

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
BACHARELADO EM ENGENHARIA COMPUTACIONAL

**Análise do desempenho térmico de
edificação de balanço energético nulo via
algoritmo evolutivo**

Gisele Goulart Tavares da Silva

JUIZ DE FORA
NOVEMBRO, 2019

Análise do desempenho térmico de edificação de balanço energético nulo via algoritmo evolutivo

GISELE GOULART TAVARES DA SILVA

Universidade Federal de Juiz de Fora

Faculdade de Engenharia

Departamento de Mecânica Aplicada e Computacional

Bacharelado em Engenharia Computacional

Orientador: Leonardo Goliatt da Fonseca

Coorientador: Priscila Vanessa Zabala Capriles Goliatt

JUIZ DE FORA

NOVEMBRO, 2019

ANÁLISE DO DESEMPENHO TÉRMICO DE EDIFICAÇÃO DE BALANÇO ENERGÉTICO NULO VIA ALGORITMO EVOLUTIVO

Gisele Goulart Tavares da Silva

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO FACULDADE DE EN-
GENHARIA DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE
INTEGRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU
DE BACHAREL EM ENGENHARIA COMPUTACIONAL.

Aprovada por:

Leonardo Goliatt da Fonseca
Doutor em Modelagem Computacional

Priscila Vanessa Zabala Capriles Goliatt
Doutora em Modelagem Computacional

Luciana Conceição Dias Campos
Doutora em Engenharia Elétrica

Fernando Tadeu de Araújo Lima
Doutor em Urbanismo

JUIZ DE FORA
29 DE NOVEMBRO, 2019

Resumo

A edificação de balanço energético nulo, também conhecida como Net-Zero Energy Building (NZEB), baseia-se no conceito de edifício com eficiência energética, que equilibra sua energia total utilizando soluções que visam mitigar as emissões de CO₂ e reduzir o uso de energia nas construções. O consumo de energia em edifícios residenciais e comerciais aumentou cerca de 40% nos países desenvolvidos e excedeu os setores industrial e de transportes. Devido às mudanças climáticas, em 2050 os edifícios poderão consumir 20% mais energia, com o desempenho energético sendo um elemento crítico para alcançar as metas climáticas e melhorar a segurança energética. O objetivo deste trabalho é maximizar o conforto térmico em um NZEB através do algoritmo evolutivo PSO (Particle Swarm Optimization), uma técnica inspirada na inteligência coletiva dos animais. Para isso, diferentes parâmetros construtivos foram inseridos em um modelo geométrico para identificar combinações que ofereçam maior conforto. Para o problema de otimização deste trabalho, os parâmetros de projeto foram: tipo de bloco, espessura do concreto usado na laje sólida, tipo de argamassa, tamanho das janelas, tamanho das portas e tipo de telhado. A partir do modelo geométrico, um arquivo .idf foi gerado para a parametrização e subsequente simulação termo-energética dos cenários criados pelo PSO no software EnergyPlus. A troca de materiais e os valores dos parâmetros do modelo atingiram menores horas de desconforto por ano em comparação aos resultados disponíveis na literatura.

Palavras-chave: Eficiência Energética, Simulação Termo-Energética, Enxame de Partículas, NZEB

Abstract

The zero-energy building, also known as Net-Zero Energy Building (NZEB), is based on the concept of an energy-efficient building that balances its total energy using solutions that aim to mitigate CO₂ emissions and reduce energy use in the constructions. Energy consumption in residential and commercial buildings increased between about 40% in developed countries and exceeded the industry and transportation sectors. Due to climate change, by 2050 buildings can consume 20% more energy, with energy performance being the critical element in achieving climate goals and improving energy security. The objective of this paper is to maximize the thermal comfort in an NZEB through the evolutionary algorithm PSO (Particle Swarm Optimization), a technique inspired by the collective intelligence of the animals. For this, different constructive parameters were inserted in a geometric model to identify combinations that offer greater comfort. For the optimization problem of this work, the design parameters were: block type, concrete thickness used in the solid slab, mortar type, window size, door size, and cover type. From the geometric model, an IDF file was generated for the parameterization and subsequent energy simulation of the scenarios created by the PSO in the EnergyPlus software. The exchange of materials and parameter values of the model reached lower hours of discomfort per year in comparison to results obtained in the literature.

Keywords: Energy Efficiency, Thermal Energetic Simulation, Particle Swarm Optimization, NZEB

Agradecimentos

A Deus por me conceder forças em toda a caminhada. Aos meus pais Jorge e Cleonice, meu irmão Gabriel e meu noivo Leandro pela paciência e apoio durante toda a jornada. Todas as palavras de incentivo, o carinho e o encorajamento foram essenciais para a finalização de mais esta etapa. A todos os meus familiares, que de alguma forma sempre estiveram presentes e me apoiaram em cada uma das fases de minha vida.

A todos os colegas do PGMC e do curso de Engenharia Computacional pelos auxílios prestados, pelas longas conversas, histórias, e por todo o apoio durante este período de graduação/mestrado.

Aos professores Leonardo Goliatt e Priscila Capriles pela orientação, amizade, incentivo e principalmente, pela paciência, sem a qual este trabalho não se realizaria. Vocês de certa forma me adotaram (hehe) e continuam me incentivando e encorajando nesta vida de incertezas.

Aos professores Fernando Tadeu e Luciana Campos por terem aceitado o convite para a banca e pelas contribuições na avaliação do trabalho.

Aos professores do Departamento de Mecânica Aplicada e Computacional e do Departamento de Ciência da Computação, assim como todos os funcionários do curso, que durante esses anos, contribuíram de algum modo para o meu enriquecimento pessoal e profissional.

Por fim, agradeço à Universidade Federal de Juiz de Fora por me fornecer a estrutura necessária para o meu crescimento pessoal e formação acadêmica, e por me proporcionar momentos tão agradáveis.

*"Nature shows us only the tail of the lion.
But I do not doubt that the lion belongs
to it even though he cannot at once reveal
himself because of his enormous size."*

Albert Einstein

Conteúdo

Lista de Figuras	6
Lista de Tabelas	7
Lista de Abreviações	8
1 Introdução	9
1.1 Apresentação e Contextualização do Problema	9
1.2 Justificativa	13
1.3 Objetivos Gerais e Específicos	13
2 Revisão Bibliográfica	14
2.1 Uso de Métodos de Aprendizado de Máquina	14
2.2 Aquisição de dados a partir de sensores	18
2.3 Aplicações em NZEB	19
2.4 Otimização através de Estratégias Evolutivas	21
3 Material e Métodos	25
3.1 <i>Software</i> de Modelagem Termo-Energética	25
3.2 Modelo NZEB	25
3.3 Parâmetros de Projeto	27
3.3.1 Seleção Evolucionária de Parâmetros	29
4 Resultados e Discussão	32
5 Conclusões	36
Bibliografia	38
A Tabelas com a composição dos telhados e propriedades dos materiais	42

Lista de Figuras

1.1	Representação gráfica dos limites de aceitabilidade descritos na norma ASHRAE 55 (2013).	12
2.1	Exemplos das geometrias das edificações simuladas por Tsanas e Xifara (2012)	15
2.2	Edificação localizada na Malásia e estudada por Qahtan (2019). A imagem (a) apresenta o exterior do edifício e (b) o interior da fachada dupla.	19
2.3	Edifício localizado em Hong Kong utilizado como estudo de caso por Li, Wang e Cheung (2018).	24
3.1	Modelo tridimensional da casa de balanço energético nulo.	26
3.2	Ilustração das camadas que podem ser utilizadas para constituir um telhado verde.	28
3.3	Fluxo de dados do modelo .idf em conjunto com o algoritmo PSO.	31
4.1	Frequências das escolhas do algoritmo evolutivo para os tipos de argamassa, bloco e telhado.	33
4.2	Frequências das escolhas do algoritmo evolutivo para incrementos de janelas e portas.	34
4.3	Gráfico de convergência da função objetivo (F) ao longo das 35 iterações do PSO.	34
4.4	Boxplots das horas desconfortáveis anuais nos cômodos da NZEB ao longo das 30 execuções.	35

Lista de Tabelas

3.1	Parâmetros de projeto utilizados para a geração das simulações dos diferentes cenários.	28
4.1	Estatísticas descritivas dos valores das horas desconfortáveis em cada cômodo da NZEB ao longo das 30 execuções.	34
4.2	Comparativo entre horas de desconforto térmico para o melhor cenário retornado pelo PSO e o modelo de referência.	35
A.1	Propriedades dos materiais utilizados para compor os tipos de telhado durante simulações.	42
A.2	Propriedades de blocos e argamassas utilizadas durante simulações.	43

Lista de Abreviações

NZEB	Edificação de Balanço Energético Nulo, do inglês <i>Net-Zero Energy Building</i>
ABNT	Associação Brasileira de Normas Técnicas
ASHRAE	Sociedade Americana de Engenheiros de Aquecimento, Refrigeração e Ar Condicionado, do inglês <i>American Society of Heating, Refrigerating and Air-Conditioning Engineers</i>
RF	Floresta Aleatória, do inglês <i>Random Forest</i>
ELM	Máquina de Aprendizado Extremo, do inglês <i>Extreme Learning Machine</i>
GP	Processo Gaussiano, do inglês <i>Gaussian Process</i>
ANN	Redes Neurais Artificiais, do inglês <i>Artificial Neural Networks</i>
GB	<i>Gradient Boosting</i>
SVM	Máquinas de Vetores Suporte, do inglês <i>Support Vector Machines</i>
KNN	K-vizinhos mais próximos, do inglês <i>K-Nearest Neighbors</i>
PSO	Otimização por Enxame de Partículas, do inglês <i>Particle Swarm Optimization</i>
ABC	Colônia de Abelhas Artificiais, do inglês <i>Artificial Bee Colony</i>
INMET	Instituto Nacional de Meteorologia

1 Introdução

1.1 Apresentação e Contextualização do Problema

O constante aumento da demanda de energia global tem intensificado a busca por soluções que minimizem os custos de produção de energia e os gastos em sistemas residenciais de aquecimento e resfriamento. Este aumento é resultado do rápido desenvolvimento da economia e da sociedade nas últimas décadas, de modo que a compreensão do comportamento do consumo elétrico dos diferentes tipos de usuários pode ser interessante tanto para as prestadoras de serviço quanto para os usuários finais (ZHOU; YANG, 2016).

