



Estimação do Impacto do El Niño/La Niña na Intensidade dos Ventos do Nordeste Brasileiro
Estimation of the El Niño/La Niña Impact in the Intensity of Brazilian Northeastern Winds

Carolina Nascimento Nogueira Lima¹; Cristiano Augusto Coelho Fernandes²;
Gutemberg Borges França³ & Gilson Gonçalves de Matos⁴

^{1,2} Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), Departamento de Engenharia Elétrica,
Rua Marquês de São Vicente, 255 - Gávea, 22451-041 - Rio de Janeiro, RJ - Brasil

³ Universidade Federal do Rio de Janeiro (UFRJ), Departamento de Meteorologia, Laboratório de Meteorologia Aplicada (LMA),
Campus Cidade Universitária, 21.941-916 - Rio de Janeiro, RJ - Brasil

⁴ Instituto Brasileiro de Geografia e Estatística (IBGE),
Av. República do Chile, 500 - Centro, 20031-170 - Rio de Janeiro, RJ - Brasil
E-mails: cris@ele.puc-rio.br; gutemberg@lma.ufrj.br; gilson.g.matos@ibge.gov.br

Recebido em: 15/08/2014 Aprovado em: 11/11/2014

DOI: http://dx.doi.org/10.11137/2014_2_232_240

Resumo

A energia eólica é hoje uma das mais promissoras fontes de energia do mundo por ser limpa e abundante. O estudo de fenômenos que estão relacionados com alterações na circulação atmosférica, como o El Niño, são de extrema importância pela possibilidade de afetarem a geração eólica. A fim de explorar o possível efeito de tais fenômenos nos ventos da região Nordeste do Brasil, é realizada uma análise estatística para a quantificação desse efeito através do modelo *Generalized Autoregressive Score* (GAS). Este permite a modelagem de séries temporais para diferentes distribuições de probabilidade. Nesse estudo, o modelo GAS é aplicado às séries de velocidade do vento a partir da distribuição Gama. Os resultados do modelo mostraram que o El Niño possui influência no comportamento do vento, ainda que esta seja pequena em magnitude.

Palavras-chave: Energia Eólica; El Niño/La Niña; modelos GAS

Abstract

Wind energy is now one of the most promising energy sources of the world for being clean and abundant. The study of phenomena that are related to changes in atmospheric circulation, such as El Niño, are extremely important for its ability to affect wind generation. In order to explore the possible effect of such phenomena in the winds of the Northeast region of Brazil, a statistical analysis to quantify this effect through the model *Generalized Autoregressive Score* (GAS) is performed. This allows the modeling of time series for different probability distributions. Thus, the GAS is applied to the wind speed series from the Gamma distribution. The model results showed that El Niño has influence on the behavior of the wind, even though it is small in magnitude.

Keywords: Wind Power; El Niño/La Niña; GAS models

1 Introdução

O Brasil é um dos países com maior capacidade disponível de geração de energia elétrica através da força dos ventos, principalmente pelas suas características climáticas e topográficas. O mesmo possuía até julho de 2013, 119 parques eólicos com uma capacidade instalada de 2.788 MW, segundo ABEEólica (2013). O maior potencial eólico brasileiro disponível está situado nas regiões Nordeste e Sul do país. O Nordeste é a região que possui maior capacidade instalada e se destaca devido aos ventos alísios constantes que sopram de leste e as brisas marítimas na costa litorânea. A mesma dispõe de 89 parques eólicos e possui uma das melhores jazidas do mundo (ABEEólica, 2013). Além disso, a região apresenta ventos com velocidade acima de 7 m/s, definida como aproveitável para a produção de energia (Grubb & Meyer, 1993).

O fortalecimento da energia eólica no Brasil nos últimos seis anos se deve, principalmente, à implantação do Programa de Incentivos às Fontes Alternativas de Energia Elétrica (PROINFA) em 2004, o qual busca o aumento da participação de energias alternativas, em especial a eólica, na Matriz Energética Brasileira. Desta forma, o programa vem impulsionando o crescimento das fontes alternativas através de investimentos neste âmbito, com apoio financeiro do Banco Nacional de Desenvolvimento (BNDES), a fim de tornar a matriz energética mais limpa e aumentar a segurança no fornecimento de energia. Com isso, houve um aumento da importância das fontes limpas e sustentáveis de energia, decorrente dos avanços tecnológicos ocorridos nos últimos anos.

