

Investigação de redes neurais artificiais para predição da velocidade do vento

Deilson Martins dos Santos * Ezequiel da Silva Oliveira **

* *Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Campus Angra dos Reis, RJ (e-mail: deilson.santos@aluno.cefet-rj.br)*

** *Departamento de Engenharia Elétrica, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Campus Angra dos Reis, RJ, (e-mail: ezequiel.oliveira@cefet-rj.br).*

Abstract: Due to the increasing use of wind power for electricity generation, studies that allow the wind speed prediction are extremely important for the planning and operation of the Electric Power System (EPS). Therefore, this work aims to contribute to the investigation of efficient techniques for the wind speed prediction, being evaluated the classical Artificial Neural Network (ANN) and the Recurrent Neural Network with Long Short-Term Memory (RNN-LSTM). Real wind speed data and parameters that influence it are used to validate and prove the efficiency of the techniques presented.

Resumo: Devido à crescente utilização de fonte eólica para geração de energia elétrica, estudos que possibilitam a previsão da velocidade do vento são de extrema importância para o planejamento e a operação do Sistema Elétrico de Potência (SEP). Portanto, este trabalho visa contribuir com a investigação de técnicas eficientes para a previsão da velocidade do vento, sendo avaliada a Rede Neural Artificial clássica (RNA) e a Rede Neural Recorrente com células de memória longa de curto prazo (RNN-LSTM). Dados reais de velocidade do vento e dos parâmetros que a influencia são utilizados para validar e comprovar a eficiência das técnicas apresentadas.

Keywords: Wind speed prediction; Heuristic; Artificial Neural Network; Recurrent Neural Network.

Palavras-chaves: Previsão da velocidade do vento; Heurística; Rede Neural Artificial; Rede Neural Recorrente.

1. INTRODUÇÃO

A energia elétrica é uma *commodity* estratégica para o desenvolvimento de um país, pois se relaciona diretamente com sua economia. Portanto, o suprimento da demanda de energia elétrica de forma ininterrupta deve ser assegurado. Com a diversificação da matriz de energia elétrica e a tendência de aumentar a participação de fontes renováveis (por exemplo, fonte eólica e solar fotovoltaica), a garantia da característica do suprimento torna-se mais difícil, pois as fontes mencionadas são operadas de forma intermitente, devido aos recursos destas fontes não serem controlados.

O perfil da geração de energia elétrica proveniente de fonte solar fotovoltaica e fonte eólica é desejável, pois impacta diretamente na operação do Sistema Elétrico de Potência (SEP). Dessa forma, o estudo de técnicas/algoritmos para previsão de irradiação solar e da velocidade do vento tem se intensificado e este trabalho visa contribuir com investigação da utilização da Rede Neural Artificial (RNA) para previsão da velocidade do vento.

Existem diversas técnicas desenvolvidas para obter previsões da velocidade do vento, por exemplo, métodos estatísticos de análise de séries temporais, como: máquinas de vetores de suporte, árvores de decisão, florestas aleatórias,

e as redes neurais artificiais (Géron, 2019). De acordo com Fente e Singh (2018), os modelos de redes neurais se destacam pela robustez e capacidade de generalização do aprendizado, características estas que tornam o modelo atrativo para a aplicação ao problema de previsão.

Em virtude da obtenção de uma matriz energética mais sustentável, a geração eólica tem se tornado uma boa opção de modo que seu crescimento vem se intensificando, já que o recurso utilizado é renovável e contribui para a descarbonização da referida matriz. A incerteza da geração eólica está relacionada à dependência das condições climáticas que influencia diretamente na velocidade do vento, cuja previsão é categorizada em quatro períodos: (i) ultra-curto-prazo (alguns segundos); (ii) curto prazo (30 minutos até 24 horas); (iii) médio prazo (24 horas até 1 semana) e (iv) longo prazo (1 semana até anos) (Çevik et al., 2018).

