

GUILHERME BITENCOURT MARTINS

# ANÁLISE DE PREVISÕES ECONÔMICAS

Trabalho de Conclusão de Curso apresentado ao  
Curso de Matemática - Licenciatura  
Departamento de Matemática  
Centro de Ciências Físicas e Matemáticas  
Universidade Federal de Santa Catarina

Orientador: Roberto Meurer

Florianópolis  
Dezembro 2007

# Sumário

<b>INTRODUÇÃO</b>	<b>3</b>
<b>1 MOTIVAÇÃO ECONÔMICA</b>	<b>4</b>
<b>2 NOTAÇÃO</b>	<b>4</b>
<b>3 SÉRIES TEMPORAIS</b>	<b>5</b>
3.1 SOBRE AS SÉRIES . . . . .	5
3.2 IPEADATA . . . . .	6
3.3 PRODUÇÃO INDUSTRIAL . . . . .	6
3.4 IMPORTAÇÕES . . . . .	8
3.5 EXPORTAÇÕES . . . . .	8
3.6 CARACTERÍSTICAS . . . . .	9
<b>4 SUAVIZAÇÃO</b>	<b>10</b>
4.1 MÉDIA MÓVEL . . . . .	10
4.2 EXPONENCIAL . . . . .	11
4.3 ERRO . . . . .	12
4.4 U de Theil . . . . .	13
<b>5 DECOMPOSIÇÃO</b>	<b>15</b>
5.1 TENDÊNCIA E CICLO . . . . .	16
5.1.1 MÉDIA MÓVEL . . . . .	17
5.1.2 EXPONENCIAL . . . . .	19
5.2 SAZONALIDADE . . . . .	25
5.3 RESÍDUO OU COMPONENTE ALEATÓRIO . . . . .	26
<b>6 AVALIAÇÃO DOS MODELOS</b>	<b>26</b>
<b>7 PREVISÕES POR DECOMPOSIÇÃO CLÁSSICA</b>	<b>39</b>
7.1 SAZONALIDADE . . . . .	40
7.2 EXPORTAÇÕES BRASILEIRAS . . . . .	40
7.3 IMPORTAÇÕES BRASILEIRAS . . . . .	43
7.4 PRODUÇÃO INDUSTRIAL BRASILEIRA . . . . .	46
<b>8 MÉTODO DE HOLT-WINTERS</b>	<b>48</b>
8.1 MÉTODO DE HOLT . . . . .	48
8.2 MÉTODO DE WINTERS . . . . .	49
8.3 VALORES INICIAIS . . . . .	50

8.4	OTIMIZAÇÃO DOS PARÂMETROS . . . . .	51
8.5	PREVISÕES PELO MÉTODO DE HOLT-WINTERS . . . . .	52
<b>9</b>	<b>CONCLUSÃO</b>	<b>63</b>
<b>10</b>	<b>ANEXOS</b>	<b>65</b>

# INTRODUÇÃO

Cada vez mais formulamos hipóteses imaginando de maneira coerente o que pode ocorrer futuramente em certa situação, seja na semana, no dia, na hora seguinte, enfim. O contexto econômico conta com recursos capazes de produzir séries temporais a partir das observações de algum dado econômico, estas que compõem os termos da série. Podemos ver que, apesar da complexidade e incerteza dos eventos que geram tais dados ao longo do tempo, eles possuem uma determinada similaridade, continuidade, podendo ser preditíveis. Permitindo generalizações de eventos futuros, frequentemente corretas, partindo de experiências passadas.

As mais diversas áreas do conhecimento humano se interessam pela previsão do comportamento futuro dos acontecimentos. Particularmente em finanças, a possibilidade de se realizar alguma previsão confiável que permita a antecipação da decisão de um investidor em relação às expectativas do mercado.

Serão analisadas neste trabalho séries de *Produção Industrial, Importações e Exportações* brasileiras, através dos métodos de previsão por Decomposição Clássica e Holt-Winters, com intenção de avaliar a eficiência destes. Contando com auxílio de ferramentas computacionais, podemos caracterizá-los para determinar os coeficientes necessários na modelagem das séries e assim concluir as previsões, verificando qual dos métodos obteve a melhor previsão.

# 1 MOTIVAÇÃO ECONÔMICA

Alguns dados macroeconômicos, como o PIB (Produto Interno Bruto), a produção industrial, o investimento, etc em geral apresentam tendência de crescimento. Este é um reflexo da idéia do desenvolvimento econômico, que é formulada em diversas teorias de desenvolvimento com base em fatores como o crescimento da população economicamente ativa, a acumulação de capital, o nível de poupança e investimento, o aumento da produtividade devido o desenvolvimento de tecnologias etc. Dada essa tendência ao crescimento tais séries nos permitem caracterizá-las com uma componente de tendência, conforme seu histórico evolutivo.

Normalmente há um espaço de tempo entre anúncio de um evento iminente ou necessidade e ocorrência deste evento. Este importante período é a principal razão para planejar e prever. Se este é zero ou muito pequeno não há a necessidade de planejamento. Porém, se dispormos de um longo tempo, e os resultados do fim de tal evento condicionados a fatores identificados, planejar pode desempenhar uma importante função. Em certas situações previsões são necessárias para determinar quando o evento ocorrerá ou precisa aparecer, e então ações apropriadas são feitas.

As perspectivas numa previsão são provavelmente tão diversas como olhares num conjunto de métodos científicos utilizados pelos gestores em suas decisões. Quem decidirá devido as previsões pode questionar a validade e eficácia de um estudo que visa o futuro incerto. No entanto, ele reconhecerá que importantes progressos em previsões têm ocorrido durante um histórico passado. Há fenômenos que agora tornam-se facilmente preditos.

Habilidade para prever vários tipos de eventos aparecem, como naturalmente hoje temos boas previsões de condições de tempo, em poucas décadas. A tendência na série possibilita prever eventos mais precisamente, particularmente nos de natureza econômica, proporcionando uma melhor base de planejamento.

Um ponto importante é a distinção entre eventos externos incontroláveis (originados com a economia nacional, governantes, clientes e competidores) e eventos internos controláveis (tais como decisões de comercialização e produção com solidez). O sucesso de uma companhia depende de ambos tipos de eventos, mas previsões aplicam-se diretamente para prever, enquanto decisões de mercado aplicam-se diretamente para o passado ocorrido. Assim temos que o planejamento faz a ligação que entre eles.

## 2 NOTAÇÃO

Previsões numéricas são dados, ou observações, que representam alguma variável

de interesse. Denotado-se  $x_i$  para um termo qualquer da série (vide tabela 1). Esta variável pode ser um número atual de taxa de câmbio, que é a relação entre moedas, custo de produção, ou qualquer outro dado de interesse, desde que possa ser quantificado. O objetivo de uma previsão é prever valores de  $X$ .  $f_i$  e  $\hat{x}_i$  denotam um termo qualquer previsto e  $e_i$  denota o erro, que é a diferença entre o valor atual da série e o valor previsto no período  $i$ :

$$e_i = x_i - \hat{x}_i \text{ ou } e_i = x_i - f_i$$

Em previsões de séries temporais e neste trabalho onde os dados são obtidos igualmente espaçados no tempo,  $t$  denota o período presente no tempo,  $t - 1$  o período anterior,  $t - 2$  dois períodos atrás, seguindo desta forma. Um período pode ser um dia, uma semana, um mês, ou outro espaço de tempo. Assim como  $t + m$  denota a previsão para  $m$  períodos futuros.

	Presente	Previsões
Valores Observados	$x_1, x_2, x_3, \dots x_{t-2}, x_{t-1}, x_t$	$f_{t+1}, f_{t+2}, \dots f_{t+m}$
Período $i$	1, 2, 3, ... t-2, t-1, t	t+1, t+2, ... t+m
Valores Estimados	$\hat{x}_1, \hat{x}_2, \hat{x}_3, \dots \hat{x}_{t-2}, \hat{x}_{t-1}, \hat{x}_t$ $f_1, f_2, f_3, \dots f_{t-2}, f_{t-1}, f_t$	$\hat{x}_{t+1}, \hat{x}_{t+2}, \dots \hat{x}_{t+m}$
Erro	$e_1, e_2, e_3, \dots e_{t-2}, e_{t-1}, e_t$	

Tabela 1: Notação usada em previsões de séries temporais

### 3 SÉRIES TEMPORAIS

**Definição 3.1** *Uma série temporal  $X$  é um conjunto discreto de amostras  $x_t$  observadas ao longo do tempo, em intervalos igualmente espaçados ou não, apresentando certa dependência entre seus instantes. A série  $X$  que possui  $t$  termos, escrevemos  $X_t$ . Assim,  $X_t = \{x_1, x_2, \dots, x_t\}$ , onde  $x_t$  é o último valor observado.*

Formalmente dizemos que uma série temporal é a realização de um processo estocástico, que é regido pela imprevisibilidade. É aleatório. Um processo assim produz resultados diferentes e imprevisíveis a cada observação futura. O contrário disso seria um processo determinístico.

#### 3.1 SOBRE AS SÉRIES

A dependência entre os valores da série que será analisada é um aspecto essencial,

pois com ela torna-se possível gerar previsões usando métodos que permitem estimar valores futuros da série. Estas previsões seriam um "chute" se não houvesse tal dependência. Logo, não se pode assegurar que a previsão obtida por certo método será sempre "boa", tudo depende das características da série em questão. Visto que diferentes séries possuem diferentes índices de previsibilidade; como exemplo, percebe-se que é frequentemente mais fácil prever uma série de temperaturas médias mensais do que a taxa mensal de inflação. Ainda, um aspecto que se deve considerar ao fazer previsões de séries temporais é o nível de incerteza, que aumenta com o horizonte de previsão, ou seja, quanto mais longe no futuro, maior é a incerteza relacionada ao valor previsto. O que é intuitivamente razoável, pois prever o futuro distante é mais difícil, devido a quantidade de incertezas que cercam a previsão.

Observando o comportamento gráfico dos dados, tem-se indicativos de relação entre sub-períodos que compõem os dados obtidos. O que pode facilitar a decisão na escolha de modelos para a previsão.

Neste trabalho serão tratadas séries de produção industrial, exportações e importações brasileiras. Dada periodicidade mensal temos que seus termos são igualmente espaçados, início é janeiro de 1977, data mais antiga na qual as séries possuem termos, fim é julho de 2007, totalizando 367 termos. A fonte é a base de dados do Ipeadata, órgão responsável por tais publicações.

## **3.2 IPEADATA**

O Ipeadata é uma base de dados macroeconômicos, financeiros e regionais do Brasil mantida pelo Ipea, Instituto de Pesquisa Econômica Aplicada. Com acesso gratuito, oferece também catálogo de séries e fontes, dicionário de conceitos econômicos, histórico das alterações da moeda nacional, e informações sobre métodos e fontes utilizadas.

O sistema é amigável, utiliza tecnologias simples e possibilita pesquisar e extrair dados por fontes, tema ou nome da série; construir tabelas, gráficos e mapas; e realizar operações matemáticas e estatísticas, dentre elas o cálculo de variações percentuais, médias móveis, mudanças de base e de periodicidade, e geração de números-índice e logaritmos. O Ipeadata permite ao usuário exportar dados, tabelas, gráficos e mapas para editores como Excel e Word.

## **3.3 PRODUÇÃO INDUSTRIAL**


A série de Produção Industrial brasileira é formada a partir das informações coletadas, pelo IBGE (Instituto Brasileiro de Geografia e Estatística), na Pesquisa

Industrial Mensal-Produção Física - PIM-PF, resultando na divulgação de índices mensais relativos a tal produção, esclarecendo que a série de produção trabalhada aqui envolve a indústria geral, que compreende a indústria extrativa e a indústria de transformação.

A variável levantada pela pesquisa é a produção física de uma série de produtos previamente selecionados e, sob determinadas hipóteses, considera-se que a mesma serve como uma medida aproximada da evolução de curto prazo do valor adicionado da indústria.

