

XIX Encontro Nacional de Tecnologia do  
Ambiente Construído  
**ENTAC 2022**

Ambiente Construído: Resiliente e Sustentável  
Canela, Brasil, 9 a 11 novembro de 2022

## Redução do custo computacional do processo de otimização baseada em simulação utilizando redes neurais aplicadas a um problema de consumo energético com sistemas de condicionamento artificial

Computational cost reduction of the simulation-based optimization process using neural networks applied to an energy consumption problem with artificial conditioning systems

---

### **Mario Alves da Silva**

Universidade Federal de Viçosa | Viçosa | Brasil | [mario.a.silva@ufv.br](mailto:mario.a.silva@ufv.br)

### **Iuri Praça Vergínio**

Universidade Federal de Viçosa | Viçosa | Brasil | [iuri.verginio@ufv.br](mailto:iuri.verginio@ufv.br)

### **Rafael de Paula Garcia**

Universidade Federal de Viçosa | Viçosa | Brasil | [rafael.pgarcia@ufv.br](mailto:rafael.pgarcia@ufv.br)

### **Joyce Correna Carlo**

Universidade Federal de Viçosa | Viçosa | Brasil | [joycecarlo@ufv.br](mailto:joycecarlo@ufv.br)

---



Como citar:

SILVA, Mario; VERGÍNIO, Iuri; GARCIA, Rafael; CARLO, Joyce. Redução do custo computacional do processo de otimização baseada em simulação utilizando redes neurais aplicadas a um problema de consumo energético com sistemas de condicionamento artificial. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 19., 2022, Canela. **Anais...** Porto Alegre: ANTAC, 2022. p. XXX-XXX.

## Resumo

*Processos de otimização baseada em simulação (OBS) são capazes de melhorar o desempenho de edificações. A combinação de OBS a métodos de aprendizado de máquina surge como uma alternativa, capaz de reduzir o custo computacional do processo sem perder a robustez das soluções. Este trabalho utilizou redes neurais associadas a um processo de OBS mono-objetivo para minimizar o consumo com sistemas de resfriamento, aquecimento e iluminação artificial em um edifício de escritórios por meio de modificações da envoltória. Os resultados apontaram uma redução significativa do custo computacional, em situações que permitem a redução de até 50% das simulações.*

Palavras-chave: Redes neurais. Algoritmos genéticos. Simulação computacional. Avaliação do desempenho. Grasshopper.

## Abstract

*Simulation-based optimization (SBO) processes can enhance building performance. The combination of OBS and machine learning methods appears as an alternative, capable of reducing the computational cost of the process without losing the robustness of the solutions. This study used artificial neural networks associated to a single objective SBO process to minimize the energy consumption with cooling, heating, and lighting systems in an office building through modifications on the building envelope. The results showed a significant reduction in the computational cost, in situations that the reduction of up to 50% of simulations.*

Keywords: Neural networks. Genetic Algorithms. Computational simulation. Building performance assessment. Grasshopper.

## INTRODUÇÃO

A crise do petróleo no final do século XX associada a mudanças climáticas ocorridas nos últimos anos impactaram diretamente o projeto de arquitetura, promovendo intensas discussões sobre o consumo de energia em edifícios, nas suas mais diversas tipologias. A partir destes acontecimentos, buscou-se cada vez mais projetar com base em premissas que priorizassem a redução na demanda energética das edificações. Ainda neste contexto, surgiram e ganharam destaque vertentes projetuais que buscaram a produção de arquiteturas produzidas por meio de ferramentas digitais com enfoque no desempenho da edificação. Estes fatores, atrelados ao avanço tecnológico, nos diversos ramos da ciência, mas principalmente na computação, permitiram aferir o desempenho destas edificações a partir da criação e emprego de *softwares* que buscam auxiliar na avaliação das edificações por meio da simulação das condições desejadas pelo arquiteto.