Estudos de alguns fenômenos que estão relacionados com alterações na circulação atmosférica, como o El Niño e o La Niña, são de extrema importância por afetarem o padrão da mesma. O Nordeste brasileiro é uma região que sofre influência dessas anomalias climáticas, principalmente na precipitação, fato já conhecido e abordado em muitos estudos (Sousa *et al.*, 2003; Lopes *et al.*, 2007).

O objetivo desse trabalho é a investigação, através de modelos estatísticos, do efeito do El Niño/La Niña, também conhecido como El Niño Oscilação Sul (ENOS), na intensidade dos ventos na região Nordeste do Brasil. A modelagem utilizada é a proposta por Creal *et al.* (2008), modelos *Generalized Autoregressive Score* (GAS), que serão aplicados às séries de vento, os quais permitem modelar séries univariadas ou multivariadas com

características como: não-gaussianidade, não-linearidade e não-estacionariedade. A utilização dos modelos GAS nesse contexto é justificada, uma vez que é sabido que séries de velocidade do vento não possuem distribuição Gaussiana, como abordado por Brown *et al.* (1984).

2 Dados

As séries de vento utilizadas nessa análise são oriundas de uma fonte de reanálise ERA- Interim do *European Center for Medium Range Weather Forecast* (ECMRWF) disponibilizadas pela empresa 3TIER. Estas se apresentavam em frequência horária para doze usinas eólicas localizadas na Zona Litorânea Norte-Nordeste definida em Amarante *et al.* (2001), a qual compreende a região entre a faixa costeira que possui cerca de 100 km de largura, que se inicia no extremo norte da costa do Amapá e se estende ao Cabo de São Roque com inclusão da cidade de Natal, no estado do Rio Grande do Norte. As séries de velocidade do vento (m/s) modeladas para 100 metros de altura compreendem o período de 01/01/1982 a 31/12/2012. Através destas foram obtidas médias horárias para cada mês ao longo dos 31 anos de dados para que se pudesse relacioná-las com o ENOS, um fenômeno de baixa frequência. Como, neste caso, a amostra é suficientemente grande e os desvios padrão da velocidade possuem valores baixos, a média é um estimador coerente e de fácil interpretação para o estudo. Assim, foram utilizadas 372 observações.

Além disso, vale ressaltar que uma análise de correlação entre as séries das doze usinas mostrou que as mesmas são fortemente correlacionadas, o que resultou em uma redução da análise para uma usina, uma vez que os ventos possuem comportamento semelhante em toda a região de estudo.

Para a investigação da relação entre velocidade do vento e fenômeno El Niño Oscilação Sul (ENOS), foram utilizadas séries mensais de anomalias e valores brutos de Temperatura da Superfície do Mar (TSM) no Oceano Pacífico Equatorial, coletadas do site do *Climate Prediction Center* (CPC)[<http://www.cpc.ncep.noaa.gov>].

3 Metodologia

Segundo Creal *et al.* (2008), a formulação GAS para séries temporais, diferentemente dos demais modelos frequentemente propostos na

literatura, introduz uma função que relaciona parâmetros variantes no tempo da distribuição condicional assumida para a série, com valores defasados dos mesmos e valores defasados do *score* condicional, além de valores correntes e/ou defasados de variáveis exógenas. Esta função pode definir o mecanismo de atualização dos parâmetros através de duas abordagens: evolução do tipo SARIMA, a qual é construída com base na formulação dos *Autoregressive Moving Average Models* (ARMA), e a evolução por componentes não observáveis, fundamentada pelo arcabouço dos modelos em espaço de estados.

3.1 Especificação do Modelo GAS com Estrutura de Evolução SARIMA

Seja y_t a variável dependente de interesse no estudo. Define-se f_t como um vetor de parâmetros variantes no tempo, x_t vetor de variáveis exógenas, no tempo t e θ o vetor de parâmetros fixos.

Além disso, pode-se definir os seguintes conjuntos:

$$Y_1^t = \{y_1, \dots, y_t\} : \text{valores de } y_t;$$

$F_1^t = \{f_1, \dots, f_t\}$: parâmetros variantes no tempo;

$$X_1^t = \{x_1, \dots, x_t\} : \text{variáveis exógenas.}$$

Toda a informação disponível em t pode ser representada por:

$$Y_1^{t-1}, F_1^{t-1} = \{f_{t-1}, F_1^{t-2}\}, \quad X_1^t \quad \text{e} \\ F_t = \{Y_1^{t-1}, X_1^t, F_1^{t-2}\}$$

Supondo uma densidade preditiva geral para y_t dada por

$$p(y_t | f_t, F_t; \theta)$$

para todo $t = 1, \dots, n$.

