



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE MATEMÁTICA
DEPARTAMENTO DE ESTATÍSTICA



Modelos para Previsão em Séries Temporais: uma Aplicação para a Taxa de Desemprego na Região Metropolitana de Porto Alegre

Autor: Marcel Henrique Becker
Orientador: Professor Dr. Cleber Bisognin

Porto Alegre, 15 de Dezembro de 2010.

Universidade Federal do Rio Grande do Sul
Instituto de Matemática
Departamento de Estatística

Modelos para Previsão em Séries
Temporais: uma Aplicação para a Taxa de
Desemprego na Região Metropolitana de
Porto Alegre

Marcel Henrique Becker

Monografia apresentada para obtenção
do grau de Bacharel em Estatística.

Banca Examinadora:
Professor Dr. Cleber Bisognin
Professor Dr. Hudson da Silva Torrent

Porto Alegre, 15 de Dezembro de 2010.

Resumo

Nesse trabalho serão apresentadas técnicas para previsão em séries temporais através da análise de dados reais. O dinamismo do mercado de trabalho e a consequente necessidade de estudos mais aprofundados, fez com que em 1985 surgisse, a partir de metodologia do Departamento Intersindical de Estatística e Estudos Socioeconômicos (DIEESE) a Pesquisa de Emprego e Desemprego (PED). Essa pesquisa foi o principal motivador desse trabalho que apresentará a caracterização da série, modelagem e tem por fim fazer previsões dos futuros valores. Os métodos utilizados para os ajustes das séries e previsões serão suavização exponencial, modelos de Holt-Winters e modelos SARIMA.

Palavras - chave: Modelos SARIMA; Holt-Winters; Suavização exponencial; Pesquisa de Emprego e Desemprego.

Abstract

This work will be shown techniques for time series forecasting by analyzing real data. The dynamism of the labor market and the consequent need for further studies, made in 1985 arose from the methodology the Department of Statistics and Socioeconomic Studies (DIEESE) the Survey of Employment and Unemployment (PED). This research was the primary motivator of this work will present the characterization of the series, modeling and seeks to make predictions of future values. Methods used for adjustments of the series and exponential smoothing forecasts are models, Holt-Winters and SARIMA models.

Sumário

1. Introdução	6
2. Modelos para séries temporais	8
2.1 Suavização Exponencial.....	9
2.2 Modelos Holt-Winters.....	10
2.2.1 Modelo Holt-Winters Aditivo	10
2.2.2 Modelo Holt-Winters Multiplicativo	11
2.3 Modelo SARIMA	12
3. Análise de Dados Reais	14
3.1 Modelo suavização exponencial	16
3.2 Modelos Holt-Winters.....	19
3.3 Modelo SARIMA	27
3.4 Modelo de Suavização Exponencial Para a Série Diferenciada	30
3.5 Modelo Holt-Winters para a série diferenciada.....	36
3.6 Comparação de resultados e previsões.....	40
4. Considerações finais	44
Referências Bibliográficas	45

1. Introdução

Ao explorarmos séries temporais nos deparamos com dados sazonais, isto é, que possuem a característica de repetir-se em determinados períodos de tempo. Séries que possuem essa característica merecem atenção especial no seu estudo para ajuste de modelo, tanto para entendermos a série quanto para fazermos previsões dos futuros valores.

Uma série temporal é uma sequência de observações feitas em um período de tempo (BOX, JENKINS e REINZEL, 1994). A análise de séries temporais permite descrever a dependência dos dados em relação ao tempo e prever valores futuros. Exemplos de séries temporais são encontrados de várias formas: ações, inflação, temperatura, taxa mensal de desemprego, número de homicídios, etc.

O objetivo é estudar os modelos para séries temporais sazonais aplicados aos resultados mensais da taxa de desemprego da Região Metropolitana de Porto Alegre. Além da taxa de desemprego, a pesquisa divulga mensalmente dados referente a ocupação, inatividade, rendimentos do trabalhador, entre outros. Essas informações auxiliam gestores a tomarem decisões para estimular o emprego e também no que se refere, por exemplo, a questão da previdência.

O período de estudo da pesquisa de emprego e desemprego (PED) que será utilizado para este trabalho será entre 1993 e 2009, restando assim o ano de 2010 para realizar previsões. A fonte desses dados é pública e está disponibilizada no site do Departamento Intersindical de Estatística e Estudos Socioeconômicos – DIEESE na internet.

No segundo capítulo serão apresentados os modelos utilizados na análise das séries. Iniciamos pelo modelo de suavização exponencial e seguindo com os modelos Holt-Winters (aditivo e multiplicativo). A seguir será apresentado o modelo SARIMA. Esse capítulo será fortemente baseado na bibliografia MORETTIN & TOLOI.

A previsão no caso do modelo de suavização exponencial deve ser atualizada a cada nova observação. No caso da PED, ocorre mensalmente. Isso é explicado pelo fato de que a previsão é realizada a partir do dado observado anteriormente e o dado previsto no passo anterior. Ou seja, se fosse realizada uma nova previsão a partir do dado previsto anteriormente, obteríamos a mesma estimativa porque o dado observado anteriormente e o dado previsto no passo anterior seriam o mesmo.

O Método de Holt-Winters é uma técnica determinística de previsão, a qual não exige qualquer manipulação dos dados originais para que, por exemplo, respeitem uma distribuição normal ou estejam estacionados. Portanto, sua aplicação resume-se apenas a utilização de suas fórmulas clássicas para que as previsões sejam geradas. O estímulo ao uso dessa técnica surgiu a partir do artigo intitulado “O uso de modelos de séries temporais no estudo da produção de álcool no Brasil” de LOPES, ALENCA, LIPPI & YAMAMOTO.

Através da metodologia de Box e Jenkins de identificação, estimação e previsão em séries temporais, os modelos ARIMA se tornaram populares na década de 70. Com a introdução da componente sazonal, chegamos ao modelo SARIMA (integrado autorregressivo e médias móveis com sazonalidade).

No terceiro capítulo serão apresentados os resultados de análise de dados reais. Serão analisados os dados mensais da PED e também a série da diferença mensal da taxa de desemprego. Na última seção do capítulo serão realizadas as comparações entre os modelos, onde se procurará apontar um melhor modelo geral para as séries estudadas. O quarto capítulo será dedicado as considerações finais.

Os softwares utilizados nas análises e resultados apresentados nesse trabalho foram o “R”, Statistical Packet of Social Science, SPSS e MINITAB.

Todas as análises serão baseadas num intervalo de confiança de 95%.

2. Modelos para séries temporais

A classe de fenômenos cujo processo observacional e consequente quantificação numérica gera uma sequência de dados distribuídos no tempo é denominada série temporal (SOUZA, 1989).

Os métodos para previsão de séries temporais são classificados como métodos quantitativos, baseiam-se na extrapolação de características de observações passadas e no inter-relacionamento entre essas observações, fornecendo previsões acuradas se o futuro apresentar comportamento similar ao passado (WHEEL, WRIGHT, 1985).

De acordo com (WHEEL, WRIGHT, 1985) a maioria dos métodos de previsão de séries temporais se baseia na suposição de que as observações passadas contém todas as informações sobre o padrão de comportamento da série temporal e esse padrão é recorrente no tempo. O propósito dos métodos de previsão consiste em distinguir o padrão de qualquer ruído que possa estar contido nas observações e então usar esse padrão para prever os valores futuros da série temporal. Assim, pela identificação desse componente, a previsão para períodos de tempo subsequentes ao observado pode ser desenvolvida.

Uma série temporal é amostra de um processo estocástico. Um processo estocástico é não estacionário por apresentar tendências. Esses movimentos na série podem dificultar a análise dos dados, ainda assim os modelos estudados nesse trabalho podem ser trabalhados sem a necessidade de estacionariedade.

Em função de não ser estacionária, a série da taxa de desemprego foi modificada (trabalhando com a diferença mensal absoluta da taxa de desemprego). Essa série modificada é estacionária e também será estudada nesse trabalho. A seguir define-se um processo estacionário:

Um processo estocástico é representado por uma sequência de variáveis aleatórias $\{X_t\}_{t \in \mathbf{Z}}$. O processo estocástico é estritamente estacionário se, para todo $i, j \in \mathbf{Z}$, $i \neq j$ e para todo $k \in \mathbf{N}$, a distribuição multivariada de $(X_i, X_{i+1}, \dots, X_{i+k})$ é idêntica à de $(X_j, X_{j+1}, \dots, X_{j+k})$. Na prática só é possível testar algumas das consequências da premissa de que um processo é estritamente estacionário; em particular, se as distribuições multivariadas são idênticas, então:

$$E(X_t) = \mu, \text{ para todo } t;$$

$$E |X_t|^2 < \infty, \text{ para todo } t;$$

$\gamma(t1, t2) = Cov \{X(t1), X(t2)\}$ é uma função de $|t1 - t2|$.

A seguir apresentamos os modelos de suavização exponencial.

2.1 Suavização Exponencial

Estes modelos serão utilizados na análise de dados reais apresentados nos capítulos 3 e 4.

O modelo de suavização exponencial satisfaz a seguinte equação:

$$\bar{Z}_t = \alpha \sum_{k=0}^{t-1} (1-\alpha)^k Z_{t-k} + (1-\alpha)^t \bar{Z}_0, t = 1, \dots, N$$

onde \bar{Z}_t é denominado valor exponencialmente suavizado e α , $0 \leq \alpha \leq 2$, é a constante de suavização. Efetuando a expansão da equação acima temos:

$$\bar{Z}_t = \alpha Z_t + \alpha(1-\alpha)Z_{t-1} + \alpha(1-\alpha)^2 Z_{t-2} + \dots$$

Isso significa que a suavização exponencial simples é uma média ponderada que atribui pesos maiores às observações mais recentes.

