

Performance predictive metamodel for dynamic facade shading

Cassio Houang Daher¹, Regina Ruschel¹

¹ Universidade Estadual de Campinas, Brasil
c209606@dac.unicamp.br; ruschel@unicamp.br

Abstract. Dynamic shading compositions present a challenge for computer simulation of illuminance performance still in the design phase of the project. Such architectural elements have a conflicting function, shading without blocking natural light. The evaluations of these dynamic elements present an infinity of parameters and several combinations, resulting in compositional complexity and making it difficult to read and understand the performance. The objective of this research is to identify the optimized positioning of dynamic facade shading elements. The dependent variable to be analyzed is the annual average illuminance. The algorithm that creates the shape of the Shoebox and manipulates the independent variables is the same that performs the annual daylight assessment. Simulation results are the metamodel input data, Machine Learning is used for the optimization. The contribution of this research is to test the set of results of the independent variables, training an algorithm capable of replacing the simulation.

Keywords: Machine Learning, Metamodel, Dynamic Shading, Performance Evaluation.

1 Introdução

As envoltórias dos edifícios foram progressivamente transformadas em envelopes com multicamadas leves e transparentes, resultando em uma diminuição da massa térmica, portanto, com menor valor de isolamento (Konstantoglou & Tsangrassoulis, 2016). A materialidade da construção, em especial, a que constitui os componentes construtivos da envoltória, podem afetar consideravelmente o desempenho energético e o conforto do edifício (Kheiri, 2018). Uma vez que a envoltória é uma barreira primária entre interior e o exterior de uma edificação, é necessário enfatizar as vantagens de se usar estratégias passivas ou ativas para redução da demanda energética, como melhorar o aproveitamento de luz natural para amenizar a necessidade por iluminação artificial (Kheiri, 2018).

O sistema passivo de sombreamento de envoltórias é um meio bioclimático eficaz para manter o equilíbrio entre a demanda visual e térmica. No entanto, estudos mostraram que os elementos de sombreamento estáticos são notavelmente incapazes de responder completamente às condições

climáticas variáveis (Al-Masrani & Al-Obaidi, 2019). Os avanços tecnológicos computacionais, tanto em programas (software) e máquinas (hardware), incitaram os projetistas a mesclar necessidades ambientais e simulações computacionais para desenvolver envoltórias de construção dinâmicas que respondem a condições variáveis climáticas (Al-Masrani & Al-Obaidi, 2019). Os exigentes requisitos para a construção de sistemas inteligentes de fachada estão ligados às conquistas tecnológicas, formando sistemas adaptativos ou responsivos. Sua atuação visa tanto contrabalançar fenômenos antagônicos, sombreamento e iluminação, quanto atuar como moderadores ambientais (Konstantoglou & Tsangrassoulis, 2016). Quando se projeta um sistema de fachada dinâmica, para coletar a luz do dia com mais eficiência, o projeto deve incorporar o uso de softwares de projeto paramétrico, projeto algorítmico e simulação dinâmica, de maneira a validar a importância da computação para aproveitar e projetar questões de complexidade de desempenho (el Sheikh & Gerber, 2011).

Existem diferentes formas para realizar simulações computacionais de predição de iluminação natural, inicialmente com métodos simples utilizando diagramas, modelo em escala, fórmulas matemáticas e com regras obtidas por experimentos (Reinhart et al., 2006). Atualmente, simulações de iluminação natural podem ser aplicadas para diferentes propósitos e variam em escala e em complexidade, seja para espaços internos, envoltórias de edificações ou em contextos urbanos(Ayoub, 2020). Contudo, mesmo com os computadores e softwares atuais, as simulações diurnas são demoradas e caras do ponto de vista computacional (Ayoub, 2020). Conjuntos arquitônicos, como uma envoltória, podem formar um sistema complexo com uma variedade de parâmetros. Portanto, simular tal sistema de envoltória, sua propriedade geométrica, bem como os impactos ambientais pode ser um processo intensivo e exigente em termos computacionais(Sebestyen & Tyc, 2020).

