

AVANÇOS NA MODELAGEM PREDITIVA PARA GERENCIAMENTO DE ENERGIA USANDO MACHINE LEARNING

Leonardo da Silva
Marcelo Borlim Coro
Eliomar Gotardi Pessoa



10.56238/rcsv14n5-010

RESUMO

A integração de técnicas de aprendizado de máquina no gerenciamento de energia tornou-se fundamental para otimizar o consumo de energia e reduzir os custos operacionais. À medida que a demanda por eficiência energética cresce, vários estudos demonstraram a eficácia da modelagem preditiva orientada por algoritmos avançados. Mawson e Hughes (2020) exploraram o uso de redes neurais profundas para prever o consumo de energia e as condições ambientais em instalações de fabricação, destacando o desempenho superior de redes neurais feedforward e recorrentes na previsão das necessidades de energia do edifício e das condições da oficina. Da mesma forma, Walker et al. (2020) examinaram algoritmos de aprendizado de máquina para prever a demanda de eletricidade nos níveis de edifícios individuais e clusters, descobrindo que métodos como árvore impulsionada, floresta aleatória e redes neurais artificiais (RNAs) forneciam previsões horárias precisas, cruciais para entender a dinâmica de energia de curto prazo. Por outro lado, Deng, Fannon e Eckelman (2018) compararam métodos de aprendizado de máquina com modelos SARIMA para prever a intensidade do uso de energia (EUI) em edifícios comerciais dos EUA. Seu estudo revelou que, embora os algoritmos de aprendizado de máquina oferecessem melhorias modestas na precisão, os modelos SARIMA eram eficazes com dados limitados. El Alaoui et al. (2023) destacaram ainda mais os pontos fortes do aprendizado de máquina sobre o SARIMA na previsão do consumo de energia de aquecimento, embora o SARIMA também tenha se mostrado útil em cenários com dados mínimos de treinamento. Jana, Ghosh e Sanyal (2020) propuseram uma abordagem híbrida de aprendizado profundo combinando transformação wavelet discreta de sobreposição máxima (MODWT) com redes de memória de longo prazo (LSTM), mostrando sua eficácia na previsão do consumo de energia em vários setores. No geral, esses estudos ressaltam o potencial do aprendizado de máquina e dos modelos híbridos no aprimoramento das estratégias de gerenciamento de energia, melhorando a precisão e otimizando o uso de energia em diferentes contextos. Os avanços contínuos nessas tecnologias serão essenciais para o desenvolvimento de soluções energéticas eficazes e para atingir as metas de sustentabilidade.

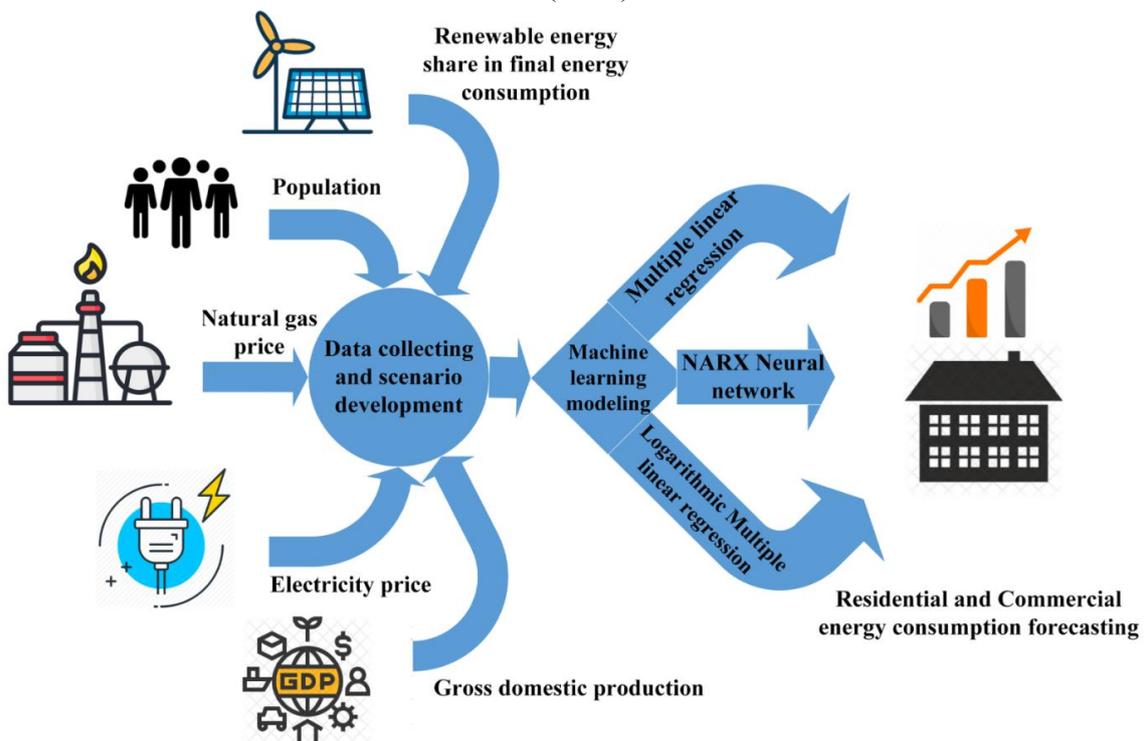
Palavras-chave: Aprendizado de Máquina, Modelagem Preditiva, Gerenciamento de Energia, Redes Neurais Profundas, Previsão de Energia.

