

REVISTA BRASILEIRA DE ENERGIAS RENOVÁVEIS

MODELAGEM DE MÉDIA MENSAL DE VELOCIDADE DO VENTO PARA REGIÃO LITORÂNEA NO NORDESTE BRASILEIRO ATRAVÉS DO MÉTODO ADITIVO HOLT-WINTERS COM VIAS A PREVISÃO DE GERAÇÃO EÓLICA¹

Henrique do Nascimento Camelo², Paulo Sérgio Lucio³, João Bosco Verçosa Leal Junior⁴

¹Aceito para Publicação no 4º Trimestre de 2016.

²Doutorando em Ciências Climáticas na Universidade Federal do Rio Grande do Norte- UFRN, henriquecamelo13@yahoo.com.br.

³Professor Dr. Associado no Departamento de Ciências Atmosféricas e Climáticas na Universidade Federal do Rio Grande do Norte- UFPR, pslucio@ccet.ufrn.br.

⁴Professor Dr. Adjunto na Universidade Estadual do Ceará- UECE, jblealjr@uece.br.

Resumo

No presente trabalho foi realizado um estudo de previsão da média mensal de velocidade do vento para a cidade de Caucaia, litoral do Estado do Ceará no nordeste do Brasil. Para isso foi utilizado o modelo aditivo de Holt-Winters, a partir dos dados de velocidade do vento ao nível de 10 m de altura no período de janeiro de 2004 até dezembro de 2005, coletados em torre meteorológica. A previsão mostrou-se eficiente baseada no fato de que a análise de erro realizada forneceu valores (em geral) reduzidos como, por exemplo, existe um o erro

percentual médio da previsão comparado ao observado de aproximadamente 3,5%. Dessa forma foi possível identificar que os dados previstos conseguem acompanhar o perfil dos dados observados indicando assim viabilidade do modelo para a região de estudo. Esse trabalho poderá ser utilizado como uma ferramenta de previsão de velocidade do vento, visando o estudo e avanço da geração eólio-elétrica em diversas regiões do país, proporcionando aos tomadores de decisão a instalação de novos parques eólicos, visto que haverá possibilidade de conhecer o regime local de intensidade de vento futuro.

Palavras-chaves: Energias Renováveis; Séries Temporais; Suavização exponencial.

Monthly average of modeling wind speed for the coastal region in northeastern Brazil through the Holt-Winters additive method routes the forecast of wind generation

Abstract

In the present work, a study was carried out to predict the monthly average wind speed for the city of Caucaia, Ceará State, in northeastern Brazil. For this, the Holt-Winters additive model was used, based on the wind speed data at the 10 m height level from January 2004 to December 2005, collected in a meteorological tower. The prediction was efficient based on the fact that the error analysis performed gave (in general) reduced values, for example, there

is an average percentage error of the forecast compared to the observed of approximately 3.5%. In this way it was possible to identify that the predicted data can follow the profile of the observed data, thus indicating feasibility of the model for the study region. This work can be used as a wind speed forecasting tool, aiming at the study and advancement of the eolic-electric generation in several regions of the country, providing the decision makers with the installation of new wind farms, since there will be possibility to know the Local regime of future wind strength.

Keyword: Renewable energy; Time Series; Exponential Smoothing.

1. Introdução

As energias renováveis são tema de constantes debates em todo o planeta na atualidade. A alegação por parte da comunidade acadêmica de que é preciso investir, cada vez mais, em fontes renováveis de energia, como uma forma de alcançar o Desenvolvimento Sustentável é necessária para não sofrer mudanças climáticas, que podem ser devastadoras para todos os seres vivos. Vale ressaltar que fontes renováveis como eólica, biomassa, solar e outras, tem sido praticadas ainda de forma tímida, quando comparadas às fontes convencionais, como é o caso das que utilizam combustíveis fósseis.

Muitos países têm-se preocupado com o desenvolvimento de pesquisa em energia renovável. Isto pode ser justificado, devido às mudanças climáticas, que muitos cientistas anunciam como resultado do aumento em emissões antropogênicas de gases como CO₂, NO_x, SO_x, que causam efeitos negativos como o aumento do efeito estufa, chuvas ácidas, e a degradação da camada de ozônio. As energias renováveis podem ser consideradas fontes inesgotáveis, limpas e livres. Os benefícios da utilização destas fontes são principalmente de ordem econômica e ambiental. Então, fazer com que as futuras gerações possam morar em um mundo saudável é um papel fundamental da humanidade, e para isso é preciso investir cada

vez mais em pesquisa de energias limpas e renováveis, como uma forma de se alcançar o Desenvolvimento Sustentável.

