

ESTUDO DE PREVISÃO NA VELOCIDADE DO VENTO: APLICAÇÃO PRÁTICA DE INTELIGÊNCIA ARTIFICIAL NA BUSCA E USO DE ENERGIA EÓLICA

Michel Braulio de Oliveira – Michel_Oliveira47@hotmail.com

Valdomiro Vega Garcia (Orientador) – valdomiro.garcia@mackenzie.br

RESUMO

Este artigo traz um guia rápido de fácil acesso ao usuário, usando ferramentas online, com foco na geração de energia eólica e escolha de melhor região para instalação de aerogeradores. Com destaque 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, tais 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 foi utilizado 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 uma boa conexão de internet para executar previsões de médio e longo prazo, devido ao carregamento inicial do banco de dados na aplicação online. Foram testados vários modelos de inteligência artificial nas previsões da velocidade do vento que foram comparados através de erro médio absoluto para encontrar o modelo mais adequado. Em destaque o modelo denso e o convolucional (método de múltiplas saídas).

Palavras-chave: Séries Temporais. Energia Eólica. Inteligência Artificial. Redes Neurais.

ESTUDO DE PREVISÃO NA VELOCIDADE DO VENTO: APLICAÇÃO PRÁTICA DE INTELIGÊNCIA ARTIFICIAL NA BUSCA E USO DE ENERGIA EÓLICA

ABSTRACT

This article provides a quick guide that is easy to access for the user, using online 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 online 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. Rio Grande do Sul.

1 INTRODUÇÃO

O consumo de combustíveis fósseis, tais como carvão, petróleo e gás vem aumentando e consequentemente produzindo concentrações de CO₂ na atmosfera, que atualmente são 39% maiores que os níveis medidos nas eras pré-industriais, com concentração de 390 ppm (IPCC, 2021). É possível que a maior parte do aumento observado na temperatura média global desde meados do século 20 seja devido ao aumento observado nas concentrações antropogênicas de gases de efeito estufa, nesse sentido novas formas de geração de energia limpa se destacam, tais como, a energia eólica e a solar (IPCC, 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, isso se torna necessário, uma vez que, os programas e computadores destinados para simulações climáticas têm acesso mais restrito e maior complexidade de operação (NASCIMENTO CAMELO, LUCIO, *et al.*, 2018). O guia prático abordado neste trabalho utiliza modelos de inteligência artificial 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 pré-definir a geração de energia. Tudo isso amparado e tendo como guia, pesquisas correlatas na previsão da velocidade do vento com uso de redes neurais, tais como, os trabalhos de Barbosa, Oliveira (2020) e Nascimento Camelo, Lucio, et al (2018). Estes últimos autores utilizaram o *software* livre R que conta com sólidas bibliotecas de estatística e de *machine learning* para fazer previsões.

O presente trabalho recorre à linguagem *Python*, simples e acessível, que conta também com bibliotecas com bases matemáticas sólidas que permitem ao usuário comum realizar previsões, sejam elas climáticas ou não, de forma prática e rápida. Estas 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 isto, utiliza-se ferramentas online (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), somado à ferramenta *Topographic-map* (2021) para a viabilidade de terreno para instalação de aerogerador(es) e finalmente utilizar modelos de previsão do *TensorFlow* (2021) da *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 inteligência artificial 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 online que permitam, por um lado, a manipulação de grandes bases de dados e por outro lado, a utilização de modelos matemáticos, tais como, as redes neurais artificiais para realizar os estudos de previsão de velocidade do vento, para avaliar os locais com potencial como citado anteriormente. Esta linha de pesquisa contribui na construção e investigação de melhores métodos científicos e econômicos para geração de energia limpa e desenvolvimento contínuo de metodologias que envolvem inteligência artificial.

2 REVISÃO DA LITERATURA

Na sequência serão abordados temas como, parâmetros atmosféricos, geração de energia e inteligência artificial necessários para a compreensão e análise realizado nesta prova de conceito.

2.1 Banco de dados climáticos

Esta pesquisa utiliza um banco de dados extraído do site do Instituto Nacional de Meteorologia (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. Estas informações permitem avaliar o potencial de geração de energias limpas no território nacional, em especial em regiões propícias para a implementar a geração de energia eólica (INMET, 2021). Os parâmetros atmosféricos acima descritos são as variáveis de

treinamento das redes neurais, que permitem fazer as previsões da velocidade do vento, que foram empregados neste presente artigo.


2.2 Formação dos ventos

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

Figura 1 - Torre eólica e seus componentes principais



Fonte: IPCC (2021)

As torres de energia eólica mais altas geralmente têm capacidade maior na captação de energia, o formato aerodinâmico e tamanho das lâminas eólicas, tanto para baixas ou altas velocidades do vento, também possuem grande influência na geração de energia (IPCC, 2021). Aerogeradores de porte médio geram entorno de 2,1 a 2,2 (MW) e as de maior porte podem produzir de 4 a 4,2 (MW), ambos os modelos sendo muito utilizados (ZAPAROLLI, 2019).

