
ESTUDO DE PREVISÃO NA VELOCIDADE DO VENTO: APLICAÇÃO PRÁTICA DE INTELIGÊNCIA ARTIFICIAL NA BUSCA E NO USO DE ENERGIA EÓLICA

Michel Braulio de Oliveira

Valdomiro Vega Garcia

Universidade Presbiteriana Mackenzie (UPM)

Resumo

Este artigo traz um guia rápido de fácil acesso ao usuário, usando ferramentas *on-line*, com foco na geração de energia eólica e na escolha de melhor região para instalação de aerogeradores. Destacam-se as ferramentas Topographic-map, para viabilidade de terreno na instalação de aerogeradores, e Google Colaboratory, para executar funções baseadas em inteligência artificial para compreender dados climáticos da própria região e prever valores futuros desses mesmos dados. Além disso, é possível explorar outro tipo de geração distribuída, como a solar, a partir desses mesmos dados e com algumas mudanças do código. Para a realização da prova de conceito, nesta pesquisa foi utilizada a linguagem de programação Python no ambiente Google Colaboratory, com funções e bibliotecas do TensorFlow, que contém diversos modelos de redes neurais. Para a realização da pesquisa, utilizou-se um banco de dados climáticos no período de 2015 a 2020 extraído do Instituto Nacional de Meteorologia e de registros de altitude do *Atlas eólico brasileiro*. O presente trabalho constatou que os melhores resultados de correlação das variáveis climáticas e das previsões são proporcionais ao incremento do banco de dados. Também foi percebida a necessidade de uma boa conexão de internet para executar previsões de médio e longo prazos, em razão do carregamento inicial do banco de dados

na aplicação *on-line*. Testaram-se vários modelos de inteligência artificial nas previsões da velocidade do vento que foram comparados por meio de erro médio absoluto para encontrar o modelo mais adequado, como destaque aos modelos denso e convolucional (método de múltiplas saídas).

Palavras-chave: Séries temporais. Energia eólica. Inteligência artificial. Redes neurais. Previsão. Velocidade do vento.

1 INTRODUÇÃO

O consumo de combustíveis fósseis, tais como carvão, petróleo e gás, vem aumentando e conseqüentemente produzindo concentrações de CO₂ na atmosfera que atualmente são 39% maiores que os níveis medidos nas eras pré-industriais, com concentração de 390 ppm (Intergovernmental Panel on Climate Change, 2021). É possível que a maior parte do aumento observado na temperatura média global desde meados do século XX seja decorrente do aumento verificado nas concentrações antropogênicas de gases de efeito estufa, e, nesse sentido, novas formas de geração de energia limpa se destacam, tais como a energia eólica e a solar (Intergovernmental Panel on Climate Change, 2021).

No setor eólico, uma estratégia bastante atual tem sido a busca por métodos de previsão de velocidade de vento que possam fornecer garantias aos investidores desse setor, de modo que essa busca possa alavancar cada vez mais pesquisas no campo de estudo da energia eólica. Este artigo traz um guia prático para tornar o tema mais próximo do cotidiano do interessado, e isso se torna necessário porque os programas e computadores destinados para simulações climáticas têm acesso mais restrito e maior complexidade de operação (Camelo *et al.*, 2018). O guia prático abordado neste trabalho utiliza modelos de inteligência artificial (IA) para a previsão da velocidade do vento. Os resultados são verificados no período escolhido, e, em posse de dados atmosféricos da região específica, é possível predefinir a geração de energia. Tudo isso está amparado em pesquisas correlatas na previsão da velocidade do vento com uso de redes neurais, tais como os trabalhos de Oliveira (2020) e Camelo *et al.* (2018). Estes últimos autores utilizaram o *software* livre R, que conta com sólidas bibliotecas de estatística e de *machine learning* para fazer predições.

O presente trabalho recorre à linguagem Python, simples e acessível, que conta também com bibliotecas com bases matemáticas sólidas que permitem ao usuário co-

num realizar previsões, sejam elas climáticas ou não, de forma prática e rápida. Essas bibliotecas também permitem a visualização dos dados, ajudando a compreender quais parâmetros climáticos são relevantes na previsão da velocidade do vento.

Com relação aos dados climáticos regionais, nesta pesquisa procura-se a melhor região para a instalação dos aerogeradores, identificando padrões benéficos ao estudo, além de facilitar o acesso a novos usuários que buscam instalar aerogeradores ou estudar o clima de uma dada região. Para isso, utilizam-se ferramentas *on-line* (com destaque ao Google Colaboratory) com capacidade de avaliação de dados e uso de redes neurais para investigar fenômenos climáticos, com fins de geração de energia (Google Research, 2021).

Este trabalho tem como objetivo geral encontrar as melhores regiões com alto potencial de geração de energia eólica e instalação de aerogeradores nessas áreas. Para isso, utilizam-se bases de dados climáticas brasileiras disponíveis no Instituto Nacional de Meteorologia – Inmet (2021), além da ferramenta Topographic-map (2021) para a viabilidade de terreno para instalação de aerogerador(es). Finalmente, utilizam-se modelos de previsão do TensorFlow (2021) do Google para encontrar os valores de velocidade de vento futuro (24 horas).

Após a definição da localização da região com melhor previsão da velocidade do vento, é possível verificar a viabilidade econômica da instalação de pequenas ou grandes fazendas de aerogeradores.

Outro objetivo atrelado a este trabalho é disseminar o uso de IA de forma prática em aplicações relacionadas com geração distribuída e usando fontes limpas de energia. Para esse fim, propõe-se manter o uso de ferramentas totalmente *on-line* que permitam, por um lado, a manipulação de grandes bases de dados e, por outro, a utilização de modelos matemáticos, como as redes neurais artificiais (RNA) para realizar os estudos de previsão de velocidade do vento e avaliar os locais com potencial, como citado anteriormente. Essa linha de pesquisa contribui para a construção e investigação de melhores métodos científicos e econômicos para geração de energia limpa e desenvolvimento contínuo de metodologias que envolvem IA.

2 REVISÃO DA LITERATURA

Na sequência, serão abordados os seguintes temas: parâmetros atmosféricos, geração de energia e IA, necessários para a compreensão e a análise realizada nessa prova de conceito.

2.1 Banco de dados climáticos

Esta pesquisa utiliza um banco de dados extraído do *site* do Inmet. Este instituto coleta as informações de estações meteorológicas espalhadas no Brasil. Alguns dos parâmetros atmosféricos são: temperatura (°C), pressão (mB), radiação global (J/m²), precipitação de chuvas (mm), umidade relativa (%) e velocidade do vento (m/s), os quais estão ordenados por data e hora. Essas informações permitem avaliar o potencial de geração de energias limpas no território nacional, sobretudo em regiões propícias para implementar a geração de energia eólica (Instituto Nacional de Meteorologia, 2021). Os parâmetros atmosféricos mencionados são as variáveis de treinamento das redes neurais, que permitem fazer as previsões da velocidade do vento, e foram empregados neste artigo.

2.2 Formação dos ventos

A energia solar é a fonte principal para o movimento do ar, e, de forma indireta, a atmosfera é aquecida pelo sol, pois os raios solares, ao incidirem sobre a superfície terrestre, aquecem-na. Essa energia em forma de calor é transferida à atmosfera até as suas regiões mais altas por movimentos verticais do ar (convecção) ou para outras regiões (advecção), ocasionando ventos que adquirem velocidades diferentes em áreas adversas (Instituto de Astronomia, Geofísica e Ciências Atmosféricas, 2021).

2.3 Geração de energia

Para a captação da energia das forças dos ventos, é preciso converter a energia cinética da movimentação do ar em energia mecânica e, por meio dela, por fim, converter em energia elétrica. Na Figura 1, é apresentado um aerogerador em diferentes vistas. Quanto mais rápido suas pás rotacionam, mais energia é gerada (Intergovernmental Panel on Climate Change, 2021).