Assim, os indicadores são construídos a partir das informações de quantidades produzidas, de um conjunto de produtos selecionados, levantadas pela PIM-PF. Os produtos, que são objeto da pesquisa, estão, por sua vez, relacionados a uma e somente uma atividade econômica e, por meio de um sistema de ponderação, construído com base nas fontes de dados disponíveis (PIA-Empresa e PIA-Produto), é possível agregar as informações de quantidades físicas e calcular os indicadores.


Por fim a série de Produção Industrial é divulgada. O número-índice de *quantum*, denominado Índice de Base Fixa Mensal, reflete a variação da produção do mês em relação ao período-base. Abaixo temos o gráfico desta série, *quantum*, índice (média 2002=100), onde podemos observar o seu comportamento.






### 3.4 IMPORTAÇÕES

Na série de Importações brasileiras os termos estão em milhões de dólares, obtidos da Seção Balanço de Pagamentos do Banco Central do Brasil. Nesta série, principalmente na primeira parte de seus dados, nota-se a presença de um fator cíclico oscilando a tendência de longo prazo. Abaixo encontra-se o gráfico desta série, onde podemos observar o seu comportamento. Claramente nota-se que a série possui tendência de crescimento, incluindo uma variação com relação a tal tendência.



### 3.5 EXPORTAÇÕES

A série de Exportações brasileiras é obtida como a série de Importações. A seguir temos o gráfico onde visualizamos seu comportamento ao longo do tempo observado. Aqui, visualmente nota-se uma mudança considerável no comportamento de longo prazo, observado o histórico da série. Como na série de importações, percebe-se que há tendência de crescimento, apesar da variação a que está sujeita.



As séries, de Importações e de Exportações, possuem uma grande similaridade em seus comportamentos no decorrer do tempo. Bem como a série de produção mostra influências destas duas séries. Possíveis relações entre os comportamentos das séries desempenham papel fundamental no estudo, permitindo assim compreender quais fatores influenciam direta ou parcialmente no conjunto dos dados observados.

### 3.6 CARACTERÍSTICAS

A partir dos dados fornecidos pela base de dados, faz-se uma separação nos termos. Definimos que os 360 primeiros termos serão tratados para definir as previsões, dos últimos 7, e assim avaliar tais previsões.

As séries são analisadas com relação ao seu comportamento evolutivo. Os métodos de previsão decompõem as séries com relação a tal comportamento. Podemos obter, a partir de seus valores, indicativos de tendência, comportamento cíclico e sazonalidade, além de sua variação aleatória, os quais podem ser definidos numericamente, através da otimização dos parâmetros necessários na composição destes indicativos, para uso nos modelos correspondentes aos métodos. Tal decomposição da série é interessante pois em muitos casos apresenta melhores resultados do que previsão ingênua ou de média simples.

**Definição 3.2** *Previsão Ingênua se caracteriza como um dos mais simples métodos de previsão, deixando de considerar componentes da série, como tendência e sazonalidade. Usa apenas o último termo observado na série como previsão para o próximo período ou períodos posteriores. Ou seja, dada uma série  $Y_t = \{y_1, y_2, \dots, y_t\}$  a previsão para o próximo período ( $y_{t+1}$ ) é  $y_t$ .*

**Definição 3.3** *Previsão por Médias Simples se caracteriza como um método simples de previsão, faz apenas o cálculo da média aritmética dos valores da série, tomando este resultado como previsão para o próximo período. Assim possibilitando construir valores futuros, a partir de cada valor definido como previsão. Ou seja, dada uma série  $Y_t = \{y_1, y_2, \dots, y_t\}$  a previsão para o próximo período é  $y_{t+1} = \frac{y_1+y_2+\dots+y_t}{t}$ .*

Para caracterizar os métodos de previsão precisamos suavizar a série, definindo certo peso para cada termo permitindo assim aplicar tais métodos.

## 4 SUAVIZAÇÃO

Podemos suavizar uma série de diversas formas distintas porém, aqui o interesse se volta para os métodos de suavização, de médias móveis e exponenciais, que são utilizados nas previsões pelo método de Holt-Winters. Estes métodos consistem em simplesmente dar peso ou suavizar as observações passadas na série, em ordem, para obter uma previsão para o futuro. Suavizando estes valores históricos, erros aleatórios são medidos fornecendo uma previsão suave que parece trabalhar bem em certas situações. As principais vantagens destes métodos são seu baixo custo, a facilidade com que podem ser aplicados e a velocidade com que são adotados. Estas características os tornam particularmente interessantes quando um grande número de itens será previsto e quando o horizonte de tempo é relativamente pequeno, menor que 1 ano.

### 4.1 MÉDIA MÓVEL

Médias móveis podem ser simples, duplas, triplas, n-uplas. Aqui faremos uso de médias simples. O termo médias móveis é usado para descrever o procedimento pois a cada nova observação que torna-se válida, uma nova média pode ser computada pela queda da observação mais antiga e inclusão de uma nova. Permanecendo o mesmo número de pontos de dados necessários para o cálculo da média, incluindo

observações mais recentes.

**Definição 4.1** *Dada uma série com  $n$  pontos, dizemos que  $MA(T)$  com  $T < n$  é a média móvel de ordem  $T$ , onde cada média usa  $T$  observações.*

Assim, dada uma série  $X = \{x_1, x_2, \dots, x_n\}$  temos que a primeira média móvel possível é  $MA(T)_1 = \frac{x_1+x_2+\dots+x_T}{T}$ , a segunda é  $MA(T)_2 = \frac{x_2+x_3+\dots+x_{T+1}}{T}$ , seguindo desta forma até,  $MA(T)_{n-T} = \frac{x_{n-T}+x_{n-T+1}+\dots+x_n}{T}$ .

Nesta suavização define-se pesos (coeficientes) para os dados da série, ou seja, a  $MA(T)_{n-T} = \frac{x_{n-T}+x_{n-T+1}+\dots+x_n}{T}$  usa  $T$  dados da série e define peso  $(\frac{1}{T})$  para cada um deles.

## 4.2 EXPONENCIAL

Podemos compor uma suavização exponencial simples, dupla, tripla, etc. Todas elas tem em comum a propriedade que valores recentes têm maior peso na previsão que os valores mais velhos. Pretendendo fazer previsões através do método de Holt-Winters, justifica o uso da suavização exponencial simples, que recebe este nome para simplificar a linguagem visto que a execução do método consiste em incluir pesos que decrescem exponencialmente quanto mais velhas são as observações. Esta suavização exponencial foi o primeiro método a ser desenvolvido ainda durante a segunda guerra mundial e sua aplicação no setor industrial aconteceu por volta 1956, quando serviu como método para o controle de estoques. É confuso se Holt(1957) ou Brown (1956) foi o primeiro a introduzi-lo. O mais importante desenvolvimento trabalhado na suavização exponencial foi completado no fim da década de 1950 e publicado no início da década de 1960. Incluindo conclusões subsequentes de Magee (1958), Brown (1959), Holt et al. (1960), Winters (1960), Brown and Meyer (1961) e Brown (1963). Desde aquele tempo, o conceito de suavização exponencial foi fixado e tornou-se um método prático com amplas aplicações, principalmente em previsões de inventários.

No caso de médias móveis, os pesos designados a cada termo são os mesmos, que é a multiplicação pela média móvel escolhida. Em suavização exponencial, no entanto, podemos ter um ou mais parâmetros de suavização determinados explicitamente, e estes determinam os pesos para cada observação.

**Definição 4.2** Dada uma série  $X = \{x_1, x_2, \dots, x_n\}$  e um parâmetro de suavização  $\alpha \in \mathbb{R}$  tal que  $0 < \alpha < 1$ . A suavização exponencial simples para um termo  $T$  é  $f_T = \alpha \cdot x_{T-1} + (1 - \alpha) \cdot f_{T-1}$ .

Onde  $x_{T-1}$  e  $f_{T-1}$  são, respectivamente, valor observado e valor suavizado um período antes, mostrando assim que a suavização num dado instante é a combinação do valor observado e do suavizado um período antes.

Com esta definição precisamos encontrar um valor para  $\alpha$  que melhor ajuste a suavização para a previsão, resultado importante para conseguir boas previsões. Uma maneira de encontrar este valor será discutida.

### 4.3 ERRO

Para avaliar os resultados, serão analisados o erro quadrado médio, erro absoluto médio e erro percentual absoluto médio, e o coeficiente U de Theil. U de Theil é um parâmetro muito utilizado para avaliar tanto a qualidade dos valores estimados como das previsões.

Por exemplo, com o valor médio de erros quadrados concluímos se há grandes fatores de erro, pois com erros razoavelmente grandes influenciando quadraticamente do valor médio, temos que este deve aumentar. Vemos também que valores de erros pequenos, não influenciarão significativamente no valor médio, supondo erros menores que um, a medida de erro pode ser até reduzida ao invés de destacada. Assim, se o valor do erro quadrado médio for grande o suficiente pra mostrar que sua raiz também é grande, dentro do esperado para a variável, percebemos a operação que proporcionou tal erro, não obteve bons resultados, ou até mesmo concluir que no dado contexto, este fornece uma boa medida. Diferenciando do erro absoluto médio, que por sua vez, apenas calcula a média dos erros, não evidenciando consideráveis diferenças de erros em termos absolutos em dados períodos que compõem a série.

O erro percentual absoluto médio (EPAM), calculado para dentro da amostra definirá qual modelo, aditivo ou multiplicativo, obtem melhores aproximações dos valores estimados para os valores reais. Esta é uma medida mais robusta por mostrar variações no erro em termos percentuais relacionando com os valores observados. Porém, analisando o EPAM, vemos que se possuímos valores observados iguais a zero temos um sério problema, pois esta medida não terá valor definido.

Definindo o erro, como a diferença entre o valor real observado e o valor previsto. Podemos calcular erros médios, quadráticos, erros relativos. Vemos a seguir suas definições:

Erro Médio

$$EM = \sum_{i=1}^n e_i/n$$

Erro Absoluto Médio

$$EAM = \sum_{i=1}^n |e_i|/n$$

Erro Quadrado Médio

$$EQM = \sum_{i=1}^n e_i^2/n$$

Erro Percentual

$$EP_i = \left(\frac{x_i - f_i}{x_i}\right) \cdot (100)$$

Erro Percentual Absoluto Médio

$$EPAM = \sum_{i=1}^n |EP_i|/n$$

A previsão ingênua usa o último valor observado como previsão para o próximo período, desta forma se aplicarmos o EPAM para este método de previsão, temos:

$$EPAM = \frac{\sum_{i=2}^n \left| \frac{(x_i - x_{i-1})}{x_i} \right|}{n-1} \cdot (100)$$

Explica-se o início do índice do somatório  $i = 2$  e a divisão por  $n - 1$  pela formação da previsão, pois no método ingênuo o último valor previsto  $f_t$  é igual a  $x_{t-1}$ , o penúltimo observado. Assim concluímos que o segundo valor previsto será o primeiro observado, gerando assim  $t - 1$  previsões, que quando avaliadas pelo EPAM, temos a fórmula acima. Resultado este que será base para o desenvolvimento da medida de avaliação U de Theil.

#### 4.4 U de Theil

Em 1966 o coeficiente de desigualdade como também é chamado, U de Theil (U), foi desenvolvido. É uma medida relativa, que fornece a idéia, em termos percentuais, dos erros de previsão cometidos um passo a frente. Espera-se que esta medida varie sempre entre zero e um, sendo este o intervalo de oscilação para as técnicas consideradas aceitáveis.