O uso eficiente da energia é uma concepção importante para a estabilidade da economia e diminuição da poluição ambiental. Nos países desenvolvidos, as edificações são responsáveis por cerca de 40% do consumo energético comercializado (LAUSTSEN, 2008; PÉREZ-LOMBARD; ORTIZ; POUT, 2008). Por vários anos a humanidade tentou melhorar a eficiência energética de edificações utilizando métodos simples, como a escolha de regiões geográficas ideais ou recorrendo ao uso de materiais para construção mais adequados ao clima.

Porém, com o desenvolvimento da tecnologia, as ações para a minimização do consumo de energia se tornaram mais complexas. Em 1973, com a crise energética global, uma busca por construções com um consumo de energia reduzido foi desencadeada globalmente, e as fontes de energia renováveis começaram a ser incorporadas nos projetos da área da construção civil (HUNN, 1996). Desde então, diversos países começaram a criar leis e regulamentações relacionadas ao uso eficiente de energia em edificações residenciais e comerciais. Considerando o contexto brasileiro, sistemas de aquecimento, ventilação e ar condicionado figuram em torno de 49% do gasto energético em edificações (NEWELL; QIAN; RAIMI, 2016).

Para a obtenção do melhor desempenho de uma construção, três fatores devem ser considerados: projeto arquitetônico, sistemas de aquecimento e resfriamento, e ocupação. O projeto arquitetônico é desenvolvido de forma iterativa, com uma equipe que repassa

todos os aspectos da edificação e repensa sobre decisões relacionadas a arquitetura (YU et al., 2015). Com um projeto bastante otimizado em mãos, especialistas da área da construção civil podem reduzir a capacidade de sistemas de refrigeração e aquecimento, e minimizar a necessidade deste conjunto de serviços.

Porém, apesar do projeto arquitetônico figurar como importante aspecto na performance da edificação, determinar materiais e configurações que otimizem o consumo e conforto na estrutura não é uma tarefa fácil. Considerações sobre a localização, estratégias de ventilação, iluminação e materiais a serem utilizados, aumentam a complexidade da concepção de um projeto energeticamente eficiente.

Dentro deste contexto, para reduzir o uso de energia dos edifícios e mitigar as emissões de CO₂, as edificações de balanço energético nulo (NZEB, do inglês *Net-Zero Energy Building* têm ganhado visibilidade no setor da construção civil. O conceito de construção com balanço energético baixo/zero, bem como as políticas para incentivar o desenvolvimento e a construção de novas edificações eficientes e sustentáveis, surgiram da necessidade de reduzir o consumo de energia das edificações e garantir maior conforto térmico aos usuários.

Apesar dos objetivos internacionais claros e da atenção internacional dada as NZEBs, dois grandes desafios precisam ser enfrentados antes da plena integração do conceito deste tipo de edificação nos códigos de construção nacionais e/ou padrões internacionais. Isso inclui, em particular, a adaptação de uma definição comum e inequívoca e o desenvolvimento de uma metodologia de apoio para calcular o balanço energético. Na literatura existente, o conceito de NZEB é descrito com uma ampla gama de termos e expressões, e várias abordagens distintas para as definições de NZEB podem ser encontradas. A falta de uma definição comum já é amplamente discutida em nível internacional (HAMDY ALA HASAN, 2013; AELENEI; AELENEI; GONÇALVES, 2013).

A necessidade de uma metodologia de cálculo robusta ganhou atenção com o crescente número de projetos NZEB e, portanto, o interesse em como o saldo 'nulo' é calculado. Um edifício de balanço energético nulo se refere a um edifício com necessidades energéticas muito baixas, devido à adoção de medidas de eficiência, em que as necessidades serão supridas por fontes renováveis de energia (AELENEI; AELENEI; GONÇALVES,

2013). Alguns países estão a caminho de incluir as NZEBs em seus códigos nacionais de construção, no entanto, ainda não existe um procedimento de cálculo padronizado e a maioria dos cálculos são apenas propostas voluntárias desenvolvidas para um caso específico do NZEB (MARSZAL P. HEISELBERG, 2011).

Como o ar condicionado pode ser um dos maiores consumidores de energia em edificações (PÉREZ-LOMBARD; ORTIZ; POUT, 2008), uma das principais maneiras de reduzir seu uso é a busca de soluções passivas, como o uso de ventilação natural, favorecendo a execução de projetos arquitetônicos que, por sua vez, devem levar em consideração diversos aspectos, desde variáveis técnico-construtivas até fatores climáticos em que o edifício de análise está inserido. A combinação e aplicação correta dessas variáveis resultará no conforto térmico adequado dentro do edifício (SILVEIRA et al., 2014).

Atualmente, dois padrões de desempenho térmico para edifícios estão em vigor no Brasil: NBR 15220 (ABNT, 2005) e NBR 15575 (ABNT, 2013). As diretrizes construtivas da NBR 15220 (ABNT, 2005) são aplicadas ao interesse social e a NBR 15575 (ABNT, 2013) é aplicada a todos os tipos de edifícios residenciais. Para Sorgato, Melo e Lamberts (2014), os padrões mostram diferenças na porcentagem de abertura para ventilação dos ambientes e também pequenas diferenças nos limites das propriedades térmicas dos componentes das paredes e do telhado. O Brasil não possui padrões de conforto térmico para edifícios com ventilação natural. Por esse motivo, as condições de conforto térmico são definidas pela ASHRAE 55/2013 - Condições ambientais para ocupação humana (STANDARD, 2013).

A ASHRAE 55/2013 (STANDARD, 2013) apresenta uma abordagem para avaliar o desempenho térmico em edifícios com ventilação natural. Para determinar o conforto térmico dos ocupantes do edifício, o método adaptativo proposto define faixas de temperatura aceitáveis para 80% e 90% dos ocupantes e utiliza o conceito de temperatura operacional - que correlaciona os efeitos da temperatura de bulbo seco¹, temperatura radiante² e velocidade do ar - como o principal indicador de conforto. A faixa de temperatura de conforto varia de 17°C a 31°C para aceitabilidade de 80% e de 18,5°C a 30,5°C

¹É a temperatura do ar no ambiente onde está instalado o termômetro.

²A temperatura radiante varia em função da exposição do indivíduo à radiação infra-vermelha, no caso dos edifícios, o Sol.

para 90% de aceitabilidade (SUDBRACK, 2017). A representação gráfica dos limites de aceitabilidade pode ser vista na Figura 1.1.

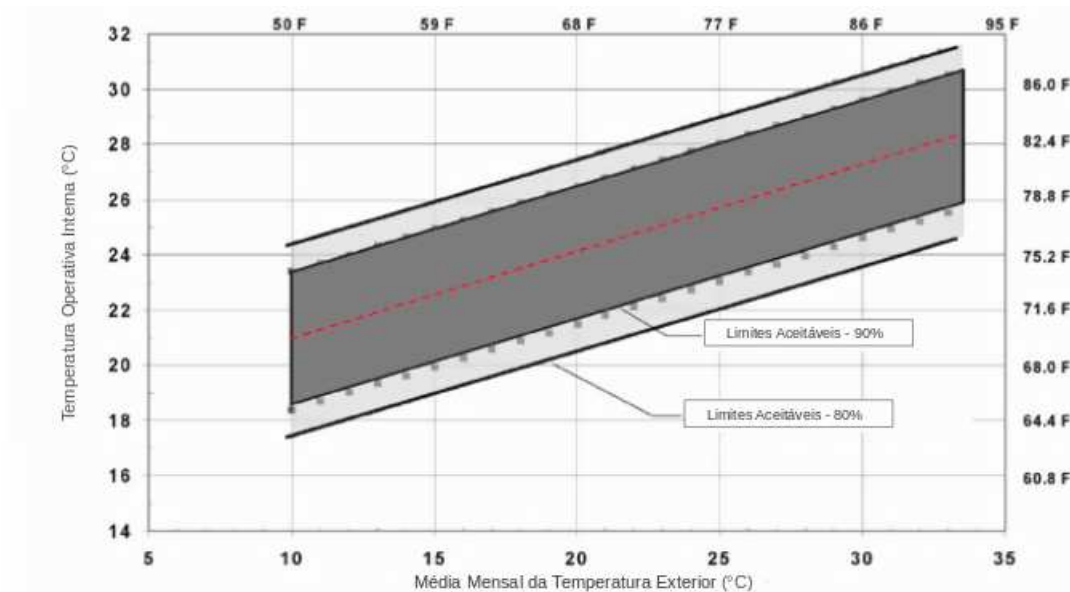


Figura 1.1: Representação gráfica dos limites de aceitabilidade descritos na norma ASHRAE 55 (2013).

Fonte: Adaptado de Sudbrack (2017)

Esse padrão prevê que a temperatura externa média mensal usada para determinar os limites aceitáveis de temperatura interna é a média simples da temperatura externa média dos últimos 30 dias. A faixa de temperatura de conforto é correlacionada com a ocorrência de temperaturas externas, permitindo a comparação entre edifícios localizados em climas diferentes (NICOL; HUMPHREYS; ROAF, 2012).

Sudbrack (2017) e Nobre (2018) identificaram as potencialidades e limitações que a tipologia residencial pré-fabricada apresenta para a construção de NZEBs no contexto climático de Brasília, levando em consideração aspectos de uso, ocupação e ventilação natural, usando a abordagem adaptativa proposta pela norma ASHRAE 55/2013. A motivação deste trabalho surge da concepção de um projeto apresentado por Nobre (2018) e, portanto, com base nessa tipologia residencial, foram inseridos novos materiais no modelo, com o objetivo de aumentar o espaço amostral, visando uma melhor aproximação com o problema real e possibilitando diferentes combinações entre os materiais para a composição da NZEB.

1.2 Justificativa

A literatura apresenta uma diversidade de trabalhos que realizaram a modelagem e a simulação de diferentes cenários com várias tipologias arquitetônicas. Contudo, as alternativas são, com frequência, testadas uma a uma, de forma separada, e os resultados referem-se à comparações dentre saídas geradas. Esse processo demanda numerosos testes e considerável tempo de execução, tornando, muitas vezes, a análise de muitas variáveis de forma simultânea, inviável. Assim, a combinação de *softwares* de modelagem energética e algoritmos de otimização tem se mostrado promissora (HARKOUSS; FARDOUN; BIWOLE, 2018; KHALID et al., 2018; ASCIONE et al., 2019).

