

Simulação da geração mensal de um parque eólico com modelos autorregressivos e variáveis climáticas

1 Introdução

A energia eólica destaca-se como uma das fontes de energia com maior crescimento no cenário mundial (12,5% no ano de 2013, de acordo com o Conselho Global de Energia Eólica - GWEC). No Brasil, a energia eólica foi introduzida na matriz em 2006, mas ganhou penetração apenas a partir de 2011, com boa parte da energia sendo vendida no Ambiente de Contratação Regulado - ACR. Em novembro de 2014, de acordo com as informações do Banco de Informações de Geração - BIG, a capacidade total de energia eólica instalada no Brasil era de 4.236 MW (3,2% da capacidade elétrica do país) e a instalação de mais 10.416 MW já estava autorizada.

A crescente participação da energia eólica na matriz mundial e brasileira levanta a questão do melhor aproveitamento das pás e do potencial eólico dos parques como um todo, bem como do desenvolvimento de métodos de previsão da velocidade do vento e da geração eólica. Milligan et al. (1995) e Barthelmie et al. (2008) são alguns dos autores que mostraram os benefícios econômicos da previsão da velocidade dos ventos. Através de previsões confiáveis é possível beneficiar tanto o empreendedor quanto o sistema elétrico.

Embora seja vasta a literatura sobre previsão da velocidade do vento e da geração eólica, os horizontes de previsão considerados são, geralmente, horas ou poucos dias a frente. Esses horizontes são extremamente relevantes para a operação de sistemas elétricos e negociações em mercados diários, mas pouco ou nada contribuem para a comercialização de energia eólica no mercado brasileiro de energia, que é essencialmente mensal.

Assim, o mercado brasileiro urge por modelos de previsão e simulação capazes de olhar horizontes estendidos, como meses e mesmo ano a frente, de modo a auxiliar a gestão da comercialização de energia de parques eólicas. Esse auxílio é particularmente importante para negociações no Ambiente de

Contratação Livre – ACL, sobre o qual é lançada a dúvida sobre a capacidade de remunerar satisfatoriamente a energia eólica (DALBEM et al., 2014).

Portanto, o foco deste estudo é a previsão mensal de geração eólica para o horizonte anual, que se enquadra na ideia de previsão para planejamento de longo prazo, um dos temas de pesquisa sugeridos por Foley et al. (2012). Um diferencial proposto é a consideração de variáveis climatológicas nas previsões e simulações, o que não é observado em outros estudos.

De fato, como a maioria dos estudos trata de horizontes de previsão de horas ou poucos dias à frente, não é possível observar uma clara influência da ocorrência de fenômenos climáticos, cuja perpetuação é de meses. Contudo, para o horizonte anual, a climatologia não pode ser desprezada. Assim, a simulação de geração eólica considerando a influência de fenômenos climáticos é uma contribuição tanto para Academia, quanto prática e, mesmo, para Governos no contexto de planejamento energético anual.

Dentro do contexto apresentado, o principal objetivo deste estudo é selecionar e avaliar a adequação de modelos autorregressivos, com e sem a incorporação de variáveis climatológicas, para previsão e simulação da média mensal de geração eólica no horizonte anual. Deste modo pretender-se-á responder às seguintes questões:

- i. Qual(is) modelo(s) autorregressivo(s) são adequados para modelagem da média mensal de geração eólica?;
- ii. Qual(is) modelo(s) autorregressivo(s) adequados para modelagem da média mensal de geração eólica são mais precisos?;
- iii. Qual o impacto da incorporação de variáveis climatológicas ao(s) modelo(s)?

Para realização do estudo utilizar-se-á os dados de um parque eólico localizado no Ceará, o que afeta diretamente a seleção de variáveis climatológicas

2 Referencial Teórico

2.1 Previsão da velocidade do vento e geração de energia eólica

Diversos trabalhos propõem modelos para previsão de velocidade dos ventos e de geração de energia eólica. Em Foley et al. (2012), Jung & Broadwater (2014) e Lei et al. (2009) são revistos mais de 120 trabalhos sobre o tema, agrupados, em linhas gerais, em três categorias segundo o tipo de modelagem: (i) física, (ii) estatística e (iii) mista. A modelagem física considera modelos meteorológicos numéricos de previsão de vento (*Numerical Weather Prediction - NWP*) e os princípios físicos para conversão do vento em geração eólica. A modelagem estatística abrange tanto modelos autorregressivos, como de inteligência artificial, redes neurais (*Artificial Neural Network - ANN*) e lógica fuzzy. Os modelos mistos costumam associar a previsão de ventos com modelos ANN e fuzzy para obtenção da previsão de geração.

Dentre as categorias, modelos estatísticos apresentam bons resultados de previsão tanto para horizontes de curto, médio e longo prazo (algumas horas a uma semana) (JUNG; BROADWATER, 2014), como para horizontes mais longos e discretizações mais esparsas, como médias mensais, trimestrais e anuais os (FOLEY et al., 2012).

Os modelos estatísticos clássicos são os modelos autorregressivos de média móvel ARMA, cuja formulação geral para variável Y consta na eq. (1).

$$Y_j = c + \sum_{i=1}^p \varphi_i \times Y_{j-i} + \sum_{i=1}^q \theta_i \times \varepsilon_{j-i} + \varepsilon_j; \varepsilon_j \sim N(0; \delta) \quad (1)$$

Onde:

Y_j = variável sob estudo no período j;

c = constante;

φ_i = parâmetro de ordem i da parte AR;

θ_i = parâmetro de ordem i da parte MA;

ε_j = resíduo no período j (ruído branco com distribuição Normal);

δ = desvio-padrão dos resíduos.

Variações dos modelos ARMA são os modelos ARIMA (ARMA com integração), SARMA (ARMA sazonal), ARMAX (ARMA com variáveis

exógenas). Os modelos ARMA pressupõem volatilidade constante, portanto, na presença de heteroscedasticidade deve-se utilizar modelos ARCH, GARCH e demais derivados. Peng & Yue (2011) e Wang et al. (2012) obtiveram menores erros de previsão no curto prazo ao utilizar modelos ARCH na previsão de velocidade do vento. Maior aprofundamento sobre a formulação de modelos autorregressivos pode ser obtido em Tsay (2010).

Como visto, modelos estatísticos, incluindo os autorregressivos, podem ser utilizados para diferentes horizontes e discretizações de previsão, mas a maior parte da literatura foca na previsão horária em horizontes que variam de algumas horas a uma semana. Jung & Broadwater (2014), por exemplo, enfatizam a importância da previsão de médio prazo (6 a 24 horas) para o gerenciamento de sistemas elétricos e negociações de energia no caso de mercados diários e intra-diários. Como o mercado brasileiro é essencialmente mensal (LUZ et al., 2012), horizontes de previsões mais extensos, como um mês a um ano (com discretização mensal) tornam-se mais relevantes para negociações de energia eólica.

Uma alternativa à modelos estatísticos para discretizações esparsas, utilizada em estudos de certificação e avaliação de futuros parques eólicos, é o ajuste de parâmetros da distribuição Weibull à série medida de vento que exista para localidade ou a séries obtidas para próximo da localidade a partir de dados de reanálise, a fim de determinar a velocidade média do vento no local (AJAYI et al., 2010). Entre os estudos que tratam de previsão de vento em horizontes anuais encontram-se Guo et al. (2011) e Caporin & Prés (2012).

Sabe-se que qualquer modelo de previsão carrega um erro associado e que este aumenta à medida que aumenta o horizonte de previsão (GOOIJER; HYNDMAN, 2006; FOLEY et al., 2012). Esse fato é particularmente verdadeiro ao tratar-se de modelos autorregressivos, em que ocorre a propagação do erro. Uma das possibilidades para lidar com a questão é a modelagem a parte do erro, como em Guo et al. (2011), em que é realizada correção do erro do modelo SARIMA através do modelo LSSVM (*Least-Square Support Vector Machine*) para previsão de médias mensais de vento. De modo geral, a utilização de abordagens mistas visa integrar e maximizar a informação capturada por cada modelo, a fim de reduzir o erro de previsão (DONGMEI et al., 2011) ou, mesmo, reduzir riscos associados a eventos extremos não capturados por alguns modelos (JUNG; BROADWATER, 2014). Apesar de alternativas como essas, ao prever-se

médias mensais de geração eólica, a maior preocupação não é acertar a geração, mas sua tendência e ser capaz de simular essa geração a fim de obter diferentes realizações plausíveis para avaliação de riscos. Foley et al. (2012) alerta, ainda, que a acurácia da previsão da velocidade do vento ou da geração eólica é fortemente dependente: (i) da precisão dos modelos numéricos meteorológicos no caso de modelos físicos; (ii) da coleta e tratamento dos dados no caso de modelos estatísticos. Jung & Broadwater (2014) complementam que a precisão de modelos estatísticos clássicos pode ser melhorada através da seleção dos parâmetros do modelo.

Com esse foco, duas vantagens de modelos autorregressivos é serem computacionalmente simples, além de ficarem evidentes as relações entre *inputs* e *outputs*, o que não ocorre em modelos do tipo ANN e fuzzy. Box et al. (2015) e Tsay (2010) são guias para ajuste de modelos autorregressivos a séries temporais.

De modo resumido, o ajuste de modelos autorregressivos segue a clássica abordagem de Box & Jenkins para modelagem matemática de séries, que se baseia nas seguintes etapas: (i) identificação da classe de modelo a partir da teoria, (ii) identificação da subclasse e modelo a ser ajustado aos dados, (iii) estimação dos parâmetros, (iv) diagnóstico e verificação da adequação do modelo aos pressupostos, devendo-se retornar à etapa (ii) em caso de rejeição (BOX et al., 2015, p. 16-17). Uma vez ajustado o modelo, passa-se à previsão.

Os principais pressupostos a serem verificados na etapa (iii) em relação aos resíduos são: estacionariedade, inexistência de autocorrelação, inexistência de autocorrelação entre seus quadrados, ou seja, homocendasticidade e normalidade (TSAY, 2010).

