

**POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA
MODELOS DE MISTURA****WIND ENERGY POTENTIAL IN NORTHEASTERN BRAZIL: A MIXTURE MODEL APPROACH****POTENCIAL DE ENERGÍA EÓLICA EN EL NORDESTE DE BRASIL: UN ENFOQUE DE
MODELOS DE MEZCLA**

Sóstenes Jerônimo da Silva¹, Débora de Sousa Cordeiro², Sílvio Fernando Alves Xavier Júnior³, Jader da Silva Jale⁴

e747543

<https://doi.org/10.47820/recima21.v7i4.7543>

PUBLICADO: 04/2026

RESUMO

Este artigo tem como objetivo apresentar uma avaliação do potencial de geração de energia eólica em quatro estações do Nordeste do Brasil por meio do ajuste de modelos estatísticos baseados em misturas de distribuições. Foram analisadas séries de velocidade do vento provenientes de quatro estações meteorológicas, representando cada estado da região. A metodologia consistiu na aplicação de um algoritmo capaz de testar diversas combinações de distribuições e selecionar os melhores modelos com base em critérios de informação (AIC, BIC e HQ), métricas de erro (MAE, MSE, RMSE e MAPE) e testes estatísticos de aderência (Anderson-Darling e von Mises), integrados por meio do índice proposto *J-index*. Os resultados indicam que, em localidades com comportamento bimodal, os modelos de mistura apresentam melhor ajuste quando comparados aos modelos univariados, permitindo estimativas mais precisas do potencial eólico. Os maiores valores de potencial foram observados nas estações de Calcanhar (Rio Grande do Norte) e Areia (Paraíba). Conclui-se que a abordagem proposta é eficiente para modelar a variabilidade do vento e constitui uma ferramenta útil para subsidiar o planejamento da geração de energia eólica.

PALAVRAS-CHAVE: Energia Eólica. Modelos de Mistura. Potencial eólico.

ABSTRACT

*This article aims to present an assessment of the wind energy generation potential in four stations in Northeast Brazil through the adjustment of statistical models based on distribution mixtures. Wind speed series from four meteorological stations, representing each state in the region, were analyzed. The methodology consisted of applying an algorithm capable of testing various distribution combinations and selecting the best models based on information criteria (AIC, BIC, and HQ), error metrics (MAE, MSE, RMSE, and MAPE), and statistical goodness-of-fit tests (Anderson-Darling and von Mises), integrated using the proposed *J-index*. The results indicate that, in locations with bimodal behavior, the mixture models show a better fit when compared to univariate models, allowing for more precise estimates of wind potential. The highest potential values were observed at the Calcanhar (Rio Grande do Norte) and Areia (Paraíba) stations. It is concluded that the proposed*

¹ Graduado em Estatística pela UEPB, Pesquisador no Laboratório de pesquisa em fluidos de perfuração – Peflab/UFCG, Campina Grande-PB, Brasil.

² Mestre em Estatística pela UFPE, Doutoranda em programa de Biometria e Estatística Aplicada pela UFRPE, Recife-PE, Brasil.

³ Doutor em Biometria e Estatística Aplicada pela UFRPE, professor na Universidade Estadual da Paraíba, Campina Grande-PB, Brasil.

⁴ Doutor em Biometria e Estatística Aplicada pela UFRPE, professor no Departamento de Estatística e Informática (DEINFO-UFRPE). Recife-PE, Brasil.

approach is efficient for modeling wind variability and constitutes a useful tool to support the planning of wind energy generation.

KEYWORDS: *Wind Energy. Mixing Models. Wind potential.*

RESUMEN

Este artículo tiene como objetivo presentar una evaluación del potencial de generación de energía eólica en cuatro centrales del Nordeste de Brasil a través del ajuste de modelos estadísticos basados en mezclas de distribución. Se analizaron las series de velocidad del viento de cuatro estaciones meteorológicas, representativas de cada estado de la región. La metodología consistió en aplicar un algoritmo capaz de probar diversas combinaciones de distribución y seleccionar los mejores modelos con base en criterios de información (AIC, BIC y HQ), métricas de error (MAE, MSE, RMSE y MAPE) y pruebas estadísticas de bondad de ajuste (Anderson-Darling y von Mises), integradas mediante el índice J-index, propuesto. Los resultados indican que, en ubicaciones con comportamiento bimodal, los modelos de mezcla muestran un mejor ajuste en comparación con los modelos univariados, lo que permite estimaciones más precisas del potencial eólico. Los valores de potencial más altos se observaron en las estaciones de Calcanhar (Rio Grande do Norte) y Areia (Paraíba). Se concluye que el enfoque propuesto es eficiente para modelar la variabilidad del viento y constituye una herramienta útil para respaldar la planificación de la generación de energía eólica.

PALABRAS CLAVE: *Energía Eólica. Modelos de Mezcla. Potencial eólico.*

1. INTRODUÇÃO

A energia eólica, classificada como uma fonte limpa, contribui para a preservação do meio ambiente ao reduzir as emissões de gases de efeito estufa e beneficiar diversos setores da sociedade (Jaber, 2013). Nos últimos 40 anos, a série temporal climática tem apresentado flutuações aleatórias semelhantes a um ruído. No entanto, observa-se uma tendência crescente, refletindo grandes alterações climáticas (Mudelsee, 2019). Nesse contexto, tais mudanças são impulsionadas, em grande parte, por atividades relacionadas à geração de energia elétrica, especialmente pela queima de combustíveis fósseis, que intensifica o efeito estufa. Diante desse cenário, sabe-se que as fontes de energia limpa ainda representam apenas cerca de um quarto da produção mundial de energia, apresentando, contudo, impacto ambiental significativamente inferior quando comparadas aos combustíveis fósseis (ONU, 2024).