Na seção 2 é realizada uma breve pesquisa dos trabalhos que envolvem a previsão da velocidade do vento por redes neurais artificiais. Na seção 3 são apresentados as técnicas que serão empregadas no problema de previsão da velocidade do vento. A seção 4 aborda a metodologia utilizada. Os resultados obtidos e as respectivas análises

são apresentadas na seção 5. Por fim, apresenta-se a conclusão do trabalho proposto na seção 6.

2. TRABALHOS RELACIONADOS

Estudos relacionados com a aplicação de redes neurais artificiais para previsão de velocidade do vento foram abordados por Huang e Kuo (2018), apresentaram um sistema de previsão da velocidade do vento pelos próximos três dias com base no histórico dos sete dias anteriores da cidade de Zuoying, Taiwan. Para validar o sistema foi utilizado duas métricas: raiz do erro quadrático médio (RMSE) e o erro médio absoluto (MAE), comparando os resultados com outras quatro arquiteturas distintas de redes neurais artificiais.

Kurdikeri e Raju (2018) propuseram um estudo comparativo entre os modelos da rede neural recorrente com modelos de redes neurais recorrentes com célula de memória de Longo Prazo (LSTM), para previsão de velocidade do vento, mostrando que os modelos LSTM são mais adequados para previsão de séries temporais para curto e longo prazo.

Çevik et al. (2018) realizaram um estudo para previsão da geração eólica para o dia seguinte, sendo utilizado um conjunto de dados de um ano com discretização horária para realizar o treinamento e um conjunto de dados de seis meses com a mesma discretização para a realização dos testes. A arquitetura de rede neural utilizada é a CVNN (*Complex Valued Neural Network*), na qual utiliza velocidade do vento e direção do vento como entrada do modelo convertida em um domínio complexo.

Em 2019, Wilms et al. (2019) utilizaram um conjunto de dados de velocidade e direção do vento nas proximidades de um parque eólico em questão, assumindo que a velocidade do vento na turbina eólica é diretamente influenciada pela distribuição do vento na topologia do parque eólico. Sendo assim, propuseram uma arquitetura de rede neural artificial recorrente LSTM convolucional, explorando a vantagem da mesma permitir incluir dependências temporais que são decorrentes das séries temporais assim como a inclusão de dependências espaciais oriunda de regiões geográficas com previsões de ventos dispersas.

Neste trabalho será apresentada a previsão horária da velocidade do vento, realizada pela RNA clássica e a recorrente com célula de memória LSTM, com cinco arquiteturas diferentes. Por fim, a previsão da velocidade do vento gerada a partir de cada RNA é comparada com os dados medidos, possibilitando a avaliação das técnicas através dos parâmetros estatísticos: MAE e RMSE.

3. REDES NEURAS ARTIFICIAS

As redes neurais artificiais foram introduzidas em 1943 pelo McCulloch e Pitts. McCulloch e Pitts (1943) apresentaram a primeira arquitetura de rede neural artificial, mostrando como seria possível utilizar a comunicação dos neurônios artificiais na realização de cálculos complexos, cujo procedimento se assimila ao da comunicação do sistema nervoso.

Warren McCulloch e Walter Pitts propuseram uma arquitetura simples de neurônio artificial na qual possuía

algumas entradas binárias (0, 1), representando ligado ou desligado, e uma saída binária. A saída de um neurônio artificial é ativada quando um número de suas entradas estão ativas. Uma rede conectada destes neurônios artificiais tem a capacidade de realizar cálculos complexos, assim como uma rede de neurônios biológicos desempenham a função de propagação de impulso nervoso ao longo do sistema nervoso (Géron, 2019).

Perceptron Multicamadas: O *Perceptron* é uma arquitetura simples de RNA que recebe várias entradas e produz uma única saída binária. Existem algumas limitações no aprendizado ao se utilizar uma arquitetura com apenas um *Perceptron*, sendo assim, é utilizado o empilhamento de *Perceptrons*, construindo uma arquitetura conhecida como *Perceptron Multicamadas* (*Multilayer Perceptron*, do inglês, MLP). O MLP é composto por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Géron, 2019). Todas as camadas são formadas por um número definido de neurônios artificiais, sendo possível cada camada ter números iguais ou diferentes de neurônios, conforme a Figura 1, onde está representado o número máximo de neurônios por n , r e k na camada de entrada, oculta e de saída, respectivamente.