A modificação de propriedades geométricas e de materiais da estrutura tem sido apresentada na literatura como estudos de configurações isoladas (BARBOSA; IP, 2014), não considerando a influência dessas alterações no projeto em sua totalidade, o que demanda a criação de um modelo computacional que realize análises mais complexas. Além disso, ainda existe uma carência de estudos que considerem parâmetros construtivos e projetos otimizados para NZEBs localizadas nas regiões subtropicais e tropicais.

1.3 Objetivos Gerais e Específicos

O presente trabalho possui como objetivo geral investigar o uso de algoritmos evolutivos em conjunto com *softwares* de modelagem termo energética na avaliação de parâmetros de projeto de edificações de balanço energético nulo a partir de modelos computacionais.

Os objetivos específicos que se destacam no trabalho são:

- determinar parâmetros alternativos para a edificação de balanço energético nulo e parametrizar o modelo computacional;
- aplicar métodos de otimização mono-objetivo para a seleção de materiais e características geométricas de edificações que visem um maior conforto térmico aos usuários;
- comparar os resultados obtidos pelos métodos de otimização mono-objetivo para o modelo estudado com os dados disponíveis na literatura.

2 Revisão Bibliográfica

A previsão do uso de energia em edificações possui um papel importante no manejo e conservação dos recursos naturais, auxiliando na construção de edificações mais eficientes energeticamente. Este tipo de previsão normalmente é realizada através de modelos de inteligência artificial e estratégias híbridas (WANG; SRINIVASAN, 2017). Enquanto as estratégias híbridas utilizam softwares e equações termodinâmicas para estimar o consumo de energia, estratégias baseadas em inteligência artificial utilizam dados históricos para prever o uso de energia futuro a partir de algumas restrições impostas.

2.1 Uso de Métodos de Aprendizado de Máquina

Métodos de aprendizado de máquina têm auxiliado em diversas áreas do conhecimento. Dentro do contexto de eficiência energética, variáveis geométricas e térmicas têm sido utilizadas em redes neurais para a previsão de informações sobre estruturas na área da construção civil. Tsanas e Xifara (2012) desenvolveram um *framework*³ estatístico baseado em aprendizado de máquina para estudar o efeito de oito variáveis de entrada em duas variáveis de saída, extraídas de modelos geométricos residenciais. Utilizando métodos estatísticos clássicos e não-paramétricos, a sensibilidade das variáveis de saída em relação às entradas foi estudada a fim de determinar os parâmetros mais importantes para a previsão. As variáveis de saída, que representam as cargas de aquecimento⁴ e resfriamento⁵ da edificação, foram aproximadas através de uma Regressão Linear e do modelo de Florestas Aleatórias (RF, do inglês *Random Forest*).

Árvores de Decisão (HASTIE; TIBSHIRANI; FRIEDMAN, 2009) são modelos estatísticos que utilizam um treinamento supervisionado para a classificação e previsão de dados. Constroem modelos de classificação semelhantes à estrutura de uma árvore, divi-

³Na área de desenvolvimento de software, um *framework* é uma abstração que une códigos comuns entre vários projetos provendo uma funcionalidade genérica.

⁴As cargas de aquecimento se referem à quantidade de energia térmica que precisaria ser adicionada a um espaço para manter a temperatura em uma faixa aceitável.

⁵As cargas de resfriamento se referem à quantidade de energia térmica que precisaria ser removida de um espaço para manter a temperatura em uma faixa aceitável.

dindo o conjunto de dados em subconjuntos gradativamente menores enquanto a árvore associada cresce de forma incremental, resultando em nós de decisão e folhas. O método RF (BREIMAN, 2001) executa a classificação dos dados a partir da construção de K árvores de decisão em K iterações, sendo K um parâmetro livre que pode ser determinado a partir da observação dos erros dos subconjuntos de treinamento. Regressão Linear é um tipo de análise estatística que tenta mostrar uma relação entre duas variáveis. A regressão linear analisa um conjunto de dados e plota uma linha de tendência, criando um modelo preditivo em dados aparentemente aleatórios e mostrando tendências nos dados.

A partir da definição da cidade de Atenas, Grécia como estudo de caso, as diversas configurações de edificações foram simuladas através do *software* proprietário Ecotect. Estas simulações deram origem a um banco de dados com 768 amostras, de modo que cada amostra possa ser caracterizada por oito parâmetros construtivos. A Figura 2.1 mostra alguns exemplos das geometrias simuladas por Tsanas e Xifara (2012).

As análises realizadas mostraram que a área de envidraçamento, considerado o parâmetro mais importante para a previsão das cargas de aquecimento e resfriamento, não é necessariamente o mais correlacionado com as saídas.

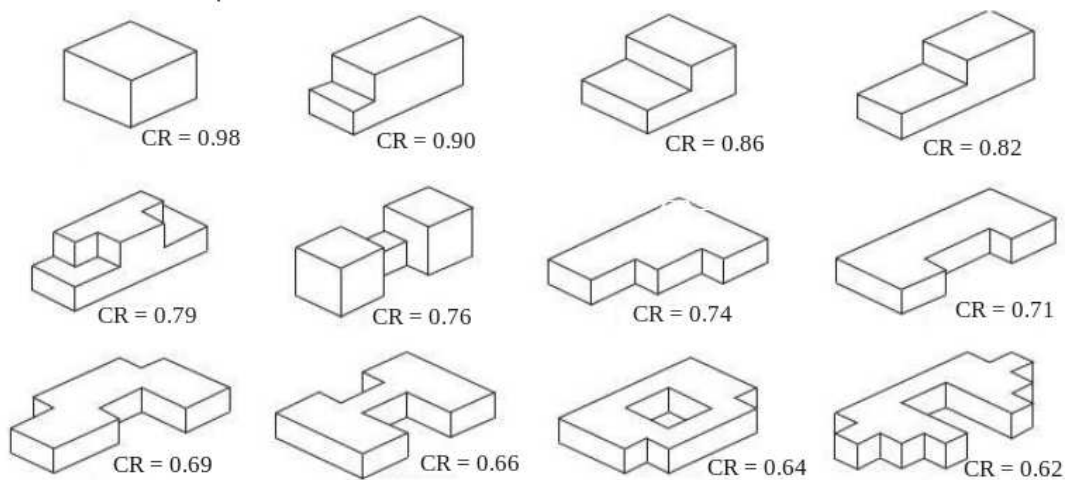


Figura 2.1: Exemplos das geometrias das edificações simuladas por Tsanas e Xifara (2012)
Fonte: Adaptado de Duarte et al. (2017).

Sajjadi et al. (2016) criaram um sistema preditivo de curto prazo para modelar as cargas de aquecimento dos consumidores que estiverem ligados ao sistema de aquecimento urbano. O sistema foi desenvolvido através da utilização do método Máquina de

Aprendizado Extremo (ELM, do inglês *Extreme Learning Machine*), com um horizonte temporal de 1 a 24 horas a frente. Os resultados foram comparados com as previsões dos modelos de Programação Genética (GP, do inglês *Genetic Programming*) e de Redes Neurais (ANN, do inglês *Artificial Neural Networks*).

Uma ANN pode ser interpretada como uma série de algoritmos que buscam relacionamentos em um conjunto de dados através de um processo que tenta reproduzir o modo de operação do cérebro humano. São tipicamente organizadas em camadas, onde estas são compostas por um número de nós interconectados que contêm uma função de ativação. Os dados são apresentados à rede através da camada de entrada, que se comunica com uma ou mais camadas ocultas, onde o processamento real é feito através de um sistema de conexões ponderadas. O modelo ELM pode ser definido como um tipo de rede neuronal sem realimentação que possui uma única camada oculta (HUANG et al., 2004), buscando balancear velocidade e desempenho na generalização.

Como um algoritmo evolutivo, o GP define como ocorre o relacionamento entre as variáveis de entrada e saída. O modelo GP pressupõe um conjunto preliminar de programas produzidos aleatoriamente, resultantes do agrupamento acidental de variáveis de entrada e funções, que incluem funções matemáticas, operadores aritméticos e funções de comparação/lógicas. Então, esse conjunto de soluções prováveis é exposto a um processo evolutivo e a aptidão dos programas evoluídos é avaliada.

Em seguida, o GP seleciona os programas com melhor desempenho na primeira população para trocar informações e desenvolver melhores programas por meio de mutação e cruzamento. Quando as melhores partes do programa são trocadas entre si, é feito o cruzamento e, quando os programas são alterados aleatoriamente para gerar novos programas, o processo é denominado mutação. Os programas com menor desempenho são eliminados e o processo evolutivo é repetido a fim de encontrar expressões representativas para o conjunto de dados estudado.

Robinson et al. (2017) utilizaram os métodos de aprendizado de máquina *Gradient Boosting* (GB), Máquinas de Vetores Suporte (SVM, do inglês *Support Vector Machines*), RF e K-vizinhos mais próximos (KNN, do inglês *K-Nearest Neighbors*) para aproximar o consumo de energia de um conjunto de edifícios comerciais. O modelo GB é classificado

como um tipo de método *ensemble*, que corresponde a combinação de vários modelos chamados *weak learners* (tipicamente árvores de decisão) para a criação de um modelo mais efetivo conhecido como *strong learner*. Este modelo possui capacidade de aumento de estabilidade da solução e redução de erros relacionados a variância, ruído e viés. A ideia geral da maior parte dos métodos do tipo *boosting* é treinar preditores sequencialmente, de modo que cada uma tente corrigir seu predecessor.

O algoritmo KNN (WU et al., 2008) realiza a classificação de uma amostra baseada nas K amostras mais próximas que possuem maior similaridade, enquanto o SVM (SHANMUGAMANI; SADIQUE; RAMAMOORTHY, 2015) combina linearmente uma série de atributos de funções *kernel*⁶ para desempenhar a classificação de amostras. Os resultados obtidos por Robinson et al. (2017) mostraram que o algoritmo GB performou como melhor preditor para a base de dados testada, com um coeficiente de determinação de 0,82. O modelo foi validado através de um conjunto de dados de consumo de energia da cidade de Nova Iorque, Estados Unidos, e testado utilizando estimativas de consumo da cidade de Atlanta, Estados Unidos. A partir dos resultados encontrados, os autores esperam poder replicar esta metodologia para diversas áreas metropolitanas nos Estados Unidos e também em outros países.