A adoção de métodos de projeto paramétrico possibilita integrar os dados das simulações ainda em fases iniciais da concepção (Ayoub, 2020). Isto, pois geralmente as simulações eram feitas em etapas mais avançadas do projeto, em que as alterações no projeto são mais difíceis, custosas e limitadas (Østergård et al., 2016). Métodos de otimização de luz do dia devem ser integrados ainda nas fases iniciais do processo de projeto. Os estágios iniciais são caracterizados por um grande número de parâmetros e possibilidades de projeto, mas, apesar dos avanços nas ferramentas de simulação de desempenho, essas ferramentas normalmente fornecem resultados determinísticos que avaliam o projeto ao invés de orientá-lo de forma proativa (Østergård et al., 2017). Conhecer o desempenho das soluções desde os momentos iniciais pode contribuir para uma melhor tomada de decisões.

Na forma convencional de projeto, se o projetista quiser mudar qualquer parâmetro, todo o processo tem de ser repetido. Em um projeto paramétrico alterar e melhorar o projeto é um processo automático que imediatamente atualiza o modelo, permitindo então um controle absoluto sobre a forma, em todas as etapas do projeto (Eltaweeel & SU, 2017). Apesar de a modelagem paramétrica permitir testar variáveis e comparar soluções facilmente, isso ainda não é o bastante para avaliar o excesso de dados que é

criado. E, por isso, recorre-se a algoritmos de otimização, como Inteligência Artificial (IA) na Aprendizagem de Máquina (AM).

Segundo Poole et al. (1998), a IA é o estudo de “agentes inteligentes”, representados por qualquer sistema que percebe seu ambiente e executa ações que maximizam a hipótese de atingir seus objetivos. Segundo Russell & Norvig (2013), o campo da IA objetiva construir entidades inteligentes. A IA pode ter o enfoque nos processos do pensamento e raciocínio ou procura imitar o comportamento humano por máquinas. Busca-se fidelidade ao desempenho humano ou da racionalidade.

A IA com o enfoque na ação por máquinas de forma humana aborda o processamento de linguagem natural, a representação do conhecimento, o raciocínio automatizado, a visão robótica, a robótica e o AM (Russell & Norvig, 2013). O AM é a capacidade das máquinas de aprender e trabalhar em novas dimensões de problemas sem serem explicitamente programadas para isso (Kumar, 2017). Para tal, os programas computacionais que realizam o AM são alterados à medida que são expostos a novos dados e cenários.

1.1 Metamodelo

Tarefas de modelagem também podem tirar proveito de abordagens de AM, seja na simplificação de modelos de simulação de edifícios, ou na geração automática de soluções de projeto baseadas em imagens, ou descrições textuais de edifícios (Belém et al., 2019). Fachadas dinâmicas, pode-se tirar proveito das ferramentas de arquitetura paramétrica, com integração de simulações de desempenho e a análise de resultados utilizando AM. Deste modo, torna-se possível a implementação de estratégias de otimização de desempenho, com soluções baseadas nos resultados obtidos das simulações (Østergård et al., 2017), avaliando quais variáveis impactam mais, removendo as que impactam menos, e consequentemente reduzindo o conjunto de soluções possíveis e o tempo de simulação necessário.

A metamodelagem é um método de construção de modelos acelerado e concentrados que correlacionam entradas a resultados obtidos por modelos matemáticos mais complexos (Østergård et al., 2017). Os metamodelos podem ser desenvolvidos por meio de diferentes métodos, utilizando técnicas de AM. Uma de suas vantagens é a capacidade de realizar uma previsão a partir de um número reduzido de parâmetros e com menor tempo de execução. Um metamodelo é capaz de substituir um processo complexo de simulação (Bracht et al., 2021). Tais modelos têm a capacidade de prever as ações e influências das variáveis, tornando-o capaz de tomar decisões que privilegiam a otimização do desempenho (Østergård et al., 2017). Tais funções de otimização e suas consequências não são capazes de qualificar a estética da edificação, estas ficam a cargo do projetista. A Figura 1 apresenta um fluxograma com a estrutura conceitual de um metamodelo.



Figura 1. Fluxograma que expressa o conceito de funcionamento de um metamodelo. Fonte: os autores.