2.4 Instalação de Aerogeradores

Inicialmente é necessário selecionar a região onde será instalado o gerador ou geradores, devendo considerar certas características de topografia (plana ou levemente ondulada), vegetação (rasteira), velocidade média anual do vento economicamente viável entorno de 7 m/s, medições e a qualidade dos dados, que devem ter no mínimo um 1 ano de registros climáticos na região (UFRJ, 2021).

Também deverá ser levada em consideração a altitude das medições, que pode ser encontrada nas simulações (2013) climáticas feitas em todo o território nacional, para estas simulações foi utilizado o software de modelo Brams, no Atlas eólico Brasileiro (CEPEL – 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 conectada, pois os custos da construção de linha de transmissão são elevados, porém, entre mais próxima à rede, mais econômica será a operação. A qualidade da infraestrutura conectada a subestações de energia também deverá ser levada em consideração, assim como as disponibilidades de conexão para acessar a rede (UFRJ, 2021).

Nos próximos tópicos serão apresentadas definições de inteligência artificial, assim como 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 inteligência artificial (IA) de forma prática.

IA é definida por Sellitto (2002), que discorre: IA é incorporar na máquina inteligência semelhante à humana, utilizando-se para esse objetivo alguns ramos de estudos fundamentais da ciência, como; computação, matemática, cibernética, psicologia e engenharia. Imitando mecanismos naturais de modo artificial, especialmente em programas de computadores, possibilitando a execução e solução de tarefas em níveis que podem se igualar ou mesmo superar às capacidades humanas.

2.6 Redes Neurais Artificiais

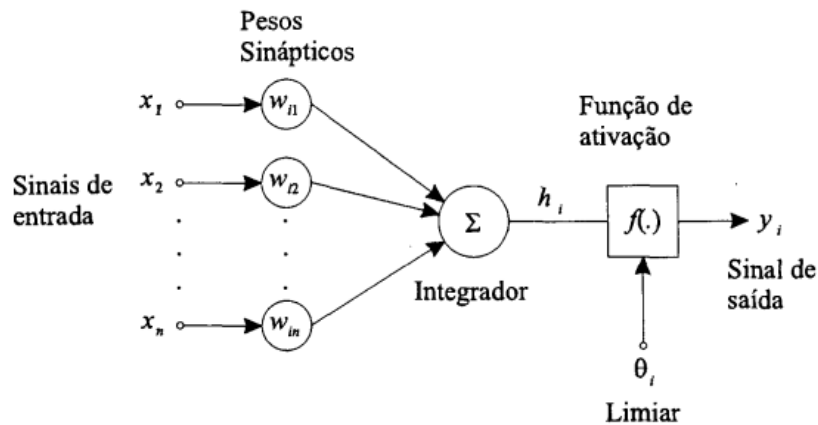
A RNA pode ser fundamentada em duas partes, a primeira sendo a arquitetura e a segunda o algoritmo de aprendizagem (a rede deve ser treinada para aprender), fornecendo parâmetros de exemplo para a rede (composta por neurônios), ela atribui pesos a essas variáveis possibilitando o entendimento do que mais afeta o sistema estudado (RAUBER, 2005).

Como apresentado por Fleck, Tavares, et al. (2016), numa RNA existem basicamente 4 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, têm-se 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). Integrador: forma um combinador linear, o qual é responsável por atribuir pesos sinápticos nas somas de sinais de entrada (OTUYAMA, 2020).

A função de ativação: dado um neurônio artificial, essa função limita a amplitude do valor de saída dele (FLECK, TAVARES, *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). *Bias*; definido como, valor externo ao neurônio

artificial (Figura 2), podendo aumentar ou diminuir a entrada do sinal da função de ativação (FLECK, TAVARES, *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, sendo a primeira:

$$h_i = \sum_{j=1}^n w_{ij} x_j \quad (1)$$

e a segunda:

$$y_i = f(h_i) \quad (2)$$

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 a sinal de saída do neurônio i . Se incorporarmos ao y_i , um limiar (*threshold*), tem-se:

$$y_i = f(h_i - \theta_i) \quad (3)$$

Onde tenta-se reduzir a entrada total da função de ativação (θ_i). Se θ_i tiver valor negativo, tem-se “Bias” (desvio), que é exatamente o efeito contrário (OTUYAMA, 2020). Segundo Fleck, Tavares, 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 definir-se matematicamente, como sendo:

$$w(k)_{ij} = w(k-1)_{ij} + \Delta w(k)_{ij} \quad (4)$$

dado k iterações, tem-se dado parâmetro w e o vetor de correção (Δw).