Jihad e Tahiri (2018) aplicaram modelos ANN para realizar a previsão da energia necessária em edifícios residenciais localizados na zona climática de Agadir, no Marrocos. Através de parametrização de um modelo base, foram geradas 5625 amostras de acordo com o modo de construção e uso de edificações residenciais da cidade estudada. Para testar o desempenho da rede, três edificações foram selecionadas e simuladas através do software proprietário Design Builder para calcular a demanda energética, alcançando resultados satisfatórios com acurácia de 98.7% e 97.6% para os conjuntos de treino e teste, respectivamente.

Goliatt, Capriles e Tavares (2019) utilizaram a mesma base de dados testada por (TSANAS; XIFARA, 2012) para avaliar a performance do modelo GB na previsão das cargas de aquecimento e resfriamento. Após uma busca exaustiva com validação cruzada para a busca dos parâmetros do modelo, o desempenho do modelo foi verificado através

⁶*Kernel* é um termo normalmente utilizado na área de aprendizado de máquina para se referir a um método que utiliza um modelo linear para resolver um problema não-linear.

de quatro métricas estatísticas. O modelo GB alcançou melhores resultados quando comparado com dados disponíveis na literatura, podendo vir a contribuir em fases iniciais de projetos da área de construção civil para a previsão de cargas térmicas a partir de parâmetros geométricos.

2.2 Aquisição de dados a partir de sensores

As vedações externas do edifício governam a transferência de calor entre o ambiente externo e o interno, influenciando diretamente no consumo de energia para aquecimento e resfriamento. Kinnane e Prendergast (2014) realizaram um estudo experimental e computacional em uma fachada dupla instalada em uma edificação comercial em Dublin, Irlanda. A fachada dupla tem ganhado reconhecimento como uma solução de projeto com potencial de melhorar o desempenho termo-energético de edificações tanto em climas quentes, quanto frios.

Kinnane e Prendergast (2014) tinham como objetivo identificar parâmetros arquitetônicos determinantes em fachadas duplas, através de monitoramento constante do fluxo de ar na fachada com o uso de sensores. O emprego de modelos de dinâmica dos fluidos combinados com dados experimentais permitiram a Kinnane e Prendergast (2014) concluir que fachadas duplas podem atuar como estratégias para a melhora do conforto térmico na edificação. Porém, esta estratégia arquitetônica necessita de atenção na fase de projeto, pois deve diminuir a perda de calor em períodos frios e não causar um aquecimento excessivo em períodos quentes.

A alta incidência solar nas fachadas leste e oeste de edifícios nos locais de clima tropical na Malásia causa um aumento excessivo na temperatura interior. Por conta disso, Qahtan (2019) realizou um estudo para investigar a efetividade de uma fachada dupla no controle do ganho de calor quando exposta a radiação solar direta na direção oeste da Malásia. O estudo foi conduzido em um edifício com fachada dupla, certificado como eficiente energeticamente. A Figura 2.2 apresenta a edificação localizada na Malásia e estudada por Qahtan (2019).

Sensores foram posicionados no interior e exterior da edificação para a captura de temperaturas do ar, de superfícies, radiação solar e velocidades do ar durante o período




Figura 2.2: Edificação localizada na Malásia e estudada por Qahtan (2019). A imagem (a) apresenta o exterior do edifício e (b) o interior da fachada dupla.

Fonte: Qahtan (2019)

de solstício de verão. Os resultados indicaram a fachada dupla como uma estratégia efetiva para o controle do ganho de calor da edificação, pois foi observada uma diferença significativa nas temperaturas externas em internas. Apesar dos resultados promissores, a fachada dupla foi inadequada para a proteção do interior da edificação da radiação solar direta (QAHTAN, 2019). Isto se deve pelo uso de uma superfície envidraçada, sendo necessários mais estudos neste campo, que levem em consideração a aplicação de outros materiais na constituição de fachadas duplas.

A partir do uso de dados de sensores, Jain et al. (2014) monitoraram e posteriormente analisaram a eficácia de um algoritmo na previsão do consumo em unidades residenciais. O algoritmo foi responsável pela busca de padrões de consumo e relações entre características específicas e níveis de ocupação nas diferentes unidades residenciais para a aproximação de um método preditivo mais abrangente e eficaz. O modelo desenvolvido para a análise dos dados de sensores foi baseado em SVM (SCHOLKOPF; SMOLA, 2001). A validação e teste ocorreram com o uso de um conjunto de dados empíricos, sendo desempenhada uma avaliação do impacto da granularidade dos dados nas escalas temporal e espacial.

2.3 Aplicações em NZEB

O aumento da eficiência energética e melhora da performance ambiental das edificações são considerados objetivos de grande importância para uma melhora da qualidade de

vida dos cidadãos e preservação do meio ambiente (PÉREZ-LOMBARD; ORTIZ; POUT, 2008; WANG; SRINIVASAN, 2017; QAHTAN, 2019). Dentro deste contexto, AlAjmi, Abou-Ziyan e Ghoneim (2016) estuda a possibilidade de se converter um edifício público, ineficiente em relação ao consumo de energia, em um NZEB.

Através de considerações sobre o custo da energia e integração de sistemas de energia solar, AlAjmi, Abou-Ziyan e Ghoneim (2016) sugerem três cenários para a edificação. Os cenários propõem a utilização de sistemas fotovoltaicos, substituição dos refrigeradores por equipamentos mais eficientes energeticamente e a combinação das duas estratégias anteriores. O uso de sistemas fotovoltaicos atinge o balanço energético próximo de zero considerando uma base anual, enquanto a estratégia de troca do sistema de refrigeradores e sua combinação com as placas de energia solar atingem este balanço tanto na base mensal quanto na anual. A implementação do último cenário resultou em expressiva economia de energia e diminuição das emissões anuais de CO₂.

Kneifel e Webb (2016) propõem o uso de um modelo estatístico de regressão multivariada para prever o consumo energético de uma NZEB. A aplicação de modelos de regressão pode vir a reduzir o número de simulações e o trabalho de modelagem de edificações com características distintas. A partir de um conjunto de dados temporais coletados, o modelo foi treinado e utilizado para prever a performance energética de um conjunto de dados hipotético. Os resultados foram comparados com simulações realizadas no *software* EnergyPlus. O modelo treinado não alcançou resultados satisfatórios para a previsão do consumo, sendo necessário o teste de métodos mais complexos na base de dados utilizada, assim como o aperfeiçoamento do modelo utilizado.

Colaborações entre NZEBs, como o compartilhamento de energias renováveis, podem melhorar o desempenho destas edificações em um nível de comunidade. Porém, para que estas colaborações sejam possíveis, as NZEBs precisam ser agrupadas de acordo com suas características relacionadas ao consumo energético. Devido a larga diversidade de características energéticas e a complexidade do acompanhamento do uso diário das edificações, o agrupamento que maximiza os benefícios advindos da colaboração se torna uma tarefa difícil (HUANG; SUN, 2019).

Huang e Sun (2019) propõem um método baseado em agrupamento para melhorar

o desempenho de um conjunto de NZEBs. Utilizando dados obtidos em campo, o método identifica características representativas em relação ao uso de energia. A partir destas características, o algoritmo procura agrupamentos que apresentem uma performance ótima de colaboração. Para validação, o agrupamento proposto foi comparado com dois casos: residências sem agrupamento e randomicamente agrupadas. Os resultados demonstraram que o método proposto pode efetivamente melhorar a atuação das NZEBs em um nível de comunidade e pode vir a auxiliar na tomada de decisão e planejamento em comunidades formadas por residências de balanço energético nulo. O uso de um sistema deste tipo pode vir a significar um aumento do aproveitamento da energia gerada por vias sustentáveis e renováveis,

2.4 Otimização através de Estratégias Evolutivas

Sistemas ativos para a manutenção do conforto térmico são os principais responsáveis pelo consumo de energia em edificações (RODRIGUEZ-UBINAS et al., 2014). Estratégias passivas têm contribuído para a melhora das condições de conforto, aumentando a eficiência em edificações e reduzindo seu consumo energético. Neste cenário, algoritmos de otimização têm sido aplicados para a simulação de configurações de edificações de forma automatizada. Otimização é a busca da melhor solução para um dado problema, consistindo em tentar várias soluções e utilizar a informação obtida neste processo de forma a encontrar soluções cada vez melhores.

Ferrara et al. (2014) realizaram simulações de uma residência familiar localizada na França, propondo um método que visa diminuir o número de modelos computacionais a serem construídos de forma manual. O método combina o uso do *software* de simulação energética dinâmica TRNSYS e o GenOpt, ferramenta de otimização. A edificação utilizada como referência possui um baixo consumo energético, e o algoritmo de otimização por enxame de partículas (PSO, do inglês *Particle Swarm Optimization*) utilizado como técnica para encontrar a combinação de parâmetros mais adequada para a estrutura de acordo com a função objetivo utilizada.

O método PSO foi proposto por Eberhart e Kennedy (1995) e consiste em uma busca constante da melhor solução a partir do movimento das partículas com uma velo-

cidade calculada a cada iteração. A partir da execução do método iterativo, o resultado esperado é a convergência para a melhor solução dentro espaço de busca. Apesar da execução da técnica de otimização e, conseqüentemente, o teste de diversos modelos da residência, Ferrara et al. (2014) concluíram que o ótimo absoluto não foi alcançado. O estudo demonstrou que existem diversos fatores que influenciam na otimização de NZEBs, considerando o quadro regulamentar para este tipo de edificação.

Ascione et al. (2015) propôs uma metodologia para a otimização de custos através do uso de um algoritmo de otimização multi-objetivo. O processo de otimização ocorreu através do acoplamento do *software* de simulação termo-energética EnergyPlus e do *software* proprietário MatLab. Um algoritmo genético foi implementado, e as funções objetivo utilizadas consideraram o consumo energético da edificação e o conforto térmico interno. Variáveis de projeto, como o tipo de janelas, de vidros, de aquecedores e refrigeradores, e variáveis relacionadas ao uso da edificação foram modificadas durante o processo iterativo.

