

Previsão de Velocidade Média do Vento através da utilização de modelagem Auto-Regressiva de Médias Móveis (*ARMA*) em Região Serrana no Estado do Ceará – Brasil¹

Henrique do Nascimento Camelo², Wesley Ferreira Teixeira³, Paulo Sérgio Lucio⁴, João Bosco Verçosa Leal Junior⁵

¹Aceito para Publicação no 3º Trimestre de 2015

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

³Acadêmico em Física no Instituto Federal de Educação, Ciência e Tecnologia do Ceará- IFCE, wesleyferreira.t@gmail.com

⁴Professor Associado do Departamento de Ciências Atmosféricas e Climáticas da Universidade Federal do Rio Grande do Norte- UFRN, pslucio@ccet.ufrn.br

⁵Professor Adjunto da Universidade Estadual do Ceará- UECE, jblealjr@gmail.com

Resumo

Nesse trabalho é realizado uma previsão de velocidade média do vento para a cidade de Ubajara região serrana do Estado do Ceará – Brasil, através de modelagem Auto-Regressiva de Médias Móveis – *ARMA*. A busca por métodos de previsão de velocidade do vento poderá garantir ainda mais investimentos em geração eólica tendo em vista que isso poderar ser um fator adicional na implantação de novos parques eólicos em diversas regiões do país. Nos últimos anos o Estado do Ceará é uma das regiões do território brasileiro que mais crescem em potencia eólica instalada, exemplo disso é que em 1999 possuía um valor de 5 MW, já no ano de 2014 possui um valor de 1,2 GW. A eficácia da previsão é afirmada mediante a análise de erros realizada comparando-se as séries real e prevista. A média do erro absoluto foi de aproximadamente 0,10 m/s, o erro quadrático médio foi de 0,37 m/s, e a média do erro absoluto percentual foi de 4,82 %.

Palavras-chaves: Geração Eólica, Previsão, ARMA, Estado do Ceará.

Abstract

This work is carried out one average wind speed forecast for the city of Ubajara mountain region of Ceará - Brazil, through Auto-Regressive modeling Moving Averages - ARMA. The search for wind speed forecasting methods can ensure further investments in wind generation in order that poderar be an additional factor in the implementation of new wind farms in various regions of the country. In recent years the State of Ceará is one of the regions of Brazil's fastest growing installed wind power, example is that in 1999 possessed a 5 MW value by the year 2014 has a value of 1.2 GW. The effectiveness of the prediction is affirmed by an analysis of errors made by comparing the actual and predicted series. The average absolute error was approximately 0.10 m/s, the mean square error was 0.37 m/s, and the average absolute percent error was 4.82%.

Keyword: Wind speed, forecast, ARMA, Ceará – Brasil.

Introdução

Atualmente, um dos grandes problemas no mundo tem sido a questão energética. O desafio energético mundial é conseguir satisfazer a crescente demanda de energia, proporcionar o uso racional das fontes energéticas atuais e a busca por novas formas de geração de eletricidade que produzam baixa ou nenhuma emissão de gases geradores do efeito estufa. Assim, as fontes de energias renováveis como a energia solar e principalmente a energia eólica, são apresentadas como alternativas à substituição das fontes convencionais de produção de eletricidade. O caráter renovável atribuído a estas fontes de energia se deve ao argumento de que estes recursos estão presentes na natureza de forma abundante, o que caracteriza uma fonte praticamente inesgotável.

O Brasil é um dos países que apresenta grande capacidade de produzir eletricidade a partir da força dos ventos, potencial eólico, onde se estima, segundo o Atlas do Potencial Eólico Brasileiro, cerca de 143 mil MW de potência eólica (CEPEL, 2010), do qual 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 encontrada 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, 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 potencia eólica disponível. Com isso, a previsão desta variável meteorológica tornou-se um importante objeto de estudo há alguns anos. No setor eólico, uma estratégia bastante atual tem sido à 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).

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

Em Cadenas e Rivera (2010) identificam a viabilidade de utilização da modelagem *ARIMA* e também *RNAs* para a previsão de velocidade do vento em localidade do México. Utilizam ainda estatística de erros como, por exemplo, o erro médio absoluto (cujo valor encontrado foi de 1.4772 m/s) 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. Em Kavasseri e Seetharaman (2009) analisam 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 24h e 48h adiante.

