

UMA ABORDAGEM PARA PREVISÃO DE MÉDIO PRAZO DA VELOCIDADE DO VENTO UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA

Anusio Menezes Correia¹, Davidson Martins Moreira², Erick Giovanni Sperandio Nascimento³

¹ Vínculo institucional Bolsista; Implantação de infra estrutura de pesquisa em simulação e modelagem computacional no estado da bahia utilizando processamento de alto desempenho. – FAPESB; anusio@hotmail.com

² Doutorado; Centro Universitário SENAI CIMATEC; Salvador-BA; davidson.moreira@fieb.org.br

³ Doutorado; Centro Universitário SENAI CIMATEC; Salvador-BA; erick.sperandio@fieb.org.br

RESUMO

Um dos principais problemas enfrentados pela sociedade moderna é a aquisição de energia sustentável que não agrida o meio ambiente. Uma das possibilidades advém da energia eólica. Contudo, o vento é uma variável climática difícil de prever e os atuais modelos computacionais demandam muito tempo de cômputo.

Assim, um modelo computacional viável que consiga com uma boa precisão prever a velocidade do vento pode auxiliar na geração da energia eólica. Desta forma, este trabalho visa demonstrar a viabilidade de utilizar as tecnologias atuais de aprendizado de máquina (*Machine Learning*, ML) para realizar as previsões das velocidades do vento.

Para tal foi utilizada uma MLP (*Multi Layer Perceptron*), que com a técnica de retroalimentação de dados, consegue prever 193 horas à frente (mais de uma semana) com 1,43 de erro absoluto médio (MAE) e 3,45 de erro quadrático médio (MSE).

PALAVRAS-CHAVE: *keras*, *tensorflow*, regressão, velocidade do vento.

1. INTRODUÇÃO

A força do vento depende do clima, sendo uma variável intermitente, esta característica torna difícil o uso do vento como energia alternativa, já que não se sabe quando contar com esta força para racionar ou ativar a geração temporária de uma outra forma de energia. Assim, uma previsão acurada da força do vento é considerada uma contribuição muito grande para uma integração de geração de energia eólica de forma confiável¹.

Contudo os tradicionais métodos de modelos computacionais capazes de fazer estas previsões são computacionalmente custosos, difíceis e relativamente caros (no sentido do equipamento e infraestrutura necessários para tal) principalmente devido à complexidade física envolvida. Uma das possibilidades é o uso de Redes Neurais Artificiais (RNA), que treinadas em cima de uma confiável base de dados, seja capaz de inferir a velocidade do vento futura utilizando dados atuais.

Atualmente, existem muitas bibliotecas que auxiliam o uso de algoritmos de ML, as bibliotecas *tensorflow* e *keras*, que são bibliotecas gratuitas e de código aberto para *Deep Learning* ou aprendizado profundo de máquina. Muitas pesquisas vêm demonstrando o uso de *deep learning* como uma poderosa ferramenta para realizar previsões, pela sua alta capacidade de reconhecimento de padrões^{2,3}.

Desta forma, o objetivo deste trabalho é demonstrar que é possível realizar inferências futuras sobre a velocidade do vento, utilizando séries temporais e uma RNA criada com as bibliotecas *tensorflow* e *keras*, com o objetivo de realizar previsões em todos os parâmetros, realizando inferências sucessivas sobre o conjunto de variáveis, estendendo a previsão para dias à frente, mantendo a confiabilidade da previsão.

2. METODOLOGIA


Para realizar o estudo, foi utilizada biblioteca Python versão 3.5, juntamente com as bibliotecas *pandas*, *numpy*, *matplotlib*, *Keras* e *Tensorflow*. Os dados atmosféricos foram coletados com os devidos instrumentos, são os mesmos dados utilizados no trabalho², sendo estes dados coletados de uma torre anemométrica em Mucuri, BA, constituindo-se a média horária medida das variáveis velocidade do vento, direção do vento, temperatura, umidade e pressão atmosférica. Por se tratarem da medição do estado do fluido atmosférico (ar) em um dado momento, estas variáveis se correlacionam e por isto foram utilizadas neste estudo.

A rede MLP (*Multi Layer Perceptron*) utilizada tem camadas escondidas com função de ativação tangente hiperbólica e camada de saída com função linear, em pesquisas relacionadas como em², se demonstrou uma excelente ferramenta na previsão da velocidade do vento com uma hora à frente. Contudo, a

MLP apresentada neste trabalho é utilizada para prever todos os parâmetros não temporais da série temporal e para realizar este feito conta com otimizador “*RMSprop*”, função de perda (*loss function* no inglês) erro percentual absoluto médio (MAPE), *batch size* (que é o tamanho do lote submetido ao processo de propagação reversa) de 32, diferentemente da versão do trabalho ². Além disto a rede foi treinada com 1000 épocas, depois reorientada com 500 e 250 épocas alterando a taxa de aprendizagem (*learning rate*) de “0,01”, “0,001” e “0,0001” no treino e nas reorientações respectivamente.