Como a modelagem autorregressiva de séries temporais não é única (GOOIJER; HYNDMAN, 2006), há duas abordagens principais para comparação e seleção de modelos: (i) avaliação da capacidade preditiva com base em medidas de erros de previsão e (ii) avaliação da adequação e parcimônia com base nos critérios de informação (BOX et al., 2015; TSAY, 2010). Para ambas abordagens, o melhor modelo é sempre o que apresenta as menores medidas. As principais medidas de erro utilizadas são apresentadas nas eq. (2) a eq. (4).

Erro médio absoluto

$$MAE = \frac{\sum_{i=1}^n |o_i - p_i|}{n} \quad (2)$$

Erro médio quadrático

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{n}} \quad (3)$$

Erro médio absoluto percentual

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{o_i - p_i}{p_i} \right|}{n} \quad (4)$$

Onde:

o_i = valores observados;

p_i = valores previstos;

n = total de previsões.

Os dois principais critérios de informação são o de Akaike, conhecido como AIC (AKAIKE, 1974), e o Baysiano, conhecido como BIC (SCHWARTZ, 1978), conforme descritos, respectivamente, em eq. (5) e eq. (6). Ambos consideram a relação entre a adequação do modelo, medida pela função de máxima verossimilhança, e a parcimônia, medida através de diferentes funções de penalidade para o número de parâmetros. A principal diferença entre o AIC e o BIC é que o BIC penaliza mais a complexidade do modelo (número de parâmetros) do que o AIC.

$$AIC = -2 \times \ln(L) + k \times 2 \quad (5)$$

$$BIC = -2 \times \ln(L) + k \times \ln(N) \quad (6)$$

Onde:

k = número de graus de liberdade, ou seja, o número de parâmetros no modelo;

L = máxima verossimilhança;

N = total de observações.

Trabalhos como os de Brown et al. (1982) e Karki et al. (2006) utilizam modelos AR e ARMA para modelagem da velocidade média do vento e posterior

conversão em geração de energia eólica pela curva de potência. Enquanto aquele fornece um exemplo ilustrativo do ajuste do modelo AR(2) a dados horários de velocidade do vento para posterior conversão em energia, este utiliza o ajuste do modelo ARMA(3,2) para simulações horárias e obtenção da distribuição da média anual da velocidade do vento em três localidades. Caporin & Prés (2012) utilizam abordagem semelhante, contudo, modelam primeiramente a sazonalidade da série histórica de vento e, posteriormente, ajustam o modelo ARFIMA-FIGARCH aos dados. Finalmente, transformam a velocidade do vento em geração eólica pela curva de potência para precificação de derivativos climáticos.

De fato, a sazonalidade das séries de vento e geração eólica é evidente pela simples inspeção visual das séries, sejam horárias, diárias ou mensais, requerendo tratamento apropriado, sobretudo, em função da discretização e horizontes de previsão considerados.

2.2 Previsão de longo prazo e sazonalidade

Gooijer & Hyndman (2006) fazem uma ampla revisão sobre a previsão de séries temporais. Dentre os modelos revistos encontram-se os modelos autorregressivos clássicos (ARIMA) e chama atenção a variabilidade de horizontes de previsão e discretização temporal das séries estudadas. Apesar de ter maior respaldo na literatura o uso de modelos autorregressivos para previsão de um ou poucos passos futuros, estudos como os de Grambsch & Stahel (1990), Preez & Witt (2003), Weller (1989) e Harris & Liu (1993) tratam de horizontes de 12 (doze) a 36 (trinta e seis) passos futuros com discretização mensal das séries. Contudo, nenhum desses estudos trata da modelagem de séries temporais climáticas ou derivadas do clima, como é o caso da velocidade do vento.

As séries temporais de velocidade do vento parecem sofrer influência de variáveis climatológicas e meteorológicas, além de possuírem sazonalidade marcante. Caso semelhante é observado para as séries de vazões de rios, particularmente, ao serem consideradas médias mensais no Brasil. Para modelagem de sazonalidade, algumas das alternativas estudadas são: (i) decomposição sazonal, como o método X-11 e similares; (ii) modelos autorregressivos sazonais, como SARMA; (iii) métodos para ajuste sazonal paramétricos, não-paramétricos e modelos sinodais; (iv) modelos de séries

temporais periódicas, como PAR. Referências sobre esses modelos, podem ser obtidas em Gooijer & Hyndman (2006).

Quanto aos modelos autorregressivos periódicos, conhecidos como PAR e PARMA, observa-se que resultam em melhores previsões que modelos não periódicos sob certas condições (FRANSES; VAN DIJK, 2005; WELLS, 1997; NOVALES; FRUTO, 1997). De fato, não há um consenso sobre o melhor modelo para representação de sazonalidade de modo global, a seleção depende dos modelos avaliados em estudo e da natureza dos dados (GOOIJER; HYNDMAN, 2006).

Em Franses & van Dijk (2005) são avaliados 9 (nove) modelos para previsão da produção industrial trimestral em diferentes países e a principal conclusão é que para horizontes curtos de previsão (um a dois passos), modelos simples de sazonalidade, como AR com dummies sazonais e SARIMA obtêm melhor performance, enquanto, para horizontes maiores (3 a 12 passos), a modelagem explícita da variação temporal da sazonalidade e da variação periódica, como em modelos PAR, melhora a capacidade preditiva.

Noakes et al. (1985) avalia a performance dos modelos SARIMA, ARMA dessazonalizado e PAR para 30 séries mensais de vazões de rios, dentre as quais a do Rio Grande no Brasil. Eles concluem que apesar da existência de modelos mais parcimoniosos, o modelo PAR/PACF (seleção da ordem p pela observação do gráfico PACF) é o mais parcimonioso adequado para modelagem das séries, dada a correlação da sazonalidade e sua precisão. Com efeito, ainda hoje a modelagem e simulação de séries de vazões de rios por modelos PAR é utilizada no Setor Elétrico Brasileiro para otimização do despacho hidrotérmico e cálculo dos preços de referência.

2.3 Velocidade do vento e climatologia no Nordeste

Os modelos NWP já mencionados consideram diversas variáveis meteorológicas como dados de entrada para previsão da velocidade do vento ou geração eólica e fornecem melhores resultados para horizontes de previsão de curtíssimo prazo (até 30 minutos a frente) (JUNG; BROADWATER, 2014). No entanto, a maioria deles não considera explicitamente a modelagem oceânica ou

mesmo a temperatura da superfície do mar (TSM), pois essas são variáveis climatológicas (FOLEY et al., 2012) e não variam no horizonte de curto prazo.

De fato, variáveis climatológicas persistem, pelo menos, de um a três meses. Embora elas possam ser ignoradas nas previsões de curto prazo, até mesmo por já estarem incorporadas aos dados observados, elas parecem ser importantes no contexto de médias mensais de velocidades de vento e de geração eólica (ZHANG et al., 2013; OLIVEIRA; COSTA, 2011), sobretudo, ao ser considerando um horizonte anual.

O trabalho de Archer & Jacobson (2013) calcula o potencial teórico global de geração eólica com auxílio de modelo numérico dinâmico e aponta características sazonais da geração eólica e sua relação com a dinâmica atmosférica e oceânica. Apesar de não ser explorada a relação entre o potencial eólico e fenômenos climatológicos, é possível esperar algum impacto dada a influência destes sobre as dinâmicas atmosférica e oceânica.

Alguns estudos tentam revelar o impacto das condições climatológicas no regime de ventos e precipitação no nordeste do Brasil (OLIVEIRA; COSTA, 2011; CERQUEIRA, 2010; ARAUJO JUNIOR et al., 2014; ARAGÃO, 1998). Por estes estudos, também, fica clara a relação entre vento e chuva, que pode ser resumida em: quanto mais chuva, menos vento e vice-versa.

Oliveira & Costa (2011) estudam a influência da variabilidade climatológica e circulação geral no comportamento do vento no nordeste do Brasil, particularmente, no Ceará. A motivação vem do incentivo para a introdução do potencial eólica na matriz energética brasileira e a reconhecida susceptibilidade do clima do nordeste brasileiro à pressão atmosférica e às anomalias de TSM dos oceanos Atlântico e Pacífico, como já apontado em Enfield (1996).

A anomalia de TSM do oceano Pacífico na região do Niño 3.4 é determinante para caracterizar a condição oceânica-atmosférica do *El Niño Southern Oscillation* (ENSO), que pode ser: neutra, La Niña ou fase fria (negativa) e El Niño ou fase quente (positiva). De modo semelhante, a anomalia de TSM do Atlântico Norte e Sul são determinantes para computar o Dipolo do Atlântico, que tem relação direta com o posicionamento da Zona de Convergência Inter Tropical (ZCIT) e a ocorrência de chuvas no nordeste brasileiro (CERQUEIRA, 2010; ENFIELD, 1996). Essas regiões podem ser melhor visualizadas nas Figuras 1 e 2.



Figura 1 - Oceano Pacífico e as regiões do Niño.

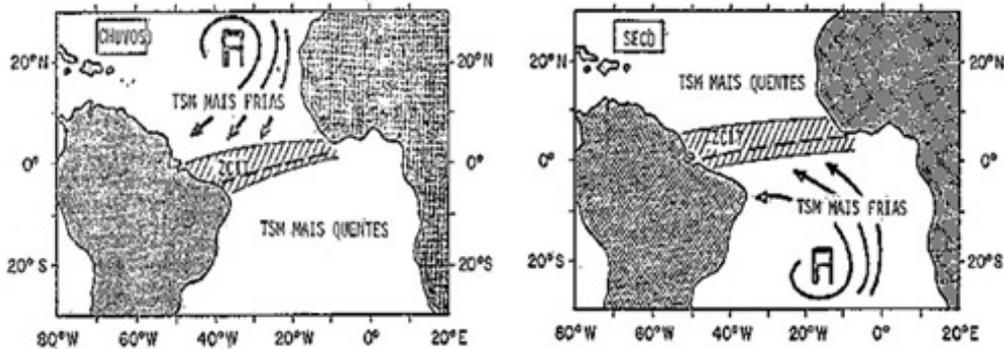


Figura 2 - Dipolo Negativo do Atlântico (à esquerda) e Dipolo Positivo do Atlântico (a direita) e o posicionamento da ZCIT.