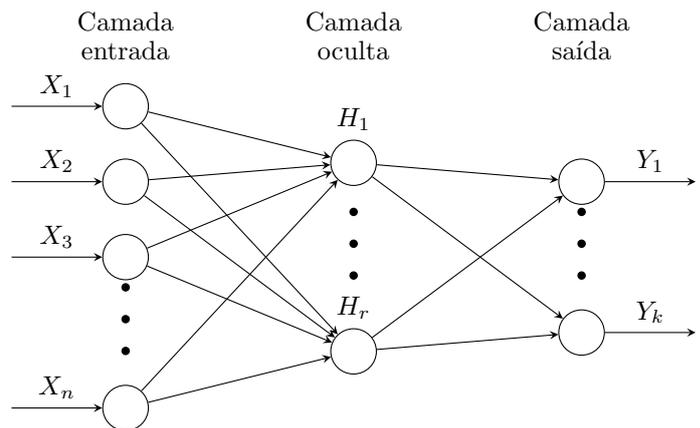


Figura 1. Diagrama de uma rede neural MLP.

3.1 Redes Neurais Recorrentes

A rede neural recorrente (*recurrent neural network*, do inglês, RNN) é um tipo de arquitetura de rede neural que tem facilidade em analisar dados de séries temporais auxiliando no processo de tomada de decisão.

A rede neural recorrente é semelhante com uma rede neural clássica, exceto pelo fato de que a cada intervalo de tempo o neurônio recorrente receber uma entrada $x(t)$ e a própria saída do tempo anterior $y(t-1)$. Essa característica permite construir uma rede neural desenrolada ao longo do tempo (Géron, 2019; Wilms et al., 2019).

Células de Memória: O neurônio recorrente tem uma saída no intervalo t que depende de todas as entradas dos intervalos de tempos anteriores, tendo uma aparência de *memória*. A parte de uma rede neural que preserva um conhecimento anterior é chamada de célula de memória (Géron, 2019).

Células de Memória Longa de Curto Prazo: (*Long short-term memory*, do inglês, LSTM), foi proposta em 1997 por Sepp Hochreiter e Jurgen Schmidhuber (Hochreiter e Schmidhuber, 1997). Esta célula é dividida em dois vetores: o estado de curto prazo ($h_{(t)}$) e o estado de longo prazo ($c_{(t)}$) que permite ter um desempenho melhor com um tempo reduzido de convergência, pois a ideia central é permitir que a rede possa saber a informação que deve armazenar a longo prazo, a informação que não deve armazenar e o que aprender com as leituras das informações.

A Figura 2 mostra uma rede neural recorrente desenrolada no tempo. A esquerda, está representada a arquitetura da rede neural recorrente com a célula de memória LSTM (A), enquanto que na direita é mostrada a RNN-LSTM desenrolada no tempo.

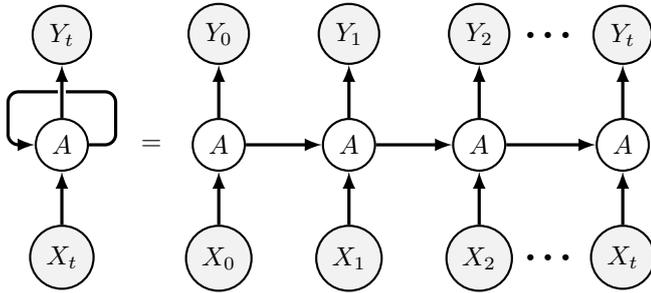


Figura 2. Diagrama básico de uma rede neural recorrente - RNN-LSTM

4. METODOLOGIA

A previsão da velocidade do vento é realizada pelas duas técnicas apresentadas anteriormente, sendo que as técnicas foram implementadas na linguagem de programação *Python*, com a utilização das seguintes bibliotecas: *numpy*, *pandas* e *matplotlib* e dos seguintes frameworks: *sklearn*, *keras*. Para realizar o treinamento do algoritmo pelo framework *keras* foi escolhido o otimizador *Adaptive Moment Estimation (Adam)*, sendo que o mesmo permitiu obter resultados satisfatórios. A Figura 3 representa o fluxograma que ilustra a metodologia utilizada neste trabalho para a execução de ambas as técnicas.

