

Fator de capacidade da geração eólica na região Nordeste: um estudo com dados de reanálises oriundos do MERRA-2 (global)

José F. M. Pessanha*. Victor A. Almeida**
Albert C.G. Melo ***

*Centro de Pesquisas de Energia Elétrica, Rio de Janeiro, Universidade do Estado do Rio de Janeiro Brasil, (e-mail: francisc@cepel.br)

** Centro de Pesquisas de Energia Elétrica, Rio de Janeiro, Brasil, (e-mail: andrade@cepel.br)

*** Centro de Pesquisas de Energia Elétrica, Rio de Janeiro, , Universidade do Estado do Rio de Janeiro Brasil, (e-mail: albert@cepel.br)}

Abstract: The introduction of wind energy has demanded the improvement of practices and methodologies used in the operation and planning of the Brazilian Interconnected Power Systems (BIPS). However, despite the significant participation of wind generation in the BIPS, the public dissemination of data on wind farms in the BIPS is still limited, in particular, the availability of anemometric records. To mitigate the effects of such a limitation, reanalysis data should be considered. In this article, we present the results of a study carried out using reanalysis data from MERRA-2 (global) to estimate capacity factors, on an hourly and monthly basis, in the Brazilian Northeast.

Resumo: A introdução da energia eólica tem demandado o aperfeiçoamento das práticas e metodologias utilizadas na operação e no planejamento do Sistema Interligado Nacional (SIN). Contudo, apesar da participação expressiva da geração eólica no SIN, a divulgação pública de dados de aproveitamentos eólicos no SIN ainda é limitada, em especial, a disponibilização de registros anemométricos. Para mitigar os efeitos de tal limitação deve-se considerar dados de reanálises. Neste artigo, apresentam-se os resultados de um estudo realizado a partir de dados de reanálises oriundos do MERRA-2 (global) para estimação de fatores de capacidade, em bases horárias e mensais, no Nordeste brasileiro.

Keywords: wind power, wind speed, factor analysis, factor capacity, K-means.

Palavras-chaves: energia eólica, velocidade do vento, análise fatorial, fator de capacidade, K-means.

1. INTRODUÇÃO

A localização privilegiada do Nordeste brasileiro na Zona de Convergência Intertropical (ZCIT) confere características excepcionalmente favoráveis para o aproveitamento da energia eólica dos ventos alísios. Assim, desde 2002 com o lançamento do programa de incentivo às fontes renováveis, a região Nordeste tem atraído um grande número de investidores interessados em construir usinas eólicas e atualmente, segundo a Associação Brasileira de Energia Eólica, a região Nordeste é responsável por cerca de 85% da produção de energia eólica no Brasil. Do total de 14.873 MW de capacidade instalada no país, 12.769 MW estão na região Nordeste. Adicionalmente, em termos regionais, a energia eólica representa 35,6% da capacidade instalada em geração de energia elétrica e foi responsável por 51,6% do suprimento do subsistema Nordeste no ano de 2018, conforme Bezerra (2019).

Segundo Silva (2003), do ponto de vista espacial, os regimes de ventos na região Nordeste podem ser organizados em três regiões: litoral Norte-Nordeste, litoral Nordeste-Sudeste e Nordeste continental. O litoral Norte-Nordeste abrange a faixa litorânea entre os estados do Maranhão e Rio Grande do Norte,

sendo que as maiores intensidades de vento são observadas nos estados do Piauí, Ceará e Rio Grande do Norte. Já o litoral Nordeste-Sudeste compreende a faixa litorânea da Paraíba até a Bahia. Vale destacar que para a Empresa de Pesquisa Energética (EPE, 2013) o conjunto das regiões litoral Norte-Nordeste e litoral Nordeste-Sudeste corresponde à região litoral Nordeste. A região do Nordeste continental abrange o interior, onde se destaca uma estreita faixa no Estado da Bahia com elevada intensidade de vento e que corresponde à região da Bahia considerada pela EPE (2013).

