

# PREVISÃO DE VELOCIDADE DO VENTO COM SÉRIE TEMPORAL MULTIVARIADA UTILIZANDO REDE NEURAS RECORRENTE

*Data de aceite: 02/05/2024*

### **Reginaldo Nunes da Silva**

Universidade Estadual do Maranhão,  
Departamento de Engenharia da  
Computação, São Luís, Maranhão, Brasil

### **Dario Gerardo Fantini**

Universidade de Brasília, Departamento  
de Engenharia Mecânica, Laboratório  
de Energia e Ambiente, Brasília, Distrito  
Federal, Brasil

### **Mauro Sérgio Silva Pinto**

Universidade Estadual do Maranhão,  
Departamento de Engenharia da  
Computação, São Luís, Maranhão, Brasil

### **Rafael Castilho Farias Mendes**

Universidade de Brasília, Departamento  
de Engenharia Mecânica, Laboratório  
de Energia e Ambiente, Brasília, Distrito  
Federal, Brasil

### **Marlos José Ribeiro Guimarães**

Laboratório de Aerodinâmica Aplicada de  
Furnas, Departamento de Segurança de  
Barragens e Tecnologia - DSB.E, Goiânia,  
Goiás, Brasil

### **Antônio César Pinho Brasil Júnio**

Universidade de Brasília, Departamento  
de Engenharia Mecânica, Laboratório  
de Energia e Ambiente, Brasília, Distrito  
Federal, Brasil

**RESUMO:** A investigação da série temporal é fundamental para o monitoramento e administração de sistemas elétricos, particularmente no contexto de sistemas de energia eólica, onde a capacidade de prever a velocidade do vento com elevada precisão é crucial. Tal previsão possibilita o despacho de energia de maneira eficiente e contribui para a mitigação dos riscos associados à volatilidade inerente das condições eólicas. O presente estudo propõe e implementa um modelo de Rede Neural Recorrente Multivariada com Memória de Curto e Longo Prazo (MV-LSTM do inglês Long Short-Term Memory Networks with Multiple Variables) para analisar dados de velocidade do vento, incluindo medidas médias, máximas e mínimas em base horária. Adicionalmente, uma Rede LSTM univariada foi desenvolvida para servir como termo de comparação. Os dados empregados neste estudo foram coletados por meio de um anemômetro sônico, durante o intervalo de 01 de janeiro a 31 de dezembro de 2015, em um ecossistema de cerrado nativo na Fazenda Água Limpa (FAL), situada no Distrito Federal, Brasil. Os resultados obtidos indicam que a inclusão dos vetores de velocidade máxima e mínima aprimora significativamente a precisão das

previsões de velocidade do vento. Além disso, o modelo MV-LSTM demonstrou uma redução no atraso das previsões em situações de transições abruptas na velocidade do vento, um desafio previamente identificado por Xie et al. (2021) em sua pesquisa. Sugere-se que o modelo pode ser aperfeiçoado através da adição de camadas adicionais e da integração com outros métodos de aprendizado de máquina para otimizar ainda mais o desempenho preditivo.

**PALAVRAS-CHAVE:** MV-LSTM, Previsão, Energia Eólica

## WIND SPEED FORECAST WITH MULTI-VARIABLE TIME SERIES USING RECURRENT NEURAL NETWORK

**ABSTRACT:** Investigating time series is crucial for monitoring and administering electrical systems, especially in the context of wind energy systems, where the ability to predict wind speed with high precision is critical. Such forecasting enables efficient energy dispatch and contributes to mitigating risks associated with the inherent volatility of wind conditions. This study proposes and implements a Multivariate Long Short-Term Memory (MV-LSTM) model to analyze wind speed data, including average, maximum, and minimum hourly measurements. Additionally, a univariate LSTM network was developed for comparison. The data used in this study were collected through a sonic anemometer, from January 1 to December 31, 2015, in a native cerrado ecosystem at Fazenda Água Limpa (FAL) in the Federal District, Brazil. The findings indicate that including maximum and minimum speed vectors significantly improves the accuracy of wind speed forecasts. Moreover, the MV-LSTM model showed a reduction in forecast lag in situations of abrupt wind speed transitions, addressing a challenge previously identified by Xie et al. (2021). It suggests that the model could be further enhanced by adding additional layers and integrating with other machine learning methods to optimize predictive performance.