2 Metodologia

O problema abordado nessa pesquisa é a multiplicidade de parâmetros e combinações associadas ao posicionamento das aletas, que é representado pelo total de possibilidades de horários e orientações, gerando um conjunto geral de iluminâncias. O objetivo é identificar o posicionamento otimizado de elementos dinâmicos de fachada, com aletas horizontais foscas de posicionamento vertical e giro axial automatizado, ainda no processo de concepção do projeto. A otimização visa o desempenho de iluminância em ambiente interno.

Os objetivos específicos são: integrar os algoritmos de geração do modelo, de simulação ao metamodelo e a concepção e comprovação da aplicação do metamodelo. A primeira hipótese a ser destacada é verificar a integração do algoritmo que gera a forma da *Shoebox*, aplica as combinações das variáveis independentes, realiza a simulação computacional, integrando a estes o metamodelo de otimização de posicionamento, a segunda hipótese é a comprovação do metamodelo, comparando os resultados relativos aos valores obtidos inicialmente.

O método de pesquisa será experimental. A pesquisa experimental requerendo determinar o um objeto de estudo, selecionar as variáveis que conseguiram influenciá-lo, definir as formas de controle e observação dos efeitos que a variável produz no objeto (Gil, 2002). Na pesquisa experimental, a operacionalização das variáveis exige que se considerem as condições de mensuração, sobretudo para serem selecionados os instrumentos apropriados. O objeto de estudo definido para esta pesquisa é a *Shoebox*, que é adotada como padrão típico para simulação de desempenho de edificação, para mostrar o impacto dos principais parâmetros de design (Reinhart et al., 2013). As dimensões do *Shoebox* de formato retangular adotadas foram 3,60 m de largura, 8,20 m de profundidade e pé direito de 2,80 m. Em uma das faces existirá uma abertura, localizada a 1,00 m do piso, com 1,50 m de altura e 3,00 m de largura. A *Shoebox* será locada em Campinas, SP, Brasil. A Tabela 1 apresenta o conjunto de variáveis independentes adotadas.

Tabela 1. Variáveis independentes e as combinações possíveis.

Variável	Orientação	Posicionamento Vertical Brises	Posicionamento Axial Brises	Hora/ Data Ocupadas	TOTAL
Quant.	4	3	5	4745 (horas 6:00-18:00)	1.067.625

Os Brise foram gerados na abertura criada em uma das laterais. A abertura tem 3,00 metros de largura com 1,50 metros de altura e distância do piso de 1,00 metro. Os elementos de sombreamento são formados por aletas planas e retangulares. O design das aletas não é o foco desta pesquisa.

Uma das variáveis independentes é a orientação da abertura, os quatro posicionamentos estão representados na Figura 2 orientação da Shoebox, a faixa indica a abertura para entrada de iluminação solar, são quatro variações de posicionamento. Os Brises são elementos dinâmicos e apresentam duas formas de movimento: a rotação axial de suas aletas e o posicionamento vertical das aletas.

Na Figura 2 estão representadas as formas de controle para variar a influência dos Brises na Shoebox. São cinco posicionamentos verticais estimados e as três possíveis rotações das aletas.

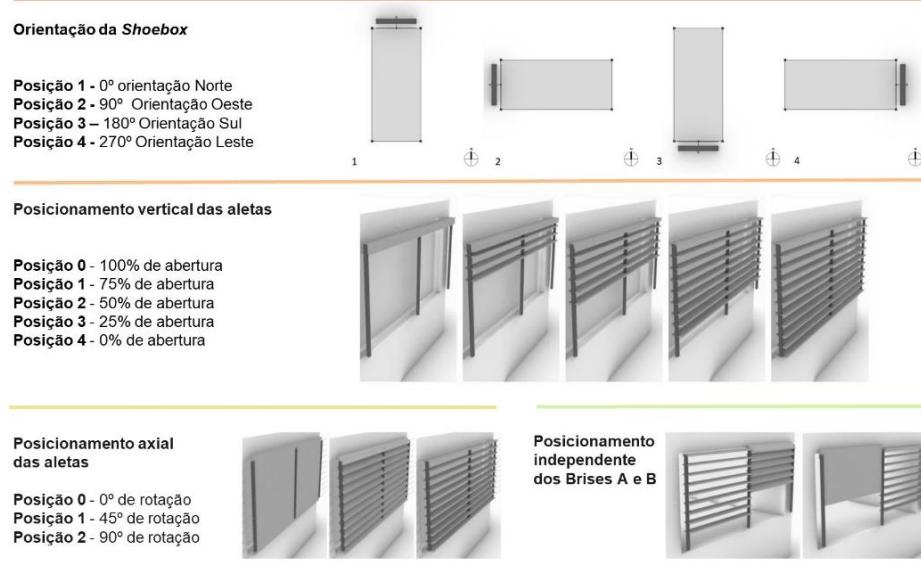


Figura 2. Operacionalização das variáveis independentes. Fonte: os autores.

