

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

**Reginaldo Nunes da Silva** – profreginaldo.n@gmail.com  
**Dario Gerardo Fantini** – dario.fantini@aluno.unb.br  
**Rafael Castilho Farias Mendes** – rafael.cfmendes@gmail.com  
**Antonio Cesar Pinho Brasil Junior** – brasiljr@unb.br  
Universidade de Brasília, Campus Darcy Ribeiro, Brasília - DF

**Resumo.** A análise de séries temporais é de extrema importância para controle e gerenciamento de sistemas de geração elétrica com elevada intermitência como é o caso dos sistemas eólicos, onde há necessidade de prever a velocidade do vento com maior precisão, com o intuito de ter uma despachabilidade de energia de forma inteligente e gerenciando riscos que a alta instabilidade do vento pode causar. Este trabalho implementa-se um modelo de Rede Neural Recorrente multivariada do tipo memória de curto longo prazo (MV-LSTM) para dados de velocidade média, máxima e mínima horária. Uma rede LSTM com única variável também é implementada para comparar os resultados. Os dados utilizados foram coletados por um anemômetro sônico no período de 01 de janeiro a 31 de dezembro de 2015 no cerrado nativo brasileiro na Fazenda Água Limpa – FAL localizada no Distrito Federal. Os resultados mostram que os vetores de velocidade máxima e mínima melhoram a previsão de velocidade do vento e que o modelo MV-LSTM reduz o atraso da previsão quando há uma mudança brusca da velocidade do vento.

**Palavras-chave:** MV-LSTM, Previsão Eólica, Energia Eólica

## 1. INTRODUÇÃO

A análise de dados de séries temporais é fundamental para o controle e gerenciamento na geração de energia elétrica com fontes renováveis de energia. Atualmente, os sistemas de conversão de energia renováveis são os principais motivadores para o desenvolvimento de análise de séries temporais (Jin et al., 2020). Uma série temporal é importante para realizar previsões de dados futuros e com isso realizar planejamento do quanto de energia será possível despachar em um determinado período e assim fazer um gerenciamento mais eficiente do parque eólico ou fotovoltaico em questão (Dubey et al., 2021). Portanto, a análise de série temporal de dados de velocidade do vento e irradiação solar são bastante estudadas com objetivo de maximizar a conversão de energia.

Contudo, para prever dados futuros, não apenas o valor histórico da variável objetivo é suficiente para realizar uma análise confiável, também devem ser considerados outros fatores com influência implícita sobre a variável objetivo (Liang, Nguyen, Jin, 2018; Jin et al., 2020; Dubey et al., 2021). A velocidade do vento pode ser influenciada pela temperatura, irradiação solar, humidade e sua direção, além das condições topográficas. Du (2018) argumenta que quando são realizadas análises com várias variáveis que apresentam correlação entre si, a precisão na previsão das variáveis objetivos é melhorada devido a correlação intrínseca e as características históricas entre elas.

Diversos trabalhos que fazem análise de série temporal para previsão de dados futuros foram publicados nos últimos anos. Dubey et al., (2021) utilizam Média Móvel Integrada Autorregressiva (ARIMA), ARIMA sazonal (SARIMA) e Long Short-Term Memory (LSTM) para prever o consumo de energia em uma base de dados diários e os resultados obtidos mostram que 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. Zufferey et al. (2016) aplica Redes Neurais Artificiais (RNAs) para previsões precisas de carga de curto prazo em sistema fotovoltaicas (PV) e investiga 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 turbina eólica é importante que se tenha de forma antecipada informações de velocidade do vento de modo a permitir uma operação estável do sistema de energia. Yao, Huang e Jia (2018) aplicaram um modelo LSTM juntamente com a teoria dos Conjuntos Fuzzy-Rough (SFR) para previsão de velocidade do vento de 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 velocidade do vento conjuntamente com o modelo LightGBM. Apesar do fato de que o LSTM consegue 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. Dessa forma, é usual que LSTM seja combinado com outro modelo de previsão.

A previsão confiável e precisa da velocidade do vento é a base para a utilização mais eficiente 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 *Multi-Variable Long-short Term Memory* (MV-LSTM), ou seja, um modelo LSTM multivariado para previsão de velocidade do vento a curto prazo baseado em temperatura, pressão e humidade. A seleção das variáveis foi feita a partir do coeficiente da correlação de Person. O modelo MV-LSTM apresentou resultados superiores ao modelo ARMA e LSTM com variável única. Portanto, é notório que o modelo LSTM

tem sido bastante utilizado para previsão de velocidade do vento, no entanto, é necessário desenvolver modelos que o auxiliem para aumentar a acurácia da previsão de modo a ter alta confiabilidade. Dessa forma, esse 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 da correlação de Person é realizada e o modelo é treinado com dados histórico coletado no Cerrado brasileiro nativo no Distrito Federal. Com inserção dos vetores de velocidade máxima e mínima no modelo as características de curto prazo podem ser melhor definidas para o modelo.