Os algoritmos genéticos são métodos de otimização e busca, que foram inspirados nos mecanismos de evolução de populações de seres vivos. Eles seguem o princípio de seleção natural e sobrevivência do mais apto. Uma edificação existente em Nápoles, Itália, foi utilizada como estudo de caso. A partir da execução do processo evolutivo, algumas ações foram listadas como prioritárias para intervenção, considerando as características que mais influenciaram no método de otimização. A possibilidade da aplicação deste método em edificações ainda em fase de projeto vem sendo estudada por Ascione et al. (2019), assim como seu emprego em outras construções já existentes e que apresentem restrições no orçamento para reformas.

O algoritmo de otimização por colônia de abelhas também tem sido utilizado em estudos relacionados a performance energética de edificações. O Algoritmo Colônia de Abelhas Artificiais (ABC, do inglês *Artificial Bee Colony*) é um algoritmo bio-inspirado proposto por Teodorovic e Dell’Orco (2005) para a resolução de problemas de otimização multimodais e multidimensionais. O fenômeno natural que inspirou o desenvolvimento do ABC foi o comportamento inteligente observado em colônias de abelhas, mais especificamente no forrageamento⁷. O ABC foi proposto inicialmente para ser aplicado na

⁷Forrageamento é a busca e a exploração de recursos alimentares. É uma habilidade importante, pois afeta a aptidão do animal, influenciando diretamente a sobrevivência e a reprodução do organismo.

resolução de problemas sem restrições.

Delgarm, Sajadi e Delgarm (2016) propõem o uso da versão multi-objetivo do ABC, implementada no MatLab, para a otimização de um escritório. Dentre os parâmetros construtivos a serem otimizados, estão: a rotação do escritório, o tamanho das janelas e as temperaturas limite para a ativação dos sistemas de aquecimento e resfriamento. Os critérios utilizados na otimização foram o consumo elétrico anual e o percentual previsto de insatisfação relacionado ao conforto térmico.

As simulações de Delgarm, Sajadi e Delgarm (2016) foram realizadas em quatro diferentes regiões climáticas do Irã, e os resultados da minimização comparados com o modelo base e com a estratégia mono-objetivo. Os resultados mostraram que a estratégia multi-objetivo foi mais adequada para os modelos testados, pois sua melhor solução apresentou o menor desvio em relação a solução ótima conhecida. Os resultados também indicaram que um aumento de cerca de 9% no consumo de energia anual reflete em uma diminuição no percentual de insatisfação de cerca de 8%.

Li, Wang e Cheung (2018) analisou os impactos de parâmetros construtivos na otimização de uma NZEB localizada em uma região de clima subtropical. Através da proposição de uma técnica que combina análise de sensibilidade dos parâmetros e otimização estrutural, um novo objetivo de otimização foi apresentado. Este leva em consideração o consumo anual de energia e o desconforto térmico no inverno, para edificações sem sistema de aquecimento. Uma análise de sensibilidade em vários estágios identificou os principais parâmetros construtivos para a execução da fase de otimização. A minimização das funções objetivo foi realizada através de um Algoritmo Genético.

Como estudo de caso, Li, Wang e Cheung (2018) utilizaram um edifício localizado em Hong Kong, China, com o objetivo de implementar o método proposto e demonstrar sua efetividade. Os resultados demonstraram que a consideração do desconforto térmico no inverno afeta a análise de sensibilidade de forma significativa, e que os parâmetros tipo de telhado e absorvância solar das paredes possuem grande importância no modelo. A inclusão de painéis fotovoltaicos, assim como sua interação com o algoritmo de otimização é indicada como trabalho futuro, pois pode vir a afetar algumas configurações do modelo.



Figura 2.3: Edifício localizado em Hong Kong utilizado como estudo de caso por Li, Wang e Cheung (2018).

Fonte: Li, Wang e Cheung (2018)

3 Material e Métodos

3.1 *Software* de Modelagem Termo-Energética

O *software* de código aberto EnergyPlus é um sistema multiplataforma que implementa modelos de fenômenos de transporte. Permite a simulação do consumo de energia em processos de aquecimento, resfriamento e ventilação, além de estimar o uso de água e o fluxo de ar em edificações.

O programa utiliza arquivos climáticos no formato .epw para a caracterização do clima da localidade de interesse, onde são consideradas informações levantadas durante 10 anos relacionadas à velocidade dos ventos, periodicidade de chuvas, temperaturas máximas e mínimas diárias, dentre outros. O modelo geométrico é convertido em um arquivo de texto no formato .epw para ser utilizado como de dado de entrada no EnergyPlus e, após a execução da simulação, as saídas são escritas em arquivos nos formatos .sql, .html, .eso, dentre outros, que são utilizados para a análise do comportamento termo energético do edifício.

3.2 Modelo NZEB

O modelo utilizado neste trabalho foi baseado em Sudbrack (2017) e Nobre (2018), consistindo em uma habitação modular pré-fabricada de 108m² composta por cozinha, sala, banheiro, três quartos (uma suíte) e varanda. A residência localiza-se em um terreno de 700m² em um condomínio residencial a sudeste do Plano Piloto - Condomínio Santa Mônica - em Brasília/DF.

A residência é ocupada por uma família de 4 pessoas, sendo um casal e duas crianças. No período de 9h às 12h o modelo assume a presença de duas pessoas na edificação; De 13h às 19h, três pessoas e a partir de 19h 4 pessoas. Todos os residentes ocupam a sala de estar/cozinha. O quarto 1 possui ocupação máxima de duas pessoas e os quartos 2 e 3 acomodam uma pessoa em cada. Vale ressaltar que o modelo não

considerou os períodos em que a casa estaria vazia. Os residentes utilizam iluminação artificial apenas em 30% das horas diárias. Uma vez que os banheiros são ambientes com permanência reduzida dos ocupantes, foi estabelecida apenas 1 hora de uso de iluminação artificial.

Com o objetivo de realizar a previsão do consumo de energia e das cargas térmicas da edificação, um consumo padrão para os equipamentos elétricos foi definido em cada cômodo: na cozinha, fogão de indução, forno, geladeira, lavadora e secadora, lava-louças e televisão; no quarto 2, um computador. Foi estimada uma potência igual a 50W devido à iluminação LED para cada quarto.

Por se tratar de uma casa pré-fabricada, com montagem facilitada em diversas configurações de terreno e orientação, adotou-se a orientação oeste para a fachada com uma porcentagem maior de aberturas envidraçadas e ângulos de proteção mais baixos, o que corresponde à pior direção (azimute 0°). Esta consideração garante que, independente da direção em que a residência for construída, o desempenho térmico será melhor ou igual ao do modelo simulado neste trabalho. A Figura 3.1 apresenta o modelo construtivo da NZEB utilizado para a execução da simulação termo energética.




Figura 3.1: Modelo tridimensional da casa de balanço energético nulo.
Fonte: O Autor.

Brises foram inseridas no modelo para atenuar o efeito da incidência solar nas superfícies envidraçadas. As duas superfícies planas presentes no telhado do modelo da casa, mostrada na Figura 3.1, simulam o efeito de sombreamento causado pelos painéis fotovoltaicos a serem instalados na residência.

As simulações foram realizadas utilizando o arquivo climático no formato .epw

(INMET, 2016) para a cidade de Brasília (Latitude 15° 46 '48' 'Sul, Longitude 47° 55 '45' Oeste). Os arquivos possuem dados horários, registrados em estações climatológicas do Instituto Nacional de Meteorologia (INMET) entre os anos de 2000 e 2010, e apresentam informações para as 8760 horas do ano, permitindo uma avaliação horária mais precisa nas simulações.

Para a simulação da ventilação natural, um dos parâmetros relevantes é a área efetiva de ventilação, que permite a troca de ar entre o ambiente interno e o exterior da residência. Para a porta de vidro que liga a cozinha ao ambiente externo e para as outras portas internas da casa, foi utilizada uma área ativa de 50% quando aberta. Para as portas de correr envidraçadas que ligam a sala de estar com o ambiente externo, divididas em quatro painéis de vidro, a área efetiva considerada foi de 75% quando aberta. Foi considerada uma área efetiva de 100% para as janelas dos quartos e 50% para a janela do banheiro.

3.3 Parâmetros de Projeto

Objetivando a busca de soluções que minimizem o número de horas de desconforto, um conjunto de parâmetros de projeto foi selecionado para que as propriedades dos materiais e características geométricas da residência fossem modificadas. A Tabela 3.1 apresenta as variáveis escolhidas empiricamente para a simulação de diferentes cenários e otimização via PSO. No caso das paredes e telhado, a composição dos materiais foi alterada com o objetivo de avaliar o desempenho da simulação quando combinações de materiais são utilizados. A Figura 3.2 apresenta um exemplo de telhado verde. Este tipo de cobertura utiliza diferentes camadas em sua estrutura. Cada camada possui uma função e resulta na sinergia da captação da água da chuva e do calor do Sol no sistema como um todo, mantendo assim a vida da terra e das plantas.

Em relação a composição das paredes, três tipos de bloco foram utilizados: cerâmico, concreto e de solo-cimento. Os tipos de argamassa foram: tradicional, celular e gesso. Para o telhado, o algoritmo evolucionário considerou quatro possibilidades, sendo estas: madeira laminada cruzada, laje de concreto sólido, laje de concreto armado e telhado verde. No caso da laje de concreto sólido, a espessura foi incluída como um




Figura 3.2: Ilustração das camadas que podem ser utilizadas para constituir um telhado verde.

Fonte: Stahlhöfer e Pereira (2013)

Tabela 3.1: Parâmetros de projeto utilizados para a geração das simulações dos diferentes cenários.

Posição	Descrição	Conjunto de Parâmetros
x_0	Tipo de Bloco	0: Cerâmico; 1: Concreto; 2: Solo-cimento
x_1	Espessura do Concreto	0: 0,08; 1: 0,10; 2: 0,12 m
x_2	Tipo de Argamassa	0: Tradicional; 1: Gesso; 2: Celular
x_3	Aumento nas Portas	0: 0,00; 1: 0,05; 2: 0,1; 3: 0,15; 4: 0,2; 5: 0,25; 6: 0,3 m
x_4	Aumento nas Janelas	0: 0,00; 1: 0,05; 2: 0,10; 3: 0,15 m
x_5	Tipo de Telhado	0: Madeira Laminada Cruzada; 1: Laje de Concreto Sólido; 2: Laje de Concreto Armado; 3: Telhado Verde

parâmetro extra no processo de otimização, sendo considerado quando o algoritmo seleciona a laje de concreto sólido como telhado da edificação. Informações sobre a composição dos telhados e propriedades dos materiais utilizados podem ser consultadas nas tabelas presentes no Anexo A.