2.6.1 Funções de ativação

Como sugerido em Fleck, Tavares, 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, que tratando-se de construção de RNA, por definição, é uma função crescente com propriedade assintótica e de suavidade (OTUYAMA, 2020). Pode assumir valores no intervalo $[0,1]$,

se mantendo balanceada no comportamento linear e não-linear (FLECK, TAVARES, *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, RNA tem organização por agrupamentos (camadas) de nós (neurônios artificiais) onde os nós de entrada, somente recebem a informação e os envia a outros nós, no caso, nós de processamento, estes que então de fato processam as informações. Existindo três classes de arquitetura de RNA. Sendo a primeira as Redes Neurais Diretas de Camada Única (*Single-Layer Feedforward Neural Networks*), na qual, uma única camada de nós de entrada envia dados de forma unilateral para camada de nós de saída. A segunda são as Redes Neurais Diretas Multicamada (*Multilayer Feedforward Neural Networks*), que possui camadas de processamento escondidas (neurônios escondidos). Essas unidades escondidas têm por função, trabalhar as informações entre a entrada externa e saída.

E a terceira sendo as Redes Neurais Recorrentes (*Recurrent Neural Networks*), em que a camada envia um sinal para si mesma, para próxima camada ou para anterior, configurando-se como uma rede neural recorrente. Existe outra classe de redes neurais, as convolucionais, em que é composta por três elementos arquitetônicos, sendo eles, 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 RNAs

Existem 2 tipos de treinamentos nas RNAs: 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 se tem 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, onde,

A classe de modelos autorregressivos é caracterizada por uma formulação para $f(\)$ 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 8.

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

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 pelos institutos CPTEC/INPE (2021). “BRAMS é um sistema de modelagem numérica projetado para previsão e pesquisa atmosférica em escala regional, com foco na química atmosférica, qualidade do ar e ciclos biogeoquímicos.”. Esse modelo, constitui uma ferramenta para estudo/pesquisa do clima, tão confiável quanto a seus homólogos empregados em outros países, possuindo um conjunto de parametrizações e funcionalidades que são de alto desempenho (CPTEC/INPE, 2016). Na sequência serão definidas as principais funções matemáticas utilizadas neste artigo.

2.7 Erro médio absoluto

Segundo a autora, Acharya (2021), podemos definir o erro médio absoluto (“MAE” pelas siglas em inglês ou EMA em português), 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 erro médio absoluto.

2.8 Correlação

Como definido por Medeiros de Araujo Lima Filho (2021), 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 apresentam 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 indicado por valores positivos da correlação, já valores negativos revelam que a relação entre as variáveis é inversamente proporcional.

2.9 Equação da velocidade

Cadeira Brandão, de Oliveira Santos e Dantas da Cunha (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 onde foi medido a velocidade atual (h1), altura onde será medida a velocidade estimada (h2) e coeficiente de rugosidade do solo (z0).

2.10 Normalização de variáveis

Os gráficos apresentados nas simulações, tem no geral suas variáveis normalizadas para melhor representação dos fenômenos nas execuções dos códigos em Python, como expõe Alissa Almalik (2018). A normalização Máx-Min se expressa na equação 12:

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

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. Logo abaixo é descrito a linguagem de programação utilizada neste trabalho.

2.11 Linguagem de programação Python

Para a realização das simulações e o estudo de variáveis foi utilizada a linguagem de programação Python, por sua versatilidade, simplicidade e de rápida implementação. A utilização desta linguagem é vantajosa, já que conta com inúmeras bibliotecas, em grande medida devido a “Python Foundation” e aos colaboradores no mundo todo, sendo umas das linguagens mais utilizadas, com destaque para IA e banco de dados, dentre outros (COUTINHO MENEZES, 2010).

Para executar as instruções em *Python*, foi utilizado o ambiente *web* do *Google Colab* ou *Colaboratory*, por sua acessibilidade (*online*) 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*, e possui as ferramentas de redes neurais profundas de uso rápido e prático (CHOLLET, 2015). Todo o código desenvolvido nesta pesquisa, junto com todos os gráficos gerados, encontra-se disponível neste *link*¹.

Na sequência é definida a microgeração distribuída, pois operadores de aerogeradores de pequeno ou médio porte podem se beneficiar deste 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. Se diferem quanto a potência de geração, a microgeração até 75 (kW) e minigeração de 75 (kW) até 5 (MW) (ANEEL, 2018).

¹ Simulações de previsões *TensorFlow*. Disponível em; <<https://github.com/MichelOliveira47/Arquivos-TCC-II>>

A microgeração compreende um grupo de equipamentos específicos, que produzem energia elétrica, sendo os mais comuns de uso residencial, no qual 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 ou 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* permite ser instalado em alturas ajustáveis (MADURO RAMOS, 2016). Na Figura 3 são apresentadas suas especificações técnicas:

Figura 3 - Especificações Air Silent X



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

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 a 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 (RS):

Tabela2 - Potencial de geração fotovoltaica em residências RS.

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).

Por tanto esta 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, ELIZIÁRIO, *et al.*, 2020).