## 2. MÉTODOS E DADOS

### 2.1 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 registradas por um anemômetro sônico a 8 m de altura com a técnica Eddy Covariance, com 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 com os componentes tridimensionais da velocidade do vento, temperatura e as concentrações de H<sub>2</sub>O e CO<sub>2</sub>.

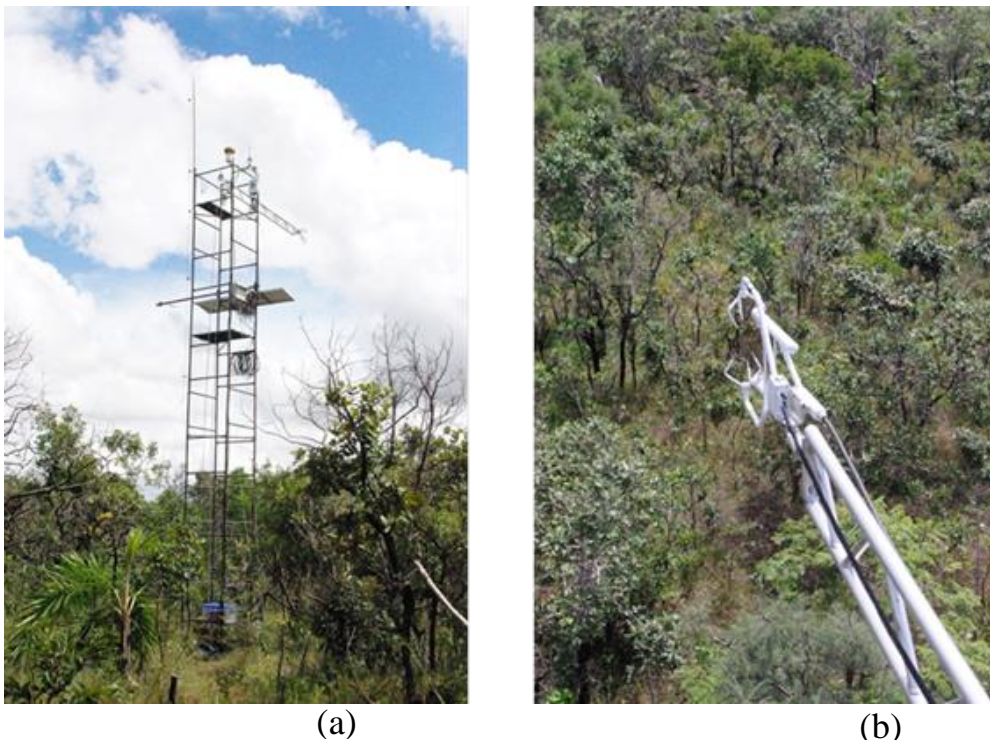


Figura 1 - Experimento Eddy Covariance. Torre de 8 m sobre área de Cerrado nativo (a); Detalhe do anemômetro sônico 3D (b).

Os dados foram coletados na Fazenda Água Limpa (FAL), que pertence à Universidade de Brasília, localizada no Distrito Federal nas coordenadas 15°57'13" S 47°54'58" W. A FAL encontra-se à 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 é instalada nas coordenadas já mencionadas conforme apresenta-se na Fig. 2.




Figura 2 – Localização da torre de coleta dos dados.

## 2.2 Descrição dos dados

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

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

	<b>Velocidade Média (m/s)</b>	<b>Velocidade Máxima (m/s)</b>	<b>Desvio Padrão</b>
<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

Neste estudo, os dados da série temporal para todos os elementos meteorológicos foram usados para prever a velocidade do vento de curto prazo com 6 hora de antecedência. As observações foram feitas de 10 em 10 minutos entre 1 de janeiro de 2015 e 31 de dezembro de 2015, no entanto os dados foram agrupados em médias horárias e 80% principais dos dados totais ( $292 \text{ dias} \times 24 \text{ h} = 7008$  amostras de dados) foram usadas para treinar o modelo, os últimos 20% dos dados totais ( $73 \text{ dias} \times 24 \text{ h} = 1752$  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 ausentes foi utilizado para reposição.