As equações seguintes representam igualmente esta medida. Assim:

$$U = \sqrt{\frac{\sum_{i=1}^{t-1} \frac{(ERP_{i+1} - ERR_{i+1})^2}{n-1}}{\sum_{i=1}^{t-1} \frac{(ERR_{i+1})^2}{n-1}}}$$

$$U = \sqrt{\frac{\sum_{i=1}^{t-1} \left\{ \left( \frac{f_{i+1} - x_i}{x_i} \right) - \left( \frac{x_{i+1} - x_i}{x_i} \right) \right\}^2}{\sum_{i=1}^{t-1} \left( \frac{x_{i+1} - x_i}{x_i} \right)^2}}$$

$$U^2 = \frac{\sum_{i=1}^{t-1} \left\{ \left( \frac{f_{i+1} - x_i}{x_i} \right) - \left( \frac{x_{i+1} - x_i}{x_i} \right) \right\}^2}{\sum_{i=1}^{t-1} \left( \frac{x_{i+1} - x_i}{x_i} \right)^2}$$

Onde o Erro Relativo de Previsão é

$$ERP_{i+1} = \frac{f_{i+1} - x_i}{x_i}$$

E o Erro Relativo Real é

$$ERR_{i+1} = \frac{x_{i+1} - x_i}{x_i}$$

Supondo que numa certa previsão obteve-se para um passo a frente ( $f_{t+1}$ ), o valor exatamente igual ao valor observado ( $x_{t+1}$ ), o que é a previsão perfeita, praticamente impossível de acontecer. Esta situação tornaria o numerador da equação acima nulo, definindo assim um coeficiente  $U = 0$ , o que conclui-se é que quanto mais próximo de zero for esta medida, mais exatas são as previsões geradas pela técnica em questão em relação ao método ingênuo, portanto, mais adequada ela é para os dados em estudo.

Em outro caso, supondo que a aplicação de uma técnica de previsão resultou um U de Theil igual a um, concluímos que o valor previsto um passo a frente foi exatamente igual ao valor do período imediatamente anterior, ou seja, a mesma situação quando aplicado o método de previsão ingênuo. Porém, quando uma aplicação gerar coeficientes U de Theil maiores que um, temos que esta aplicação é menos eficiente que a previsão ingênua.

Enfim, o coeficiente U de Theil avalia um método de previsão usado em relação a previsão perfeita e a previsão ingênua, que apesar de ser um método sem memória pode obter melhores resultados que outros que possuem.

## 5 DECOMPOSIÇÃO

Os métodos de suavização descritos são baseados no conceito que quando existe um padrão implícito na série de dados, esse padrão pode ser distinto de aleatório pela suavização dos valores passados. O efeito desta suavização é eliminar a aleatoriedade e então o padrão pode ser planejado para o futuro e usado como uma previsão. Métodos de suavização não conseguem identificar componentes individuais do básico padrão implícito. Em vários casos o padrão pode ser decomposto em sub-padrões que identificam cada componente da série temporal separadamente. Como um colapso pode frequentemente facilitar precisões melhoradas na previsão e ajudar a entender melhor o comportamento da série.

Tais métodos usualmente tentam identificar três componentes separadamente no padrão implícito que leva a caracterizar séries econômicas. Estes fatores são a tendência, o ciclo e a sazonalidade. A tendência representa o comportamento de longo prazo dos dados e pode ser crescente, decrescente ou constante. O fator cíclico representa os altos e baixos de uma economia ou de uma indústria específica e é comum para séries tais como, produção industrial, demanda habitacional, preços de ação e outras. O fator sazonal relaciona flutuações periódicas de comprimento constante que são causadas por coisas como temperatura, chuvas, mês do ano, e políticas adotadas. A distinção entre sazonalidade e ciclo é que a sazonalidade se repete em intervalos fixos de tempo, como um ano, mês, semana, enquanto fatores cíclicos têm um duração longa que varia de ciclo para ciclo.

A decomposição assume que os dados são produzidos como:

série = padrão + resíduo

série = f(tendência,ciclo,sazonalidade) + resíduo

Assim é adicionado nos componentes do padrão, um elemento resíduo ou sua ausência também é assumido na decomposição. Este resíduo é assumido como a diferença entre o efeito combinado dos três sub-padrões da série e o dado atual.

Métodos de decomposição estão entre as mais velhas aproximações de previsões. Eles eram usados no início do século passado por economistas que tentavam identificar e controlar o ciclo dos negócios. A base dos atuais métodos de decomposição foi estabelecida na década de 1920 quando o conceito de razão para a tendência foi introduzido. Desde aquele tempo decomposições aproximadas eram usadas amplamente por economistas e homens de negócios.

Haviam diversas alternativas de aproximações para decompor a série temporal, todas com objetivo de isolar cada componente das séries exatamente conforme possível.



O conceito básico em tal separação é empírico e consiste em primeiro remover a sazonalidade, depois a tendência e por fim o ciclo. Algum resíduo é assumido como aleatório, este que enquanto não pode ser previsto, pode ser identificado. De um ponto de vista estatístico lá está um número de fraqueza teórica na decomposição aproximada. Profissionais, entretanto, têm ignorado amplamente esta fraqueza e assim usado a aproximação com sucesso considerável.

A representação geral matemática da decomposição é:

$$x_t = f(i_t, t_t, c_t, e_t)$$

Onde  $X_t$  é o valor da série temporal (dado atual) no período  $t$ ,

$i_t$  é a componente sazonal no período  $t$ ,

$t_t$  é a componente tendência no período  $t$ ,

$c_t$  é a componente cíclica no período  $t$ , e

$r_t$  é o resíduo ou componente aleatório no período  $t$ .

Estes métodos podem assumir dois modelos, aditivo e multiplicativo e pode ser de várias formas.

**Definição 5.1** *Modelo Aditivo de Decomposição consiste em escrever um valor  $x_t$  de uma série  $X$  como:  $x_t = i_t + t_t + c_t + r_t$*

**Definição 5.2** *Modelo Multiplicativo de Decomposição consiste em escrever um valor  $x_t$  de uma série  $X$  como:  $x_t = i_t * t_t * c_t * r_t$*

## 5.1 TENDÊNCIA E CICLO

Seu cálculo é o primeiro passo na decomposição de uma série, por ser uma componente de fácil visualização. Percebe-se sua presença quando os valores da série aumentam ou diminuem no intervalo de tempo. Existem diferentes tipos de tendência, as mais comuns são a linear, a quadrática e a exponencial, que podem ser aplicadas em diferentes intervalos de tempo de acordo com o comportamento da série. Como o comportamento cíclico de uma série também representa os crescimentos e decrescimentos que não ocorrem em períodos fixos de tempo, principal diferença entre este e a sazonalidade, nas decomposições o ciclo é sempre calculado juntamente com a tendência.

**Definição 5.3** *Dada uma série temporal  $X$ , o conjunto dos dados suavizados da série representa a tendência e o ciclo.*

A partir daqui entende-se por tendência de uma série, o conjunto das componentes de tendência e ciclo.  $(t_t + c_t)$  quando no modelo aditivo e  $(t_t * c_t)$  quando no modelo multiplicativo.

### 5.1.1 MÉDIA MÓVEL


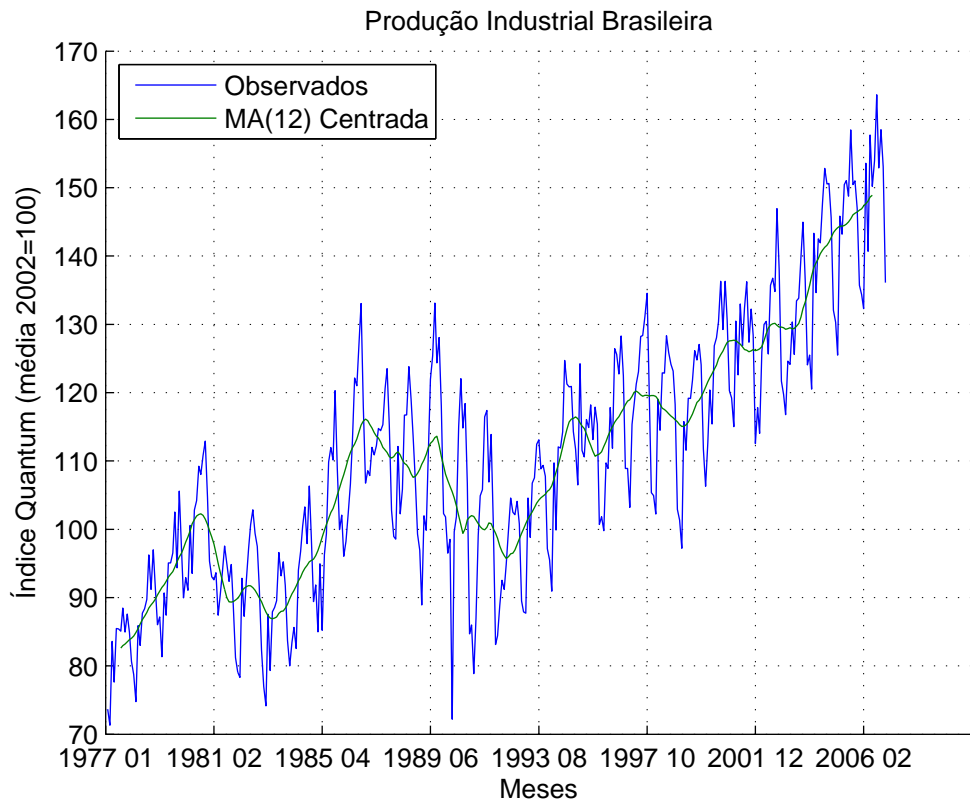
No cálculo da tendência e ciclo através de médias móveis, deve-se observar como estão dispostos seus termos, para assim escolher a sua ordem  $T$ . Se os dados são mensais devemos usar médias móveis de ordem 12, se trimestrais ordem 4, etc.


Nos casos em que a ordem da média móvel é par devemos centralizá-las, pois este valor médio encontra-se entre dois dados da série, casos de ordem ímpar não há esta necessidade, por exemplo, o valor médio obtido por uma  $MA(7)$ , encontra-se na posição do 4º dado utilizado. No caso de uma série com  $MA(12)$  seu ponto médio situa-se entre os dados 6 e 7 usados no cálculo da média.

**Definição 5.4** *Média Móvel Centrada (MMC), caracteriza-se como a média entre duas médias móveis. Assim, dada uma série  $X = \{x_1, x_2, \dots, x_n\}$ , com  $MA(T)$ ,  $T$  par, temos:*

$$MMC_1 = \frac{MA(T)_1 + MA(T)_2}{2}$$

Abaixo estão os gráficos das séries de produção industrial, importação e exportação brasileiras, com indicativo de tendência e ciclo calculado com  $MA(12)$  centradas.





### 5.1.2 EXPONENCIAL

Para definir a tendência e ciclo exponencialmente vamos suavizar a série, uma boa observação gráfica do comportamento de tal série, ajudará a decidir quais dados desta série são mais importantes para análise, ou seja, quais possuem mais importância no comportamento influenciando possíveis alterações. Por vezes, os primeiros valores de uma série não são importantes na suavização, pois não têm peso considerável numa futura previsão. Logo, identificados seus principais dados, podemos escolher um  $\alpha$  que proporcione uma boa suavização, distribuindo pesos aos dados da série com relação a sua importância para futuras previsões.

Suavizar a série exponencialmente requer a definição de um valor  $\alpha$  que está entre 0 e 1, como visto. Este intervalo para escolha do valor é definido a partir da definição de suavização.