As equações de previsão para o modelo de suavização exponencial são dadas pelas seguintes expressões:

$$\hat{Z}_t(h) = \bar{Z}_t, \forall h > 0$$

$$\hat{Z}_t(h) = \alpha Z_t + (1-\alpha)\hat{Z}_{t-1}(h+1)$$

De acordo com as duas últimas expressões acima é possível perceber uma vantagem do método de suavização exponencial. A não necessidade de armazenagem de dados, devido ao fato de que para a atualização de previsão existe a necessidade apenas do valor de α , da observação mais recente e a última previsão. Porém esse fato também pode ser considerado uma desvantagem, ao passo que, não é possível fazer previsões mais que um passo a frente.

Enquanto que na Média Móvel as observações usadas para encontrar a previsão do valor futuro contribuem em igual proporção para o cálculo dessa previsão, no Alisamento Exponencial Simples as informações mais recentes são evidenciadas pela aplicação de um fator que determina essa importância (WHEEL, WRIGHT, 1985).

A maior dificuldade do método está em determinar o valor da constante α . Um α maior dá maior peso as previsões mais atuais. Em geral, valores mais baixos são

determinados para séries que possuem maiores flutuações, ou seja, maior aleatoriedade. O valor de $\alpha = 2/(r-1)$ fornece previsões semelhantes ao método de médias móveis com parâmetro r , onde r é o número de observações utilizadas para calcular a média no modelo de médias móveis.

Os próximos modelos a serem estudados serão os modelos de suavização Holt-Winters.

2.2 Modelos Holt-Winters

Esse modelo de suavização para séries temporais possui dois procedimentos distintos, porém semelhantes. O procedimento aditivo e o multiplicativo. A adoção de um ou outro dependerá da série considerada. A determinação, ou diferenciação, de aditivo ou multiplicativo será dada pelo fator sazonal do modelo.

Cada um desses dois procedimentos possui três equações em relação ao padrão da série: nível, tendência e sazonalidade e, cada uma das três equações possui uma constante de suavização diferente.

Para um melhor ajuste a idéia é minimizar a soma dos erros ao quadrado de ajustamento através das constantes de suavização. A dificuldade na determinação dessas constantes é uma das desvantagens do processo de suavização Holt-Winters.

Como vantagem pode ser citada a aplicabilidade do processo, adequada a análise de séries com comportamento mais geral. Além disso, o modelo Holt-Winters não exige a normalidade dos erros, nem que a série seja um processo estacionário (ruído branco).

O primeiro dos modelos de suavização Holt-Winters a ser estudado será o modelo Holt-Winters aditivo.

2.2.1 Modelo Holt-Winters Aditivo

O modelo Holt-Winters aditivo é descrito por uma equação principal e três equações de suavização que a compõem. Estas equações serão apresentadas nessa seção juntamente com as equações de previsão.

O modelo aditivo é dado pela seguinte equação:

$$Z_t = \mu_t + T_t + F_t + \varepsilon_t,$$

para $t = 1, \dots, N$, onde N é o tamanho da série, isto é, o número de observações da série.

As equações de suavização são apresentadas a seguir e representam as estimativas do fator sazonal, do nível e da tendência.

$$\begin{aligned}\hat{F}_t &= D(Z_t - \bar{Z}_t) + (1-D)\hat{F}_{t-s}, \quad 0 < D < 1, \\ \bar{Z}_t &= A(Z_t - \hat{F}_{t-s}) + (1-A)(\bar{Z}_{t-1} + \hat{T}_{t-1}), \quad 0 < A < 1, \\ \hat{T}_t &= C(\bar{Z}_t - \bar{Z}_{t-1}) + (1-C)\hat{T}_{t-1}, \quad 0 < C < 1,\end{aligned}$$

onde A, C e D são as constantes de suavização.

O valor ótimo das constantes de suavização é determinado pelo vetor (D, A, C) que minimiza a soma dos erros quadráticos de previsão.

As equações de previsão para o modelo aditivo são dadas pelas seguintes expressões as quais dependem do valor da sazonalidade $s \in \mathbb{N}$.

$$\hat{Z}_t(h) = \bar{Z}_t + h\hat{T}_t + \hat{F}_{t+h-s},$$

onde $h = 1, 2, \dots, s$.

$$\hat{Z}_t(h) = \bar{Z}_t + h\hat{T}_t + \hat{F}_{t+h-2s},$$

onde $h = s+1, \dots, 2s$.

O próximo modelo de suavização a ser estudado será o modelo Holt-Winters multiplicativo.

2.2.2 Modelo Holt-Winters Multiplicativo

A seguir serão apresentadas as equações e principais ideias a respeito do modelo Holt-Winters multiplicativo.

O modelo multiplicativo é dado pela seguinte equação:

$$Z_t = \mu_t F_t + T_t + \varepsilon_t$$

As equações de suavização que representam as estimativas do fator sazonal, do nível e tendência são dadas a seguir:

$$\begin{aligned}\hat{F}_t &= D\left(\frac{Z_t}{\bar{Z}_t}\right) + (1-D)\hat{F}_{t-s}, \quad 0 < D < 1, t = s+1, \dots, N \\ \bar{Z}_t &= A\left(\frac{Z_t}{\hat{F}_{t-s}}\right) + (1-A)(\bar{Z}_{t-1} + \hat{T}_{t-1}), \quad 0 < A < 1, t = s+1, \dots, N\end{aligned}$$

$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1-C)\hat{T}_{t-1}, \quad 0 < C < 1,$$

onde A, C e D são constantes de suavização, que são determinadas pelo vetor (D, A, C) que minimiza a soma dos erros quadráticos de previsão, s corresponde ao valor sazonal (sazonalidade) e N ao número de observações na série.

A previsão no caso multiplicativo pode ser expressa pelas equações abaixo, onde s é o fator sazonal:

$$\hat{Z}_t(h) = (\bar{Z}_t + h\hat{T}_t)\hat{F}_{t+h-s},$$

onde $h = 1, 2, \dots, s$.

$$\hat{Z}_t(h) = (\bar{Z}_t + h\hat{T}_t)\hat{F}_{t+h-2s},$$

onde $h = s+1, \dots, 2s$.

O próximo modelo a ser estudado será o modelo SARIMA, que será descrito na seção 2.3.

2.3 Modelo SARIMA

A seguir apresentamos os modelos SARIMA, os quais serão utilizados na análise de dados no Capítulo 3.

Seja $\{X_t\}_{t \in \mathbb{Z}}$ um processo estocástico satisfazendo a equação:

$$\Phi(B^s)\phi(B)(1-B)^d(1-B^s)^D(X_t - \mu) = \Theta(B^s)\theta(B)\varepsilon_t,$$

onde μ é a média do processo, $\{\varepsilon_t\}_{t \in \mathbb{Z}}$ é um processo ruído branco, $s \in \mathbb{N}$ é a sazonalidade, B é o operador de defasagem, isto é, $B^j(X_t) = X_{t-j}$, $B^{sj}(X_t) = X_{t-sj}$, para $j, s \in \mathbb{N}$, $(1-B)^d$ e $(1-B^s)^D$ são os operadores, respectivamente, diferença e diferença sazonal, $\phi(\cdot)$ e $\theta(\cdot)$, $\Phi(\cdot)$ e $\Theta(\cdot)$ são os polinômios de ordem p , q , P e Q , respectivamente, definidos por:

$$\phi(z) = \sum_{l=0}^p (-\phi_l)z^l, \quad \theta(z) = \sum_{m=0}^q (-\theta_m)z^m,$$

$$\Phi(z) = \sum_{r=0}^P (-\Phi_r)z^r, \quad \Theta(z) = \sum_{m=0}^Q (-\Theta_m)z^m,$$

onde $\phi_l, 1 \leq l \leq p$, $\theta_m, 1 \leq m \leq q$, $\Phi_r, 1 \leq r \leq P$, $\Theta_l, 1 \leq l \leq Q$, são constantes reais e $\phi_0 = \Phi_0 = -1 = \theta_0 = \Theta_0$. Então, $\{X_t\}_{t \in \mathbb{Z}}$ é um processo sazonal auto-regressivo integrado de média móvel de ordem $(p,d,q) \times (P,D,Q)_s$, denotado por SARIMA $(p,d,q) \times (P,D,Q)_s$, onde d e D são, respectivamente, o grau de diferenciação e o grau de diferenciação sazonal.

No capítulo 3 estudaremos a aplicação dos modelos em um caso real.

3. Análise de Dados Reais

Neste capítulo será feita a análise de dados reais utilizando as técnicas apresentadas no Capítulo 2.

Apresentaremos a análise da série “Taxa mensal de desemprego na região metropolitana de Porto Alegre”. Também será feita a análise da variação absoluta da taxa (série original diferenciada) para retirarmos a tendência da série e verificarmos o comportamento dos modelos.

A seguir são apresentadas as duas séries que serão analisadas. A série da taxa de desemprego total da região metropolitana de Porto Alegre e, também a série que corresponde a diferença da taxa mensal de desemprego.

Figura 1: Taxa mensal de desemprego e diferença mensal da taxa de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Figura 2: Gráfico da função de autocorrelação da taxa mensal de desemprego, na região metropolitana de Porto Alegre.