No Brasil, a EPE disponibiliza algumas informações sobre a velocidade de vento no sistema de Acompanhamento de Medições Eólicas (AMA). Embora interessantes, os dados disponibilizados não apresentam resoluções espaciais e temporais necessárias para a realização de análises mais sofisticadas e abrangentes como as apresentadas em Lisboa et al. (2019) e Pessanha et al. (2017, 2018, 2019). Diante da dificuldade de obtenção de dados adequados de medições de velocidade de vento para parques eólicos, inclusive aqueles oriundos de projetos vencedores de leilões públicos de compra de energia, uma alternativa consiste em usar dados de reanálises, por exemplo, os dados oriundos do MERRA-2

(global), disponíveis para qualquer local do planeta e com resolução horária em <https://www.renewables.ninja> (STAFFELL e PFENNINGER, 2016).

O presente artigo tem por objetivo apresentar os principais resultados de uma análise exploratória de dados conduzida por meio da aplicação de métodos estatísticos multivariados (JOHNSON e WICHERN, 1998) aos dados de reanálises para as localizações dos parques eólicos na região Nordeste. A análise de dados foi realizada no ambiente R (R CORE TEAM, 2020) e entre os resultados obtidos destacam-se a identificação de regimes de vento na região Nordeste compatíveis com os regimes mencionados por Silva (2003) e pela EPE (2013), assim como os perfis horários e mensais dos fatores de capacidade em cada região. A metodologia utilizada e os resultados apresentados podem ser úteis na geração de informações para a modelagem de aproveitamentos eólicos em estudos de planejamento e operação de sistemas elétricos, especialmente em situações de escassez de dados, ou ainda em algoritmos para tratamento de dados medidos.

2. CORRELAÇÕES ESPACIAIS

Inicialmente, buscou-se examinar a matriz de correlações entre as séries horárias de velocidade de vento a 100 m de altura, oriundas do MERRA-2 (global) para o período de 2001-2017 em 498 parques eólicos que totalizam uma capacidade instalada de cerca de 12.676 MW, agregados em 79 municípios de 8 estados da região Nordeste, conforme a Tabela 1.

Tabela 1. Distribuição dos parques eólicos analisados

Estados	Municípios	Parques eólicos	Capacidade Instalada (MW)
BA	18	142	3.635
CE	16	81	2.055
MA	3	13	329
PB	3	15	157
PE	10	35	784
PI	7	60	1.638
RN	21	151	4.043
SE	1	1	35
Total	79	498	12.676

Fonte: Banco de Informações de Geração – ANEEL

Na Fig. 1, a matriz de correlações, entre as séries horárias de velocidades de vento nos 79 municípios nordestinos, revela a existência de dois, três ou quatro grupos de velocidades espacialmente correlacionadas, um resultado compatível com as regiões identificadas por Silva (2003) e pela EPE (2013). O bloco em azul no quadrante superior esquerdo da matriz de correlações corresponde ao conjunto composto predominantemente por parques eólicos no interior da Bahia. Os demais blocos destacados em azul estão associados com parques eólicos no litoral Norte-Nordeste e no litoral Nordeste-Sudeste (SILVA, 2003).

3. ANÁLISE MULTIVARIADA

Embora a matriz de correlações na Fig. 1 identifique um dos grupos de parques eólicos espacialmente correlacionados, os demais grupos não estão claramente delimitados. A

discriminação dos grupos pode ser alcançada com a aplicação da análise fatorial exploratória (AFE), seguida da análise de agrupamentos (JOHNSON e WICHERN, 1998).

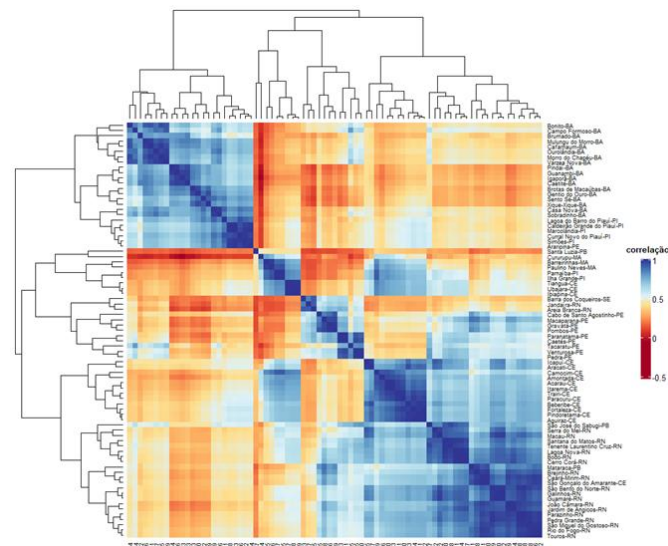


Fig. 1 Matriz de correlações entre as velocidades de vento.