Para as janelas e portas externas, o aumento no comprimento objetiva testar o impacto da entrada de luz e circulação de ar na estrutura modelada. No caso das janelas,

quatro valores possíveis para o aumento foram distribuídos no intervalo $[0, 0.15m]$ e para as portas, sete valores possíveis foram distribuídos no intervalo $[0, 0.3m]$ para realização dos testes.

3.3.1 Seleção Evolucionária de Parâmetros

PSO é um método estocástico de pesquisa baseado em populações, inspirado no comportamento social de animais, como pássaros e peixes. No PSO, cada indivíduo, chamado de partícula, percorre o espaço de busca do problema e ajusta sua posição de acordo com sua própria experiência e a experiência de seus vizinhos. Uma partícula pode mover-se rapidamente e longe das melhores posições para explorar áreas desconhecidas (pesquisa global) ou muito lentamente e perto de uma posição específica (ajuste fino) para encontrar melhores resultados. Cada partícula tem uma posição virtual que representa uma possível solução para algum problema de minimização. O PSO é bastante simples de implementar e possui poucos parâmetros de controle. As duas regras fundamentais de atualização do PSO padrão são apresentadas na Equação 3.1.

$$\begin{cases} v_i(t+1) = \omega v_i(t) + c_1 r_1 (p_i(t) - x_i(t)) + c_2 r_2 (p_g(t) - x_i(t)) \\ x_i(t+1) = x_i(t) + v_i(t+1) \end{cases} \quad (3.1)$$

onde v_i e x_i são vetores de velocidade e posição da partícula i , respectivamente, p_i é a melhor posição local encontrada pela partícula i e p_g é a melhor posição global encontrada em toda a população. Os parâmetros c_1 e c_2 são constantes positivas, chamadas fatores de aprendizado; c_1 representa o quanto uma partícula é atraída para sua melhor posição e c_2 representa a atração da partícula para a posição global. Os valores desses dois parâmetros podem variar dependendo da natureza do problema, mas geralmente são considerados iguais a 2,0; ω é o peso de inércia, que determina a taxa de contribuição da velocidade anterior de uma partícula para sua velocidade no passo atual; r_1 e r_2 são variáveis aleatórias uniformes, fornecendo o aspecto estocástico do algoritmo.

Neste artigo, cada partícula codifica uma solução candidata para o modelo testado. Considerando a abordagem PSO, o objetivo é encontrar um cenário que minimize

horas desconfortáveis na NZEB.

O algoritmo PSO foi utilizado em associação com o software EnergyPlus para procurar cenários que minimizassem as horas desconfortáveis dentro da NZEB. Usando a média geométrica dos valores das horas de desconforto em cada cômodo como função objetivo (Equação 3.2), tentou-se obter uma homogeneidade de tempo desconfortável em cada cômodo da casa. Essa estratégia evita a ocorrência de grandes períodos desconfortáveis em um cômodo em vantagem de outros.

$$F = \left(\prod_{i=1}^n x_i \right)^{\frac{1}{n}} = \sqrt[n]{x_1 x_2 \cdots x_n} \quad (3.2)$$

onde x_i representa os valores das horas de desconforto e n o número de cômodos.

Inicialmente, o arquivo de extensão .idf do modelo geométrico foi parametrizado, permitindo que determinadas seções do arquivo fossem modificadas usando um *script*, sem comprometer a sintaxe reconhecida pelo EnergyPlus. Após modificar o arquivo .idf, o script utiliza o EnergyPlus para executar a simulação do modelo termo-energético e analisa os arquivos de saída para extrair os limites aceitáveis. Assim, foi possível utilizar o PSO para otimizar os parâmetros do modelo descritos na Tabela 3.1, atuando na geração de cenários e análise da função objetivo. A Figura 3.3 apresenta o fluxo de dados no algoritmo que avalia e simula as combinações de parâmetros de projeto.

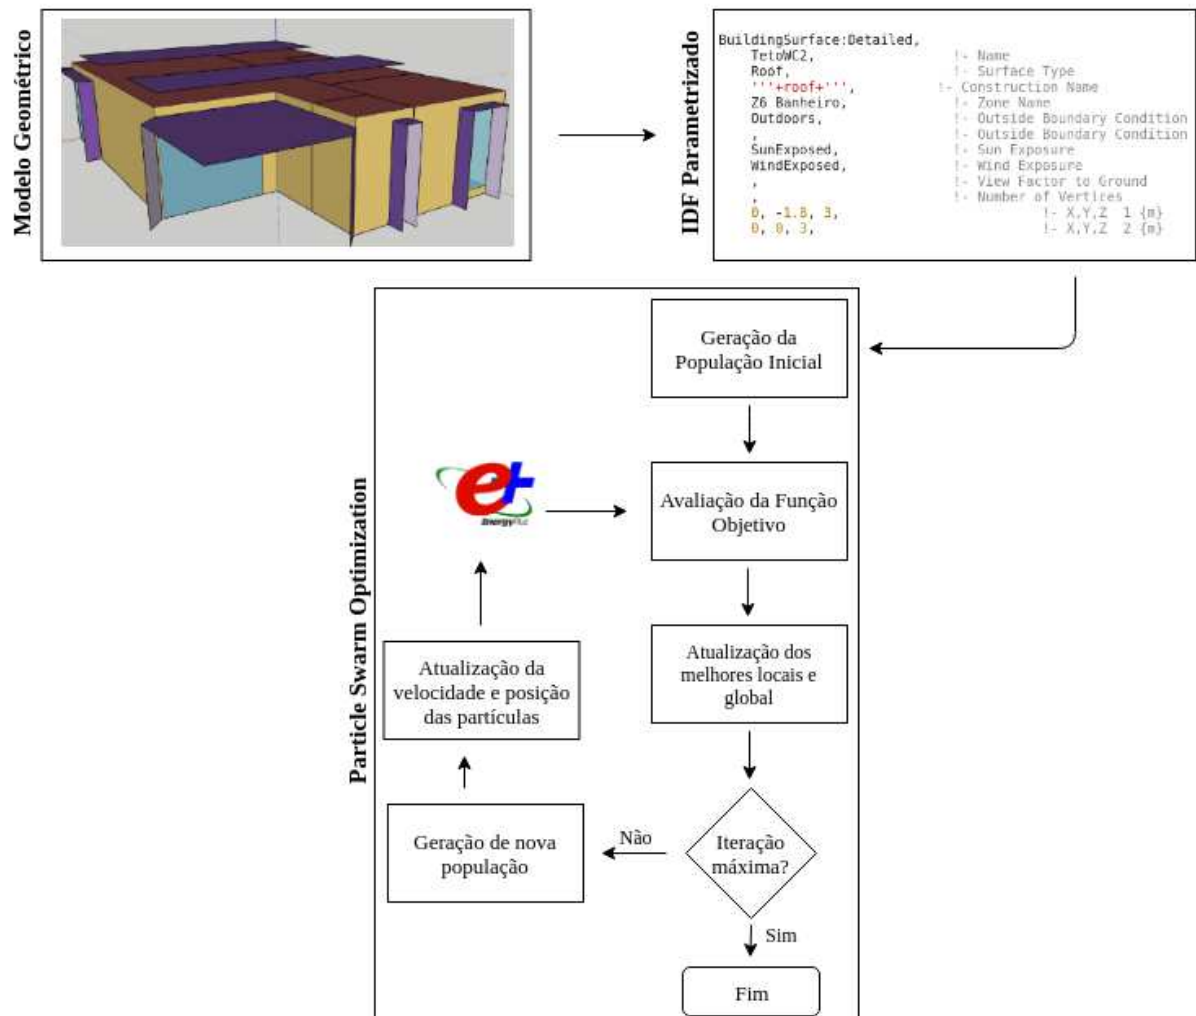


Figura 3.3: Fluxo de dados do modelo .idf em conjunto com o algoritmo PSO.
Fonte: O Autor.

4 Resultados e Discussão

Nesta seção, são apresentados os resultados obtidos para a minimização de horas desconfortáveis no modelo NZEB descrito na Seção 3.2. Cada experimento computacional foi executado 30 vezes de forma independente. Na etapa de seleção do modelo, o PSO foi definido com os seguintes parâmetros: 15 indivíduos na população evoluindo em 35 gerações; os parâmetros c_1 , c_2 foram definidos como 2,05 de forma empírica; $\omega = 0,7298$ para todas as gerações; a função objetivo (a ser minimizada) é a média geométrica dos limites de aceitabilidade calculados utilizando o *software* EnergyPlus. O espaço de parâmetros utilizado no PSO é mostrado na Tabela 3.1.

Os experimentos computacionais foram conduzidos com base no framework PyGMO (IZZO, 2012) e implementações adaptadas de Hastie, Tibshirani e Friedman (2009). O computador utilizado para a execução dos experimentos possui as seguintes configurações: Processador AMD Opteron 6272 (32 núcleos de 2,1 GHz e memória cache de 2 MB), memória RAM de 250 GB e sistema operacional Linux Ubuntu 14.04.4 LTS.

As Figuras 4.1 e 4.2 apresentam as frequências das escolhas do algoritmo evolutivo para os parâmetros construtivos utilizados neste trabalho ao longo das 30 execuções independentes. Para a argamassa utilizada para revestimento das paredes do modelo NZEB (Figura 4.1 (a)), o tipo tradicional apresentou melhor desempenho em todas as execuções. Situação semelhante ocorreu com a distribuição de frequências do tipo de bloco (Figura 4.1 (b)), pois o bloco de concreto foi selecionado em 28 de 30 execuções, indicando que é uma escolha mais adequada para a construção de paredes de alvenaria quando comparada com blocos de cerâmica e solo-cimento quanto se trata de análise de conforto térmico.

A Figura 4.1 (c) indica que o uso de madeira laminada cruzada ou telhado verde é mais eficiente quando objetivamos minimizar as horas de desconforto, atingindo frequências de 16 e 14, respectivamente. Embora a madeira laminada cruzada tenha sido selecionada em pouco mais da metade do número total de execuções, o uso do telhado verde pode trazer benefícios fora de casa, tanto arquitetônicos quanto ambientais.