O Brasil é um dos países que apresenta grande capacidade de produzir eletricidade a partir de fontes renováveis de energia. Exemplo disso é que em sua matriz energética a principal fonte é proveniente de hidráulica, com aproximadamente 70%, de acordo com o Balanço Energético Brasileiro de 2014 (EPE, 2014). Em termos de potencial eólico, se estima, segundo o Altas do Potencial Eólico Brasileiro, cerca de 143 mil MW de potência eólica (CEPEL, 2010), dos quais 51% está sobre a região Nordeste do país. De todo este potencial, o Estado do Ceará detém aproximadamente 18 mil MW de potência eólica aproveitável e médias anuais da velocidade do vento, a 50 m de altura, da ordem de 8,5 m/s (SEINFRA, 2001), o que tem feito com que o estado receba bastante atenção de empresas do setor eólico. Esta média anual de velocidade do vento é bastante significativa quando comparada com as médias encontradas no Atlas Europeu do Vento, em especial na Alemanha, onde a velocidade média dos ventos é da ordem de 5 a 6 m/s (TROEN e PETERSEN, 1989).

A produção de eletricidade através da Energia Eólica é um fator totalmente dependente da velocidade dos ventos incidentes na região, e esta é uma variável inconstante e de difícil previsão, o que provoca problemas nas estimativas de potência eólica disponível. Com isso, a tentativa de previsão desta variável meteorológica tornou-se um importante objeto de estudo há alguns anos. No setor eólico, uma estratégia bastante atual tem sido a busca por métodos de previsão de velocidade de vento que possam fornecer garantias aos investidores do setor eólico, de modo que essa busca possa alavancar cada vez mais pesquisas no campo de estudo da energia eólica. Na literatura é possível identificar alguns trabalhos que mostram a viabilidade de se fazer previsão de variáveis meteorológicas, como em Dorvlo (2002), Bhaskar (2010) e Díaz (2012).

De acordo com Zhang (2003), a previsão de séries temporais é uma área relevante e essencial, nas quais as previsões de observações passadas (de uma mesma variável) são coletadas e analisadas, para desenvolver um modelo que descreve relações. Muito esforço está

sendo dedicado para o desenvolvimento e melhoria dos modelos de previsão de séries temporais.

Nos últimos anos, a previsão de séries temporais de velocidade média do vento para fins de geração de energia vem sendo muito estudada por diversos pesquisadores pelo mundo afora. Vários métodos têm sido utilizados para poder chegar ao menor erro possível entre dados observados (medição *in loco*) e dados previstos. Nesse sentido é possível destacar os seguintes métodos: Utilização de Redes Neurais Artificiais (RNA); utilização de modelagem numérica de mesoescala, através de programas de modelagem atmosférica, exemplo disso o modelo *Weather Research and Forecasting* (WRF); Modelo Auto-Regressivo Integrado de Média Móvel (ARIMA); e Suavização Exponencial (SE) ou Holt-Winters (HW).

Um modelo de previsões de séries temporais que deve ser destacado, devido a sua importância e utilidade, é o Modelo Autorregressivo Integrado e de Médias Móveis (ARIMA). Este tipo de modelo é muito popular por causa de suas propriedades estatísticas, bem como a conhecida metodologia de Box e Jenkins (BOX e JENKINS, 1978) no processo de construção do modelo. Os modelos ARIMA possuem características flexíveis, permitindo ajustes e adaptações em seus parâmetros, contribuindo para que diferentes tipos de séries temporais sejam representados, assumindo assim, uma estrutura de correlação linear entre os valores das séries temporais (MORETTIN e TOLOI, 2006). Da mesma forma, as técnicas de Inteligência Artificial são muito utilizadas em problemas complexos. Recentemente as Redes Neurais Artificiais (RNA) vêm se destacando na aplicação a problemas de previsão e, assim, têm sido amplamente estudadas para sua utilização em previsões de séries temporais, pois possui a grande vantagem de modelagem não linear.