Os movimentos verticais vão até as aletas chegarem no topo, onde se encaixam. Já os movimentos de rotação são realizados nos eixos de cada uma das aletas. Neste estudo são dois os Brises, denominados A e B, com tamanhos iguais. São conjuntos de aletas com movimentos independentes. O ambiente desta pesquisa experimental é computacional, realizada em ambiente virtual com o controle das variáveis, já que este ambiente permite a maximização do efeito das variáveis independentes sobre a dependente.

O fluxograma de definição do ambiente segue a lógica de softwares e *plugins* utilizados, como representado na Figura 3. Todo o projeto da *Shoebox* e dos *Brises* foi desenvolvido no *Rhinoceros* (Mcneel, 2022) e *Grasshopper* (Davidson, 2022). Todas variáveis independentes foram criadas em um mesmo algoritmo, seguindo uma linha de lógica paramétrica que permite a exploração de todas as combinações.

O *Climate Studio* (Solemma, 2021) é um plugin para o *Rhinoceros*, desenvolvido para realizar simulações computacionais avançadas de iluminação natural e simulação de gasto de energia. Foi construído com base nos motores de simulação validados, denominados *EnergyPlus* e *Radiance*. Destaca-se pela velocidade de cálculo e por apresentar resultados precisos. O cálculo a ser realizado será de disponibilidade de luz do dia. Essas métricas avaliam as distribuições de iluminância interna devido à incidência de luz natural, durante o ano todo.

A coleta de dados na pesquisa experimental é feita mediante a manipulação de certas condições e a observação dos efeitos produzidos. O *Climate Studio* funciona avaliando uma designada superfície, denominada *grid*. A superfície a ser observada precisa ser definida pelo usuário. O *grid* de observação é dividido segundo um padrão geométrico, e com número de sensores definido, como pode ser observado na Figura 4.

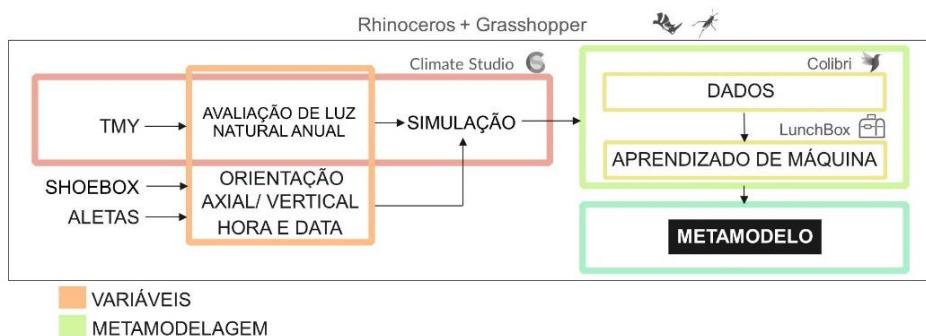


Figura 3. Fluxograma de definição do ambiente. Fonte: os autores.

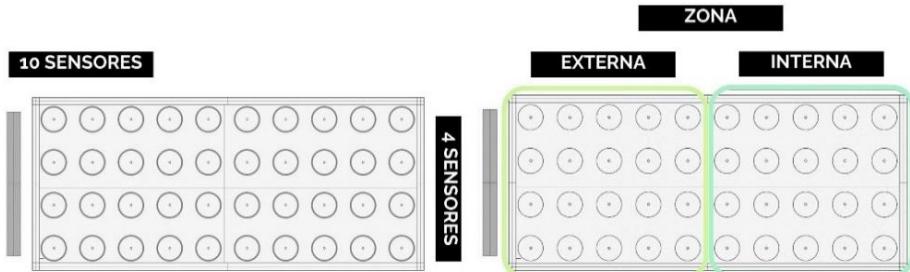


Figura 4. Grids para avaliação da iluminância. Fonte: os autores.