A suavização de uma série  $X = \{x_1, x_2, \dots, x_n\}$  com  $\alpha \in \mathbb{R}$  e  $0 < \alpha < 1$ , para um termo  $t$  é  $f_t = \alpha \cdot x_{t-1} + (1 - \alpha) \cdot f_{t-1}$ . Assim já podemos escrever a expressão para os próximos termos, suavizados, que farão parte da previsão. Então

$$f_{t+1} = \alpha \cdot x_t + (1 - \alpha) \cdot f_t$$

De sua recorrência, temos

$$f_{t+1} = \alpha x_t + \alpha(1 - \alpha)x_{t-1} + \alpha(1 - \alpha)^2 x_{t-2} + \dots + \alpha(1 - \alpha)^{t-3} x_3 + \alpha(1 - \alpha)^{t-2} x_2 + \alpha(1 - \alpha)^{t-1} x_1 + (1 - \alpha)^t f_1$$

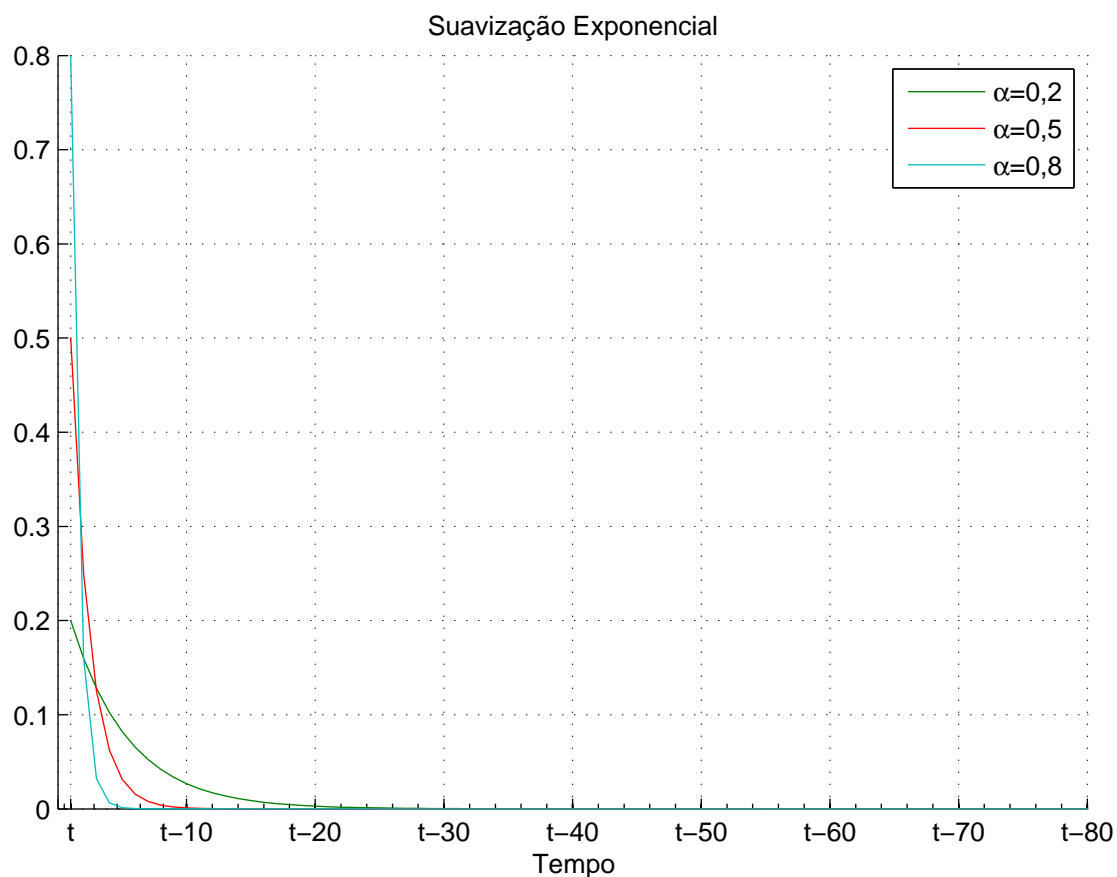
Nos cálculos das previsões, os primeiros valores das séries suavizadas  $f_1$ , temos  $f_1 = x_1$ . Dado que é o nosso último valor (mais velho).

*i)* Se  $\alpha = 0$  temos que  $f_{t+1} = f_1$



*ii)* Se  $\alpha = 1$  temos que  $f_{t+1} = f_t$

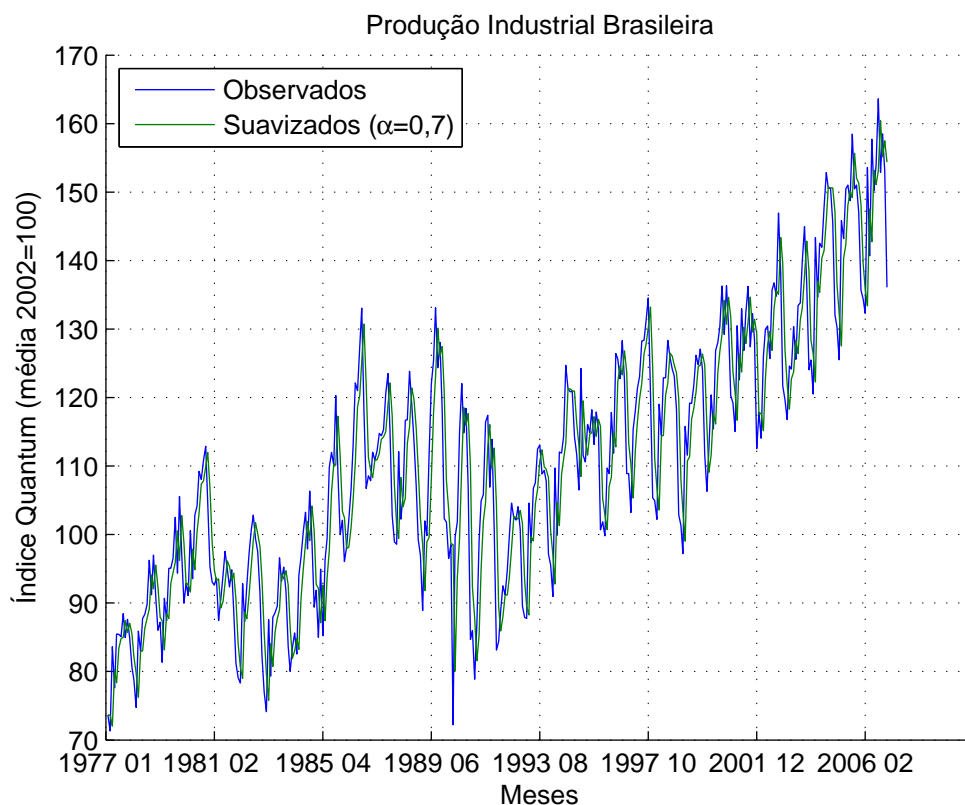
Percebe-se que em *i)* o método possui memória, porém apenas o primeiro valor observado é computado para a previsão. Em *ii)* a suavização define o método ingênuo. Em ambas situações o valor de  $\alpha$  não forneceu uma boa suavização, pois acaba desprezando os outros termos da série.

Encontra-se diversas formas para obter um valor de  $\alpha$  que proporcione uma boa suavização. Entender o comportamento da série de valores de  $\alpha$  escolhidos entre 0 e 1 é interessante. Por exemplo, se  $\alpha = 0,2$  temos  $\alpha(1 - \alpha) = 0,16$ ,  $\alpha(1 - \alpha)^2 = 0,128$ ,  $\alpha(1 - \alpha)^3 = 0,1024$ , continuando desta forma podemos obter quantos necessários à previsão. Dados os limites deste valor, 3 valores iniciais foram plotados para avaliar suas distribuições de peso (Vide gráfico abaixo). Observa-se um decréscimo exponencial, batizando a suavização dos dados. Visto que a otimização do valor de  $\alpha$  é um problema não linear e objetivando uma forma com menor custo computacional para sua escolha, estimativas iniciais serão feitas dividindo o intervalo (0,1) em 4 partes, fixando  $\alpha$  em 0,2, 0,5 e 0,8 e avaliando qual dos novos intervalos proporcionou uma boa suavização através da análise do erro cometido, e também quais pesos exatamente as potências  $\alpha(1 - \alpha)^t$  distribuem a cada observação passada. Repetindo o processo para o sub-intervalo de interesse, até encontrar um valor inicial que faça uma boa distribuição dos valores, de acordo com a estratégia de trabalho em questão. Não serão necessárias muitas divisões de tais intervalos para se obter um bom valor inicial. A partir destes, tem-se boa visualização do comportamento gerado por tais escolhas e o melhor valor passa a ser encontrado mais precisamente.



Vemos que o dado observado no tempo  $t$  tem peso igual ao valor  $\alpha$  escolhido e o decréscimo de suas potências  $\alpha(1 - \alpha)^t$ . Como  $\alpha$  está entre 0 e 1,  $(1 - \alpha)$  também está entre 0 e 1, assim podemos concluir que potências crescentes de um valor entre 0 e 1 tende a zero. Numa planilha qualquer de dados, podemos obter o peso que um  $\alpha$  dado distribui para a cada termo da série, permitindo um ajuste preciso. A seguir vemos a série de exportações com coeficiente  $\alpha = 0,38$ , série de importações com coeficiente  $\alpha = 0,5$  e série de produção industrial brasileiras com coeficiente  $\alpha = 0,5$ .








Através do suplemento *Solver*, que é um programa de otimização não linear, componente do software Microsoft Excel, obtem-se o melhor valor para  $\alpha$ , valor este que minimiza o EPAM (Erro Percentual Absoluto Médio), definido adiante. Desta forma adquirimos, a melhor suavização para a série em questão, permitindo assim definir índices sazonais seguros.

A seguir temos as séries suavizadas através de valores ótimos para  $\alpha$  definidos pelo suplemento *Solver*. Para a série de exportações o valor de  $\alpha$  definido foi aproximadamente 0,525. Para a série de importações o valor de  $\alpha$  foi aproximadamente 0,472. E para a série de produção industrial o valor de  $\alpha$  definido foi aproximadamente 0,596.







## 5.2 SAZONALIDADE

A componente sazonal de uma série temporal é determinada indiretamente, diferente da tendência e ciclo, com auxílio de um conjunto de números índices, calculados para cada observação em um intervalo fixo de tempo (diário, semanal, mensal, trimestral). Seu cálculo será determinado a partir do modelo de decomposição escolhido, aditivo ou multiplicativo. Estes índices sazonais representarão a variação da série ao longo do tempo em termos unitários, no caso da decomposição aditiva, e as porcentagens de variação desta série ao longo do tempo, no caso multiplicativo.

Há três etapas a serem cumpridas para o cálculo da sazonalidade, nos dois modelos de decomposição.

*i)* Calcula-se a tendência e o ciclo através da média móvel centrada e suavização exponencial.

*ii)* Temos que  $(t_t + c_t) + i_t + r_t = x_t$ , assim o próximo passo é retirar a tendência e ciclo da série original. Este procedimento se dá de maneira distinta entre os modelos, aditivo e multiplicativo. Se o modelo adotado for o aditivo, a retirada da tendência e ciclo será através da subtração,  $(x_t - (t_t + c_t))$ . Se o modelo adotado for o multiplicativo, o procedimento é realizado através da divisão,  $(\frac{x_t}{(t_t + c_t)})$ .

*iii)* Assim, os índices sazonais são calculados como a média dos valores de um dado

mês, a partir dos dados obtidos na segunda etapa. Por exemplo, o índice sazonal para o mês de janeiro é a média aritmética de todos os valores registrados em janeiro de cada ano, sem tendência e ciclo.

### 5.3 RESÍDUO OU COMPONENTE ALEATÓRIO

Componente presente em praticamente todas as séries históricas, denominado de diversas formas, também como discrepância, componente irregular, corresponde aquela diferença que não pode ser considerada tendência e ciclo ou mesmo sazonalidade. Em caso contrário as séries temporais seriam determinísticas, desta forma, procurando fazer previsões das mesmas, tendo identificadas as componentes tendência-ciclo e sazonalidade, não haveria a possibilidade de haver resíduo.

**Definição 5.5** *O resíduo obtido pelo modelo aditivo, é  $r_t = x_t - (i_t + t_t + c_t)$ .*



**Definição 5.6** *O resíduo obtido pelo modelo multiplicativo, é  $r_t = \frac{x_t}{i_t \cdot (t_t + c_t)}$ .*


## 6 AVALIAÇÃO DOS MODELOS

Agora com o valor de cada componente, tanto para o modelo aditivo quanto para o modelo multiplicativo, estimamos os valores para os termos dentro da amostra pelos dois modelos e avaliamos o EPAM cometido. Para todas as séries o modelo multiplicativo teve menor EPAM dentro da amostra, este resultado define que o modelo a ser utilizado para as previsões será o multiplicativo.