A dinâmica dos parâmetros variantes no tempo é introduzida através do seguinte mecanismo de atualização:

$$f_t = \omega + \sum_{i=1}^p A_i s_{t-i} + \sum_{j=1}^q B_j f_{t-j} \quad (1)$$

onde ω é um vetor de constantes, A_i e B_j são matrizes com dimensões apropriadas para $i = 1, \dots, p$ e $j = 1, \dots, q$, s_t é uma função escalar, que pondera o *score* da log-verossimilhança, que por sua vez depende das

observações passadas, dos parâmetros variantes no tempo f_t e do vetor de parâmetros fixos θ .

Assim, o mecanismo de atualização dos parâmetros que variam no tempo é dado por uma equação com forma familiar à estrutura autoregressiva nos modelos SARIMA de Box e Jenkins.

Nota-se que essa dinâmica também é semelhante à equação utilizada nos métodos de otimização Gauss-Newton.

A função que pondera o vetor *score*, s_t , é dada por:

$$s_t = S_t \cdot \nabla_t \text{ e } \nabla_t = \frac{\partial \ln p(y_t | f_t, F_t; \theta)}{\partial f_t} \quad (2)$$

onde S_t é a matriz de ponderação do vetor *score*.

A matriz S_t pode ser definida de várias maneiras, ou seja, existem muitas formas de ponderação do vetor *score*. No entanto, segundo Creal *et al.* (2013), é natural que a forma da ponderação dependa da variância do vetor *score*. Assim, uma das escolhas mais realizadas é a matriz de ponderação S_t , como sendo a pseudo-inversa da matriz de informação de Fisher. Esta e outras formas de ponderação do vetor *score* como a raiz quadrada da pseudo-inversa da matriz de informação de Fisher e a matriz identidade, são apresentadas abaixo:

$$S_t = I_{t|t-1}^{-1}, \quad S_t = I_{t|t-1}^{-1}, \quad S_t = I \quad (3)$$

onde

$$I_{t|t-1} = E_{t-1}[\nabla_t \nabla_t'] = -E_{t-1} \left[\frac{\partial^2 \ln p(y_t | f_t, F_t; \theta)}{\partial f_t^2} \right] \quad (4)$$

3.2 Especificação do Modelo GAS com Estrutura de Evolução CNO

Segundo Creal *et al.* (2008), modelos de componentes não observáveis pertencente à classe de modelos guiados por parâmetros com uma única fonte de erro. Com isso, é proposto um outro mecanismo de evolução para os modelos GAS, onde este é baseado na estrutura dos modelos de componentes não observáveis. Nesta nova formulação, um sinal univariado ψ_t pode ser extraído da série temporal $\{y_1, y_2, \dots, y_n\}$ e, assim, o vetor $(f_{1,t}, f_{2,t}, \dots, f_{r,t})$ é decomposto em r fatores, onde estes representam cada uma das componentes não observáveis da série temporal, como por exemplo: tendência, sazonalidade e ciclo.

Um exemplo é apresentado a seguir.

Seja uma série temporal $\{y_1, y_2, \dots, y_n\}$, a qual pode ser decomposta em componentes de tendência com *drift* ($f_{1,t}$) e ciclo ($f_{2,t}$) e, assim, $r = 2$. O fator de tendência é representado por um passeio aleatório, enquanto que o fator de ciclo por um processo autoregressivo de segunda ordem. Assim, tem-se que:

$$\begin{aligned}\psi_t &= f_{1,t-1} + f_{2,t-1} \\ f_{1,t} &= \omega + \alpha_1 s_t + f_{1,t-1} \\ f_{2,t} &= \alpha_2 s_t + \phi_1 f_{2,t-1} + \phi_2 f_{2,t-2}\end{aligned}$$

Portanto, através dessa decomposição, obtém-se o modelo GAS (1,2), representado pela equação de observações $y_t = \psi_t + \varepsilon_t = f_{1,t} + f_{2,t} + \varepsilon_t$, com equação de evolução dada por f_t (Equação 1), onde $p(y_t | \psi_t; \theta)$ é uma distribuição $N(f_{1,t-1} + f_{2,t-1}, \sigma^2)$. Os parâmetros $\omega, \alpha_1, \alpha_2, \phi_1$ e ϕ_2 são estimados por máxima verossimilhança, assim como no modelo GAS com evolução SARIMA.