A modelagem paramétrica, marcada pela possibilidade de se produzirem tipologias de objetos segundo parâmetros específicos que, com pequenas alterações, podem gerar objetos diversos, vem ganhando cada vez mais espaço no campo da arquitetura [1][2]. Quando a parametrização é associada ao projeto baseado em desempenho torna-se possível avaliar a variação no desempenho do edifício para diferentes soluções projetuais, sendo possível garantir edifícios de maior qualidade em diferentes aspectos, como conforto, consumo de energia, iluminação etc.

Processos de Otimização Baseada em Simulação (OBS) permitem um avanço no processo de busca por soluções projetuais e a consequente avaliação de seus desempenhos, com a associação de processos de modelagem paramétrica, otimização

e simulação. Esta abordagem, portanto, permite aplicar iterativamente um processo que busca maximizar o desempenho de um edifício, através de parâmetros definidos pelo simulador e guiados por um ou mais objetivos. Processos de OBS em arquitetura ocorrem majoritariamente pela aplicação de algoritmos genéticos [3], que são rotinas que aplicam processos que mimetizam aspectos evolutivos darwinianos para evoluir uma população de soluções de tal maneira que ela convirja para a solução ótima do problema. A evolução destas soluções ocorre com a associação de valores de funções-objetivo, aqui obtidas por simulações, que garantem a continuidade delas no processo a depender de quão boas elas são. No entanto, apesar de muito usados, processos de OBS em arquitetura enfrentam diversos problemas para a sua aplicação, dentre os quais o tempo demandado pelos processos de simulação.

Ainda sobre os avanços computacionais, é evidente que hoje, computadores conseguem ler, interpretar e operacionalizar uma imensa quantidade de dados em pouco tempo, fazendo da ciência de dados uma matéria importante e imprescindível atualmente, inclusive na Arquitetura. O Aprendizado de Máquina, do inglês *machine learning*, é um dos campos da Inteligência Artificial que vem recebendo bastante atenção, não apenas pela precisão e agilidade com que os seus algoritmos conseguem aprender com os dados, mas também devido a sua aplicabilidade nas mais diversas ciências. Estes algoritmos utilizam grandes conjuntos de entradas e saídas de dados para reconhecer padrões e efetivamente aprender, treinando a máquina para fazer recomendações ou decisões autônomas. Isso possibilita com que após repetições suficientes e inúmeras modificações do algoritmo, a máquina se torne capaz de receber uma entrada e prever uma saída [4].

A competição “ASHRAE – Great Energy Predictor III” propôs aos participantes a utilização de métodos de *machine learning* para a proposição de modelos precisos e robustos capazes de prever o uso energético em diversas tipologias de edificações, através de uma base de dados proveniente de medições *in loco* [5]. No cenário brasileiro, [6] utilizam um método de *machine learning* através de redes neurais para propor um novo modelo simplificado ao RTQ-C, e assim, aumentar a eficácia nas predições do consumo de energia e conseqüente desempenho de edificações comerciais, de serviços e públicas brasileiras. Quando comparado ao primeiro modelo proposto, obtido por métodos de regressão linear [7], observou-se a superioridade da aplicação dos métodos de *machine learning* para realizar as predições, tanto na previsão do desempenho das edificações estudadas quanto na observação das relações entre as características observadas nas edificações [6].

Observa-se, portanto, que o uso de métodos de *machine learning* beneficia a avaliação de desempenho de edificações, uma vez que a partir de bases de dados confiáveis e robustas, têm a capacidade de prever o desempenho em novas situações. Assim, este trabalho busca analisar o impacto da integração de um método de *machine learning* baseado em redes neurais ao processo de Otimização Baseada em Simulação (OBS), como mecanismo para redução do custo computacional.