A análise da velocidade do vento é fundamental para o planejamento e a expansão da geração eólica, especialmente no Brasil, onde cerca de 13% da energia elétrica é proveniente dessa fonte (ANEEL, 2024). Nesse contexto, a região Nordeste destaca-se como o principal polo de geração eólica do país, concentrando a maior parte da capacidade instalada. Atualmente, o Brasil possui aproximadamente 22.000 MW de capacidade instalada em energia eólica, dos quais mais de 90% estão localizados na região Nordeste. Dos 828 parques eólicos em operação no país, 725 encontram-se nessa região, evidenciando sua relevância estratégica para a matriz energética nacional.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

Entre os estados nordestinos, o Rio Grande do Norte lidera a geração de energia eólica, seguido pela Bahia, Piauí e Ceará. Em conjunto, esses estados foram responsáveis por cerca de 84% da produção nacional nos últimos 12 meses (ENGIE, 2022). Diante desse cenário, o estudo dos padrões de velocidade do vento torna-se essencial para o aprimoramento das tecnologias eólicas e para a otimização da geração de energia.

Nesse contexto, a modelagem estatística da velocidade do vento desempenha papel central na caracterização do recurso eólico. Atualmente, essa modelagem é conduzida, em geral, por duas abordagens principais: paramétrica e não paramétrica. As abordagens paramétricas assumem uma forma funcional previamente definida para a distribuição (como Normal, Weibull ou Log-normal), enquanto as não paramétricas permitem que essa forma seja inferida diretamente dos dados (Wang *et al.*, 2021). Entre os métodos paramétricos, destacam-se as misturas de distribuições, especialmente adequadas para dados multimodais, censurados ou com baixa incidência de vento.

Nesse contexto, Dos Santos *et al.*, (2024) utilizaram misturas de distribuições Weibull para modelar o comportamento do vento em diferentes regiões do Brasil, obtendo bons resultados. De forma complementar, Wang *et al.*, (2021) propuseram um modelo conjunto para velocidade e direção do vento baseado em misturas Weibull e von Mises, com estimação via algoritmo EM e avaliação por AIC, BIC, R^2 e RMSE, evidenciando ganhos de acurácia. Em outra abordagem, Marzouk (2025) aplicou modelos Weibull para estimar a produção anual de energia, enquanto Zhao *et al.*, (2025) destacam a relevância de métodos baseados em aprendizado profundo para capturar a variabilidade espaço-temporal do vento.

Do ponto de vista econômico, a geração eólica apresenta elevado retorno, com impacto estimado de aproximadamente três vezes o valor investido no Produto Interno Bruto (PIB) brasileiro, além de retorno em um período de 10 a 14 meses (ABEEólica, 2022). O setor também contribui para a geração de empregos e apresenta menor impacto ambiental, com movimentação média anual de cerca de R\$36,67 bilhões entre 2011 e 2020.

Diante desse cenário, o presente estudo tem como objetivo avaliar o potencial de geração de energia eólica em quatro estações do Nordeste do Brasil, por meio do ajuste de modelos estatísticos baseados em misturas de distribuições.

2. MÉTODOS

Realizou-se uma pesquisa quantitativa baseada em dados secundários (Shitsuka *et al.*, 2014; Pereira *et al.*, 2018; Risemberg *et al.*, 2026), com uso de modelagem e séries temporais (Nascimento *et al.*, 2015; Costa Neto; Bekman, 2009).



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

2.1. Dados e área em estudo

Os dados de velocidade e direção do vento foram obtidos junto ao Instituto Nacional de Meteorologia (INMET, 2025). O conjunto de dados inclui registros horários de 151 estações meteorológicas, abrangendo todo o território da região Nordeste do Brasil, coletados no período de 2000 a 2023, dos quais foram utilizados para construção dos mapas interpolados. A partir desses mapas serão selecionados os estados com densidade e intensidade de vento. Dessa forma, serão selecionadas quatro estações meteorológicas localizadas nesses estados, escolhendo-se uma estação representativa por estado, com o objetivo de representar as áreas de maior destaque na velocidade do vento e aplicar o método proposto.

Valores de velocidade do vento iguais a zero foram substituídos por 0,01 m/s, uma vez que as distribuições utilizadas, como a Weibull, são definidas apenas para valores estritamente positivos. Essa substituição evita problemas numéricos na estimação dos parâmetros, especialmente em métodos baseados em máxima verossimilhança. Ressalta-se que o valor adotado é suficientemente pequeno para não alterar a forma da distribuição ajustada nem as estimativas do potencial eólico, dado que a contribuição de velocidades próximas de zero para a densidade de potência é desprezível.

2.2. Distribuições de Probabilidade

A variável analisada é a velocidade do vento (contínua, $x \in (0, \infty)$), modelada por funções densidade de probabilidade (FDP), cuja área em um intervalo fornece a probabilidade e cujo a moda indica a maior concentração (Ross, 2009). Ao estimar a FDP, é possível analisar o comportamento da curva e identificar a maior concentração de probabilidade. A maior concentração ocorre no ponto modal (ou pontos), em que a função densidade atinge seu valor máximo. Dessa forma, a seleção das distribuições adequadas é fundamental para modelar os dados de velocidade do vento na região Nordeste, uma vez que esta região é conhecida por eventos extremos de seca e por períodos chuvosos severos. Com base nas características específicas dos dados, como a variabilidade e a presença de caudas pesadas, optou-se por uma combinação de distribuições paramétricas amplamente reconhecidas para capturar as diferentes nuances da série temporal.

Dada a variabilidade e possíveis caudas pesadas típicas do Nordeste (secas e chuvas severas), foram selecionadas distribuições não negativas (Weibull, Gamma, Log-normal, Logística, entre outras), bem como distribuições como Normal e Cauchy apenas no suporte positivo. Estas distribuições foram combinadas em pares para capturar a heterogeneidade dos dados. A Tabela 1 resume as distribuições adotadas e suas referências.