1 INTRODUÇÃO

A gestão eficiente de energia em ambientes comerciais é cada vez mais desafiadora devido ao aumento dos custos operacionais e às demandas de sustentabilidade. A modelagem preditiva, alimentada por técnicas de aprendizado de máquina, oferece uma solução promissora para esses desafios, fornecendo informações valiosas para otimizar o uso de energia e reduzir despesas. O aprendizado de máquina abrange métodos que permitem que os sistemas aprendam com os dados sem programação explícita. Em ambientes comerciais, essas técnicas podem prever o consumo de energia, identificar ineficiências e implementar estratégias eficazes de economia de energia.

A modelagem preditiva se destaca na análise de extensos dados históricos e em tempo real para prever as necessidades futuras de energia. Técnicas como redes neurais artificiais, árvores de decisão e modelos de regressão podem processar dados de sensores, sistemas de controle de edifícios e informações meteorológicas para criar modelos precisos de demanda de energia. Esses modelos levam em conta variáveis como padrões de ocupação, condições climáticas e eventos especiais, permitindo um gerenciamento de energia mais proativo e personalizado.

Figura 1: Abordagem para previsão do consumo de energia residencial e comercial. Fonte: Nabavi et al. (2020).



Além disso, a modelagem preditiva ajuda a identificar padrões de uso ineficientes e recomendar ajustes em sistemas HVAC, iluminação e outros equipamentos. A integração desses modelos com sistemas de controle inteligentes permite ajustes em tempo real, aumentando a eficiência energética e

reduzindo custos. Estudos recentes, como os de Mawson e Hughes (2020), demonstram a eficácia das redes neurais profundas na previsão do consumo de energia e das condições ambientais em instalações fabris. Sua pesquisa, que comparou redes neurais feedforward e recorrentes, mostrou alta precisão na previsão do uso de energia e variáveis ambientais, comprovando o valor do aprendizado de máquina no gerenciamento de energia industrial.

Da mesma forma, Deng, Fannon e Eckelman (2018) avaliaram métodos de aprendizado de máquina em relação aos modelos SARIMA para prever o desempenho energético em edifícios de escritórios comerciais dos EUA. Suas descobertas indicam que, embora os modelos de aprendizado de máquina, como Support Vector Machines e Random Forest, ofereçam maior precisão, os modelos de regressão linear foram mais eficazes para certas previsões, como cargas de plugue. Isso destaca o desempenho diferenciado de algoritmos preditivos baseados em conjuntos de dados específicos.

Walker et al. (2020) exploraram o uso de algoritmos de aprendizado de máquina para prever a demanda de eletricidade em edifícios individuais e aglomerados de edifícios, enfatizando a necessidade de previsões precisas de curto prazo. Seu estudo descobriu que algoritmos como árvore impulsionalada, floresta aleatória e redes neurais artificiais forneceram os melhores resultados para previsões horárias, oferecendo informações valiosas para gerenciar o consumo de eletricidade.

Em outro estudo, Jana, Ghosh e Sanyal (2020) introduziram uma abordagem híbrida de aprendizado profundo combinando transformação wavelet discreta de sobreposição máxima (MODWT) com redes de memória de longo prazo (LSTM). Sua abordagem demonstrou desempenho superior na previsão do consumo de energia em vários setores, decompondo dados de séries temporais e agregando previsões de diferentes componentes.