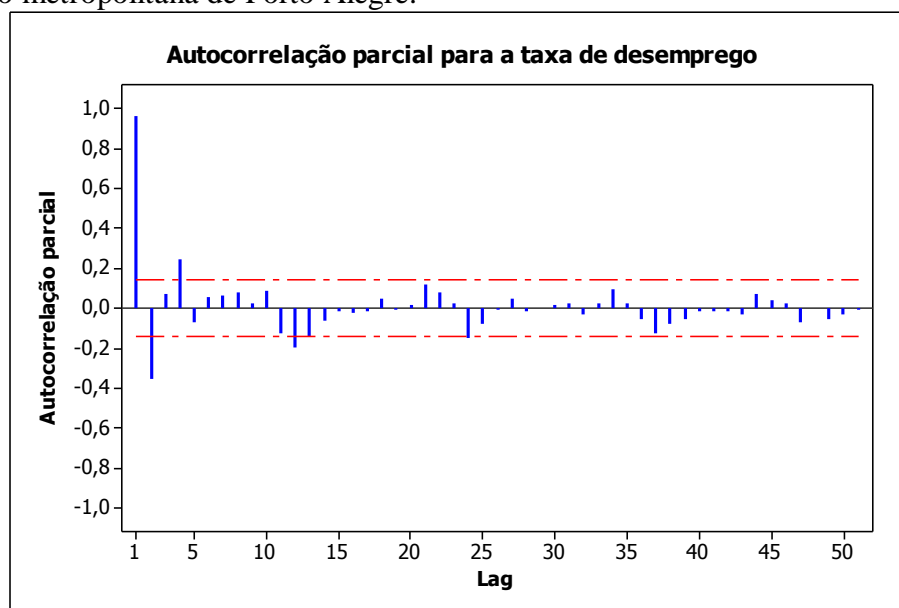


Figura 3: Gráfico da função de autocorrelação parcial da taxa mensal de desemprego, na região metropolitana de Porto Alegre.



Cada uma das séries possui duzentos e quatro observações ao longo de 17 anos (série mensal). Na figura 1 a série mais acima é a série original da taxa de desemprego. A série abaixo é a variação da taxa de desemprego original (taxa de desemprego de um mês menos taxa de desemprego do mês imediatamente anterior), ou seja, diferenciamos a série para retirar a tendência.

A pesquisa de emprego e desemprego é realizada desde o ano de 1992 e teve seus primeiros resultados divulgados em junho daquele ano. Desde então, todos os meses são divulgados dados referentes ao mercado de trabalho da região metropolitana de Porto Alegre. Essa mesma pesquisa é realizada em outras cinco regiões metropolitanas (Belo Horizonte, Fortaleza, Recife, Salvador e São Paulo) além do Distrito Federal. A metodologia da pesquisa é do DIEESE (Departamento Intersindical de Estatística e Estudos Socioeconômicos) e, em cada localidade ela possui parcerias, em geral, com órgãos ligados aos governos estaduais e municipais das regiões.

As Figuras 2 e 3 referem-se as funções de autocorrelação e autocorrelação parcial da taxa de desemprego – que será a primeira série a ser analisada -. Essas figuras indicam que a série possui certa dependência, que pode ser notada principalmente no gráfico da função autocorrelação pelo seu decaimento lento e também a presença da sazonalidade. Essas características também apontam para a não estacionariedade da série. O gráfico da função de autocorrelação parcial, através dos lags 12 e 24, também indica a presença de sazonalidade na série.

3.1 Modelo suavização exponencial

O modelo de suavização exponencial é, dentre os modelos apresentados nesse trabalho, o menos complexo. Uma desvantagem do modelo é a dificuldade em realizar previsões a longo prazo. Ao mesmo tempo a facilidade para atualização das previsões pode ser vista como uma vantagem do modelo.

A análise das figuras 4 e 5 indicam um modelo bem ajustado. As figuras de análise de resíduos não apresentam comportamento irregular. As medidas de acurácia MAPE, MAD e MSD apontam melhor qualidade com valores baixos e, a estatística MSD é comprável entre modelos diferentes para a mesma série. No caso da suavização exponencial, a estatística MSD foi 0,22908. A constante de suavização α foi estimada em 1,41406. Porém ao observarmos as figuras de autocorrelação e autocorrelação parcial dos resíduos indicam que o nosso modelo não está muito bem ajustado pois não capta bem a sazonalidade da série que aparece nos lags 12, 24, 36 e 48 nos dois indicadores.

Em relação às previsões, só é possível ajustar previsões até o mês de novembro, pois esse modelo é ajustado a cada nova observação. Ou seja, para o cálculo dessas previsões já foram inseridos os resultados originais da série até o mês de outubro

do ano de 2010. Por esse motivo, as previsões não apresentam elevado grau de amplitude no intervalo de confiança. Ao analisar a Figura 8 e a Tabela 1 observa-se que os valores previstos para 2010 e os dados reais estão próximos.

Figura 4: Gráfico da previsão através do modelo de suavização exponencial para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Figura 5: Análise de resíduos do modelo de suavização exponencial para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.

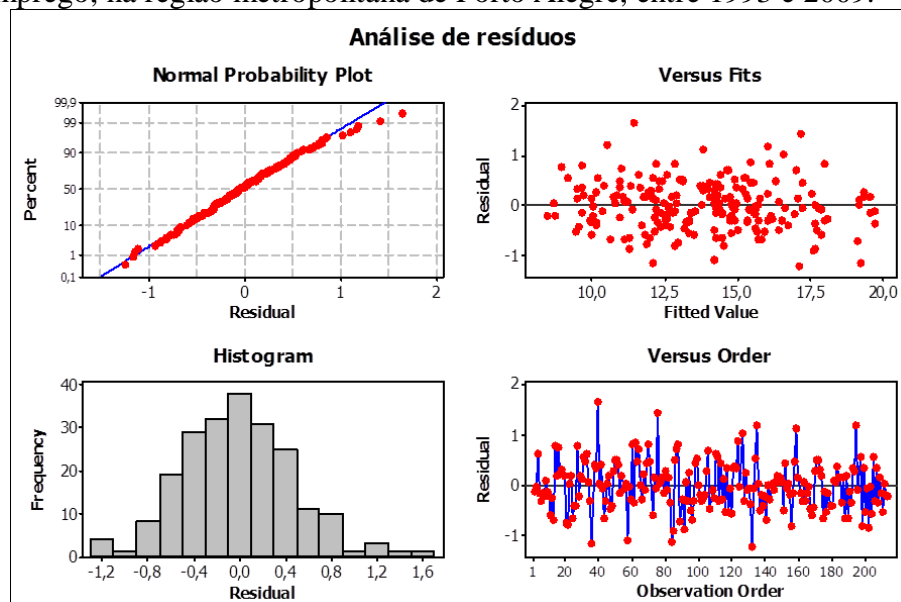


Figura 6: Função de autocorrelação dos resíduos do modelo de suavização exponencial.




Figura 7: Função de autocorrelação parcial dos resíduos do modelo de suavização exponencial.




Figura 8: Série original de 2008 a outubro de 2010 e previsão para os meses de janeiro a novembro do ano de 2010, segundo o modelo de suavização exponencial.

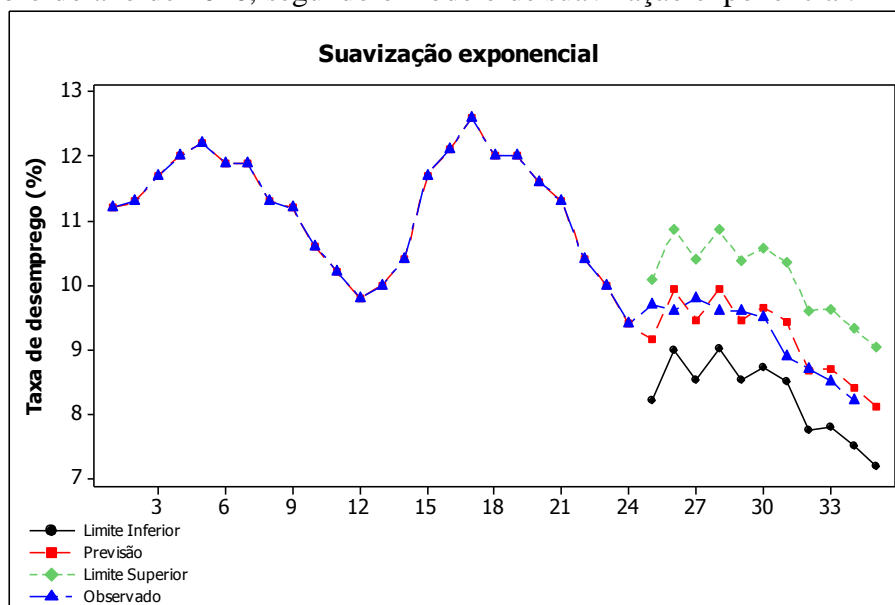


Tabela 1: Previsão através do modelo de suavização exponencial para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

Mês	Dados Observados	Previsão	Limite Inferior	Limite Superior
Janeiro	9,7	9,1507	8,2220	10,0794
Fevereiro	9,6	9,9295	8,9989	10,8601
Março	9,8	9,4632	8,5332	10,3931
Abril	9,6	9,9392	9,0098	10,8686
Mai	9,6	9,4603	8,5313	10,3892
Junho	9,5	9,6575	8,7313	10,5836
Julho	8,9	9,4352	8,5116	10,3588
Agosto	8,7	8,6787	7,7533	9,6041
Setembro	8,5	8,7088	7,7875	9,6301
Outubro	8,2	8,4137	7,4943	9,3331
Novembro		8,1116	7,1941	9,0291

3.2 Modelos Holt-Winters

Assim como no estudo dos demais modelos, serão apresentados para os modelos de Holt-Winters uma análise de resíduos, previsão para a taxa de desemprego em 2010 e funções de autocorrelação e autocorrelação parcial.

A maior dificuldade na utilização dos modelos Holt-Winters está na determinação das suas constantes de suavização. Assim, foi utilizado o software livre “R” que indica essas constantes, minimizando a soma dos erros quadráticos de previsão.

Foi baseado nessas indicações que foram realizadas as previsões para os modelos aditivo e multiplicativo de Holt-Winters.

Figura 9: Gráfico da previsão utilizando o modelo de suavização Holt-Winters ADITIVO para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Figura 10: Análise de resíduos do modelo de suavização Holt-Winters ADITIVO para a taxa mensal de desemprego, na região metropolitana de Porto Alegre.