Tabela 1. Distribuições utilizadas, abreviaturas e referências dos autores

Nº	Distribuição	Acrônimo	Autores e referências.
1	Normal	N	(Kotz <i>et al.</i> , 1994)
2	Weibull	W	(Kotz <i>et al.</i> , 1994)
3	Gamma	G	(Kotz <i>et al.</i> , 1994)
4	Log-normal	LN	(Kotz <i>et al.</i> , 1994)
5	Logística	L	(Johnson <i>et al.</i> , 1995)
6	Cauchy	C	(Kotz <i>et al.</i> , 1994)
7	Gumbel	Gu	(Gumbel, 1958)
8	Gompertz Logarítmica	LGom	(Kotz <i>et al.</i> , 1994)
9	Pareto Inversa	IPa	(Arnold, 1983)
10	Log-gamma	LG	(Hager and Bain, 1970)
11	Weibull Inversa	IW	(Mudholkar <i>et al.</i> , 1995)
12	Gaussiana Inversa	IN	(Kotz <i>et al.</i> , 1994)
13	Log-logística	LL	(Fisk, 1961)

Fonte: Elaborado pelos autores.

Embora esses modelos de distribuição sejam úteis, ainda não permitem uma análise completa do comportamento de todas as séries de velocidade do vento, isto é, algumas distribuições apresentam características multimodais. Assim, a combinação desses modelos surge como uma solução plausível, permitindo capturar o comportamento da velocidade do vento em diferentes modas e refletir de maneira mais precisa as complexidades dos dados observados. Na seção a seguir, serão apresentadas as misturas de distribuições e como podem ser aplicadas para abordar essas complexidades.

2.3. Modelos de mistura

Os modelos de misturas são ferramentas estatísticas amplamente utilizadas para modelar dados provenientes de populações heterogêneas ou homogêneas, em que os dados observados podem ser representados como combinação de diferentes distribuições de probabilidade. Neste trabalho, foram considerados modelos de mistura finitos (McLachlan; Peel, 2000), compostos por duas distribuições ajustadas em pares, com o objetivo de capturar a variabilidade dos dados de velocidade do vento na região Nordeste.

Cada modelo de mistura foi construído a partir de duas distribuições, denotadas como $f_1(x|\theta_1)$ e $f_2(x|\theta_2)$, em que θ_1 e θ_2 representam os vetores de parâmetros associados às respectivas distribuições e x representa a série de velocidade do vento. A combinação dessas distribuições é expressa por meio de uma função de densidade de probabilidade que considera a contribuição ponderada de cada componente. A função de densidade de probabilidade para o modelo de mistura é definida como

$$f_{mistura}(x|\theta_1, \theta_2) = \pi f_1(x|\theta_1) + (1 - \pi) f_2(x|\theta_2), \quad (1)$$

em que π é o parâmetro de peso, que assume valores no intervalo $[0, 1]$. Esse parâmetro assegura que a combinação seja convexa, garantindo que a soma das contribuições individuais de f_1 e f_2 represente uma distribuição de probabilidade válida.

A escolha de dois componentes na mistura permite capturar diferentes regimes ou padrões nos dados de velocidade do vento. Essa abordagem possibilita uma descrição mais precisa da variabilidade presente nos dados, representando uma ferramenta importante para análises relacionadas ao planejamento energético.

2.4. Métodos de Estimação

Os métodos de estimação são essenciais para determinar os parâmetros de um modelo de mistura de distribuições a partir dos dados observados. Em modelos de mistura, como o modelo descrito na seção anterior, os parâmetros θ_1 e θ_2 das distribuições $f_1(x|\theta_1)$ e $f_2(x|\theta_2)$, bem como o parâmetro de ponderação π , devem ser estimados para melhor representar a estrutura dos dados.

A escolha do método de estimação depende da natureza do modelo, da complexidade dos dados e dos requisitos computacionais. A seguir, são descritos os métodos de estimação utilizados neste trabalho: *Máxima Verossimilhança* (MV) e *Mínimos Quadrados Ordinários* (MMQ).

O método de *Máxima Verossimilhança* (MV) busca estimar os parâmetros do modelo de mistura $(\theta_1, \theta_2, \pi)$ de forma a maximizar a probabilidade dos dados observados, por meio da função de verossimilhança. A função de verossimilhança para o modelo de mistura, segundo McLachlan and Peel (2000), para duas distribuições é dada por:

$$L(\theta_1, \theta_2, \pi | x) = \prod_{i=1}^n [\pi f_1(x_i | \theta_1) + (1 - \pi) f_2(x_i | \theta_2)], \quad (2)$$

em que x_i são as observações dos dados e n é o número total de observações. A estimativa dos parâmetros é obtida ao maximizar a função de log-verossimilhança:

$$\mathcal{L}(\theta_1, \theta_2, \pi | x) = \sum_{i=1}^n \log(\pi f_1(x_i | \theta_1) + (1 - \pi) f_2(x_i | \theta_2)). \quad (3)$$

Esse método é amplamente utilizado por sua base teórica sólida e pela eficiência na estimação dos parâmetros, especialmente quando se lida com distribuições complexas. Além disso, o método de *Mínimos Quadrados Ordinários* (MMQ) busca estimar os parâmetros θ_1 , θ_2 e π minimizando a soma dos quadrados das diferenças entre os valores observados e os valores preditos pelo modelo (Mooijjaart *et al.*, 1999), sendo o mesmo utilizado como alternativa para a convergência dos modelos propostos. A função de erro é dada por:

$$S(\theta_1, \theta_2, \pi) = \sum_{i=1}^n (x_i - \hat{x}_i(\theta_1, \theta_2, \pi))^2, \quad (4)$$

na qual $\hat{x}_i(\theta_1, \theta_2, \pi)$ é a estimativa predita para o valor x_i dada pelos parâmetros θ_1 , θ_2 e π . Esse método é simples de implementar e oferece uma solução rápida, mas pode ser sensível a *outliers*.