Figura 1 Torre eólica e seus componentes principais

Fonte: Intergovernmental Panel on Climate Change (2021).

As torres de energia eólica mais altas geralmente têm capacidade maior na captação de energia, e o formato aerodinâmico e o tamanho das lâminas eólicas, tanto para baixas ou altas velocidades do vento, também possuem grande influência na geração de energia (Intergovernmental Panel on Climate Change, 2021). Os aerogeradores de porte médio geram em torno de 2,1 a 2,2 (MW), e os de maior porte podem produzir de 4 a 4,2 (MW), e ambos os modelos são muito utilizados (Zaparolli, 2019).

2.4 Instalação de aerogeradores

Inicialmente é necessário selecionar a região onde será instalado o gerador ou os geradores. Para tanto, deve-se considerar certas características de topografia (plana ou levemente ondulada), vegetação (rasteira), velocidade média anual do vento economicamente viável em torno de 7 m/s, medições e qualidade dos dados, que devem ter no mínimo um ano de registros climáticos na região (Universidade Federal do Rio de Janeiro, 2021).

Deve-se considerar também a altitude das medições que pode ser encontrada nas simulações climáticas de 2013 feitas em todo o território nacional. Para essas simulações, foi utilizado o *software* de modelo BRAMS, no *Atlas eólico brasileiro* (Centro de Pesquisas de Energia Elétrica, 2013). Outra condição para viabilizar a instalação de aerogerador(es) é a distância da geração de energia até a rede na qual será conectado, pois os custos da construção de linha de transmissão são elevados, porém, quanto mais próxima à rede, mais econômica será a operação. A qualidade da infraes-

trutura conectada a subestações de energia também deverá ser levada em consideração, assim como as disponibilidades de conexão para acessar a rede (Universidade Federal do Rio de Janeiro, 2021).

Nos próximos tópicos, serão apresentadas definições de IA, assim como os modelos de redes neurais.

2.5 Inteligência artificial

O presente estudo tem o intuito de adequar uma ferramenta computacional que permita a análise de dados de ventos (previsão) utilizando a IA de forma prática.

De acordo com Sellitto (2002), o papel da IA é incorporar na máquina inteligência semelhante à humana, utilizando alguns ramos de estudos fundamentais da ciência, como computação, matemática, cibernética, psicologia e engenharia. Ao imitar mecanismos naturais de modo artificial, especialmente em programas de computadores, a IA possibilita a execução e solução de tarefas em níveis que podem se igualar às capacidades humanas ou mesmo superá-las.

2.6 Redes neurais artificiais

A RNA pode ser fundamentada em duas partes: a arquitetura e o algoritmo de aprendizagem (a rede deve ser treinada para aprender), fornecendo parâmetros de exemplo para a rede (composta por neurônios). Ela atribui pesos a essas variáveis de modo a possibilitar o entendimento do que mais afeta o sistema estudado (Raubert, 2005).

Como apresentado por Fleck *et al.* (2016), numa RNA existem basicamente quatro componentes essenciais ao seu funcionamento: conjunto de sinapses, um integrador, função de ativação e *bias*. Esses componentes são exibidos na Figura 2 e detalhados a seguir. Para o conjunto de sinapses, há camadas de neurônios que geram o peso de sinapse. Na junção neurônio (i) com a entrada de sinapse (j), o peso sináptico (w_{ij}) é multiplicado pelo sinal de entrada (x_j) (Otuyama, 2020). O integrador forma um combinador linear, o qual é responsável por atribuir pesos sinápticos às somas de sinais de entrada (Otuyama, 2020).

Dado um neurônio artificial, a função de ativação limita a amplitude do valor de saída dele (Fleck *et al.*, 2016). Por essa atribuição, também é conhecida como “função limitante”, ou seja, o valor de saída é limitado em uma faixa de amplitude finita (valor normalizado no intervalo fechado de $[0, 1]$) (Otuyama, 2020). O *bias* é definido como valor externo ao neurônio artificial (Figura 2), podendo aumentar ou diminuir a entrada do sinal da função de ativação (Fleck *et al.*, 2016).

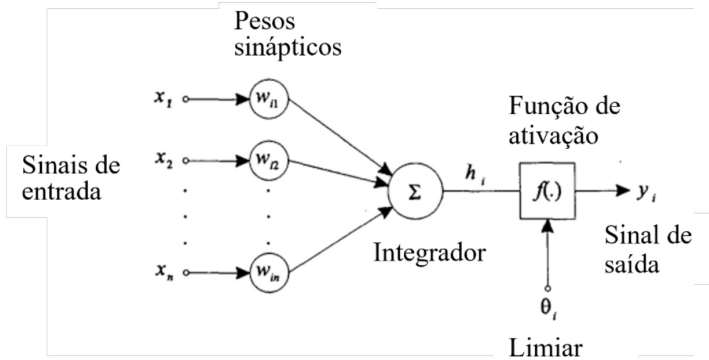


Figura 2 Modelo de neurônio artificial

Fonte: Otuyama (2020).

A Figura 2 ajuda a demonstrar matematicamente a descrição de um neurônio i , que pode ser feita por duas equações:

$$h_i = \sum_{j=1}^n w_{ij} x_j \tag{1}$$

$$y_i = f(h_i) \tag{2}$$

em que: x é igual aos sinais de entrada ($x_1, x_2, x_3, \dots, x_n$); w é igual a pesos sinápticos do neurônio i ($w_{i1}, w_{i2}, w_{i3}, \dots, w_{in}$), combinação linear dos sinais de entrada do neurônio i (h), função de ativação (f); e y sendo igual ao sinal de saída do neurônio i . Se incorporarmos ao y_i um limiar (*threshold*), teremos:

$$y_i = f(h_i - \theta_i) \tag{3}$$

em que se tenta reduzir a entrada total da função de ativação (θ_i). Se θ_i tiver valor negativo, haverá *bias* (desvio), que é exatamente o efeito contrário (Otuyama, 2020). Segundo Fleck *et al.* (2016), para determinar os pesos sinápticos e *bias*, é preciso o treinamento da RNA, no qual um processo iterativo usa valores iniciais até a convergência do processo. Pode-se definir matematicamente sendo:

$$w(k)_{ij} = w(k - i)_{ij} + \Delta w(k)_i \tag{4}$$

dado k iterações, há o parâmetro w e o vetor de correção (Δw).

2.6.1 Funções de ativação

Como sugerido em Fleck *et al.* (2016), existem outros tipos de função de ativação, sendo os mais conhecidos: função limiar, função linear e, com destaque, a função sigmoide, que é a mais comum. Em se tratando de construção de RNA, por definição, é uma função crescente com propriedade assintótica e de suavidade (Otuyama, 2020). Pode assumir valores no intervalo [0,1] mantendo-se balanceada nos comportamentos linear e não linear (Fleck *et al.*, 2016). Um tipo de função sigmoide é a função logística, expressa por:

$$f(x) = \frac{1}{1+e^{-\alpha x}} \quad (5)$$

α = parâmetro da inclinação da função sigmoide.

Algumas características dessa função são: aumentando o valor de α maior é a inclinação da curva e essa função é derivável, o que é muito útil nos estudos de RNA (Otuyama, 2020).

2.6.2 Arquitetura de redes neurais

Otuyama (2020) propõe que a RNA tem organização por agrupamentos (camadas) de nós (neurônios artificiais), em que os nós de entrada somente recebem a informação e a enviam a outros nós, no caso, nós de processamento, que então de fato processam as informações. Existem três classes de arquitetura de RNA:

- Redes neurais diretas de camada única (*single-layer feedforward neural networks*): nesse caso, uma única camada de nós de entrada envia dados de forma unilateral para a camada de nós de saída.
- Redes neurais diretas multicamada (*multilayer feedforward neural networks*): possuem camadas de processamento escondidas (neurônios escondidos). Essas unidades escondidas têm por função trabalhar as informações entre a entrada externa e a saída.
- Redes neurais recorrentes (*recurrent neural networks*): a camada envia um sinal para si mesma, para a próxima camada ou para a anterior, configurando-se como uma rede neural recorrente.