**KEYWORDS:** MV-LSTM, Forecast, Wind Energy

## INTRODUÇÃO

A análise de dados de séries temporais é fundamental para o controle e gerenciamento de diversos sistemas. Atualmente, os sistemas de conversão de energia renovável representam os principais motivadores para o desenvolvimento de análises de séries temporais (Jin et al., 2020). Séries temporais são importantes para realizar previsões de dados futuros e, com isso, planejar quanto de energia será possível despachar em determinado período, assim como para o gerenciamento de parques eólicos ou fotovoltaicos (Dubey et al., 2021). Portanto, análises de séries temporais de dados de velocidade do vento e irradiação solar são bastante estudadas com o objetivo de maximizar a conversão de energia.

Contudo, para prever o futuro dos dados, não basta apenas o valor histórico da variável-alvo; outros fatores com influência implícita também devem ser considerados na análise (Liang, Nguyen, Jin, 2018; Jin et al., 2020; Dubey et al., 2021). A velocidade do

vento pode ser influenciada pela temperatura, irradiação solar, umidade e direção do vento, além das condições topográficas. Du (2018) argumenta que, ao realizar análises com variáveis multidimensionais que apresentam correlação entre si, a precisão das variáveis-alvo da análise é melhorada devido à correlação intrínseca e às características históricas.

Diversos trabalhos que fazem análise de séries temporais para previsão de dados futuros foram publicados nos últimos anos. Dubey et al. (2021) utilizam a Média Móvel Integrada Autoregressiva (ARIMA), ARIMA sazonal (SARIMA) e Long Short-Term Memory (LSTM) para prever o consumo de energia em uma base de dados diária, e os resultados obtidos mostram que o modelo LSTM apresenta melhores resultados. Rashid (2018) desenvolveu uma análise de um conjunto de dados de consumo de energia para criar um modelo de previsão utilizando ARIMA. Essas análises de big data podem ajudar as empresas de energia a melhorar a gestão de energia e serviços. Zufferey et al. (2016) aplicam Redes Neurais Artificiais (RNAs) para previsões precisas de carga de curto prazo em sistemas fotovoltaicos (PV) e investigam diferentes níveis de agregação espacial. Os resultados mostram que o fluxo de energia confirma os benefícios da previsão de séries temporais para apoiar a operação da rede.

Para um controle e gerenciamento inteligente de turbinas eólicas, é importante ter informações antecipadas de velocidade do vento para permitir uma operação estável do sistema de energia. Yao, Huang e Jia (2018) aplicaram um modelo LSTM em conjunto com a teoria dos Conjuntos Fuzzy-Rough (SFR) para a previsão de velocidade do vento a curto prazo. Os resultados mostraram que o modelo FRS-LSTM tem maior precisão de predição do que a rede neural tradicional. Cao e Gui (2018) utilizaram o modelo LSTM para previsão de séries temporais de velocidade do vento em conjunto com o modelo LightGBM. Apesar de o LSTM conseguir identificar as dependências de longo prazo, sua capacidade de lidar com diferentes janelas de dados no curto prazo para vários intervalos de tempo é insuficiente para uma boa previsão. Assim, é comum que o LSTM seja combinado com outro modelo de previsão.

A previsão confiável e precisa da velocidade do vento é a base para a utilização eficaz da energia eólica. Shao (2021) utiliza a combinação da rede LSTM e FWA (Firework Algorithm) para fazer a previsão da velocidade do vento baseada na velocidade em tempo real. Os resultados mostram que o método FWA-LSTM reduz os erros de previsão da velocidade do vento. Xie et al. (2021) desenvolveram um modelo LSTM multivariado (MV-LSTM) para previsão de velocidade do vento a curto prazo baseado em temperatura, pressão e umidade. A seleção das variáveis foi feita a partir do coeficiente de correlação de Pearson. O modelo MV-LSTM apresentou resultados superiores aos modelos ARMA e LSTM com variável única. Portanto, é evidente que o modelo LSTM tem sido amplamente utilizado para previsão de velocidade do vento; no entanto, é necessário desenvolver modelos que auxiliem o LSTM a aumentar a acurácia da previsão para alcançar alta confiabilidade.

Com a inserção dos vetores de velocidade máxima e mínima no modelo, as características de curto prazo podem ser mais bem definidas. Dessa forma, este artigo propõe um modelo de previsão de velocidade do vento utilizando o modelo LSTM multivariado baseado em dados de velocidade média, máxima e mínima horária. Uma análise baseada no coeficiente de correlação de Pearson é realizada, e o modelo é treinado com dados históricos coletados no Cerrado brasileiro nativo no Distrito Federal.