## 2.3 Long Short-Term Memory (LSTM)

Em 1997, Hochreiter et al. (1997) propôs o modelo de rede LSTM, que combina memória de curto e longo prazo por meio de controle de porta, de modo que o problema de desaparecimento ou explosão de gradiente em Redes Neurais Recorrentes fosse resolvido até certo ponto. A Fig. 3 mostra a estrutura básica de uma célula LSTM. A rede é composta por célula com uma porta de saída  $\Gamma_o$ , uma célula de memória  $\tilde{c}_t$ , uma porta de entrada  $\Gamma_i$  e uma porta de esquecimento  $\Gamma_f$ .  $W$  e  $U$  são a matriz de coeficiente de peso compartilhado dos neurônios,  $h_t$  é o estado oculto no tempo  $t$ ,  $x_t$  é a entrada da rede no tempo  $t$ , e  $\sigma$  e  $\tanh$  são a funções de ativação.

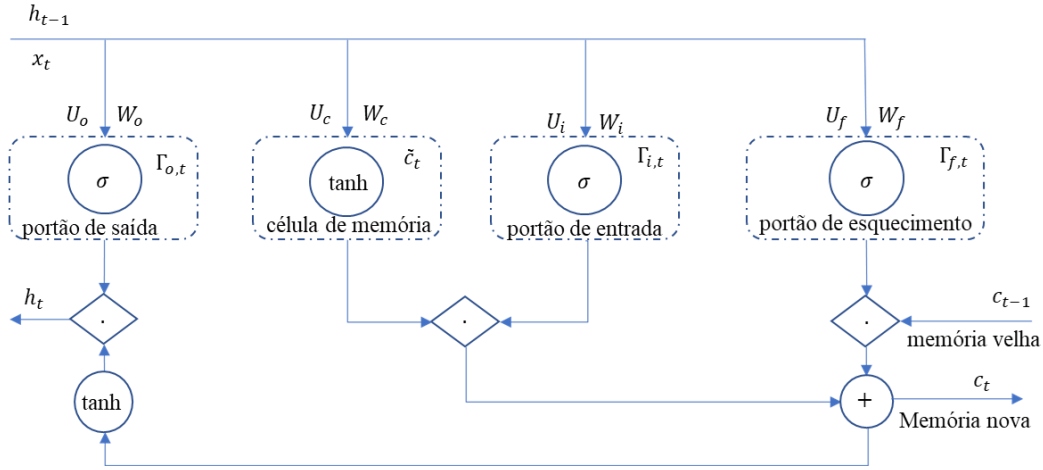


Figura 3 – Estrutura básica de uma célula da rede LSTM.

A rede LSTM funciona a partir do controle dos *gates*. O portão 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.

O portão 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 o portão de saída, no qual 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 do portão de saída são calculadas pelas Eq. (4) e Eq. (5)

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

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

#### 2.4 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 das previsões 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)