Existe outra classe de redes neurais, as convolucionais, composta por três elementos arquitetônicos: campos receptivos locais, pesos compartilhados (podendo também ter

replicação de pesos) e subamostragem espacial, a fim de gerar um determinado grau de desvio, certo grau de escala e invariância de distorção (Homann de Topin, 2020).

2.6.3 Algoritmo de treinamento nas RNA

Existem dois tipos de treinamento nas RNA: o treinamento (aprendizagem) supervisionado, que obtém a solução para os problemas em forma de sinais de entrada, comparando os dados de resposta esperados com os dados de saída da RNA. E outro tipo de aprendizagem chamado de treinamento não supervisionado, no qual não há exemplos de resposta para executar o treinamento, restando apenas a correlação dos parâmetros de entrada; nessa situação, a RNA tenta criar categorias de saída que se correlacionem com as categorias de entrada (Otuyama, 2020).

2.6.4 RNA método autorregressivo

Genericamente e de modo simplificado, Magalhães de Pinho (2019) define o modelo autorregressivo como sendo uma aplicação de uma dada função:

A classe de modelos autorregressivos é caracterizada por uma formulação para $f(t)$ onde apenas as defasagens dos retornos são capazes de modelar o retorno em t , sendo o termo de erro (a_t) um ruído branco estacionário (média zero, variância constante e não-autocorrelacionado).

O modelo autorregressivo é representado pela Equação 6.

$$r_t = \phi_0 + \phi_1 r_{t-1} + \phi_2 r_{t-2} + \phi_3 r_{t-3} + \dots + \phi_p r_{t-p} + a_t \quad (6)$$

na qual estão tempo (t), valores passados de retorno (r), valor das defasagens (p), fator de autocorrelação (ϕ) e erro do tipo ruído branco estacionário (a).

2.6.5 Modelo BRAMS

O modelo BRAMS é explicado pelo Centro de Previsão de Tempo e Estudos Climáticos e pelo Instituto Nacional de Pesquisas Espaciais (2021): “BRAMS é um sistema de modelagem numérica projetado para previsão e pesquisa atmosférica em escala regional, com foco na química atmosférica, na qualidade do ar e nos ciclos biogeoquímicos”. Esse modelo constitui uma ferramenta para estudo/pesquisa do clima, tão confiável quanto os seus homólogos empregados em outros países, possuindo um conjunto de parametrizações e funcionalidades que são de alto desempenho

(Centro de Previsão de Tempo e Estudos Climáticos; Instituto Nacional de Pesquisas Espaciais, 2016). Na sequência, serão definidas as principais funções matemáticas utilizadas neste artigo.

2.7 Erro médio absoluto

Segundo Acharya (2021), podemos definir o erro médio absoluto – EMA (*mean absolute error* – MAE) como sendo:

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - Y_j| \quad (7)$$

As variáveis são: número de observações/amostras (n), valor atual da amostra (y) e valor futuro da amostra (Y). Os gráficos de comparação de eficiência de predições deste trabalho são avaliados por meio da função de EMA.

2.8 Correlação

Como definido por Lima Filho (2021), a correlação tem por finalidade mensurar o grau de relacionamento entre duas variáveis, ou seja, se essas variáveis forem representadas num gráfico de dispersão e seus pontos de representação estiverem ao longo de uma reta imaginária, as duas variáveis apresentarão correlação. Sua principal notação matemática pode ser definida pelo coeficiente de correlação linear de Pearson:

$$r = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}} \quad (8)$$

tal que: r é sempre um valor entre -1 a 1 , variável qualquer(x), variável qualquer(y). Relação diretamente proporcional é indicada por valores positivos da correlação; já valores negativos revelam que a relação entre as variáveis é inversamente proporcional.

2.9 Equação da velocidade

Brandão *et al.* (2020) definem a velocidade aproximada do vento como sendo expressa por:

$$V = v_{ref} \frac{\log^{h_2/z_0}}{\log^{h_1/z_0}} \quad (9)$$

e definindo as variáveis: velocidade estimada (V), velocidade atual (v), altura em que foi medida a velocidade atual (h_1), altura em que será medida a velocidade estimada (h_2) e coeficiente de rugosidade do solo (z_0).

2.10 Normalização de variáveis

Os gráficos apresentados nas simulações têm no geral suas variáveis normalizadas para melhor representação dos fenômenos nas execuções dos códigos em Python, como expõe Almaliki (2018). A normalização máx-mín se expressa na Equação 10:

$$x_i = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (10)$$

O intervalo dessas variáveis compreende geralmente de 0 a 1 ou de -1 a 1, tendo x_i como valor normalizado, x sendo o valor a ser convertido, x_{min} o valor mínimo da variável x e x_{max} o seu valor máximo. A seguir, é descrita a linguagem de programação utilizada neste trabalho.

2.11 Linguagem de programação Python

Para a realização das simulações e do estudo de variáveis, foi utilizada a linguagem de programação Python, por sua versatilidade, simplicidade e rápida implementação. A utilização dessa linguagem é vantajosa, já que conta com inúmeras bibliotecas, em grande medida por causa da Python Foundation e dos colaboradores no mundo todo, sendo umas das linguagens mais adotadas, com destaque para IA e banco de dados, entre outros (Coutinho Menezes, 2010). Para executar as instruções em Python, foi utilizado o ambiente *web* do Google Colab ou Colaboratory, por sua acessibilidade (*on-line*) e simples execução (Google Research, 2021).

Para fazer os treinamentos dos modelos de previsão, este trabalho usa as bibliotecas do TensorFlow (2021), em especial a biblioteca Keras, que possui as ferramentas de redes neurais profundas de uso rápido e prático (Chollet, 2015). Todo o código desenvolvido nesta pesquisa e todos os gráficos gerados estão disponíveis em: <https://github.com/MichelOliveira47/Arquivos-TCC-II>.

Na sequência, é definida a microgeração distribuída, pois operadores de aerogeradores de pequeno ou médio porte podem se beneficiar desse recurso.

2.12 Microgeração ou minigeração distribuída

Tanto a microgeração ou minigeração distribuída são definidas pela produção de energia elétrica via fontes renováveis de energia, em pequenas estações geradoras que estão conectadas à rede de distribuição. Diferem-se quanto à potência de geração, à microgeração até 75 (kW) e à minigeração de 75 (kW) até 5 (MW) (Agência Nacional de Energia Elétrica, 2018).

A microgeração compreende um grupo de equipamentos específicos que produzem energia elétrica, sendo os mais comuns aqueles de uso residencial, nos quais são encontrados mais facilmente painéis fotovoltaicos para captação de energia solar ou microturbinas para geração de energia proveniente do vento. No uso residencial, também são encontrados aparelhos para cogeração, tais como turbina a vapor, motores alternativos, motores *stirling*, microturbinas e pilhas de combustível (Santos Moreira, 2010).

Esses equipamentos permitem participação na geração distribuída na rede elétrica, ou seja, ao gerar a própria energia, o proprietário pode conseguir abatimentos nas contas no uso de energia elétrica por baixo consumo ou por ceder à rede a energia da microgeração, tendo por principais vantagens a proximidade do consumidor com a produção de energia e benefícios ambientais que permitem menos desperdício de energia elétrica ao usar a rede-padrão, tanto na transmissão quanto na distribuição (Nascimento Araujo, 2016).

2.13 Aerogerador Air Silent X

O trabalho atual considera para a microgeração o aerogerador Air Silent X, por ser um produto comercial mais acessível financeiramente (US\$ = 1,429.00) e ter uma relação custo-benefício atrativa. O Air Silent X pode ser instalado em alturas ajustáveis (Maduro Ramos, 2016). Na Figura 3, são apresentadas suas especificações técnicas.