De acordo com a Figura 3, a etapa denominada: Aplicação do Algoritmo Inteligente, refere-se às redes neurais utilizadas, portanto, para os estudos, ora era selecionada a rede neural artificial clássica (RNA), ora era selecionada a rede neural artificial recorrente (RNN-LSTM).

4.1 Métricas para avaliação do desempenho

Para avaliar o desempenho dos algoritmos inteligentes foram utilizadas métricas difundidas na literatura, que são: erro médio absoluto (*mean absolute error*, do inglês, MAE) e a raiz do erro quadrático médio (*root-mean-square error*, do inglês, RMSE) e o coeficiente U de Theil. Os cálculos dessas métricas estão apresentados a seguir:

O erro médio absoluto (MAE):

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (1)$$

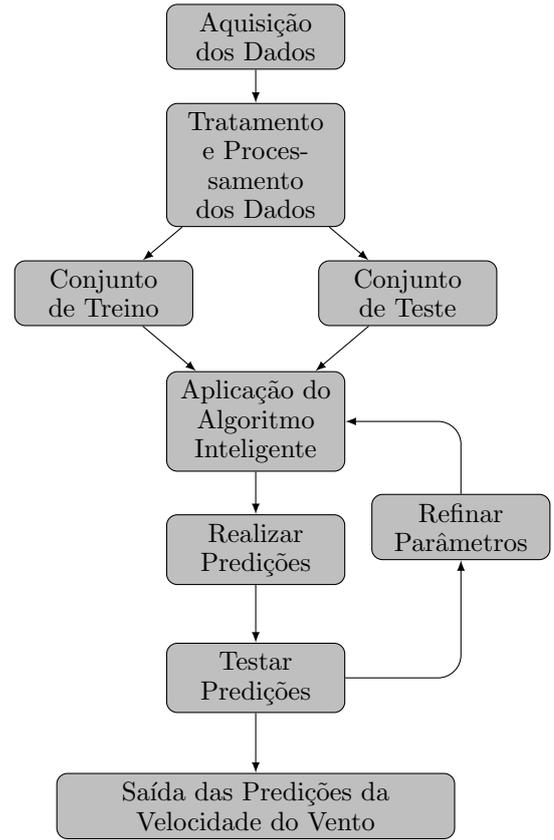


Figura 3. Fluxograma da metodologia para previsão da velocidade do vento.

A raiz do erro quadrático médio (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (2)$$

O coeficiente U de Theil:

$$UTHEIL = \frac{\sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2}}{\sqrt{\frac{1}{n} \sum_{j=1}^n (y_j)^2 + \frac{1}{n} \sum_{j=1}^n (\hat{y}_j)^2}} \quad (3)$$

onde:

- n é o número total de pontos;
- \hat{y}_j é o valor resultante da previsão;
- y_j é o valor real desejado na previsão para o tempo t .

O MAE e o RMSE dito anteriormente expressam o erro médio da previsão realizada pelo modelo, na mesma unidade (dimensão). A interpretação destes parâmetros mostra que quanto menor o seu valor, melhor é o modelo, já que a previsão se mostra mais próxima ao valor real. Comparando as duas métricas têm-se que o RMSE penaliza desvios grandes, enquanto o MAE tem pesos iguais para todos os desvios. Theil (1966) apresentou uma métrica para avaliar a precisão e a sensibilidade de previsões conhecida como coeficiente U de Theil, classificando a previsão entre zero e um, sendo zero um ajuste perfeito do modelo.