Abaixo encontram-se os gráficos das três séries sem a componente de tendência e ciclo, ou seja, apenas as componentes de sazonalidade e resíduo, suavizadas pelos métodos de Média Móvel e Exponencial, extraídas pelo modelo multiplicativo. No método Exponencial a suavização foi feita com valores de  $\alpha$  definidos pelo *Solver*, estes que minimizam o EPAM.

(i) Média Móvel:







(ii) Suavização Exponencial:






$i_t^* r_t$  pelo Modelo Multiplicativo da série de Importações






$i_t^* r_t$  pelo Modelo Multiplicativo da série de Produção Industrial



A partir destes valores, define-se os índices sazonais, mensais devido a periodicidade, e em termos percentuais devido a sua multiplicidade. Logo:





Deste índices decompostos, percebe-se que as séries de exportações e importações



tem índices semelhantes, mostrando que em dados períodos a sazonalidade possui altas e baixas. E comparando os índices obtidos pela média móvel e pela suavização exponencial, tem-se certa diferença entre os índices sazonais. Através dos índices obtidos pela média móvel, temos uma melhor idéia das variações sazonais em relação ao nível médio dos dados observados.

Na série de exportações vemos um período de alta entre fevereiro e agosto, de agosto a novembro um período de baixa, em dezembro um crescimento isolado, seguido de queda até fevereiro.


Para os índices de importações há uma maior estabilidade em torno de um valor médio, mostrando, como na série de exportações, crescimento a partir de fevereiro, seguido de uma estabilidade iniciando em março, com uma baixa isolada em abril, até julho onde há um novo crescimento e estabilidade em torno deste crescimento, mostrando uma nova alta para o fim do ano, finalizando em queda até fevereiro.

Nos índices sazonais da série de produção, percebemos dois períodos bem distintos. O primeiro de alta que inicia em março e vai até outubro, mostrando dois momentos de queda, em abril e setembro, e o segundo de queda que inicia em outubro e acaba em fevereiro.


Do cotidiano coletivo, pode-se notar certa relação com tais índices, no caso das exportações e importações, vemos um acompanhamento no crescimento, e também acompanhamento na queda, este período de queda também é percebido na série de produção. Ora, para o fim do ano temos aquecimento de exportações e importações advindas, por exemplo das festas e gastos de finais de anos, época de negócios visto que a produção no segundo semestre do ano é alta. A baixa da produção no fim de ano, também podemos relacioná-la, com os recessos que costumam ocorrer nesta época, reduzindo o trabalho efetivo e consumando a queda na produção.



Abaixo podemos ver, os gráficos da componente  $r_t$  extraídas das três séries, através do modelo multiplicativo:



Resíduo obtido da série de Exportações – MA(12) Mult





Resíduo obtido da série de Importações – MA(12) Mult





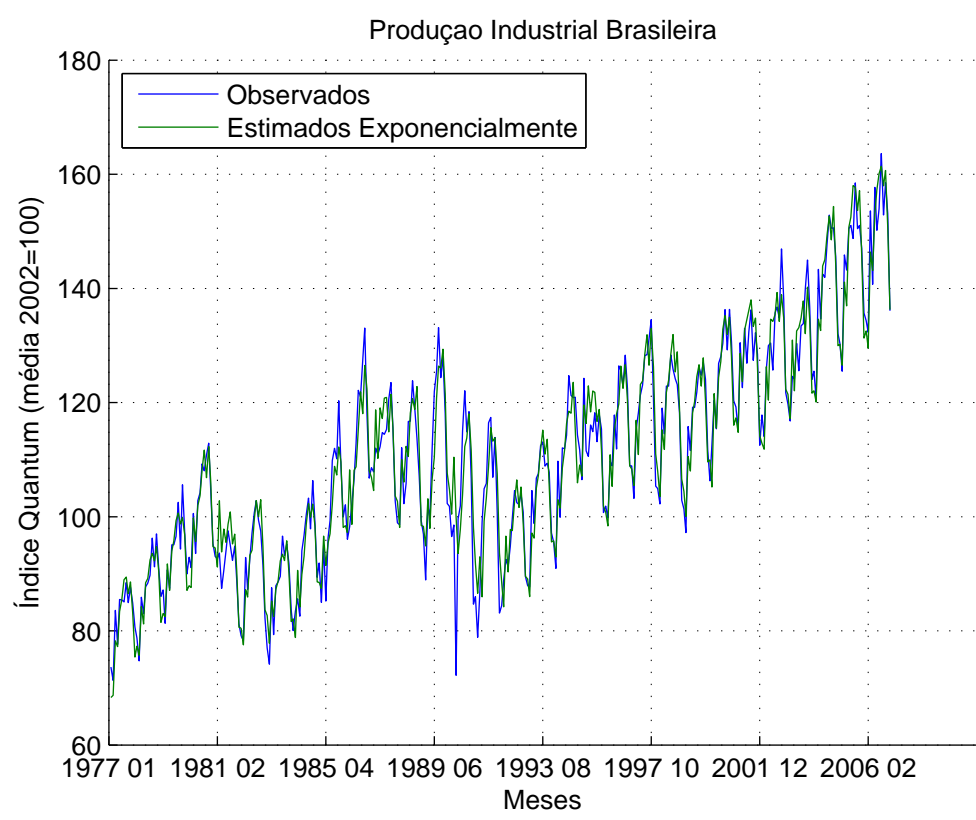





Fazendo a recomposição das séries a partir das componentes extraídas, obtemos:







Nas previsões por decomposição clássica e pelo método de Holt-Winters, os val-

ores reais observados passam a ser os estimados que minimizam o EPAM dentro da amostra. Permitindo assim as otimizações dos parâmetros no caso do método de Holt-Winters.

## 7 PREVISÕES POR DECOMPOSIÇÃO CLÁSSICA

Acima decompomos os valores de cada componente, a partir dos valores observados obtendo os valores estimados na recomposição. Para estimar a tendência através da decomposição clássica, fazemos uma regressão simples, que consiste em ajustar uma reta do tipo  $\hat{X} = a + bt$ , como valor médio de longo prazo de  $n$  termos.

Onde,

$$b = \frac{n \sum_{t=1}^n tX_t - \sum_{t=1}^n t \sum_{t=1}^n X_t}{n \sum_{t=1}^n t^2 - (\sum_{t=1}^n t)^2}$$

$$a = \frac{\sum_{t=1}^n X_t}{n} - b \frac{\sum_{t=1}^n t}{n}$$

Verificando os valores  $a$  e  $b$ . Dados  $t$  valores observados denotados por  $X$ , a equação de regressão,  $\hat{X} = a + bt$ , pode ser calculada para minimizar a soma dos desvios quadráticos, desta maneira fornecendo o comportamento de longo prazo.

Definindo,

$$e_i = X_i - \hat{X}_i$$

Assim,

$$e_i^2 = (X_i - \hat{X}_i)^2$$

e

$$\sum e_i^2 = \sum (X_i - \hat{X}_i)^2$$

Substituindo

$$\sum e_i^2 = \sum (X_i - a - bt_i)^2$$

Derivando em relação as variáveis de interesse temos,

$$\frac{\partial \sum e_i^2}{\partial a} = -2 \sum (X_i - a - bt_i) = 0$$

$$\frac{\partial \sum e_i^2}{\partial b} = -2 \sum t_i (X_i - a - bt_i) = 0$$

Logo,

$$-\sum X_i + ta + b \sum t_i = 0$$



e

$$-\sum t_i X_i + a \sum t_i + b \sum t_i^2 = 0$$

Definindo assim  $a$  e  $b$

$$a = \frac{\sum X_i}{t} - b \frac{\sum t_i}{t}$$

e

$$b = \frac{t \sum t_i X_i - \sum t_i \sum X_i}{t \sum t_i^2 - (\sum t_i)^2}$$

Desta forma os valores de  $a$  e  $b$  definidos acima correspondem aos pontos onde a primeira derivada é zero; que é onde a soma dos erros quadrados é mínima. Podemos fazer mais de uma regressão dentro de uma mesma série, de acordo com o comportamento da série, qualificando assim o ajuste linear.

## 7.1 SAZONALIDADE

Os índices sazonais mensais são obtidos pela média dos valores de cada mês, sem tendência, ou seja, resultado da divisão entre o valor original da série e o valor de tendência de longo prazo previsto linearmente, em cada período. Por isto uma melhor adequação da tendência linear, qualificará os índices sazonais que irão compor a previsão.



**Definição 7.1** *Previsão por Decomposição Clássica* para  $m$  períodos a frente:

$$f_{t+m} = (a + b(t + m))i_{t-l+m}$$

Onde  $m$  é o horizonte de previsão,  $a$  e  $b$  definidos através da regressão e o índice sazonal pela média dos valores de cada mês da série sem tendência.

## 7.2 EXPORTAÇÕES BRASILEIRAS

Nesta série foi necessário um ajuste duplo, o primeiro envolvendo todo o histórico da série até dezembro de 2001 e o segundo a partir de janeiro de 2002, por ser o período inicial de uma significativa mudança na quantidade de exportações, o que pode facilmente ser percebido no gráfico. Comparando os ajustes, com uma e com duas regressões, percebemos claramente a diferença e obtemos assim um melhor ajuste aos dados observados, incorrendo erros menores.



Pela regressão simples do último período desta série temos

$$a = -39329,092$$

e

$$b = 143,499$$

abaixo temos a tabela com os valores dos índices sazonais mensais obtidos pelo modelo multiplicativo de decomposição, a partir dos valores suavizados exponencialmente.

Mês	Janeiro	Fevereiro	Março	Abril	Mai	Junho
Índice	0,8697	0,9027	1,1210	1,0766	1,1372	1,0620
Mês	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
Índice	1,0729	1,0516	0,9809	0,9743	0,9390	1,0246

Tabela 2: Índices Sazonais Mensais da série de Exportações Brasileiras

Aplicando a previsão para os 7 períodos que serão avaliados temos:

$$f_{361} = (-39329,092 + 143,499(361))0,8697 = 10849,589$$

$$f_{362} = (-39329,092 + 143,499(362))0,9027 = 11390,708$$


Continuando desta forma até  $f_{367}$ , lembrando que quanto mais distantes se encontram as previsões sua precisão diminui, ainda mais se ultrapassado seu ciclo sazonal. Na tabela abaixo temos os valores previstos, índice U de Theil, erro quadrado médio e o erro absoluto médio, deste modelo.

O resultado do índice U de Theil, mostra que mesmo sem grandes custos computacionais podemos obter resultados melhores que a previsão ingênua, o que é um bom indicativo. Com as medidas EQM e EAM, vemos que grandes erros foram observados, dado o elevado valor do EQM. Porém ao analisarmos o EAM vemos que este está dentro de uma janela aceitável de erro.

No contexto econômico em questão, pequenos fatores podem influenciar uma variação como a observada. Com o EAM podemos definir um intervalo de confiança para as previsões, tal que os valores previstos, podem estar condicionados a um acréscimo ou decréscimo de tal valor. Proporcionando diferentes decisões em torno dos valores previstos posteriormente por este método, com relação ao erro observado neste instante.


Período	Observado	Previsto
2007 01	10963	10849,582
2007 02	10103	11390,626
2007 03	12889	14305,895
2007 04	12446	13894,093
2007 05	13647	14838,378
2007 06	13119	14010,204
2007 07	14120	14307,697
	U de theil	0,7534
	EQM	1146324,57
	EAM	933,76

Tabela 3: Previsão por Decomposição Clássica da série de Exportações



### 7.3 IMPORTAÇÕES BRASILEIRAS

Nesta série foram necessários seis ajustes, o primeiro envolvendo dados de janeiro de 1977 até dezembro de 1980, o segundo de janeiro de 1981 até janeiro de 1986, o terceiro de fevereiro de 1986 até setembro de 1994, o quarto de outubro de 1994 até fevereiro de 2000, o quinto de março de 2000 até maio de 2003 e o sexto de junho de 2003 até dezembro de 2006, períodos de diferentes tendências de longo prazo.