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

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

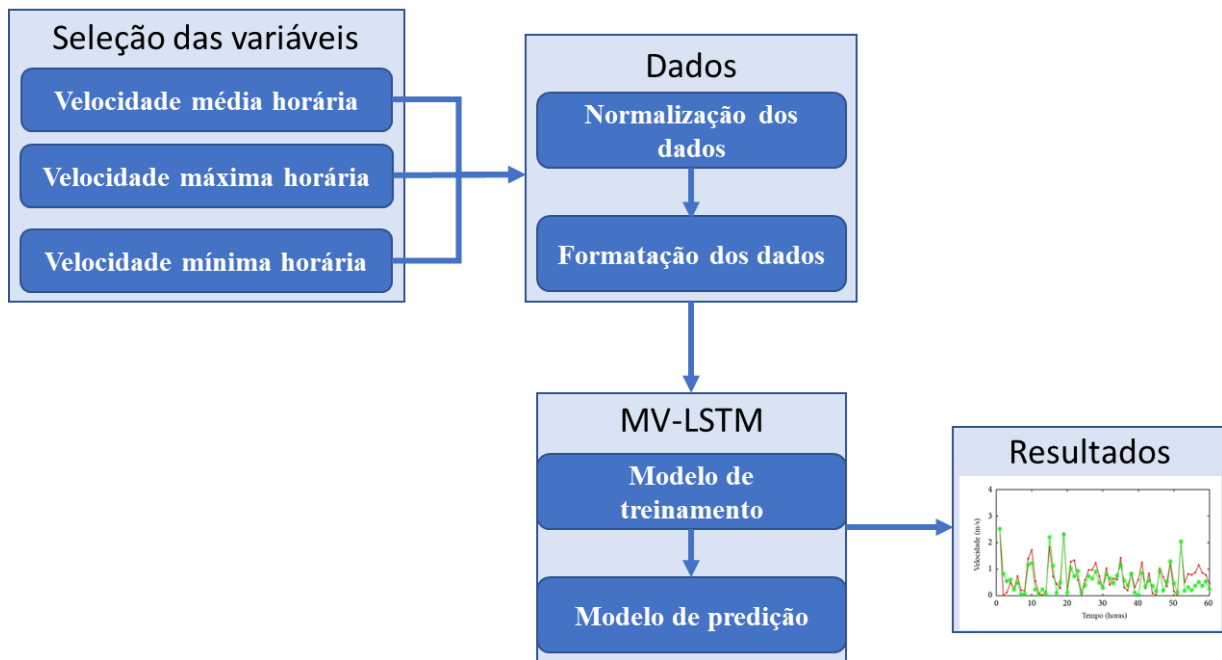


Figura 4 – Estrutura da rede LSTM multivariável proposta para previsão da velocidade do vento descrita em quatro etapas de desenvolvimento.

Para garantir que as variáveis de entrada tenham escalas e estrutura 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 a 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 utilizada a biblioteca Keras para Python. 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).

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

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

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.

Tabela 2 – Hiper parâmetros da rede MV-LSTM.

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

A última etapa do processo foi a previsão da velocidade do vento com o modelo da rede MV-LSTM treinado. O conjunto de dados de teste foi usado 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).

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

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

### 2.3 Métricas de avaliação

Para avaliar o desempenho do método MV-LSTM foram empregados 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:

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

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

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

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

em que,  $y_i$  é a observação da velocidade do vento no tempo  $i$  e  $yn'_i$  é a previsão da velocidade do vento no tempo  $i$ .

## 3. 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 são totalmente correlacionadas 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*.

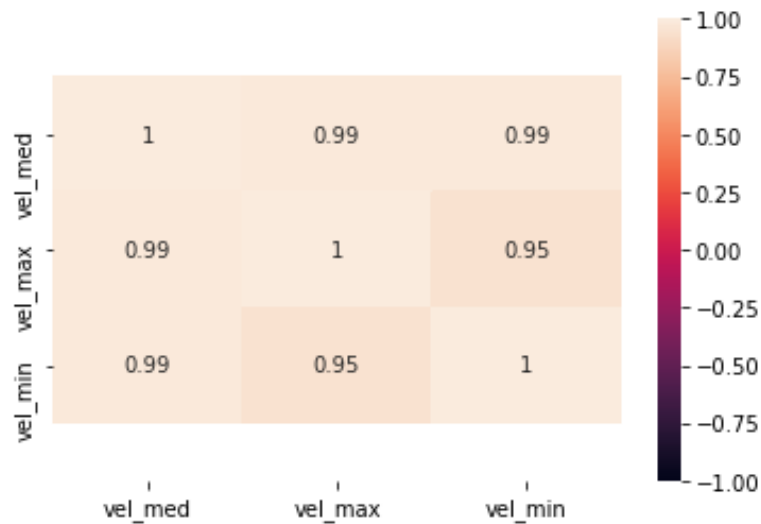


Figura 5 – Correlação de Pearson para os três vetores de velocidade.

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.

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

Métodos	MAE	RMSE	MSE	R <sup>2</sup>
LSTM	0.24	0.096	0.0094	0.54
MV-LSTM	<b>0.0394</b>	<b>0.061</b>	<b>0.0037</b>	<b>0.702</b>




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-se 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. A performance do modelo MV-LSTM foi 12.2% melhor que o modelo LSTM com variável única.

#### 4. 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 registrado com anemômetro sônico do Laboratório de Energia e Ambiente -UnB que realizou medições entre 01 de janeiro de 2015 e 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 esta sofre uma alteração brusca, como no caso de 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, de modo a obter melhor performance, 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 adicionar 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.

#### 4.3 Autorizações e reconhecimentos

Os autores autorizam a publicação do trabalho em favor da ABENS, assumindo toda a responsabilidade sobre o conteúdo dos mesmos.

#### 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.



## 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.

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

**Abstract.** Time series analysis is extremely important for control and management of electrical systems. In wind systems, there is a need to predict the wind speed with greater precision, which allows for an intelligent energy dispatch and managing risks that the high volatility of the wind can cause. This paper implements a multivariate Recurrent Neural Network model of short-term memory type (MV-LSTM) for hourly average, maximum and minimum speed data. A single variable LSTM network is also implemented to compare the results. The data used were collected by a sonic anemometer from January 1st to December 31st, 2015 in the native Brazilian cerrado at Fazenda Água Limpa – FAL located in the Federal District. The results show that maximum and minimum speed vectors improve wind speed prediction and that the MV-LSTM model reduces the forecast delay when there is a sudden change in wind speed, which is a problem cited by Xie et al. (2021) his work. The model can be optimized by adding more layers and combining with other machine learning models.

**Key words:** MV-LSTM, Forecast, Wind Energy