



**Estratégias para a Previsão de Múltiplos Horizontes Usando
Redes Neurais Artificiais: uma Aplicação em Séries
Temporais de Potência Eólica**

PROPOSTA DE TRABALHO DE GRADUAÇÃO

Aluno: João Vitor da Silva Gomes (jvsg@cin.ufpe.br)

Orientador: Tsang Ing Ren (tir@cin.ufpe.br)

Área: Aprendizagem de Máquina

Recife, 14 de junho de 2021

Resumo

A capacidade instalada de usinas de energia eólica vem aumentando ao longo dos anos e muito disso se deve ao fato dos ventos serem um recurso inesgotável, tornando esta modalidade uma fonte de energia limpa. Entretanto as irregularidades acerca da disponibilidade dos ventos geram oscilações indesejáveis. Sendo assim, modelos de previsão exercem papel fundamental para a tomada de decisões. O objetivo deste trabalho é estabelecer uma comparação entre estratégias para a previsão da potência gerada em múltiplos horizontes, desde 30 minutos até 6 horas a frente. Para isso será feito o uso de redes neurais artificiais Multilayer Perceptron e Long-Short Term Memory em conjunto com quatro possíveis abordagens de previsão múltipla, sendo três de saída única: direta, recursiva ou híbrida; ou uma última de saídas múltiplas.

Introdução

O aumento significativo na instalação de usinas de energia eólica ao redor do mundo deve-se principalmente às suas vantagens ambientais. Existem diversos argumentos a favor do uso dos ventos, como: a renovabilidade, a perenidade e a grande disponibilidade. Entretanto, sua natureza intermitente faz com que a potência de saída das centrais eólicas flutue constantemente. Um crescimento ou decréscimo abrupto na potência de saída pode gerar instabilidades na rede elétrica. Dito isto, faz-se necessária a implementação de um sistema de previsão para que seja possível tomar medidas preventivas, estabelecer cronogramas de produção de energia, além de estar um passo à frente na comercialização de eletricidade [1].

É possível resumir este problema a uma modelagem de séries temporais seguida de uma previsão, conhecida como regressão. Existem diversos modelos de regressão bem estabelecidos na área da estatística que tratam de realizar esse tipo de modelagem, indo desde aqueles lineares como os modelos Autoregressive (AR) e Autoregressive Integrated Moving Average (ARIMA), até os não lineares [2]. Ao longo das últimas décadas, com o desenvolvimento glorioso da área de aprendizagem de máquina, foram criados algoritmos tais quais árvores de regressão e Support Vector Regression que também atacam, com suas particularidades, problemas de regressão. Entretanto, neste trabalho destacaremos as técnicas mais recentes de redes neurais que pertencem ao domínio da aprendizagem profunda, são elas as Multilayer Perceptron (MLP) [3] e Long-Short Term Memory (LSTM) [2].

Por um lado, modelos de redes neurais muitas vezes dispõem de uma grande quantidade de hiper parâmetros que precisam ser ajustados de forma empírica, levando a um elevado custo computacional. Por outro lado, esta flexibilidade permite que sejam construídos modelos que melhor respondam ao problema em questão. Por exemplo em previsão de séries temporais, duas das decisões críticas durante a criação dos modelos é quantas e quais serão as variáveis de entrada e de saída.

Considerando situações onde deseja-se fazer previsões para múltiplos horizontes a frente, há ainda a opção de utilizar a previsão de horizontes recentes para prever horizontes mais distantes. Dentre as várias estratégias, pode-se citar: a direta, que se baseia na criação de um modelo específico para prever cada horizonte, usando somente amostras observacionais; a recursiva, que cria um único modelo responsável por prever somente o primeiro horizonte, e utiliza seus próprios resultados como entrada para prever os mais distantes; a híbrida, que utiliza um modelo para prever cada horizonte, mas também se beneficia do artifício recursivo; e a de múltiplas saídas, onde uma única rede neural prevê todos os n horizontes de interesse através de uma camada de saída com n neurônios [4,5,6].

Objetivos

O objetivo geral deste trabalho é prover uma comparação entre as diferentes estratégias para previsão de múltiplos horizontes utilizando redes neurais Multilayer Perceptron e Long-Short Term Memory no tocante a séries temporais de potência eólica.