Cadenas e Rivera (2010) identificaram a viabilidade de utilização da modelagem ARIMA e também RNA para a previsão de séries temporais de velocidade do vento em uma localidade do México. Utilizam ainda estatística de erros para mostrar a melhor configuração dos modelos mencionados. Vale ressaltar que a utilização de modelagem ARIMA é muito útil

quando se trabalha com séries temporais não-estacionárias, ou seja, quando há variações bruscas da série em questão. Kavasseri e Seetharaman (2009) analisaram a velocidade dos ventos de Dakota do Norte nos EUA para examinar a possibilidade de previsão com a modelagem ARIMA no sentido de identificar valores para 24 h e 48 h adiante.

Corrar e Theóphilo (2004) explicam que Holt-Winters (Holt, 1957) e (Winters, 1960) é um método destinado ao tratamento de séries temporais que apresentam tendência (verifica o sentido de deslocamento da série temporal, seja, crescente ou decrescente) e sazonalidade (movimento ondulatório de curta duração, em geral, inferior a um ano associada, na maioria dos casos, a mudanças climáticas). Operando de forma semelhante ao método de Holt, o método de Winters incorpora parâmetros adicionais para o tratamento da sazonalidade da série.

Dantas e Oliveira (2014) afirmaram que os resultados da previsão de séries temporais de velocidade média do vento através do método Holt-Winters indicam que esse método foi capaz de prever com significativa habilidade. A abordagem proposta foi capaz de melhorar a qualidade das previsões de velocidade do vento na estação anemométrica de São João do Cariri-PB. Ficou evidenciado que a medida que a janela de previsão aumenta, por exemplo, 24 horas, a qualidade da previsão decresce. A comparação dos dados observados com os previstos pelo método Holt-Winters foi feita utilizando-se a Média do Erro Absoluto Percentual (MAPE¹), e a Raiz do Erro Quadrático Médio (RMSE²). Para o MAPE foi observado um valor de aproximadamente de 13%, já para o RMSE o valor encontrado foi de 0,90 m/s. Ressalta-se que quanto menor esses valores melhor será o modelo de previsão no sentido de representar os dados observados.

Esse trabalho tem como objetivo utilizar o método de suavização exponencial de Holt-Winters, para realizar previsão de séries temporais de médias mensais de velocidade do vento na região litorânea do Estado do Ceará – Brasil. Dessa forma, pretende-se identificar se o

¹ Do inglês *Mean Absolute Percentage Error*.

² Do inglês *Root Mean Squared Error*.

modelo proposto oferece menor erro em relação aos dados reais de velocidade do vento, identificando assim, uma possível ferramenta que poderá ser amplamente utilizada para o estudo e avanço da potência eólica no Estado do Ceará e também em outras regiões do país.

2. Materiais e métodos

A série temporal utilizada neste trabalho são medições horárias da velocidade do vento que foram coletadas a uma altura de 10 m, durante todos os dias dos anos de 2004 e 2005 na cidade de Caucaia, no Estado do Ceará – Brasil, conforme ilustrado na Figura 1. Os dados foram cedidos pela Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCME). Para os dois anos foram registadas 17448 medições.



Figura 1. Mapa do Estado do Ceará, destacando a cidade de Caucaia. Fonte:

<https://pt.wikipedia.org/wiki/Caucaia>. (Consultado em 12/05/2015).

Para a previsão da série temporal da média mensal de velocidade do vento, será utilizado o método de suavização exponencial de Holt-Winters aditivo. Esse método

busca propor previsões baseadas no cálculo de médias móveis exponencialmente ponderadas, sendo assim os dados mais recentes recebem um peso maior, ou seja, são mais importantes para a previsão da variável em questão.

De acordo com Makridakis (1998), no ano de 1957 Holt expandiu o modelo de suavização exponencial simples para lidar com dados que apresentavam tendência linear, e assim realizar previsões que fossem mais precisas que as realizadas com suavização exponencial simples, por ajustá-las a esta condição. Em 1960, Winters estendeu o modelo de Holt, incluindo uma nova equação que possibilitasse ser acrescentada nas previsões o comportamento da componente sazonal dos dados que se estivessem trabalhando, gerando assim o Método de Holt-Winters (MAKRIDAKIS, 1998).