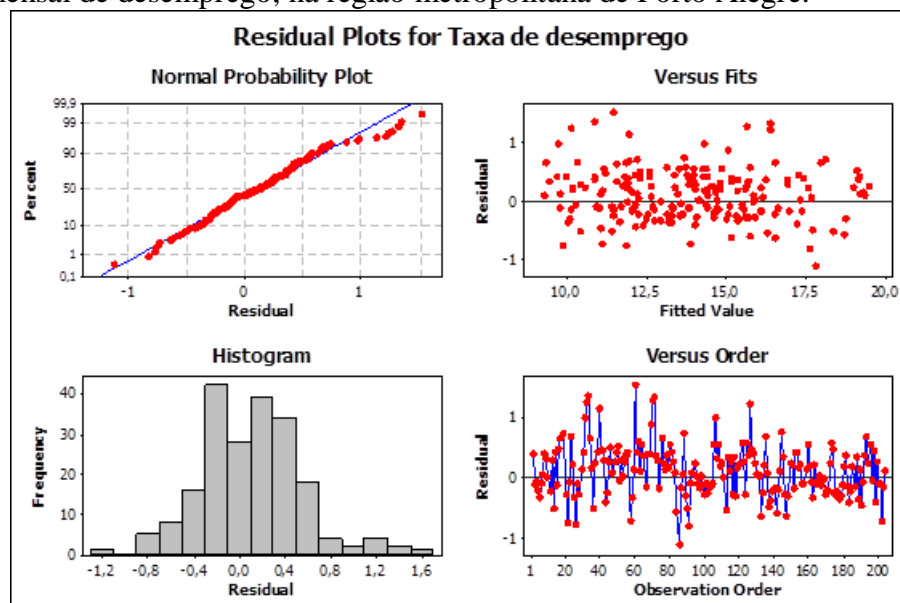


Figura 11: Função de autocorrelação dos resíduos do modelo Holt-Winters ADITIVO.

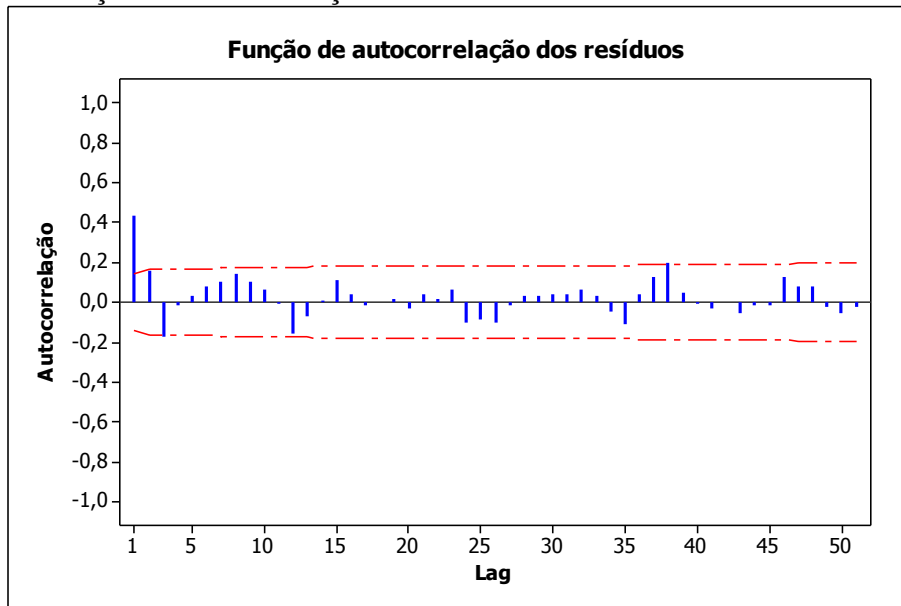


Figura 12: Função de autocorrelação parcial dos resíduos do modelo Holt-Winters ADITIVO.




Figura 13: Gráfico da série original de 2008 a outubro de 2010 e previsão para o ano de 2010 segundo o modelo Holt-Winters ADITIVO.




Tabela 2: Previsão através do modelo de suavização Holt-Winters ADITIVO para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

Mês	Dados Observados	Previsão	Limite Inferior	Limite Superior
Janeiro	9,7	9,0077	8,15043	9,8649
Fevereiro	9,6	9,1951	7,98282	10,4075
Março	9,8	10,0109	8,36945	11,6524
Abril	9,6	10,4541	8,35432	12,5539
Mai	9,6	10,5513	7,97955	13,123
Junho	9,5	10,3089	7,25798	13,3599
Julho	8,9	10,0824	6,54786	13,6169
Agosto	8,7	9,7663	5,74552	13,7872
Setembro	8,5	9,5502	5,0412	14,0592
Outubro	8,2	9,301	4,30247	14,2995
Novembro		9,0359	3,54686	14,5249
Dezembro		8,3574	2,37717	14,3377

A análise dos gráficos e tabelas relativos ao modelo de suavização aditivo de Holt-Winters nos indica boa suavização. Isso é reafirmado na Figura 11 referente a função de autocorrelação dos resíduos, que não possui nenhuma observação fora dos limites de confiança. O indicador MSD de acurácia é inferior ao registrado no modelo de suavização exponencial, o que significa um melhor ajuste. Os resíduos aparentemente apresentam distribuição normal e o gráfico de suavização apresenta as linhas de suavização e dados observados muito próximos. Em relação à previsão nota-se

que, com o passar dos meses a previsão situa-se num intervalo de confiança muito grande, não trazendo muita informação ao problema. Os valores observados no ano de 2010 estão sempre dentro dos limites de confiança e, os dados previstos e observados seguem tendência semelhante.

As constantes de suavização foram estimadas em $A = 0,89026$ para o nível, $C = 0,000463$ para a tendência e $D = 1$ para a sazonalidade. Os valores dessas constantes reforçam a idéia de que a sazonalidade é importante para a série e, que a tendência não é um fator que tenha importância grande para esse modelo.

Em relação ao modelo de suavização exponencial as figuras de autocorrelação dos resíduos e autocorrelação parcial dos resíduos apontam um melhor ajuste no modelo Holt-Winters aditivo.

Na sequencia realizaremos a análise para o modelo de suavização Holt-Winters multiplicativo. Após as figuras de previsão, análise de resíduos e autocorrelação e autocorrelação parcial será apresentada uma tabela com as taxas de desemprego previstas para 2010, junto com os intervalos de confiança e os dados reais observados.

Figura 14: Gráfico da previsão utilizando o modelo de suavização Holt-Winters MULTIPLICATIVO para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Figura 15: Análise de resíduos do modelo de suavização Holt-Winters MULTIPLICATIVO para a taxa mensal de desemprego.

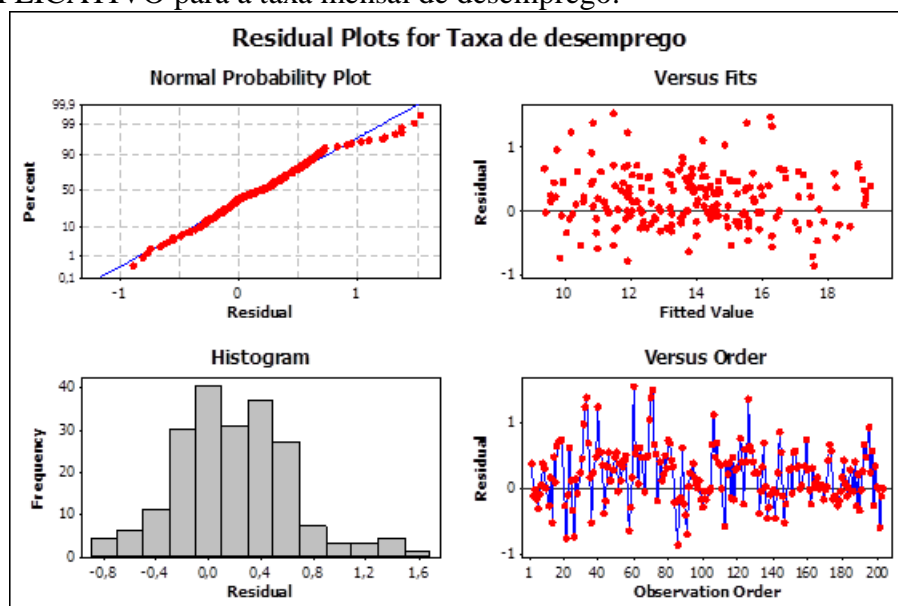


Figura 16: Função de autocorrelação dos resíduos para o modelo Holt-Winters MULTIPLICATIVO.

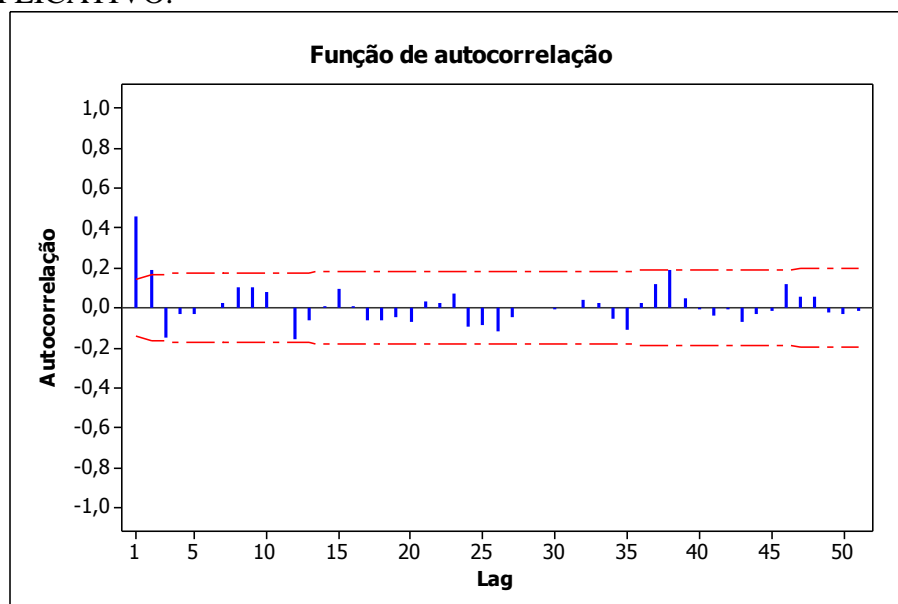


Figura 17: Função de autocorrelação parcial dos resíduos para o modelo Holt-Winters MULTIPLICATIVO.