Oliveira & Costa (2011) concluem que a ocorrência de El Niño e Dipolo Positivo do Atlântico favorecem a geração eólica, enquanto a ocorrência de La Niña e Dipolo Negativo do Atlântico resultam em aumento da precipitação, desfavorecendo, assim, a geração eólica. Os efeitos das anomalias de TSM do Atlântico e do Pacífico não foram analisados separadamente, no entanto, observou-se que: (i) anomalias de TSM nas regiões Niño 3 e Niño 3.4 do Pacífico precedem em dois meses mudanças na velocidade do vento; (ii) a velocidade do vento responde mais rapidamente a anomalias na TSM do Atlântico Tropical, conforme observado em relação à precipitação por Enfield (1996).

Araujo Junior et al. (2014), também, analisam o impacto do ENSO na produção de energia de eólica no Ceará e obtém o mesmo resultado sobre a influência do ENSO, ou seja, melhor condição para produção de energia eólica na fase quente e pior na fase fria, principalmente no litoral.

Aragão (1998) explica que o Dipolo do Atlântico inibe ou aumenta a formação de nuvens sobre o nordeste brasileiro e alguns países de África. Quando a TSM do Atlântico Norte tem anomalia positiva e a TSM do Atlântico Equatorial ou Sul tem anomalia negativa (Dipolo Positivo do Atlântico), a formação de nuvens é inibida e a ZCIT posiciona-se mais ao norte, restando a precipitação

reduzida. Por outro lado, quando a TSM do Atlântico Norte tem anomalia negativa e a TSM do Atlântico Equatorial ou Sul tem anomalia positiva (Dipolo Negativo do Atlântico), a formação de nuvens é reforçada e a ZCIT posiciona-se mais ao sul, restando a precipitação aumentada. A relação entre ENSO e precipitação (OLIVEIRA; COSTA, 2011; CERQUEIRA, 2010; ARAUJO JUNIOR et al., 2014), também, é ratificada. Outro resultado obtido é que as informações de TSM do Atlântico até seis meses antes do início da estação chuvosa são mais relevantes do que as do Pacífico para prever anomalias de precipitação no nordeste brasileiro.

Cerqueira (2010) traz alguns estudos que confirmam o sinal da influência do ENSO e do Dipolo do Atlântico sobre a precipitação no nordeste brasileiro. Ele também conclui que a influência do Dipolo do Atlântico parece ser maior do que a influência do ENSO (La Niña e El Niño). No entanto, ele observa que a relação entre a TSM do Atlântico e precipitação torna-se maior na ocorrência de La Niña ou El Niño fortes.

Nos trabalhos apresentados fica clara a existência teórica e, mesmo, empírica da influência dos fenômenos El Niño, La Niña e Dipolo Positivo e Negativo do Atlântico sobre a precipitação e velocidade do vento no nordeste brasileiro, particularmente, no Ceará. Assim, ao realizar a previsão de geração eólica nessa região para horizontes anuais, espera-se que incorporar esses fenômenos na modelagem resulte em um modelo mais robusto e com melhor acurácia de previsão.

3 Metodologia

O principal objetivo deste estudo é a seleção de modelos autorregressivos adequados para modelagem da média mensal de geração eólica, testando-se a incorporação de variáveis climatológicas exógenas aos dados. O estudo é de natureza empírica, com ajuste dos modelos aos dados de um parque eólico específico.

O ajuste de modelos autorregressivos seguiu as orientações de Box & Jenkins. Os modelos selecionados para ajuste a partir do referencial foram: SARMA, AR com 11 dummies sazonais e PAR. Todos os ajustes e cálculos de modelos foram processados em R.

Para avaliação e comparação dos modelos utilizou-se as medidas de erro e critérios de informação presentes nas eq. (2) a eq. (2), bem como o teste de Dielbod-Mariano (DIEBOLD; MARIANO, 1995; FRANCES; VAN DIJK, 2005), ANOVA, conforme Guo et al. (2011) e teste de Turkey (TURKEY, 1953).

3.1 Base de dados

Os dados de velocidade do vento deste estudo são referentes a um parque eólico localizado no Ceará, com 75,6 MW de capacidade instalada e 28 aerogeradores, e são originários de duas fontes: dados brutos a cada 10 minutos de uma torre anemométrica do parque a 90m, a partir de 2009 e dados horários de reanálise do MERRA a 50m, a partir de 1979 (maiores informações sobre dados de reanálise podem ser obtidas em Sonderegger (2011)). Os dados referentes a variáveis climatológicas foram obtidos junto ao NOAA-NCEP.

3.2 Série histórica de geração teórica de energia eólica

Os dados de medição de vento do parque eólico sob estudo compreendem apenas um período de aproximadamente 5 (cinco) anos, de fevereiro de 2009 a julho de 2014, durante o qual ocorreram um El Niño (Trimestre JJA/2009 a MAM/2010) e dois La Niña (Trimestre JJA/2010 a MAM/2011; Trimestre ASO/2011 a FMA/2012). Como o objetivo da previsão de longo prazo é abranger um período de um ano à frente, o histórico medido pode ser considerado insuficiente para estimação de parâmetros. Ademais, como pretende-se testar a influência de variáveis climatológicas, faz-se necessário a obtenção de um histórico estendido para ter-se um mínimo de dados com a ocorrência das diferentes configurações de ENSO e Dipolo do Atlântico, variáveis climatológicas apontadas como as principais no referencial teórico.

Assim, para ajuste e estimação de modelos autorregressivos, optou-se por estender a série medida com dados de reanálise. A série de reanálise escolhida foi a base de dados horária do MERRA a 50m de altura com longitude -39.999 e latitude -3.500 de maio/1979 a abril/2014, ajustada para 90m de altura, dentre quatro séries do MERRA a 50m de altura com coordenadas mais próximas às do parque. A escolha da série do MERRA deu-se por apresentar melhor ajuste à média horária dos dados de medição do parque a 90m de altura, apresentando um

R² de 0,56 e correlação de 0,75 para base horária e, R² de 0,96 e correlação de 0,98 para base mensal, sendo, também, a mesma série de referência do estudo de avaliação e certificação do parque. O ajuste da velocidade média do vento de 50m para 90m de altura para cada horário foi calculado pela equação do perfil vertical do vento (eq. (7)), conforme Dongmei (2011) e Lira et al. (2011), utilizando-se o expoente de 0,27, obtido no estudo de avaliação do parque e verificado como expoente médio entre as séries de vento para as três alturas com medição no parque (90m, 57,2m e 37,6m).

$$U_{h_1} = \left(\frac{h_1}{h_2}\right)^\alpha \times U_{h_2} \quad (7)$$

Onde:

U_h= velocidade média do vento na altura h (m/s);

h = altura acima do nível do solo (m);

α = expoente de perfil vertical do vento.

Inicialmente, os dados brutos de velocidade do vento do parque, também, foram analisados com o programa SPSS® e procedeu-se a complementação de dados faltosos, de modo similar a Lira et al. (2011). A Tabela 1 apresenta o resumo dessa complementação.

Dados	Nº de dados	Média	Desvio-padrão	Mínimo	Máximo
Originais	255525	7,392570	2,5468241	,380000	17,490000
Faltosos entrados	12501	6,284642	2,2469474	,000064	15,024847
Completos	268026	7,340896	2,5443717	,000064	17,490000

Tabela 1 - Dados entrados na série medida a 90m com discretização de 10 minutos

Finalmente, a série de vento utilizada para conversão em série teórica de geração foi composta pela série da velocidade horária do MERRA ajustada para 90m de 01/janeiro/1982 00:00 a 31/janeiro/2009 23:00 e pela série da média horária da velocidade medida do parque a 90m, de 01/fevereiro/2009 00:00 a 31/julho/2014 23:00. À essa série de vento horária foi aplicada a curva de potência do equipamento instalado no parque para conversão do vento em geração eólica (Figura 3), seguindo a ideia de Dongmei (2011), Brown et al. (1984), Karki et al (2006) e Caporin & Prés (2012). Após, calculou-se a média mensal, obtendo-

se a geração teórica para um aerogerador, utilizada para ajuste e comparação dos modelos.



Figura 3 - Curva de potência do aerogerador

A série temporal de geração utilizada contém 391 observações e os valores estão MW médio, ou seja, média da geração de MWh por hora (MWh/h), e suas propriedades podem ser melhor observadas nas Figuras 4 a 6.

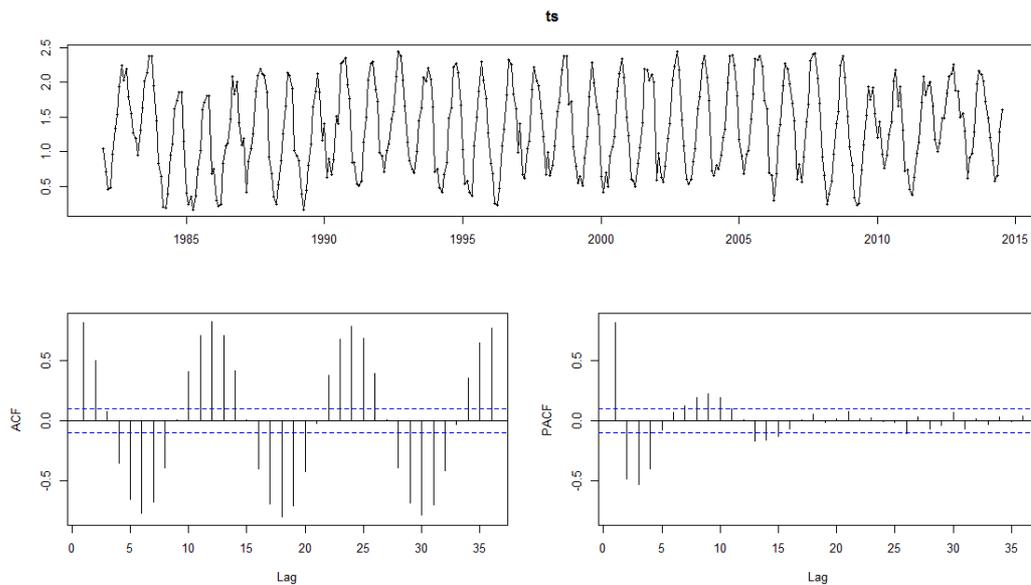


Figura 4 - Série temporal de média mensal de geração eólica (jan/1982 a jul/2014) (acima) e funções de autocorrelação - ACF (à esquerda) e autocorrelação parcial - PACF (à direita)