Esse trabalho tem como objetivo é utilizar modelagem Auto-Regressiva de Médias Móveis – *ARMA*, para realizar previsão de velocidade média de vento na região serrana de Ubajara, cidade do Estado do Ceará – Brasil. Dessa forma, pretende-se identificar se o 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.

Materiais e Métodos

A série temporal utilizada neste trabalho são medições horárias da velocidade do vento coletadas a uma altura de 10 m em relação ao nível do solo durante todos os dias do ano de 2005 na cidade de Ubajara, no Estado do Ceará – Brasil, conforme ilustrado na Fig. 1. Os dados foram cedidos pela Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME). Para o ano de 2005, na cidade de Ubajara foram registradas 8724 medições, as quais foram agrupadas em médias horárias com um total de 24 períodos.



Figura 1. Mapa do Estado do Ceará. Fonte: <http://www.portalubajara.com.br/>.

Para que seja possível fazer a previsão com os dados de velocidade de vento citados será utilizado o modelo matemático Auto-Regressiva de Médias Móveis – *ARMA*. Vale ressaltar que esse tipo de modelagem é muito utilizado em economia de mercado e produção como é possível observar em (OLIVEIRA, 2010; WERNER, 2003; JACOBS, 2011).

Uma série temporal pode ser conceituada simplesmente como qualquer conjunto de observações ordenadas no tempo (MORETTIN e TOLOI, 2006). Pode-se expressar uma série temporal por:

$$V_t = \{t \in R \vee t = 1,2,3,\dots,N\}, \quad (1)$$

onde t é o índice temporal da série e N é a quantidade de observações. Na Fig. (2) temos um exemplo de série temporal, onde estão dispostas as médias mensais da velocidade do vento para o ano de 2005 na cidade de Camocim/CE, medidos a 60 m de altura em relação ao nível do solo.




Figura 2. Exemplo de série temporal – velocidade média mensal do vento na cidade de Camocim no Estado do Ceará. Fonte: (SEINFRA, 2013).

Um conjunto de observações pode se propagar de diversas formas, pode se desenvolver aleatoriamente, no tempo, em torno de uma média constante, refletindo alguma forma de equilíbrio estável, estas séries são ditas Séries Temporais Estacionárias. Existem ainda as séries temporais Não Estacionárias, que apresentam fatores característicos como tendências lineares positivas ou negativas e sazonalidades. Estes conceitos podem ser mais bem explorados em Morettin e Tolo, 1981.

De um modo geral, uma série temporal nada mais é do que uma descrição do passado, e um procedimento lógico para realizar previsões é fazer uso desses dados históricos. Se os dados passados são indicativos do que se esperar no futuro, pode-se então postular um modelo matemático que seja representativo do processo. O modelo poderá então ser usado para gerar previsões.

Neste trabalho faremos uso da modelagem *ARMA* um método comumente encontrado na literatura e que já apresenta grande aplicabilidade em áreas como economia de mercado e produção. Uma contrapartida a esse método é que ele só pode ser aplicado em séries temporais estacionárias. Para verificar o padrão estacionário da série utilizada neste trabalho, utilizou-se o cálculo do Coeficiente de Correlação de Postos de Spearman (SIEGEL, 1975), que é escrito como:

$$\rho = 1 - \frac{6T}{n^3 - n} \quad (2)$$

$$T = \sum_{i=1}^n d_i^2 \quad (3)$$

onde ρ (rho) é um número adimensional que varia entre -1 e 1, n é o número de pares (x_i, y_i) e $d_i = (\text{posto de } x_i \text{ dentre os valores de } x) - (\text{postos de } y_i \text{ dentre os valores de } y)$. A série é dita estacionária quando $\rho < 0$, e $\rho > 0$ para a série é dita não estacionária.

Agora, consideremos V_{t+1} a previsão da série temporal V_t da Eq. (1), para o tempo $(t + 1)$, onde V , neste trabalho, será a velocidade do vento em um instante de tempo t , temos então para o modelo *ARMA*:

Ainda sobre séries temporais em Souza e Camargo (2004) mostram quatro objetivos principais para a análise de séries temporais: descrição, explicação, previsão e controle. No entanto, para que se atinjam esses objetivos, é preciso considerar alguns pressupostos existentes para a análise de séries temporais, como a autocorrelação dos dados.