De acordo com os resultados obtidos, o tamanho original das janelas do modelo

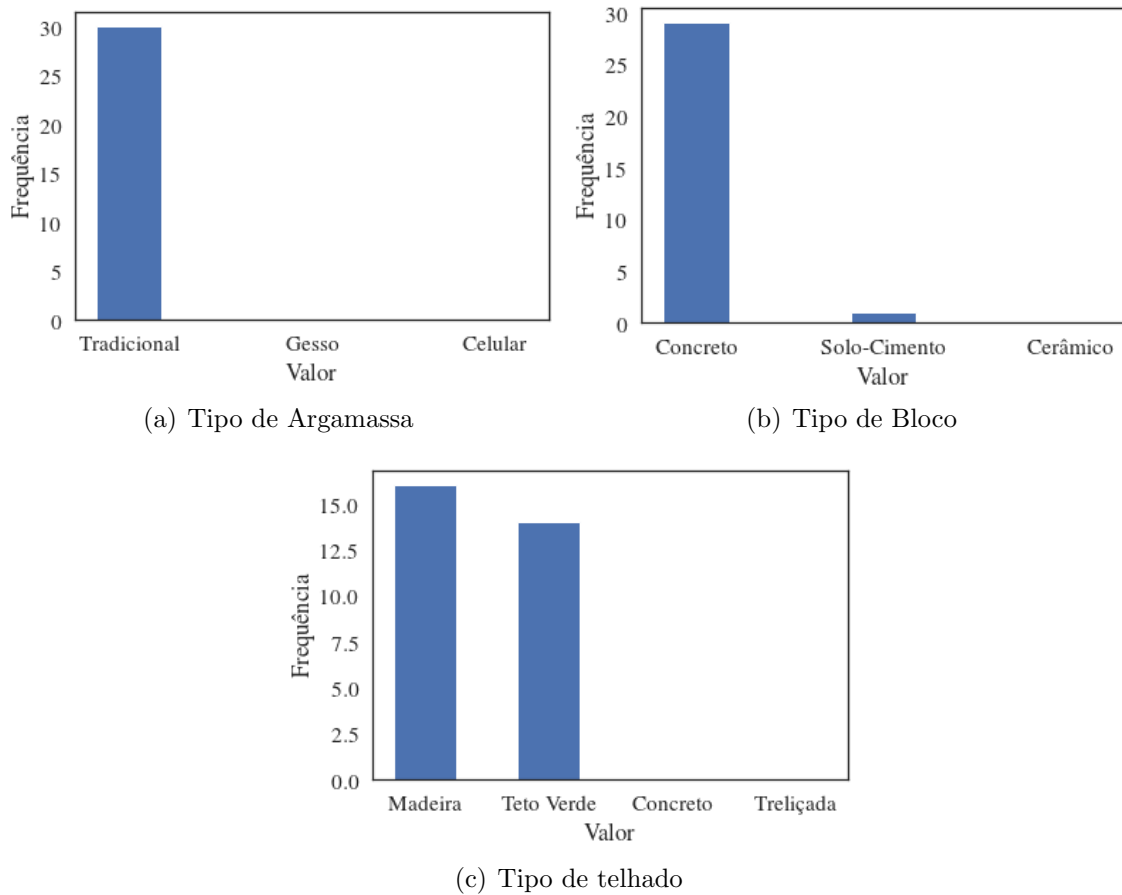


Figura 4.1: Frequências das escolhas do algoritmo evolutivo para os tipos de argamassa, bloco e telhado.

Fonte: O Autor.

era adequado, pois, como pode ser visto na Figura 4.2 (a), o algoritmo retornou uma quantidade maior de soluções que não propõem o aumento do tamanho das janelas, com frequência de 26 em 30 execuções. Para as portas (Figura 4.2 (b)), as frequências mais altas ocorreram com a adição de 5 cm e 15 cm em cada lado do componente, indicando que o aumento da entrada de luz e circulação de ar na NZEB a partir das portas pode vir a diminuir nas horas de desconforto.

Para o modelo estudado, o PSO convergiu para o valor da função objetivo 56,15 a partir da 14^a geração (Figura 4.3). A Figura 4.4 mostra os boxplots das horas desconfortáveis anuais nos cômodos da NZEB e a Tabela 4.1 as estatísticas descritivas. A Sala/Cozinha apresentou a maior mediana, seguida pelo Quarto 2, Quarto 3, e Quarto 1, onde houve a ocorrência da menor mediana. Em relação a variabilidade, ao longo das 30 execuções independentes, no cômodo Sala/Cozinha os valores das horas de desconforto apresentaram maior variação, seguido pelo Quarto 2, onde houve a segunda maior varia-

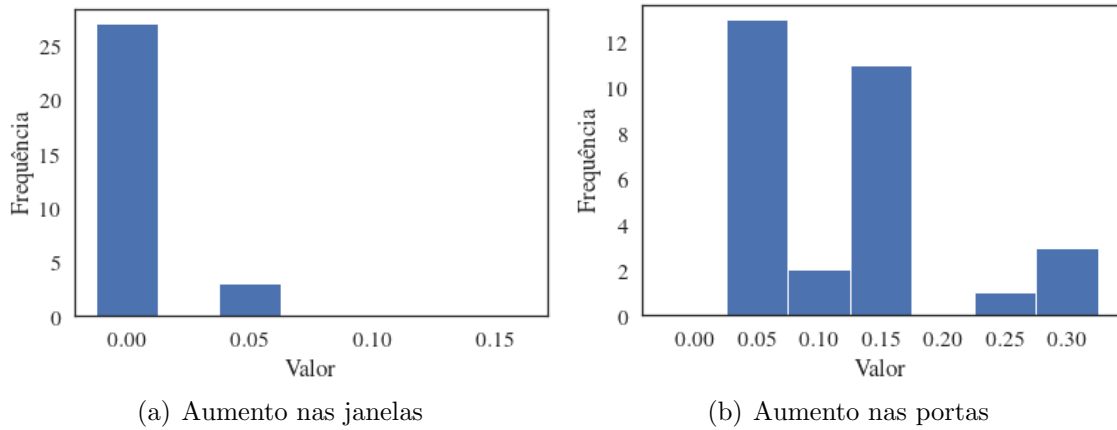


Figura 4.2: Frequências das escolhas do algoritmo evolutivo para incrementos de janelas e portas.

Fonte: O Autor.

bilidade. Estes dois cômodos obtiveram distribuições assimétricas a direita. Os Quartos 3 e 4 não apresentaram variabilidade e a maior quantidade de *outliers* ocorreu no Quarto 2.




Figura 4.3: Gráfico de convergência da função objetivo (F) ao longo das 35 iterações do PSO.

Fonte: O Autor.

Tabela 4.1: Estatísticas descritivas dos valores das horas desconfortáveis em cada cômodo da NZEB ao longo das 30 execuções.

Cômodo	Mínimo	Mediana	Máximo	Média	Desvio Padrão
Quarto 1	1,00	1,00	5,00	1,10	0,38
Quarto 2	469,00	483,00	564,00	481,00	12,22
Quarto 3	32,00	37,00	53,00	35,41	2,71
Sala/Cozinha	573,00	618,00	722,00	609,00	31,79

Fonte: O Autor.

Considerando os materiais e configurações com frequências mais altas em cada um




Figura 4.4: Boxplots das horas desconfortáveis anuais nos cômodos da NZEB ao longo das 30 execuções.

Fonte: O Autor.

dos parâmetros, a configuração que apresentou o menor valor de função objetivo tem em sua composição: argamassa tradicional, blocos de concreto, madeira laminada cruzada, janelas em seu tamanho original e um aumento de 5 cm nas portas. A Tabela 4.2 apresenta os valores de horas de desconforto em cada cômodo para o melhor cenário retornado pelo PSO e o erro relativo (ER) em relação ao trabalho desenvolvido por Nobre (2018). Considerando a média geométrica como função objetivo, foi alcançada uma melhoria de 27% em comparação ao modelo base desenvolvido por Nobre (2018). Para todos os cômodos, foi alcançada uma redução nas horas de desconforto a partir da alteração dos parâmetros construtivos.

Tabela 4.2: Comparativo entre horas de desconforto térmico para o melhor cenário retornado pelo PSO e o modelo de referência.

	Nobre (2018) (horas)	PSO (horas)	Ganho de Desempenho Relativo
Função Obj.	77,88	56,15	-27%
Quarto 1	3	1	-67%
Quarto 2	488	469	-4%
Quarto 3	41	37	-10%
Sala/Cozinha	613	573	-6%

Fonte: O Autor.

5 Conclusões

Após o término da análise realizada pelo PSO, é possível concluir que o algoritmo apresentou resultados satisfatórios na busca de combinações mais eficientes em termos energéticos, apresentando uma redução nas horas de desconforto de até 27%. Além disso, em todos os cômodos da casa, houve uma diminuição das horas desconfortáveis, confirmando que as alterações de parâmetros do modelo foram eficazes para a melhora do conforto térmico no interior da residência. A partir deste resultado não podemos afirmar que foi encontrada a melhor combinação disponível para esta habitação, pois, de acordo com o funcionamento do algoritmo evolutivo, apenas algumas combinações de parâmetros foram contempladas considerando todo o espaço de busca. No entanto, pode-se considerar que estudos como esse permitem a previsão de melhores cenários em termos de conforto térmico, disponibilizando uma análise prévia do comportamento da estrutura perante a otimização de parâmetros de projeto.

O estudo pode vir a auxiliar na seleção de parâmetros de projeto que reduzam e contribuam para a tomada de decisões mais rápidas e assertivas para edificações ainda em fase de projeto, trazendo economia de recursos. Embora em alguns casos os materiais a serem utilizados podem possuir custos mais elevados em relação aos tradicionalmente empregados, esse investimento pode ser compensado com o tempo, pois com o aumento do conforto natural na edificação, o uso de equipamentos elétricos pode diminuir, reduzindo desta forma o consumo de energia.

Como trabalhos futuros, propõe-se a comparação dos resultados obtidos com outras estratégias evolutivas, observando as características de cada algoritmo para a determinação dos mais adequados para este tipo de estudo. Além disso, o uso de modelos de dinâmica caótica é proposto para introduzir diversidade na população ao longo das iterações e assim, analisar a ocorrência de convergência prematura da função objetivo. Outro ponto interessante a ser desenvolvido é a implementação de métodos de otimização multiobjetivo, com o objetivo de capturar alterações no modelo através da inserção de outros parâmetros de projeto e otimização simultânea de funções objetivo relacionadas

também a iluminação e gasto energético. A função objetivo multiplicativa apresentará problemas caso sejam calculadas zero horas de desconforto em determinado cômodo, pois o resultado da análise será sempre zero e inviabilizará o uso do algoritmo evolutivo. Para a resolução de tal situação, é proposto o teste de outras tipos de função objetivo, como por exemplo utilizando a norma de Frobenius.