Note que a estrutura de atualização f_t é a mesma utilizada na evolução por tipo SARIMA, porém nessa abordagem a dinâmica da série temporal é dividida em componentes.

Logo, a especificação de um modelo GAS baseia-se principalmente numa escolha adequada dos parâmetros variantes no tempo e da matriz de ponderação do vetor *score*, S_t , responsável pelo mecanismo de atualização destes parâmetros.

3.3 Modelos Univariados GAMA

Para a modelagem das séries de vento, utilizou-se a distribuição Gama com parâmetros de forma α e escala λ por esta possuir suporte $[0, \infty)$, o qual é adequado ao intervalo de variação das séries em estudo. Utilizando as duas configurações de evolução dos modelos GAS, SARIMA e CNO, a parametrização escolhida para a Gama foi a proposta em Matos (2013), onde a média condicional de y_t é o próprio parâmetro λ . Esta parametrização não é a comumente utilizada, onde se tem a distribuição Gama com parâmetros de forma e taxa, contudo, a primeira é a escolha mais apropriada para o propósito desse estudo.

Assim, optou-se por utilizar a seguinte distribuição condicional para y_t :

$$p(y_t | f_t, F_t; \theta) \sim \text{Gama} \left(\alpha, \frac{\lambda_t}{\alpha} \right)$$

ou seja,

$$p(y_t | f_t, F_t; \theta) = \frac{1}{\Gamma(\alpha) (\alpha^{-1} \lambda_t)^\alpha} y_t^{\alpha-1} \exp\left(-\frac{\alpha}{\lambda_t} y_t\right), y_t > 0, \alpha, \lambda_t > 0$$

cujas esperanças e variâncias dados respectivamente por:

$$E[Y | f_t, F_t; \theta] = \lambda_t \quad V[Y | f_t, F_t; \theta] = \frac{\lambda_t^2}{\alpha}$$

e a função de log-verossimilhança de y_t é dada por:

$$l(\theta) = \sum_{t=12}^n \ln p(y_t | f_t, F_t; \theta) = \sum_{t=12}^n \left[\ln \Gamma(\alpha) + \alpha (\ln(\alpha) - \ln(\lambda_t)) + (\alpha - 1) \ln y_t - \frac{\alpha}{\lambda_t} y_t \right]$$

Escolhendo, neste caso, o parâmetro de escala λ_t como o parâmetro variante no tempo tem-se que uma parametrização natural seria $\tilde{f}_t = \ln \lambda_t$, preferível à $f_t = \lambda_t$, de forma a garantir a positividade na estimação do mesmo.

Assim, o interesse está em calcular o vetor *score* e a matriz de informação de Fisher, que será utilizada no cálculo final do *score* ponderado, foco principal da modelagem GAS. Para esta abordagem, necessita-se apenas da derivada em relação ao parâmetro variante λ_t .

Sendo assim, a derivada de $\ln p(y_t | f_t, F_t; \theta)$, que é a contribuição de cada valor de y_t para o vetor *score*, em relação à λ_t é dada por:

$$\frac{\partial \ln p(y_t | f_t, F_t; \theta)}{\partial \lambda_t} = \frac{\alpha}{\lambda_t} \left(\frac{y_t}{\lambda_t} - 1 \right)$$

A partir desta, calcula-se o vetor *score* para a parametrização escolhida, onde $h(f_t) = \ln \lambda_t \Rightarrow \dot{h}_t = \frac{1}{\lambda_t}$ que é dado por:

$$\tilde{v}_t = \frac{\partial \ln p(y_t | f_t, F_t; \theta)}{\partial \tilde{f}_t} = (\dot{h}_t)^{-1} v_t = \alpha \left(\frac{y_t}{\lambda_t} - 1 \right)$$