Pela regressão simples do último período desta série, período este que influencia diretamente para previsões temos

$$a = -29242,256$$

e

$$b = 103,890$$

abaixo temos a tabela com os valores dos índices sazonais mensais obtidos pelo modelo multiplicativo de decomposição, a partir dos valores suavizados exponencialmente.

Mês	Janeiro	Fevereiro	Março	Abril	Maiο	Junho
Índice	0,8902	0,8867	1,0636	0,9877	1,0588	1,0312
Mês	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
Índice	1,1016	1,0786	1,0053	1,0351	1,0247	1,0342

Tabela 4: Índices Sazonais Mensais da série de Importações Brasileiras


Neste momento podemos aplicar a previsão sete períodos a frente e avalia-la verificando se o trabalho foi válido. Obtendo índice U de Theil igual 0,5241 percebemos que as previsões para a série de Importações brasileiras não foram ruins, mesmo não

tendo um custo tão alto foi consideravelmente melhor que a previsão ingênua.

Mostrando também, EQM e EAM melhores que os observados na previsão feita para a série de exportações, permitindo uma decisão mais segura em relação aos resultados alcançados para esta série. Nesta série percebemos, um comportamento de longo prazo estável linearmente, enquanto na série anterior há um crescimento de longo prazo aparentemente não linear. Fator este que contribuiu para diferenças em tais resultados.


Período	Observado	Previsto
2007 01	8466,201	7896,859
2007 02	7225,435	7226,891
2007 03	9545,377	8344,048
2007 04	8254,921	8030,751
2007 05	9780,682	8619,875
2007 06	9302,949	8733,776
2007 07	10772,700	9505,357
	U de theil	0,5241
	EQM	727883,79
	EAM	713,37

Tabela 5: Previsão por Decomposição Clássica da série de Importações



## 7.4 PRODUÇÃO INDUSTRIAL BRASILEIRA

Nesta série foram necessários dois ajustes, o primeiro envolvendo dados de janeiro de 1977 até outubro de 1997, e o segundo envolvendo o restante dos dados. Local que de acordo com o histórico é um bom ponto para definir o último período da regressão, visto que este influencia diretamente as previsões. Pode-se perceber também um comportamento cíclico no início da série, como uma variação da tendência de longo prazo.



Pela regressão simples do último período desta série, temos  $a = 16,578$  e  $b = 0,275$ . Abaixo temos a tabela com os valores dos índices sazonais mensais obtidos pelo modelo multiplicativo de decomposição clássica.

Mês	Janeiro	Fevereiro	Março	Abril	Maio	Junho
Índice	0,9176	0,8688	0,9971	0,8622	1,0222	1,0287
Mês	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
Índice	1,0685	1,0968	1,0645	1,0934	1,0455	0,9331

Tabela 6: Índices Sazonais Mensais da série de Produção Industrial Brasileira


Neste momento podemos aplicar a previsão sete períodos a frente e avalia-la verificando se o trabalho foi válido. Obtendo índice U de Theil igual 0,6263 percebemos que a série de Importações brasileiras teve o comportamento esperado, um bom ajuste

linear foi um ponto positivo na qualidade do resultado.

Semelhante a série de importações, esta possui uma tendência linear estável, permitindo assim bons resultados através deste método. Gerando valores do EQM e EAM, aceitáveis e portanto possibilitando conclusões para tomada de decisões.

Período	Observado	Previsto
2007 01	109,22	106,40
2007 02	104,08	100,99
2007 03	121,21	116,18
2007 04	113,58	100,69
2007 05	125,46	119,67
2007 06	121,61	120,71
2007 07	125,46	125,68
	U de theil	0,6263
	EQM	34,69
	EAM	4,38

Tabela 7: Previsão por Decomposição Clássica da série de Produção Industrial





## 8 MÉTODO DE HOLT-WINTERS

Por volta de 1957 Holt expandiu a suavização exponencial simples para séries que possuíam tendência, pois até então se faziam previsões apenas com a suavização exponencial simples, mas esta não proporcionava bons resultados em dados com tendência. Dado que a série possui tendência, haverá uma tendência de crescimento ou decréscimo, informação esta que não era considerada na suavização exponencial simples, gerando assim previsões deslocadas, sem precisão.

Apesar do problema com a tendência presente nas séries ser resolvido, ainda há problemas com a sazonalidade. A sazonalidade caracterizando-se como um padrão repetitivo na série, esperado para certos períodos de tempo dentro dos valores observados, permite um ajuste, o qual foi feito por Winters em 1960 com base na mesma idéia, desenvolvendo o método de Holt que ajustava a tendência, mas não acompanhava a sazonalidade. Ajustada a tendência como definido por Holt, linear, ajusta-se por fim a sazonalidade, segundo Winters.

### 8.1 MÉTODO DE HOLT

Baseia-se em três equações, para os valores estimados  $f_t$ , para o crescimento da tendência  $b_t$  e para as previsões  $f_{t+m}$ , onde  $m$  é o horizonte de previsão. Faz uso de duas constantes de suavização,  $\alpha$  para os valores estimados e  $\beta$  para o crescimento da tendência, ambas entre zero e um. Observando que este crescimento da tendência corresponde a taxa de crescimento da função que define a componente de tendência da série, podendo ser linear, quadrática, exponencial, etc. Percebe-se que são feitas suavizações exponenciais para as componentes da previsão, dando mais flexibilidade ao modelo, permitindo diferentes suavizações. As equações são:

$$f_t = \alpha x_t + (1 - \alpha) \underbrace{(f_{t-1} + b_{t-1})}_{\text{tendência}}$$

$$b_t = \beta \underbrace{(f_t - f_{t-1})}_{\text{crescimento}} + (1 - \beta)b_{t-1}$$

$$f_{t+m} = f_t + mb_t$$

Assim temos que  $f_t$  é ajustada diretamente da tendência do período anterior, adicionando  $b_{t-1}$  ao último valor suavizado da série. O que ajuda a eliminar a diferença e induz  $f_t$  para aproximadamente o valor da série.  $b_t$  atualiza a tendência, que é expressada através da diferença entre os dois últimos valores suavizados da série.

## 8.2 MÉTODO DE WINTERS

Caracterizado como método de Holt-Winters. Seu método é fundamentado em três equações de suavização, conservando o método de Holt, com uma equação para suavização da tendência (que é sempre linear) e acrescentando uma equação de suavização da sazonalidade, que determina dois métodos, Holt-Winters Aditivo, onde a sazonalidade é aditiva e Holt-Winters Multiplicativo, onde a sazonalidade é multiplicativa. A partir das equações, para a suavização  $f_t$ , para o crescimento  $b_t$  e para a sazonalidade  $i_t$ , forma-se a previsão de  $m$  períodos adiante. Abaixo temos as equações de suavização de  $f_t$ ,  $b_t$  e  $i_t$  e a equação de previsão para  $m$  períodos, para os métodos de Holt-Winters Aditivo e Multiplicativo:

(i) *Sazonalidade Aditiva* :

$$f_t = \alpha \cdot \underbrace{(x_t - i_{t-l})}_{\text{série dessazonalizada}} + (1 - \alpha) \underbrace{(f_{t-1} + b_{t-1})}_{\text{tendência}}$$

$$b_t = \beta \underbrace{(f_t - f_{t-1})}_{\text{crescimento}} + (1 - \beta)b_{t-1}$$

$$i_t = \gamma \left( \underbrace{x_t - f_t}_{\text{índice sazonal}} \right) + (1 - \gamma)i_{t-l}$$

$$f_{t+m} = f_t + b_t m + i_{t-l+m}$$

(ii) *Sazonalidade Multiplicativa* :

$$f_t = \alpha \cdot \underbrace{\left( \frac{x_t}{i_{t-l}} \right)}_{\text{série dessazonalizada}} + (1 - \alpha) \underbrace{(f_{t-1} + b_{t-1})}_{\text{tendência}}$$

$$b_t = \beta \underbrace{(f_t - f_{t-1})}_{\text{crescimento}} + (1 - \beta)b_{t-1}$$

$$i_t = \gamma \left( \underbrace{\frac{x_t}{f_t}}_{\text{índice sazonal}} \right) + (1 - \gamma)i_{t-l}$$

$$f_{t+m} = (f_t + b_t m) i_{t-l+m}$$

Onde  $l$  é o peso da sazonalidade (por exemplo, número de meses ou trimestres em um ano),  $b$  é o crescimento da tendência, ou seja, o coeficiente angular da reta suporte da tendência,  $i$  é o fator de ajuste sazonal, e  $f_{t+m}$  é a previsão para  $m$  períodos a frente. A formação da previsão se dá de acordo com o comportamento da série, se a série apresenta sazonalidade multiplicativa, multiplica-se seu valor  $i$  pela componente de tendência definida e se for aditiva,  $i$  é adicionado à componente de tendência, ambos os casos foram feitos acima.

Vemos também nas equações que quando os valores de  $f_t$  são definidos, sua variável de peso  $\alpha$  é a série dessazonalizada, se definida como o quociente entre os valores reais e os índices sazonais temos sazonalidade multiplicativa, se definida como a subtração entre o valores reais e os índices sazonais temos sazonalidade aditiva.

Deste modo, temos dois modelos para o método de Holt-Winters, sazonalidade aditiva e multiplicativa, ambos com tendência linear, que é formado pelo modelo de Holt que dá base para as previsões. Dado que o modelo que obteve menor erro foi o modelo multiplicativo temos as seguintes equações para as previsões:

$$f_t = \alpha \frac{x_t}{i_{t-l}} + (1 - \alpha)(f_{t-1} + b_{t-1})$$

$$b_t = \beta(f_t - f_{t-1}) + (1 - \beta)b_{t-1}$$

$$i_t = \gamma \frac{x_t}{f_t} + (1 - \gamma)i_{t-l}$$

$$f_{t+m} = (f_t + b_t m)i_{t-l+m}$$

### 8.3 VALORES INICIAIS

Da definição dos modelos temos que são iterativos, porém precisamos fornecê-los valores iniciais para aplicarmos tal iteração. Precisaremos do valor inicial da série dessazonalizada, do crescimento da tendência e dos  $i_{t-l}$  índices sazonais. A seguir veremos como obter cada um destes.

Aqui há a perda do ano mais antigo de dados, pois o termo que inicia o método é definido com base em tal período. Logo, temos que o primeiro valor da série passa a ser o termo  $x_{l+1}$ , ponto inicial da suavização.

Na suavização da série dessazonalizada, considera-se  $f_{l+1} = x_{l+1}$ , definindo assim

o valor inicial da suavização.

O valor inicial  $b_{L+1}$  será obtido como o valor médio do crescimento de um período sazonal completo, da seguinte forma:

$$b_{l+1} = \frac{(x_{l+1}-x_1)+(x_{l+2}-x_2)+\dots+(x_{l+l}-x_l)}{l}$$

Onde cada um dos termos  $\frac{(x_{L+i}-x_i)}{L}$  estima a tendência por um período sazonal, assim um valor inicial de  $b$  é estimado através da média dos  $L$  termos.

Os  $i_{t-l}$ , índices sazonais iniciais são os seguintes,  $i_{-11}, i_{-10}, \dots, i_{-1}$  e  $i_0$ , onde o  $i_{-11}$  corresponde ao índice sazonal inicial para o mês de janeiro,  $i_{-10}$  para fevereiro, seguindo desta forma. Os valores do ajuste de cada mês, é de maneira geral:

$$i_{k-l} = \frac{x_k}{\bar{x}}$$

com  $k \in \mathbb{N}$  onde

$$\bar{x} = \sum_{k=1}^l \frac{x_k}{l}$$

Logo, temos 17 valores iniciais a serem estimados, são eles os 12 índices sazonais, o valor inicial da série dessazonalizada, do crescimento da tendência e os parâmetros de suavização  $\alpha$ ,  $\beta$  e  $\gamma$ . Estes três últimos que devem ser otimizados para assim minimizar o EPAM dentro da amostra e prever valores com certo grau de confiabilidade, que será avaliado através do índice U de Theil.