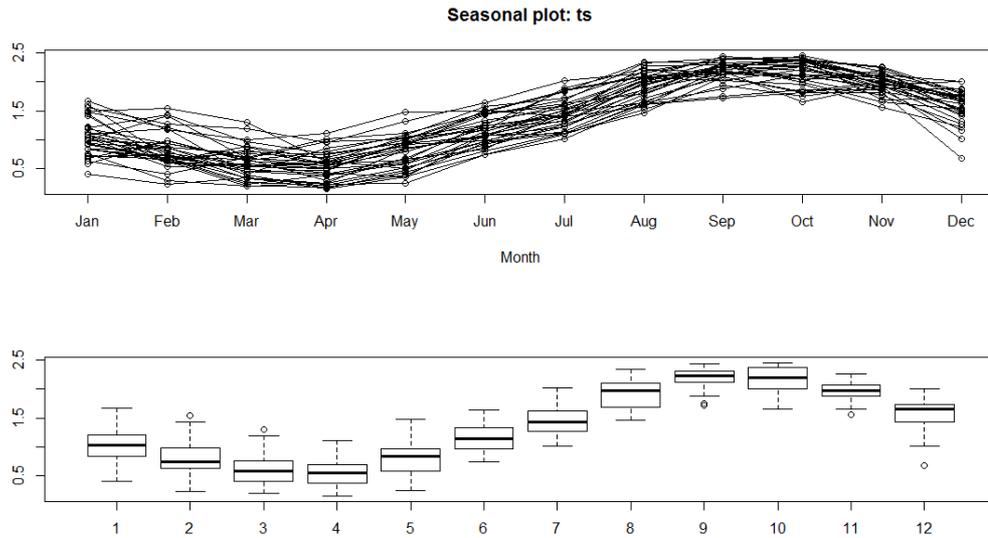


Figura 5 - Série temporal periódica de média mensal de geração eólica (jan/1982 a jul/2014) (acima) e *box-plot* da série periódica (abaixo)

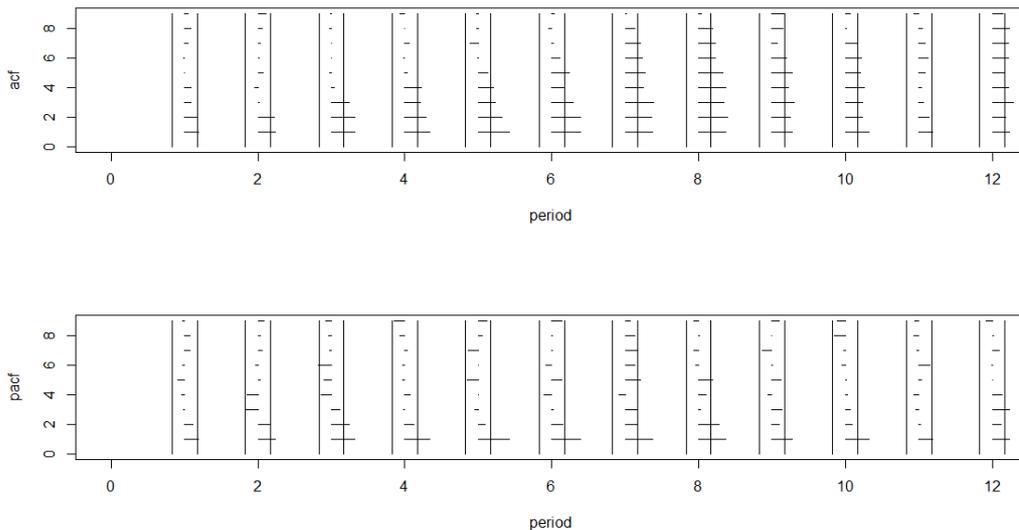


Figura 6 - ACF (acima) e PACF (abaixo) periódicas para geração eólica

3.3 Séries históricas de variáveis climatológicas

Uma vez visualizada as características da série a ser modelada, é interessante visualizar, também, os candidatos a variáveis exógenas a serem incorporados. A partir do referencial, obteve-se que as ocorrências de El Niño e/ou Dipolo Positivo Atlântico estão associadas a condições favoráveis à velocidade do vento e desfavoráveis à precipitação no Ceará, enquanto as

ocorrências de La Niña e/ou Dipolo Negativo do Atlântico estão associadas à condição inversa. Os estudos referenciam, ainda, que a influência do Dipolo é mais relevante no período chuvoso, isto é, de fevereiro a maio. Assim, as variáveis exógenas testadas foram:

- i. anomalia mensal de TSM na região do Niño 3.4 (ninoA);
- ii. diferença da anomalia mensal de TSM entre o Atlântico Norte e o Atlântico Sul (dipA);
- iii. dummy para ocorrência de El Niño a cada mês (nino);
- iv. dummy para ocorrência de La Niña a cada mês (nina);
- v. dummy para ocorrência de Dipolo Positivo do Atlântico a cada mês (dipP);
- vi. dummy para ocorrência de Dipolo Negativo do Atlântico a cada mês (dipN).

Enquanto a ninoA é obtida diretamente do NOAA-NCEP, a nina e nino foram definidas como 1 para o mês central de um trimestre com ocorrência de La Niña e El Niño, respectivamente, e 0 para os demais meses. Ao observar as anomalias trimestrais de TSM no Niño 3.4 a partir dos dados do NOAA-NCEP, a ocorrência de La Niña é verificada nos trimestres azuis, enquanto a ocorrência de El Niño é identificada pelos trimestres vermelhos.

Para o Dipolo do Atlântico não há uma disponibilização direta do índice, portanto, o cálculo do dipA seguiu a ideia de Araujo Junior (2014), conforme eq. (8). A partir da eq. (8), definiu-se as dummies para Dipolo Positivo e Negativo do Atlântico nas eq. (9) e (10), respectivamente.

$$dipA = \begin{cases} |Anom\ TSM\ AtlN| + |Anom\ TSM\ AtlS|, & \text{se } Anom\ TSM\ AtlN > 0 \text{ e } Anom\ TSM\ AtlS < 0 \\ -(|Anom\ TSM\ AtlN| + |Anom\ TSM\ AtlS|), & \text{se } Anom\ TSM\ AtlN < 0 \text{ e } Anom\ TSM\ AtlS > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (8)$$

$$dipP = \begin{cases} 1, & \text{se } Anom\ TSM\ AtlN > 0 \text{ e } Anom\ TSM\ AtlS < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (9)$$

$$dipN = \begin{cases} 1, & \text{se } Anom\ TSM\ AtlN < 0 \text{ e } Anom\ TSM\ AtlS > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (10)$$

Onde:

Anom TSM AtlN = anomalia de TSM no Atlântico Norte;

Anom TSM AtlS = anomalia de TSM no Atlântico Sul.

As séries de dipA e ninoA estão presentes na Figura 7, enquanto nino, nina, dipP e dipN, na Figura 8. Pela inspeção visual é possível notar redução da geração eólica, sobretudo, das gerações mínimas na presença de La Niña e Dipolo Negativo do Atlântico, conforme destacado nas Figuras 7 e 8. De modo inverso, observa-se aumento das gerações mínimas na presença de El Niño e Dipolo Positivo do Atlântico.

A vantagem de testar-se variáveis dummies climatológicas reside no fato de ser mais usual e robusta a previsão de especialista sobre a ocorrência ou não dos fenômenos climáticos considerados (El Niño, La Niña, Dipolo Positivo e Dipolo Negativo do Atlântico) para horizontes futuros do que a previsão numérica das anomalias de TSM. De qualquer modo, é possível obter previsões de TSM do Atlântico e Pacífico junto ao NOAA Research (<http://www.esrl.noaa.gov/psd/forecasts/sstlim/>).

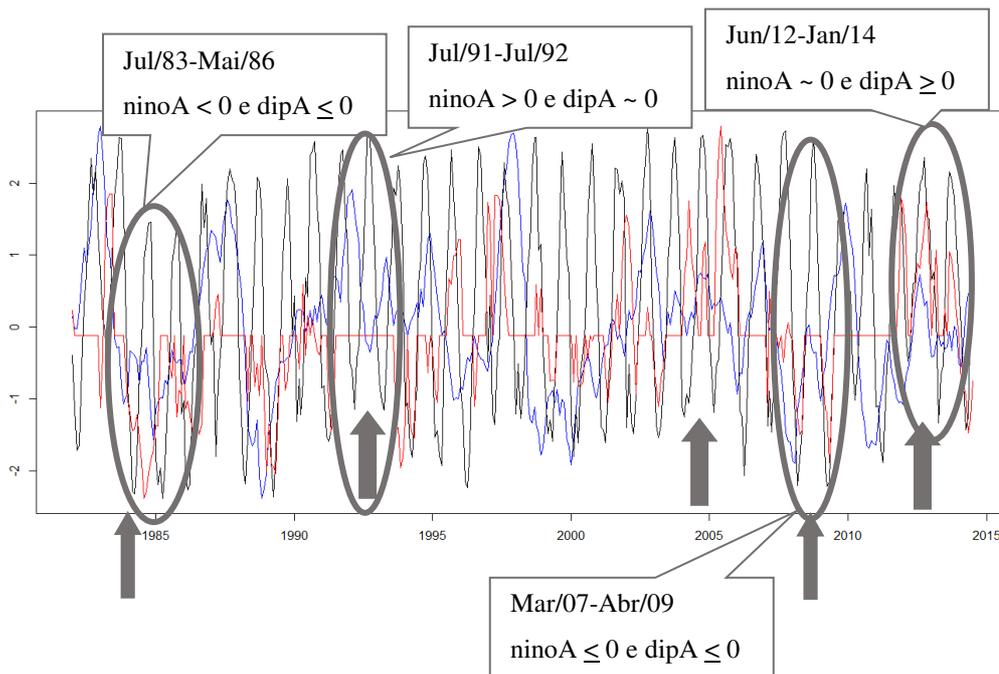


Figura 7 - Histórico de geração eólica (preto), ninoA (azul) e dipA (vermelho); valores do eixo-y referentes a ninoA e dipA