Figura 18: Gráfico da série original de 2008 a outubro de 2010 e previsão para o ano de 2010 segundo o modelo Holt-Winters MULTIPLICATIVO.

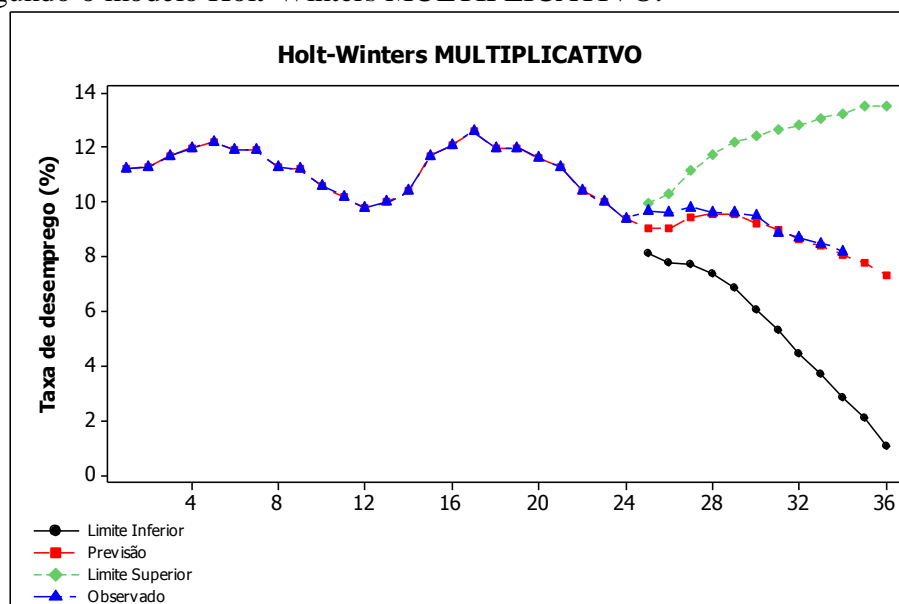


Tabela 3: Previsão através do modelo de suavização Holt-Winters MULTIPLICATIVO para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

Mês	Dados Observados	Previsão	Limite Inferior	Limite Superior
Janeiro	9,7	9,04686	8,15602	9,9377
Fevereiro	9,6	9,03226	7,77241	10,2921
Março	9,8	9,44749	7,74165	11,1533
Abril	9,6	9,58666	7,40455	11,7688
Mai	9,6	9,55527	6,88274	12,2278
Junho	9,5	9,24172	6,07118	12,4123
Julho	8,9	8,99605	5,32301	12,6691
Agosto	8,7	8,646	4,46757	12,8244
Setembro	8,5	8,38979	3,70404	13,0756
Outubro	8,2	8,06198	2,86751	13,2564
Novembro		7,7976	2,09342	13,5018
Dezembro		7,30733	1,09267	13,522

As constantes de suavização estimadas para o modelo multiplicativo de Holt-Winters foram $A = 0,86499$ para o nível, $C = 0$ para a tendência e $D = 1$ para a sazonalidade. Essas constantes nos indicam a mesma direção que no caso aditivo, onde a tendência tem peso irrelevante, enquanto a sazonalidade possui grande influência na suavização da série.

Quanto à qualidade da suavização é possível observar pela Figura 14, alta similaridade entre a série original e a série suavizada. A estatística MSD para o modelo Holt-Winters multiplicativo possui valor maior (0,22093) do que no modelo Holt-Winters aditivo (0,19852) e inferior ao modelo de suavização exponencial (0,22908). Em relação às previsões observa-se que o intervalo de confiança é elevado já nas previsões referentes aos primeiros meses do ano. Em dezembro, por exemplo, estima-se que a taxa de desemprego não seja inferior a 1,09267%. Esse dado pode ser considerado irrelevante, já que, na história moderna do país nunca tivemos um indicador de desemprego tão baixo e, para que esse fato aconteça uma grande massa deve ser ocupada, o que é praticamente impossível que ocorra em apenas um ano. Ainda assim, a previsão dos dados foi muito bem sucedida.

Apesar do intervalo de confiança não ser muito preciso, os dados previstos estão muito próximos dos realmente observados (isso pode ser observado na figura 18 e na Tabela 3 com mais detalhes) e coloca o modelo como candidato a melhor modelo de ajuste para esse conjunto de dados (ver Capítulo 4).

3.3 Modelo SARIMA

O modelo SARIMA foi trabalhado no software “R” e MINITAB afim de se obter uma melhor relação entre os seus componentes sazonais e não-sazonais auto – regressivos e médias móveis. Por fim, a partir do teste de Box-Pierce para verificação de estacionariedade, e análise das funções de autocorrelação e autocorrelação parcial, foi definido como melhor modelo o SARIMA $(0,1,3) \times (2,1,0)_{12}$, ou seja, um modelo na parte não sazonal com uma diferença e três médias móveis. Na parte sazonal, uma diferença, e dois auto - regressivos. O período da sazonalidade é 12, ou seja, a cada 12 meses o comportamento da série tende a ser semelhante.

Tabela 4: Coeficientes estimados pelo modelo SARIMA $(0,1,3) \times (2,1,0)_{12}$ para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

SARIMA $(0,13) \times (2,1,1)_{12}$	Coeficiente	p-valor
Constante	-0,013261	0,01
Média móvel 1	-0,4872	<0,001
Média móvel 2	-0,3848	<0,001
Média móvel 3	0,3056	<0,001
Auto regressivo sazonal 1	-0,3137	<0,001
Auto regressivo sazonal 2	-0,2392	0,004
Média móvel sazonal 1	0,8942	<0,001

Figura 19: Gráfico de previsão através do modelo SARIMA para a taxa mensal de desemprego, na região metropolitana de Porto Alegre.

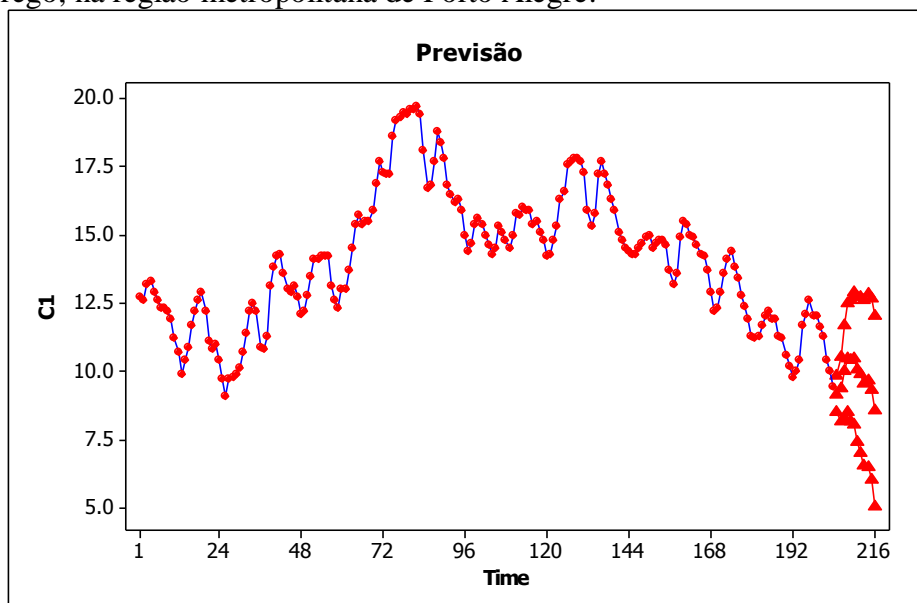


Figura 20: Análise de resíduos do modelo SARIMA $(0,1,3) \times (2,1,0)_{12}$ para a taxa mensal de desemprego, na região metropolitana de Porto Alegre

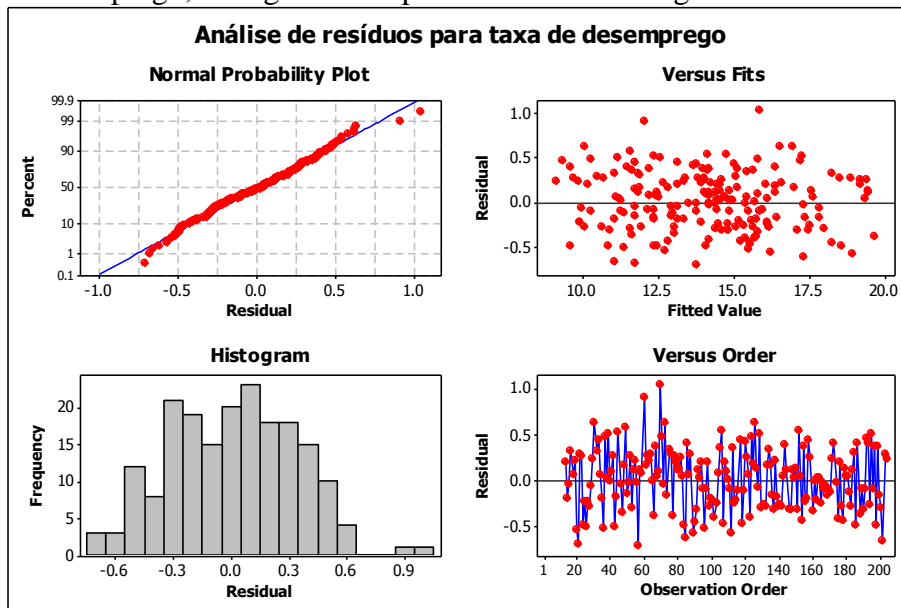


Figura 21: Gráfico da função de autocorrelação dos resíduos, obtida através do modelo SARIMA $(0,1,3) \times (2,1,0)_{12}$, para a taxa mensal de desemprego.