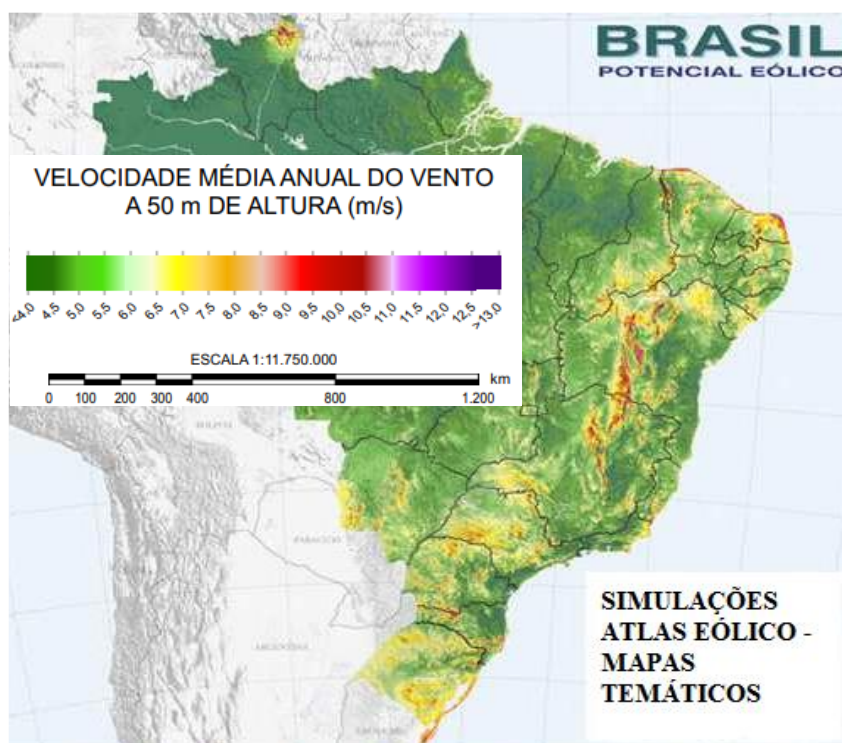
Na sequência será apresentada a metodologia, onde serão exibidas as ações e abordagens que permitem a realização do estudo proposto neste trabalho, iniciando pela escolha da região.

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 (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 50m), tais como: região norte (Roraima), região nordeste (Rio Grande do Norte, Bahia e Ceará), região sudeste (Minas Gerais e São Paulo), região centro-oeste (Mato Grosso do Sul) e região 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 50m de altura no território Brasileiro



Fonte: CEPEL – 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 nas áreas que compreende os municípios Barra do Chuí e Santa Vitória do Palmar. Seguido foi pesquisada a estação meteorológica mais propícia ao estudo na região, no caso específico a estação de leitura automática A899 (INSTITUTO NACIONAL DE METEOROLOGIA - INMET, 2021).

Os dados coletados da estação A899, estão disponíveis *online* em formato de planilhas Excel, com períodos de tempo anuais, com medições a 26 metros de altura. Os dados disponíveis possuem a velocidade média do vento que possibilitam o estudo de viabilidade de área e econômica (UFRJ, 2021).

3.2 Análise de dados e previsões

A partir da coleta do banco de dados das medições meteorológicas, estes dados foram tratados para serem inseridos no ambiente *Python* de *google colab*. Neste ambiente foram utilizadas as principais bibliotecas com funções necessárias para a análise dos dados e execução dos modelos. Dentre as bibliotecas em destaque estão: *os*, *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, foram gerados gráficos para a pré-visualização dos mesmos, foi aplicada a normalização dos dados necessários para o treinamento de modelos de IA para fazer as respectivas previsões. Foram realizadas correlações para observar como cada variável impacta em maior a menor intensidade em outra. Estes efeitos foram exibidos em gráfico e analisados, permitindo definir as grandezas com maior influência nos modelos.

A partir do tratamento prévio dos dados do INMET (2021), os modelos foram treinados para fazer as previsões da velocidade do vento num período pré-definido. Por fim, foram comparados os modelos de previsões através do erro médio absoluto (EMA), pois como define Nascimento Camelo, Henrique et al (2018), existem outras formas de verificar 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 e múltiplas saídas foram: linha de base (*linebase*), linear (*line*), denso (*dense*), redes neurais recorrentes (*RNN - LSTM*) e rede neural convolucional (*CNN*). O modelo de múltiplas etapas densas (*multi-step dense*), foi adicionado para

saída única e para múltiplas saídas, o modelo autorregressivo de médias móveis (*AR LSTM*) (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 UFRJ (2021), nesse sentido, os registros de ventos com maior potencial estão na região Sul, nos municípios de Barra do Chuí e Santa Vitória do Palmar. Estes dados foram coletados a uma altura de 26 metros, que é uma altura próxima à inicial para geração de grandes aerogeradores, além disso, apresenta 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 dentre as regiões que mais ventam no Brasil, também foi observado o tipo de topografia adequado da região, que pode ser observado na Figura 5.