## 8.4 OTIMIZAÇÃO DOS PARÂMETROS

Uma das maiores desvantagens de se utilizar o método de Holt-Winters para fazer previsões é a otimização dos parâmetros de suavização.

Os valores de  $\alpha$ ,  $\beta$  e  $\gamma$  que minimizam o erro de previsão são obtidos por intermédio de uma planilha de cálculos que executa sucessivas iterações de maneira que, variando o valor do parâmetro, o valor do erro percentual absoluto médio seja mínimo.

Neste momento temos o valor ótimo de  $\alpha$  que foi definido anteriormente para ajustar os dados originais por meio de uma suavização de modo a minimizar o EPAM do ajuste. Assim, através da decomposição obtemos os valores da componente de tendência-ciclo e os valores dos índices sazonais. Valores estes que serão usados para otimização dos parâmetros.

Otimizar os valores de  $\beta$  e  $\gamma$  será minimizar o valor do EPAM cometido entre os valores suavizados através destes parâmetros e os valores esperados, definidos através

do ajuste dos dados observados. A partir de  $\alpha$  temos  $f_t$  que corresponde a tendência e ciclo da série ajustada num período  $t$ . Logo, também temos  $i_t$  que é a componente sazonal da série ajustada no período  $t$ .

Quando se suaviza a série, obtem-se o valor da componente sazonal com um certo resíduo, este fator que não podemos determinar. Esta série  $I_t$ , que é a série original sem a componente de tendência-ciclo, definida a partir da suavização por  $\alpha$ , contem os índices sazonais e uma componente residual. Assim, podemos otimizar o valor de  $\gamma$  para que o EPAM entre  $(I_t - i_t)$  seja mínimo. Definidos os  $i_{t-l}$  anteriormente.

Com o valor de  $\gamma$  otimizado, obtem-se a série dessazonalizada, pelo quociente entre os valores observados ajustados e os índices  $i_t$  com  $\gamma$  otimizado.

Agora tem-se os valores de  $\alpha$  e  $\gamma$  otimizados. Assim otimiza-se o valor de  $\beta$ . Dada a equação para a suavização do crescimento da tendência e o valor inicial estimado podemos definir um valor ótimo de  $\beta$ . De maneira que o valor  $b_{t-1}$  quando somado ao de  $f_{t-1}$ , na equação de suavização que gera o valor de  $f_t$ , o EPAM entre  $F_t - f_t$  seja mínimo, onde  $F$  é a série sem componente sazonal definida acima, ou seja, o quociente entre os dados observados ajustados e o valores da componente sazonal, com certo resíduo, a partir de  $\gamma$  ótimo.


Por fim temos valores ótimos de  $\alpha$ ,  $\beta$  e  $\gamma$  que permitem definir as componentes das previsões que estarão dentro de uma janela de variação aceitável.

## 8.5 PREVISÕES PELO MÉTODO DE HOLT-WINTERS


Aplicando as equações definidas acima, compara-se os valores previstos através do modelo e os reais observados. Através do índice U de Theil, sabe-se se o esforço em montar tal previsão foi válido. Como visto, o índice U de Theil deve ser menor que um, e quanto mais próximo de zero, melhor é o valor previsto pelo modelo. Paralelamente a observação dos valores do EQM e EAM, dá-nos uma boa perspectiva da margem de erro constante nos resultados das previsões.

Para a série de Exportações brasileiras os valores otimizados dos parâmetros foram os seguintes:  $\alpha = 0,5257$ ,  $\beta = 0$  e  $\gamma = 0,0171$ .

Dado que a variação do crescimento da tendência tem aparente média constante, a suavização obteve valor ótimo de  $\beta$  igual a zero, mostrando que o valor inicial estimado não necessita de suavização. Abaixo vemos o gráfico desta suavização.




Pelo gráfico vemos a componente sazonal com resíduo, mostrada anteriormente, agora suavizada, dado o valor ótimo de  $\gamma$ .




Na série de Importações, otimizando os parâmetros obtivemos os seguintes valores:  $\alpha = 0,4670$ ,  $\beta = 0,0435$  e  $\gamma = 0,2457$ .

Semelhante a série anterior, a variação do crescimento da tendência tem aparente média constante, abaixo vemos o gráfico do crescimento da tendência original, e suavizado.




Vemos abaixo o gráfico da componente sazonal com resíduo antes e após a suavização, com o valor ótimo de  $\gamma$ .






Na série de Produção Industrial otimizando os parâmetros obtivemos os seguintes valores:  $\alpha = 0,5963$ ,  $\beta = 0,0034$  e  $\gamma = 0,0282$ .

Nesta série, a variação do crescimento da tendência apresenta média constante, semelhante as anteriores, como vemos no gráfico. Onde temos o crescimento da tendência original, e suavizado.



Abaixo temos o gráfico da componente sazonal com resíduo antes e após a suavização, com o valor ótimo de  $\gamma$ .



Da própria definição do método de Holt-Winters, temos que sua tendência é definida como linear, por isso observamos uma grande suavização em tal componente, podemos ver que na série original a variação é muito grande. Porém, após a suavização temos tal componente, se não linear, muito próxima, apresentando variações mínimas.

Diferentemente vemos a suavização da sazonalidade, esta que representa um importante papel nas previsões, busca o melhor acompanhamento da sua série original. Determinando uma variação em torno da tendência de longo prazo, que faz com que as previsões se aproximem do valor real observado. Lembrando que nesta componente não desprezamos o resíduo, este que implicitamente está sempre presente nas decomposição das séries, e sendo suavizado juntamente com a sazonalidade, aproxima mais ainda a previsão esperada.

Logo, temos as tabelas dos valores previstos para as três séries, pelo método de Holt-Winters, usando a metodologia acima junto com o EQM, EAM e o índice U de Theil obtido por cada.

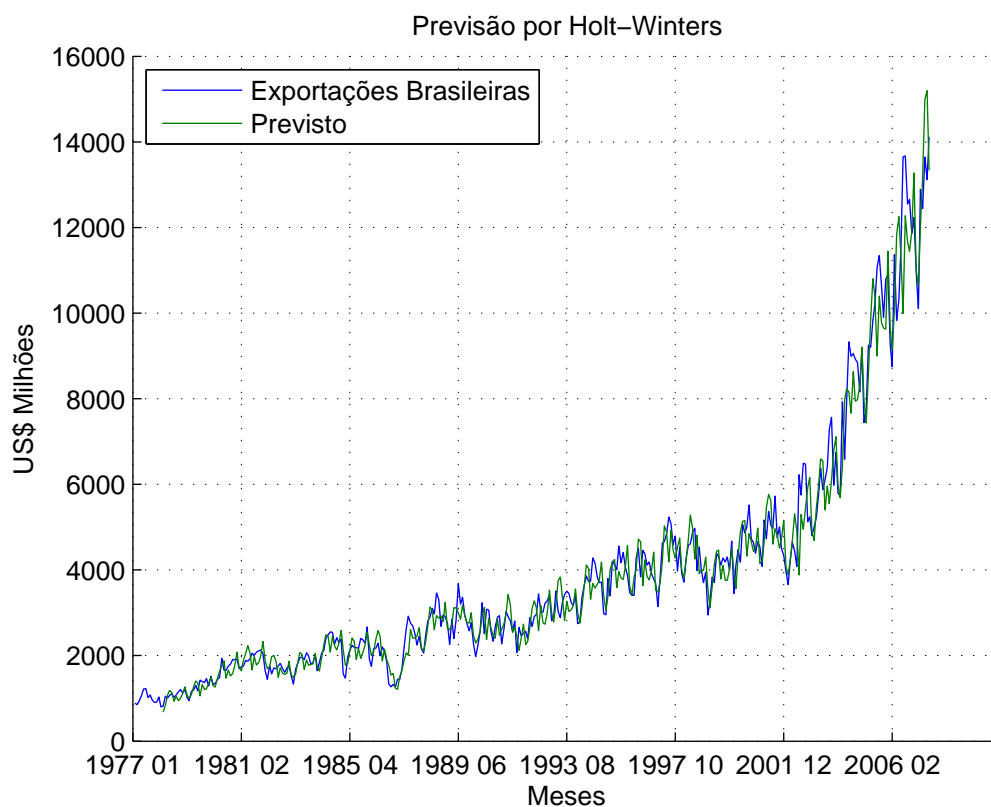
Segue abaixo os gráficos de cada série, com valores observados e valores previstos, pra dentro da amostra e para o horizonte de previsão.

Período	Observado	Previsto
2007 01	10963	11001,715
2007 02	10103	10643,740
2007 03	12889	12019,558
2007 04	12446	13194,716
2007 05	13647	14997,545
2007 06	13119	15199,618
2007 07	14120	13335,521
	U de theil	0,6778
	EQM	1196965,24
	EAM	916,18

Tabela 8: Previsão por Holt-Winters da série de Exportações


Período	Observado	Previsto
2007 01	8466,201	7290,700
2007 02	7225,435	6862,823
2007 03	9545,377	8126,915
2007 04	8254,921	7536,789
2007 05	9780,682	8054,718
2007 06	9302,949	8046,995
2007 07	10772,700	8726,036
	U de theil	0,7960
	EQM	1826606,15
	EAM	1243,33


Tabela 9: Previsão por Holt-Winters da série de Importações



Período	Observado	Previsto
2007 01	109,22	104,04
2007 02	104,08	95,66
2007 03	121,21	117,76
2007 04	113,58	92,07
2007 05	125,46	120,14
2007 06	121,61	121,20
2007 07	125,46	121,63
	U de theil	0,9754
	EQM	87,92
	EAM	6,87

Tabela 10: Previsão por Holt-Winters da série de Produção Industrial





Comparando os valores observados e os valores previstos através do método podemos perceber sua qualidade, com pequenos erros que advêm do contexto econômico, portanto não sendo previsíveis. Obtemos uma boa margem de exatidão, valores previstos próximos dos observados, dentro de uma diferença aceitável.

Com os valores do EQM e EAM, fica claro a diferença de erro ocorrida com a utilização dos diferentes métodos. Na série de exportações, vemos que o índice U de Theil foi melhor nos valores previstos pelo método de Holt-Winters do que no método de decomposição, mas percebemos que o EQM foi menor pelo método de decomposição, o que nos diz que o método de Holt-Winters, apesar de prever melhores resultados, incorre erros tão grandes ou maiores que o método de decomposição. Por fim, avaliando o EAM vemos que a média dos erros absolutos, foi menor quando calculado a partir do método de Holt-Winters, permitindo assim uma escolha mais segura de qual método utilizar para tomada de decisões, tendo consciência de limites de erros que são aceitáveis.

Analisando os resultados obtidos pelos diferentes métodos para as previsões da série de importações, é facilmente percebido que o método de decomposição clássica atendeu melhor a modelagem da série que o método de Holt-Winters. Incorrendo uma razoável diferença em todos os coeficientes de avaliação dos métodos, apesar da maior simplicidade e menor custo computacional. Alguns fatores presentes ao longo

da série podem ter influenciado na qualidade dos resultados obtidos pelo método de Holt-Winters, este que suavizando a série leva em consideração todos os seus termos. Enquanto para o método de decomposição, que nas previsões não leva em consideração todo o histórico da série, tais fatores não tiveram peso a ponto de influenciar nos resultados.

A partir dos valores do índice U de Theil, EQM e EAM obtidos para a série de produção industrial calculados após os resultados encontrados pelos métodos, concluimos que o método de decomposição alcançou melhores resultados para as previsões que o método de Holt-Winters. Principal diferença observada no índice U de Theil, enquanto o índice para o método de Holt-Winters nesta série, com dado custo computacional para aplicação, resultou índice próximo ao da previsão ingênua, considerada um dos mais simples métodos de previsão, temos que o método de decomposição clássica, com um bom ajuste linear através da regressão definida, resultou índice melhor. Outra contribuição para a comparação dos métodos foi o EQM, pois notou-se considerável diferença nesta medida entre os métodos escolhidos. Já no EAM, não houve grande diferença o que mostra que os erros relacionados com os valores reais, foram parecidos.