Os métodos de otimização são centrais na estimação de modelos de misturas, ao minimizar funções de custo ou maximizar funções-objetivo. Neste trabalho serão empregados BFGS, L-BFGS-B (com restrições de caixa), Nelder–Mead e SANN, adequados a problemas de alta dimensão e complexidade. A literatura corrobora essa escolha: a identificabilidade em classes Weibull generalizadas e a avaliação de NM, BFGS e SANN em simulações e em dados reais são discutidas em De Gusmão *et al.*, (2021); já a distribuição Normal–Weibull–Weibull, construída por composição de duas *baselines*, é validada por meio de Monte Carlo e aplicada a dados de cinco cidades do Nordeste do Brasil em Silveira *et al.*, (2023). O uso prévio e bem-sucedido desses métodos reforça sua robustez e eficiência, sustentando sua adoção neste estudo.

2.5. $\mathcal{J}$ -Index

No presente trabalho, propomos um novo índice chamado $\mathcal{J}$ -index. O objetivo da nova proposta é ser uma métrica composta, normalizada e ponderada para integrar estatísticas de aderência, métricas de erro preditivo e medidas de penalização de complexidade (critérios de informação). Essa proposta inovadora combina múltiplas dimensões em um único índice no intervalo $[0, 1]$. Isso facilita múltiplas comparações relativas entre modelos no mesmo conjunto de dados, a fim de obter um índice global de desempenho para modelos de misturas de distribuição de probabilidade.

Para compor o $\mathcal{J}$ -index, utilizou-se os critérios de informação AIC, BIC e HQ (Hannan–Quinn) (Akaike, 1974; Schwarz, 1978; Hannan; Quinn, 1979); as estatísticas modificadas de Anderson–Darling (AD) e de von Mises (VM) para aderência (Chen; Balakrishnan, 1995); e, para acurácia preditiva, MAE, MAPE, MSE, RMSE e R^2 (Hossain, 2017).

Seja um conjunto de n modelos candidatos. Para cada modelo $i = 1, \dots, n$, sejam observadas k métricas de desempenho, tais que

$$x_i = (x_{i1}, x_{i2}, \dots, x_{ik}) \in R^k, \quad (5)$$

em que x_{ij} é o valor da j -ésima métrica no modelo i . Além disso, definem-se dois subconjuntos disjuntos de métricas:

- $\mathcal{M}_{min}$: conjunto de métricas de minimização.
- $\mathcal{M}_{max}$: conjunto de métricas de maximização.

Assim, $k = |\mathcal{M}_{min}| + |\mathcal{M}_{max}|$ é o total de métricas avaliadas. Para obter o $\mathcal{J}$ -index são realizados os seguintes passos:

1. Faça a normalização Min-Max (por métrica). Para cada métrica $j = 1, \dots, k$:

$$\text{norm}_j(x) = \frac{x - \min_i x_{ij}}{\max_i x_{ij} - \min_i x_{ij}} \quad (6)$$

2. Escores normalizados

Defina o escore normalizado do modelo i na métrica j :

$$s_{ij} = \begin{cases} 1 - norm_j(x_{ij}) & \text{if } j \in \mathcal{M}_{min} \\ norm_j(x_{ij}) & \text{if } j \in \mathcal{M}_{max} \end{cases} \quad (7)$$

3. Calcular $\mathcal{J}$ -index

Sejam os pesos $w_j > 0$ tais que $\sum_{j=1}^k w_j = 1$, então:

$$\mathcal{J} - index(i) = \sum_{j=1}^k w_j \cdot s_{ij}, \quad (8)$$

em que:

- $0 \leq \mathcal{J} - index(i) \leq 1$;
- $\mathcal{J} - index(i) = 1$, se e somente se, o modelo i é o melhor em todas as k métricas;
- $\mathcal{J} - index(i) = 0$, se e somente se, o modelo i é o pior em todas as k métricas;
- O melhor modelo é dado por: $i^* = \arg \max_i \mathcal{J} - index(i)$.

Dessa forma, neste trabalho será utilizada a seguinte configuração:

- $\mathcal{M}_{min} = \{AIC, BIC, HQ, MAE, MSE, RMSE, MAPE, Anderson - Darling, von Mises\}$.

$$\mathcal{M}_{max} = R^2, k = 10, w_j = 1/10, \forall j = 1, \dots, 10.$$

Ressalta-se que o presente estudo possui caráter aplicado, sendo o índice proposto utilizado como ferramenta auxiliar para a integração de múltiplos critérios de avaliação. Adotou-se a utilização de pesos iguais, com o objetivo de evitar priorização arbitrária entre as métricas consideradas e garantir uma avaliação global e equilibrada do desempenho dos modelos.

2.6. Potencial eólico

No setor de energia eólica, a densidade de energia eólica (*Wind Power Density*, WPD) é estimada em função da densidade dos modelos de mistura. Essa métrica é fundamental para avaliar e quantificar o potencial energético de uma estação (Bagci *et al.*, 2021). A densidade de energia eólica pode ser definida pela seguinte fórmula:

$$WPD(x) = \frac{1}{2} \rho \int_0^\infty x^3 \cdot f_{mistura}(x) dx \quad (W/m^2), \quad (9)$$

em que:

- WPD : Densidade de energia eólica média (W/m^2);
- ρ : Densidade do ar, comumente considerada $1,225 kg/m^3$ ao nível do mar;
- x : Velocidade do vento em m/s^2 ;
- $f_{mistura}(x)$: função de densidade de probabilidade do vento, modelada por uma mistura de duas distribuições.

Para este trabalho, a função de densidade de probabilidade $f_{mistura}(x)$ representa uma combinação de duas distribuições ajustadas às séries temporais de velocidade do vento para cada



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

estação localizada na região Nordeste. Essa abordagem considera a variabilidade estatística do vento e a contribuição ponderada de múltiplos regimes de vento característicos das diferentes regiões.

A análise apresentada é fundamental para o planejamento energético do Nordeste, destacando o papel estratégico da energia eólica na diversificação da matriz energética brasileira. A integração da energia eólica a outras fontes renováveis, como hidrelétrica, solar e de biomassa, é essencial para promover uma matriz energética sustentável e resiliente, conforme aponta o estudo de Stefanello *et al.*, (2018).