Segundo Makridakis (1998), e também Morettin e Toloi (2006), as equações referentes ao método de suavização exponencial com sazonalidade e tendência linear, ou seja, com a componente sazonal sendo tratada de forma aditiva, são as seguintes:

$$a_t = \alpha(Y_t - s_{t-p}) + (1 - \alpha)(a_{t-1} + b_{t-1}) \quad (1)$$

$$b_t = \beta(a_t - a_{t-1}) + (1 - \beta) + b_{t-1} \quad (2)$$

$$s_t = \gamma(Y_t - a_t) + (1 - \gamma) + s_{t-p} \quad (3)$$

$$Y_{t+n} = a_t + b_t \cdot h + s_{t-p+n} \quad (4)$$

Em que:

a_t representa o nível da série, cuja unidade nesse trabalho é m/s – está relacionada de que forma a série temporal prevista evolui com o tempo, sendo que é identificado se a mesma variar lentamente no tempo ou, excepcionalmente, sofrer variações bruscas. Por exemplo, a

série prevista pode ter movimento de crescimento lenta de forma linear;

b_t representa a tendência, cuja unidade nesse trabalho é m/s^2 – está relacionada com o fato da série temporal prevista possuir movimentos de crescimento ou decrescimento que pode ocorrer em intervalos de tempos distintos. Por exemplo, uma série temporal prevista hipotética possui uma tendência de crescimento linear no seu primeiro ano, já no segundo ano a mesma foi identificada com um decrescimento linear;

s_t representa a componente sazonal, cuja unidade nesse trabalho é o m/s – que está relacionada com o fato da série temporal prevista existir padrões cílicos de variação que se repetem em intervalos relativamente constantes de tempo. Por exemplo, uma série temporal prevista hipotética durante um ano apresenta comportamento ondulatório a cada três meses;

Y_{t+n} representa a previsão para o período n adiante, e possui unidade de m/s ;

Y_t representa o valor observado que possui unidade de m/s ;

p representa o período sazonal;

$n = 1, 2, 3, \dots, h$ (horizonte da previsão);

Em que α, β, γ – parâmetros exponenciais alisadores, do nível, da tendência e da sazonalidade, respectivamente. Vale ressaltar que os coeficientes (α, β , e γ) são encontrados de tal forma que ofereçam uma série temporal da previsão que minimize o erro quando comparado a série temporal observada (real), e variam entre 0 e 1.

Ainda sobre a produção dos valores de nível, tendência e sazonalidade, Makridakis et al. (1998) menciona que, para determinar os valores da sazonalidade é necessário pelo menos um período sazonal de dados históricos completo. Enquanto isso, os valores iniciais do nível e da tendência são iniciados no período sazonal p . O nível, por exemplo, pode ser calculado com a média da primeira época sazonal, conforme a Equação (5), apresentada a seguir:

$$a_p = \frac{1}{p} (Y_1 + Y_2 + Y_3 + \dots + Y_p) \quad (5)$$

Observe que o nível é uma média móvel de ordem p , com o intuito de retirar o efeito da sazonalidade. Para iniciar o elemento da tendência, Makridakis et al. (1998) usa duas épocas sazonais, e expõe a Equação (6):

$$b_p = \frac{1}{p} \left(\frac{Y_{p+1} - Y_1}{p} + \frac{Y_{p+2} - Y_2}{p} + \frac{Y_{p+3} - Y_3}{p} + \dots + \frac{Y_{p+p} - Y_p}{p} \right) \quad (6)$$

Para encontrar o valor da sazonalidade para os primeiros períodos da época sazonal esse índice são divididos os primeiros valores observados pelo valor inicializado do elemento nível, conforme a Equação (7):

$$s_1 = \frac{Y_1}{a_p}, s_2 = \frac{Y_2}{a_p}, \dots, s_p = \frac{Y_p}{a_p}. \quad (7)$$

Uma preocupação na previsão de séries temporais é determinar quão bem um modelo se adaptou à série histórica. Neste contexto, a acurácia é tida como um dos principais critérios para a seleção de um modelo de previsão. A acurácia se refere ao quão bem um modelo de previsão é capaz de reproduzir os dados de uma série temporal já conhecidos. Para que seja feita uma comparação entre as séries temporais observada e prevista, com a finalidade de identificar o grau de proximidade entre valores de ambas, será realizada uma análise estatística dos erros (ou seja, comparação direta entre as séries temporais observada e prevista). Através desta análise é possível identificar se existe semelhança ou não, entre dados observados e previstos.

O Erro Médio Absoluto, mede o valor médio de erro entre as séries real e prevista.

Nessa análise essa variável será representada por MAE³, cuja representação matemática é dada por,

$$MAE = \frac{1}{o} \sum_{i=1}^o |v_{\text{prevista}} - v_{\text{observada}}|, \quad (8)$$

em que v_p representa valor individual da série prevista e v_r representa valor individual da série real (ou observada), e o é a ordem das séries. O MAE possui a unidade de medida neste estudo de metros por segundo, ou m/s.