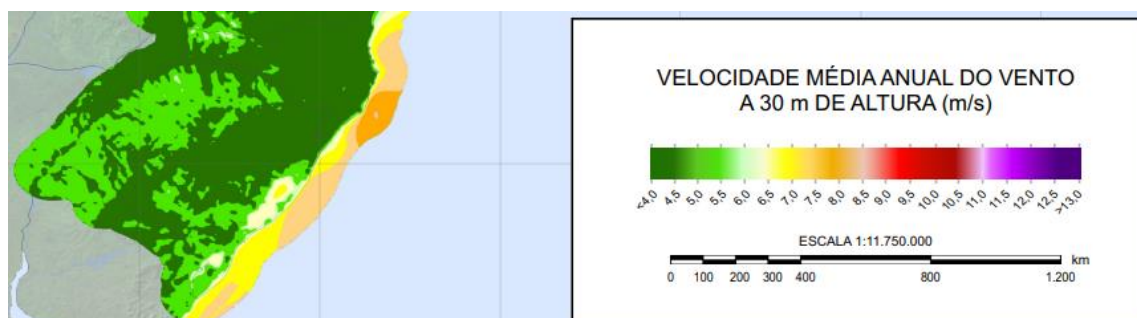
Figura 5 – Topografia, Barra do Chuí e Santa Vitória do Palmar



Fonte: Imagem do autor.

A Figura 5 ilustra a homogeneidade da altitude na região litorânea, com suaves variações, sendo notável as extensas regiões planas, propícias para a aerogeração, a obtenção dessa informação foi possível devido à ferramenta online 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 metros.

Figura 6 – Velocidade média anual do vento na região Sul do Brasil



Fonte: CEPEL – Centro de pesquisas de energia elétrica (2013).

4.2 Selecionando o melhor período de medições nas planilhas

O banco de dados climáticos do INMET (2021) compreende os anos de 2000 a 2021 (até 31/08/2021), contudo, na verificação detalhada dos dados foi possível observar que grande parte das tabelas possuem 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. Estes dados foram formatados e corrigidos adequadamente para inserção no ambiente *Google Colaboratory*, seguido de uma avaliação estatísticas desses dados.

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 52608 medições de 2015 a 2020), que registrou a média de 4,76 m/s nos 5 anos de medições. Além disso, 50% das amostras possuem valor igual ou acima de 4,4 m/s e 75% das amostras atingem 6,4 m/s ou mais.

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	0.938581	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.m²)	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: Imagem do autor.

Também é possível notar que a região escolhida tem baixa precipitação, com registro médio de 0.1213 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 metros (ABEEÓLICA, 2019). A partir da equação (13) são obtidas velocidades de 7,31; 7,5 e 7,64 (m/s) respectivamente. Tendo esses valores confirmados nas simulações da CEPEL (2013), foi utilizado o coeficiente de rugosidade do solo igual a 0,01, que é definido pelo órgão governamental SEMA (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 (INMET, 2021). Utilizando esta informação e visando a sua utilização em microgeração, é possível estimar uma produção de energia elétrica acima de 1080 Wh/dia se for instalado um aerogerador *Air Silent X*. Isto mostra que pode ser viável a instalação deste tipo de equipamento para uso residencial, permitindo usuários domésticos participarem da microgeração geração distribuída e 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 entre -0,029 a 0,19, consideradas como correlações bem fracas (GONZAGA ALVES ARAUJO, SANTOS e SIMÕES 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 observar-se que a correlação da variável “VENTO VELOCIDADE HORÁRIA” com a variável “RAJADA MÁXIMA DE VENTO” para o intervalo 2015 a 2020 é similar ao analisado anteriormente (0,92), já a correlação com as variáveis restantes apresenta um incremento considerável no valor de 0,029 a 0,38. Tendo destaque 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.

Figura 7 - Correlação das variáveis climáticas com “VENTO, VELOCIDADE HORARIA (m/s)
INMET (2015 a 2020)

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	

Fonte: Imagem do autor.

Correlações baixas de variáveis climáticas podem apresentar-se em grande medida devido ao estudo ser focado numa região específica. Para uma compreensão melhor dos fenômenos climáticos é necessário um 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 (INPE, 2021).


A seguir serão analisados e avaliados vários modelos de previsão, os quais contemplam 24 horas no futuro e 5 anos de passado (treinamento). As 24 horas foram definidas devido às limitações da ferramenta online.

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 pode ser observada no link². Na Figura 8 é exibida a acurácia entre os modelos de predição de etapa única e múltiplas saídas.

² Simulações de previsões *TensorFlow*. Disponível em; <<https://github.com/MichelOliveira47/Arquivos-TCC-II>>

Figura 8 - Comparação entre os métodos de previsões



Fonte: Imagem do autor.


Os resultados das previsões foram avaliados pelo erro médio absoluto, 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 3 anos e o segundo de 6 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 INMET (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.