3.1 Análise Fatorial Exploratória

Seja X a matriz de dados de reanálises, em que cada coluna guarda a série temporal da velocidade de vento em uma localidade com parque eólico. Assim, para o caso de n localidades com uma série temporal com q registros horários de velocidade de vento, a matriz X tem dimensões $q \times n$.

A partir da matriz X pode-se obter a matriz de covariâncias S entre as velocidades de vento nas n localidades. A matriz S tem dimensões $n \times n$ e cada elemento S_{ij} contém a covariância entre as velocidades de vento nas localidades i e j .

A AFE é uma técnica para redução da dimensionalidade de dados na qual admite-se que a velocidade do vento x_i em cada localidade i seja expressa em função da soma dos efeitos de m ($m < n$) regimes eólicos (fatores latentes $F_j \forall j=1,m$) mais uma componente específica ε_i da i -ésima localidade:

$$x_i = l_{i1}F_1 + l_{i2}F_2 + \dots + l_{im}F_m + \varepsilon_i \quad \forall i=1,n \quad (1)$$

em que l_{ij} é o peso do i -ésima localidade no j -ésimo fator latente.

A partir da combinação linear em (1) e da premissa de independência entre F_1, F_2, \dots, F_m e $\varepsilon_i \forall i=1,n$ obtém-se a seguinte decomposição da matriz de covariâncias:

$$S = L^T L + \Phi \quad (2)$$

em que L é uma matriz de dimensões $n \times m$, na qual cada linha guarda os pesos de cada localidade i nos m fatores latentes, i.e., cada linha é formada pelo elementos $l_{i1}, \dots, l_{im} \forall i=1,n$.

Em (2), a parcela $L^T L$ é denominada comunalidade e captura a contribuição dos m regimes de vento para a variabilidade das velocidades de vento nas n localidades. Já a parcela Φ é uma matriz diagonal, cujos elementos capturam a variabilidade da

velocidade de vento em cada localidade que não é explicada pelos m regimes de vento.

A estimação do modelo em (1) e (2) pode ser realizada por meio do cálculo dos n autovetores e_1, e_2, \dots, e_n e respectivos autovalores $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ da matriz S . Adicionalmente, a soma dos autovalores é igual ao traço da matriz S , i.e., a variância total dos ventos nas n localidades analisadas. A determinação do número de fatores latentes m e a formação da matriz L consiste em encontrar um valor para m tal que $S \cong L^T L$.

Pelo Teorema da Decomposição Espectral (JOHNSON e WICHERN, 1998) tem-se que:

$$S = \lambda_1 e_1^T e_1 + \lambda_2 e_2^T e_2 + \dots + \lambda_n e_n^T e_n \quad (3)$$

Dado que $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$, os primeiros autovalores concentram a maior parcela da variância total, então os primeiros termos da soma em (3) são os que mais contribuem para a formação da matriz S . Assim, para que $L^T L$ forneça uma boa aproximação da matriz S , o número de fatores m deve satisfazer a seguinte condição (JOHNSON e WICHERN, 1998):

$$100\%(\lambda_1 + \lambda_2 + \dots + \lambda_m) / (\lambda_1 + \lambda_2 + \dots + \lambda_n) \geq 80\% \quad (4)$$

Definido o número de fatores m , a matriz L pode ser gerada com base nos autovetores de S associados aos primeiros m autovalores:

$$L = [\sqrt{\lambda_1} e_1 \quad \sqrt{\lambda_2} e_2 \quad \dots \quad \sqrt{\lambda_m} e_m] \quad (5)$$

Se a condição em (4) é satisfeita com menos de três fatores ($m \leq 3$) pode-se gerar uma visualização das n localidades com parques eólicos em um sistema de m eixos fatoriais por meio de um mapa que permite a rápida identificação de grupos de parques eólicos espacialmente correlacionados.