A Raiz do Erro Quadrático Médio (RMSE⁴) representa as diferenças individuais quadráticas entre as séries temporais reais e previstas, que pode ser definido matematicamente por,

$$RMSE = \sqrt{\frac{1}{o} \sum_{i=1}^o (v_{\text{prevista}} - v_{\text{observada}})^2} \quad (9)$$

Da mesma forma o RMSE na Eq. (9) possui unidade de m/s. É importante ressaltar que o RMSE pode ainda ser interpretado da seguinte maneira: se houver grandes valores desta variável, os mesmos representam grandes erros nas variáveis previstas, e valores próximos de zero indicam uma previsão quase perfeita. Maiores detalhes sobre RMSE podem ser obtidos em (COCHRAN, 1977).

Outra forma de medida de erro é a Média do Erro Absoluto Percentual (MAPE⁵). A grande vantagem de utilizar essa expressão está na sua representação em termos percentuais (%) que fornece um rápido entendimento. Já uma desvantagem que deve ser considerada está no sentido de que se, por acaso, o valor real for muito pequeno, qualquer discrepância faz o MAPE “explodir”. A expressão utilizada com essa variável é representada por,

³ Do inglês *Mean Absolute Error*

⁴ Essa abreviatura do inglês *Root Mean Squared Error*.

⁵ Do inglês *Mean Absolute Percentage Error*.

$$MAPE = \frac{1}{o} \sum_{i=1}^o \left| \frac{v_{\text{previsão}} - v_{\text{observado}}}{v_{\text{observado}}} \right| \times 100 \quad (10)$$

Maiores detalhes sobre estatística de erros, em especial às Equações 8, 9, e 10 que serão usadas nesse trabalho, podem ser obtidos em Montgomery *et al.* (2008).

Todos os cálculos realizados nesse estudo pelas equações mostradas, e além da parte gráfica, serão produzidos pelo *software* livre *R* (R-PROJECT, 2014). O *R* fornece uma ampla variedade estatística (modelagem linear e não-linear, testes estatísticos clássicos, análise de séries temporais, testes paramétricos e não-paramétricos, suavização, etc.) e técnicas gráficas, e é altamente extensível. Um dos pontos fortes do *R* é a facilidade com que pode ser produzida a edição, com qualidade, de gráficos, incluindo símbolos e fórmulas matemáticas, quando necessário. Grandes cuidados foram tomados na elaboração dos padrões durante a escolha do projeto gráfico, mas o usuário mantém o controle total. O *R* está disponível como *software* livre, nos termos da licença GNU, na forma de código aberto. Pode ser compilado e executado em um grande número de plataformas UNIX e sistemas semelhantes (incluindo FreeBSD e Linux), Windows e MacOS.

3. Resultados e discussão

Com o auxílio do *software* *R* foi possível realizar a previsão da média mensal da velocidade do vento para a cidade de Caucaia, litoral do Estado do Ceará no nordeste brasileiro, através do modelo aditivo de Holt-Winters. Os parâmetros necessários para a previsão foram encontrados com os seguintes valores: α (nível) de aproximadamente 0,034, β (tendência) de aproximadamente 1, e γ (sazonalidade) de aproximadamente 0,1. Na Tabela 1 estão os coeficientes para estimativa da previsão.

Tabela 1: Coeficientes do modelo Holt-Winters a partir dos dados observados.

Coeficientes	Valores estimados	Coeficientes	Valores estimados
--------------	-------------------	--------------	-------------------

a	3,68737708	s_6	-0,73607088
b	0,03484410	s_7	-0,19730082
s_1	-0,06755106	s_8	0,41806254
s_2	-0,10455566	s_9	1,00476550
s_3	-0,79213904	s_{10}	0,98211053
s_4	-0,72832407	s_{11}	0,74068420
s_5	-0,82006337	s_{12}	0,34519979

De posse dos dados da Tabela 1 foi possível encontrar os valores das séries temporais ajustada e a prevista ambas pelo modelo Holt-Winters. Na Figura 2, a série temporal dos dados observados está representada (em círculos vazio na cor preta), a série temporal ajustada devido ao modelo Holt-Winters está representada (em círculos sólido na cor vermelha), sendo que o modelo Holt-Winters forneceu uma defasagem de 12 meses. A série temporal prevista está representada (em círculos na cor azul), sendo que a mesma foi realizada para 6 meses adiante (para efeito ilustrativo), ou seja, de janeiro de 2006 até junho de 2006. No período de 2005 é possível identificar que os dados ajustados conseguem acompanhar os dados observados, indicando desta forma a possibilidade do modelo Holt-Winters ter viabilidade para a previsão da média mensal da velocidade do vento na cidade de Caucaia. Da mesma forma, a série temporal prevista acompanha a série temporal observada como, por exemplo, há coincidência no seu valor de mínimo de velocidade do vento comparado ao ano de 2005 para o mês de março no valor de aproximadamente 3,0 m/s.