Em relação à autocorrelação, Maddala (2003) explica que, há situações em que os termos de erro a_t do modelo de regressão podem ser correlacionados, nesse caso, a_t em um período de tempo t , é correlacionado com os termos de erro a_{t+1}, a_{t+2}, \dots e a_{t-1}, a_{t-2} , e assim por diante, violando, dessa forma um das premissas necessárias para a escolha do melhor estimador não-viesado, realizada pelo Método dos Mínimos Quadrados Ordinários (MQO).

Uma das técnicas amplamente citadas para o tratamento dos dados autocorrelacionados são os ajustes realizados pela família de modelos *ARMA*, desenvolvidos por Box e Jenkins (1978), cujo principal objetivo é remover a autocorrelação dos dados.

A família de modelos *ARMA* é composta, basicamente, por modelos auto-regressivos *AR(p)*, modelos de média móvel *MA(q)*, modelos auto-regressivos de média móvel *ARMA(p, q)* e modelos auto-regressivos integrados de média móvel *ARIMA(p, d, q)*. Os modelos *AR(p)* podem ser definidos de forma geral pela Eq. 4:

$$V_t = \varphi_1 V_{t-1} + \varphi_2 V_{t-2} + \dots + \varphi_p V_{t-p} + a_t, \quad (4)$$

onde a_t é um termo de erro ruído branco e p corresponde ao número de termos autorregressivos. Nos modelos $AR(1)$, o valor de V no período t depende do seu valor no período $t-1$ e um termo de erro aleatório, sendo os valores de V expressos como desvios da sua média, ou seja, o valor previsto para X_t é simplesmente uma proporção (Φ_1) do valor de X_{t-1} (Gujarati, 2006). Outro modelo pertencente à família $ARMA$ é o $MA(q)$ que pode ser expresso conforme a Eq. 5:

$$V_t = \mu + \beta_0 a_t + \beta_1 a_{t-1} + \beta_2 a_{t-2} + \dots + \beta_q a_{t-q}, \quad (5)$$

onde μ é uma constante e q é o número médias móveis existentes. Gujarati (2006) destaca que nos modelos $MA(q)$ o valor de X no período t é uma constante (μ) mais uma média móvel dos termos de erro presentes (β_0) e passados (β_q). O processo de $MA(q)$ é simplesmente uma combinação linear de termos de erro de um ruído branco (a_t). Um modelo ainda pode apresentar características de um processo $AR(p)$ e de um processo $MA(q)$. Os Modelos $ARMA(p, q)$ podem ser representados da seguinte forma:

$$V_t = \theta + \varphi_1 V_{t-1} + \beta_0 a_t + \beta_1 a_{t-1} + \varphi_2 V_{t-2} + \beta_2 a_{t-2} + \dots + \varphi_p V_{t-p} + \beta_q a_{t-q}, \quad (6)$$

onde θ é um termo constante. É interessante notar que os modelos $AR(p)$, $MA(q)$ e $ARMA(p, q)$ pressupõe que a série analisada seja estacionária (média e variância constantes ao longo do tempo). No entanto nem sempre essa premissa se verifica empiricamente. Caso a série seja não estacionária, uma alternativa é a utilização do modelo $ARIMA(p, d, q)$. Onde d corresponde ao número de diferenciações necessárias para que a série se torne estacionária. Maiores detalhes ainda sobre o modelo $ARIMA$ podem ser encontrados em (WHEELWRIGHT e MAKRIDAKIS, 1985).

Para que seja feita uma comparação entre as séries temporais reais e prevista, com a finalidade de identificarmos o grau de proximidade entre valores de ambas, será realizada uma análise estatística de erros. Através desta análise é possível observarmos se existe semelhança ou não, entre dados reais e previstos.

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

Nessa nossa análise representaremos essa variável por EB , cuja a representação matemática é dada por,

$$EB = \frac{1}{n} \sum_{i=1}^n |v_p - v_r|, \quad (7)$$

onde v_p representa valor individual da série prevista e v_r representa valor individual da série real. O EB possui a unidade de medida em nosso estudo de (metros por segundo, simbolizado por m/s).

O Erro Quadrático Médio (simbolizado por $RMSE$, sendo que essa abreviatura é do inglês *Root Mean Squared Error*) representa as diferenças individuais quadráticas entre as séries temporais reais e previstas, que pode ser definido matematicamente por,

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (v_p - v_r)^2} \quad (8)$$

Da mesma forma o $RMSE$ na Eq. (8) possui unidade de m/s . É importante ressaltar que o $RMSE$ pode ainda ser interpretado da seguinte maneira: Se caso temos 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 o Erro Quadrático Médio podem ser obtidos em (PEDRO, H. T.C., 2012; CAMELO, H.N., 2007).