5. ESTUDO DE CASO

O estudo de séries temporais precisas e confiáveis é de suma importância para a previsão de observações futuras com base nos dados disponíveis. Para tal é necessário levar em consideração diversos aspectos, tais como a seleção apropriada dos dados de entrada e a escolha do algoritmo inteligente a ser utilizado, sendo estas escolhas diretamente influentes nos resultados da previsão.

O conjunto de dados apresenta discretização horária, portanto os modelos desenvolvidos neste trabalho realizam a previsão da velocidade do vento para um passo a frente, ou seja, realizam as previsões para a próxima hora.

Todas as previsões foram realizadas em um computador pessoal com as seguintes configurações de processador: *Intel Core i5-8300H, 8 Geração, Quad Core, Frequência de 2.3 GHz à 4.0 GHz, 8MB de SmartCache, Chipset: Intel HM370.*

O repositório com a implementação das técnicas pode ser acessado no seguinte link: <https://bityli.com/riBuW>

5.1 Conjuntos de Dados

O conjunto de dados para avaliar as metodologias propostas refere-se ao Parque Eólico de Pedra Rajada, localizada em Cerro Corá - Rio Grande do Norte, com as seguintes coordenadas -5,914116 e -36,30923 de latitude e longitude, respectivamente. Estes dados foram obtidos no site da VORTEX, mediante a realização de um cadastro, que pode ser acessado através do link: <https://vortexfdc.com/>. O conjunto detém quatro mil trezentos e sessenta e quatro pontos de medições da velocidade do vento em módulo e direção, da densidade do ar, da pressão e da temperatura registrados a cada intervalo de uma hora, cujo período que foi escolhido arbitrariamente corresponde ao dia 05/11/2018 até 06/05/2019. A Figura 4 mostra um histograma do conjunto de dados, onde o eixo da abcissa representa a grandeza avaliada e o eixo da ordenada representa a frequência absoluta com que o valor da grandeza se repete no conjunto de dados, esta escolha se justifica pelo início do estudo e pela disponibilização gratuita dos dados pelo site para um período de seis meses.

Para realizar o treinamento das redes neurais é necessário a separação correta do conjunto de dados, conforme a Figura 3. Foi utilizado em torno de 70% dos dados para o conjunto de treinamento, que corresponde a três mil pontos, e o restante para o conjunto de testes, que equivale a mil trezentos e sessenta e quatro pontos.

5.2 Discussão dos Resultados

Neste trabalho, dois tipos de redes neurais são utilizadas para prever o valor da velocidade do vento, para ambas as técnicas o número de camadas foram o mesmo, sendo: uma camada de entrada, uma camada oculta e uma camada de saída com um neurônio. Para a rede neural clássica foram utilizados quatro parâmetros de entrada: densidade do ar, temperatura, pressão, e ângulo da direção do vento. No entanto, para a rede neural recorrente foram utilizados cinco parâmetros de entrada, sendo quatro destes iguais ao utilizado na RNA, mais um para a entrada do módulo da

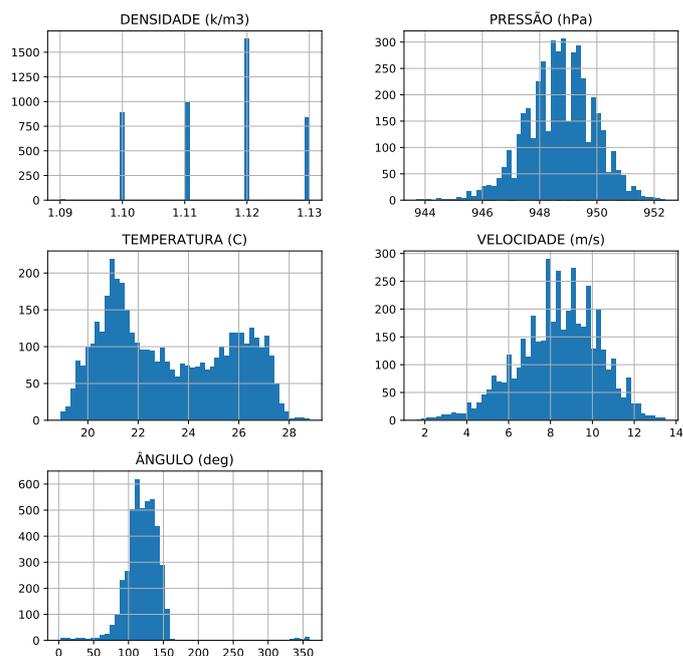


Figura 4. Histograma do conjunto de dados utilizado.