Figura 22: Gráfico da função de autocorrelação parcial dos resíduos, obtida através do modelo SARIMA $(0,1,3) \times (2,1,0)_{12}$, para a taxa mensal de desemprego.

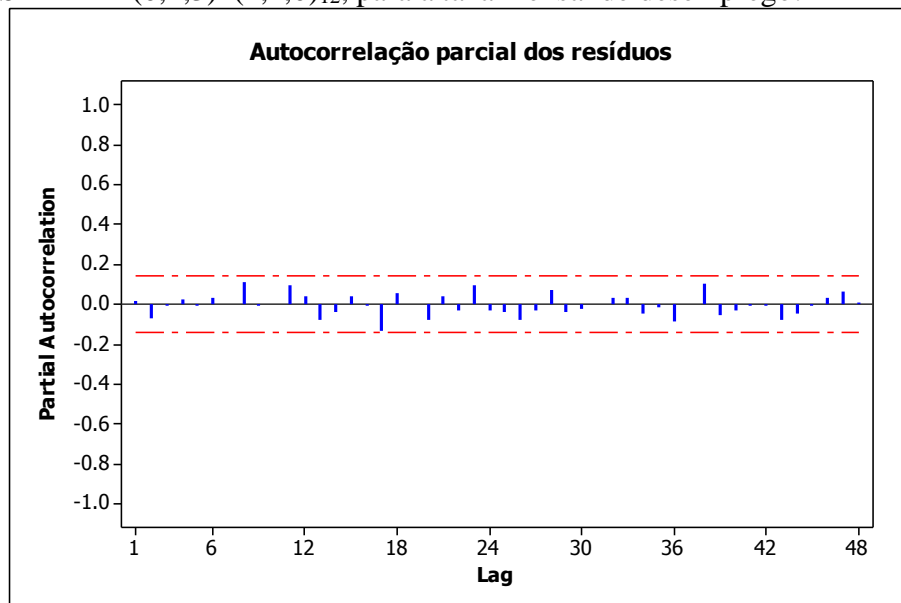


Figura 23: Gráfico da série original de 2008 a outubro de 2010 e previsão para o ano de 2010 segundo o modelo SARIMA $(0,1,3) \times (2,1,0)_{12}$




Tabela 5: Gráfico da previsão através do modelo SARIMA $(0,1,3) \times (2,1,0)_{12}$ para a taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

Mês	Dados Observados	Previsão	Limite Inferior	Limite Superior
Janeiro	9,7	9,1663	8,5143	9,8164
Fevereiro	9,6	9,3485	8,1800	10,5171
Março	9,8	9,9821	8,2923	11,6720
Abril	9,6	10,4903	8,5158	12,4649
Mai	9,6	10,4030	8,1800	12,6261
Junho	9,5	10,4694	8,0229	12,9158
Julho	8,9	10,0421	7,3910	12,6932
Agosto	8,7	9,8631	7,0221	12,7042
Setembro	8,5	9,5647	6,5457	12,5838
Outubro	8,2	9,6732	6,4860	12,8603
Novembro		9,3373	5,9904	12,6841
Dezembro		8,5482	5,0490	12,0474

Através da Figura 23 é possível observar que a série prevista se assemelha bastante com a série original e, os resíduos estão bem ajustados conforme sugerem as figuras 20, 21 e 22 indicando que o modelo ajustado é adequado para os dados. Além disso, as Figuras 21 e 22 das funções de autocorrelação e autocorrelação parcial se encontram totalmente concentradas dentro dos limites de confiança, corroborando a análise inicial. A hipótese de sazonalidade dos dados é reforçada pela necessidade de incluir uma diferenciação sazonal no ajuste do modelo.

Outra observação a ser realizada, refere-se a Tabela 5 e a Figura 23, onde as previsões mensais estão coerentes com a idéia de que, em geral, as taxas são mais elevadas nos primeiros meses do ano, enquanto decaem no segundo semestre. Além disso, os intervalos de confiança do modelo SARIMA são menos amplos em relação aos modelos de Holt-Winters.

3.4 Modelo de Suavização Exponencial Para a Série Diferenciada

Como forma alternativa de estudo a série original da taxa de desemprego, se propôs estudar a série diferenciada da taxa de desemprego, isto é, tornamos a série estacionária. O primeiro dado refere-se a diferença entre as taxas observadas em janeiro de 1993 em relação a taxa observada em dezembro de 1992 e, o último dado refere-se a diferença entre as taxas de dezembro de 2009 e novembro do mesmo ano, totalizando assim também 204 observações ao longo da série. Foi utilizado o dado de dezembro de

1992, pois eram necessários 205 dados para obtermos as 204 diferenças da taxa de desemprego. Para a série original da taxa de desemprego foram considerados os dados mensais observados entre janeiro de 1993 e dezembro de 2009.

Será realizado aqui estudo semelhante ao da série original, as exceções encontram-se no modelo Holt-Winters multiplicativo, que é aplicável somente a séries com valores estritamente positivos, o qual não é o caso da série diferenciada e, ao SARIMA que aqui perde o sentido da aplicabilidade, pois na série original já foi suavizada a partir da primeira diferença e primeira diferença sazonal. Essa série será suavizada apenas pelos modelos exponencial simples e Holt-Winters aditivo.

Começaremos a análise pelo modelo de suavização exponencial.

Figura 24: Gráfico da função de autocorrelação da diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre.





Figura 25: Gráfico da função de autocorrelação parcial da diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre.



Na Figura 24 encontra-se o gráfico da função de autocorrelação da série a qual apresenta indícios muito grandes de sazonalidade na série, indícios que estavam mascarados pela não estacionariedade da série original. Os lags sazonais 12, 24, 36, 48 estão fora dos limites de confiança apontando a presença da sazonalidade. O gráfico da função de autocorrelação parcial corrobora essa hipótese e também apresenta valores fora dos limites de confiança nos lags sazonais 12, 24 e 36.

Figura 26: Gráfico da previsão através do modelo de suavização exponencial para a diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Figura 27: Análise de resíduos do modelo de suavização exponencial para a diferença de taxa mensal de desemprego, na região metropolitana de Porto Alegre.

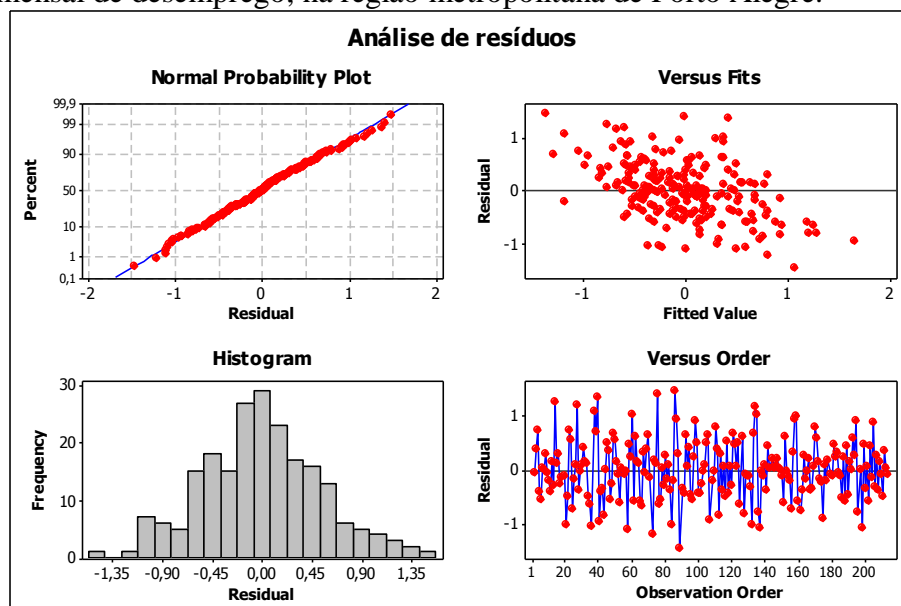


Figura 28: Gráfico da função de autocorrelação dos resíduos da diferença da taxa mensal de desemprego, para o modelo suavização exponencial, na região metropolitana de Porto Alegre.




Figura 29: Gráfico da função de autocorrelação parcial dos resíduos da diferença da taxa mensal de desemprego, para o modelo suavização exponencial, na região metropolitana de Porto Alegre.




Figura 30: Gráfico da previsão utilizando o modelo de suavização exponencial para a diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Tabela 6: Previsão através do modelo de suavização exponencial para a diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

Mês	Dados Observados	Previsão	Limite Inferior	Limite Superior
Janeiro	0,3	-0,5864	-1,6365	0,4637
Fevereiro	-0,1	0,2228	-0,8328	1,2784
Março	0,2	-0,0700	-1,1241	0,9840
Abril	-0,2	0,1740	-0,8782	1,2261
Mai	0	-0,1630	-1,2145	0,8885
Junho	-0,1	-0,0163	-1,0647	1,0320
Julho	-0,6	-0,0916	-1,1359	0,9528
Agosto	-0,2	-0,5492	-1,5945	0,4961
Setembro	-0,2	-0,2363	-1,2807	0,8080
Outubro	-0,3	-0,2038	-1,2437	0,8361
Novembro		-0,2899	-1,3261	0,7462

O ajuste não parece ser muito bom. A figura de resíduos por valores suavizados apresenta uma leve tendência de acordo com o diferente valor suavizado. Uma modelagem de qualidade apresentaria esse gráfico de forma equilibrada, centrada no valor zero para os resíduos e sem tendências. Nesse caso, o valor da estatística MSD foi 0,295.