Parâmetro	Valores
Diâmetro do rotor	1,17 m
Peso	5,9 kg
Tensão nominal (V_{DC})	12 V
Tensão de ajuste (V_a)	Entre 13,6 e 17,0 V
Potência máxima ($P_{máx}$)	430 W
Vento para início de geração (v_g)	3,13 m/s
Vento limite	49,2 m/s
Produção de energia	90 Ah/dia a 5,5 m/s

Figura 3 Especificações do Air Silent X

Fonte: Maduro Ramos (2016).

2.14 Potencial fotovoltaico no Rio Grande do Sul

Este trabalho faz estudos do potencial eólico na região de Santa Vitória do Palmar e Barra do Chuí, entretanto essas áreas também possuem potencial de geração de energia solar por meio de painéis com células fotovoltaicas. Estudos paralelos podem ser feitos, já que aerogeradores e painéis solares podem ser instalados em conjunto. A Tabela 1 revela a geração de energia solar e compara com o gasto de energia residencial na Unidade da Federação (UF) do Rio Grande do Sul.

TABELA 1

Potencial de geração fotovoltaica em residências do Rio Grande do Sul

UF	Potencial Fotovoltaico Residencial (MW médios)	Potencial Fotovoltaico Residencial (GWh/ano)	Consumo Residencial Anual 2013 (GWh)	Potencial Fotovoltaico/Consumo Residencial (%)
RS	1.970	17.257	7.750	223

Fonte: Oliveira da Rosa e Perin Gasparin (2016).

Portanto, essa região também possui potencial de geração de energia a partir do hidrogênio verde, via dispositivos de eletrólise que são ligados a fontes de energias limpas, como os geradores de energia solar e eólica, permitindo a produção de hidrogênio em estado puro, com possível aplicação para combustão de motores (Dantas *et al.*, 2020).

Na sequência, será apresentada a metodologia em que serão exibidas as ações e abordagens que permitem a realização do estudo proposto neste trabalho, iniciando pela escolha da região.

3 METODOLOGIA

3.1 Escolha da região para medições

Seguindo os critérios estabelecidos pela Universidade Federal do Rio de Janeiro (2021), foram realizadas pesquisas prévias no *Atlas eólico brasileiro* (Centro de Pesquisas de Energia Elétrica, 2013), contendo simulações em modelo BRAMS para todo o território nacional. Aparecem em destaque algumas regiões da Federação, que possuem a maior velocidade média do vento por altura (no caso, a 50 m), tais como Norte (Roraima), Nordeste (Rio Grande do Norte, Bahia e Ceará), Sudeste (Minas Gerais e São Paulo), Centro-Oeste (Mato Grosso do Sul) e Sul (Rio Grande do Sul, Paraná e Santa Catarina). Na Figura 4 podem ser observadas as áreas com maior velocidade média dos ventos com incidência anual:

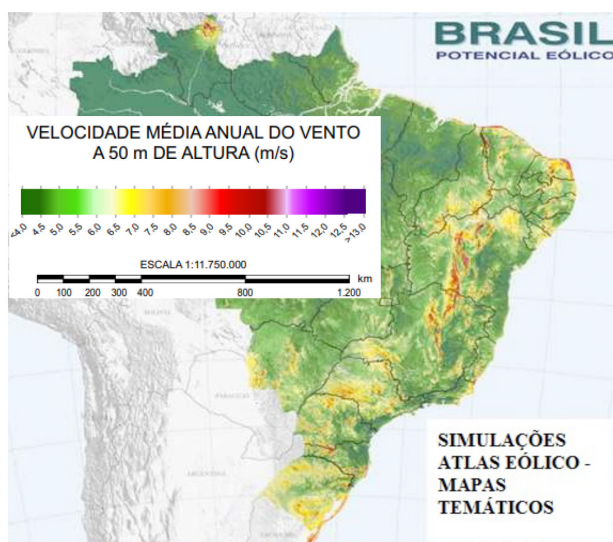


Figura 4 Velocidade média do vento anual a 50 m de altura no território brasileiro

Fonte: Centro de Pesquisas de Energia Elétrica (2013).

Com base na Figura 4, o estado do Rio Grande do Sul foi selecionado para o estudo, com destaque para as áreas que compreendem os municípios Barra do Chuí e Santa Vitória do Palmar. Em seguida, pesquisou-se a estação meteorológica mais propícia ao estudo na região, no caso específico, a estação de leitura automática A899 (Instituto Nacional de Meteorologia, 2021).

Os dados coletados da estação A899 estão disponíveis *on-line* em formato de planilhas Excel, com períodos de tempo anuais, com medições a 26 m de altura. Os dados disponíveis possuem a velocidade média do vento, o que possibilita o estudo de viabilidades de área e econômica (Universidade Federal do Rio de Janeiro, 2021).

3.2 Análise de dados e previsões

A partir da coleta do banco de dados das medições meteorológicas, esses dados foram tratados para ser inseridos no ambiente Python de Google Colab. Nesse ambiente, utilizaram-se as principais bibliotecas com funções necessárias para a análise dos dados e execução dos modelos. Entre as bibliotecas, destacam-se Datetime, Matplotlib, Numpy, Pandas, Seaborn e TensorFlow (Google Research, 2021).

As linhas de código implementadas em Python permitiram a leitura do banco de dados de interesse, a análise estatística, a simulação dos modelos e a comparação dos resultados para estimar o modelo mais adequado.

Além disso, geraram-se gráficos para a pré-visualização deles, e aplicou-se a normalização dos dados necessários para o treinamento de modelos de IA para fazer as respectivas previsões. Realizaram-se correlações para observar a forte ou fraca relação entre uma variável e outra. Esses efeitos foram exibidos em gráfico e analisados, permitindo definir as grandezas com maior influência nos modelos.

A partir do tratamento prévio dos dados do Instituto Nacional de Meteorologia (2021), os modelos foram treinados para fazer as previsões da velocidade do vento num período predefinido. Por fim, foram comparados os modelos de previsões por meio do EMA, pois, como definem Camelo *et al.* (2018), existem outras formas de verificar a acurácia das previsões por análise estatística de erros, contudo este artigo busca facilitar a experiência do usuário iniciante na interpretação dos resultados das previsões, usando como comparador o EMA (TensorFlow, 2021).

3.3 Treinamento de modelos e previsões com IA

Para os treinamentos da IA, foram utilizados dois tipos de modelos: os de saída única, que a partir de dados do passado, fazem a previsão de um único valor no futuro;

e os de múltiplas saídas, que treinam a rede com diversos valores do passado, prevendo vários valores no futuro.

Os modelos utilizados tanto em saída única como em múltiplas saídas foram: linha de base (*linebase*), linear (*line*), denso (*dense*), redes neurais recorrentes RNN – LSTM (do inglês Recurrent Neural Network e Long Short Term Memory, respectivamente) e rede neural convolucional CNN (do inglês Convolutional Neural Network). O modelo de múltiplas etapas densas (do inglês *multi-step dense*) foi adicionado para saída única, e, para múltiplas saídas, o modelo autorregressivo de médias móveis AR LSTM (do inglês Autoregressive Network) (TensorFlow, 2021).

4 RESULTADOS E DISCUSSÃO

4.1 Escolha da região

Para a escolha da região, foi seguido o roteiro de pesquisa conforme os parâmetros estabelecidos pela Universidade Federal do Rio de Janeiro (2021), e, nesse sentido, os registros de ventos com maior potencial estão na Região Sul, nos municípios de Barra do Chuí e Santa Vitória do Palmar. Esses dados foram coletados a uma altura de 26 m, que é uma altura próxima à inicial para geração de grandes aerogeradores. Além disso, apresentaram uma velocidade anual dentro da necessária para a exploração comercial de 5,16 m/s em 2020 ou mais significativa com 8,52 m/s em 2017. Os dados analisados também apresentaram os registros anuais, mais completos, sem grandes interrupções em medições entre as regiões onde mais venta no Brasil. Também foi observado o tipo de topografia adequado da região, que pode ser visto na Figura 5.