## MÉTODOS E DADOS

### Descrição do sítio

O Laboratório de Energia e Ambiente da Universidade de Brasília vem conduzindo, ao longo dos últimos cinco anos, um experimento de caracterização da camada limite atmosférica sobre uma área de Cerrado brasileiro nativo na cidade de Brasília. O estudo utiliza medições experimentais em torres de 8 m de altura com a técnica Eddy Covariance, com o objetivo de verificar a dinâmica da camada limite atmosférica e estimar fluxos no bioma (ver Fig. 1). Registra-se um conjunto de dados com taxas de aquisição de 10 Hz que incluem os componentes tridimensionais da velocidade do vento, as concentrações de H<sub>2</sub>O e CO<sub>2</sub>, e a temperatura.



Figura 1 - Experimento Eddy Covariance. Torre de 8 m sobre área de Cerrado nativo (a); Detalhe do anemômetro sônico 3D (b).

Os dados foram coletados na Fazenda Água Limpa (FAL), que pertence à Universidade de Brasília, localizada no Distrito Federal, com as coordenadas 15°57'13" S 47°54'58" W. A FAL está localizada a 28 km da sede do Campus Universitário da Asa Norte e faz parte da Área de Proteção Ambiental das Bacias do Gama e Cabeça do Veado. A torre com anemômetro sônico foi instalada nas coordenadas mostradas na Fig. 2.

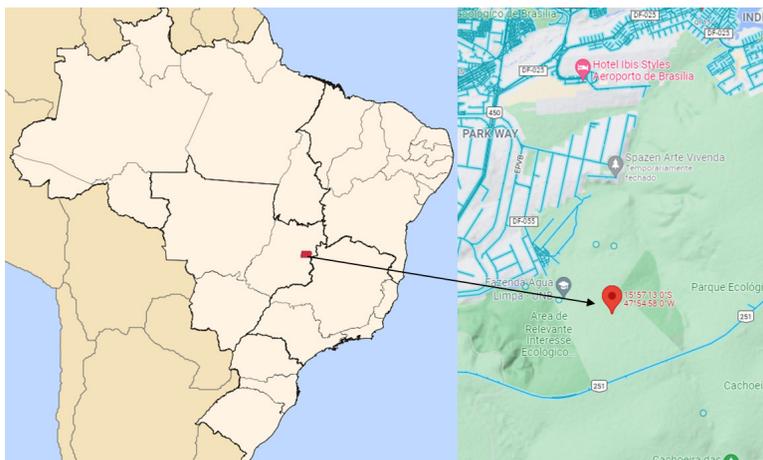


Figura 2 – Localização da torre de coleta dos dados.

## Descrição dos dados

As séries temporais são agrupadas em valores horários e em bases mensais no sentido de estabelecer a resposta sazonal da camada limite atmosférica sobre a área de Cerrado nativo. De forma ilustrativa, esses valores são apresentados na Tabela 1. Observa-se que, nesta região, os ventos são fracos, com médias em torno de 2 m/s. Em alguns dias, a velocidade máxima do vento pode excepcionalmente atingir 5 m/s. A velocidade do vento é maior nos meses de junho a agosto, período em que as ondas de frio características do inverno local proporcionam ventos mais intensos.

	Velocidade Média (m/s)	Velocidade Máxima (m/s)	Desvio Padrão
<b>Jan</b>	1.9	4.8	0.841
<b>Fev</b>	2.0	5.8	1.002
<b>Mar</b>	1.6	4.1	0.790
<b>Abr</b>	1.5	4.8	0.769
<b>Mai</b>	1.9	5.2	0.832
<b>Jun</b>	2.9	5.7	0.858
<b>Jul</b>	2.1	6.2	0.995
<b>Ago</b>	2.3	5.0	1.021
<b>Set</b>	1.9	4.9	0.940
<b>Out</b>	1.9	4.9	0.974
<b>Nov</b>	1.8	6.6	0.932
<b>Dez</b>	1.8	4.8	0.847

Tabela 1 - Valores médios mensais de vento em torre de 8 m sobre o Cerrado.