A previsão para os meses do ano de 2010 sofrem influência dos próprios dados do ano de 2010, que são utilizados para atualizar a série mensalmente. Isso auxilia a estimação a se concentrar próximo aos dados observados, principalmente quando a série

é estacionária como a apresentada. Esse fato pode ser confirmado a partir da análise do gráfico na Figura 30, onde não existe uma tendência definida para os dados.

As figuras 28 e 29 de autocorrelação e autocorrelação parcial dos resíduos apontam muitos dados fora dos intervalos de confiança. Isso ajuda a identificar um mau modelo.

Durante o ano de 2010, a taxa de desemprego vem apresentando várias quedas, isso reflete nas previsões apresentadas. Para o mês de novembro espera-se uma queda 0,2899 ponto percentual na taxa de desemprego.

3.5 Modelo Holt-Winters para a série diferenciada

Nesta seção continuaremos analisando a série da diferença mensal da taxa de desemprego. O modelo utilizado será o Holt-Winters aditivo. A seguir apresentamos os gráficos referentes a esta análise.

Figura 31: Gráfico da previsão através do modelo de suavização Holt-Winters ADITIVO para a diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre, entre 1993 e 2009.




Figura 32: Análise de resíduos do modelo Holt-Winters ADITIVO para a diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre

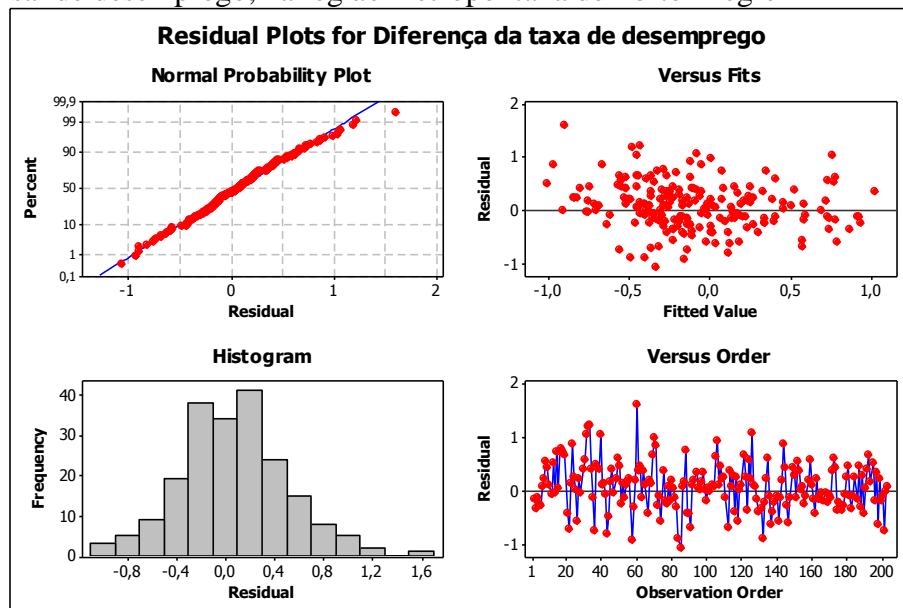


Figura 33: Gráfico da função de autocorrelação dos resíduos da diferença da taxa mensal de desemprego, para o modelo Holt-Winters ADITIVO.




Figura 34: Gráfico da função de autocorrelação parcial dos resíduos da diferença da taxa mensal de desemprego, para o modelo Holt-Winters ADITIVO.




Figura 35: Gráfico da série diferenciada de 2008 a outubro de 2010 e previsão para o ano de 2010 segundo o modelo Holt-Winters ADITIVO.

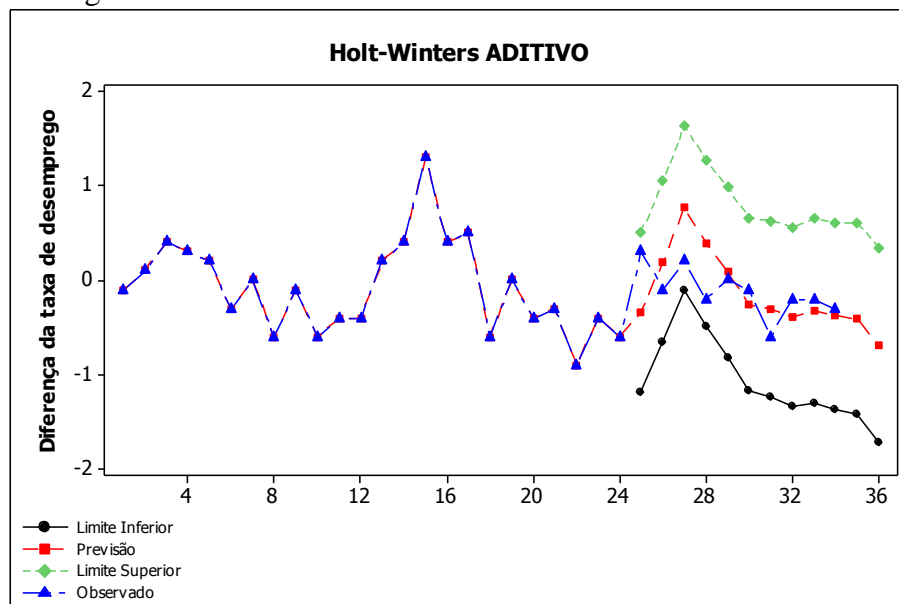


Tabela 7: Previsão através do modelo de suavização Holt-Winters ADITIVO para a diferença da taxa mensal de desemprego, na região metropolitana de Porto Alegre, no ano de 2010.

Mês	Dados Observados	Previsão	Limite Inferior	Limite Superior
Janeiro	0,3	-0,336294	-1,1805	0,50791
Fevereiro	-0,1	0,192628	-0,66337	1,04863
Março	0,2	0,766368	-0,10272	1,63546
Abril	-0,2	0,391979	-0,49143	1,27539
Maio	0	0,083488	-0,81543	0,9824
Junho	-0,1	-0,25324	-1,16878	0,6623
Julho	-0,6	-0,305115	-1,23833	0,6281
Agosto	-0,2	-0,390491	-1,34239	0,56141
Setembro	-0,2	-0,32385	-1,29537	0,64767
Outubro	-0,3	-0,377705	-1,36973	0,61432
Novembro		-0,40823	-1,4216	0,60514
Dezembro		-0,687191	-1,72268	0,3483

A estimação para a diferença da taxa de desemprego parece ser adequada através da suavização Holt-Winters aditiva. Os dados de previsão obtidos são coerentes com as suposições de elevação da taxa de desemprego na primeira metade do ano e com o declínio da mesma na segunda metade. Essa suposição existe devido ao afastamento no início do ano dos contratados temporários para a época de festas no final do ano e, pelo mesmo motivo a taxa de desemprego apresenta decréscimo no segundo semestre, em função das contratações de final de ano. Tanto no comércio como indústria esses movimentos são tradicionais, pois é um período de entrega de produtos finais e matéria-prima. Além disso, os intervalos de confiança se mostram relativamente precisos, creditando assim maior credibilidade ao modelo. Poucos dados estão fora dos intervalos de confiança nas figuras de autocorrelação e autocorrelação parcial dos resíduos.

O modelo foi estimado a partir das constantes $A = 0,1225694$ para o nível, $C = 0,019404$ para a tendência e $D = 0,189050$ para a sazonalidade. Em relação aos estudos da taxa de desemprego a discrepância entre as constantes de suavização é menor, ou seja, aqui a importância de cada um dos termos é mais equilibrada. O indicador de acurácia MSD foi de 0,198, abaixo daquele verificado na suavização exponencial, que foi de 0,295.

Vale citar também a análise de resíduos do modelo que visualmente está apropriado. O gráfico de probabilidade normal, por exemplo, possui valores muito próximos da linha de perfeita normalidade. Porém a figura de autocorrelação parcial dos

resíduos da diferença da taxa mensal de desemprego apresenta alguns dados fora do intervalo de confiança e indicando sazonalidade, pois são os lags 12 e 24.

3.6 Comparação de resultados e previsões

A partir das observações reais obtidas no ano de 2010, se procurará definir o melhor modelo de estimação para cada uma das duas séries estudadas.

Como critério para seleção de modelos, utilizamos soma dos quadrados dos erros de previsão

$$SE = \sum_{h=1}^k \hat{e}_h^2,$$

na qual \hat{e}_h é o erro de previsão para h passos à frente dado por

$$\hat{e}_h = X_{n+h} - \hat{X}_n(h),$$

onde X_{n+h} é o valor real com origem em n e $\hat{X}_n(h)$ é o valor previsto com origem em n e h passos a frente.

Classificamos como melhor modelo aquele que possui menor soma dos quadrados dos erros de previsão.

Figura 36: Dados observados e previstos para a série da taxa de desemprego no ano de 2010.




Tabela 8: Dados de previsão para taxa mensal de desemprego no ano de 2010 e dados observados até outubro de 2010 e estatística SE.

Mês	OBSERVADOS	SUAVIZAÇÃO EXPONENCIAL	HOLT-WINTERS ADITIVO	HOLT-WINTERS MULTIPLICATIVO	SARIMA
Janeiro	9,7	9,1507	9,0077	9,0469	9,1663
Fevereiro	9,6	9,9295	9,1951	9,0323	9,3485
Março	9,8	9,4632	10,0109	9,4475	9,9821
Abril	9,6	9,9392	10,4541	9,5867	10,4903
Maio	9,6	9,4603	10,5513	9,5553	10,4030
Junho	9,5	9,6575	10,3089	9,2417	10,4694
Julho	8,9	9,4352	10,0824	8,9961	10,0421
Agosto	8,7	8,6787	9,7663	8,6460	9,8631
Setembro	8,5	8,7088	9,5502	8,3898	9,5647
Outubro	8,2	8,4137	9,3010	8,0620	9,6732
Novembro		8,1116	9,0359	7,7976	9,3373
Dezembro			8,3574	7,3073	8,5482
SE	-	1,059305	7,826666	0,985409	8,719526

O critério apresentado no início do capítulo, isto é, o modelo mais adequado para a série é aquele que possui menor soma dos quadrados dos erros de previsão, nos apresenta como modelo mais adequado o modelo de suavizamento Holt-Winters multiplicativo, isto para a série da taxa de desemprego na região metropolitana de Porto Alegre. Ainda assim, deve ser analisado que, apesar de ter os dados mais assertivos, o modelo multiplicativo de Holt-Winters multiplicativo possui um intervalo de confiança bastante amplo.