2.7. Recursos computacionais

A linguagem R foi utilizada para implementação de todos os procedimentos, incluindo a geração de misturas de modelos, aplicação dos métodos de estimação, técnicas de otimização e execução das análises. O R (versão 4.4.1) foi escolhido devido à sua ampla gama de pacotes estatísticos e de otimização, além do suporte nativo à paralelização e ao tratamento eficiente de grandes volumes de dados (R-PROJECT, 2010).

Além disso, nesse trabalho, não foi empregado um único algoritmo específico, mas sim um procedimento sistemático para realizar todas as combinações possíveis entre diferentes modelos, métodos de estimação e técnicas de otimização. Nesta etapa, o objetivo foi ajustar misturas de modelos estatísticos e comparar o desempenho de diferentes combinações.

Foram considerados 13 modelos de distribuições distintas. Esses modelos foram combinados entre si em pares (2×2), considerando arranjos com repetição e com ordem, ou seja, misturas como $W - N$ e $N - W$ são distintos, e são permitidas repetições como $W - W$. Esse processo resultou em um total de $13 \times 13 = 169$ combinações possíveis de misturas bivariadas de distribuições. Cada uma dessas misturas foi ajustada utilizando 2 métodos de estimação diferentes, e para cada método de estimação foram aplicados 4 métodos de otimização distintos, totalizando por estação:

$$169 \times 2 \times 4 = 1552 \text{ ajustes realizados.}$$

Esse processo possui um custo computacional elevado devido a grande quantidade de combinações e à complexidade do ajuste das misturas. Por essa razão, foi necessário adotar métodos de paralelização, distribuindo as tarefas entre múltiplos núcleos do processador para viabilizar a execução do algoritmo em um tempo razoável.

Devido ao grande número de combinações e ao custo computacional elevado para ajustar cada mistura, o processo foi paralelizado. Foi utilizado o pacote *foreach* (Microsoft; Weston, 2022) em conjunto com o pacote *doParallel* (Corporation; Weston, 2022) para distribuir as tarefas de ajuste entre múltiplos núcleos da CPU. O *doParallel* foi responsável por registrar e gerenciar os *clusters* de processamento, enquanto o *foreach* permitiu a execução das iterações em paralelo.

ISSN: 2675-6218 - RECIMA21


Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Essa abordagem reduziu significativamente o tempo total de processamento necessário para concluir todas as combinações de modelos, métodos de estimação e técnicas de otimização.

3. RESULTADOS E DISCUSSÃO

Apresentam-se, nesta seção, os principais resultados da aplicação de modelos de mistura às séries temporais de velocidade do vento. Inicialmente, são exibidos mapas da velocidade média que permite identificar padrões espaciais.

Figura 1. Mapa das velocidades médias no primeiro semestre do ano



Fonte: Elaborado pelos autores.


Na Figura 1 apresenta-se a distribuição das médias mensais da velocidade do vento no primeiro semestre. Destacam-se as faixas litorâneas do Rio Grande do Norte, Paraíba e Ceará, com valores mais elevados (tons amarelados), em geral superiores a 4 m/s . O padrão é mais intenso em janeiro--fevereiro, enfraquece nos meses seguintes e volta a se intensificar em junho.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

Figura 2. Mapa das velocidades médias no segundo semestre do ano



Fonte: Elaborado pelos autores.

Conforme a Figura 2, mantém-se o padrão espacial de velocidades médias mais elevadas ao longo da faixa litorânea, especialmente no Ceará, Rio Grande do Norte e Paraíba, no segundo semestre dos anos analisados. As áreas com valores superiores a 3 m/s permanecem concentradas no litoral norte (tons amarelados), com ampliação entre agosto e outubro, o que sugere reforço sazonal associado a padrões atmosféricos regionais. De acordo com Gorayeb and Brannstrom (2016), embora a energia eólica se apresente como solução benéfica para o meio ambiente, sua implantação pode gerar impactos sociais e ambientais negativos para populações que residem em áreas costeiras. Portanto, políticas de desenvolvimento ambiental devem considerar esses efeitos com atenção especial às regiões litorâneas. Além disso, nota-se uma tendência de redução da variabilidade nos meses de novembro e dezembro, especialmente no estado do Maranhão, onde predominam tons mais suaves, indicando menor velocidade do vento, padrão esse consistente com a análise estatística realizada por Oliveira *et al.*, (2024).

Considerando esses padrões, foram selecionadas quatro estações, do Nordeste, com base na representatividade geográfica e na presença de bimodalidade nas séries, para a aplicação detalhada dos modelos de mistura. Por fim, os parâmetros estimados são utilizados para calcular o potencial eólico de cada localidade.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

Tabela 1. Medidas descritivas das séries de velocidade do vento das quatro estações

Estações	Mín.	1º Q.	Med.	3º Q.	Máx.	Média	Desvio P.
Quixadá - CE	0,1	1,1	2,0	2,9	7,6	2,0	1,1
Areia - PB	0,1	3,2	4,1	5,0	11,0	4,1	1,4
Recife - PE	0,1	0,8	1,6	2,5	6,2	1,7	1,0
Calcanhar - RN	0,1	5,3	7,3	8,7	15,3	7,0	2,3

Fonte: Elaborado pelos autores.

Conforme a Tabela 2, as estações de Calcanhar - RN (7,02 m/s) e Areia - PB (4,09 m/s) apresentam as maiores médias de velocidade do vento, destacando-se pelo maior potencial eólico. As maiores velocidades máximas foram registradas em Calcanhar - RN (15,30 m/s) e Areia - PB (11,00 m/s), indicando maior ocorrência de ventos intensos. Todas as séries analisadas mostram médias e medianas acima do limite mínimo de operação dos aerogeradores (2,7 m/s) apontado por Enel Green Power (2024), com exceção da estação de Recife - PE, assegurando a viabilidade da geração de energia e confirmando, pelos quartis, que boa parte das medições supera esse limiar operacional.

A seguir, são apresentados os três melhores ajustes para cada uma das quatro estações. Ressalta-se que, quando o parâmetro de peso P5 assume valores próximos de 0 ou de 1, o modelo de mistura tende a convergir para um modelo univariado, indicando que apenas uma das distribuições é suficiente para representar adequadamente a série de velocidades do vento.

