
- b) distribuição a priori para θ - $q(\theta)$ (θ = parâmetros de interesse — tendência e sazonal); e
- c) distribuição a priori para λ - $h(\lambda)$ (λ = vetor dos fatores de desconto).

Para cada coeficiente de θ adota-se, como distribuição a priori, uma distribuição normal independente com média zero e variância igual a 10000 (priori vaga). Para cada fator de desconto adota-se, como distribuição a priori, uma distribuição uniforme independente no intervalo [0.05 ; 1].

Pelo teorema de Bayes, então, $f(\theta | y, \lambda) \propto p(y | \theta, \lambda) q(\theta)$. Se há interesse em obter-se a verossimilhança para os fatores de desconto, basta fazer-se a seguinte integração:

$$m(y | \lambda) = \int p(y | \theta, \lambda) g(\theta) d\theta$$

Após observar-se y , $m(y|\lambda)$ faz o papel formal de uma verossimilhança para os fatores de desconto. Dados y e λ , pode-se utilizar o filtro de Kalman, como descrito na Subseção 2.2, para obter-se $m(y|\lambda)$. Como $h(\lambda)$, a distribuição a priori para os fatores de desconto, no nosso artigo, é vaga na região onde $m(y|\lambda)$ assume seus maiores valores, então $n(\lambda|y) \propto m(y|\lambda)$. As inferências, a respeito da distribuição a posteriori de λ , podem então ser feitas a partir de $m(y|\lambda)$. Neste caso a estimativas clássica e bayesiana dos fatores de desconto são equivalentes. Obter-se o valor de λ que maximiza $m(y|\lambda)$ é o mesmo que se obter a moda de $n(\lambda|y)$.

No entanto, os métodos clássico e bayesiano de estimação de θ são diferentes. No método clássico basta estimar-se θ condicional no valor de λ que maximiza $m(y|\lambda)$. Já no método bayesiano é necessário se fazer a seguinte integração:

$$f(\theta|y) = \int k(\theta|y, \lambda) n(\lambda|y) d\lambda,$$

onde:

$$k(\theta|y, \lambda) = p(y|\theta, \lambda) g(\theta) / m(y|\lambda).$$

No nosso artigo obtemos esta última integração pelo método de Amostragem Ponderada-Reamostragem, apresentado a seguir.

4 - AMOSTRAGEM PONDERADA-REAMOSTRAGEM

Como mencionado anteriormente, adotamos, para cada fator de desconto, como distribuição a priori, distribuições uniformes no intervalo [0.05; 1]. Não utilizamos zero, como limite inferior, porque o modelo não está definido para este valor do fator de desconto.

A Amostragem Ponderada foi conduzida da seguinte forma:

- a)** para cada fator de desconto (existem seis), é feita uma extração independente (com reposição) de uma distribuição uniforme definida no intervalo [0.05; 1];
- b)** o procedimento descrito em **(a)** foi repetido 49.500 vezes;
- c)** através dos procedimentos **(a)** e **(b)** são obtidos 49.500 pontos no espaço (\mathbb{R}^6) dos possíveis valores dos fatores de desconto;
- d)** para cada um dos 49.500 pontos (λ_j) é atribuída uma probabilidade π_j . Sendo:

$$\pi_j = m(\mathbf{y} | \lambda_j) / \sum_{i=1}^{49500} m(\mathbf{y} | \lambda_i).$$

Os procedimentos descritos nos itens anteriores permitem obter uma amostra da posteriori de λ , ou seja, dos fatores de desconto. Poderíamos utilizar esta amostra para realizarmos a integração necessária à obtenção da posteriori de θ , ou seja, a tendência e os fatores sazonais. No entanto, como descreveremos a seguir, esta integração pode ser feita de maneira menos custosa utilizando-se os resultados da Reamostra [ver, a este respeito, Smith e Gelfand (1992)].

A Reamostragem foi obtida fazendo-se 5.000 extrações (com reposição) da amostra da posteriori de λ . A tendência e o fator sazonal da produção industrial, em cada período t , foram obtidos através da média simples dos seus valores suavizados (utilizando toda a informação amostral) obtidos para cada valor de λ pertencente à Reamostra.

Os gráficos das Figuras 1, 2 e 3 apresentam os resultados da amostra da posteriori de λ para os 1.986 pontos, no espaço dos fatores de desconto, com maior probabilidade, já que o pacote STATGRAPHICS não foi capaz, por falta de memória, de mapear os 49.500 pontos sorteados. O gráfico da Figura 1 apresenta a distribuição a posteriori, dos dois fatores de desconto (tendência e sazonal) para os meses sem intervenção, quando é feita a integração em relação aos dois outros fatores de desconto. Os gráficos das Figuras 2 e 3 são similares ao da Figura 1 e apresentam as amostras das distribuições a posteriori dos fatores de desconto dos meses em que foram feitas intervenções no modelo (86.04 e 90.04).