Outra forma de medida de erro é a Média do Erro Absoluto Percentual (simbolizado por $MAPE$, do inglês *Mean Absolute Percentage Error*). A grande vantagem de utilizarmos 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,

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{v_p - v_r}{v_r} \right| \times 100 \quad (9)$$

Maiores detalhes sobre estatística de erros, em especial as eqs. (7), (8), e (9) que serão usadas nesse trabalho pode ser obtido em (MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. 2008).

Resultados e Discussão

Para se identificar a viabilidade da modelagem $ARMA$ em nosso estudo o primeiro passo foi identificar se a série temporal de velocidade média do vento horária para Ubajara trata-se de uma Série Estacionária. O cálculo do Coeficiente de Correlação de Postos de Spearman da Eq. (2) revelou um valor de $(-0,43)$, e como dissemos antes valores negativos

para esse coeficiente mostram que a série temporal em questão é **Estacionária**.

Com a utilização do Método dos Mínimos Quadrados Ordinários (MQO), foi verificado que a melhor tentativa de previsão é fornecida com um modelo *ARMA* de ordem 2. Os coeficientes encontrados para esse modelo foram: $\beta_0 = 0.78$, $\beta_1 = 1.52$, e $\beta_2 = -0.66$.

Na Tab. (1) abaixo, temos a comparação das séries temporais real e prevista através do modelo *ARMA de ordem AR(2)*. E também o calculo do erro absoluto, ver Eq. (7), entre as séries, ou seja, real menos previsto para que seja possível identificamos o grau numérico de semelhança.

Tabela 1. Modelagem *ARMA* de ordem *AR(2)* comparando as duas séries, ou seja, real e prevista e ainda o erro absoluto *EB*.

Tempo (h)	Real (m/s)	Prevista (m/s)	Erro (m/s)
0:00	4,70		
1:00	4,85		
2:00	5,02	5,04	0,02
3:00	5,17	5,20	0,03
4:00	5,40	5,31	0,09
5:00	5,59	5,57	0,02
6:00	5,74	5,69	0,05
7:00	6,07	5,81	0,26
8:00	7,28	6,20	1,08
9:00	7,93	7,82	0,11
10:00	7,72	8,00	0,28
11:00	7,11	7,26	0,15
12:00	6,43	6,47	0,04
13:00	5,87	5,85	0,02
14:00	5,45	5,44	0,01
15:00	5,23	5,17	0,06
16:00	5,16	5,12	0,04
17:00	5,07	5,16	0,09
18:00	4,32	5,07	0,75
19:00	3,41	3,98	0,57
20:00	3,86	3,12	0,74
21:00	4,26	4,39	0,13
22:00	4,42	4,70	0,28
23:00	4,52	4,67	0,15

Analisando a Tab. (1) é possível identificar que na maioria dos horários a diferença entre as séries temporais real e prevista é abaixo de 1 m/s. Em destaque temos os horários de 2:00h e 13:00h, com uma diferença de 0,02 m/s e também no horário de 14:00h uma diferença de 0,01 m/s. A maior diferença entre as duas séries foi verificado no horário de 8:00h com valor de 1,08 m/s. O erro médio absoluto *EB* foi encontrado em um valor de 0.23 m/s.

Analisando o *RMSE* foi possível encontrar o valor de 0,37 m/s, lembrando que caso haja grandes valores desta variável, os mesmos representam grandes erros nas variáveis previstas, mas valores próximos de zero indicam uma previsão quase perfeita. Por fim, nas análises de erros entre as séries real e prevista, temos o erro percentual *MAPE* que foi encontrado no valor de 4,59%, mostrando dessa forma um valor de erro percentual reduzido na comparação entre as duas séries. Baseado nos resultados de *EB*, *RMSE*, e *MAPE* é possível afirmar que o modelo *ARMA* de ordem *AR(2)* mostrou-se eficaz na previsão da série temporal de velocidade de vento média horária para a cidade de Ubajara região serrana do Estado do Ceará.

Na Fig. (3), temos a comparação gráfica das séries real e prevista no modelo *ARMA*. Nessa figura é possível observar que a série temporal prevista possui tendência de acompanhar a série temporal real. Os valores das duas séries são muito próximos de forma que é possível afirmar que a previsão com o *ARMA* de ordem *AR(2)* é satisfatória e portanto poderá se configurar em uma ferramenta matemática bastante útil na previsão de novas séries temporais. Ainda na Fig. (3), como uma forma apenas ilustrativa extrapolamos a previsão para uma hora seguinte, a qual denominamos como o tempo 25. Nesse tempo temos o valor da

previsão da ordem de 4,73 m/s.