Os sensores são observados individualmente, quanto maior o número de sensores, maior a precisão da avaliação e o maior o tempo de cálculo. No caso desta pesquisa foram definidos quarenta sensores, em fileiras equidistantes com quatro linhas e dez colunas. Para melhor avaliar os resultados, foi decidido dividir o *grid* em duas partes iguais, um setor com vinte sensores localizados mais próximos ao caixilho, denominado Zona Externa, e uma Zona Interna, com os mesmos vinte sensores, mas localizada distante do caixilho.

3 Resultados

Os resultados da avaliação de luz natural anual, foram apresentados em valores de iluminância média das horas ocupadas anuais de uma *Shoebox*, considerando apenas as horas ocupadas, das 6:00 até 18:00, para uso de escritório. O *Grid* foi definido com 40 sensores (divididos em 20 *grids* externos e 20 *grids* internos) e os resultados da simulação para os sensores tipo *timestep* do *Climate Studio*, foram separados por data e hora [lux] [wh/m²].

3.1 Metamodelagem

A metamodelagem foi realizada no *Grasshopper*, na Figura 5 a seguir estão descritos os passos do algoritmo para chegar ao resultado. Os algoritmos foram separados e todos têm funções específicas, a separação ocorreu devido ao peso computacional. O primeiro passo foi o algoritmo de geração do modelo de informação para fachada dinâmica em uma *Shoebox*, com aletas horizontais foscas de posicionamento vertical e giro axial, denominado *Shoebox+CS 01*.

Neste mesmo arquivo em que o modelo foi gerado, o algoritmo tem continuidade com a simulação de desempenho utilizando o *Climate Studio* e o componente de avaliação de lux natural anual, apenas as horas ocupadas.

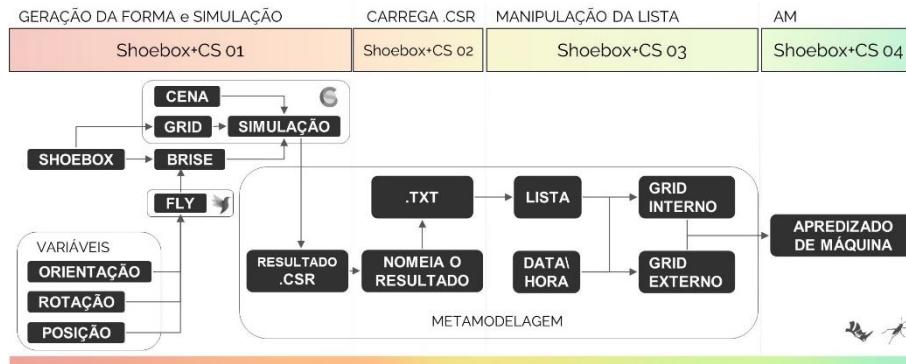


Figura 5. Processo de metamodelagem, definição de função dos arquivos de Grasshopper. Fonte: os autores.

A configuração do *grid*, dos materiais para a cena, configuração das aberturas estão todos no mesmo arquivo. Os resultados da simulação são exportados e salvos em uma pasta, arquivos em formato .CSR. Os resultados das simulações dos posicionamentos em .CSR precisam ser reinseridos no *Grasshopper* para que possam ser organizados e nomeados, passo seguinte representado no arquivo de nome Shoebox+CS 02. O algoritmo organiza os dados e exporta as listas em formato .TXT, para posteriormente explorar as diferentes combinações das variáveis, para realizar tal tarefa de forma automatizada foi utilizado o plugin do *Grasshopper* Colibri.

O próximo passo é a importação das listas em formato .TXT, geradas a partir dos arquivos de simulação, realizada no arquivo Shoebox+CS 03. O processo de organização das listas permite a aplicação de algoritmo de AM, classificando o desempenho da solução na concepção, e possibilitando diferentes arranjos e combinações das variáveis.