Pelo motivo acima citado, o intervalo de 2015 a 2020 foi estabelecido para as previsões por seus dados apresentar maior consistência, sem a necessidade de muitas correções, dito isto, foi realizado o comparativo entre as previsões da planilha 2016 a 2018 (3 anos) e da planilha 2015 a 2020 (5 anos). Como pode ser observado 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

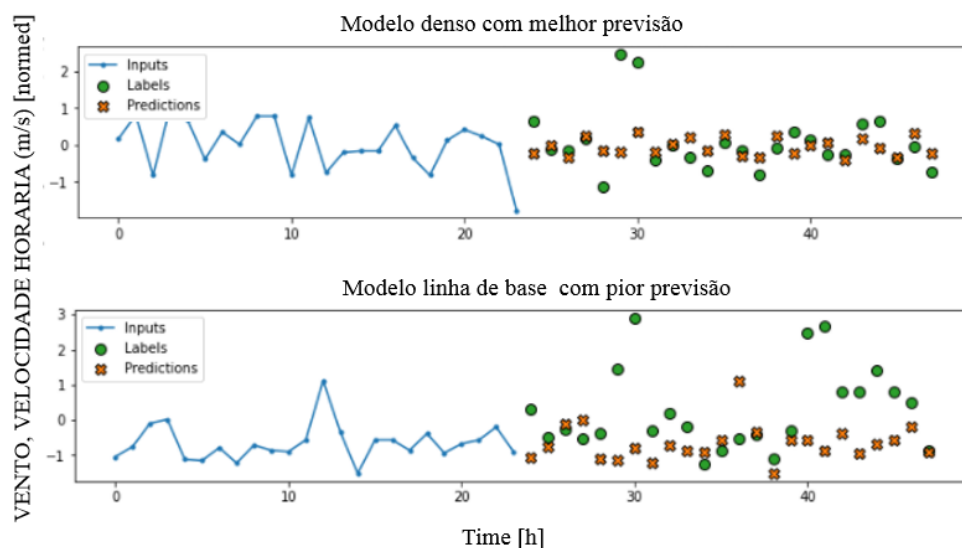


Fonte: Imagem do autor.

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. Isto 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, se diferenciando entre si por apenas 1,62%, o que os tornam semelhantes no nível de resposta. Comparando o melhor e o pior modelo, respectivamente, tem-se: o modelo de múltiplas etapas com rede neural do tipo denso (*dense*) com MAE de 0,4260 e em contraparte o modelo com rede neural do tipo linha de base com MAE 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 a 7,5 m/s) para instalação de aerogeradores eólicos, com foco no uso residencial ou de microgeração.

Por outro lado, a realização de um breve estudo dos parâmetros climáticos que mais impactam na velocidade do vento, como por exemplo, a altura das medições. Com o objetivo de responder essas

questões, foram utilizados dados meteorológicos disponíveis e ferramentas de forma totalmente online, 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 completos e atualizados 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 área é majoritariamente plana, foi utilizado o *Topograph-Map*, que confirmou a viabilidade da região da região, acima citada, para a instalação de aerogeradores eólicos.

Foi utilizada a ferramenta *TensorFlow* (em *python*) em ambiente *online* 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 igual ou acima de 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 foi realizado treinamento e teste para a previsão de velocidade do vento, utilizando modelos de inteligência artificial embutidos na ferramenta e que permite de forma simples a usuários com pouco fundamento científico (“leigos”) interagir com ela.

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

Os modelos acima citados podem ser utilizados para a realização de estudos gratuitos (sem a necessidade de contratar algum serviço especializados) 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 no Brasil, assim como aprofundamento em métodos específicos de redes neurais utilizados nesse 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). Este tipo de análise pode ser utilizado para selecionar as variáveis mais indicadas para o treinamento assertivo dos modelos de IA.

REFERÊNCIAS

ABEEÓLICA. abeeolica.org.br/. **Associação Brasileira de Energia Eólica - ABEEólica**, 2019. Disponível em: <<http://abeeolica.org.br/?s=altura>>. Acesso em: 02 jun. 2021.

ACHARYA, Shwetha. towardsdatascience.com. **What are RMSE and MAE? A Simple Guide to evaluation metrics**, 2021. Disponível em: <<https://towardsdatascience.com/what-are-rmse-and-mae-e405ce230383>>. Acesso em: 14 jun. 2021.

ALISSA ALMALIK, Zaid. dataakkadian.medium.com. **Padronização VS Normalização**, 2018. Disponível em: <<https://dataakkadian.medium.com/standardization-vs-normalization-da7a3a308c64>>. Acesso em: 01 out. 2021.

ANEEL. aneel.gov.br. **ANEEL - Agência Nacional de Energia Elétrica**, 2018. Disponível em: <<https://www.aneel.gov.br/geracao-distribuida>>. Acesso em: 16 nov. 2021.

BARBOSA OLIVEIRA, Felipe M. repositorio.utfpr.edu.br. **Repositório Institucional da Universidade Tecnológica Federal do Paraná (RIUT)**, 2020. Disponível em: <<https://repositorio.utfpr.edu.br/jspui/bitstream/1/23577/1/velocidadeventomodelosautorregressivos.pdf>>. Acesso em: 12 abr. 2021.

CADEIRA BRANDÃO, João H.; DE OLIVEIRA SANTOS, Wesley; DANTAS DA CUNHA, Sharon. editorarealize.com.br. **CONGRESSO NACIONAL de PESQUISA e ENSINO em CIÊNCIAS - V CONAPESC**, 2020. ISSN 2525-3999. Disponível em: <https://editorarealize.com.br/editora/anais/conapesc/2020/TRABALHO_EV138_MD1_SA23_ID702_27102020100040.pdf>. Acesso em: 15 ago. 2021.