3.2 Análise de agrupamentos – K-Means

A análise de agrupamentos (*cluster analysis*) é uma técnica estatística útil na segmentação de um conjunto de n objetos (municípios com parques eólicos), caracterizados por m atributos, em subconjuntos mutuamente exclusivos, denominados *clusters*, de tal forma que os objetos em um mesmo subconjunto sejam semelhantes entre si, mas ao mesmo tempo diferentes dos objetos pertencentes aos outros subconjuntos. Entre os principais métodos de análise de agrupamentos destaca-se o *K-Means* (JOHNSON e WICHERN, 1998).

O *K-Means* classifica o conjunto de objetos em k *clusters*, em que k é um número especificado a priori. O critério utilizado pelo método consiste em minimizar a variabilidade dentro dos agrupamentos, expressa pela soma dos quadrados dos desvios entre as observações e os centroides dos *clusters* nos quais as observações foram alocadas (*Within Sum of Squares - WSS*):

$$WSS = \sum_{j=1}^k \left(\sum_{i, x_i \in C_j} \|x_i - c_j\|^2 \right) \quad (6)$$

em que $x_i, i=1, n$, é o i -ésimo objeto, C_j é o j -ésimo *cluster*, c_j é o centroide do j -ésimo *cluster* e n é o número de objetos a serem classificados.

Cada objeto pertence a apenas um dos k *clusters*, portanto, a classificação dos n objetos pode ser representada por uma matriz binária U de dimensões $n \times k$, onde $u_{ij} = 1$ se o i -ésimo objeto pertence ao j -ésimo *cluster* e $u_{ij} = 0$, caso contrário.

O método *K-Means* pode ser implementado segundo o algoritmo a seguir, onde a matriz U e os centroides dos *clusters* são obtidos de forma iterativa:

- 1) Inicialize os centroides dos *clusters* pelo sorteio de k objetos entre os n a serem classificados.
- 2) Determine a matriz U de acordo com o critério do centroide mais próximo, i.e., aloque cada objeto ao *cluster* com o centroide mais próximo.
- 3) Calcule o valor da função objetivo WSS em (6). Pare se o valor da função estiver abaixo de uma tolerância pré-especificada, se a melhoria em relação à iteração anterior for desprezível ou se o máximo de iterações for alcançado.
- 4) Atualize os centroides dos *clusters* e volte para o passo 2.

3.3 Clusters de municípios com parques eólicos

A aplicação da AFE aos dados de reanálises indica que uma solução com 3 fatores latentes ($m=3$) consegue capturar cerca de 80% da variância total presente nos dados. Adicionalmente, a solução com 3 fatores permite a visualização dos 79 municípios nordestinos analisados, conforme apresentado na Fig. 2, onde as coordenadas dos municípios nos eixos fatoriais correspondem às colunas da matriz L . Ainda na Fig. 2, os três grupos foram identificados com o auxílio do método *K-Means* aplicado às coordenadas dos parques eólicos nos três eixos fatoriais.




Fig. 2 Projeção dos 79 municípios analisados nos eixos fatoriais, seguida da classificação pelo método *K-Means*.

A abordagem empregada neste artigo permite ainda a obtenção da espacialização dos três grupos de parques eólicos na Fig. 3. Os resultados obtidos evidenciam uma configuração compatível com as três regiões indicadas em Silva (2003).

O grupo indicado em verde reúne 24 municípios, predominantemente na Bahia, e que, juntos, totalizam uma capacidade instalada de cerca de 5.248 MW. Já o *cluster* indicado em vermelho abrange 34 municípios pertencentes à região do litoral Nordeste-Sudeste, em especial no Rio Grande do Norte, e possui uma capacidade instalada da ordem de 4.928 MW. Por fim, o grupo indicado em preto é composto por 21 municípios na região do litoral Norte-Nordeste, em especial o Ceará, e reúne uma capacidade instalada igual a 2.500 MW.