3.2 Aplicação de Aprendizado de Máquina

Foi aplicado algoritmo de otimização denominado *k-Nearest Neighbor* (*k-NN*) de AM para a classificação dos posicionamentos otimizados de iluminância das aletas. Os arquivos em .TXT são importados, eles já estão separados em três arquivos, as zonas internas, zonas externas e as *strings*. A lógica do algoritmo é importar os TXT's, organizá-los e combiná-los, para então encontrar o valor do posicionamento otimizado com o k-NN, Figura 6.

Os valores das zonas são designados como eixo X e Y e formam um ponto. Estes pontos são os valores de iluminância e variam entre 0 e 10.000 lux. Estes valores, em lux, são remapeados para números entre 0 e 1, todas as horas do ano são testadas individualmente, para todas as combinações das variáveis independentes de cada horário. Então é adicionado um ponto de referência, o valor de otimização definido pelo autor. Neste projeto, foram adotados os valores de referência 500, 1.000, 1.500 e 2.000 lux.

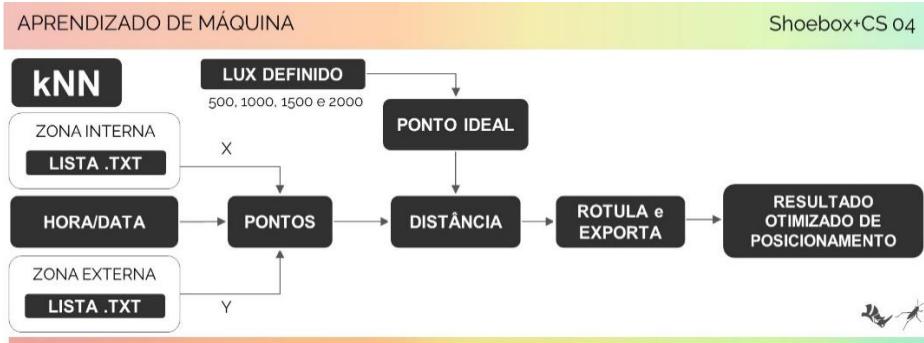


Figura 6. Algoritmo kNN para otimização de posicionamento. Fonte: os autores.

O k-NN calcula o vizinho mais adequado, neste caso utilizando a distância como definição de adequação. Entre os 225 valores para os posicionamentos e combinações das aletas, ele encontra o mais próximo e o define como o candidato ideal. O restante do algoritmo avalia todas as horas ocupadas no ano, as rotula e exporta para uma planilha, com as informações completas das combinações. Os resultados do processo de metamodelagem geraram o conjunto de posicionamentos para os Brises da Shoebox. Eles foram separados em planilhas de Excel de acordo com faixas de conforto determinadas pela quantidade de Lux. Essas faixas de iluminância foram definidas seguindo a premissa de Nabil e Mardaljevic (2006). O exemplo representado na Figura 6 é do funcionamento de um algoritmo de k-NN. O código tem início com a extração de valores do banco de dados, neste caso são os resultados das simulações de iluminância. Os valores estão separados em zona interna e externa, e podem ser extraídos por hora do ano. Com estes dados são criados pontos em um plano cartesiano, remapeados de 0 a 1,0. É inserido neste plano um ponto ideal, em vermelho, neste caso o ponto é de 2.000 Lux. O valor máximo de 2.000 lux não foi atingido em nenhuma média mensal. São medidas todas as distâncias entre os pontos criados e o ponto ideal, as linhas verdes da Figura 6. O ponto com a menor distância, neste caso o ponto B, é o ponto selecionado.

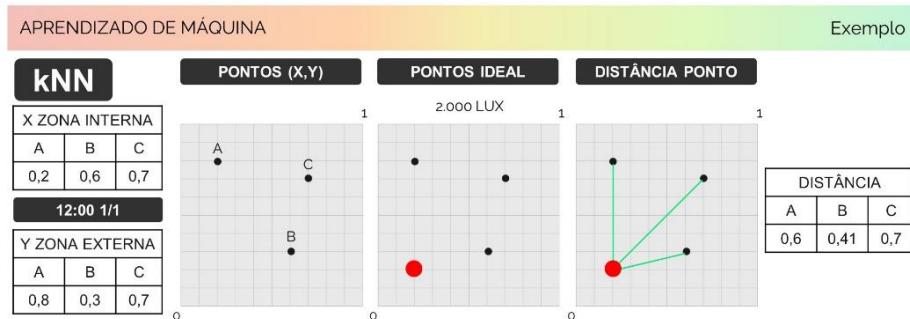


Figura 7. Algoritmo kNN para otimização de posicionamento. Fonte: os autores.