CEPEL – CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA. <http://novoatlas.cepel.br/>. **ATLAS EÓLICO BRASILEIRO - Simulações 2013**, 2013. Disponível em: <<http://novoatlas.cepel.br/index.php/mapas-tematicos/>>. Acesso em: 02 nov. 2021. il. color.

CHOLLET, François. keras.io. **Keras Simples. Flexível. Poderoso.**, 2015. Disponível em: <<https://keras.io/>>. Acesso em: 15 ago. 2021.

COUTINHO MENEZES, Nilo N. s3.novatec.com.br. **novatec editora**, 2010. Disponível em: <<https://s3.novatec.com.br/capitulos/capitulo-9788575222508.pdf>>. Acesso em: 23 out. 2021.

CPTEC/INPE. inpe.br. **Instituto Nacional de Pesquisas Espaciais INPE MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES**, 2016. Disponível em: <http://www.inpe.br/noticias/noticia.php?Cod_Noticia=4133>. Acesso em: 15 nov. 2021.

CPTEC/INPE. brams.cptec.inpe.br. **BRAMS**, 2021. Disponível em: <<http://brams.cptec.inpe.br/about/>>. Acesso em: 19 nov. 2021.

DA COSTA, Renato N. Repositório Institucional Universidade Federal de Minas Gerais. **Repositório Institucional da UFMG**, 2020. Disponível em: <<https://repositorio.ufmg.br/bitstream/1843/35709/2/Intelig%20c3%aancia%20Artificial%20e%20Organiza%20a7%20a3o%20do%20Trabalho%20Banc%20a1rio.pdf>>. Acesso em: 10 set. 2021.

DALELES RENNÓ, Camilo; BORMA, Laura S. dpi.inpe.br. **Divisão de Processamento de Imagens COORDENAÇÃO-GERAL DE OBSERVAÇÃO DA TERRA**, 2017. Disponível em: <<http://www.dpi.inpe.br/~camilo/prochidr/pdf/01precipitacao.pdf>>. Acesso em: 04 out. 2021.

DANTAS, Marta et al. gesel.ie.ufrj.br. **GESEL - Grupo de Estudos do Setor Elétrico - Universidade Federal do Rio de Janeiro (UFRJ)**, 2020. Disponível em: <http://www.gesel.ie.ufrj.br/gesel/app/webroot/files/publications/31_elizario_2020_11_18.pdf>. Acesso em: 23 nov. 2021.

FLECK, Leandro et al. Redes Neurais Artificiais: Princípios Básicos. **academia.edu**, 2016. ISSN 2175-1846. Disponível em: <<https://d1wqtxts1xzle7.cloudfront.net/57830283/4330-15577-1-PB-with-cover-page-v2.pdf?Expires=1636669373&Signature=VqOSOVA9L76xmXJX6S7Iic0d0U3ZcW-G3vkqINKR-kUzaFLTrY4YZqGkutzeI33MCoFyCVqcJaz63IhWh2DtqHb6oRKqmo2jjaLw0Y0zLCAHLDAF7xxsgP9vPE56eataG0nPGmnmcVRO>>. Acesso em: 12 set. 2021.

GONZAGA ALVES ARAUJO, Jonathas V.; SANTOS, Marcos; SIMÕES GOMES, Carlos F. researchgate.net. **XIX SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA**, 2019. Disponível em: <https://www.researchgate.net/profile/Marcos_Dos_Santos6/publication/335796808_Developing_a_code_in_Python_for_generation_of_matrices_of_Correlation_of_Pearson_from_n_variables_taken_two_by_two/links/5dda8572458515dc2f496965/Des>. Acesso em: 23 jul. 2021.

GOOGLE RESEARCH. colab.research.google.com. **Colaboratory**, 2021. Disponível em: <https://colab.research.google.com/?utm_source=scs-index#scrollTo=5fCEDCU_qrC0>. Acesso em: 03 maio 2021.

HOMANN DE TOPIN, Luiz O. repositorio.ufsc.br. **Repositório Institucional da UFSC**, 2020. Disponível em: <<https://sistemas.furg.br/sistemas/sab/arquivos/bdtd/0000013595.pdf>>. Acesso em: 01 out. 2021.

IAG. iag.usp.br. **Instituto de Astronomia, Geofísica e Ciências Atmosféricas**, 2021. Disponível em: <<https://www.iag.usp.br/siae98/meteorologia/dinamica.htm>>. Acesso em: 06 maio 2021.

INMET. portal.inmet.gov.br. **Instituto Nacional de Meteorologia - MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO**, 2021. Disponível em: <<https://portal.inmet.gov.br/>>. Acesso em: 15 jun. 2021.

INPE. inpe.br. **Instituto Nacional de Pesquisas Espaciais INPE MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES**, 2021. Disponível em: <<http://www.inpe.br/faq/index.php?pai=3>>. Acesso em: 13 out. 2021.