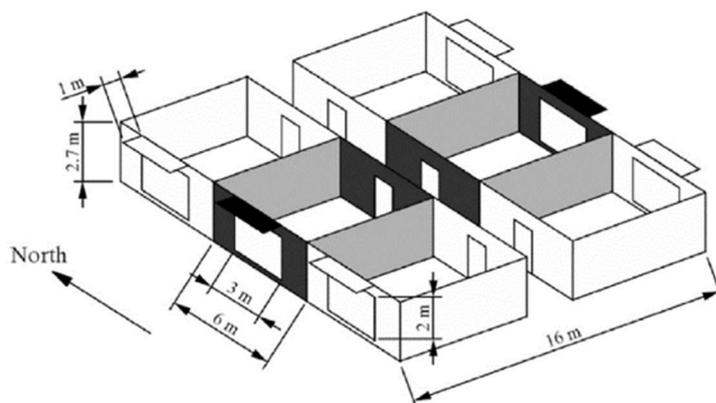
## MÉTODO

### SELEÇÃO DO PROBLEMA E CONFIGURAÇÃO DA OTIMIZAÇÃO

O problema utilizado foi criado por [8], e busca minimizar o consumo anual com sistemas de condicionamento artificial (aquecimento, resfriamento e iluminação artificial) em uma modelagem simplificada de um edifício de escritórios representado por apenas uma zona térmica do pavimento tipo. [8] avaliou o desempenho para as cidades de Seattle, Houston e Chicago, a partir dos dados meteorológicos de arquivos TMY2. O presente estudo, no entanto, limitou-se apenas à avaliação da cidade de Seattle.

A Figura 1 apresenta a disposição de alguns ambientes no pavimento, mas para a criação do modelo de simulação [8] utiliza apenas os escritórios ao centro (cores escuras), juntamente com o corredor. O modelo consiste, portanto, em uma zona térmica com 6 metros de largura e 16 de profundidade. As aberturas, foram posicionadas apenas nas paredes Leste e Oeste, como apresentado na Figura 1. [8] utiliza a versão 8.5 do programa *EnergyPlus* para a modelagem termoenergética.

**Figura 1: Modelo 3D do edifício de escritórios**



Fonte: [8].

As paredes externas possuem transmitância térmica de  $0,25 \text{ W}/(\text{m}^2\text{K})$ . As aberturas possuem vidro duplo *low-e* insulado com gás Criptônio. As aberturas possuem ainda dispositivos de sombreamento externos, ativados somente durante o verão, caso a radiação incidente nas aberturas exceda  $200 \text{ W}/\text{m}^2$ . A influência das paredes internas, foi considerada por [8] através do componente *Internal Mass* ao qual foram atribuídas as propriedades térmicas de uma parede de tijolo maciço com espessura igual a 12cm. Para o teto e o piso foi utilizada uma laje de concreto com uma camada de material isolante na parte inferior e carpete na porção superior.

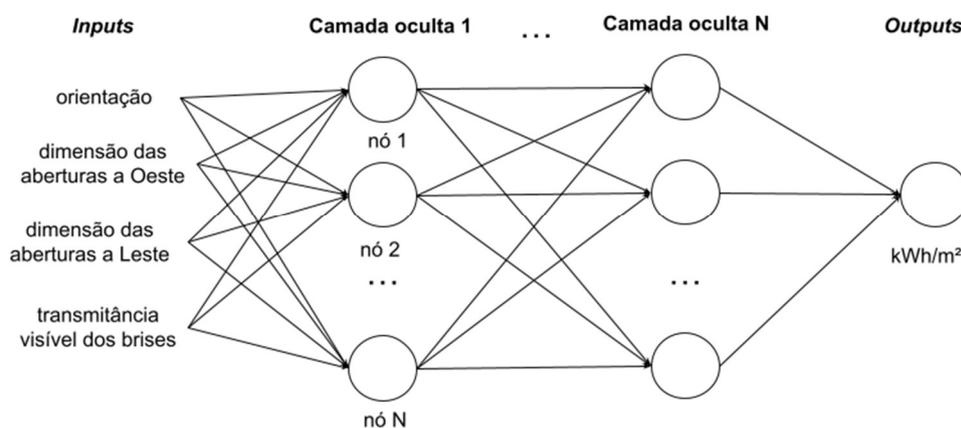
[8] estabelece 4 parâmetros, a partir dos quais observa-se a variação no consumo energético, são eles: orientação da edificação ( $-180$  a  $180^\circ$ ); largura das aberturas a Leste (0,1 a 5,9 metros); largura das aberturas a Oeste (0,1 a 5,9 metros); e transmitância dos elementos de sombreamento (0,2 a 0,8).

