

MACHINE LEARNING E OTIMIZAÇÃO BASEADA EM SIMULAÇÃO PARA AVALIAÇÃO DO DESEMPENHO DE EDIFICAÇÕES

Iuri Praça Verginio, Rafael de Paula Garcia

Universidade Federal de Viçosa - Departamento de Arquitetura e Urbanismo. iuri.verginio@ufv.br, rafael.pgarcia@ufv.br

Ciências Exatas e Tecnológicas - Arquitetura e Urbanismo
Pesquisa

Palavras chave: Desempenho de edificações; Machine learning; Otimização baseada em simulação; Simulação paramétrica

Introdução

Devido aos avanços tecnológicos das últimas décadas, técnicas computacionais, como o aprendizado de máquina, têm encontrado aplicação em diversas áreas do conhecimento. Ao atuar como uma ferramenta para aprimorar o desenvolvimento de novos projetos de construção, o aprendizado de máquina auxilia na avaliação do desempenho de edifícios, utilizando dados reais para prever novas respostas e oferecer soluções mais rápidas do que os métodos tradicionais de avaliação. Portanto, a incorporação de técnicas de aprendizado de máquina nos processos de simulação baseada em otimização (SBO) reduz o custo computacional desses procedimentos ao diminuir a quantidade de simulações necessárias, fazendo previsões com base em um banco de dados seguro.

Objetivos

Existe uma variedade de métodos de aprendizado de máquina que podem ser aplicados a problemas de SBO, e a escolha do método apropriado pode influenciar significativamente os resultados dos processos. Portanto, o objetivo da pesquisa é de comparar o desempenho de dois métodos de machine learning acoplados a processos de OBS e aplicados a um problema de desempenho de uma edificação, de modo a reduzir o custo computacional do processo.

Metodologia

Inicialmente, foi realizada uma investigação na literatura para identificar e selecionar os métodos de predição mais relevantes aplicados a problemas de OBS. Redes Neurais (RN) e Random Forest (RF) foram os métodos selecionados para as comparações devido ao seu grande uso. Em seguida, definiu-se um edifício multipavimentos de escritório como modelo de edificação (Figura 1). Paralelamente, o acoplamento entre OBS e as estratégias de ML foram implementadas na plataforma Rhino + Grasshopper, incluindo a escolha dos motores e algoritmos de otimização mais adequados. Após, foram realizadas simulações paramétricas do modelo definido para gerar um banco de dados inicial, para fins de comparação, e posteriormente, novas avaliações paramétricas foram conduzidas, mesclando resultados obtidos por simulação e por predição seguindo o fluxo de trabalho da Figura 2.

A quantidade de soluções geradas por simulação foram diminuindo de 10 em 10%, partindo de 90/10 até 50/50, ou seja, 50% simulado e 50% predito. Por fim, os resultados de ambas as técnicas foram comparados e avaliados de acordo com a convergência das soluções, a raiz do erro quadrático médio (RMSE).

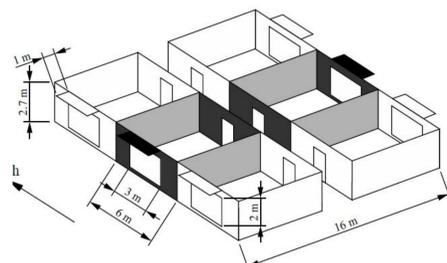


Figura 1: Modelo 3D utilizado de um edifício de escritórios.

Fonte: Wetter, M., Wright, J., 2004.

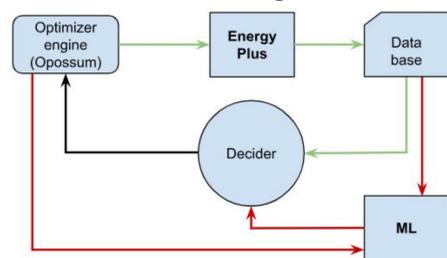


Figura 2: Fluxo de trabalho dos casos somente simulados (verde) e que mesclam simulação e predição (em vermelho)

Fonte: Elaborado pelo autor(2023).

Apoio financeiro

FAPEMIG (projeto número 206442 - UFV/PIBIC/FAPEMIG 2022 - 2023).