IPCC. ipcc-wg3.de. **Painel Intergovernamental de Mudanças Climáticas - IPCC/ONU**, 2021. Disponível em: <https://www.ipcc-wg3.de/report/IPCC_SRREN_Ch07.pdf>. Acesso em: 14 maio 2021.

MADURO RAMOS, Hadrian. repositorio.unesp.br. **REPOSITÓRIO INSTITUCIONAL UNESP**, 2016. Disponível em: <<https://repositorio.unesp.br/bitstream/handle/11449/155262/000881308.pdf?sequence=1&isAllowed=y>>. Acesso em: 17 ago. 2021.

MAGALHÃES DE PINHO, Frank. rpubs.com. **Modelos Autorregressivos (AR) - Instituto Brasileiro de Mercado de Capitais (IBMEC)**, 2019. Disponível em: <<https://www.rpubs.com/frank-pinho/522364>>. Acesso em: 05 set. 2021.

MEDEIROS DE ARAUJO LIMA FILHO, Luiz. de.ufpb.br. **UNIVERSIDADE FEDERAL DA PARAÍBA - UFPB**, 2021. Disponível em: <<http://www.de.ufpb.br/~luiz/AED/Aula9.pdf>>. Acesso em: 26 jun. 2021.

MIGON, Hélio. dme.ufrj.br. **Universidade Federal do Rio de Janeiro Instituto de Matemática Departamento de Métodos Estatísticos Análise de Séries Temporais**, 2021. Disponível em: <<http://www.dme.ufrj.br/dani/pdf/slidespartefrequentista.pdf>>. Acesso em: 25 out. 2021.

NASCIMENTO ARAUJO, Sandro R. repositorio.ufc.br. **UNIVERSIDADE FEDERAL DO CEARÁ**, 2016. Disponível em:

<http://www.repositorio.ufc.br/bitstream/riufc/35618/1/2016_tcc_srnaraujo.pdf>. Acesso em: 06 jul. 2021.

NASCIMENTO CAMELO, Henrique et al. scielo.br. **SciELO Brasil - Proposta para Previsão de Velocidade do Vento Através de Modelagem Híbrida Elaborada a Partir dos Modelos ARIMAX e RNA**, 2018. Disponível em:

<<https://www.scielo.br/j/rbmet/a/n6cRPrvLYyhdhYyJhgKFcXv/?lang=pt>>. Acesso em: 12 maio 2021.

OLIVEIRA DA ROSA, Antonio R.; PERIN GASPARI, Fabiano. PANORAMA DA ENERGIA SOLAR FOTOVOLTAICA NO BRASIL. **Revista Brasileira de Energia Solar**, v. 7, n. 1, p. 140-147, Dezembro 2016. ISSN 2.

OTUYAMA, Júlio M. repositorio.ufsc.br. **Repositório Institucional da UFSC**, 2020. Disponível em:

<<https://repositorio.ufsc.br/bitstream/handle/123456789/78340/171568.pdf?sequence=1&isAllowed=y>>. Acesso em: 3 out. 2021.

RAUBER, Thomas W. Redes Neurais Artificiais. **researchgate**, 2005. 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, Daniel F. repositorio-aberto.up.pt. **Repositório Aberto da Universidade do Porto**, 2010. Disponível em: <<https://repositorio-aberto.up.pt/bitstream/10216/60292/1/000143803.pdf>>. Acesso em: 08 ago. 2021.

SELLITTO, Miguel A. SciELO Brasil. **scielo**, 2002. Disponível em:

<<https://www.scielo.br/j/gp/a/kc6XPVSQvV6SVzZv8fcWjGM/?format=pdf&lang=pt>>. Acesso em: 24 out. 2021.

SEMA. sema.rs.gov.br. **SECRETARIA DO MEIO AMBIENTE E INFRAESTRUTURA - Atlas Eólico do Rio Grande do Sul**, 2014. Disponível em:

<https://drive.google.com/file/d/1mC9v_vzh4k_wroeEmIEP3k6o6Tfqno28/view>. Acesso em: 27 out. 2021.

TENSORFLOW. tensorflow.org. **TensorFlow**, 2021. Disponível em:

<<https://www.tensorflow.org/?hl=pt-br>>. Acesso em: 22 abr. 07.

TOPOGRAPHIC-MAP. pt-br.topographic-map.com. **Topographic-map**, 2021. Disponível em:

<<https://pt-br.topographic-map.com/>>. Acesso em: 12 out. 2021.

UFRJ. poli.ufrj.br. **Energias Renováveis - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO**, 2021. Disponível em: <<https://sites.google.com/a/poli.ufrj.br/energias-renovaveis/energia-eolica/instalacao>>. Acesso em: 03 out. 2021.

ZAPAROLLI, Domingos. revistapesquisa.fapesp.br. **Pesquisa - Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP)**, 2019. Disponível em:

<<https://revistapesquisa.fapesp.br/ventos-promissores-a-caminho/#:~:text=o%20potencial%20de%20gera%20c3%a7%20c3%a3o%20de,atual%20de%20energia%20do%20brasil>>. Acesso em: 02 maio 2021.