A implementação na plataforma *Grasshopper* para *Rhinoceros* foi disponibilizada por [9]. Foi utilizado um algoritmo genético como método de otimização contido no motor Galápagos [10], com uma população de 14 soluções e 50 gerações [8]. Os demais parâmetros do algoritmo foram mantidos como valores *default* do motor de otimização.

## REDES NEURAS ARTIFICIAIS

Redes neurais artificiais funcionam através de 3 elementos principais: *inputs*, camadas ocultas e *outputs*. Os *inputs* correspondem aos parâmetros do problema. Os nós são estruturas de avaliação e verificação dos *inputs*, associando seus valores às respostas obtidas e, por fim, são obtidos *outputs*, que representam o valor aproximado da variável resposta, obtido com o uso das redes neurais (Figura 2).

**Figura 2: Diagrama simplificado do funcionamento das redes neurais artificiais**



Fonte: os autores.

Para a implementação do aprendizado de máquina, foi utilizado o *plugin* *GHPythonRemote* para *Grasshopper* que permite conectar instâncias Python externas à plataforma ao ambiente de programação visual do *Grasshopper*. Para este problema, foram empregadas as bibliotecas de *Scikit-learn*, *Numpy* e *Pandas* para a montagem das redes neurais.

Para a configuração das redes neurais, inicialmente foi realizado um processo de OBS onde as 700 soluções foram obtidas 100% por simulação e este banco de dados foi utilizado para configurar as redes neurais. A partir de testes, foram definidas 2000 como o valor máximo de iterações, 30 nós e 30 camadas ocultas, como os parâmetros principais das redes neurais. Tais valores obtiveram um RMSE de 0,397 kWh/m<sup>2</sup> para o banco de dados de 700 soluções, dividido em uma proporção de 80/20, onde 80% do banco foi usado para treino e 20% usado para teste das redes.

A combinação do processo de OBS e das redes neurais ocorreu através da substituição de simulações por valores aproximados de função objetivo. Foram estabelecidos 9 processos de OBS com uso de redes neurais, são eles: 90/10, 80/20, 70/30, 60/40, 50/50, 40/60, 30/70, 20/80, 10/90. Nos casos mencionados, a relação estabelecida é entre o percentual de soluções obtidas por simulação e o percentual obtido por

aproximação, respectivamente, totalizando 100% de soluções. Em todos os processos, as simulações e as aproximações são contínuas, ou seja, inicialmente ocorre o percentual simulado e depois o percentual aproximado, até que se obtenham as 700 soluções, não havendo intercalações entre simulação e aproximação. Quanto às configurações das redes neurais, em todos os processos de OBS com *machine learning* são utilizadas as mesmas configurações, obtidas a partir do caso 100% simulado, de modo a possibilitar uma comparação justa entre os resultados.

## MÉTODOS DE ANÁLISE

A partir dos resultados obtidos nos processos de OBS com e sem *machine learning*, foi inicialmente comparada a convergência da função objetivo, isto é, foi avaliada a evolução do algoritmo ao longo das 700 soluções obtidas e o sucesso na obtenção do menor valor para o consumo com sistemas de condicionamento artificial.