## 9 CONCLUSÃO

No desenvolvimento deste trabalho, ficou claro que com idéias simples e pleno domínio das ferramentas necessárias, podemos determinar importantes projeções. Num ambiente macroeconômico, onde inicialmente pode se pensar que não deve haver espaços para incertezas e margens de erro razoáveis, consegue-se com um certo esforço computacional uma janela confiável de valores, que podem servir como base para tomada de decisões. Porém não com grande horizonte de previsão, o que por vezes é tão importante quanto a previsão.

As séries tratadas aqui mostram relação entre si, com uma atenta observação dos dados observa-se que a série de Produção Industrial, possui uma aparente condensação entre os valores de Importações e Exportações. O que pode ser imaginado da relação de mercado, pois conforme os registros de Importações e Exportações se relacionam há necessidade de crescimento ou decréscimo da produção, de acordo com os períodos esperados. Períodos estes que formam sazonalidades, anuais, devido a composição das séries. Onde estas flutuações também podem ser utilizadas para ajustes e previsões.

Sem dúvida os recursos tecnológicos foram essenciais para a efetivação do trabalho. Softwares como Microsoft Excel, que fornecem os recursos necessários a estudos deste tipo. Possibilitando otimizações não-lineares de parâmetros de suma importância nos resultados do trabalho.

Um fator indispensável foi o índice U de Theil, que mostrou a qualidade dos resultados obtidos em relação a previsão ingênua e as medidas de erro, EQM e EAM. Mostrando que mesmo com apenas uma decomposição e manipulação dos dados, obteve-se valores previstos próximos dos reais observados. Comparando tais índices obtidos para os valores previstos por decomposição clássica e pelo método de Holt-Winters. Vemos que para as séries de importações e produção, um bom ajuste linear, apenas com a clássica decomposição melhores resultados foram obtidos do que suavizando exponencialmente as componentes da série.



## Referências

- [1] MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven; McGEE, Victor. **Forecasting: Methods and Applications**. 2. ed. John Wiley and Sons, Inc, 1983. 923 p.
- [2] FALCO, Glaucia de Paula - **Técnicas univariadas aperfeiçoadas para a previsão de curtíssimo prazo a partir de dados horários**. 2ª 2005. 139 f. Dissertação (Mestrado em Engenharia Elétrica) PUC-RJ, 2005.
- [3] MORETTIN, Pedro A. **Econometria Financeira**. São Paulo: Associação Brasileira de Estatística, 2006. v. 1. 340 p.
- [4] EHLERS, R.S. (2005) **Análise de Séries Temporais**. Departamento de Estatística, UFPR. Disponível em <http://leg.est.ufpr.br/ehlers/notas>. Acesso em: 15 abr. 2007.
- [5] SAMOHYL, Robert; SOUZA, Gueibi; Miranda, Rodrigo. **Métodos Simplificados de Previsão Empresarial**. 1. ed. Florianópolis. Disponível em <<http://www.qualimetria.ufsc.br>>. Acesso em: 6 out. 2007.
- [6] PINDYCK, Robert S.; RUBINFELD, Daniel L. **Econometric models and economic forecasts**. 3 ed. McGraw-Hill, Inc, 1991. 596 p.
- [7] IPEA. IPEADData: Divulgação de séries temporais. Disponível em: <<http://www.ipeadata.gov.br>>. Acesso em: 13 julho 2007.
- [8] IBGE. Pesquisa Industrial Mensal - Produção Física: Publicação de resultados. Disponível em: <<http://www.ibge.gov.br>>. Acesso em: 16 ouo 2007.

## 10 ANEXOS

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1977	885	853	950	1072	1218	1227	1020	1080	960	908	913	1033
1978	803	818	1052	1012	1065	1108	1020	1082	1153	1209	1126	1210
1979	1013	950	1160	1199	1302	1176	1423	1387	1369	1461	1290	1514
1980	1369	1444	1521	1600	1681	1764	1849	1936	2025	2116	2209	2304
1981	1696	1735	1755	1880	1869	1925	2052	2010	2081	2112	2127	2051
1982	1646	1440	1767	1569	1713	1690	1758	1822	1698	1606	1713	1753
1983	1533	1331	1683	1805	1952	1964	1907	2066	1996	1809	1827	2026
1984	1647	1835	2054	2123	2396	2484	2550	2540	2269	2417	2303	2387
1985	1571	1470	1957	2124	2238	2194	2184	2170	2404	2370	2292	2665
1986	1907	1750	2156	2171	2289	1999	2204	2094	1847	1337	1270	1325
1987	1264	1452	1436	1673	2187	2643	2923	2755	2692	2505	2247	2447
1988	2158	2060	2472	2813	2904	3103	2972	3462	3312	2680	2950	2903
1989	2751	2263	2847	2398	2832	3686	3200	3364	2951	2744	2576	2771
1990	2280	1974	2232	2558	3232	2510	3082	3062	2592	2333	2665	2894
1991	2929	2270	2612	3024	2911	2811	2561	2805	2070	2655	2458	2514
1992	2569	2389	2887	2681	2916	2954	3441	3024	3016	3220	3277	3419
1993	2813	2890	3509	3028	2884	3238	3423	3503	3446	3240	3171	3410
1994	2747	2778	3351	3635	3862	3728	3738	4282	4162	3842	3706	3714
1995	2980	2952	3799	3394	4205	4119	4004	4558	4167	4405	4048	3875
1996	3473	3405	3408	4271	4506	3840	4459	4381	4115	4188	3912	3789
1997	3685	3146	3826	4629	4659	4844	5239	5075	4588	4793	3976	4534
1998	3917	3716	4274	4576	4612	4886	4970	3986	4538	4017	3704	3944
1999	2949	3267	3829	3707	4386	4313	4117	4277	4187	4304	4002	4673
2000	3453	4123	4472	4181	5063	4861	5003	5519	4724	4638	4390	4659
2001	4538	4083	5167	4730	5368	5041	4965	5727	4755	5003	4500	4346
2002	3972	3658	4260	4641	4441	4079	6223	5751	6492	6474	5127	5243
2003	4805	5001	5239	5711	6372	5874	6105	6403	7280	7566	5980	6748
2004	5800	5722	7927	6590	7941	9328	8992	9056	8923	8844	8159	9194
2005	7444	7756	9251	9202	9818	10206	11062	11346	10634	9903	10790	10896
2006	9271	8750	11366	9830	10305	11463	13651	13671	12548	12659	11866	12234
2007	10963	10103	12889	12446	13647	13119	14120					

Tabela 11: Dados Observados - Exportações Brasileiras. Valores em milhões de dólares.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1977	959	885	1003	1004	1133	980	924	1129	1027	647	1346	982
1978	974	994	1062	1071	1069	1135	1362	1247	1149	1072	1245	1297
1979	1222	1064	1272	1228	1469	1279	1653	1828	1579	1857	1715	1914
1980	1896	1685	1900	1975	1929	1845	1946	1895	2201	1994	1850	1834
1981	1829	1892	1884	1936	1857	1771	1961	1822	1826	1703	1765	1840
1982	1653	1440	1710	1547	1701	1623	1696	1724	1650	1548	1506	1592
1983	1412	1203	1209	1238	1239	1173	1173	1428	1305	1243	1286	1515
1984	1122	990	1042	1065	1179	1162	1380	1143	1206	1138	1203	1281
1985	1045	985	1063	1045	1005	964	957	1073	1101	1256	1213	1440
1986	1208	1123	1021	880	951	928	1198	1149	1312	1419	1308	1542
1987	1299	1131	1133	1170	1226	1212	1466	1326	1194	1312	1245	1330
1988	1111	1164	1241	917	1154	1277	1114	1377	1284	1172	1243	1548
1989	1235	1164	1280	1030	1481	1601	1680	1909	1789	1686	1652	1751
1990	1678	1251	1646	1362	1534	1369	1576	1999	1898	2037	2263	2044
1991	1622	1245	1463	1619	1577	1837	1789	2152	1671	2247	2005	1808
1992	1651	1521	1457	1504	1564	1656	1956	1622	1643	1992	1761	2222
1993	1798	1431	2000	2124	1590	2292	2770	2340	2217	2094	2039	2555
1994	1768	2030	2248	2152	2624	2498	2514	2775	2641	3186	4114	4523
1995	3283	4012	4721	3863	4897	4896	4002	4461	3687	4076	4136	3932
1996	3439	3434	3876	4073	4249	4167	4806	4661	4748	5496	4755	5634
1997	2512	4249	4727	5534	4721	5208	5782	5369	5435	5644	5262	5299
1998	4640	3936	5167	4629	4733	4700	5392	4153	5723	5455	4729	4451
1999	3645	3163	4051	3668	4078	4459	4026	4461	4243	4457	4530	4424
2000	3568	4047	4450	3995	4700	4604	4886	5422	5045	5165	5022	4872
2001	5014	4005	5447	4609	5156	4761	4856	5099	4159	4756	4213	3492
2002	3802	3396	3663	4139	4063	3399	5023	4174	4002	4283	3848	3442
2003	3650	3888	3702	3988	3854	3520	4049	3730	4615	5030	4262	3997
2004	4216	3761	5345	4635	4831	5529	5529	5623	5753	5840	6082	5686
2005	5262	4979	5909	5331	6372	6172	6056	7695	6315	6227	6715	6566
2006	6451	5971	7706	6741	7287	7365	7991	9116	8108	8738	8657	7213
2007	8466	7225	9545	8254	9780	9302	10772					

Tabela 12: Dados Observados - Importações Brasileiras. Valores em milhões de dólares.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1977	50	46	59	43	60	59	58	61	57	58	59	56
1978	54	48	60	46	62	61	61	67	61	65	64	60
1979	60	53	64	49	68	66	66	72	63	72	68	63
1980	64	60	72	53	74	73	77	76	77	77	74	67
1981	64	61	67	49	66	67	69	68	66	67	64	58
1982	56	53	67	49	67	69	71	74	71	68	66	59
1983	54	50	63	45	64	64	64	70	67	67	67	60
1984	57	57	62	47	69	70	73	75	71	76	72	64
1985	67	58	69	49	70	72	81	82	81	87	80	73
1986	75	67	72	61	79	83	91	89	96	98	88	79
1987	80	77	83	67	83	85	86	85	91	91	86	76
1988	74	70	84	62	79	86	87	92	90	84	80	73
1989	72	64	77	60	84	90	94	100	94	97	89	75
1990	76	70	74	47	75	78	87	92	87	90	81	64
1991	66	59	66	75	80	81	88	88	82	87	77	63
1992	65	68	71	70	73	76	80	78	78	80	77	68
1993	67	67	80	76	82	82	86	87	83	84	83	74
1994	73	70	84	76	86	86	88	96	93	93	93	88
1995	86	82	95	85	85	89	88	91	87	90	88	77
1996	78	76	84	83	90	86	97	96	94	98	94	83
1997	83	79	88	91	93	94	98	98	101	103	92	81
1998	80	78	91	88	94	94	98	96	95	94	91	79
1999	78	74	89	85	91	91	93	97	96	97	95	86
2000	81	86	92	88	97	98	100	104	99	105	100	92
2001	91	88	100	94	102	97	101	104	98	101	98	86
2002	90	87	97	100	100	96	104	105	103	113	106	93
2003	92	90	96	95	99	95	101	102	107	113	107	98
2004	95	92	108	102	108	107	112	116	116	117	116	106
2005	101	95	110	109	114	114	113	120	115	117	117	109
2006	104	101	116	107	119	114	117	124	117	123	122	109
2007	109	104	121	113	125	121	125					

Tabela 13: Dados Observados - Produção Industrial Brasileira. Valores em Índice *quantum*.