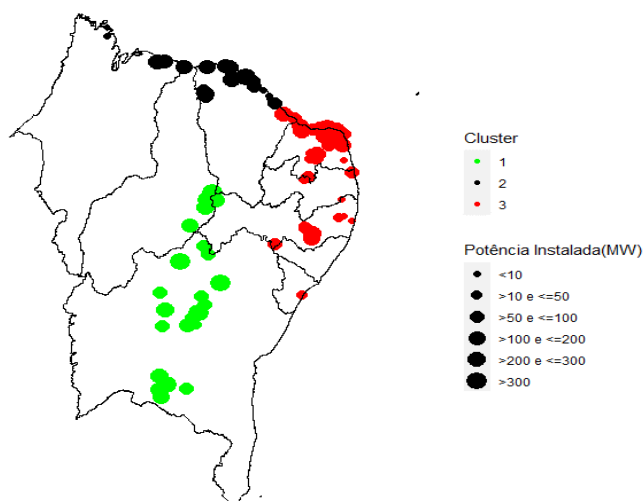


Fig. 3 Mapa dos *clusters* de municípios com eólicas.

4. FATOR DE CAPACIDADE

As estimativas do fator de capacidade (FC) foram calculadas por meio da equação (7) proposta por Jangamshetti e Rau (1999), cuja expressão depende apenas das velocidades características da curva de potência do aerogerador (*cut-in speed* v_p , *rated speed* v_n e *cut-out speed* v_c) e do modelo de Weibull (AMARANTE et al., 2001) utilizado para representar a distribuição de probabilidade da velocidade de vento $f(v)$.

$$FC = \frac{1}{v_n^3} \int_{v_p}^{v_n} v^3 f(v) dv + \int_{v_n}^{v_c} f(v) dv \quad (7)$$

Na estimação do fator de capacidade foram considerados dados de reanálises para as médias horárias da velocidade do vento à 100 m de altura, ao longo do ano de 2017, nas coordenadas geográficas das sedes dos 79 municípios analisados. A partir dos dados de reanálises foi possível estimar os parâmetros de escala (c) e forma (k) que caracterizam a distribuição de Weibull para a velocidade do vento em cada localidade. A estimação foi realizada pelo método dos momentos, conforme ilustrado em Pessanha et al. (2015), no qual as estimativas para c e k devem satisfazer as equações (8) e (9), respectivamente, as equações da média e da variância amostrais da velocidade do vento.

$$\bar{X} = c\Gamma\left(1 + \frac{1}{k}\right) \quad (8)$$

$$S^2 = c^2 \left[\Gamma\left(1 + \frac{2}{k}\right) - \Gamma\left(1 + \frac{1}{k}\right)^2 \right] \quad (9)$$

No que tange ao conjunto de velocidades características da curva de potência foram adotados os mesmos valores para

todos os parques, i.e., $v_p=2$ m/s, $v_n=11$ m/s e $v_c = 25$ m/s. Neste trabalho buscou-se um conjunto de velocidades características que minimizassem os desvios relativos entre as estimativas dos FC mensais e os respectivos valores informados nos Boletins de Geração Eólica do Operador Nacional do Sistema (ONS) para o ano de 2017.

4.1 Fator de capacidade horário

Neste caso, os dados horários de velocidade de vento, relativos a cada município, foram classificados por mês e organizados em matrizes de dimensões (dias do mês) \times 24, e, portanto, cada linha guarda um perfil horário da velocidade do vento. Na sequência, a partir dos dados em cada coluna, foram estimados os parâmetros da distribuição de Weibull para cada hora e calculado o fator de capacidade horário. Como resultado deste procedimento, obtém-se um perfil típico do fator de capacidade para cada localidade em cada mês do ano. Adicionalmente, o perfil do fator de capacidade horário em uma região corresponde à média dos perfis dos respectivos municípios, ponderados pelos valores das respectivas capacidades instaladas. Nas Fig. 4-6 são apresentados os perfis horários do fator de capacidade das localidades (em cinza) e nas regiões (em preto) para cada mês do ano. Os resultados mostram que em boa parte dos parques eólicos o FC alcança valores excepcionalmente elevados em algumas horas do dia.