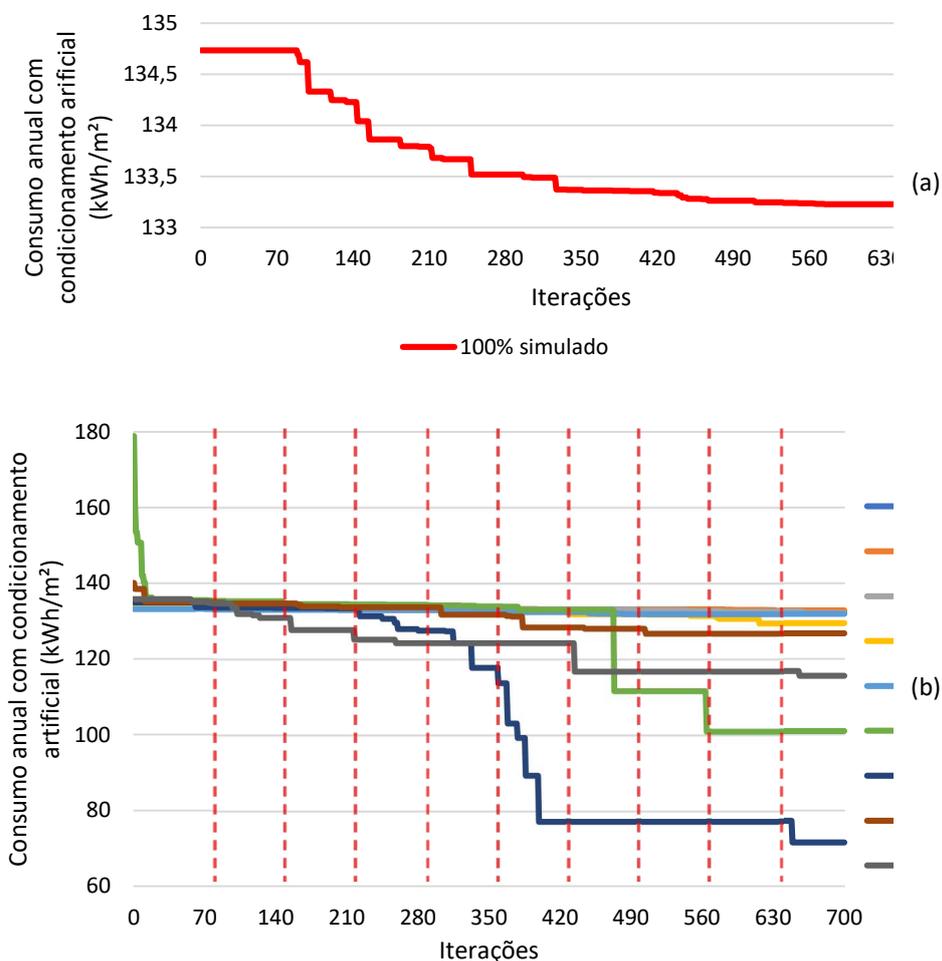
Posteriormente foram analisadas todas as soluções obtidas por aproximação em cada processo de OBS e seu respectivo valor simulado, de modo a se obter a Raiz do Erro Quadrático Médio (RMSE, *Root Mean Square Error*). O indicador RMSE permitiu avaliar a discrepância entre os valores aproximados e simulados na unidade do indicador de desempenho utilizado, deste modo, foi obtido um valor de RMSE em kWh/m<sup>2</sup>. Após a identificação dos processos de OBS com o pior desempenho, foram avaliadas as diferenças destes casos em relação ao processo de OBS 100% simulado.

## RESULTADOS E DISCUSSÃO

O caso 100% simulado, usado como base para configuração das redes neurais, apresenta uma pequena variação quanto à convergência da função objetivo, isto é, ao serem analisadas consecutivamente as iterações, têm-se uma redução de 1,51 kWh/m<sup>2</sup> da 1ª à 700ª iteração, como pode ser verificado pela Figura 3a. A Figura 3b apresenta ainda a convergência da função objetivo para os casos nos quais inseriu-se redes neurais para a aproximação do valor da função objetivo de algumas soluções.

A partir dos resultados, é possível observar que a combinação de 30% de casos simulados e 70% aproximados (30/70) obteve a melhor resposta, com um indicador de consumo de aproximadamente 71 kWh/m<sup>2</sup>. Os processos com as proporções 40/60 e 10/90 ocupam respectivamente a segunda e a terceira posição. As demais combinações obtiveram valores de consumo próximos a 135 kWh/m<sup>2</sup>, que é próximo do valor de 133 kWh/m<sup>2</sup> obtido no caso 100% simulado.