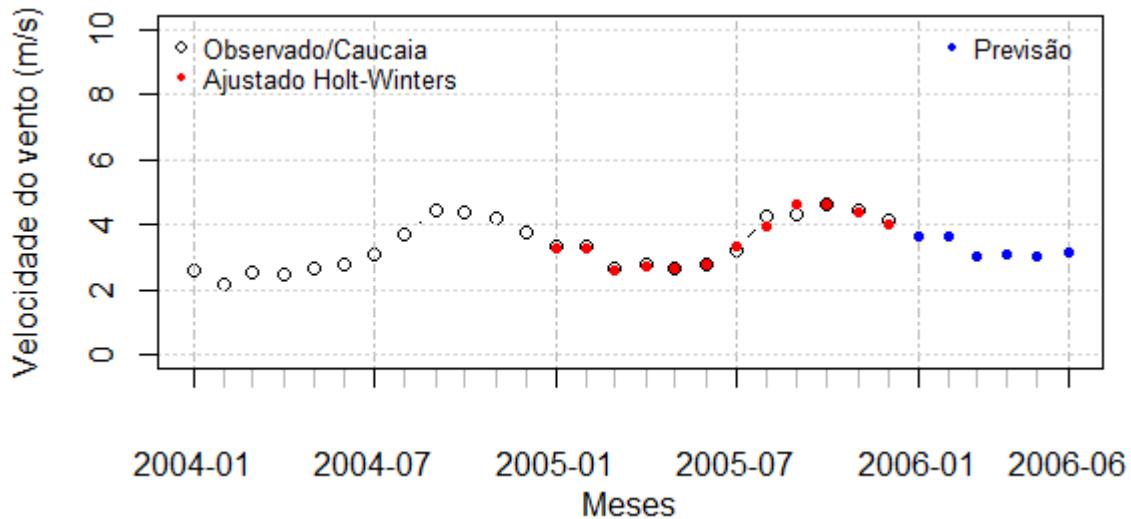


Figura 2: Comparação entre as séries temporais (observados e previstos), para a cidade de Caucaia no período de 2004 até 2005, sendo extrapolado para junho de 2006.

Na Tabela 2, é possível identificar a comparação numérica entre as duas séries temporais em conjunto com os resíduos. Entende-se como resíduo a diferença entre a série temporal observada (real) com a série temporal prevista. Em todos os meses dessa comparação os resíduos estão abaixo de 0,5 m/s, com o menor resíduo encontrado para o mês de outubro, com valor de aproximadamente 0,04 m/s. Já o mês de maior resíduo foi o de setembro, com aproximadamente 0,35 m/s em módulo.

Tabela 2: Comparação numérica para 2005 entre as séries temporais seguido dos resíduos, sendo que todos os dados estão em m/s.

Mês	Observados	Previstos	Resíduos
Janeiro	3,36	3,25	0,11
Fevereiro	3,35	3,24	0,11
Março	2,68	2,58	0,10
Abril	2,75	2,68	0,07

Maio	2,68	2,63	0,06
Junho	2,79	2,75	0,05
Julho	3,19	3,34	-0,15
Agosto	4,27	3,94	0,34
Setembro	4,29	4,64	-0,35
Outubro	4,63	4,59	0,04
Novembro	4,43	4,39	0,05
Dezembro	4,11	4,02	0,09

A análise de erros foi realizada no software *R* com o auxílio do pacote (qualV) que fornece o Erro médio absoluto (MAE), A Raiz do Erro Quadrático Médio (RMSE) e Média do Erro Absoluto Percentual (MAPE). Lembrando que se procura o menor valor possível desses erros para atestar a confiabilidade do modelo de previsão Holt-Winters aditivo. A saída do *R* para as análises de erros forneceu os seguintes valores: MAE = 0,12 m/s; RMSE = 0,16 m/s; e MAPE = 3,48%. De acordo com os valores dessas variáveis já mostrados na literatura, é possível afirmar que o modelo de previsão de Holt-Winters teve um ótimo ajuste para a série temporal real de média mensal da velocidade do vento para os meses de 2005, principalmente quando é verificado um erro percentual médio de aproximadamente 3,5%.