Neste estudo, os dados da série temporal de todos os elementos meteorológicos foram usados para prever a velocidade do vento a curto prazo. As observações foram feitas entre 1 de janeiro e 31 de dezembro de 2015 e agrupadas em médias horárias. 80% dos dados totais (292 dias  $\times$  24 h = 7008 amostras de dados) foram usados para treinar o modelo, e os últimos 20% dos dados totais (73 dias  $\times$  24 h = 1752 amostras de dados) foram usados para testar o modelo. Para abordar a questão dos valores ausentes, o valor médio dos dois pontos de dados antes e depois do ponto de dados ausente foi utilizado para reposição.

### Long Short-Term Memory (LSTM)

Em 1997, Hochreiter et al. (1997) propuseram o modelo de rede Long Short-Term Memory (LSTM), que incorpora memória de curto e longo prazo através de um mecanismo de controle de portas, mitigando assim o problema de desaparecimento ou explosão de gradientes encontrado em Redes Neurais Recorrentes (RNNs). A Fig. 3 ilustra a estrutura básica de uma célula LSTM. A rede é composta por uma célula com uma porta de saída  $T_o$ , uma célula de memória  $\tilde{c}_t$ , uma porta de entrada  $T_i$  e uma porta de esquecimento  $T_f$ .  $W$  e  $U$  representam as matrizes de pesos compartilhados dos neurônios,  $h_t$  é o estado oculto no momento  $t$ ,  $x_t$  é a entrada da rede no momento  $t$ , e  $\sigma$  e  $\tanh$  são as funções de ativação.

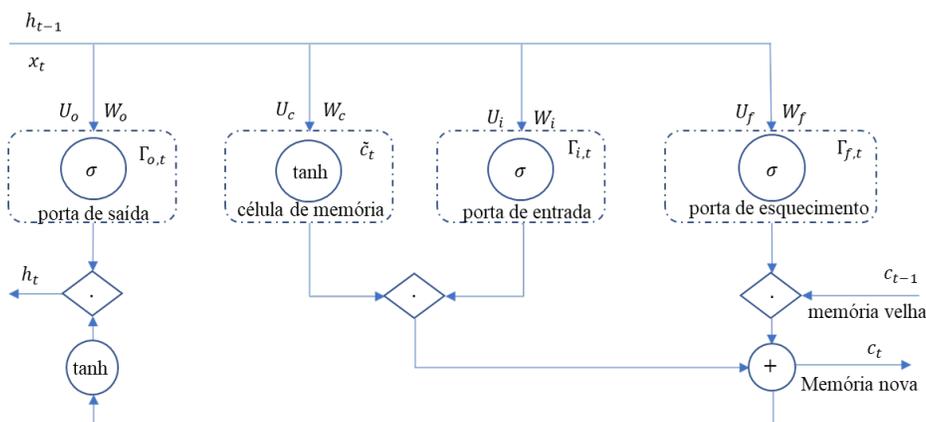


Figura 3 – Estrutura básica de uma célula da rede LSTM.

A rede LSTM funciona a partir do controle dos *gates*. A porta de esquecimento determina quais informações da memória velha é descartada ou retida. Com  $h_{t-1}$  e  $x_t$ , uma saída de 0 e 1 é obtida, onde 0 significa descartado e 1 retido. A saída da porta de esquecimento é dada pela Eq. (1)

$$\Gamma_{f,t} = \sigma(U_f h_{t-1} + W_f x_t + b_f), \quad (1)$$

em que,  $b_f$  é o vetor de polarização.

A porta de entrada determina as informações que são adicionadas à célula e tem como função gerar informações para as funções tanh e sigmóide de modo combinado com a porta de esquecimento e atualiza o estado da célula da rede LSTM. As informações são dadas pelas Eq. (2) e Eq. (3).

$$\Gamma_{i,t} = \sigma(U_i h_{t-1} + W_i x_t + b_i) \quad (2)$$

$$\tilde{c}_i = \tanh(U_c h_{t-1} + W_c x_t + b_c) \quad (3)$$

A última etapa da célula de uma rede LSTM é A porta de saída. É na porta de saída que as informações do estado atual da célula são determinadas e em conjunto com as funções sigmóide e tanh calcula a saída da célula. As informações da porta de saída são calculadas pelas Eq. (4) e Eq. (5)

$$\Gamma_{o,t} = \sigma(U_o h_{t-1} + W_o x_t + b_o), \quad (4)$$

$$h_t = \Gamma_{o,t} \tanh(c_t), \quad (5)$$

### **Rede Long Short-Term Memory Multivariado (MV-LSTM)**

Neste artigo, é proposto um modelo LSTM multivariado para previsão de dados de velocidade do vento a curto prazo baseado nas velocidades média, máxima e mínima horária. As características dos dados são analisadas a partir do coeficiente de correlação de Pearson. A estrutura do modelo é mostrada na Fig. 4.