Tabela 3. Resultados para os três melhores modelos das estações selecionadas do Nordeste

Estação	Misturas	Est. (Otim.)	P1	P2	P3	P4	P5	J-index
Quixadá (CE)	G-Gu	MLE (SANN)	2,71	3,44	2,11	0,87	0,36	0,87
Quixadá (CE)	IN-LL	MLE (SANN)	2,17	5,11	1,99	1,77	0,78	0,866
Quixadá (CE)	G-N	MLE (SANN)	1,86	1,71	2,5	0,95	0,42	0,861
Areia (PB)	LN-LL	MLE (SANN)	1,39	0,26	0,62	1,49	0,99	0,807
Areia (PB)	C-N	MLE (L-BFGS-B)	4,1	0,01	4,09	1,43	0,02	0,778
Areia (PB)	Gu-N	MLE (SANN)	3,85	0,95	1,88	0,66	0,88	0,765
Recife (PE)	W-W	MLE (L-BFGS-B)	2,55	0,65	2,66	2,36	0,26	0,855
Recife (PE)	G-N	MLE (BFGS)	3,66	4,93	2,25	0,8	0,37	0,852
Recife (PE)	LN-LN	MLE (L-BFGS-B)	0,89	0,25	0,01	0,72	0,38	0,849
Calcanhar (RN)	G-G	MLE (BFGS)	7,34	1,31	46,28	5,39	0,52	0,794
Calcanhar (RN)	LL-LL	MLE (L-BFGS-B)	4,85	0,2	11,13	0,12	0,46	0,792
Calcanhar (RN)	LL-LL	MLE (BFGS)	4,85	0,2	11,13	0,12	0,46	0,792

Fonte: Elaborado pelos autores.

Para representar os resultados dos melhores ajustes, apresentados na Tabela 3, obtidos nas séries de velocidade do vento, foram gerados histogramas com as três curvas mais bem ajustadas para cada estação selecionada.

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

As distribuições foram estimadas pelo método da Máxima Verossimilhança (MLE), com otimização por *Simulated Annealing* (SANN), e avaliadas por meio da métrica J -index, que integra critérios de ajuste e de erro, apresentado na Tabela 4. Essa métrica permitiu identificar, para cada estação, os modelos com melhor desempenho global, sendo a distribuição Log-Logística (LL) a mais recorrente entre os melhores ajustes.

Tabela 4. Métricas de desempenho dos modelos selecionados para cada estação


Estação	Misturas	AIC	BIC	HQ	MAE	MAPE	MSE	RMSE	R2	AD	VM
Quixadá (CE)	G-Gu	-38272,53	-38235,25	-38260,07	1,79	75,83	4,67	2,16	0,78	853,77	181,80
Quixadá (CE)	IN-LL	-40616,31	-40579,02	-40603,84	1,79	76,01	4,76	2,18	0,74	329,60	43,68
Quixadá (CE)	G-N	-37829,39	-37792,11	-37816,92	1,78	77,35	4,62	2,15	0,61	369,19	71,70
Areia (PB)	LN-LL	-544651,84	-544602,51	-544637,10	3,87	94,17	16,99	4,12	0,00	4302,06	355,06
Areia (PB)	C-N	-497781,12	-497731,78	-497766,38	3,88	94,33	17,03	4,13	0,00	6154,91	771,15
Areia (PB)	Gu-N	-508867,42	-508818,08	-508852,68	3,89	94,57	17,12	4,14	0,00	918,38	103,31
Recife (PE)	W-W	-286892,03	-286843,96	-286877,51	1,40	66,97	3,11	1,76	0,53	84,23	10,97
Recife (PE)	G-N	-287249,83	-287201,76	-287235,30	1,40	67,32	3,10	1,76	0,55	3469,09	504,22
Recife (PE)	LN-LN	-289394,14	-289346,07	-289379,62	1,40	68,05	3,11	1,76	0,49	225,52	25,02
Calcanhar (RN)	G-G	-263080,83	-263035,85	-263066,86	6,90	98,14	52,53	7,25	0,10	20,20	2,13
Calcanhar (RN)	LL-LL	-264216,30	-264171,31	-264202,32	6,90	98,14	52,53	7,25	0,07	51,83	5,13
Calcanhar (RN)	LL-LL	-264216,28	-264171,29	-264202,30	6,90	98,14	52,53	7,25	0,07	51,78	5,13

Fonte: Elaborado pelos autores.

A Tabela 4 mostra as métricas de avaliação dos modelos. O índice proposto (J -index) permite uma avaliação global do desempenho dos modelos ao integrar estas métricas de naturezas distintas, incluindo critérios de minimização e maximização, além de diferentes escalas. Por meio da normalização adotada, tornou-se possível comparar e combinar essas medidas em uma única métrica, proporcionando uma análise mais consistente e abrangente.

Dessa forma, a Figura 3 reflete graficamente a qualidade dos ajustes obtidos e ilustra a capacidade das misturas de distribuições em representar adequadamente a variabilidade das velocidades do vento, nas diferentes localidades analisadas.

Figura 3. Histogramas das séries de velocidade do vento com as três curvas de melhor ajuste



Fonte: Elaborado pelos autores.

A Figura 3 apresenta os três melhores ajustes para cada estação. Nas séries em que não se observa separação clara entre as modas, observa-se predominância de um único componente na mistura, com pesos elevados (superiores a 0,8), indicando que esse componente representa a maior proporção dos dados, como observado em Quixadá-CE e Areia-PB. Embora testes formais de multimodalidade possam ser empregados, sua aplicação em amostras de grande dimensão tende a detectar desvios estatisticamente significativos mesmo na presença de pequenas irregularidades na distribuição. Dessa forma, a avaliação da multimodalidade foi baseada no comportamento dos pesos das misturas e na inspeção visual dos ajustes, critérios mais consistentes com o objetivo de modelagem adotado neste estudo.