4.2 Fator de capacidade mensal

Neste caso, os dados horários de velocidade de vento, relativos a cada município, foram classificados por mês e na sequência foram estimados os parâmetros da distribuição de Weibull para cada mês e calculado o respectivo fator de capacidade mensal. Na Tabela 2 são apresentadas estimativas mensais dos fatores de capacidade para as regiões identificadas na Fig. 3.

Tabela 2. Fator de capacidade mensal (%)

Mês	Litoral		Bahia
	Norte-Nordeste	Nordeste-Sudeste	
Jan	33	46	26
Fev	27	37	19
Mar	15	26	18
Abr	20	31	30
Mai	27	33	36
Jun	42	52	50
Jul	51	68	69
Ago	62	61	46
Set	77	78	71
Out	78	69	51
Nov	62	53	26
Dez	48	47	24

A seguir, nas Fig. 7-9 são apresentados os fatores de capacidade mensais para os 79 municípios analisados (em cinza) e as médias mensais para as regiões (em preto).

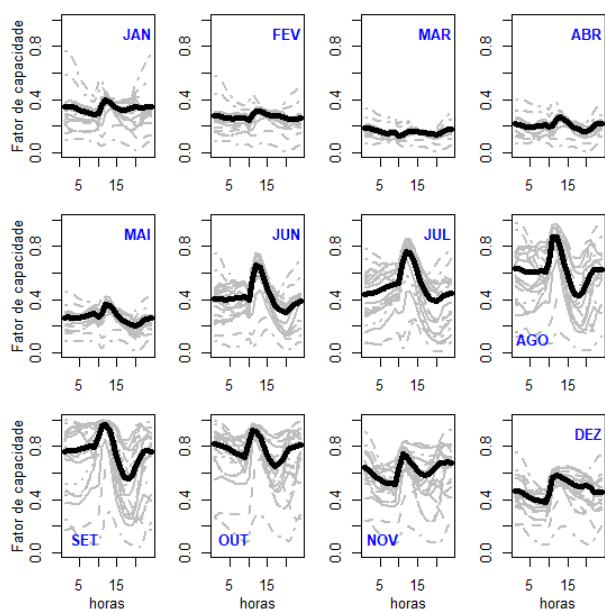


Fig. 4 Perfis horários do FC no litoral Norte-Nordeste.

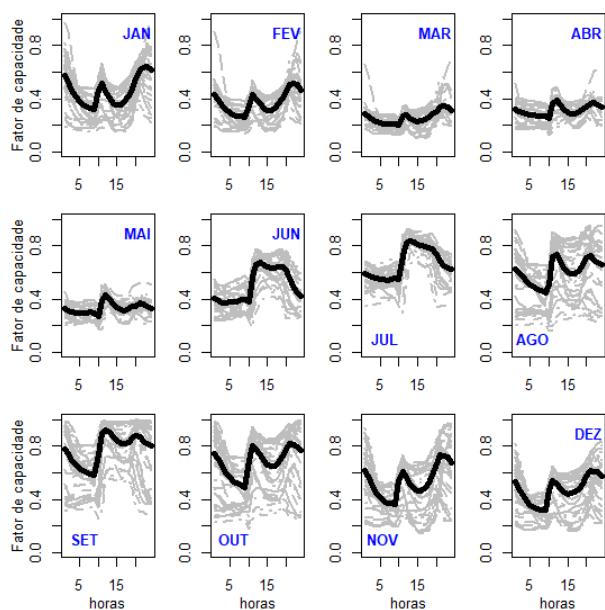


Fig. 5 Perfis horários do FC no litoral Nordeste-Sudeste.