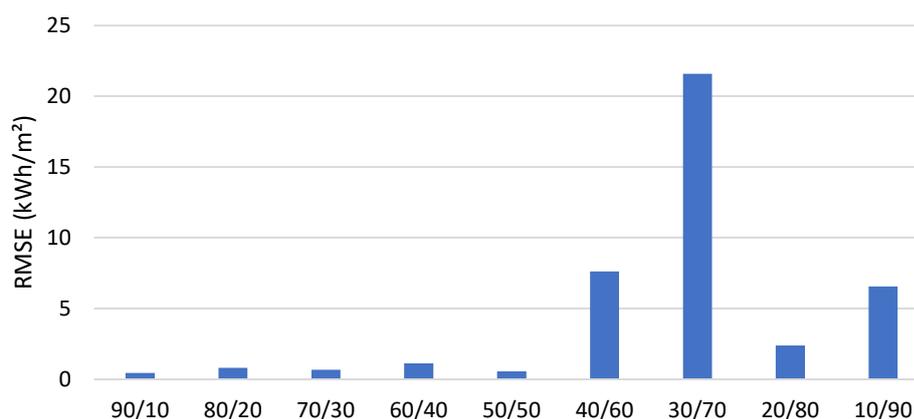
Figura 3: Evolução da função objetivo ao longo das 700 iterações para o caso 100% simulado (a) e os casos com aproximação (b). (No segundo gráfico as linhas tracejadas em vermelho dividem as iterações em 10 regiões, que podem ser relacionadas as proporções entre simulação e aproximação utilizadas neste trabalho)



Fonte: os autores.

Apesar dos resultados na Figura 3b apontarem um melhor desempenho da relação 30/70, é necessário que seja avaliada a diferença entre os valores aproximados e o valor simulado. A partir dos resultados obtidos na Figura 4, observa-se que apesar de obter o menor valor de função objetivo, a relação 30/70 obtém o maior RMSE (21,58) e, conseqüente, o maior erro de aproximação. As relações 40/60 e 10/90, que também apresentam variações significativas em relação às demais combinações, também obtém valores aproximados de baixa qualidade. A combinação 90/10 apresenta os melhores resultados, com o menor RMSE, igual a 0,46. No entanto, a alta qualidade desta aproximação era esperada, visto que 90% das soluções utilizam um processo de Otimização Baseada em Simulação e, somente 10% finais utilizam um processo de Otimização Baseada em *Machine Learning*.

Figura 4: RMSE considerando os casos aproximados e simulados



Fonte: os autores.

A partir das diferenças entre as 3 combinações com o pior RMSE (30/70, 40/60 e 10/90) e o caso 100% simulado, observa-se que a combinação 40/60 apresenta maiores diferenças a partir da 470ª solução (Figura 3). Sendo assim, o processo de aproximação foi capaz de obter bons resultados entre a 280ª e a 470ª solução. No entanto, a partir da 470ª solução houve piora nas soluções, com uma diferença final de aproximadamente 40kWh/m<sup>2</sup> para a solução ótima. Na combinação 30/70, a partir da 210ª execução começam a ser perceptível diferenças entre a relação 30/70 e o processo 100% simulado. Ao final do processo, a relação 30/70 apresenta diferença aproximada de 60 kWh/m<sup>2</sup>. A relação 10/90 apresenta diferenças por volta da 70ª execução e caso ótimo com diferença aproximada de 20 kWh/m<sup>2</sup>. Tais resultados permitem observar que as combinações 30/70 e 10/90 apresentaram diferenças logo na mudança do uso de simulações para o uso de aproximações, indicando que os dados até então simulados não foram suficientes para manter o processo de aproximação com baixas diferenças, como ocorre na relação 40/60.

A relação 20/80 apresenta um baixo erro e boa similaridade com o caso 100% simulado, no entanto essa situação provavelmente ocorre devido à aleatoriedade envolvida com o processo de OBS na porção inicial de 20%, correspondente aos casos simulados. Devido à seleção de variáveis feita pelo motor de otimização Galápagos, é possível que a porção de 20% tenha sido direcionada já a valores de parâmetros próximos aos ótimos. Deste modo, não houve grandes variações no decorrer do processo.