Por outro lado, nas séries em que a distribuição dos dados apresenta mais de um padrão de concentração, os modelos de mistura apresentaram melhor desempenho no ajuste. Em Calcanhar-RN, as combinações Log-Logística e Log-Logística reproduziram adequadamente a forma do histograma, enquanto em Recife-PE todos os modelos apresentaram bom ajuste. Destaca-se, ainda, Calcanhar-RN pela maior concentração de ventos em velocidades elevadas. A seguir, apresenta-se o potencial eólico estimado a partir do melhor modelo ajustado em cada estação.

Tabela 5. Estimativas do potencial eólico com base nos modelos ajustados

Estações	Misturas	Potencial do vento (W/m^2)
Calcanhar (RN)	LL - LL	284,1459
Areia (PB)	Gu - N	57,8183
Quixadá (CE)	IN - LL	11,2608
Recife (PE)	W - W	6,3434

Fonte: Elaborado pelos autores.

A Tabela 5 apresenta, em ordem decrescente, os valores estimados do potencial eólico com base nos melhores modelos ajustados para cada estação representativa dos estados do Nordeste. Calcanhar (RN) registrou densidade de potência de $284,15 W/m^2$ e Areia (PB) de $57,82 W/m^2$. Considerando a lei de Betz (Horn, 2010), apenas 59,3% dessa potência pode ser convertida em energia útil, resultando em $168,7 W/m^2$ para estação de Calcanhar.

4. CONSIDERAÇÕES

Com base nos mapas de velocidade média, verifica-se que o regime de ventos no Nordeste do Brasil apresenta padrões espaciais e sazonais bem definidos. As maiores velocidades ocorrem ao longo do litoral do Rio Grande do Norte, Paraíba e Ceará, sobretudo nos meses de janeiro, fevereiro, agosto e setembro. Esses padrões refletem a influência de sistemas atmosféricos sazonais e reforçam a necessidade de considerar tanto a intensidade quanto a variabilidade dos ventos no planejamento de projetos eólicos.

Neste estudo, foi desenvolvido e aplicado um algoritmo capaz de testar automaticamente diferentes combinações de distribuições de mistura, identificando o modelo mais adequado para representar as séries de velocidade do vento. A abordagem mostrou-se eficiente ao combinar critérios clássicos (AIC, BIC e HQ) com métricas de erro, aderência e avaliação visual, sintetizadas em uma métrica J -index que possibilitou uma análise mais robusta do desempenho dos modelos.

Os resultados indicaram que, para séries unimodais, uma única distribuição é suficiente, evidenciada pelos pesos próximos de 0 ou 1, enquanto, nas séries bimodais, as misturas proporcionaram ajustes mais precisos e coerentes com a forma empírica dos dados. Essa flexibilidade foi essencial para capturar as particularidades estatísticas de cada localidade.

A estimativa do potencial eólico, com base nos modelos selecionados, confirmou a importância da modelagem estatística na aplicação prática ao planejamento energético. A distribuição espacial dos resultados destacou as localidades com maior potencial de geração, com ênfase em Calcanhar-RN.

5. AGRADECIMENTOS

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. À CAPES e, através das críticas

construtivas e sugestões, aos revisores anônimos agradecemos toda contribuição no aprimoramento deste trabalho.

REFERÊNCIAS

ABEEÓLICA. Associação Brasileira de Energia Eólica. 2022. Disponível em: <http://abeeolica.org.br/>. Acesso em: 20 mar. 2026.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, p. 716–723, 1974.

ANEEL. Agência Nacional de Energia Elétrica. **Recorde na expansão da geração**: matriz elétrica brasileira teve aumento de 10,3 GW em 2023. São Paulo: Aneel, 2024. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/noticias/2024/recorde-na-expansao-da-geracao-matriz-eletrica-brasileira-teve-aumento-de-10-3-gw-em-2023>. Acesso em: 20 mar. 2026.

ARNOLD, B. C. **Pareto distributions**. [S.l.]: International Cooperative Publishing House, 1983.

BAGCI, K.; ARSLAN, T.; CELIK, H. E. Inverted Kumarswamy distribution for modeling the wind speed data: Lake Van, Turkey. **Renewable and Sustainable Energy Reviews**, v. 135, p. 110110, 2021.

CHEN, G.; BALAKRISHNAN, N. A general purpose approximate goodness-of-fit test. **Journal of Quality Technology**, v. 27, p. 154–161, 1995.

CORPORATION, M.; WESTON, S. **DoParallel**: Foreach parallel adaptor for the “parallel” package. 2022. Disponível em: <https://CRAN.R-project.org/package=doParallel>. Acesso em: 20 mar. 2026.

COSTA NETO, P. L. O.; BEKMAN, O. R. **Análise estatística da decisão**. 2. ed. São Paulo: Blücher, 2009.

DE GUSMÃO, F. R. *et al.* Analyzing and solving the identifiability problem in the exponentiated generalized Weibull distribution. **Journal of the Egyptian Mathematical Society**, v. 29, p. 1–17, 2021.

DOS SANTOS, F. S. *et al.* Brazilian wind energy generation potential using mixtures of Weibull distributions. **Renewable and Sustainable Energy Reviews**, v. 189, p. 113990, 2024. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1364032123008481>. Acesso em: 20 mar. 2026.

ENEL GREEN POWER. **Hélice eólica**. [S. l.]: Enel Green Power, 2024. Disponível em: <https://www.enelgreenpower.com/pt/learning-hub/energias-renoveveis/energia-eolica/helice-eolica>. Acesso em: 20 mar. 2026.

ENGIE. Rio Grande do Norte avança na produção de energia eólica. **Além da Energia**, 2022. Disponível em: <https://www.alemdaenergia.engie.com.br/rio-grande-do-norte-avanca-na-producao-de-energia-eolica/>. Acesso em: 20 mar. 2026.