Conforme ilustrado nas Fig. 7-9, o fator de capacidade mensal apresenta diferentes padrões nas três regiões, porém, nos três casos o fator de capacidade tende a ser maior no período entre julho e outubro, uma característica também apresentada pelo fator de capacidade informado pelo ONS para o ano de 2017, conforme ilustrado na Fig. 10. Esta característica revela a complementaridade entre a geração eólica no Nordeste e o regime de vazões no Rio São Francisco (ROCHA et al., 1999), constituindo-se em um importante benefício para a operação do sistema. Na Tabela 3 são apresentados os fatores de capacidade estimados neste trabalho e verificados para o ano de 2017, acompanhados dos respectivos desvios.

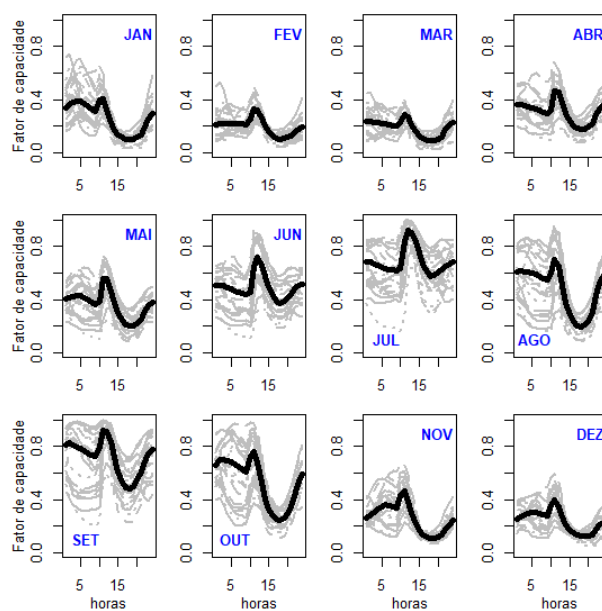


Fig. 6 Perfis horários do FC na região da Bahia.




Fig. 7 Fator de capacidade mensal no litoral Norte-Nordeste.

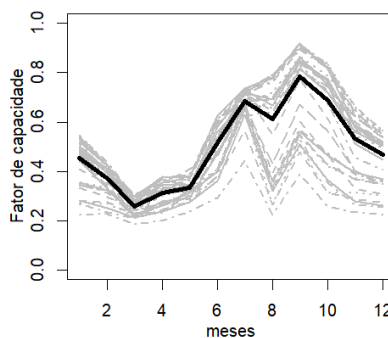


Fig. 8 Fator de capacidade mensal no litoral Nordeste Sudeste.




Fig. 9 Fator de capacidade mensal na região da Bahia.

Tabela 3. Fatores de capacidade estimados e verificados

Mês	Fator de capacidade (%)		Desvio absoluto (%)
	estimado	verificado*	
Jan	34,9	39,7	4,8
Fev	27,6	34,3	6,7
Mar	20,6	25,5	4,9
Abr	28,6	34,3	5,7
Mai	33,1	36,2	3,1
Jun	48,9	47,3	1,6
Jul	65,3	55,4	9,9
Ago	55,0	56,4	1,4
Set	75,0	65,2	9,8
Out	63,4	58,1	5,3
Nov	43,5	47,0	3,5
Dez	37,4	40,2	2,8

Fonte: Boletins Mensais de Geração Eólica – ONS*

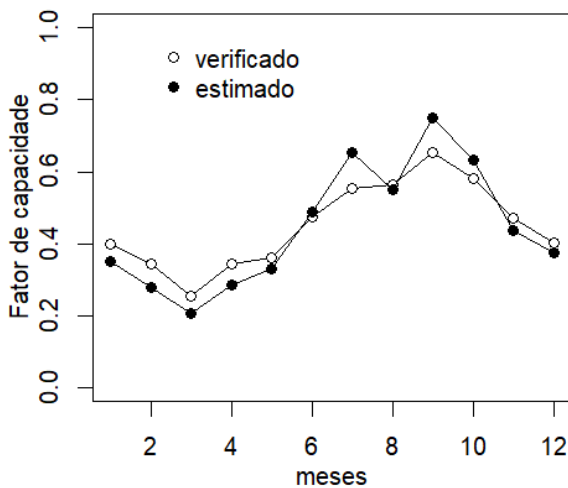


Fig. 10 Fator de capacidade mensal: estimativas e valores verificados em 2017.