Para o cálculo da matriz de informação de Fisher, necessita-se das derivadas parciais de segunda ordem. Como o parâmetro variante no tempo é λ_t , isto é, $f_t = \ln \lambda_t$, o interesse está no elemento da matriz $I_{t|t-1}$ referente a este parâmetro, sendo assim, tem-se que:

$$I_{t|t-1} = -E \left[\frac{\partial^2 p(f_t, F_t; \theta)}{\partial f_t^2} \right] = -E \left[\frac{\alpha}{\lambda_t^2} - \frac{\alpha y_t}{\lambda_t^3} \right] = \frac{\alpha}{\lambda_t^2}$$

e, assim em relação à \dot{h}_t , obtém-se que:

$$\tilde{I}_{t-1} = (\dot{h}_t)^{-1} I_{t|t-1} (\dot{h}_t')^{-1} = \alpha$$

A partir dos resultados anteriores e das equações (2), (3), (4), pode-se obter o *score* ponderado para algumas escolhas de ponderação, como:

$$s_t = (\alpha)^d \left(\frac{y_t}{\lambda_t - 1} \right), \quad d = \frac{1}{2}, 0 \leq d \leq 1. \quad (5)$$

as quais são obtidas a partir das seguintes ponderações: raiz quadrada da pseudo-inversa da matriz $I_{t|t-1}$, pseudo-inversa da matriz $I_{t|t-1}$ e matriz identidade I , respectivamente.

Os modelos Gama-SARIMA propostos com o parâmetro λ variante no tempo possuem a seguinte forma:

$$\tilde{f}_{t+1} = \omega + a_1 s_t + a_2 s_{t-1} + a_3 s_{t-2} + a_4 s_{t-10} + a_5 s_{t-11} + b_1 \tilde{f}_t + b_2 \tilde{f}_{t-1} + b_3 \tilde{f}_{t-2} + b_4 \tilde{f}_{t-10} + b_5 \tilde{f}_{t-11}$$

Neste, buscou-se capturar as dinâmicas de curto prazo pelas defasagens 1, 2 e 3, bem como dinâmicas de longo prazo, caracterizando a sazonalidade, através dos defasagens 11 e 12.

Os modelos GAS com evolução por componentes não observáveis propostos nesse estudo buscam capturar a dinâmica das séries de vento através de uma componente de sazonalidade (Equação 6), característica que é presente e se destaca nas séries vento, bem como uma componente autoregressiva de ordem 1 (Equação 7), como é apresentado a seguir.

$$\tilde{f}_{1,t+1} = - \sum_{k=1}^{11} \tilde{f}_{1,t-k} + a_1 s_t \quad (6)$$

$$\tilde{f}_{2,t+1} = \theta \tilde{f}_{2,t} + a_2 s_t \quad (7)$$

$$\tilde{f}_{t+1} = \omega + \tilde{f}_{1,t+1} + \tilde{f}_{2,t+1}$$

nas quais θ , a_1 e a_2 são parâmetros estáticos relacionados aos vetores \tilde{f}_t e s_t , estimados por máxima verossimilhança.

A inclusão de variáveis exógenas no modelo foi realizada diretamente no cálculo da média condicional λ_t , na forma aditiva, como proposto por Creal *et al.* (2013), é apresentado a seguir:

$$\tilde{f}_t = h(\lambda_t) = - \left[\sum_{k=1}^r \phi_k g(x_{t-k+1}) \right] + \ln \lambda_t$$

ou de forma equivalente

$$\lambda_t = \exp \left[\tilde{f}_t + \sum_{k=1}^r \phi_k g(x_{t-k+1}) \right]$$

na qual \tilde{f}_t é o parâmetro variante no tempo e x_t é o vetor de variáveis exógenas a serem incorporadas no modelo.

A mensuração do efeito do EL Niño/La Niña na intensidade do vento foi realizada através do cálculo da variação percentual na média condicional de $t - 1$ para t .

Assim, dada a variável exógena TSM, x_t , tem-se que:

$$\lambda_t = E[y_t | f_t, F_t; \theta] = e^{(\tilde{f}_t + \phi x_t)},$$

$$\lambda_{t-1} = E[y_{t-1} | f_{t-1}, F_{t-1}; \theta] = e^{(\tilde{f}_{t-1} + \phi x_{t-1})}$$

Desta forma, a variação percentual é dada por:

$$\begin{aligned} \Delta\% &= 100 \cdot \left(\frac{\lambda_t}{\lambda_{t-1}} - 1 \right) \\ &= 100 \cdot \left(e^{(\tilde{f}_t - \tilde{f}_{t-1} + \phi(x_t - x_{t-1}))} - 1 \right) \\ &= 100 \cdot \left(e^{(\Delta\tilde{f}_t + \phi(\Delta x_t))} - 1 \right) \end{aligned} \quad (8)$$

Vale ressaltar que a distribuição Weibull, muito conhecida pelo sua boa adequação para descrever o comportamento de séries de ventos, não apresentou bom desempenho neste estudo, onde as séries de velocidade foram utilizadas em frequência mensal.