A seleção das variáveis de entrada para o modelo foi definida com o objetivo de verificar se inserindo dois vetores com velocidade máxima e mínima ao modelo os resultados previstos melhoram. A correlação de Pearson foi utilizada para verificar o quanto esses vetores se correlacionam. Variáveis correlacionada melhoram os resultados previstos para o modelo MV-LSTM apresentado por Xie et. al (2021). Porém, os valores máximo e mínimo ainda não apresentam bons resultados devido o modelo apresentar instabilidades com esses dados. O coeficiente da correlação de Pearson pode ser calculado pela Eq. (6)

$$r(x, y) = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y}, \quad (6)$$

em que,  $r(x, y)$  é o coeficiente de correlação de Pearson entre  $x$  e  $y$ ,  $\text{cov}(x, y)$  é a covariância entre  $x$  e  $y$ ,  $\sigma_x$  é o desvio padrão de  $x$  e  $\sigma_y$  é o desvio padrão de  $y$ .

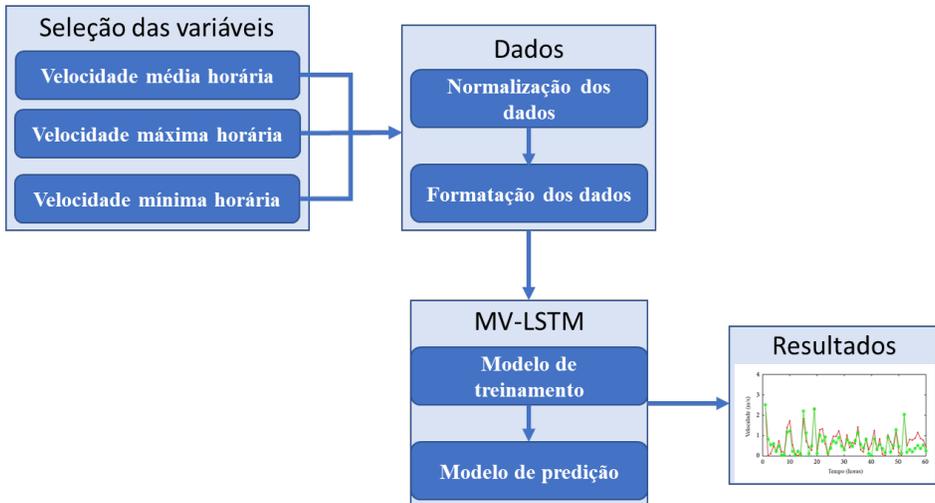


Figura 4 – Estrutura da rede LSTM multivariável proposta para previsão da velocidade do vento descrita em quatro etapas de desenvolvimento.

Para garantir que as variáveis de entrada tenham escalas e estruturas semelhantes em todos os vetores é necessário a normalização. Os valores máximo e mínimo são utilizados para normalizar os dados de treinamento e teste. Todos os vetores são normalizados a partir da Eq. (7).

$$v_{inorm} = \frac{v_i - v_{min}}{v_{max} - v_{min}}, \quad (7)$$

em que,  $v_{inorm}$  são os valores do recurso normalizado para o tempo  $i$ ,  $v_{max}$  e  $v_{min}$  são os valores máximo e mínimo do conjunto de dados para um recurso,  $v_i$  são os valores real no tempo  $i$ . Todos os dados foram normalizados e escalonados entre 0 e 1.

O próximo passo é formatar os dados de forma que todos os vetores de velocidade se tornem uma matriz de entrada no modelo MV-LSTM. Para configurar a rede MV-LSTM foi utilizado a biblioteca Python chamada Keras. Sendo uma rede de aprendizado supervisionado, LSTM precisa ter duas partes de dados. Dessa forma, os dados são divididos em amostra e os rótulos correspondentes, ou seja, entrada  $x$  e saída  $y$ , onde a entrada  $x$  representa os dados de amostra e  $y$  representa o rótulo correspondente aos dados de amostra. Portanto, os conjuntos de treinamento e teste precisam ser formatados em duas partes  $x$  e  $y$ . As amostras de velocidade são representadas pelo vetor  $v_i = (v_{média}, v_{máxima}, v_{mínima})$ , assim a formatação dos dados pode ser feita a partir da montagem de uma matriz contendo todos os vetores de acordo com a Eq. (8) e Eq. (9).

$$\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} v_1 & v_2 & \dots & v_t \\ v_2 & v_3 & \dots & v_{t+1} \\ \vdots & \vdots & \vdots & \vdots \\ v_n & v_{n+1} & \dots & v_{t+n-1} \end{bmatrix} \quad (8)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} y_{t+1} \\ y_{t+2} \\ \vdots \\ y_{t+n} \end{bmatrix} \quad (9)$$

em que,  $x_i$  é a amostra de um recurso,  $v_i$  são as observações dos dados no tempo  $i$ .