Os gráficos das Figuras 4, 5 e 6 apresentam os resultados de uma reamostra com 1.500 sorteios da amostra ponderada. Novamente, utilizamos no gráfico 1.500 sorteios devido às limitações de memória do STATGRAPHICS. No entanto, na obtenção das estimativas finais da tendência e componente sazonal, foram utilizados 5.000 sorteios. O gráfico da Figura 4 apresenta os resultados para os fatores de desconto dos períodos sem intervenção e os gráficos das Figuras 5 e 6 os dos períodos de intervenção.

No conjunto de gráficos da Figura 7 apresentamos os histogramas das amostras das posterioris marginais dos seis fatores de desconto. Como os fatores de desconto não são independentemente distribuídos, inferências baseadas em distribuições marginais podem induzir a erros.

5 - RESULTADOS

Utilizando-se os métodos clássico e bayesiano de estimação (este último baseado na moda da amostra da distribuição a posteriori) obtivemos as seguintes para os fatores de desconto apresentadas na Tabela 1.

Tabela 1

Estimativas dos fatores de desconto utilizando os métodos clássico e bayesiano para cada componente do modelo para os períodos sem intervenção e para os dois períodos de intervenção

	Clássico		Bayesiano	
	Tendência	Sazonal	Tendência	Sazonal
Sem intervenção	0.821381	0.788281	0.816396	0.795956
Plano Cruzado	0.05	1.000000	0.111723	0.819875
Plano Collor	0.05	0.7161406	0.139323	0.434082

Note-se que, em ambos os métodos, a intervenção é bem mais forte no componente de tendência com uma redução drástica nos fatores de desconto associados. Quanto ao componente sazonal, os dois métodos estimam fatores de desconto menores apenas no Plano Collor, sendo que a redução é maior no método bayesiano.

Os resultados para os componentes do modelo (tendência e sazonal) são apresentados no conjunto de gráficos da Figura 8. Junto com as estimativas clássica e bayesiana são também apresentados os resultados quando se utiliza o procedimento X11-Arima (no Anexo I estão as estimativas do modelo Arima selecionado). Como se pode observar não há diferença entre o método SIR e o de Máxima Verossimilhança. No entanto, não se rejeita que o Plano Cruzado e o Plano Collor tiveram um impacto significativo no Índice da Produção Industrial.

Anexo I

X11 Procedure — Seasonal Adjustment of - PIND

Conditional Least Squares Estimation

	Approx.			
Parameter	Estimate	Std Error	T Ratio	Lag
MU	0.06903	0.09669	0.71	0
MA1,1	-1.07469	0.02854	-37.66	1
MA1,2	-0.96446	0.02962	-32.56	2
MA2,1	0.81031	0.05114	15.85	12
AR1,1	-1.13328	0.01437	-78.89	1
AR1,2	-0.99233	0.01427	-69.55	2

Constant Estimate = 0.21577

Variance Estimate = 26.50679

Std Error Estimate = 5.14847

AIC = 1063.83657*

SBC = 1082.75632*

Number of Residuals = 173

* Does not include log determinant.

Criteria Summary for Model 5: (2,1,2) (0,1,1)s, No Transformation

Box-Ljung Chi-square: 29.93 with 19 df Prob= 0.05

(Criteria prob > 0.05)

Test for over-differencing: sum of MA parameters = 0.81

(must be < 0.90)

MAPE - Last Three Years: 3.28 (Must be < 15.00 %)

- Last Year: 2.81

- Next to Last Year: 4.04

- Third from Last Year: 2.99

The SAS System 75

15:39 Saturday, August 31, 1996

Seasonal Adjustment of - PIND

Stable Seasonality Test

	Sum of	Dgrs.of	Mean	F
	Squares	Freedom	Square	
Between Months	11495.754	11	1045.069	68.087
Error	2670.715	174	15.349	
Total	14166.469	185		

Probability of a Larger F is < 0.0001

Figura 1

Fatores de desconto dos componentes do modelo para os períodos sem intervenção. Dentre os 49.500 pontos foram selecionados 1.986 com as maiores probabilidades




Figura 2

Fatores de desconto da componente de tendência para os períodos com intervenção. Dentre os 49.500 pontos foram selecionados 1.986 com as maiores probabilidades




Figura 3
Fatores de desconto da componente sazonal para os períodos com intervenção.
Dentre os 49.500 pontos foram selecionados os 1.986 com as maiores probabilidades




Figura 4
Fatores de desconto dos componentes do modelo para os períodos sem intervenção. Dentre os 49.500 pontos foram selecionados 1.500 via amostragem ponderada




Figura 5

Fatores de desconto da componente de tendência para os períodos com intervenção. Dentre os 49.500 pontos foram selecionados 1.500 via amostragem ponderada




Figura 6
Fatores de desconto da componente sazonal para os períodos com intervenção.
Dentre os 49.500 pontos foram seleccionados 1.500 via amostragem ponderada