Neste trabalho, a estimação dos parâmetros fixos do modelo via verossimilhança se deu a partir de métodos numéricos como: BGFS e Nelder-Mead. Os parâmetros variantes no tempo foram estimados através de relações recursivas pelo método da máxima verossimilhança. Mais detalhes sobre os procedimentos de estimação dos parâmetros estáticos dos modelos GAS podem ser encontrados em Creal *et al.* (2013).

4 Resultados e Discussões

Primeiramente, foi realizada uma análise exploratória do efeito do El Niño no vento, onde buscou-se analisar o perfil da velocidade ao longo dos anos através de médias horárias da velocidade do vento condicionada à três fases: El Niño, La Niña e neutro. Para essa classificação, considerou-se como ocorrência de El Niño os valores de anomalia

de TSM da região Niño 3.4¹ maiores ou iguais a 0,5; ocorrência de La Niña menores ou iguais a -0,5 e a fase neutra como valores contidos no intervalo de -0,5 e 0,5. Essa classificação é similar à utilizada na classificação do fenômeno ENOS através do *Oceanic Niño Index - ONI*, um dos índices construídos pelo NOAA para o monitoramento deste fenômeno. Isto foi realizado com o intuito de se observar possíveis diferenças mensais, o que caracteriza um efeito do fenômeno ENOS no vento.




Figura 1 Médias horárias da velocidade do vento por mês na usina eólica condicionada a fase de ENOS para o período de 01/1982 a 12/2012.

Analisando a Figura 1, é possível notar diferenças no padrão de ocorrências do El Niño e La Niña entre fevereiro e julho, sendo a maior diferença observada no mês de abril, tanto para a fase fria do fenômeno (La Niña), quanto para a fase quente (El Niño), característica também encontrada por Harper *et al.* (2007). Além disso, os ventos mais intensos são observados no segundo semestre do ano, em destaque para o mês de setembro. O comportamento menos intenso do vento nos primeiros meses do ano coincide com o período de seca na região Nordeste.

Para quantificar o efeito do fenômeno ENOS na velocidade do vento, foi utilizada como variável exógena do modelo a série de TSM da região Niño 3.4.

A fim de investigar a relação temporal entre a série de vento e a série de TSM da região Niño 3.4, foi realizada a correlação cruzada, a qual mensura a dependência temporal entre séries temporais (Figura 2).

A partir desta inspeção, nota-se uma dependência temporal significativa entre as séries,

¹ A região Niño 3.4 localiza-se em (5°N-5°S)(170-120°O), no Oceano Pacífico Equatorial e fornece boas medidas de mudanças importantes na TSM, sendo comumente utilizada para classificação dos fenômenos El Niño e La Niña em índices elaborados pelo NOAA (NOAA, 2014).




Figura 2 Correlação Cruzada entre velocidade do vento e TSM na região Niño 3.4.

nas defasagens de ordem 4 e 5. Assim, optou-se por utilizar nos primeiros modelos apenas as defasagens 4 e 5 da variável exógena (TSM da região Niño 3.4). No entanto, os modelos com a defasagem 4 da TSM e matriz de ponderação sendo a pseudo-inversa da informação de Fisher (Equação 5) forneceram melhores resultados.

Utilizando a metodologia apresentada, foram estimados modelos Gama com estrutura de evolução SARIMA e CNO para a série de velocidade do vento para a usina em estudo. Os resultados são apresentados a seguir.

Na Figura 3, observa-se o ajuste (linha pontilhada) da série de vento (linha sólida) para o modelo Gama com evolução SARIMA com a inclusão da variável exógena TSM com defasagem 4.




Figura 3 Ajuste da série de velocidade do vento para o período de estimação do Modelo Gama-SARIMA.

Nota-se que, de forma geral, a dinâmica da velocidade do vento da usina eólica foi capturada. No entanto, pode-se observar alguns descolamentos entre a velocidade observada e a estimada.

Para diagnóstico dos modelos, foram calculados os resíduos quantílicos², onde estes mostraram que a dependência linear da série foi capturada de forma satisfatória, o que pode ser observado na Figura 4 e corroborado pelo teste de autocorrelação de Ljung-Box (Tabela 1). No entanto, nota-se, pelo teste de normalidade, que os resíduos não seguem uma distribuição normal. Estes apresentam uma assimetria negativa. Tal característica está relacionada a observações mal ajustadas, mas como o objetivo central do trabalho não é realizar previsões, este comportamento dos resíduos não compromete a análise efetuada.