Figura 5 Topografia de Barra do Chuí e Santa Vitória do Palmar

Fonte: Elaborado pelos autores.

A Figura 5 ilustra a homogeneidade da altitude na região litorânea, com suaves variações, sendo notáveis as extensas regiões planas, propícias para a aerogeração. A obtenção dessa informação foi possível por meio da ferramenta *on-line* de topografia (Topographic-map, 2021). Na Figura 6, pode ser observada a velocidade do vento no intervalo de 6,5 a 7,5 m/s para uma altura próxima de 30 m.




Figura 6 Velocidade média anual do vento na Região Sul do Brasil

Fonte: Centro de Pesquisas de Energia Elétrica (2013).

4.2 Selecionando o melhor período de medições nas planilhas

O banco de dados climáticos do Instituto Nacional de Meteorologia (2021) compreende os anos de 2000 a 2021 (até 31 de agosto de 2021), contudo, na verificação detalhada dos dados, foi possível observar que grande parte das tabelas possui valores não preenchidos ou errôneos. As tabelas com menor número de erros correspondem ao período de 2005 a 2020, possibilitando seu uso mais adequado na análise de séries temporais. Esses dados foram formatados e corrigidos adequadamente para inserção no ambiente Google Colaboratory, com uma avaliação estatísticas deles.

4.3 Estatísticas dos dados climáticos de 2005 a 2020

Na Tabela 2, apresentam-se as grandezas atmosféricas disponíveis, sendo de maior interesse a velocidade do vento (um total de 52.608 medições de 2015 a 2020), que registrou a média de 4,76 m/s nos cinco anos de medições. Além disso, 50% das amostras possuem valor igual ou superior a 4,4 m/s, e 75% das amostras atingem 6,4 m/s ou mais. Algumas grandezas extraídas do banco de dados não apresentam acentos do português e para evitar conflitos em uma futura atualização dos dados, esses acentos não foram corrigidos e aparecerão ao longo do texto em figuras e tabelas com as palavras originais da extração.

TABELA 2

Estatísticas das variáveis climáticas de 2005 a 2020

	count	mean	std	min	25%	50%	75%	max
PRECIPITAÇÃO TOTAL. HORÁRIO (mm)	52608.0	0.121373	0.938881	0.0	0.0	0.0	0.00	44.6
PRESSAO ATMOSFERICA AO NIVEL DA ESTACAO. HORARIA (mB)	52608.0	966.187639	216.802611	0.0	1009.8	1014.4	1018.80	1034.9
PRESSÃO ATMOSFERICA MAX.NA HORA ANT. (AUT) (mB)	52608.0	966.197459	217.389614	0.0	1010.1	1014.6	1019.10	1034.9
PRESSÃO ATMOSFERICA MIN. NA HORA ANT. (AUT) (mB)	52608.0	965.672702	217.274537	0.0	1009.5	1014.1	1018.60	1034.7
RADIAÇÃO GLOBAL (KJ.m ²)	52608.0	509.154976	959.241629	0.0	0.0	0.0	543.95	4496.6
TEMPERATURA DO AR - BULBO SECO. HORARIA (°C)	52608.0	16.545811	6.406338	0.0	12.9	17.1	21.30	36.1
TEMPERATURA DO PONTO DE ORVALHO (°C)	52608.0	13.572774	5.753152	-3.9	10.3	14.2	17.90	26.7
TEMPERATURA MÁXIMA NA HORA ANT. (AUT) (°C)	52608.0	17.010126	6.531206	0.0	13.2	17.6	21.70	37.0
TEMPERATURA MÍNIMA NA HORA ANT. (AUT) (°C)	52608.0	16.096003	6.298578	0.0	12.5	16.7	20.80	35.3
TEMPERATURA ORVALHO MAX. NA HORA ANT. (AUT) (°C)	52608.0	14.029231	5.791837	-2.5	10.8	14.6	18.30	27.0
TEMPERATURA ORVALHO MIN. NA HORA ANT. (AUT) (°C)	52608.0	13.122466	5.736928	-4.6	9.7	13.7	17.40	25.6
UMIDADE REL. MAX. NA HORA ANT. (AUT) (%)	52608.0	80.986789	21.362790	0.0	76.0	87.0	94.00	100.0
UMIDADE REL. MIN. NA HORA ANT. (AUT) (%)	52608.0	77.025148	21.855952	0.0	70.0	82.0	92.00	100.0
UMIDADE RELATIVA DO AR. HORARIA (%)	52608.0	79.087876	21.579699	0.0	73.0	85.0	93.00	100.0
VENTO, DIREÇÃO HORARIA (gr) (° (gr))	52608.0	150.352418	105.935451	0.0	60.0	137.0	242.00	360.0
VENTO, RAJADA MAXIMA (m/s)	52608.0	7.880056	4.037587	0.0	5.1	7.6	10.30	32.4
VENTO, VELOCIDADE HORARIA (m/s)	52608.0	4.757503	2.812152	0.0	2.8	4.4	6.40	23.0

Fonte: Elaborado pelos autores.

Também é possível notar que a região escolhida tem baixa precipitação, com registro médio de 0,213 mm.

Conhecendo os valores de velocidade do vento obtidos nas tabelas (medições), é possível estimar a velocidade do vento para alturas superiores de interesse, em caso de grandes aerogeradores, de alturas mais comuns de 80, 100 e 120 m (Associação Brasileira de Energia Eólica, 2019). A partir da Equação 9 são obtidas velocidades de 7,31, 7,5 e 7,64 (m/s), respectivamente. Tendo esses valores confirmados nas simulações do Centro de Pesquisas de Energia Elétrica (2013), foi utilizado o coeficiente de rugosidade do solo igual a 0,01, que é definido pela Secretaria do Meio Ambiente e Infraestrutura (2014), com valor z_0 no intervalo de 0,001 a 0,01 para solo com pouca vegetação e velocidade do vento média igual a 6,4 m/s.

4.4 Potencial de geração de energia elétrica

A partir do banco de dados obtido, pode-se constatar que entre 2017 e 2020 a velocidade média do vento corresponde a 5,89 m/s (Instituto Nacional de Meteorologia, 2021). Utilizando essa informação e visando à sua utilização em microgeração, é

possível estimar uma produção de energia elétrica acima de 1.080 Wh/dia se for instalado um aerogerador Air Silent X. Isso mostra que pode ser viável a instalação desse tipo de equipamento para uso residencial, permitindo aos usuários domésticos participarem da microgeração de energia distribuída e de seus benefícios.

4.5 Correlação das variáveis climáticas

Foi calculada a matriz de correlação com todas as colunas originais para o ano 2020. De todas as variáveis correlacionadas, “vento, velocidade horária” apresenta maior correlação com a variável “rajada máxima de vento”, com valor de 0,91. Já com as variáveis restantes, o valor de correlação varia de -0,029 a 0,19, considerada como correlação bem fraca (Araujo; Santos; Gomes, 2019).

Posteriormente foi utilizado um período maior de tempo, de 2015 a 2020, obtendo um melhor resultado, como apresenta-se na matriz de correlação da Figura 7.

Na Figura 7, pode-se observar que a correlação da variável “vento, velocidade horária” com a variável “rajada máxima de vento” para o intervalo 2015 a 2020 é similar à correlação analisada anteriormente (0,92); já a correlação com as variáveis restantes apresenta um incremento considerável no valor de 0,029 a 0,38, em que se destacam as variáveis de pressão atmosférica, temperatura e umidade, registrando as maiores alterações (valores crescentes) dos valores de correlação. Outro destaque é a variável de radiação, que é a única registrando valor de correlação decrescente, passando de 0,19 para 0,13.