velocidade do vento proveniente da saída do tempo anterior. O número de neurônios da camada oculta foi variado aleatoriamente a fim de obter o valor deste parâmetro que resultasse na melhor eficiência da rede neural. Ambas as técnicas foram expostas as mesmas condições para que seja possível realizar a comparação da eficiência.

Os modelos de previsão desenvolvidos são testados em um conjunto de dados reservado antes do treinamento para que a rede neural não tenha contato algum com estes dados. A fim de ilustrar as previsões obtidas, são mostrados nas Figuras 5 e 6 as séries de velocidade do vento medidas, obtidas do conjunto de dados e previstas com a rede neural clássica e com a rede neural recorrente com célula de memória LSTM, respectivamente. Ambas as técnicas possuem trinta neurônios na camada oculta.

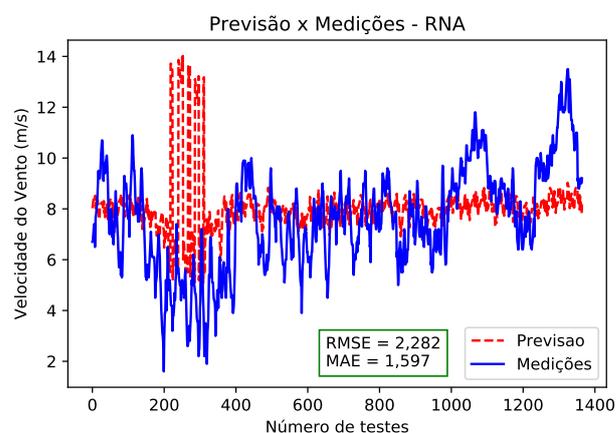


Figura 5. Previsão da velocidade do vento pela RNA.

Diante da análise gráfica das figuras acima, nota-se que as previsões realizadas pela RNN-LSTM são mais precisas ao compará-las aos valores reais (medidos) da velocidade do vento. Para consolidar a análise do desempenho das

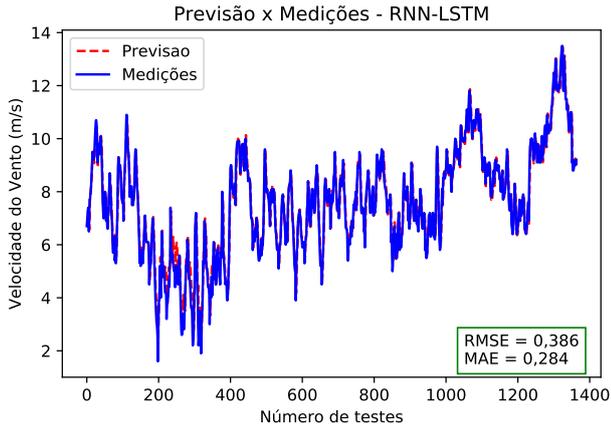


Figura 6. Previsão da velocidade do vento pela RNN-LSTM.

redes neurais, são apresentados nas Tabela 1 e 2, para cada configuração do número de neurônios da camada oculta da rede neural, os parâmetros estatísticos, RMSE, MAE, UTHEIL e o tempo computacional total, que contempla o tempo necessário para treinar a rede neural e o tempo para gerar as previsões (validação da rede neural). Nas referidas tabelas, as configurações de melhor desempenho encontram-se em destaque

Tabela 1. Parâmetros de análise para RNA clássica.