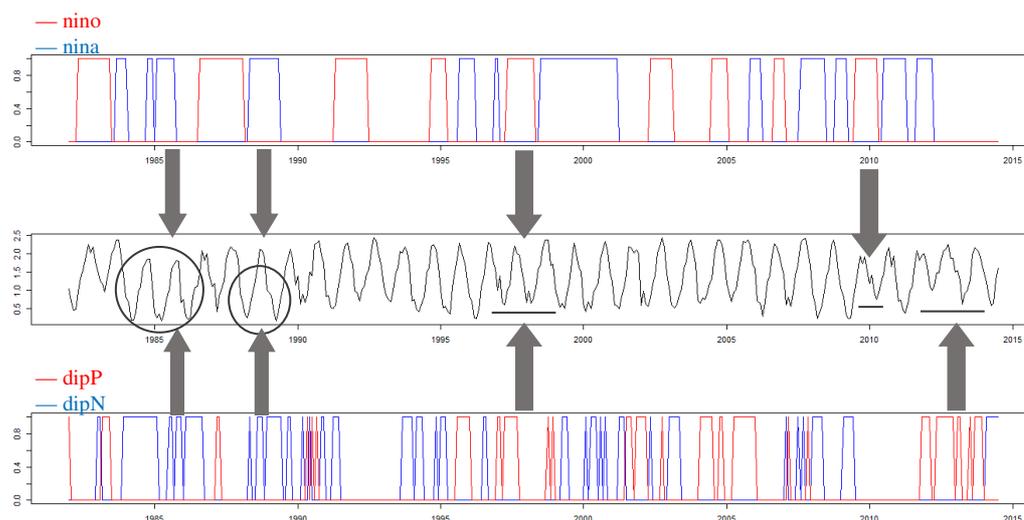


Figura 8 - Histórico de geração eólica (centro) e dummies climatológicas: nino (vermelho, acima), nina (azul, acima), dipP (vermelho, abaixo) e dipN (azul, abaixo)

3.4 Comparação de modelos

Conforme mencionado, considerando a sazonalidade marcante da série, buscou-se, primeiramente, o ajuste de modelos SARMA, AR com 11 variáveis dummies para definição da sazonalidade (ARX-11) e PAR à série de geração eólica. A seleção da ordem do melhor modelo para cada tipo foi baseada nos critérios de informação, seguindo-se o método de Box e Jenkins para ajuste e validação do modelo.

Escolheu-se, então, o melhor modelo entre o SARMA e ARX-11 com base nos critérios de informação e medidas de erro presentes nas eq. (2) a eq. (6), para inclusão das variáveis climatológicas como exógenas. Primeiramente, incluiu-se ninoA e dipA conjuntamente e, posteriormente, as quatro dummies conjuntamente. Observou-se, além dos critérios já mencionados e adequação do modelo, a significância dos parâmetros associados às variáveis climatológicas. Testou-se, ainda, a consideração das variáveis exógenas apenas para determinados meses, conforme sugerido em Oliveira & Costa (2011). No caso, testou-se os períodos de fevereiro a maio e dezembro a maio, correspondentes ao período chuvoso na região, logo, de menor geração, contudo, serão reportados apenas os resultados referente a dezembro a maio por terem sido mais significativos.

Após, passou-se ao ajuste do modelo PAR. Testou-se, também, a existência de diferença estatística entre a acurácia dos melhores modelos, seguindo Diebold & Mariano (1995).

Finalmente, foram simuladas 100 séries de média mensal de geração eólica para o horizonte de 17 meses, ou seja, até dezembro do próximo ano, utilizando-se o melhor modelo sem e com variáveis climatológicas. Cada ponto simulado foi multiplicado por 28 para ter-se uma ideia da geração total do parque.

4 Resultados e discussão

Nesta seção serão apresentadas diversas tabelas e figuras referentes à comparação dos modelos ajustados. A Tabela 2 compara os resultados para os modelos SARMA, ARX-11 e ARMA (apenas como referência) sem variáveis climatológicas. A primeira parte da tabela apresenta o p-valor dos testes de Ljung-Box para os resíduos e o quadrado dos resíduos (Ljung-Box²), bem como para o teste de normalidade de Shapiro-Wilk. A hipótese nula do teste de Ljung-Box é a não existência de autocorrelação entre os resíduos, portanto, para um modelo bem ajustado, espera-se falhar em rejeitar a hipótese nula (p-valores elevados). No caso do Ljung-Box², a hipótese nula é a não existência de autocorrelação entre o quadrado dos resíduos, cuja existência sugeriria a presença de heteroscedasticidade. Mais uma vez, para um modelo bem ajustado, espera-se falhar em rejeitá-la. Já a hipótese nula do teste de Shapiro-Wilk é que os dados possuem distribuição normal, portanto, para um modelo bem ajustado, deve-se falhar em rejeitá-la. A segunda parte apresenta os valores dos critérios de informação e as terceira e quarta, as medidas de erro, sendo que na terceira parte as medidas de erro são calculadas para amostra completa (*in sample*) e, na quarta parte, apenas para os últimos 19 meses estimados como fora da amostra (*out of sample*).

Modelo	Auto.Arima: SAR (3)(2)[12]	ARMA(5,5)	SARMA(2,0)(1,1)[12]	ARX(2)-11
p-valor dos Testes				
Ljung-Box (autocorrelação resíduos)	0,5004	0,4150	0,7409	0,7776
Ljung-Box ² (autocorrelação resíduos ²)	0,1497	0,4734	0,0490	0,2187
Shapiro-Wilk (normalidade)	0,3670	0,1702	0,6102	0,1149
CrITÉrios de Infomação				
AIC	7,72	-113,50	-89,23	-140,59
BIC	35,51	-65,88	-65,41	-81,06
Medidas de erro (in sample)				
RMSE	0,2345	0,1994	0,2020	0,1944
MAE	0,1869	0,1551	0,1599	0,1510
MAPE	21,33%	16,99%	17,84%	16,73%
Medidas de erro (out of sample - 19 meses)				
RMSE	0,2819	0,2736	0,2767	0,2838
MAE	0,2233	0,2075	0,2053	0,2111
MAPE	23,64%	17,41%	16,33%	16,76%

Tabela 2 - Comparação de modelos autorregressivos sem variáveis climatológicas

O primeiro modelo da tabela SAR(3)(2)[12] foi obtido pelo ajuste automático do programa R (função Auto.Arima), contudo, mostrou-se inferior aos demais quanto aos critérios de informação e medidas de erros. O modelo ARX(2)-11 obteve o melhor desempenho, exceto ao serem consideradas as medidas de erro *out of sample*, para as quais os modelos ARMA (5,5) e SARMA(2,0)(1,1)[12] tiveram melhor desempenho. Sobre o modelo SARMA(2,0)(1,1)[12] há apenas que ser ter certa cautela, pois a teste Ljung-Box² foi rejeitado a nível de significância de 5%. Ao comparar os modelos dois a dois pelo teste de Diebold-Mariano para o horizonte de 19 meses (*out of sample*) e de 12 meses (*in sample*), obteve-se que:

- i. a acurácia do modelo ARX(2)-11 é maior que a do modelo SAR(3)(2)[12] ao nível de 1% de significância;
- ii. a acurácia do modelo ARX(2)-11 é maior que a do modelo SARMA(2,0)(1,1)[12] ao nível de 5% de significância;
- iii. a acurácia do modelo ARX(2)-11 é maior que a do modelo ARMA(5,5) ao nível de 2% de significância.

Testou-se, ainda, a comparação da média de geração eólica obtida com a série real pelo teste ANOVA (GUO et al., 2011). Para os quatros modelos a hipótese de médias iguais não foi rejeitada. Em complementação, foi realizado o teste *post hoc* de Turkey, pelo qual não foi possível distinguir um modelo de outro, conforme comparação 2 a 2 dos modelos na Tabela 3, onde WP é a série original de geração eólica. No teste de Turkey a hipótese nula é de igualdade das médias.

Modelos	diferença	mínimo	máximo	p-valor
ARX-11-ARMA	-0,0007976197	-0,02194893	0,02035369	0,9999746

SAR-ARMA	-0,0019876773	-0,02313898	0,01916363	0,9990457
SARMA-ARMA	-0,0096727427	-0,03082405	0,01147856	0,7225287
WP-ARMA	-0,0006821295	-0,02183344	0,02046918	0,9999864
SAR-ARX-11	-0,0011900576	-0,02234136	0,01996125	0,9998749
SARMA-ARX-11	-0,0088751230	-0,03002643	0,01227618	0,7819709
WP-ARX-11	0,0001154902	-0,02103582	0,02126680	1,0000000
SARMA-SAR	-0,0076850654	-0,02883637	0,01346624	0,8589116
WP-SAR	0,0013055478	-0,01984576	0,02245685	0,9998193
WP-SARMA	0,0089906132	-0,01216069	0,03014192	0,7737065

Tabela 3 - Teste de Turkey para modelos sem variáveis climatológicas

Apesar de não ser possível distinguir os modelos pelo teste de Turkey, observou-se p-valor mais elevado para o modelo ARX(2)-11 quando comparado à série original, reforçando os resultados da Tabela 2 e do teste de Diebold-Mariano. Portanto, a inclusão de variáveis climatológicas foi realizada no modelo ARX(2)-11 e os primeiros resultados são apresentados nas Tabelas 4 e 5.