Os dados do conjunto de treinamento formatado são utilizados para treinar o modelo de rede LSTM. A rede aprende de forma iterativa de modo que os parâmetros de peso são otimizados para o modelo aprender as características dos dados. A Tab. 2 mostra os hiper parâmetros do modelo de rede LSTM.

Parâmetros	VALOR
epoch size	30
batch size	64
neuron size	12
loss function	mean absolute error (MAE)
optimizer	adaptive moment estimation (adam)

Tabela 2 – Hiper parâmetros da rede MV-LSTM.

A última etapa do processo foi a previsão da velocidade do vento com o modelo da rede MV-LSTM treinado com o conjunto de teste foi usada como a entrada do modelo, e o modelo treinado tem como valor previsto  $yn'$ , como mostrado na Eq. (10). Com os dados de testes e com os valores previstos o modelo calcula-se o valor do erro a partir da Eq. (11).

$$\begin{bmatrix} yn'_1 \\ yn'_2 \\ \vdots \\ yn'_n \end{bmatrix} = \begin{bmatrix} yn'_{t+1} \\ yn'_{t+2} \\ \vdots \\ yn'_{t+n} \end{bmatrix} \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - yn'_i| \quad (11)$$

## Métricas de avaliação

Para avaliar o desempenho do método MV-LSTM foi empregado as quatro métricas quantitativas que são as mais utilizadas. O erro foi calculado a partir do Mean absolute erro (MAE), R-squared ( $R^2$ ), a raiz do erro quadrático médio (RMSE) e erro quadrado médio (MSE). O MAE, RMSE, MSE e  $R^2$  são definidos da seguinte forma:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - yn'_i|, \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \widehat{y}_i)^2}, \quad (13)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \widehat{y}_i)^2, \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \widehat{y}_i)^2}{\sum_{i=1}^n (y_i - \overline{y})^2} \quad (15)$$

em que,  $y_i$  é a observação da velocidade do vento no tempo  $i$  e  $\widehat{y}_i$  é a previsão da velocidade do vento no tempo  $i$ .

## RESULTADOS E DISCUSSÕES

A partir dos dados de velocidade média, máxima e mínima para cada hora do ano de 2015 foi calculado a matriz dos coeficientes da correlação de Pearson. Os coeficientes são apresentados no gráfico da Fig. 5. Como era esperado as velocidades máxima e mínima tem alta correlação com a velocidade média, mas a velocidade mínima é menos correlacionada com a velocidade máxima do que a velocidade média. É importante destacar que outros parâmetros meteorológicos apresentam correlação com as mudanças na velocidade do vento, no entanto, para este artigo foi considerado apenas as velocidades máxima e mínima horária em conjunto com a velocidade média, de modo a melhorar a previsão de uma rede LSTM multivariável. O coeficiente da correlação de Pearson varia de -1 a 1. Quando as variáveis apresentam alta correlação o coeficiente é igual a 1 e quando são totalmente descorrelacionadas é igual a -1. No caso, das variáveis utilizadas nesse estudo são altamente correlacionadas, visto que, são dados de velocidade do mesmo *dataset*.

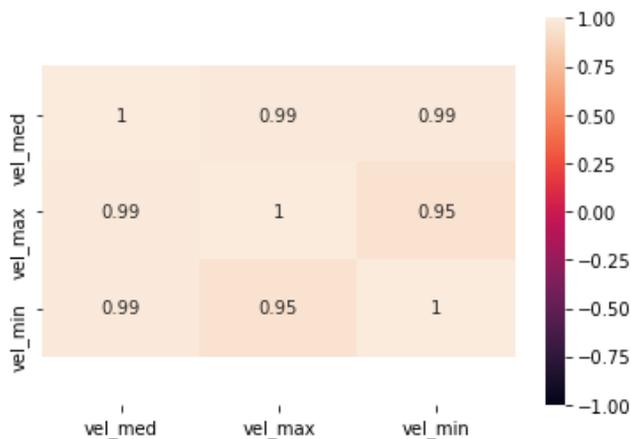


Figura 5 – Correlação de Pearson para os três vetores de velocidade.