Resultados e Discussão

Em todos os percentuais utilizados, os valores de RMSE variaram entre 0,74 kwh/m² a 1,65 kwh/m² para RN e 0,59 kwh/m² a 1,62 kwh/m² para RF.

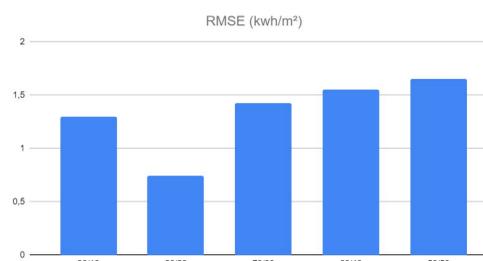


Figura 3: RMSE de cada processo da RN.

Fonte: Elaborado pelo autor(2023)

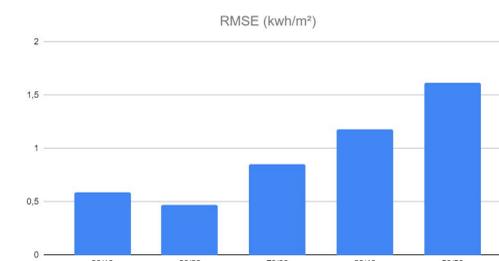


Figura 4: RMSE de cada processo da RF.

Fonte: Elaborado pelo autor(2023)

Quanto à convergência de ambos os métodos, mostra-se que a rede neural, em todos os seus processos, convergiu perto de 200 iterações. Na RF, entretanto, essa convergência leva mais tempo para acontecer, indicando que os processos da rede neural poderiam ter sido interrompidos muito antes, minimizando ainda mais o custo computacional e superando a aplicação de RF.

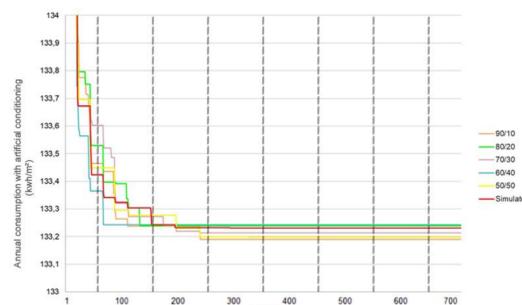


Figura 5: Gráfico de convergência da RN.

Fonte: Elaborado pelo autor(2023)

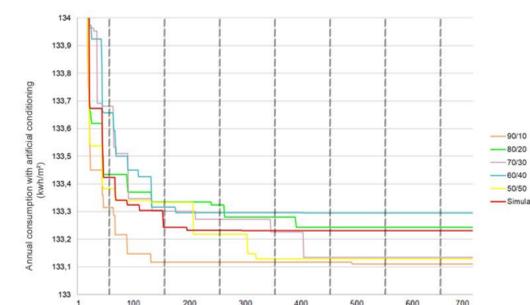


Figura 6: Gráfico de convergência RF.

Fonte: Elaborado pelo autor(2023)

Adicionalmente, os valores ótimos apresentados no gráfico de convergência são semelhantes à curva dos resultados do caso 100% simulado. Para a RN, a configuração mais próxima disso foi a 80/20, onde 80% das soluções são simuladas e 20% são aproximadas. O mesmo acontece na aplicação do RF, onde 80/20 não só é o mais próximo do caso 100% simulado, mas também possui o menor valor de RMSE de 0,47 kwh/m².

Conclusões

Conclui-se que ambas as técnicas apresentam redução no custo computacional, obtendo os melhores resultados na divisão 80/20 e baixos valores de RMSE. Porém, a rede neural mostrou-se mais adequada para este problema, visto que convergiu mais rapidamente, o que demonstra que não haveria necessidade de realizar todas as outras iterações restantes depois da convergência dos resultados, reduzindo assim, o tempo necessário para finalizar o processo. Ainda assim, estudos futuros devem comparar o desempenho da rede neural em diferentes naturezas de problemas de OBS.

Agradecimentos

Os autores agradecem o apoio financeiro da FAPEMIG, ao Laboratório de Tecnologias em Conforto Ambiental e Eficiência Energética e ao Departamento de Arquitetura e Urbanismo.