Para sinalizar o uso das variáveis apenas no período de dezembro a maio foi utilizado * após a sigla da variável nas Tabelas 4 e 5. Além disso, essas tabelas apresentam uma quinta parte na qual consta a significância das variáveis climatológicas, com p-valor do teste t para hipótese nula de que o coeficiente associado a elas é nulo. Ao lado de cada variável consta a indicação geral da significância observada, de modo que: ¹ representa significância a 1%, ² a 5%, ³ a 10% e ⁴ quer dizer que a variável não foi significativa.

Modelo	ARX(2) - 13 Anomalias	ARX(2) -15 Dummies	ARX(2) - 15 Dummies*
p-valor dos Testes			
Ljung-Box (autocorrelação resíduos)	0,4817	0,5704	0,4214
Ljung-Box ² (autocorrelação resíduos ²)	0,3541	0,5482	0,5949
Shapiro-Wilk (normalidade)	0,0844	0,1432	0,3510
Crîtérios de Infomação			
AIC	-157,33	-148,38	-157,17
BIC	-89,86	-72,97	-81,71
Medidas de erro (in sample)			
RMSE	0,1894	0,1905	0,1884
MAE	0,1494	0,1494	0,1485
MAPE	16,37%	16,51%	16,36%
Medidas de erro (out of sample - 19 meses)			
RMSE	0,3097	0,3011	0,2865
MAE	0,2419	0,2383	0,2151
MAPE	18,96%	18,94%	17,50%
p-valor significância variáveis climatológicas			
ninoA ³	0,0853		
dipA ¹	0,0000		
nino ²		0,0424	0,0282
nina ⁴		0,5574	0,6261
dipP ¹		0,0031	
dipN ⁴		0,1466	
dipP* ¹			0,0007
dipN* ²			0,0203
dipA* ¹			

Tabela 4 - Comparação de modelos autorregressivos com variáveis climatológicas (parte 1)

Modelo	ARX(2) - 14 Dummies*	ARX(2) - 13 nino dipA*	ARX(2) - 12 dipA*
p-valor dos Testes			
Ljung-Box (autocorrelação resíduos)	0,4141	0,6452	0,7204
Ljung-Box ² (autocorrelação resíduos ²)	0,5962	0,4352	0,3534
Shapiro-Wilk (normalidade)	0,3697	0,3165	0,2723
Crîtérios de Infomação			
AIC	-158,94	-161,94	-159,34
BIC	-87,50	-94,48	-95,84
Medidas de erro (in sample)			
RMSE	0,1885	0,1882	0,1893
MAE	0,1484	0,1483	0,1498
MAPE	16,33%	16,12%	16,34%
Medidas de erro (out of sample - 19 meses)			
RMSE	0,2878	0,2920	0,2936
MAE	0,2161	0,2185	0,2198
MAPE	17,59%	17,37%	17,50%
p-valor significância variáveis climatológicas			
ninoA ³			
dipA ¹			
nino ²	0,0229	0,0348	
nina ⁴			
dipP ¹			
dipN ⁴			
dipP* ¹	0,0007		
dipN* ²	0,0199		
dipA* ¹		0,0000	0,0000

Tabela 5 - Comparação de modelos autorregressivos com variáveis climatológicas (parte 2)

Pelas Tabelas 4 e 5 observou-se que a anomalia de TSM no Niño 3.4 (ninoA) foi significativa apenas a 10% e que a ocorrência de La Niña (nina) não foi significativa. Tanto para a diferença de anomalia de TSM no Atlântico (dipA) quanto para os Dipolos Positivo (dipP) e Negativo (dipN) do Atlântico, observou-se melhora da significância das variáveis, das medidas de erro e dos critérios de informação ao restringir-se a influência das variáveis ao meses de dezembro a maio. Com base nessas medidas, o modelo que apresentou melhor desempenho foi o AR(2)-13 nino dipA*, ou seja, o modelo AR(2)-11 apresentado anteriormente com inclusão da dummy de El Niño e da diferença de anomalia de TSM no Atlântico apenas nos meses de dezembro a maio. Contudo, esse modelo não apresentou a melhor desempenho ao serem observadas as medidas de erro *out of sample*, obtendo melhor resultado nesse caso, o modelo AR(2)-15 Dummies*, ou seja, o modelo AR(2)-11 com inclusão das 4 dummies climatológicas, mas sendo as dummies dipP e diN consideradas apenas de dezembro a maio.

Conforme feito anteriormente, os modelos foram comparados com auxílio do teste de Diebold-Mariano, obtendo-se que a acurácia dos modelos com variáveis exógenas é a mesma, ou seja, não foi possível distinguir a acurácia entre eles. Contudo, ao compará-los com o modelo AR(2)-11, obteve-se que:

- i. a acurácia dos modelos ARX(2)-13 Anomalias, ARX(2)-13 nino dipA* e ARX(2)-12 dipA* é maior que a do modelo ARX(2)-11 ao nível de 1% de significância;
- ii. a acurácia dos modelos ARX(2)-15 Dummies, ARX(2)-15 Dummies*, ARX(2)-14 Dummies* é maior que a do modelo ARX(2)-11 ao nível de 5% de significância.

Novamente, pelos testes de ANOVA e Turkey não foi possível obter diferença entre os modelos. A partir do exposto, foram tomados como referência os seguintes modelos: ARX(2)-11, ARX(2)-13 nino dipA* e ARX(2)-15 Dummies*, cujas equações estão presentes em eq. (11) a eq. (13).

ARX(2)-11

$$\begin{aligned}wp_j = & 0,4345 + 0,4221wp_{j-1} + 0,2995wp_{j-2} - 0,5191Jan - 0,7285Fev \\ & - 0,9467Mar - 1,009Abr - 0,7697Mai - 0,3993Jun \\ & - 0,1065Jul + 0,3649Ago + 0,6229Set + 0,5931Out \\ & + 0,4079Nov + \varepsilon_j; \varepsilon_j \sim N(0; 0,0378)\end{aligned}\tag{11}$$

Onde:

wp_j = geração eólica teórica do aerogerado no mês j ;

ε_j = resíduo do modelo no mês j .

ARX(2)-13 nino dipA*

$$\begin{aligned}wp_j = & 0,4898 + 0,3973wp_{j-1} + 0,2818wp_{j-2} - 0,5146Jan - 0,7040Fev \\ & - 0,9149Mar - 0,9765Abr - 0,7344Mai - 0,3836Jun \\ & - 0,0907Jul + 0,3776Ago + 0,6301Set + 0,6002Out \\ & + 0,4149Nov + 0,0866nino + 0,1694dipA \\ & + \varepsilon_j; \varepsilon_j \sim N(0; 0,0354)\end{aligned}\tag{12}$$

ARX(2)-15 Dummies*

$$\begin{aligned}wp_j = & 0,5777 + 0,3997wp_{j-1} + 0,2817wp_{j-2} - 0,5086Jan - 0,6996Fev \\ & - 0,9212Mar - 0,9748Abr - 0,7399Mai - 0,3810Jun \\ & - 0,0876Jul + 0,3811Ago + 0,6350Set + 0,6049Out \\ & + 0,4203Nov + 0,0889nino - 0,0183nina + 0,1291dipP^* \\ & - 0,807dipN^* + \varepsilon_j; \varepsilon_j \sim N(0; 0,0355)\end{aligned}\tag{13}$$

Após ajuste dos modelos não periódicos, foi ajustado o modelo PAR sem variáveis climatológicas à série. Observando os gráficos de autocorrelação periódica (Figura 6), sugere-se a ordem 3 ou 12 para o modelo, sendo a ordem 3 selecionada pelo critério BIC. Ademais, para ordens superiores os pressupostos de adequação do modelo foram rejeitados. O resumo do ajuste do modelo PAR(3) consta na Tabela 6, assim como os dados dos 3 modelos de referência selecionados.

Modelo	ARX(2)-11	ARX(2) - 15 Dummies*	ARX(2) - 13 nino dipA*	PAR (3)
p-valor dos Testes				
Ljung-Box (autocorrelação resíduos)	0.7776	0.4214	0.6452	0.7895
Ljung-Box ² (autocorrelação resíduos ²)	0.2187	0.5949	0.4352	0.1186
Shapiro-Wilk (normalidade)	0.1149	0.3510	0.3165	0.0733
Crítérios de Infomação				
AIC	-140.59	-157.17	-161.94	-123.55
BIC	-81.06	-81.71	-94.48	-107.70
Medidas de erro (in sample)				
RMSE	0.1944	0.1884	0.1882	0.1825
MAE	0.1510	0.1485	0.1483	0.1390
MAPE	16.73%	16.36%	16.12%	15.33%

Tabela 6 - Comparação de modelos autorregressivos não periódicos e periódicos

O modelo PAR(3) obteve melhor desempenho que os demais (Tabela 6), contudo, ao realizar o teste de Diebold-Mariano obteve-se que:

- i. a acurácia dos modelos PAR(3) é maior que a do modelo ARX(2)-11 ao nível de 1% de significância;
- ii. a acurácia dos modelos PAR(3) não é maior que a do modelo ARX(2)-13 nino dipA* ou do modelo ARX(2)-15 Dummies*.

Deste modo, optou-se por realizar as simulações apenas com os modelos de referência definidos anteriormente em função de sua simplicidade. Ainda assim, o ajuste do modelo PAR(3) à série de geração pode ser observado na Figura 9.