FISK, P. R. The log-logistic distribution. **Journal of the American Statistical Association**, v. 56, p. 245–249, 1961.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

POTENCIAL DE ENERGIA EÓLICA NO NORDESTE BRASILEIRO: UMA ABORDAGEM VIA MODELOS DE MISTURA
Sóstenes Jerônimo da Silva, Débora de Sousa Cordeiro, Sílvia Fernando Alves Xavier Júnior, Jader da Silva Jale

GORAYEB, A.; BRANNSTROM, C. Toward participatory management of renewable energy resources (wind-farm) in northeastern Brazil. **Mercator**, v. 15, p. 101–115, 2016.

GUMBEL, E. J. **Statistics of extremes**. New York: Columbia University Press, 1958.

HAGER, R. M.; BAIN, L. J. Inferential procedures for the log-gamma distribution. **Journal of the American Statistical Association**, v. 65, p. 1601–1609, 1970.

HANNAN, E. J.; QUINN, B. G. The determination of the order of an autoregression. **Journal of the Royal Statistical Society: Series B**, v. 41, p. 190–195, 1979.

HORN, D. A. Análise numérica da esteira aerodinâmica formada por uma turbina eólica com dimensionamento ótimo de Betz. **Revista Brasileira de Ensino de Física**, 2010. Disponível em: <https://lume.ufrgs.br/handle/10183/26540>. Acesso em: 20 mar. 2026.

HOSSAIN, M. E. Application of Gaussian mixture regression model for short-term wind speed forecasting. In: **North American Power Symposium (NAPS)**. [S. l.]: IEEE, 2017. p. 1–6.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Dados meteorológicos. 2025. Disponível em: <https://www.inmet.gov.br>. Acesso em: 20 mar. 2026.

JABER, S. Environmental impacts of wind energy. **Journal of Clean Energy Technologies**, v. 1, p. 251–254, 2013.

JOHNSON, N. L.; KOTZ, S.; BALAKRISHNAN, N. **Continuous univariate distributions**. v. 2. New York: John Wiley & Sons, 1995.

KOTZ, S.; BALAKRISHNAN, N.; JOHNSON, N. L. **Continuous multivariate distributions: models and applications**. New York: John Wiley & Sons, 1994.

MARZOUK, O. A. Wind speed Weibull model identification in Oman and computed normalized annual energy production. **Engineering Reports**, v. 7, e70089, 2025.

MCLACHLAN, G. J.; PEEL, D. **Finite mixture models**. New York: John Wiley & Sons, 2000.

MICROSOFT; WESTON, S. **Foreach**: provides foreach looping construct. Versão 1.5.2, 2022. Disponível em: <https://CRAN.R-project.org/package=foreach>. Acesso em: 20 mar. 2026.

MOOIJART, A. *et al.* A least squares algorithm for a mixture model for compositional data. **Computational Statistics & Data Analysis**, v. 30, p. 359–379, 1999.

MUDELSEE, M. Trend analysis of climate time series: a review of methods. **Earth-Science Reviews**, v. 190, p. 310–322, 2019.

MUDHOLKAR, G. S.; SRIVASTAVA, D. K.; KOLLIA, G. D. A generalization of the Weibull distribution. **Journal of the American Statistical Association**, v. 90, p. 267–276, 1995.

NASCIMENTO, E. G. S. *et al.* Um algoritmo baseado em técnicas de agrupamento para detecção de anomalias em séries temporais. In: SHITSUKA, R.; SHITSUKA, D. M. (org.). **Estudos e práticas de aprendizagem de matemática e finanças com apoio de modelagem**. Rio de Janeiro: Ciência Moderna, 2015. p. 55–86.



OLIVEIRA, E. R. de et al. **Análise estatística do vento à superfície no Nordeste do Brasil**. 2024. 54 f. Dissertação (Mestrado em Meteorologia) – Instituto de Ciências Atmosféricas, Programa de Pós Graduação em Meteorologia, Universidade Federal de Alagoas, Maceió, 2024. Disponível em: <https://www.repositorio.ufal.br/jspui/handle/123456789/15927>. Acesso em: 20 mar. 2026.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU). **Causes and effects of climate change**. Geneva: ONU, 2024. Disponível em: <https://www.un.org/pt/climatechange/science/causes-effects-climate-change>. Acesso em: 20 mar. 2026.

PEREIRA, A. S. et al. **Metodologia da pesquisa científica**. Santa Maria: Editora da UFSM, 2018. (E-book).

R PROJECT. **R Project for Statistical Computing**. 2010. Disponível em: <http://www.r-project.org/>. Acesso em: 20 mar. 2026.

RISEMBERG, R. I. C. et al. A importância da metodologia científica no desenvolvimento de artigos científicos. **E-Acadêmica**, v. 7, n. 1, e0171675, 2026. Disponível em: <https://eacademica.org/eacademica/article/view/675>. Acesso em: 20 mar. 2026.

ROSS, S. **Probabilidade: um curso moderno com aplicações**. Porto Alegre: Bookman, 2009.

SCHWARZ, G. Estimating the dimension of a model. **The Annals of Statistics**, p. 461–464, 1978.

SHITSUKA, R. et al. **Matemática fundamental para tecnologia**. 2. ed. São Paulo: Érica, 2014.

SILVEIRA, F. et al. Modelling wind speed with a univariate probability distribution. **Hacettepe Journal of Mathematics and Statistics**, p. 1–20, 2023.

STEFANELLO, C.; MARANGONI, F.; ZEFERINO, C. L. A importância das políticas públicas para o fomento da energia solar fotovoltaica no Brasil. In: **CONGRESSO BRASILEIRO DE ENERGIA SOLAR (CBENS)**. 2018.

WANG, Y. et al. Bayesian infinite mixture models for wind speed distribution estimation. **Energy Conversion and Management**, v. 236, p. 113946, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0196890421001229>. Acesso em: 20 mar. 2026. DOI: <https://doi.org/10.1016/j.enconman.2021.113946>.

ZHAO, L. et al. A location-centric transformer framework for multi-location short-term wind speed forecasting. **Energy Conversion and Management**, v. 328, p. 119627, 2025.