

Análise preditiva na geração distribuída de energia fotovoltaica: aplicações e algoritmos inteligentes

Lucas G. Ramos ¹

UNESP, Rosana, SP

Marilaine Colnago ²

UNESP, Rosana, SP

Wallace Casaca ³

UNESP, Rosana, SP

Os impactos ambientais ocasionados pelo crescimento desenfreado do setor industrial e da economia nos últimos anos estão cada vez mais presentes em nosso cotidiano. Parte desses impactos deve-se ao fato de que toda a economia mundial esta alicerçada no uso de combustíveis fósseis, e tentar frear esse crescimento em contraste ao modelo econômico atual tem sido uma saída inviável na prática [1, 2]. Sendo assim, uma alternativa tem sido a utilização de fontes renováveis de energia como forma de mitigar os efeitos provenientes do uso de fontes não renováveis. Desta forma, a presente pesquisa objetiva estudar o impacto ocasionado pela energia exportada à rede elétrica gerada por sistemas fotovoltaicos distribuídos, que são operados por agentes residenciais e comerciais. Para cumprir com esse propósito, foram empregados modelos de Aprendizado de Máquina (AM) e ferramentas de Análise Exploratória de Dados (AED). Assim, a presente pesquisa é importante, sobretudo, para compreender o modelo de crescimento da exportação da energia gerada por sistemas fotovoltaicos conectados à rede elétrica, isto é, a chamada *geração distribuída*, o que tem sido um tema de ampla discussão na indústria de energia [3].

A fim de viabilizar pesquisa, foram empregados dados da região de Queensland, Austrália, uma vez que tal país tem promovido importantes avanços no campo da energia fotovoltaica, além de contar com um vasto repositório de dados, incluindo a plataforma *PV-Output* ⁴, utilizada no trabalho.

A predição da energia exportada foi obtida a partir de três modelos de AM: Florestas Randômicas (RF, do inglês *Random Forest*), Máquinas de Vetores de Suporte (SVM, do inglês *Support Vector Machines*), e Aumento do Gradiente (GTB, do inglês *Gradient Tree Boosting*). Os modelos foram treinados e ajustados seguindo o mesmo procedimento metodológico tal como descrito em [4], entretanto, com os dados de geração distribuída da base *PV-Output* de energia fotovoltaica. Inicialmente, a base de dados *PV-Output* possuía 8 variáveis (*features*) e, após a inserção de variáveis estatísticas como média, mediana, além de variáveis artificiais criadas a partir das originais, a base analisada passou a ter 19. Na predição, foi adotado uma proporção de 3/1 (treino/teste) considerando três anos para treino (01/07/2015 à 31/06/2018), e um ano para teste (01/07/2018 à 31/06/2019).

A Figura 1 evidencia a performance dos preditores construídos em um dos conjuntos de dados (*datasets*) das bases analisadas. É possível notar que as três curvas apresentam aderência aos

¹gomes.ramos@unesp.br

²marilainecolnago@gmail.com

³wallace.casaca@unesp.br

⁴Disponível em: <https://pvoutput.org/>. Acesso em: 14 mar 2020.

valores reais, cujos valores para o MAPE (*Mean Absolute Percentage Error*) foram de 1.4% (*RF*), 1.6% (*GTB*), 0.9% (*SVM*).

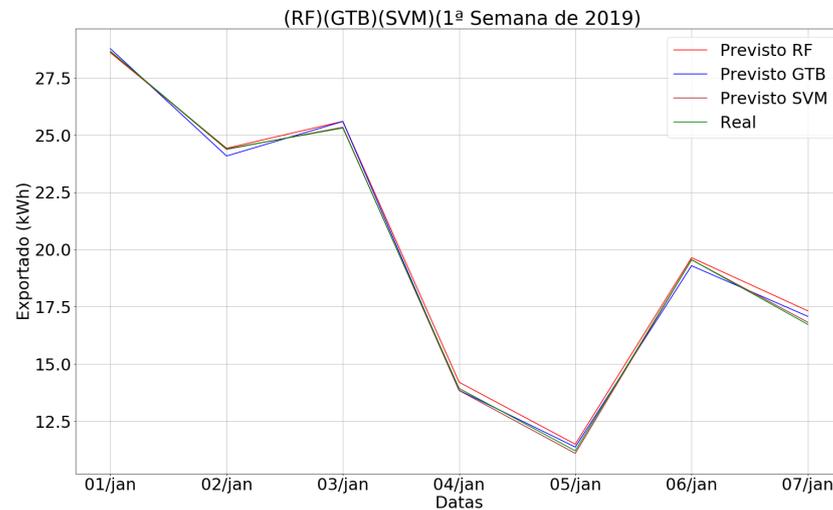


Figura 1: Curvas de predição obtidas pelos métodos estudados \times dados reais da energia exportada.

A pesquisa de IC conduzida demonstrou que os preditores construídos foram capazes de estimar a energia exportada de forma bastante satisfatória, evidenciando dessa forma, que modelos de AM podem ajudar na tomada de decisões de agentes do setor energético, sejam eles agências governamentais, consumidores locais, ou concessionárias de distribuição de eletricidade.

Agradecimentos

Agradecemos à FAPESP pelo fomento à pesquisa (Nº Processo: 2019/18857-1)

Referências

- [1] Allan, G. et al. The economics of distributed energy generation: a literature review, *Renewable and Sustainable Energy Reviews*, 42:543–556, 2015. DOI: 10.1016/j.rser.2014.07.064.
- [2] De Paula, M., Colnago, M. e Casaca, W. Redes neurais MLP e NARX aplicadas na previsão da velocidade do vento em parques eólicos do estado da Bahia, *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, 7:010424-1–7, 2020. DOI: 10.5540/03.2020.007.01.0424.
- [3] Ertugrul, O. F. Forecasting electricity load by a novel recurrent extreme learning machines approach, *International Journal of Electrical Power and Energy Systems*, 78:429–435, 2016. DOI: 10.1016/j.ijepes.2015.12.006.
- [4] Leme, J., Casaca, W., Colnago, M. and Dias, M. A. Towards assessing the electricity demand in Brazil: data-driven analysis and ensemble learning models, *Energies*, 13:1-21, 2020. DOI: 10.3390/en13061407.