Para que seja possível conhecer a distribuição dos dados de velocidade do vento da cidade de Caucaia, identificando assim o grau de simetria existente, na Figura 3 é representado um gráfico do tipo *boxplot* para médias horárias como estão dispostos originalmente os dados. É possível identificar que em todos os horários os dados são aproximadamente simétricos, ou seja, não há grandes variações. De acordo com Magalhães e Lima (2013) o fato de que a média e mediana em um gráfico *boxplot* sejam semelhantes, leva a uma situação de simetria dos dados trabalhados.

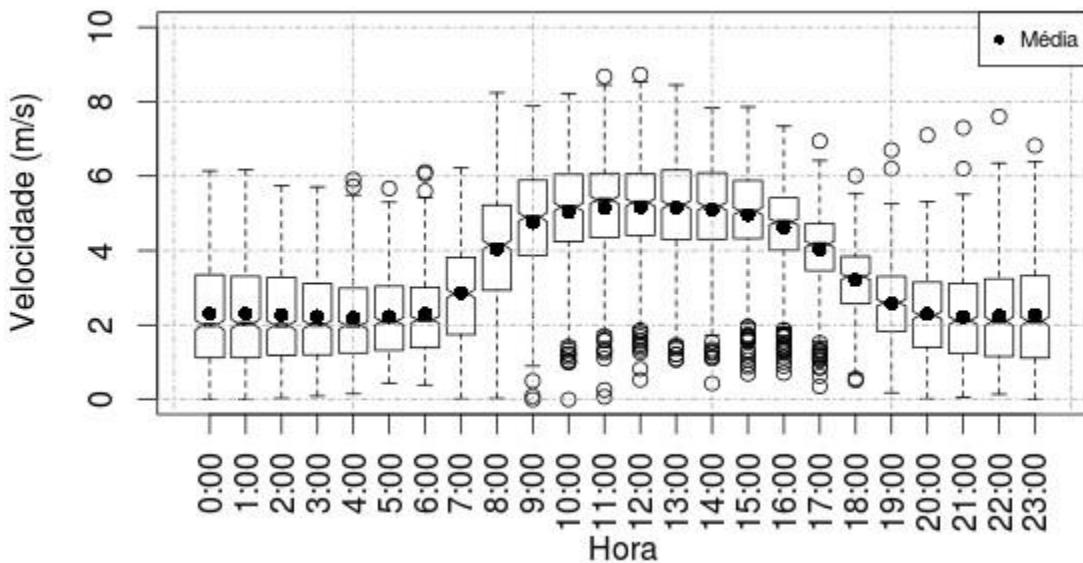


Figura 3: Gráfico tipo *boxplot* da média horária da velocidade do vento para a cidade Caucaia nos anos de 2004 e 2005.

Ainda na Figura 3, vale destacar alguns pontos *outliers* (palavra do inglês que em português significa valores extremos), que representam valores acima ou abaixo do normal da série temporal em estudo. Como foram utilizados 17444 dados de velocidade do vento, os pontos *outliers* são reduzidos quando comparados a esse valor. É possível destacar que na maioria dos horários no gráfico *boxplot* não foi identificado *outliers*, como, por exemplo, entre 00 h e 03 h local. Outro destaque relevante é referente a quase uniformidade da média da velocidade do vento em alguns horários, como, por exemplo, entre 10 h e 16 h, a média se aproxima de 5 m/s, e é precisamente neste intervalo que os ventos possuem uma maior intensidade na região de estudo a 10 m de altura.

4. Conclusões

A utilização do modelo de previsão de séries temporais Holt-Winters para a cidade de Caucaia, litoral do Estado do Ceará no nordeste do Brasil, mostrou-se eficiente. A afirmativa é baseada no fato de que a análise de erro realizada forneceu valores reduzidos quando

comparado com a literatura. Por exemplo, existe um Erro Percentual Médio da previsão comparado ao observado de aproximadamente 3,5%.

Ressalta-se que para o modelo proposto conseguir captar os parâmetros de suavização de nível, tendência, e sazonalidade, o mesmo teve que fornecer uma defasagem de 12 meses. Mas mesmo assim, para o período previsto, ou seja, o ano de 2005, é possível identificar que os dados previstos conseguem acompanhar os dados observados, indicando desta forma a possibilidade do modelo Holt-Winters ter viabilidade na previsão da média mensal da velocidade do vento na cidade de Caucaia.