## CONCLUSÃO

A utilização de métodos de *machine learning* é capaz de reduzir significativamente o custo computacional de processos de OBS e, conseqüentemente, disseminar seu uso. A partir dos resultados obtidos neste trabalho, que avaliou a redução no consumo energético com sistemas de aquecimento, resfriamento e iluminação artificial, através de um processo de OBS e redes neurais em um edifício de escritórios, observa-se que o uso de aproximações permitiu redução no custo computacional do processo. A partir das relações estabelecidas, entre simulação e aproximação, observa-se que até a

relação 50/50, existe uma redução significativa no custo computacional para a execução do processo sem que haja alteração significativa no desempenho do processo de OBS. Para os casos em questão, o RMSE variou entre 0,46 kWh/m<sup>2</sup> e 1,12 kWh/m<sup>2</sup>. Entre as relações 40/60 e 10/90 há maiores divergências entre os valores aproximados e o valor real (simulado). Tais resultados apontam a necessidade de um maior banco de dados inicial, para que seja possível a obtenção de valores aproximados condizentes com os valores reais. Nessas relações, foram obtidos os maiores erros, onde a relação 30% simulado e 70% aproximado obtém um RMSE igual a 21,58 kWh/m<sup>2</sup>.

Em geral, processos de OBS que utilizaram até 50% dos valores aproximados da função objetivo foram capazes de obter bons resultados, com valores de RMSE suficientemente baixos e com valores ótimos próximos ao caso em que 100% das soluções foram simuladas. Os resultados indicam, portanto, que a configuração 50/50 seja a mais indicada para o uso, uma vez que ela é a que apresenta maior redução do custo computacional do processo.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) através do edital PIBIC/UFV 2021-2022.

## REFERÊNCIAS

- [1] OXMAN, R. Thinking difference: Theories and models of parametric design thinking. **Design Studies**, v. 52, p. 4–39, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.destud.2017.06.001>>.
- [2] FAROUK, A.; ELDALY, H.; DEWIDAR, K. Parametric Design As a Tool for Performative Architecture. **Journal of Al-Azhar University Engineering Sector**, v. 14, n. 50, p. 148–157, 2019.
- [3] KHEIRI, F. A review on optimization methods applied in energy-efficient building geometry and envelope design. **Renewable and Sustainable Energy Reviews**, v. 92, n. May 2017, p. 897–920, 2018. Disponível em: <<https://doi.org/10.1016/j.rser.2018.04.080>>.
- [4] SEYEDZADEH, S.; POUR RAHIMIAN, F.; RASTOGI, P.; GLESK, I. Tuning machine learning models for prediction of building energy loads. **Sustainable Cities and Society**, v. 47, n. March, p. 101484, 2019. Disponível em: <<https://doi.org/10.1016/j.scs.2019.101484>>.
- [5] MILLER, C.; ARJUNAN, P.; KATHIRGAMANATHAN, A.; FU, C.; ROTH, J.; PARK, J. Y.; *et al.* The ASHRAE Great Energy Predictor III competition: Overview and results. **Science and Technology for the Built Environment**, v. 26, n. 10, p. 1427–1447, 2020. Disponível em: <<https://doi.org/10.1080/23744731.2020.1795514>>.
- [6] MELO, A. P.; CÓSTOLA, D.; LAMBERTS, R.; HENSEN, J. L. M. Development of surrogate models using artificial neural network for building shell energy labelling. **Energy Policy**, v. 69, p. 457–466, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.enpol.2014.02.001>>.
- [7] CARLO, J.; LAMBERTS, R. Development of envelope efficiency labels for commercial

buildings: Effect of different variables on electricity consumption. **Energy and Buildings**, v. 40, n. 11, p. 2002–2008, 2008. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378778808001114>>.

- [8] WETTER, M.; WRIGHT, J. A comparison of deterministic and probabilistic optimization algorithms for nonsmooth simulation-based optimization. **Building and Environment**, v. 39, n. 8, p. 989–999, 2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360132304000332>>.
- [9] WAIBEL, C.; WORTMANN, T.; EVINS, R.; CARMELIET, J. Building energy optimization: An extensive benchmark of global search algorithms. **Energy and Buildings**, v. 187, p. 218–240, 2019. Disponível em: <<https://doi.org/10.1016/j.enbuild.2019.01.048>>.
- [10] RUTTEN, D. Galapagos: On the logic and limitations of generic solvers. **Architectural Design**, v. 83, n. 2, p. 132–135, 2013.