Para atingir o objetivo principal será necessário atender aos seguintes pontos:

- Pré-processar as séries temporais para que possam ser usadas como entrada para os modelos;
- Ajustar os hiper parâmetros das redes neurais para encontrar a configuração com melhor desempenho.

Metodologia

Dentre as ferramentas necessárias para a implementação deste trabalho estão as bibliotecas científicas disponíveis na linguagem Python, como:

- Numpy: para manipulação numérica e de arrays;
- Pandas: para manipulação de dados estruturados;
- Matplotlib, Seaborn: para visualização de dados;
- Scikit-learn, tensorflow, keras: para construção de modelos de redes neurais.

As principais etapas da metodologia proposta estão presentes na figura 1. Os dados brutos de potência obtidos a partir de usinas eólicas australianas [7] passarão por uma etapa de pré-processamento onde as amplitudes serão normalizadas e amostras não valoradas serão tratadas, de forma a melhor servir aos modelos. Consecutivamente, a série completa será dividida em porções para treinamento e teste.

No próximo bloco os modelos MLP e LSTM serão construídos em conjunto com cada uma das quatro estratégias para previsão de múltiplos horizontes. Aqui as redes neurais serão treinadas sobre o conjunto de treinamento, onde serão escolhidos os hiperparâmetros que levem às melhores performances.

No pós-processamento as normalizações de amplitude serão revertidas para a escala original. Finalmente, todas as combinações entre redes neurais (MLP, LSTM) e estratégias de previsão múltipla (direta, recursiva, híbrida e de múltiplas saídas) serão avaliadas por meio de métricas de erro e de semelhança em relação ao conjunto de teste. Dentre as métricas mais comuns pode-se citar: mean square error (MSE) e mean absolute error (MAE). Além de outras como root mean square difference (RMSD), coeficiente de correlação de Pearson e a razão entre desvios padrão para representações através de diagramas de Taylor [8].



Figura 1: Diagrama de blocos da metodologia

Referências

- [1] Foley, A. M., Leahy, P. G., Marvuglia, A., McKeogh, E. J. “Current Methods and Advances in Forecasting of Wind Power Generation” *Renewable Energy*, vol 37, pp. 1-8, 2012.
- [2] Siami-Namini, S., Tavakoli, N., Namin, A. S. “A Comparison of ARIMA and LSTM in Forecasting Time Series” *17th IEEE International Conference on Machine Learning and Applications*, pp. 1394-1401, 2018.
- [3] Li, S., Wunsch, D. C., O’Hair, E. A., Giesselmann, M. G. “Using Neural Networks to Estimate Wind Turbine Power Generation” *IEEE Transactions on Energy Conversion*, vol 16, pp. 276-282, 2001.
- [4] Taieb, S. B., Bontempi, G., Atiya, A. F., Sorjanna, A. “A Review and Comparison of Strategies for Multi-step Ahead Time Series Forecasting Based on the NN5 Forecast Competition.” *Expert Systems with Applications*, vol 39, pp. 7067-7083, 2012.
- [5] Taieb, S. B., Sorjanna, A., Bontempi, G. “Multiple-output Modeling for Multi-step-ahead Time Series Forecasting.” *Neurocomputing* vol 73, pp. 1950-1957, 2010.
- [6] Borchani, H., Varando, G., Bielza, C., Larranaga, P. “A Survey on Multi-output Regression.” *WIREs Data Mining Knowl Discov* vol 5, pp. 216-233, 2015.
- [7] AEMO Energy Generation Data. Disponível em: <https://anero.id/energy/data>
- [8] Taylor, K. E. “Summarizing Multiple Aspects of Model Performance in a Single Diagram” *Journal of Geophysical Research*, vol 106, pp. 7183-7192, 2001.

Possíveis Avaliadores

Prof. Paulo Salgado Gomes de Mattos Neto

Prof. George Darmiton da Cunha Cavalcanti

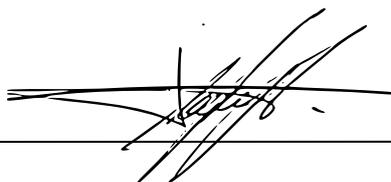
Assinaturas

Recife, 14 de junho de 2021

João Vitor da Silva Gomes

João Vitor da Silva Gomes

(Aluno)



Tsang Ing Ren

(Orientador)