Para trabalhos futuros poderá ser testado, a partir da disponibilidade de dados de velocidade do vento, nessa região de estudo, uma previsão com uma maior série temporal e, portanto, identificar se com isso haverá uma redução ainda maior na análise de erros realizada. Também poderá ser testado outros modelos para comparação, como, por exemplo, ARIMA, SARIMA, Regressão linear, dentre outros. Esse trabalho poderá ser utilizado como uma ferramenta de previsão de velocidade do vento, visando o estudo e avanço da potência eólica em diversas regiões do país, proporcionando aos tomadores de decisão a instalação de novos parques eólicos, visto que haverá possibilidade de conhecer o regime local de intensidade do vento futuro.

5. Agradecimentos

6. Referências Bibliográficas

BOX, G. P.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. São Francisco: Holden Day, 525 p., 1978.

BHASKAR, M.; JAIN, A.; SRINATH, N. V. Wind speed forecasting: present status. In: PROCEEDING OF THE 2010 INTERNATIONAL CONFERENCE ON POWER SYSTEM

TECHNOLOGY, Hangzhou, China. **Anais**. p. 1-6. 2010.

CADENA, E.; RIVERA, W. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA - ANN model. **Renewable Energy**, v. 35, n. 12, p. 2732-2738, 2010.

CEPEL, Centro de Pesquisas de Energia Elétrica. 2010. Disponível em: <<http://www.cepel.br>>. (Consultado em 12/01/2015).

CORRAR, L. J.; THEÓPHILO, C. R. Pesquisa operacional para decisão em contabilidade e administração: contabilometria. São Paulo, SP: Atlas, 125 p., 2004.

COCHRAN, W. G. The stimation of sample sign. In: *Sampling Techniques*. 3 ed. Nova York: John Willey, 1997, Cap. 4 p. 7290.

DANTAS, T. M.; OLIVEIRA, F. L. C. Previsão de velocidade de vento: Uma abordagem utilizando Bagging Holt Winters com decomposição STL. In: XLVI Simpósio Brasileiro de Pesquisa Operacional, Salvador/Ba. **Anais**. p. 1111-1121. 2014.

DÍAZ, J. A.; SOUTO, A.; RODRÍGUEZ, S., SAAVEDRA, J.; CASARES, J. An ensemble-in-time forecast of solar irradiance. In: International Conference on Renewable Energies and Power Quality, Santiago de Compostela. **Anais**. p. 311-316. 2012.

DORVLO, A. S. S.; JERVASE, J. A.; Al-LAWATI, A. Solar radiation estimation using artificial neural networks. **Applied Energy**, v. 71, n. 4, p. 307–319, 2002.

EPE, Empresa de Pesquisa Energética. 2014. Disponível em: <<http://www.epe.gov.br>>. (Consultado em 12/05/2015).

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages,

ONR Research Memorandum, Carnegie Institute 52, 1957.

KAVESSERI, R. G.; SEETHARAMAN, K. Day-ahead wind speed forecasting using f-ARIMA models. **Renewable Energy**, v. 34, n. 5, p. 1388–1393. 2009.

MAGALHÃES, M. N.; LIMA, A. C. P. Noções de Probabilidade e Estatística. 7^a.ed., São Paulo, SP: Edusp, 392 p., 2013.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. Forecasting: methods and applications. 3 Ed. New York, USA: Wiley, 656 p., 1998.

MORETTIN, P. A.; TOLOI, C. M. C. Análise de Séries Temporais. 2. ed. São Paulo: Edgard Blücher, 350 p., 2006.

MONTGOMERY, D. C. Introduction to Time Series Analysis and Forecasting. 6 ed. New York: Wiley-Interscience, 650 p., 2008.

R-PROJECT. (2014). The R Project for Statistical Computing. Disponível em: <<http://www.r-project.org/>>. Acesso em: junho de 2015.

TRORØEN, I.; PETERSEN, E.L. (1989). European Wind Atlas. Risø National Laboratory, Roskilde, Denmark.

SEINFRA Secretaria de Infraestrutura do Estado do Ceará. 2001. Disponível em: <<http://www.seinfra.ce.gov.br/>>. (Consultado em 12/01/2015).

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. **Management Science**, v. 6, n. 3, p. 324–342. 1960.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing, Amsterdam**, v. 50, n.1, p. 159-175. 2003.