	Autocorrelação	Normalidade
Gama-SARIMA	0.40	0.00

Tabela 1 P-valor dos testes para os resíduos quantílicos do Modelo Gama-SARIMA.

Para o modelo Gama-SARIMA, a estimativa do parâmetro ϕ relacionado à variável exógena TSM da região Niño 3.4 foi de 0.019 e seu erro padrão de 0.005, o que resultou em uma estatística t igual a 3.81, sendo esta variável significativa no modelo. Assim, o efeito da TSM da região Niño 3.4 na velocidade do vento, obtido a partir da Equação 8, supondo $\Delta f_t = 0$ e $\Delta x_t = 1^\circ C$ é de 1.92 %.

Após a análise do modelo Gama-SARIMA, estimou-se o modelo Gama-CNO a fim de comparar o desempenho de ambos.

2 Kalliovirta (2009) apresenta uma descrição detalhada dos resíduos quantílicos, os quais são apropriados em casos onde os resíduos convencionais não são adequados.




Figura 4 FAC e histograma dos resíduos quantílicos do Modelo Gama-SARIMA.

O ajuste do modelo Gama-CNO com a inclusão da variável exógena pode ser observado na Figura 5.




Figura 5 Ajuste da série de velocidade do vento para o período de estimação do Modelo Gama-CNO.

O modelo Gama-CNO possui maior interpretabilidade do que o modelo Gama-SARIMA, uma vez que suas componentes podem ser interpretadas separadamente. Na Figura 6, apresenta-se a componente autoregressiva para todo o período de estudo e a sazonalidade para os últimos dez anos.

Em relação aos resíduos do Gama-CNO (Figura 7), nota-se que o comportamento destes é bem similar do Modelo Gama-SARIMA (Figura 4).

	Autocorrelação	Normalidade
Gama-CNO	0.27	0.00

Tabela 2 P-valor dos testes para os resíduos quantílicos do Modelo Gama-CNO.

Para o modelo Gama-CNO, a estimativa do parâmetro ϕ relacionado à variável exógena TSM

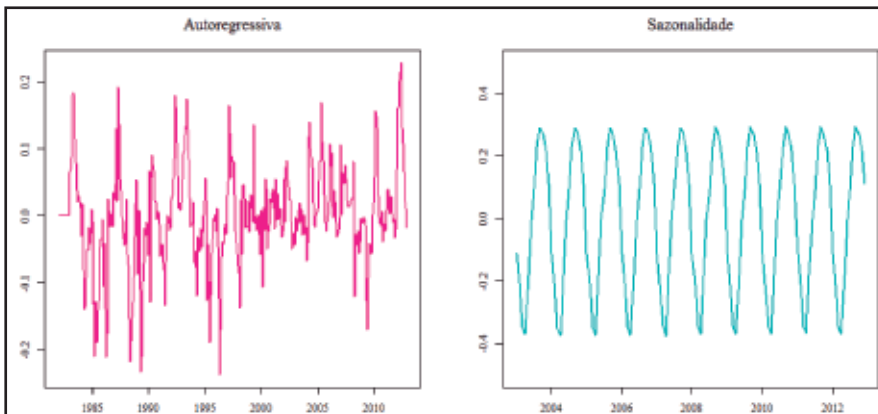


Figura 6 Componentes autoregressiva e sazonalidade do Modelo Gama-CNO.




Figura 7 FAC e histograma dos resíduos quantílicos do Modelo Gama-CNO.

região Niño 3.4 foi de 0.039 e seu erro padrão de 0.011, o que resultou em uma estatística t igual a 3.26, sendo esta variável significativa no modelo. Assim, o efeito da TSM da região Niño 3.4 na velocidade do vento, obtido a partir da Equação 8, com as mesmas suposições para o modelo Gama-SARIMA, é de 3.98 %.

	AIC	BIC	Log-likelihood
SARIMA	1009.60	1060.12	-491.80
CNO	957.47	980.79	-472.74

Tabela 3 Critérios de adequação dos modelos.

	RMSE	MAE	MASE	SMAPE	Pseudo - R ²
SARIMA	0.80	0.63	0.66	5.07	0.80
CNO	0.74	0.57	0.59	4.65	0.83

Tabela 4 Medidas de ajuste dos modelos.