Números de Neurônios	RMSE (m/s)	MAE (m/s)	UTHEIL	Tempo (s)
5	2,306	1,731	0,145	2,370
10	2,174	1,659	0,137	2,491
20	2,437	1,612	0,142	2,380
30	2,282	1,597	0,151	2,583
50	2,319	1,585	0,139	3,372

Tabela 2. Parâmetros de análise para RNN-LSTM.

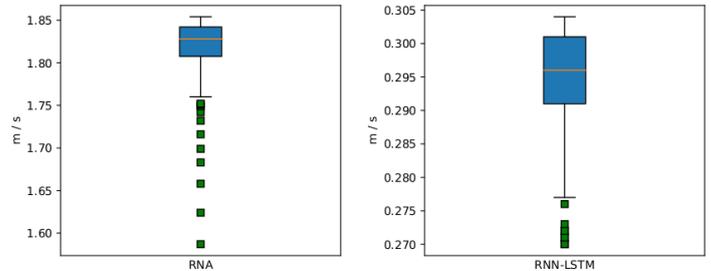
Números de Neurônios	RMSE (m/s)	MAE (m/s)	UTHEIL	Tempo (s)
5	0,431	0,327	0,038	3,772
10	0,391	0,288	0,025	3,862
20	0,387	0,287	0,026	3,909
30	0,386	0,284	0,024	4,016
50	0,398	0,288	0,024	6,411

A acurácia obtida pela RNN-LSTM reflete nos menores valores das métricas estatísticas, sendo os melhores resultados apresentados para a configuração de trinta neurônios na camada oculta, pois apresenta o menor valor de RMSE, MAE e UTHEIL, dessa forma, esta técnica se destaca como a mais eficiente na previsão da velocidade do vento. Em relação ao tempo computacional, a RNN-LSTM sempre apresenta um valor superior quando comparada com a clássica, este fato está relacionado com a complexidade no seu processo de previsão, porém não inviabiliza a utilização da técnica.

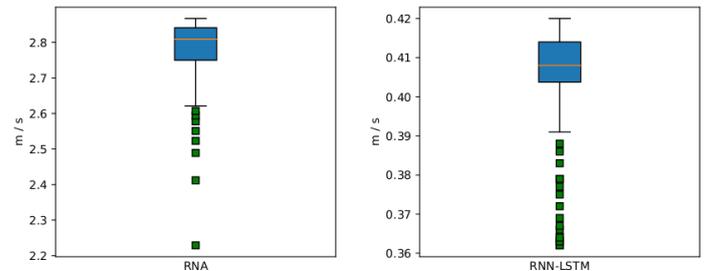
Observando ambas as Tabelas 1 e 2 nota-se que a métrica RMSE se mostra sempre maior que a MAE, enfatizando que os erros obtidos não são de mesma magnitude. Embora

o tempo computacional da RNN-LSTM mostra-se ligeiramente superior, não inviabiliza a utilização da técnica, visto que a sua precisão é extremamente relevante.

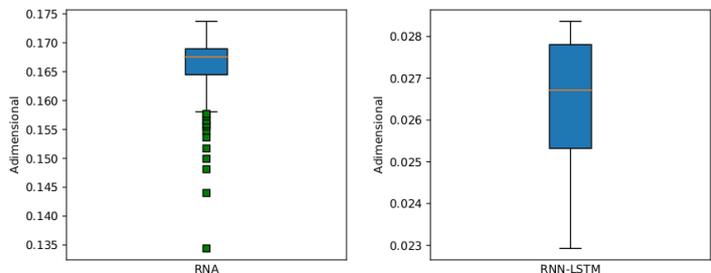
Após a identificação da arquitetura de rede neural que obteve o melhor desempenho, correspondente a trinta neurônios na camada oculta, foi realizado um estudo da variabilidade dos erros MAE e RMSE para cem previsões, cujos resultados são apresentados através dos boxplots da Figura 7.



(a) Comparação da variação do MAE.



(b) Comparação da variação do RMSE.



(c) Comparação da variação do UTHEIL.