PRECIPITAÇÃO TOTAL. HORÁRIO (mm)	0.052055
PRESSAO ATMOSFERICA AO NIVEL DA ESTACAO. HORARIA (mB)	0.384099
PRESSÃO ATMOSFERICA MAX.NA HORA ANT. (AUT) (mB)	0.383815
PRESSÃO ATMOSFERICA MIN. NA HORA ANT. (AUT) (mB)	0.383519
RADIACAO GLOBAL (KJ.m ²)	0.135574
TEMPERATURA DO AR - BULBO SECO. HORARIA (°C)	0.285867
TEMPERATURA DO PONTO DE ORVALHO (°C)	0.191952
TEMPERATURA MÁXIMA NA HORA ANT. (AUT) (°C)	0.282646
TEMPERATURA MÍNIMA NA HORA ANT. (AUT) (°C)	0.296585
TEMPERATURA ORVALHO MAX. NA HORA ANT. (AUT) (°C)	0.208967
TEMPERATURA ORVALHO MIN. NA HORA ANT. (AUT) (°C)	0.187909
UMIDADE REL. MAX. NA HORA ANT. (AUT) (%)	0.226471
UMIDADE REL. MIN. NA HORA ANT. (AUT) (%)	0.186148
UMIDADE RELATIVA DO AR. HORARIA (%)	0.201872
VENTO, DIREÇÃO HORARIA (gr) (° (gr))	0.042561
VENTO, RAJADA MAXIMA (m/s)	0.914940
VENTO, VELOCIDADE HORARIA (m/s)	1.000000
Name: VENTO, VELOCIDADE HORARIA (m/s), dtype: float64	

Figura 7 Correlação das variáveis climáticas com “VENTO, VELOCIDADE HORÁRIA (m/s)” – Inmet (de 2015 a 2020)

Fonte: Elaborado pelos autores.

Correlações baixas de variáveis climáticas podem apresentar-se em grande medida pelo fato de o estudo concentrar-se numa região específica. Para uma compreensão melhor dos fenômenos climáticos, são necessários estudo e acompanhamento em escala global, utilizando variados centros meteorológicos de diversos países, além de dados via satélite. Mesmo na atualidade, o clima continua sendo um fenômeno altamente complexo (Instituto Nacional de Pesquisas Espaciais, 2021).

A seguir serão analisados e avaliados vários modelos de previsão, os quais contemplam 24 horas no futuro e cinco anos de passado (treinamento). As 24 horas foram definidas por causa das limitações da ferramenta *on-line*.

4.6 Previsões de disparo único e múltiplos

A partir da base de dados meteorológica, já tratada, foi realizado o treinamento dos modelos de previsão de saídas únicas e de múltiplas saídas. Cada modelo recebe como entrada o banco de dados de 2015 a 2020, com os nomes das variáveis climáticas (precipitação, pressão, radiação etc.) exibidos na Figura 7, e a previsão é testada com 24 horas futuras. Os resultados obtidos nas previsões utilizando TensorFlow (2021) mostram que os modelos de múltiplas saídas possuem erro menores que os

modelos de saídas únicas. A análise de vários períodos com todos os modelos está disponível em: <https://github.com/MichelOliveira47/Arquivos-TCC-II>.

Na Figura 8 é exibida a acurácia entre os modelos de previsão de etapa única e múltiplas saídas.

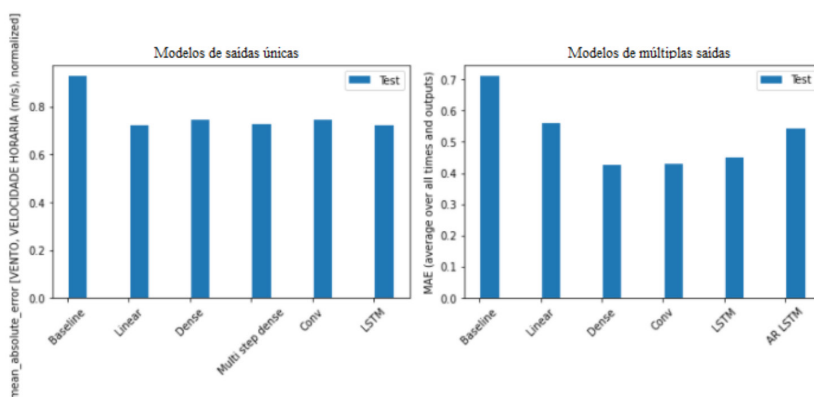


Figura 8 Comparação entre os métodos de previsões

Fonte: Imagem do autor.

Os resultados das previsões foram avaliados pelo EMA, pois, para um grande número de amostras, cada variável isolada não possui grande peso nas medições, e, como é perceptível, os modelos mais complexos, no caso, os de múltiplas saídas, obtiveram menor erro e, conseqüentemente, maior precisão. Na sequência, é realizada a comparação de previsões com dados de intervalos diferentes de tempo, o primeiro de três anos e o segundo de cinco anos.

4.6.1 Diferenças do erro (EMA) de 2016 a 2018 e de 2015 a 2020

A partir do estudo das planilhas Excel dos dados climáticos do Instituto Nacional de Meteorologia (2021), observou-se que os dados dos anos 2000 a 2014 possuem inconsistências, tais como ausência de leituras dos anemômetros (linhas sem dados) e valores preenchidos como -9999 em todas as variáveis.

Por isso, o intervalo de 2015 a 2020 foi estabelecido para as previsões por seus dados apresentarem maior consistência, sem a necessidade de muitas correções. Isso posto, foi realizado o comparativo entre as previsões da planilha 2016 a 2018 (três anos) e da planilha 2015 a 2020 (cinco anos). Na Figura 9, é possível constatar que os

modelos de IA utilizados têm maior capacidade de aprendizado com um conjunto maior informações.




Figura 9 Comparação entre os métodos de previsões

Fonte: Imagem do autor.

Como indicado no parágrafo anterior, com uma escala de tempo menor, todos os métodos da planilha de dados de 2016 até 2018 apresentaram resultados com erros maiores; em contrapartida, os mesmos métodos no intervalo de tempo de 2015 até 2020 apresentaram significativa redução nos erros. Isso mostra que os algoritmos de IA melhoram sua *performance* com um histórico maior de dados.

Os resultados das previsões indicam que o método de múltiplas etapas com o modelo denso e o modelo convolucional foram os que apresentaram os melhores resultados, diferenciando-se entre si por apenas 1,62%, o que os torna semelhantes no nível de resposta. Comparando o melhor e o pior modelo, respectivamente, há o seguinte: o modelo de múltiplas etapas com rede neural do tipo denso (*dense*) com EMA de 0,4260 e, em contraparte, o modelo com rede neural do tipo linha de base com EMA de 0,7103. Na Figura 10, pode ser observado o comportamento do resultado dos dois modelos comparados.




Figura 10 Acurácia do melhor e pior modelo de previsão, respectivamente

Fonte: Imagem do autor.

Na Figura 10, os gráficos em azul representam as entradas (*inputs*) da rede neural, os círculos em verde representam os rótulos (*labels*) de valores verdadeiros, e os valores em “x” vermelho são as previsões (*predictions*).

5 CONSIDERAÇÕES FINAIS

O presente trabalho realizou estudos simplificados, por um lado, para localizar no território nacional a região mais propícia para geração de energia eólica, ou seja, a que tivesse ventos adequados (entre 6 e 7,5 m/s) para a instalação de aerogeradores eólicos, com foco no uso residencial ou de microgeração.

Por outro lado, realizou-se um breve estudo dos parâmetros climáticos que mais impactam a velocidade do vento, como a altura das medições. Com o objetivo de responder a essas questões, utilizaram-se dados meteorológicos disponíveis e ferramentas de forma totalmente *on-line* a fim de facilitar o acesso a todos que necessitem investigar problemas similares.

