

PREVISÃO DE RADIAÇÃO SOLAR A CURTO PRAZO UTILIZANDO MODELOS DE MACHINE LEARNING

Camila Klippel Krohling^{1*}, Adriano Matos de Oliveira², Gabrielli Harumi Yamashita³, Jeffson Veríssimo de Oliveira², Jailson dos Santos Silva⁴

¹Universidade de São Paulo (USP)

²Universidade Federal de Santa Catarina (UFSC)

³Universidade Federal do Ceará (UFC)

⁴Universidade do Estado de Santa Catarina (UDESC)

1. Introdução

A crise da energia fóssil e o efeito estufa, ocasionado pelas emissões de carbono, tornaram-se dois dos mais sérios desafios mundiais, gerando uma necessidade imprescindível de desenvolver e aperfeiçoar métodos e fontes alternativas para a produção de energia limpa e sustentável [1-3]. Dentre essas alternativas, a energia solar é uma das mais promissoras para substituir os combustíveis fósseis [4]. Todavia, faz-se necessário prever a radiação dessa fonte geradora no curto prazo, a fim de identificar a necessidade de fontes alternativas de energia para suprir o *gap* existente em períodos sem luz solar, garantindo um planejamento adequado para o abastecimento energético de forma eficiente e segura [5-6]. Portanto, o objetivo deste trabalho é comparar o desempenho de modelos de *Machine Learning* (ML) na previsão de energia solar em tempo real e a curto prazo, utilizando variáveis meteorológicas como parâmetros de entrada.

2. Experimento

A Figura 1 apresenta as etapas adotadas neste estudo.

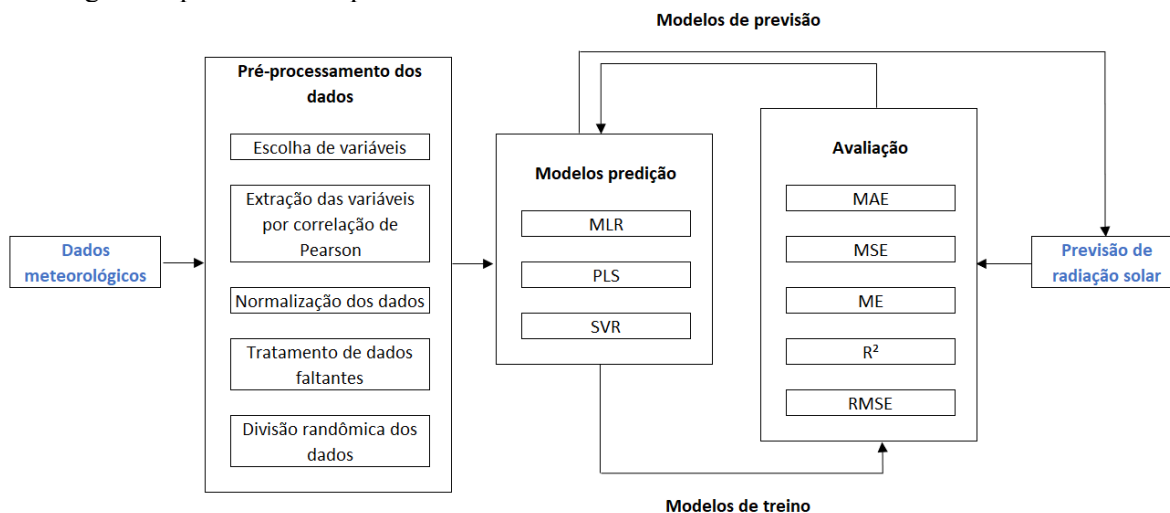


Fig. 1. Etapas da pesquisa

Os dados meteorológicos foram obtidos do Instituto Nacional de Pesquisas Espaciais (INPE) no período de 2019 a 2022, com coleta a cada 3 horas nas cidades de Ouricuri-PE, Encruzilhada do Sul-RS e Jaboticabal-SP. As variáveis climáticas utilizadas incluem pluviometria, bateria, radiação solar acumulada, temperatura do ar, temperatura máxima, temperatura mínima, umidade relativa, velocidade do vento e correlação de Pearson da presença de sol.

*Autor correspondente: adrianomatosdeoliveira90@gmail.com

Após a seleção das variáveis, processo no qual se utilizou a correlação de Pearson para excluir aquelas pouco correlacionadas, foi conduzido um tratamento dos dados, que foram normalizados e divididos em conjuntos de treino (75%) e teste (25%).

Para a análise preditiva, foram operacionalizados três modelos de ML, a saber: *Support Vector Regression* (SVR), *Partial Least Squares* (PLS) e o *Multiple Linear Regression* (MLR). Ao final, seus resultados foram avaliados por meio das principais métricas de erro (*Mean Error* – ME; *Mean Absolute Error* – MAE; *Mean Squared Error* – MSE; *Root Mean Squared Error* - RMSE) e do coeficiente de determinação (R^2). Os dados foram rodados no *software Matlab*®.

3. Resultados e Discussão

No que tange aos resultados, estes indicam desempenho semelhante entre os modelos, com leve vantagem para os métodos lineares (PLS e MLR) em todas as localidades analisadas. Em Encruzilhada do Sul, PLS/MLR apresentaram melhor ajuste ($R^2 = 0,5525$) e menores erros (RMSE = 2,0503) em comparação ao SVR, sugerindo maior capacidade explicativa. Em Jaboticabal, observou-se o melhor desempenho global entre as regiões, com os maiores valores de R^2 (0,7574) e menores erros, novamente favorecendo PLS/MLR. Já em Ouricuri, embora os erros sejam um pouco mais elevados, o padrão se mantém, com PLS/MLR superando ligeiramente o SVR em termos de ajuste ($R^2 = 0,6705$) e RMSE. Assim, os resultados sugerem que modelos lineares foram mais consistentes e robustos para os dados analisados, enquanto o SVR apresentou desempenho inferior ou equivalente, sem ganhos expressivos de precisão.

Além disso, pode-se concluir que a utilização de modelos de aprendizado de máquina para a previsão de energia solar a curto prazo apresenta-se como uma solução viável e promissora para garantir um planejamento adequado do abastecimento de energia e a eficiência dos sistemas fotovoltaicos conectados à rede.

4. Referências

- [1] Gong, X., Zheng, S., Zhao, X., and Vomiero, A. Engineering high-emissive silicon-doped carbon nanodots towards efficient large-area luminescent solar concentrators. *Nano Energy*, 101, 107617, (2022).
- [2] Ren, Z., Wu, L., Pang, Y., Zhang, W., and Yang, R. Strategies for effectively harvesting wind energy based on triboelectric nanogenerators. *Nano Energy*, 100, 107522, (2022).
- [3] Wan, C., Zhao, J., Song, Y., Xu, Z., Lin, J., and Hu, Z. Photovoltaic and solar power forecasting for smart grid energy management. *CSEE Journal of Power and Energy Systems*, 1(4), 38–46, (2016).
- [4] Sen, S., and Ganguly, S. Opportunities, barriers and issues with renewable energy development – A discussion. *Renewable and Sustainable Energy Reviews*, 69, 1170–1181, (2017).
- [5] De Giorgi, M. G., Congedo, P. M., and Malvoni, M. Photovoltaic power forecasting using statistical methods: Impact of weather data. *IET Science, Measurement and Technology*, 8(3), 90–97, (2014).
- [6] Jebli, I., Belouadha, F. Z., Kabbaj, M. I., and Tilioua, A. Prediction of solar energy guided by pearson correlation using machine learning. *Energy*, 224, 120109, (2021).