El Alaoui et al. (2023) avaliaram o desempenho de modelos de aprendizado de máquina versus modelos SARIMA para prever o consumo de energia de aquecimento no Marrocos. Eles descobriram que os modelos de aprendizado de máquina geralmente superaram os modelos SARIMA na precisão da previsão, mas observaram que os modelos SARIMA eram eficazes com dados limitados. Isso sugere que, embora o aprendizado de máquina ofereça alta precisão, os modelos SARIMA também têm seu lugar na previsão de energia.

Finalmente, Ahmad, Zhang e Yan (2020) revisaram vários modelos de previsão para energia renovável e eletricidade, destacando seu papel na melhoria da eficiência do sistema de energia e apoiando os esforços de planejamento. A revisão abrangeu algoritmos de aprendizado de máquina, abordagens de conjunto e redes neurais artificiais, observando sua capacidade de lidar com grandes conjuntos de dados e fornecer previsões precisas. Esta análise abrangente orienta os profissionais na seleção de métodos de previsão apropriados para o planejamento energético e o desenvolvimento de políticas.

Em conclusão, a integração de técnicas de aprendizado de máquina nas estratégias de gerenciamento de energia oferece uma vantagem significativa para enfrentar os desafios complexos de otimizar o consumo de energia e reduzir custos em vários setores. Os estudos revisados destacam a eficácia da modelagem preditiva no aprimoramento do gerenciamento de energia, com algoritmos de aprendizado de máquina demonstrando precisão e eficiência superiores em comparação com os métodos tradicionais em muitos casos. A pesquisa de Mawson e Hughes (2020) e Walker et al. (2020) ressalta o potencial das redes neurais profundas e algoritmos preditivos avançados na previsão das necessidades de energia e no gerenciamento do consumo de eletricidade, tanto no nível individual quanto no cluster.

No entanto, as descobertas também revelam que, embora os modelos de aprendizado de máquina, como Support Vector Machines e Random Forest, forneçam informações valiosas e recursos de previsão aprimorados, há circunstâncias em que modelos tradicionais como o SARIMA ainda têm mérito, particularmente em cenários com dados limitados (Deng, Fannon e Eckelman, 2018; El Alaoui et al., 2023). As abordagens híbridas discutidas por Jana, Ghosh e Sanyal (2020) ilustram ainda mais o potencial de combinar técnicas avançadas para previsões de energia mais granulares e precisas.

No geral, esses estudos demonstram a importância de aproveitar o aprendizado de máquina e os modelos híbridos para enfrentar os desafios de gerenciamento de energia de forma eficaz. Eles também destacam a necessidade de inovação e refinamento contínuos em algoritmos preditivos para melhorar sua aplicabilidade e precisão em vários contextos. À medida que o gerenciamento de energia se torna cada vez mais crítico diante do aumento dos custos operacionais e das demandas de sustentabilidade, a adoção dessas técnicas avançadas será crucial para desenvolver estratégias energéticas eficazes e alcançar eficiência e economia de custos a longo prazo.

REFERÊNCIAS

- Ahmad, T., Zhang, H., & Yan, B. (2020). A review on renewable energy and electricity requirement forecasting models for smart grid and buildings. **Sustainable Cities and Society, 55**, 102052. <https://doi.org/10.1016/j.scs.2020.102052>
- Alaoui, M., Chahidi, L., Rougui, M., Lamrani, A., & Mechaqrane, A. (2023). Prediction of energy consumption of an administrative building using machine learning and statistical methods. **Civil Engineering Journal**. <https://doi.org/10.28991/cej-2023-09-05-01>
- Deng, H., Fannon, D., & Eckelman, M. (2018). Predictive modeling for US commercial building energy use: A comparison of existing statistical and machine learning algorithms using CBECS microdata. **Energy and Buildings, 163**, 34-43. <https://doi.org/10.1016/J.ENBUILD.2017.12.031>
- Jana, R., Ghosh, I., & Sanyal, M. (2020). A granular deep learning approach for predicting energy consumption. **Applied Soft Computing, 89**, 106091. <https://doi.org/10.1016/j.asoc.2020.106091>
- Mawson, V., & Hughes, B. (2020). Deep learning techniques for energy forecasting and condition monitoring in the manufacturing sector. **Energy and Buildings**. <https://doi.org/10.1016/j.enbuild.2020.109966>
- Walker, S., Khan, W., Katić, K., Maassen, W., & Zeiler, W. (2020). Accuracy of different machine learning algorithms and added-value of predicting aggregated-level energy performance of commercial buildings. **Energy and Buildings, 209**, 109705. <https://doi.org/10.1016/j.enbuild.2019.109705>