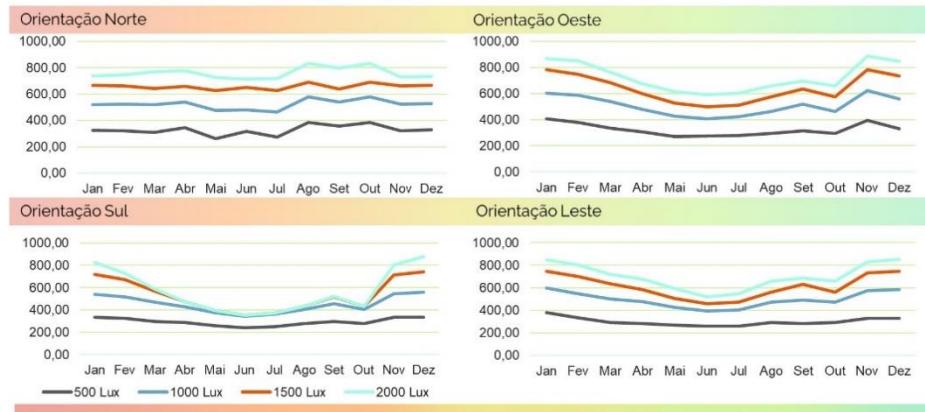


Figura 8. Gráficos com os resultados médios para cada um dos cenários avaliados.
Fonte: os autores.

A análise dos resultados foi realizada a partir dos valores médios de cada um dos cenários avaliados, de maneira que possam ser comparados. Na Figura 8 os gráficos representam avaliações dos metamodelos, separadas por orientação e por valor de otimização em Lux. São valores de iluminância média mensal calculados após a otimização de posicionamentos das aletas. Observa-se que na localização deste experimento simulado para a orientação sul qualquer otimização de posicionamento das aletas na abertura resulta luminância máxima de 400 lux entre os meses de abril e outubro. Diferentes cenários existem para ampliar a atuação do metamodelo e possibilitar a adaptação dos posicionamentos. A Figura 9 apresenta os gráficos com os posicionamentos mais comuns, para os diferentes cenários analisados.



Figura 9. Posicionamentos mais comuns nos diferentes cenários. Fonte: os autores.

Os levantamentos representados nos gráficos da Figura 9 foram separados pela orientação e para cada um dos cenários em Lux, somando as quantidades de aparições de cada um dos 225 diferentes posicionamentos possíveis em todas as horas ocupadas do ano. São 4.745 possíveis posicionamentos para cada um dos cenários, eles foram numerados seguindo a lógica de combinação apresentada no código, por isso não existe uma relação expressa entre a numeração dos posicionamentos os números seguintes. Os posicionamentos das aletas mais comuns foram: número 160, com as aletas abaixadas e em ângulo de 45º, número 150, com as aletas abaixadas e em ângulo de 90º e número 0, com as aletas recolhidas, foram encontrados somando todos os cenários possíveis, 4 orientações da fachada e quatro cenários em Lux, num total de 75.920 posicionamentos.

4 Considerações Finais

A contribuição desta pesquisa é gerar o conjunto dos resultados das variáveis independentes capacitando a proposição de um metamodelo para substituir a simulação. Essa é uma pesquisa em andamento e o processo de metamodelagem sofrerá provável alteração, com o intuito de verificar sua eficiência e precisão. Serão revistas técnicas de AM a serem utilizadas.

Agradecimentos. Meus sinceros agradecimentos a Prof.^a Dr.^a Ana Lúcia Harris (em memória), sem a qual este trabalho não teria início, nem meio e muito menos fim.