Figura 7. Análise estatística descritiva.

A Figura 7 apresenta uma análise estatística descritiva das métricas utilizadas para a avaliação do desempenho das técnicas. Em relação aos valores absolutos das métricas, a RNN-LSTM apresenta os menores valores com a menor amplitude interquartilica (AIQ) acompanhado da menor dispersão dos resultados quando comparada à RNA, conforme a Tabela 3. Portanto, com esta investigação identificam-se o melhor desempenho e a maior eficiência da RNN-LSTM na previsão da velocidade do vento.

6. CONCLUSÃO

Neste artigo foi proposto a comparação de duas técnicas para a previsão da velocidade do vento. A primeira técnica

Tabela 3. Parâmetros da estatística descritiva.

MAE		
Rede neural	AIQ	Dispersão
RNA	0,034	0,103
RNN-LSTM	0,010	0,029

RMSE		
Rede neural	AIQ	Dispersão
RNA	0,091	0,290
RNN-LSTM	0,010	0,028

UTHEIL		
Rede neural	AIQ	Dispersão
RNA	0,004	0,015
RNN-LSTM	0,002	0,005

consiste em uma rede neural supervisionada clássica cujo treinamento utiliza os algoritmos *feedforward* e *backpropagation*. A segunda técnica consiste em uma rede neural aprimorada, rede neural recorrente com células de memória LSTM.

Diante dos resultados apresentados, pode-se concluir que a rede neural recorrente (RNN-LSTM) prediz a velocidade do vento com mais eficiência do que a rede neural supervisionada clássica. Destacando-se como o modelo apropriado para o estudo e previsão da energia elétrica proveniente de fontes eólicas.

Decorrente deste trabalho, estudos futuros são necessário a fim de otimizar o número de neurônios a ser utilizado na camada oculta com o objetivo de aprimorar o processo de previsão, e de aplicar a técnica de RNN-LSTM nos problemas relacionados à geração provenientes de fontes renováveis que compõem ao Sistema Elétrico de Potência, no quais se destacam:

- Previsão da geração eólica (no momento atual, é necessário obter a expressão do aerogerador que relaciona a potência elétrica de saída com a velocidade do vento, dado que a previsão do vento foi realizada);
- Realizar a previsão da geração fotovoltaica a partir da previsão da irradiação solar;
- Realizar a previsão de afluências para a geração hidrelétrica.

7. AGRADECIMENTOS

Os autores gostariam de agradecer ao Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ) pelo incentivo à pesquisa e ao site VORTEX por possibilitar a aquisição dos dados reais para viabilizar o estudo.

REFERÊNCIAS

- Çevik, H.H., Acar, Y.E., and Çunkaş, M. (2018). Day ahead wind power forecasting using complex valued neural network. In *2018 International Conference on Smart Energy Systems and Technologies (SEST)*, 1–6. IEEE.
- Fente, D.N. and Singh, D.K. (2018). Weather forecasting using artificial neural network. In *2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)*, 1757–1761. IEEE.

Géron, A. (2019). Mãos à obra: Aprendizado de máquina com scikit-learn tensorflow. In *ALTA BOOKS EDITORA*.

Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735–1780.

Huang, C.J. and Kuo, P.H. (2018). A short-term wind speed forecasting model by using artificial neural networks with stochastic optimization for renewable energy systems. *Energies*, 11(10), 2777.

Kurdikeri, R.B. and Raju, A. (2018). Comparative study of short-term wind speed forecasting techniques using artificial neural networks. In *2018 International Conference on Current Trends towards Converging Technologies (ICCTCT)*, 1–5. IEEE.

McCulloch, W.S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.

Theil, H. (1966). Applied economic forecasting, rand mcnally and company.

Wilms, H., Cupelli, M., Monti, A., and Gross, T. (2019). Exploiting spatio-temporal dependencies for rnn-based wind power forecasts. In *2019 IEEE PES GTD Grand International Conference and Exposition Asia (GTD Asia)*, 921–926. IEEE.