

Análise preditiva do preço e da geração de energia solar fotovoltaica no mercado de energia elétrica

Leonardo Fini¹
Samantha Vieira Lanzelotti²
Marilaine Colnago³
Wallace Casaca⁴

Depto. de Engenharia de Energia, Universidade Estadual Paulista (UNESP), Campus de Rosana

Atualmente, tem-se discutido a relação do crescimento da demanda por energia com o aumento do consumo energético em escala mundial. Nesse contexto, há o crescimento das fontes de energias alternativas, as quais têm possibilitado minimizar parte dos custos da produção elétrica, além dos impactos ambientais provenientes de fontes não renováveis. Sendo assim, a predição da energia gerada, bem como do preço que é comercializada, tem se tornado um fator crucial, uma vez que a melhor escolha de energia contratada e preço, trará benefícios em diversos setores [1]. Dessa forma, algoritmos de Machine Learning para prever a carga elétrica a ser gerada e o preço da energia, estão sendo cada vez mais empregados nesse âmbito, já que viabilizam a exploração e a visualização dos dados com o intuito de produzir modelos preditivos mais assertivos e eficientes.

Para a presente pesquisa, fez-se uso da plataforma de programação Anaconda Navigator, a qual contém a interface gráfica Spyder, que permite a utilização da linguagem em Python. Em relação as bases de dados utilizadas, tem-se os dados climáticos do Instituto Nacional de Meteorologia (INMET) e de geração solar fotovoltaica do Operador Nacional do Sistema Elétrico (ONS), ambos no período de 17/12/2017 à 31/10/2020, os dados mensais do Índice Nacional de Preços ao Consumidor Amplo (IPCA) do IBGE no período de 01/1995 à 12/2020, e os dados horários do Preço de Liquidação das Diferenças (PLD) da Câmara de Comercialização de Energia Elétrica (CCEE) no período de 01/01/2019 à 31/12/2020.

No entanto, antes de aplicarmos os modelos preditivos, realizou-se a “limpeza” dos dados, que consistiu no tratamento de valores faltantes ou inconsistentes. Além disso, dividiu-se as bases de dados em 85% de sua totalidade para o treinamento dos algoritmos, com o objetivo de alcançar a melhor acurácia, e 15% para teste, o qual corresponde a validação dos modelos escolhidos.

Já no que diz respeito dos modelos preditivos, foram utilizados o Random Forest (RF), a Rede Neural Artificial (Multilayer Perceptron, MLP) e o Support Vector Regressor (SVR), empregando como métrica de validação o Erro Percentual Médio (MAPE), que pode ser calculada como:

$$MAPE = \frac{1}{n} \sum_{i=0}^n \frac{y_i - \hat{y}_i}{y_i} \quad (1)$$

onde n são as amostras, y_i os valores reais e \hat{y}_i os valores previstos (para mais detalhes acerca desta métrica, vide [2]).

Os dados do INMET e do ONS foram utilizados para a predição da geração da carga elétrica, realizada em 30 subintervalos de tempo (vide Figura 1). Nesse caso, obteve-se MAPE de 9.51%, 12.50% e 10.81% para os modelos preditivos RF, SVR e Rede Neural MLP, respectivamente.

¹l.fini@unesp.br

²samantha.lanzelotti@unesp.br

³marilaine.colnago@unesp.br

⁴wallace.casaca@unesp.br

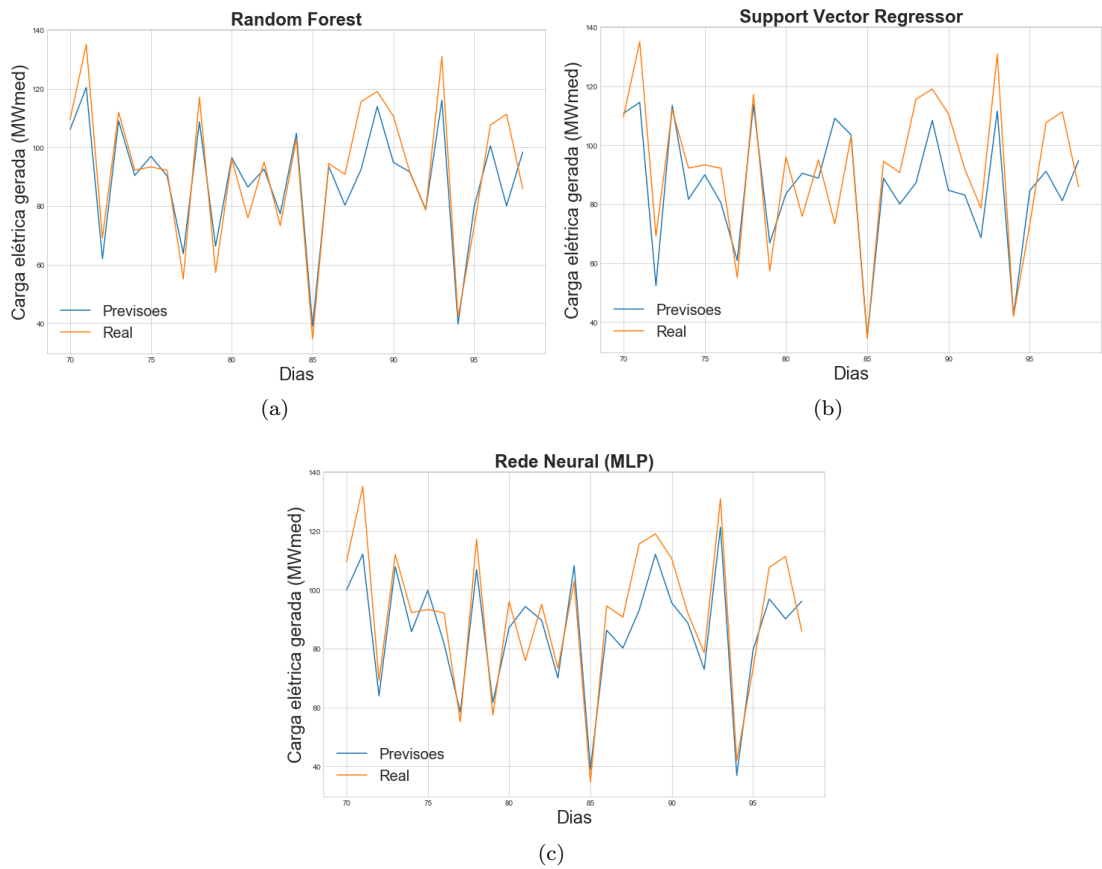


Figura 1: Gráficos da predição da carga elétrica, em MW médio, com os modelos preditivos.

Como exposto acima, o modelo Random Forest apresentou uma melhor taxa de assertividade em relação a predição da carga elétrica, apresentando o menor MAPE. Espera-se que para as futuras predições (preço de energia elétrica) os resultados obtidos também sejam satisfatórios, ajustando os hiperparâmetros de cada modelo preditivo, assim como foi realizado na predição da carga elétrica.

Agradecimentos

Os autores agradecem à PIBIT/CNPq pelo suporte à pesquisa.

Referências

- [1] Barbosa, A. Inteligência Computacional Aplicada na Previsão de Máxima Potência em Concentradores Fotovoltaicos. Dissertação de Mestrado, Universidade Federal de São João Del-Rei, 2017.
- [2] Leme, J. V. et al. Towards Assessing the Electricity Demand in Brazil: Data-Driven Analysis and Ensemble Learning Models. *Energies*, 13(6), 2020. DOI: 10.3390/en13061407.