- Al-Masrani, S. M., & Al-Obaidi, K. M. (2019). Dynamic shading systems: A review of design parameters, platforms and evaluation strategies. *Automation in Construction*, 102(March), 195–216. <https://doi.org/10.1016/j.autcon.2019.01.014>
- Ayoub, M. (2020). A review on machine learning algorithms to predict daylighting inside buildings. *Solar Energy*, 202(March), 249–275. <https://doi.org/10.1016/j.solener.2020.03.104>
- Belém, C. G., Leitão, A. M., Santos, L., & Leitão, A. M. (2019). On the Impact of Machine Learning: Architecture without Architects ? *CAAD Futures 2019*, June, 247–293.
- Bracht, M. K., Melo, A. P., & Lamberts, R. (2021). A metamodel for building information modeling-building energy modeling integration in early design stage. *Automation in Construction*, 121(September 2020), 1–19. <https://doi.org/10.1016/j.autcon.2020.103422>
- Davidson, S. (2022). Grasshopper (No. 2022). <https://www.grasshopper3d.com>
- el Sheikh, M., & Gerber, D. J. (2011). Building skin intelligence: A parametric and algorithmic tool for daylighting performance design integration. *Integration Through Computation - Proceedings of the 31st Annual Conference of the*

- Association for Computer Aided Design in Architecture, ACADIA 2011, November 2011, 170–177.
- Eltaweel, A., & SU, Y. (2017). Parametric design and daylighting: A literature review. *Renewable and Sustainable Energy Reviews*, 73(October 2016), 1086–1103. <https://doi.org/10.1016/j.rser.2017.02.011>
- Gil, A. C. (2002). Como Elaborar Projetos de Pesquisa. In Editora Atlas (Ed.), *Como Elaborar Projetos de Pesquisa* (4º Edição).
- Kheiri, F. (2018). A review on optimization methods applied in energy-efficient building geometry and envelope design. *Renewable and Sustainable Energy Reviews*, 92(March), 897–920. <https://doi.org/10.1016/j.rser.2018.04.080>
- Konstantoglou, M., & Tsangrassoulis, A. (2016). Dynamic operation of daylighting and shading systems: A literature review. *Renewable and Sustainable Energy Reviews*, 60, 268–283. <https://doi.org/10.1016/j.rser.2015.12.246>
- Kumar, R. (2017). Machine Learning and Cognition in Enterprises. In *Machine Learning and Cognition in Enterprises*. Apress. <https://doi.org/10.1007/978-1-4842-3069-5>
- Mcneel, R. (2022). Rhinoceros 3d (7 SR14 & 7.14.22010.17001. 2022). <https://www.rhino3d.com>
- Østergård, T., Jensen, R. L., & Maagaard, S. E. (2016). Building simulations supporting decision making in early design - A review. In *Renewable and Sustainable Energy Reviews* (Vol. 61, pp. 187–201). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2016.03.045>
- Østergård, T., Jensen, R. L., & Maagaard, S. E. (2017). Early Building Design: Informed decision-making by exploring multidimensional design space using sensitivity analysis. *Energy and Buildings*, 142, 8–22. <https://doi.org/10.1016/j.enbuild.2017.02.059>
- Poole, D. (1998). Computational intelligence: a logical approach. *Choice Reviews Online*, 35(10), 35-5701-35-5701. <https://doi.org/10.5860/choice.35-5701>
- Reinhart, C. F., Jakubiec, J. A., & Ibarra, D. (2013). Definition of a reference office for standardized evaluations of dynamic façade and lighting technologies. *Proceedings of BS 2013: 13th Conference of the International Building Performance Simulation Association*, 3645–3652.
- Reinhart, C. F., Mardaljevic, J., & Rogers, Z. (2006). Dynamic daylight performance metrics for sustainable building design. *LEUKOS - Journal of Illuminating Engineering Society of North America*, 3(1), 7–31. <https://doi.org/10.1582/LEUKOS.2006.03.01.001>
- Russell, S., & Norvig, P. (2013). Inteligência Artificial. Elsevier.
- Sebestyen, A., & Tyc, J. (2020). Machine Learning Methods in Energy Simulations for Architects and Designers. *ECAADe* 38, 1(MAKING THROUGH CODE), 613–622.
- Solemma. (2021). Climate Studio (ClimateStudio_1.6.8014.23580 nov. 2021.). <https://www.solemma.com/climatestudio>