Figura 7

Histogramas das amostras das posteriores marginais dos fatores de desconto dos componentes de tendência e sazonalidade e dos períodos de intervenção

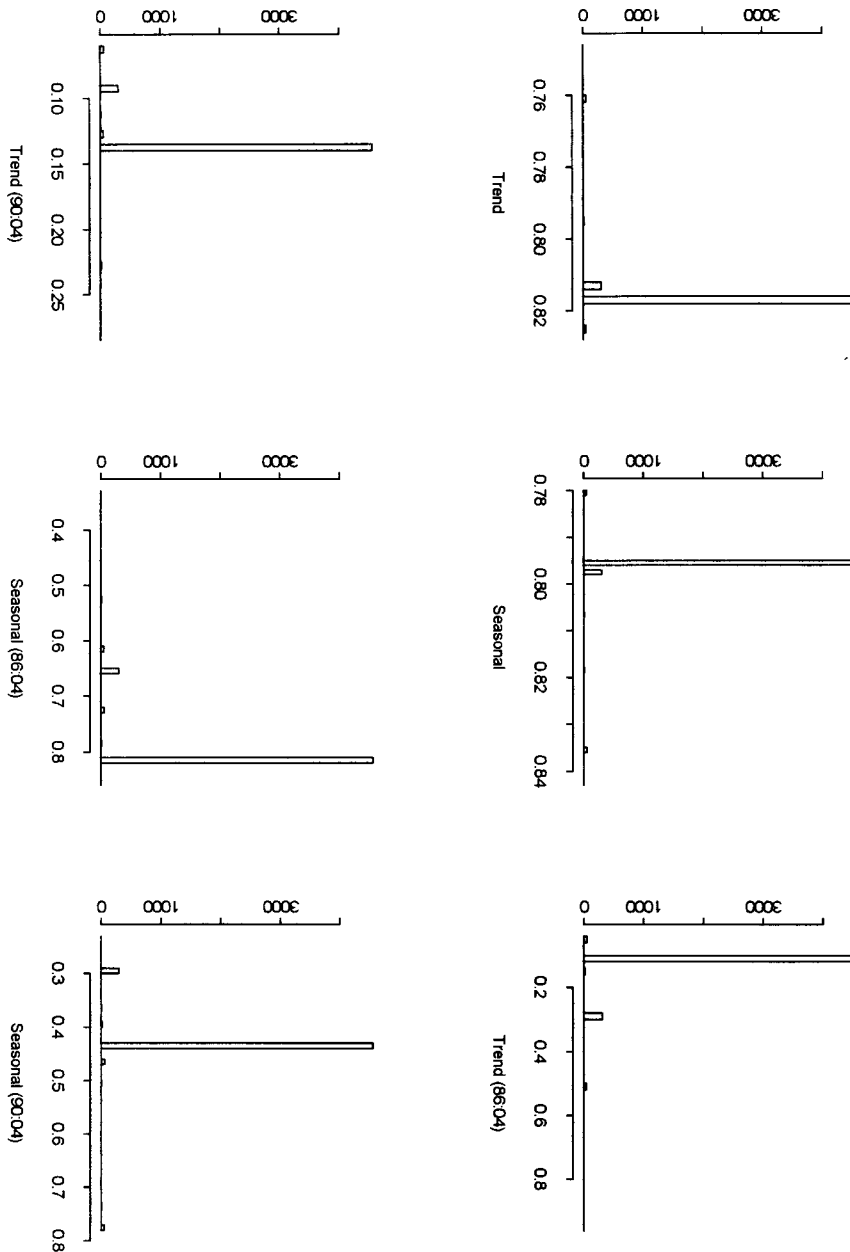




Figura 8
Componentes de tendência e sazonal suavizados para os anos em que ocorreram intervenções — 1986/90



Obs.: Fatores sazonais suavizados.



Obs.: Tendências suavizada.

BIBLIOGRAFIA

- AMEEN, J.R.M., HARRISON, P.J. Normal discount bayesian models. In: BERNARDO, J.M. **et alii** (eds.). **Bayesian Statistics 2**. Valencia University Press, 1985.
- HARRISON, J., JOHNSTON, F.R. Discount weighted regression. **Journal of the Operational Research Society**, v.35, n.10, p.923-932, 1984.
- HARVEY, A.C. **Forecasting, structural time series models and the Kalman Filter**. Cambrigde University Press, 1989.
- EHLERS, R.S. Modelos estruturais bayesianos: aplicação às séries de produção industrial e PIB no Brasil. **Boletim Conjuntural**, n.34, p.41-44, jul. 1996.
- SMITH, A.F.M., GELFAND, A.E. Bayesian statistics without tears: a sampling - resamplig perspective. **The American Statistician**, v.46, n.2, p.84-88, 1992.
- WEST, M., HARRISON, J. **Bayesian forecasting and dynamic models**. New York: Springer-Verlag, 1989.