Os resultados de predição dos métodos LSTM e MV-LSTM são mostrados como os valores das métricas de avaliação nas Tab. 3, onde o melhor desempenho é destacado em negrito. Os valores de RMSE mostram que o modelo MV-LSTM tem um desempenho melhor do que o modelo LSTM. O método MV-LSTM pode lidar bem com os picos de velocidade. A Fig. 6 apresenta o erro médio absoluto para os dados de treino e teste para o modelo MV-LSTM. O erro do teste é um pouco maior do que o de teste, de certo modo, esse é um comportamento esperado.

Métodos	MAE	RMSE	MSE	R2
LSTM	0.24	0.096	0.0094	0.54
MV-LSTM	<b>0.0394</b>	<b>0.061</b>	<b>0.0037</b>	<b>0.602</b>

Tabela 3 – Os valores métricos de avaliação para os dois modelos no conjunto de teste.

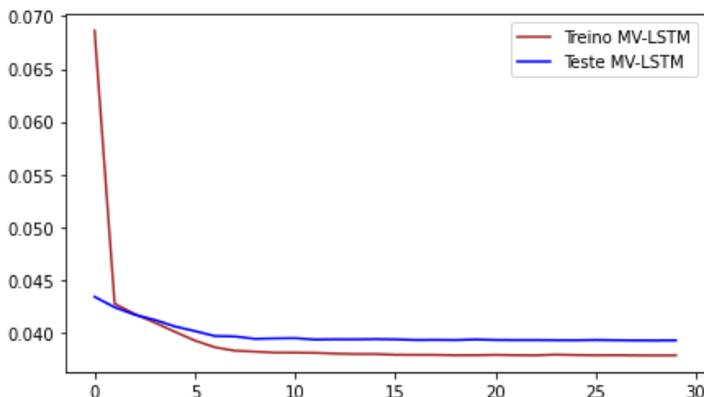


Figura 6 – Curva do erro médio absoluto do modelo VM-LSTM.

Comparando os dados de teste com os dados preditos foi verificado que os picos de velocidade para a rede MV-LSTM com dados de velocidade máxima e mínima diária melhora a previsão dos picos de velocidade média em comparação com as previsões feitas com a rede LSTM com uma variável. A Fig. 5 apresenta as três curvas com destaque para o detalhe de dois picos de velocidade em que o modelo MV-LSTM apresenta valor mais próximo do valor observado e resolve o atraso quando se tem uma mudança de velocidade brusca. No trabalho de Xie et. al (2021) o modelo MV-LSTM implementado apresenta melhoria na previsão, porém continua com atrasos quando há uma mudança brusca de velocidade.

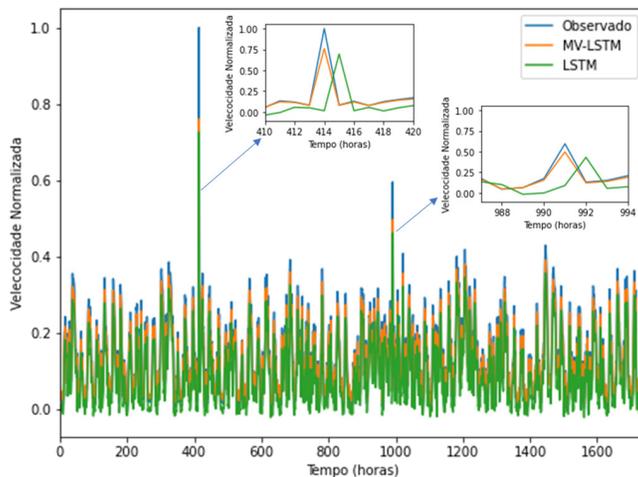


Figura 7 – Dados de testes da rede LSTM e VM-LSTM.

Com as informações dos picos de velocidade horária o modelo aprende as mudanças bruscas dos dados e com isso as informações de picos máximo e mínimos não são descartadas. Diferentemente quando não tem os valores dos picos das mudanças repentinas o modelo descarta, visto que, com os valores médios esses picos apresentam em menor magnitude e menor período. Com os dados de máximo e mínimo de hora em hora modelo MV-LSTM aprende as características dos dados e desenvolve uma previsão com maior acurácia.