Após treinar o modelo para previsão de uma hora à frente, foi então seguido o padrão descrito na Figura 1, retro-alimentando a rede com a saída da hora anterior para prever a próxima em uma sequência definida de vezes, tendo a finalidade de prever *n* horas a frente utilizando apenas as medições atuais dos instrumentos, conforme abordagem apresentada em ⁴ para o mesmo tipo de problema.


Figura 1 - Retroalimentação dos dados para a previsão de horas à frente. Adaptado de ⁴.



3. RESULTADOS E DISCUSSÃO

A rede teve sucesso em treinar e prever os dados de uma hora à frente para dados nunca antes vistos, como se observa na Figura 2, que representa os dados de testes comparados com a previsão resultante da MLP para uma hora à frente, isto para todos os parâmetros não temporais da série.

Figura 2 - Resultado da previsão da rede, no conjunto de teste, para velocidade do vento, direção do vento, temperatura, umidade e pressão atmosférica.



Contudo ao se analisar as métricas estatísticas de comparação de dados, na Tabela 1, alguns parâmetros obtiveram MSE alto, porém são uma boa previsão, como observado na Figura 2, isto ocorre devido a métrica estatística tirar a média dos dados, e alguns dados não foram preditos corretamente diminuindo a média geral.

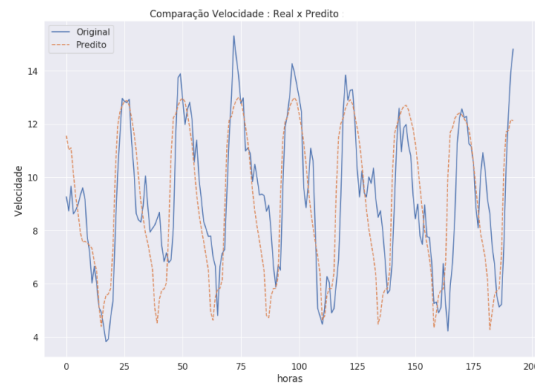
Com este modelo treinado, segundo o padrão descrito na Figura 1, ou seja retroalimentando os dados na rede, a velocidade do vento ficou com o padrão da Figura 3, e obteve as métricas MAE, MAPE, MSE, coeficiente de Pearson R, coeficiente de correlação R² e Fator de 2 (Fac2) com valores {1,43006 17,7993

3,45305 0,774945 0,600539 0,989637} respectivamente, demonstrando que o modelo aprendeu o padrão da velocidade do vento para este caso.

Tabela 1 - Métricas estatísticas do resultado da rede para o conjunto de teste.

Atributo	MAE	MAPE	MSE	Pearson	R ²	Fac2
Velocidade	0,673414	9,70248	0,923857	0,937968	0,879785	0,998178
Direção	8,09487	16,8037	297,608	0,870829	0,758343	0,934426
Temperatura	0,35464	1,47164	0,255554	0,952965	0,908142	1
Umidade	1,80822	2,23579	7,05027	0,951079	0,904552	1
Pressão	3,22682	0,319454	30,0401	0,791672	0,626744	1

Figura 3 - Predição para 193 horas à frente com retroalimentação dos dados.



4. CONSIDERAÇÕES FINAIS

Redes Neurais Artificiais têm sido muito utilizadas atualmente em pesquisas relacionadas a previsões devido a sua capacidade de relacionar dados de forma não linear. A rede neural obteve resultados significativos, conseguindo realizar uma predição de dias à frente com uma boa acurácia, utilizando a retroalimentação dos dados na própria rede. Desta forma, as MLPs e algoritmos de inteligência artificial em geral tem um grande potencial na predição de padrões em séries temporais.

Agradecimentos

Este trabalho contou com o apoio da FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) e foi desenvolvido no Centro de Supercomputação para Inovação Industrial do SENAI CIMATEC.

5. REFERÊNCIAS

- XIAOCHEN, Wang. PENG, Guo. XIAOBIN, Huang. **A Review of Wind Power Forecasting Models**. Energy Procedia, Volume 12, Pages 770-778, ISSN 1876-6102, 2011.
- Zucatelli, Pedro.J. Nascimento, Erick.G.S. Aylas, Georgynio.Y.R. Souza, Noéle.B.P. Kitagawa, Yasmin.K.L. Moreira, Davidson.M. Santos, Alex.A.B. **PREVISÃO DA VELOCIDADE DO VENTO A CURTO PRAZO USANDO REDES NEURAS ARTIFICIAIS EM MUCURI, BAHIA**. 10.26678/ABCM.CONEM2018.CON18-0393, 2018.
- ELANGASINGHE, Madhavi. NARESH, Singhal. KIN N, Dirks. SALMOND Jennifer A., **Development of an ANN-based air pollution forecasting system with explicit knowledge through sensitivity analysis**, Atmospheric Pollution Research, Volume 5, Issue 4, 2014.
- Zucatelli, Pedro.J. Nascimento, Erick.G.S. Aylas, Georgynio.Y.R. Souza, Noéle.B.P. Kitagawa, Yasmin.K.L. Santos, Alex.A.B. Arce, Alejandro.M.G. Moreira, Davidson.M. **Short-term wind speed forecasting in Uruguay using computational intelligence**, Salvador: Heliyon, 2019