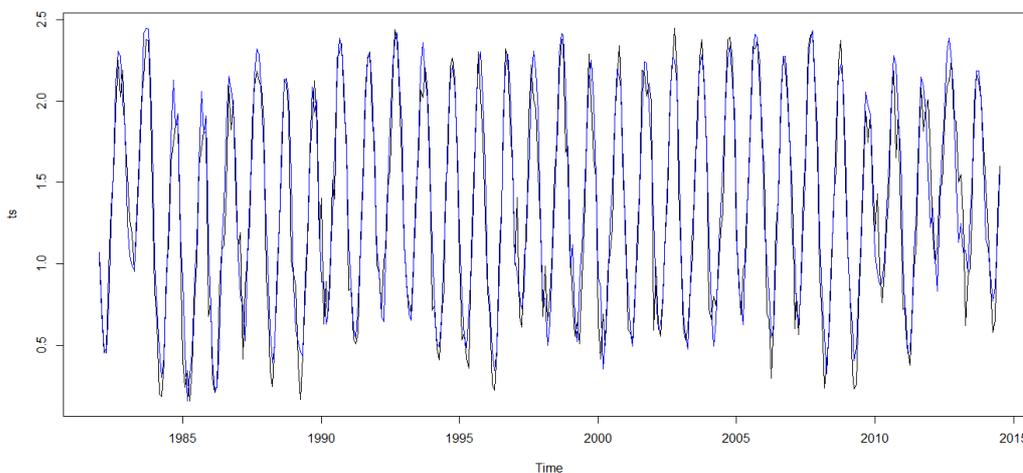


Figura 9 - Série de geração eólica (preto) e série ajustada pelo modelo PAR (azul)

Quanto às simulações, foram realizadas 100 simulações para o horizonte de 17 meses (agosto/2014 a dezembro/2015) com os modelos de referência. Os valores para variáveis climatológicas foram obtidos junto ao NOAA. As Figuras 10 a 12 apresentam essas simulações já multiplicadas pelo total de aerogeradores do parque e limitadas pela potência instalada para se ter uma visão geral da

capacidade de geração. Um breve resumo e comparação das simulações é apresentado na Figura 13.

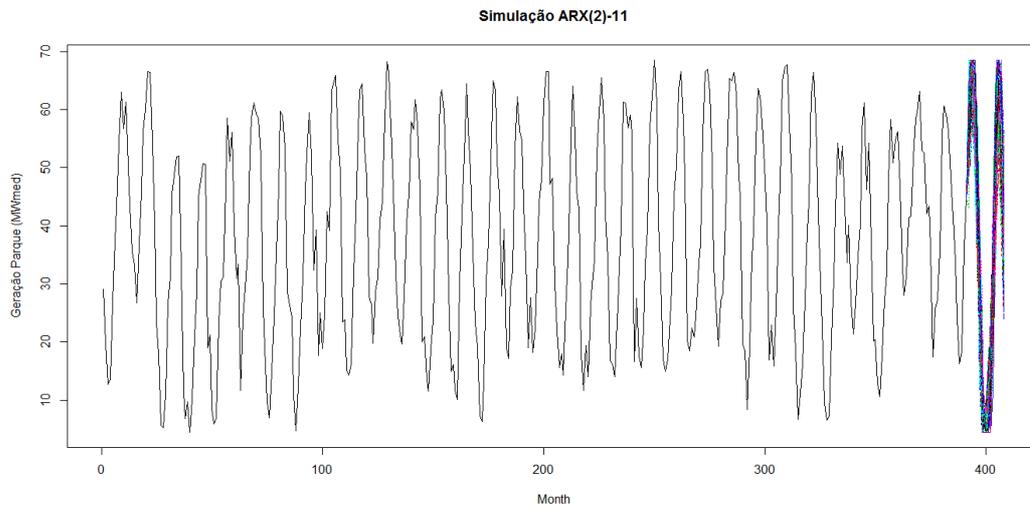


Figura 10 - Simulações de geração do parque com modelo ARX(2)-11

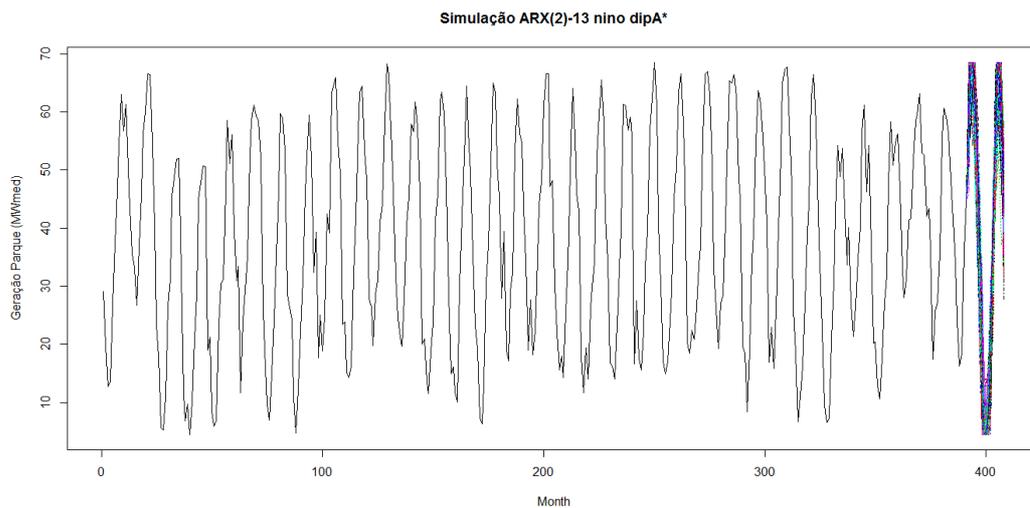


Figura 11 - Simulações de geração do parque com modelo ARX(2)-13 nino dipA*, com presença de El Niño de out/2014 a dez/2015

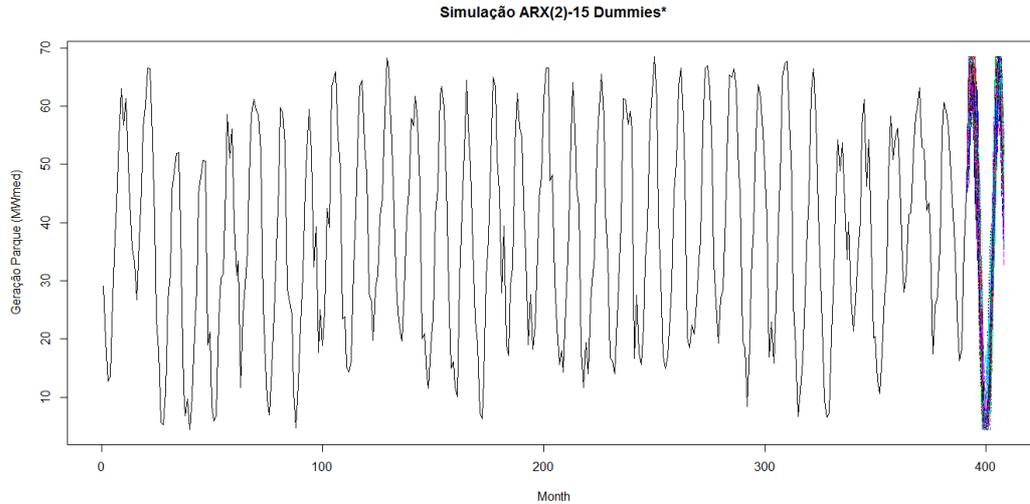


Figura 12 - Simulações de geração do parque com modelo ARX(2)-15 Dummies*, com presença de El Niño de out/2014 a dez/2015

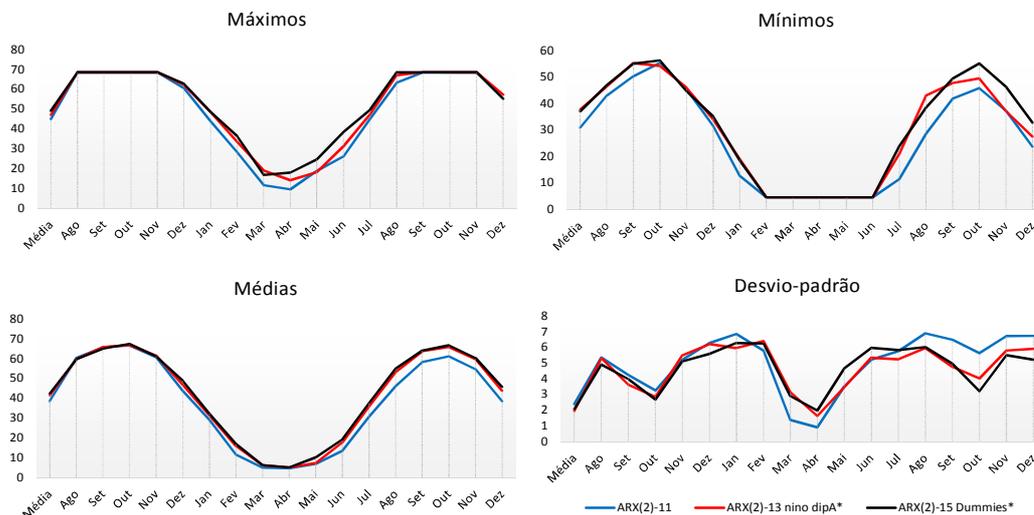


Figura 13 - Estatísticas básicas das simulações por mês

Observando-se a Figura 13 fica claro que a incorporação das variáveis climatológicas afeta os valores máximos de simulação nos períodos de menor geração eólica e, os valores mínimos, no período de maior geração. No caso do período simulado há presença de El Niño de out/2014 a dez/2015, Dipolo Positivo do Atlântico em dez/2014 e Dipolo Negativo do Atlântico de mar/2015 a mai/2015. O efeito do El Niño é marcante nos valores máximos e mínimos das simulações com variáveis climatológicas, chegando a serem observadas diferenças da ordem 30% a 50% em relação ao modelo sem essas variáveis, corroborando com a importância da inclusão das variáveis climatológicas.

5 Conclusão

O objetivo deste estudo era obter modelos autorregressivos adequados para previsão e simulação da média mensal de geração eólica no horizonte anual. Em resposta à primeira pergunta: “Qual(is) modelo(s) autorregressivo(s) são adequados para modelagem da média mensal de geração eólica?”, pode-se dizer que tanto o modelo SARMA(2,0)(1,1)[12], ARMA (5,5), ARX(2)-11, PAR(3), quanto os modelos com variáveis climatológicas são adequados para modelagem, contudo, dada a característica sazonal/periódica da série, o modelo ARMA(5,5) é conceitualmente menos adequado.

Em relação à segunda pergunta: “Qual(is) modelo(s) autorregressivo(s) adequados para modelagem da média mensal de geração eólica são mais precisos?”, obteve-se que os modelos com variáveis climatológicas e o PAR(3) são mais precisos, seguidos pelo ARX(2)-11.