5. CONCLUSÕES

A utilização de dados de reanálises é uma alternativa viável diante da dificuldade observada na obtenção de dados de medições de velocidade de ventos nos parques eólicos do SIN. Os resultados apresentados neste trabalho mostram que as análises conduzidas com os dados de reanálises conseguiram identificar os regimes de vento na região Nordeste e permitiram gerar estimativas consistentes para os fatores de capacidade. Resultados ainda melhores podem ser obtidos com informações mais detalhadas dos parques, por exemplo, a curva de potência e as alturas das torres. Por fim, o trabalho evidenciou a necessidade de disponibilização de uma base pública da dados de vento e de geração eólica, com resolução temporal pelo menos horária, e.g., a partir dos projetos vencedores nos leilões públicos de compra de energia elétrica.

REFERÊNCIAS

Amarante, O.A.C., Brower, M., Zack, J., Sá, A.L. (2001). *Atlas do Potencial Eólico Brasileiro*, Centro de Pesquisas de Energia Elétrica, Brasília.

- Bezerra, F.D. (2019). Energia eólica no Nordeste, *Caderno Setorial*, Banco do Nordeste, ano 4, n. 66, Fevereiro.
- EPE - Empresa de Pesquisas Energéticas (2013). Acompanhamento de medições anemométricas – AMA: Caracterização do Recurso Eólico e Resultados Preliminares de sua Aplicação no Sistema Elétrico, Nota Técnica DEA 15/13, Rio de Janeiro, Agosto.
- Jangamshetti, S.H.J., Rau, V.G. (1999). Site matching of wind turbine generators: a case study, *IEEE Transactions on Energy Conversion*, v. 14, n. 4, December, pp.1537-1543.
- Johnson, R.A., Wichern, D.W. (1998) *Applied Multivariate Statistical Analysis*, 4th edition, Prentice Hall.
- Lisboa, M.L.V., Machado, J.G.S., Damázio, J.M., Pessanha, J.F.M., Sabóia, C.H.M., Curty, M.G. (2019). Análise do Impacto da Variabilidade das Fontes Renováveis na Expansão Integrada dos Sistemas Elétrico e de Gás Natural. XXV Seminário Nacional de Produção e Transmissão de Energia Elétrica, Belo Horizonte.
- Pessanha, J.F.M., Oliveira, F.L.C., Souza, R.C. (2015). Teaching Statistical Methods in Engineering Courses Through Wind Power Data, IASE 2015 Satellite Conference, Rio de Janeiro.
- Pessanha, J.F.M., Castellani, V., Almeida, V.A. (2017). Short-Term Wind Power Forecasting Based on Quantile Regression. Brazil Windpower 2017, Rio de Janeiro.
- Pessanha, J.F.M., Melo, A.C.G., Almeida, V.A. (2018) Impact of Wind Speed Correlations on Probabilistic Power Flow by Using Nataf Transformation. Probabilistic Methods Applied to Power Systems, Boise.
- Pessanha, J.F.M., Melo, A.C.G., Bessa, R.J.G.S.B., Almeida, V.A. (2019). Uma metodologia para geração de cenários de produção eólica compatíveis com as correlações espaciais entre os regimes de ventos. XXV Seminário Nacional de Produção e Transmissão de Energia Elétrica, Belo Horizonte.
- R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Rocha, N.A., Amarante, O.C., Schultz, D.J., Sugai, V.B. (1999). Bittencourt, R.M. Estabilização sazonal da oferta de energia através da complementaridade entre os regimes hidrológico e eólico. XV Seminário Nacional de Produção e Transmissão de Energia Elétrica, Foz do Iguaçu.
- Silva, G.R. (2003). Características de vento da região Nordeste, Dissertação de Mestrado, Engenharia Mecânica, Universidade Federal de Pernambuco.
- Staffell, I., Pfenninger, S. (2016). Using Bias-Corrected Reanalysis to Simulate Current and Future Wind Power Output. *Energy* 114, pp. 1224-1239.