5 Conclusões

Nesse artigo utiliza-se uma classe de modelos não-gaussianos para séries temporais com o objetivo de estimar o impacto do El Niño/La Niña na velocidade dos ventos no Nordeste brasileiro.

Os resultados obtidos mostraram que o modelo GAS com evolução CNO apresentou melhores

propriedades como: maior R²; menores RMSE, MAE, MAPE e critérios de informação; maior verossimilhança, quando comparado ao modelo por evolução SARIMA. Sendo assim, o efeito do fenômeno ENOS foi extraído do Gama-CNO, onde o parâmetro relacionado ao ENOS através da TSM foi igual a 0.039. Logo, pode-se inferir que a TSM da região Niño 3.4 apresentou um efeito positivo de aproximadamente 3.98 % na média condicional da velocidade do vento para os dados de estudo. Tal efeito, ainda que pequeno em magnitude, poderia acarretar em um efeito de ordem maior na potência gerada pela usina, uma vez que a potência é função da velocidade do vento ao cubo.

6 Agradecimentos

Este trabalho foi parcialmente desenvolvido com o apoio do projeto de P&D ANEEL PD-7625-0001/2013 e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

7 Referências

- Associação Brasileira de Energia Eólica/ABEEólica. 2013. *Boletim Mensal de Dados do Setor Eólico*, 7: 10 p.
- Amarante, O.A.C.; Brower, M.; Zack, J. & Sá, A.L. 2001. *Atlas do Potencial Eólico Brasileiro*. Brasília, 45 p.
- Brown, B.G.; Katz, R.W. & Murphy, A.H. 1984. Time Series Models to Simulate and Forecast Wind Speed and Wind Power. *Journal of Climate and Applied Meteorology*, 23:

- 1184-1195.
- Climate Prediction Center/CPC. 2013. El Niño – Southern Oscillation (ENSO). Disponível em: <<http://www.cpc.ncep.noaa.gov/products/precip/CWlink/MJO/enso.shtml>>. Acesso em: Fevereiro de 2012.
- Creal, D.; Koopman, S.J. & Lucas, A.A. 2008. A General Framework for Observation Driven Time-Varying Parameter Models. *Tinbergen Institute Discussion*, 108: 52 p.
- Creal, D.; Koopman, S.J. & Lucas, A.A. 2013. Generalized Autoregressive Score Models with Applications. *Journal of Applied Econometrics*, 28: 777-795.
- Grubb, M.J. & Meyer, N.I. 1993. Wind energy: resources, systems and regional strategies. In: JOHANSSON, T.B.; KELLY, H.; REDDY, A.K.N. & WILLIAMS, R.H. (eds.) *Renewable Energy: Sources for Fuels and Electricity*. Editora Island Press, p. 157-212.
- Harper, B.R.; Katz, E.W. & Harris, R.C. 2007. Statistical Methods for Quantifying the Effect of the El Niño-Southern Oscillation on Wind Power in the Northern Great Plains of the United States. *Wind Engineering*, 31 (3): 123-137.
- Kalliovirta, L. 2009. *Diagnostic Tests Based on Quantile Residuals for Nonlinear Time Series Models*. Programa de Pós-graduação em Economia, University of Helsinki, Tese de Doutorado, 165p.
- Lopes, F.Z.; Diniz, G.B & Marques, J.R. 2007. Relação entre o Multivariate Enso Index (MEI) e a TSM das Regiões dos Niños com a Precipitação em Regiões Homôneas do Estado do Rio Grande do Sul. *Anuário do Instituto de Geociências*, 30 (2): 11-22.
- Matos, G.G. 2013. *Modelos GAS Aplicados a Séries Temporais de Vazão e Vento*. Programa de Pós-graduação em Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Dissertação de Mestrado, 103p.
- National Oceanic and Atmospheric Administration/NOAA. Equatorial Pacific Sea Surface Temperatures. 2014. Disponível em: <www.ncdc.noaa.gov/teleconnections/enso/indicators/>. Acesso em: Abril de 2014.
- Sousa, E.P.P. 2003. *Relações entre as anomalias de TSM do Atlântico e Pacífico e as precipitações na Amazônia oriental*. Programa de Pós-graduação em Meteorologia, Instituto Nacional de Pesquisas Espaciais, Dissertação de Mestrado, 78p.