Por fim, a terceira pergunta: “Qual o impacto da incorporação de variáveis climatológicas ao(s) modelo(s)?”, pode ser respondida sobre diferentes perspectivas. Primeiramente, a incorporação das variáveis climatológicas agregou capacidade preditiva ao modelo ARX(2)-11 e mostrou que em simulações com a presença dos fenômenos modelados, a não incorporação das variáveis pode acentuar ou mascarar eventos extremos de geração. Dentre as variáveis testadas, a ocorrência de La Niña foi não significativa, apesar do sinal do parâmetro ser negativo, conforme esperado. Dentre as variáveis significativas, a diferença de anomalia de TSM no Atlântico (Dipolo do Atlântico) foi a mais significativa, também, conforme esperado, especialmente, ao ser considerada apenas de dezembro a maio, período em que realmente está associada ao posicionamento da ZCIT e ocorrência de chuvas. Outra conclusão relevante sobre as variáveis climatológicas é o fato da simples consideração de dummies para identificação da ocorrência dos fenômenos já bastar para agregar acurácia ao modelo.

Uma consideração final a ser feita é que o modelo PAR(3) foi considerado igualmente preciso aos modelos AR(2)-11 com variáveis climatológicas, contudo, não foi testada a incorporação das variáveis ao modelo PAR, o que, potencialmente, melhoraria a sua capacidade preditiva. Apesar da complexidade dessa incorporação, o teste é válido para avaliação mais completa dos modelos periódicos.

6 Referências bibliográficas

AJAYI, O. O.; FAGBENLE, R. O.; KATENDE, J. Wind Profile Characteristics and Econometrics Analysis of Wind Power Generation of a Site in Sokoto State, Nigeria. **Energy Science and Technology**, v. 1, n. 2, p. 54-66, 2011.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19 n. 6, p. 716-72, 1974.

ARAGÃO, J. O. R. O impacto do ENSO e do Dipolo do Atlântico no Nordeste do Brasil. **Bull. Inst. Fr. Études andines**, v. 27, n. 3, p. 839-844, 1998.

ARAUJO JUNIOR, L. M. et al. Avaliação dos recursos eólicos simulado no Estado do Ceará: um estudo de caso para o El Niño 97/98 e para La Niña 98/99. **Revista Brasileira de Meteorologia**, v. 29, n. 1, p. 139-152, 2014.

ARCHER, C. L.; JACOBSON, M. Z. Geographical and seasonal variability of the global “practical” wind resources. **Applied Geography**, v. 45, p. 119-130, 2013.

BARTHELMIE, R. J.; MURRAY, F.; PRYOR, S. C. The economic benefit of short-term forecasting for wind energy in the UK electricity market. **Energy Policy**, v. 36, n. 5, p. 1687-1696, 2008.

BIG Banco de Informações de Geração. Disponível em: <<http://www.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>> Acesso em: 06 nov. 2014.

BOX, G. E. P. et al. **Time series analysis: forecasting and control**. New Jersey: John Wiley & Sons, 2015.

BROWN, B. G.; KATZ, R. W.; MURPHY, A. H. Time series models to simulate and forecast wind speed and wind power. **Journal of climate and applied meteorology**, v. 23, p. 1184-1195, 1984.

CAPORIN, M.; PRÉS, J. Modelling and forecasting wind speed intensity for weather risk management. *Computational Statistics and Data Analysis*, v. 56, p. 3459-3476, 2012.

CERQUEIRA, H. D. V. **Modulação da temperatura da superfície do mar do Pacífico e Atlântico Tropical na precipitação no Estado da Paraíba**. Campina Grande, 2010. 112p. Dissertação (Mestrado em Meteorologia) - Centro de Tecnologia e Recursos Naturais, Universidade Federal de Campina Grande.

DALBEM, M. C.; BRANDÃO, L. E. T.; GOMES, L. L. Can the regulated market help foster a free market for wind energy in Brazil? **Energy Policy**, v. 66, p. 303-311, 2014.

DIEBOLD, F. X.; MARIANO, R. S. Comparing predictive accuracy. **Journal of Business and Economic Statistics**, v. 13, p. 253-263, 1995.

DONGMEI, Z.; YUCHEN, Z.; XU, Z. Research on wind power forecasting in wind farms. In: Power Engineering and Automation Conference (PEAM), 2011 IEEE. **Proceedings... IEEE**, 8-9 Sept. 2011, v. 1, p. 175-178,

ENFIELD, D. B. Relationships of inter-American rainfall to tropical Atlantic and Pacific SST variability. **Geophysical Research Letters**, v. 23, n. 23, p 3305-3308, 1996.

FOLEY, A. M. et al. Current methods and advances in forecasting of wind power generation. **Renewable Energy**, v. 37, n. 1, p. 1-8, 2012.

FRANSES, P. H.; VAN DIJK, D. The forecasting performance of various models for seasonality and nonlinearity for quarterly industrial production. **International Journal of Forecasting**, v. 21, n. 1, p. 87-102, 2005.

GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, v. 22, p. 443-473, 2006.

GRAMBSCH, P.; STAHEL, W. A. Forecasting demand for special telephone services: A case study. **International Journal of Forecasting**, v. 6, p. 53-64, 1990.

GUO, Z. et al. A corrected hybrid approach for wind speed prediction in Hexi Corridor of China. **Energy**, v. 36, p. 1668-1679, 2011.

HARRIS, J. L.; LIU, L. M. Dynamic structural analysis and forecasting of residential electricity consumption. **International Journal of Forecasting**, v. 9, p. 437-455, 1993.

JUNG, J.; BROADWATER, R. P. Current status and future advances for wind speed and power forecasting. **Renewable and Sustainable Energy Reviews**, v. 31, p. 762-777, 2014.

KARKI, R. et al. A Simplified Wind Power Generation Model for Reliability Evaluation. **IEEE Transactions on Energy Conversion**, v. 21, n. 2, p. 533-540, 2006.

LEI, M. et al. A review of wind speed and power generated power. **Renewable and Sustainable Energy Reviews**, v. 13, p. 915-920, 2009.

LIRA, M. A. T.; SILVA, E. M.; ALVES, J. M. B. Estimativa dos recursos eólicos no litoral cearense usando a teoria da regressão linear. **Revista Brasileira de Meteorologia**, v. 26, n. 3, p. 349-366, 2011.

LUZ, C. P. M. S.; GOMES, L. L.; BRANDÃO, L. E. T. Análise da dinâmica do Mercado a termo de energia elétrica no Brasil. **Revista Brasileira de Gestão de Negócios**, v. 14, n. 44, p. 314-334, 2012.

MILLIGAN, M. R.; MILLER, A. H.; CHAPMAN, F. Estimating the economic value of wind forecasting to utilities. Golden, CO: **National Renewable Energy Laboratory**, 1995.

NOAA-NCEP Climate Diagnostics Center. Monitoring and Data. Disponível em: <http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ensyears.shtml> Acesso em: 2 dez. 2014.

NOAA-NCEP Climate Diagnostics Center. Monthly Atmospheric and SST Indices. Disponível em: <<http://www.cpc.ncep.noaa.gov/data/indices/sstoi.atl.indices>> Acesso em: 2 dez. 2014.

NOAA-NCEP Climate Diagnostics Center. Monthly Atmospheric and SST Indices. Disponível em: <<http://www.cpc.ncep.noaa.gov/data/indices/sstoi.indices>> Acesso em: 31 jan. 2015.

NOAKES, D. J.; MCLEOD, A. I.; HIPEL, K. W. Forecasting monthly riverflow time series. **International Journal of Forecasting**, v. 1, p. 179-190, 1985.

NOVALES, A.; FRUTO, R. F. Forecasting with time periodic models: A comparison with time invariant coefficient models. **International Journal of Forecasting**, v. 13, p. 393-405, 1997.

OLIVEIRA, J. L.; COSTA, A. A. Estudo de variabilidade do vento em escala sazonal sobre o nordeste brasileiro utilizando o RAMS: os casos de 1973-1974 e 1982-1983. **Revista Brasileira de Meteorologia**, v. 26, n. 1, p. 53-66, 2011.

PENG, L. V.; YUE, L.. Short-term wind speed forecasting based on non-stationary time series analysis and ARCH model. In: International Conference on Multimedia Technology (ICMT), 2011. **Proceedings...** IEEE, 2011. p. 2549-2553.

PREEZ, J.; WITT, S. F. Univariate versus multivariate time series forecasting: An application to international tourism demand. **International Journal of Forecasting**, v. 19, p. 435-451, 2003.

SCHWARTZ, G. E. Estimating the dimension of a model. **Annals of Statistics**, v. 6, n. 2, p. 461-464, 1978.

SONDEREGGER, J. **Performance of long-term correction at wind power development**: An analysis of results from different reanalysis data sets. Göteborg, Sweden, 2011. 38p. Master of Science Thesis (Master Degree Program Industrial Ecology for a Sustainable Society) - Department of Energy and Environment, Chalmers University of Technology.

TSAY, R. S. **Analysis of financial time series**. 3. ed. New Jersey: John Wiley & Sons, 2010.

TUKEY, J.W. **The problem of multiple comparisons**. Mimeographs Princeton University, Princeton, New Jersey, 1953

WANG, M. D.; QIU, Q. R.; CUI, B. W. Short-term wind speed forecasting combined time series method and arch model. In: International Conference on Machine Learning and Cybernetics (ICMLC), 2012. **Proceedings...** IEEE, 2012. p. 924-927.

WELLER, B. R. National indicator series as quantitative predictors of small region monthly employment levels. **International Journal of Forecasting**, v. 5, p. 241-247, 1989.

WELLS, J. M. Modelling seasonal patterns and long-run trends in U.S. time series. **International Journal of Forecasting**, v. 13, p. 407-420, 1997.

ZHANG, Y.; WANG, J.; WANG, X. Review on probabilistic forecasting of wind power generation. **Renewable and Sustainable Energy Reviews**, v. 32, p. 255-270, 2014.