Figura 2. Ilustração da velocidade do vento das séries real e prevista no modelo *ARMA* para a cidade de Ubajara-CE para o ano de 2005 médias horárias.

Conclusão e Perspectivas Futuras

A previsão de velocidade média horária do vento para a cidade de Ubajara-CE através do modelo de ordem 2, mostrou-se eficaz quando comparada com os dados reais cedidos pela Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME). Nesse sentido essa modelagem poderá se configurar em uma ferramenta matemática bastante útil na previsão de novas séries temporais inclusive para outras regiões de estudo futuramente. O presente estudo também identificou que a série temporal real da velocidade do vento em Ubajara-CE é Estacionária, ou seja, não há grandes variações em seus valores ao longo do período de medições. Esse é um fator muito importante para se caracterizar uma região como possível geradora de energia elétrica devido ao seu potencial eólico.

A previsão com o modelo *ARMA* mostrou-se satisfatória mediante a análise de erros realizada comparando-se as séries real e prevista. A média do erro absoluto foi de aproximadamente 0,23 m/s, o erro quadrático médio foi de 0,37 m/s, e a média do erro absoluto percentual foi de 4,59 %.

Agradecimentos

Os autores gostariam de agradecer a Fundação Cearense de Meteorologia e Recursos Hídricos – FUNCEME pela doação dos dados de velocidade de vento que proporcionaram o presente estudo.

Referências

BHASKAR, M.; JAIN, A., and SRINATH, N. V. “Wind speed forecasting: present status,” in Proceedings of the 2010 International Conference on Power System Technology, pp. 1–6, Hangzhou, China, October 2010.

BOX, G. P. E; JENKINS, G. M. Time Series Analysis: Forecasting and Control . Edição revista. São Francisco: Holden Day, 1978.

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

CAMELO, H. N. Estudo Numerico do Vento Aracati para Caracterização de seu Potencial Eólico. 2006. 95 f. Dissertação (Mestrado em Ciências Físicas Aplicadas) - Universidade Estadual do Ceará, Fortaleza 2007.

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

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, march 2012.

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

GUJARATI, D. Econometria Básica. Tradução da 4ª edição. Editora Campus. Rio de Janeiro: Elsevier, 2006.

JACOBS, W. ; COSTA, M. . Uma referência para a construção de modelos ARIMA para previsão de demanda com base na metodologia de Box-Jenkins. In: ENEGEP - Encontro Nacional de Engenharia de Produção, 2011, Belo Horizonte. Sessão temática, 2011.

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

MADDALA, G. S. Introdução à econometria . (3a ed.). Rio de Janeiro: Editora LTC, 2003.

MONTGOMERY, D. C., C. L. JENNINGS, and M. KULAHCI, Introduction to Time Series

Analysis and Forecasting. 6 ed. New York: Wiley-Interscience, 2008.

MORETTIN, P.A. ; TOLOI, C.M.C. Modelos para previsão de séries temporais. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, vols. 1 e 2, 1981, 623p.

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

OLIVEIRA, M. O. R. ; MILACH, F. T. ; CORTE, V. F. D. . Aplicação dos Modelos ARMA na Previsão de Vendas. In: Encontro de Marketing, 2010, Florianópolis. IV Encontro de Marketing da ANPAD, 2010.

PEDRO, H.T.C., C.F.M. Assessment of forecasting techniques for solar power production with no exogenous inputs. Solar Energy, v. 86, p. 2017–2028, mai. 2012.

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

SIEGEL, S. Estatística não-paramétrica: para as ciências do comportamento. São Paulo: McGraw-Hill do Brasil, 1975.

SOUZA, R. C. & CAMARGO, M. E. (2004) Análise e previsão de séries temporais : os modelos ARIMA. (2a ed.). Rio de Janeiro.

TROEN, I. PETERSEN, E.L. European Wind Atlas. Rise National Laboratory, Roskilde, Denmark. 1989.

WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. Revista Gestão & Produção, v. 10, p. 47-68, abr. 2003.

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. Forecasting Methods for Management. 4th edition. New York : John Wiley & Sons Inc, 1985.