Nesse sentido, foi encontrado no *site* do Instituto Nacional de Meteorologia o banco de dados climáticos mais completo e atualizado sobre o clima de todas as regiões do

território brasileiro, que, após ser conferido, teve o estado do Rio Grande do Sul em destaque, especialmente para as regiões dos municípios da Barra do Chuí e Santa Vitória do Palmar, onde foram focados os estudos deste artigo. Na sequência, a fim de conhecer a região e verificar se a área é majoritariamente plana, foi utilizado o Topographic-map, que confirmou a viabilidade da região citada para a instalação de aerogeradores eólicos.

Foi utilizada a ferramenta TensorFlow (em Python) em ambiente *on-line* do Google Colaboratory para processar o banco de dados de variáveis climáticas das estações do Inmet. Na análise estatística inicial, foram obtidos valores de velocidade do vento iguais ou superiores a 6,40 m/s para 75% das amostras, confirmando que a região selecionada é adequada para a instalação de aerogeradores.

Além disso, na mesma ferramenta, realizaram-se treinamento e teste para a previsão de velocidade do vento, utilizando modelos de IA embutidos na ferramenta que permitem de forma simples a usuários com pouco fundamento científico (“leigos”) interagir com ela.

Foram utilizados 12 tipos distintos de modelos de previsão, dentro dos quais se destacaram o denso e o convolucional, por seu baixo EMA.

Os modelos citados podem ser utilizados para a realização de estudos gratuitos (sem a necessidade de contratar algum serviço especializado) e prévios dos parâmetros climáticos e da velocidade média do vento na região, permitindo ao usuário comum testar bancos de dados climáticos em qualquer localidade para estimar o potencial da geração de energia eólica.

Dessa maneira, é possível evitar a necessidade de compra de instrumentos meteorológicos, fazendo um teste prático de viabilidade econômica antecipado, evitando prejuízos econômicos para os investidores na etapa de exploração do local com alto potencial de geração de energia.

Para trabalhos futuros, é recomendado o estudo das correlações das variáveis climáticas em mais unidades da Federação, assim como aprofundamento em métodos específicos de redes neurais utilizados neste artigo. Além disso, investigar o treinamento das redes a profundidade, utilizando diversos conjuntos de variáveis.

Neste estudo foi possível identificar, por exemplo, a forte correlação positiva de algumas variáveis climáticas sobre a velocidade do vento, tendo destaque a rajada máxima (correlação igual a 0,92). Esse tipo de análise pode ser utilizado para selecionar as variáveis mais indicadas para o treinamento assertivo dos modelos de IA.

WIND SPEED FORECAST STUDY: PRACTICAL APPLICATION OF ARTIFICIAL INTELLIGENCE IN THE SEARCH AND USE OF WIND ENERGY

Abstract

This article provides a quick guide that is easy to access for the user, using on-line tools, focusing on wind power generation and choosing the best region for installing wind turbines. Highlighting the Topographic-map tools, for terrain feasibility in the installation of wind turbines and Google Collaboration to perform functions based on artificial intelligence to understand climate data from the region itself and predict future values of these same data. Furthermore, it is possible to explore another type of distributed generation, such as solar, using these same data and with some code changes. To carry out the proof of concept, in this research, the programming language Python was used in the Google Collaborative environment, with functions and libraries from TensorFlow, which contains several models of neural networks. To carry out the research, a climate database was used for the period 2015 to 2020, extracted from the National Institute of Meteorology and altitude records from the *Brazilian wind atlas*. The present work found that the best correlation results for climatic variables and forecasts are proportional to the increase in the database. The need for a good internet connection to perform medium and long term forecasts was also perceived, due to the initial loading of the database in the on-line application. Several artificial intelligence models were tested in the wind speed predictions, which were compared by mean absolute error to find the most suitable model. Highlights the dense and convolutional model (multiple output method).

Keywords: Time series. Wind energy. Artificial intelligence. Neural network. Forecast. Wind speed.

REFERÊNCIAS

ABEEÓLICA. RN tem potencial eólico duas vezes maior que o estimado em 2003. Revista técnica [on-line]: Alturas de aerogeradores mais utilizadas. Associação Brasileira de Energia Eólica - ABEEólica, 21 dez. 2022. Disponível em: <https://abeeolica.org.br/rn-tem-potencial-eolico-duas-vezes-maior-que-o-estimado-em-2003/>. Acesso em: 2 jun. 2021.

ACHARYA, S. What are RMSE and MAE? A simple guide to evaluation metrics, 2021. Site técnico - Consulta de métricas de erro [on-line]. Disponível em: <https://towardsdatascience.com/what-are-rmse-and-mae-e405ce230383>. Acesso em: 14 jun. 2021.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. Anel, 2018. Micro e Minigeração Distribuída. Site governamental [on-line]. Saiba mais sobre micro e minigeração distribuída. Disponível em: <https://www.anel.gov.br/geracao-distribuida>. Acesso em: 16 nov. 2021.

ALMALIKI, Z. A. Standardization vs Normalization - Site técnico [on-line]. Medium, 2018. Disponível em: <https://dataakkadian.medium.com/standardization-vs-normalization-da7a-3a308c64>. Acesso em: 1º out. 2021.

ARAUJO, J. V. G. A.; SANTOS, M. dos; GOMES, C. F. S. Desenvolvimento de um código em Python para geração de matrizes de correlação de Pearson com laços a partir de “n” variáveis tomadas duas a duas. In: SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA, 19., 2019. Rio de Janeiro, RJ, Brasil. Documento pdf [on-line]. Disponível em: https://www.researchgate.net/profile/Marcos_Dos_Santos6/publication/335796808_Desenvolvimento_de_um_codigo_em_Python_para_geracao_de_Matrizes_de_Correlacao_de_Pearson_com_lacos_a_partir_de_n_variaveis_tomadas_duas_a_duas/links/5dda8572458515dc2f496965/Des. Acesso em: 23 jul. 2021.

BRANDÃO, J. H. C. *et al.* Estudo do potencial eólico do município de Apodi e região de Pau dos Ferros - RN. *Anais do V Conapesc.* Campina Grande: Realize Editora, 2020. Disponível em: <https://editorarealize.com.br/artigo/visualizar/72898>. Acesso em: 15 ago. 2021.

CAMELO, H. do N. *et al.* Proposta para previsão de velocidade do vento através de modelagem híbrida elaborada a partir dos modelos ARIMAX e RNA. Grupo de pesquisas - Programa de Pós-Graduação em Ciências Climáticas, Universidade Federal do Rio Grande do Norte, Campus Lagoa Nova, Natal, RN, Brasil, 2018. Site científico, página com resultados da pesquisa [on-line]. Disponível em: <https://www.scielo.br/j/rbmet/a/n6cRPrvLYyhdhYyJhgKFcXv/?lang=pt>. Acesso em: 12 maio 2021.

CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA. *Atlas eólico brasileiro: simulações 2013.* Brasília: Cepel, 2013. Atlas – Resultados de pesquisa, velocidades médias do vento sobre o território nacional, Brasil. Site Governamental [on-line]. Disponível em: <http://novoatlas.cepel.br/index.php/mapas-tematicos/>. Acesso em: 2 nov. 2021.

CENTRO DE PREVISÃO DE TEMPO E ESTUDOS CLIMÁTICOS; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Cptec, Inpe, 2016. CPTEC/INPE lança nova versão

do modelo BRAMS. Site informativo governamental [on-line]. Disponível em: http://www.inpe.br/noticias/noticia.php?Cod_Noticia=4133. Acesso em: 15 nov. 2021.

CHOLLET, F. Keras simples. Flexível. Poderoso - Keras: Deep Learning for humans, 2015. Biblioteca de programação em Python de código aberto. Site [on-line]. Disponível em: <https://keras.io/>. Acesso em: 15 ago. 2021.