A suavização exponencial é outro modelo que estimou bem os valores da taxa de desemprego, porém ele é o único modelo de previsão que já tem incorporado dados do ano de 2010.

Os outros dois modelos (SARIMA e Holt-Winters aditivo) não apresentaram valores muito próximos do verdadeiro valor observado. Isso influenciou no resultado do critério de seleção de modelo. A estatística SE foi de 8,719526 para o modelo SARIMA e, 7,826666 para o modelo Holt-Winters aditivo.

Para a série analisada o modelo que se mostrou mais adequado foi o Holt-Winters multiplicativo. Isso é confirmado a partir do critério da estatística SE que apresentou valor 0,985409. O outro modelo com menor SE foi a suavização exponencial com estatística igual a 1,059305.

Figura 37: Dados observados e previstos para a série da Diferença da taxa de desemprego no ano de 2010.

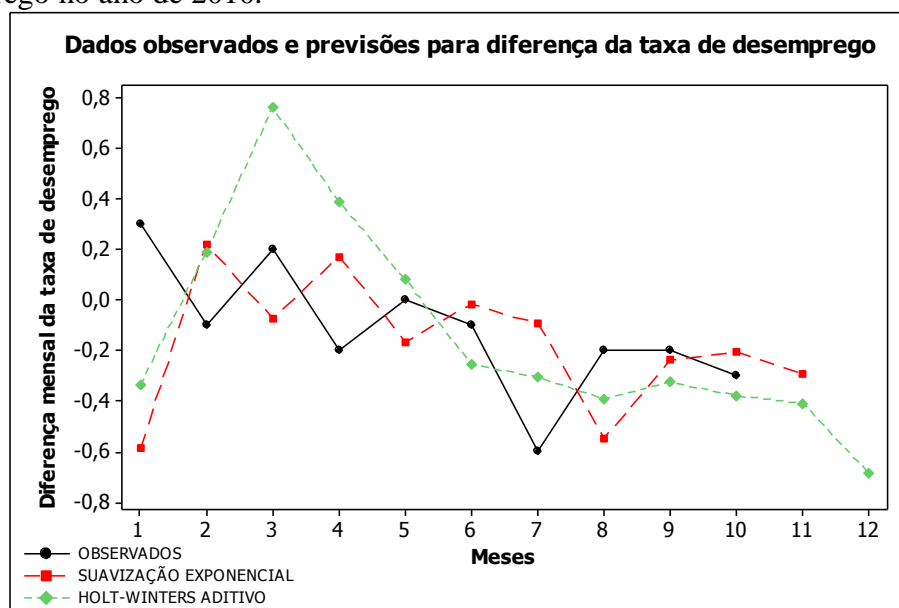


Tabela 9: Dados de previsão para taxa mensal de desemprego no ano de 2010 e dados observados até outubro de 2010.

Mês	OBSERVADOS	SUAVIZAÇÃO EXPONENCIAL	HOLT-WINTERS ADITIVO
Janeiro	0,3	-0,5864	-0,3363
Fevereiro	-0,1	0,2228	0,1926
Março	0,2	-0,0700	0,7664
Abril	-0,2	0,1740	0,3920
Maio	0	-0,1630	0,0835
Junho	-0,1	-0,0163	-0,2532
Julho	-0,6	-0,0916	-0,3051
Agosto	-0,2	-0,5492	-0,3905
Setembro	-0,2	-0,2363	-0,3239
Outubro	-0,3	-0,2038	-0,3777
Novembro		-0,2899	-0,4082
Dezembro			-0,6872
SE		1,527235	1,336787

Os dois modelos apresentam comportamento semelhante para a estimação da diferença da taxa de desemprego, sendo mais assertivo a partir do mês de maio.

Os dois modelos convergem para a expectativa de mais um mês de queda na taxa de desemprego no mês de novembro.

Ao analisar a amplitude dos intervalos de confiança estimados, o modelo Holt-Winters aditivo foi melhor, mesmo em desvantagem em relação ao modelo de

suavização exponencial que utilizou dados observados no ano de 2010 para realizar as previsões. O modelo Holt-Winters aditivo apresentou amplitudes de intervalo de confiança inferiores aos intervalos do modelo de suavização exponencial

Pelo critério da estatística de minimização de erros SE o melhor modelo para a estimação da diferença em relação ao mês imediatamente anterior da taxa de desemprego foi o Holt-Winters aditivo, com uma estatística 1,336787, enquanto o modelo de suavização exponencial apresentou valor 1,527235.

4. Considerações finais

O estudo da taxa de desemprego é muito útil na tomada de decisão de políticas públicas em relação ao mercado de trabalho. Através desses dados podem ser definidos incentivos fiscais, análise de dados referentes à previdência, análises setoriais e de renda.

É sabido da demanda por parte dos administradores, imprensa e estudiosos por previsões para esses indicadores. O presente estudo apresenta uma proposta de modelos para estimar a taxa de desemprego para futuros meses.

No caso da taxa de desemprego o modelo ótimo, dentre os modelos estudados, foi o Holt-Winters multiplicativo. Para a taxa de desemprego diferenciada o melhor modelo foi o Holt-Winters aditivo.

De um modo geral, os modelos estavam bem ajustados. Isso pode ser concluído através dos gráficos de probabilidade normal, gráficos de análise de resíduos, gráficos de autocorrelação e autocorrelação parcial dos resíduos, além dos indicadores de qualidade MAPE, MAD e MSD.

Em relação ao critério SE para escolha do melhor modelo de previsão, o critério se mostrou bastante adequado. Apenas uma análise gráfica nos levaria a também a conclusão de que o modelo Holt-Winters multiplicativo é o melhor para prever a taxa de desemprego. Quanto a série da taxa de desemprego diferenciada, o critério SE foi fator determinante para definição do melhor modelo.

Não foi possível escolher um melhor modelo geral para o estudo de previsão em séries temporais. No caso do presente estudo, isso se deve ao fato de não podermos utilizar os mesmos quatro modelos para as duas séries estudadas. Não foi possível indicar um melhor modelo geral. Essa conclusão se estende às séries em geral, não sendo possível encontrar um modelo melhor para qualquer série.

Referências Bibliográficas

- MORETTIN, Pedro A.; Toloí C. M. C. *Análise de Séries Temporais* – São Paulo: Edgard Blücher, 2004.
- MONTGOMERY, D. C.; JOHNSON, L. A.; GARDINER, J. S. *Forecasting & Time Series analysis* – McGraw-Hill, 2ª edição, 1990.
- LOPES, C. M. C.; ALENCA A. P.; LIPPI F. de Sá B.; YAMAMOTO F. H. O uso de modelos de séries temporais no estudo da produção de álcool no Brasil. *R. bras. Estat.*, Rio de Janeiro, v.70, n.232, p.71-88, jan/jun.2009.
- KALEKAR, P. S. *Time series Forecasting using Holt-Winters Exponential Smoothing*, KanwalRekhi School of Information Tecnology, December 6, 2004.
- GELPER, S.; FRIE, R.; CROUX, C. *Robust Forecasting with Exponential and Holt-Winters Smoothing*. April 30, 2007.
- BOX, G. E. P.; JENKINS, G. M. (1976) *Time series analysis: forecasting and control*. San Francisco: Holden- Day.
- CHATFIELD, Christopher. *The analysis of time series: an introduction*. 5th.ed. Boca Raton: Chapman & Hall/CRC, c1999.
- MORETTIN, Pedro Alberto. *Modelos para previsão de séries temporais*. Rio de Janeiro: Impa, 1981. Volume 2.
- Morettin, Pedro Alberto. *Previsão de séries temporais*. São Paulo: Atual, 1985. 435 p.
- GRANGER, C.W.J. *Forecasting economic time series*. New York: Academic, 1977. xii, 333 p.
- BACO, Samuel Bozzi; LIMA, Renato Silva; PAIVA, Anderson Paulo de. *Comparação de modelos de séries temporais para previsão de demanda de matéria prima na fabricação de anéis de pistão*. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 26., 2006, Fortaleza. *Anais eletrônicos...* Fortaleza: Abepro, 2006. Disponível em: <http://www.abepro.org.br/biblioteca/ENEGEP2006_TR460317_8586.pdf>. Acesso em: 26 nov. 2010.
- FARIAS, Odair; NOGUEIRA NETO, Mário de Souza; NOGUEIRA, Carlos César Sales. *Estudo comparativo da aplicação de modelos clássicos na previsão de demanda no agronegócio*. *Organizações em contexto*, São Paulo, n. 3, jun. 2006. Disponível em:

<<http://mjs.metodista.br/index.php/roc/article/viewFile/299/233>>. Acesso em: 27 nov. 2010.

MUELLER, Alessandro. Uma aplicação de redes neurais artificiais na previsão do mercado acionário. 1996. Dissertação (Mestrado em Engenharia) – Universidade Federal de Santa Catarina, Florianópolis, 2006.

SOUZA, Gueibi Peres; SAMOHYL, Robert Wayne; MEURER Roberto; CORVALÃO, Éder Daniel. Combinação de modelos de séries temporais para previsões do consumo industrial de energia elétrica em Santa Catarina. Disponível em: <http://www.qualimetria.ufsc.br/artigos_arquivos/20051.pdf>