## CONCLUSÕES

Neste artigo, é proposto um modelo de rede neural recorrente multivariada do tipo memória de curto longo prazo (MV-LSTM) para previsão de velocidade a curto prazo. Sendo um modelo multivariáveis pode-se prever velocidade do vento a partir de dados históricos de velocidade média, máxima e mínima horária para previsão de velocidade do vento. O modelo foi verificado a partir de dados histórico de uma torre com anemômetro sônico da Laboratório de Energia e Ambiente -UnB que realizou medições entre 01 de janeiro de 2015 a 31 de dezembro de 2015.

O resultado do modelo MV-LSTM é comparado com resultado do modelo LSTM com única variável de entrada. As observações experimentais mostram que o desempenho do modelo MV-LSTM apresenta desempenho de previsão melhor que a rede LSTM de variável única com base apenas em dados históricos de velocidade média do vento. A rede MV-LSTM implementada com as velocidades máximas e mínimas retirou o atraso na previsão da velocidade quando há uma alteração brusca, como em uma rajada de vento. Isso é importante, pois os modelos utilizados atualmente não lidam muito bem com as instabilidade e volatilidade dos dados de velocidade do vento.

O modelo implementado não foi testado com outro conjunto de dados. No entanto, a próxima etapa vai ser implementar o modelo para outro *dataset* de dados e otimizar a capacidade de aprendizado do modelo, bem como implementar *Gated Recurrent Unit Network* (GRU) que é um modelo de aprendizado de máquina supervisionada e fazer comparações. Com base nisso, consideraremos otimizar a capacidade de aprendizado do modelo aumentando sua complexidade, como adicionando camadas de rede e combinando outras redes neurais, melhorando assim a precisão de previsão do modelo para velocidades do vento com maior instabilidade e volatilidade.

## AGRADECIMENTOS

Este trabalho faz parte do projeto de P&D “Otimização do modelo meteorológico BRAMS, com validação experimental, para subsidiar aperfeiçoamentos de modelagens em sistemas eólicos” - PD-0394-1709/2017, regulamentado pela Agência Nacional de Energia Elétrica - ANEEL, desenvolvido pela Eletrobras FURNAS e Universidade de Brasília.

R N Silva e M S S Pinto agradecem à Universidade Estadual de Maranhão - UEMA, Brasil.

## REFERÊNCIAS

- Cao, Y., Gui, L., 2018. Multi-Step wind power forecasting model Using LSTM networks, Similar Time Series and LightGBM, 5th International Conference on Systems and Informatics (ICSAI), pp. 192-197.
- Dubey, A. K., Kumar, A., García-Díaz, V., Sharma, A. K., Kanhaiya, K., 2021. Study and analysis of SARIMA and LSTM in forecasting time series data, Sustainable Energy Technologies and Assessments, vol. 47, n. 10, pp. 114-128.
- Du, S., Li, T., Yan Y., Shi-Jinn, H., 2019. Deep Air Quality Forecasting Using Hybrid Deep Learning Framework, arXiv, vol. 47, pp. 114-126.
- Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory, Neural Comput, vol. 9, pp. 1735–1780.
- Jin, X., Yu, X., Wang, X., Bai, Y., Su, T., Kong, J., 2020. Prediction for Time Series with CNN and LSTM, Springer Singapore, pp. 631-641.
- Liang, S., Nguyen, L., Jin, F., 2018. A Multi-variable Stacked Long-Short Term Memory Network for Wind Speed Forecasting, IEEE Int. Conf. Big Data, pp. 4561–4564.
- Rashid, M. H., 2018. AMI Smart Meter Big Data Analytics for Time Series of Electricity Consumption, 17th IEEE International Conference On Trust, Security And Privacy In Computing And Communications, pp. 1771-1776.
- Xie, A., Yang, H., Chen, J., Sheng, L., Zhang, Q., 2021. A Short-Term Wind Speed Forecasting Model Based on a Multi-Variable Long Short-Term Memory Network, vol. 12, n. 1, pp. 2073-4433.
- Yao, W., Huang, P. Jia, Z., 2018. Multidimensional LSTM Networks to Predict Wind Speed, 37th Chinese Control Conference (CCC), pp. 7493-7497.
- Zufferey, T., Ulbig, A., Koch, S., Hug, G., 2017. Forecasting of Smart Meter Time Series Based on Neural Networks, Springer International Publishing, pp. 10-21.