COUTINHO MENEZES, N. N. Introdução à Programação com Python. Algoritmos e lógica de programação para iniciantes 2010. Documento técnico pdf [on-line] – Capítulo I. Disponível em: <https://s3.novatec.com.br/capitulos/capitulo-9788575222508.pdf>. Acesso em: 23 out. 2021.

DANTAS, M. *et al.* IFE: Informativo Eletrônico de Hidrogênio – GESEL-UFRJ. Grupo de estudos do Setor Elétrico. Site [on-line]. Universidade Federal do Rio de Janeiro, 2020. Disponível em: <https://gesel.ie.ufrj.br/ife/ife-h2-59/>. Acesso em: 23 nov. 2021.

FLECK, L. *et al.* Redes neurais artificiais: princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia* [on-line], v. 7, n. 15, 2016. Disponível em: <https://periodicos.utfrpr.edu.br/recit/article/view/4330>. Acesso em: 12 set. 2021.

GOOGLE RESEARCH. Colaboratory, 2021. Site de simulação para escrever e executar linguagem de programação Python no navegador [on-line]. Disponível em: https://colab.research.google.com/?utm_source=scs-index#scrollTo=5fCEDCU_qrC0. Acesso em: 3 maio 2021.

HOMANN DE TOPIN, L. O. *Redes neurais convolucionais e sua aplicação assistiva como auxílio para identificação de curvas algébricas no plano cartesiano*. 2020. Dissertação (Mestrado em Engenharia da Computação) – Universidade Federal do Rio Grande, Rio Grande, 2020. Disponível em: <https://sistemas.furg.br/sistemas/sab/arquivos/bdtd/0000013595.pdf>. Acesso em: 1º out. 2021.

INSTITUTO DE ASTRONOMIA, GEOFÍSICA E CIÊNCIAS ATMOSFÉRICAS. Formação do vento. IAG, 2021. Site informativo [on-line]. Disponível em: <https://www.iag.usp.br/siae98/meteorologia/dinamica.htm>. Acesso em: 6 maio 2021.

INSTITUTO NACIONAL DE METEOROLOGIA. Inmet, 2021. Site governamental com simulador climático para consulta [on-line]. Disponível em: <https://portal.inmet.gov.br/>. Acesso em: 15 jun. 2021

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Inpe, 2021. Site governamental informativo para consulta de efeitos climáticos [on-line]. Disponível em: <http://www.inpe.br/faq/index.php?pai=3>. Acesso em: 13 out. 2021.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. IPCC, 2021. Cap. 7, Wind Energy. Estudos climáticos, documento pdf [on-line]. Disponível em: https://www.ipcc-wg3.de/report/IPCC_SRREN_Ch07.pdf. Acesso em: 14 maio 2021.

LIMA FILHO, L. M. de A. *Correlação e regressão*. Universidade Estadual da Paraíba, 2021. Documento didático pdf, p. 5-9 [on-line]. Disponível em: <http://www.de.ufpb.br/~luiz/AED/Aula9.pdf>. Acesso em: 26 jun. 2021.

MADURO RAMOS, H. *Microgeração de eletricidade com energia eólica*. 2016. Trabalho de Conclusão de Curso – Universidade Estadual Paulista, Guaratinguetá, 2016. Documento pdf [on-line].

Disponível em: <https://repositorio.unesp.br/bitstream/handle/11449/155262/000881308.pdf?sequence=1&isAllowed=y>. Acesso em: 17 ago. 2021.

MAGALHÃES DE PINHO, F. Modelos autorregressivos (AR). Funcionamento do modelo autorregressivo. Instituto Brasileiro de Mercado de Capitais, 2019. IBMEC/MG. Página informativa [on-line]. Disponível em: <https://www.rpubs.com/frank-pinho/522364>. Acesso em: 5 set. 2021.

NASCIMENTO ARAUJO, S. R. *A geração distribuída*. 2016. Trabalho de conclusão de curso – Universidade Federal do Ceará, Fortaleza, 2016. [on-line]. Disponível em: http://www.repositorio.ufc.br/bitstream/riufc/35618/1/2016_tcc_srnaraujo.pdf. Acesso em: 6 jul. 2021.

OLIVEIRA, F. M. B. *Previsão da velocidade do vento utilizando redes neurais artificiais e modelos autorregressivos*. 2020. (Tese de Pós-Graduação) – Universidade Tecnológica Federal do Pará, Belém, 2020. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/23577>. Acesso em: 12 abr. 2021.

OLIVEIRA DA ROSA, A. R.; PERIN GASPARIN, F. Panorama da energia solar fotovoltaica no Brasil. *Revista Brasileira de Energia Solar*, v. 7, n. 1, p. 140-147, dez. 2016.

OTUYAMA, J. M. *Rede neural por convolução para reconstrução estéreo*. 2020. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 2020. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/78340/171568.pdf?sequence=1&isAllowed=y>. Acesso em: 3 out. 2021.

RAUBER, T.W. *Redes neurais artificiais*. Universidade Federal do Espírito Santo, 2005. Publicação de pesquisa, Cap. 2, documento pdf [on-line]. Disponível em: https://www.researchgate.net/profile/Thomas-Rauber_2/publication/228686464_Redес_neurais_artificiais/links/02e7e521381602f2bd000000/Redes-neurais-artificiais.pdf. Acesso em: 14 set. 2021.

SANTOS MOREIRA, D. F. *Implementação de Microgeração no Sector Residencial*. 2010. Dissertação (Mestrado em Engenharia Eletrotécnica e de Computadores) – Universidade do Porto, Porto, 2010. Disponível em: <https://repositorio-aberto.up.pt/bitstream/10216/60292/1/000143803.pdf>. Acesso em: 8 ago. 2021.

SECRETARIA DO MEIO AMBIENTE E INFRAESTRUTURA. *Atlas eólico do Rio Grande do Sul*. Sema, 2014. Disponível em: https://drive.google.com/file/d/1mC9v_vzh4k_wroeE-mIEP3k6o6TfqN028/view. Acesso em: 27 out. 2021.

SELLITTO, M. A. *Revisão bibliográfica: a Inteligência Artificial - Centro de Ciências Exatas e Tecnológicas*. Artigo científico, tóp. 2, pág. 2. Documento pdf [on-line]. Universidade do Vale do Rio dos Sinos, São Leopoldo, 2002. Disponível em: <https://www.scielo.br/j/gp/a/kc6XPVsqvV6SVzZv8fcWjGM/?format=pdf&lang=pt>. Acesso em: 24 out. 2021.

TENSORFLOW. Criar modelos de machine learning no nível de produção com o TensorFlow. TensorFlow, 2021. Site da biblioteca de código aberto para uso de redes neurais e aprendizado de máquina [on-line]. Disponível em: <https://www.tensorflow.org/?hl=pt-br>. Acesso em: 22 abr. 2021.

TOPOGRAPHIC-MAP. Ferramenta on-line para análise de relevo. Topographic-map, 2021. Site simulador [on-line]. Disponível em: <https://pt-br.topographic-map.com/>. Acesso em: 12 out. 2021.

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO. *Energias renováveis*. Guia de instalação. Guia de estudos para instalação de aerogeradores. UFRJ, 2021. Site com resultado de estudos [on-line]. Disponível em: <https://sites.google.com/a/poli.ufrj.br/energias-renovaveis/energia-eolica/instalacao>. Acesso em: 3 out. 2021.

ZAPAROLLI, D. Ventos promissores a caminho. *Revista de Estudos Técnicos*, n. 275, 2019. [on-line]. Disponível em: <https://revistapesquisa.fapesp.br/ventos-promissores-a-caminho/#:~:text=o%20potencial%20de%20gera%20a%20de,atual%20de%20energia%20do%20brasil>. Acesso em: 2 maio 2021.

Contato

Michel Braulio de Oliveira

E-mail: michel_oliveira47@hotmail.com

Tramitação

Recebido em: 15/03/2022

Aprovado em: 21/12/2022