Bibliografia

- ABNT, N. 15220-3: Desempenho térmico de edificações. *Rio de Janeiro*, 2005.
- ABNT, N. 15575: Edificações habitacionais–desempenho. *Rio de Janeiro*, 2013.
- AELENEI, D.; AELENEI, L.; GONÇALVES, H. Edifícios de balanço energético nulo: uma síntese das características principais. *Revista Edifícios e Energia*, p. 70–74, 2013.
- ALAJMI, A.; ABOU-ZIYAN, H.; GHONEIM, A. Achieving annual and monthly net-zero energy of existing building in hot climate. *Applied energy*, Elsevier, v. 165, p. 511–521, 2016.
- ASCIONE, F. et al. Building envelope design: Multi-objective optimization to minimize energy consumption, global cost and thermal discomfort. application to different italian climatic zones. *Energy*, Elsevier, v. 174, p. 359–374, 2019.
- ASCIONE, F. et al. A new methodology for cost-optimal analysis by means of the multi-objective optimization of building energy performance. *Energy and Buildings*, Elsevier, v. 88, p. 78–90, 2015.
- BARBOSA, S.; IP, K. Perspectives of double skin façades for naturally ventilated buildings: A review. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 40, p. 1019–1029, 2014.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001.
- DELGARM, N.; SAJADI, B.; DELGARM, S. Multi-objective optimization of building energy performance and indoor thermal comfort: A new method using artificial bee colony (abc). *Energy and Buildings*, Elsevier, v. 131, p. 42–53, 2016.
- DUARTE, G. R. et al. Comparison of machine learning techniques for predicting energy loads in buildings. *Ambiente Construído*, v. 17, n. 3, p. 103–115, 2017.
- EBERHART, R.; KENNEDY, J. Particle swarm optimization. In: CITESEER. *Proceedings of the IEEE international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948.
- FERRARA, M. et al. A simulation-based optimization method for cost-optimal analysis of nearly zero energy buildings. *Energy and Buildings*, Elsevier, v. 84, p. 442–457, 2014.
- GOLIATT, L.; CAPRILES, P. V.; TAVARES, G. G. Gradient boosting ensembles for predicting heating and cooling loads in building design. In: SPRINGER. *EPIA Conference on Artificial Intelligence*. [S.l.], 2019. p. 495–506.
- HAMDY ALA HASAN, K. S. M. A multi-stage optimization method for cost-optimal and nearly-zero-energy building solutions in line with the epbd-recast 2010. *Energy and Buildings*, Elsevier, Aalto University, School of Engineering, Department of Energy Technology, P.O. Box 14400, FI-00076 Aalto, Finland, 2013.

- HARKOUSS, F.; FARDOUN, F.; BIWOLE, P. H. Multi-objective optimization methodology for net zero energy buildings. *Journal of Building Engineering*, Elsevier, v. 16, p. 57–71, 2018.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning - Data Mining, Inference, and Prediction*. 2. ed. Verlag, New York: Springer, 2009. 745 p. ISBN 978-0-387-84857-0.
- HUANG, G.-B. et al. Extreme learning machine: a new learning scheme of feedforward neural networks. *Neural networks*, v. 2, p. 985–990, 2004.
- HUANG, P.; SUN, Y. A clustering based grouping method of nearly zero energy buildings for performance improvements. *Applied Energy*, Elsevier, v. 235, p. 43–55, 2019.
- HUNN, B. D. *Fundamentals of building energy dynamics*. [S.l.]: MIT Press, 1996. v. 4.
- INMET, I. N. d. M. Normais climatológicas do brasil. 2016.
- IZZO, D. Pygmo and pykep: open source tools for massively parallel optimization in astrodynamics (the case of interplanetary trajectory optimization). In: *Proceedings of the Fifth International Conference on Astrodynamics Tools and Techniques, ICATT*. [S.l.: s.n.], 2012.
- JAIN, R. K. et al. Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. *Applied Energy*, Elsevier, v. 123, p. 168–178, 2014.
- JIHAD, A. S.; TAHIRI, M. Forecasting the heating and cooling load of residential buildings by using a learning algorithm “gradient descent”, morocco. *Case studies in thermal engineering*, Elsevier, v. 12, p. 85–93, 2018.
- KHALID, A. et al. Towards dynamic coordination among home appliances using multi-objective energy optimization for demand side management in smart buildings. *Ieee Access*, IEEE, v. 6, p. 19509–19529, 2018.
- KINNANE, O.; PRENDERGAST, T. Assessment of the double-skin façade passive thermal buffer effect. In: *Passive Low Energy Architecture Conference, Ahmedabad, India*. [S.l.: s.n.], 2014.
- KNEIFEL, J.; WEBB, D. Predicting energy performance of a net-zero energy building: A statistical approach. *Applied energy*, Elsevier, v. 178, p. 468–483, 2016.
- LAUSTSEN, J. Energy efficiency requirements in building codes, energy efficiency policies for new buildings: Iea information paper. *Support of the G8 Plan of Action*, 2008.
- LI, H.; WANG, S.; CHEUNG, H. Sensitivity analysis of design parameters and optimal design for zero/low energy buildings in subtropical regions. *Applied energy*, Elsevier, v. 228, p. 1280–1291, 2018.
- MARSZAL P. HEISELBERG, J. B. E. M. K. V. I. S. A. N. A. Zero energy building – a review of definitions and calculation methodologies. *Energy and Buildings*, Elsevier, 2011.
- NEWELL, R. G.; QIAN, Y.; RAIMI, D. *Global energy outlook 2015*. [S.l.], 2016.

NICOL, F.; HUMPHREYS, M.; ROAF, S. *Adaptive thermal comfort: principles and practice*. [S.l.]: Routledge, 2012.

NOBRE, V. d. C. Análise da solução de climatização passiva para habitação pré fabricada de balanço energético nulo em Brasília. 2018.

PÉREZ-LOMBARD, L.; ORTIZ, J.; POUT, C. A review on buildings energy consumption information. *Energy and buildings*, Elsevier, v. 40, n. 3, p. 394–398, 2008.

QAHTAN, A. M. Thermal performance of a double-skin façade exposed to direct solar radiation in the tropical climate of Malaysia: A case study. *Case Studies in Thermal Engineering*, Elsevier, v. 14, p. 100419, 2019.

ROBINSON, C. et al. Machine learning approaches for estimating commercial building energy consumption. *Applied energy*, Elsevier, v. 208, p. 889–904, 2017.

RODRIGUEZ-UBINAS, E. et al. Passive design strategies and performance of net energy plus houses. *Energy and Buildings*, Elsevier, v. 83, p. 10–22, 2014.

SAJJADI, S. et al. Extreme learning machine for prediction of heat load in district heating systems. *Energy and Buildings*, Elsevier, v. 122, p. 222–227, 2016.

SCHOLKOPF, B.; SMOLA, A. J. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. Cambridge, MA, USA: MIT Press, 2001. ISBN 0262194759.

SHANMUGAMANI, R.; SADIQUE, M.; RAMAMOORTHY, B. Detection and classification of surface defects of gun barrels using computer vision and machine learning. *Measurement*, Elsevier, v. 60, p. 222–230, 2015.

SILVEIRA, F. M. et al. Análise do desempenho térmico de edificações residenciais ventiladas naturalmente: Nbr 15.575 e ASHRAE 55. 2014.

SORGATO, M. J.; MELO, A. P.; LAMBERTS, R. Análise do método de simulação de desempenho térmico da norma NBR 15.575. *Paranoá: cadernos de arquitetura e urbanismo*, n. 12, 2014.

STAHLHÖFER, I. S.; PEREIRA, M. F. B. Políticas públicas de implementação de coberturas verdes: O projeto de lei n 115/2009 da câmara de vereadores de São Paulo. *Revista Eletrônica do Curso de Direito da UFSM*, v. 8, p. 386–398, 2013.

STANDARD, A. Standard 55-2013. *Thermal environmental conditions for human occupancy*, 2013.

SUDBRACK, L. O. Casa zero: diretrizes de projeto para casas pré-fabricadas de balanço energético nulo em Brasília. 2017.

TEODOROVIC, D.; DELL'ORCO, M. Bee colony optimization—a cooperative learning approach to complex transportation problems. *Advanced OR and AI methods in transportation*, Publishing House of Poznan University of Technology Poland, v. 51, p. 60, 2005.

TSANAS, A.; XIFARA, A. Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy and Buildings*, Elsevier, v. 49, p. 560–567, 2012.

WANG, Z.; SRINIVASAN, R. S. A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 75, p. 796–808, 2017.

WU, X. et al. Top 10 algorithms in data mining. *Knowledge and information systems*, Springer, v. 14, n. 1, p. 1–37, 2008.

YU, W. et al. Application of multi-objective genetic algorithm to optimize energy efficiency and thermal comfort in building design. *Energy and Buildings*, Elsevier, v. 88, p. 135–143, 2015.

ZHOU, K.; YANG, S. Understanding household energy consumption behavior: The contribution of energy big data analytics. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 56, p. 810–819, 2016.

A Tabelas com a composição dos telhados e propriedades dos materiais

Tabela A.1: Propriedades dos materiais utilizados para compor os tipos de telhado durante simulações.

	Tipo de Telhado				
	Madeira Laminada Cruzada				
	Manta Aluminizada		Madeira Laminada Cruzada		
Rugosidade	Liso		Liso		
Espessura {m}	0,003		0,2		
Condutividade {W/m.K}	0,23		0,13		
Densidade {kg/m ³ }	1000		550		
Calor Específico {J/kg.K}	1460		2100		
Absortância Térmica	0,05		0,9		
Absortância Solar	0,05		0,7		
Absortância Visível	0,05		0,7		
	Laje de Concreto Sólido				
	Manta Aluminizada		Concreto Reforçado		
Rugosidade	Liso		Liso		
Espessura {m}	0,003		1,75		
Condutividade {W/m.K}	0,23		2400		
Densidade {kg/m ³ }	1000		1000		
Calor Específico {J/kg.K}	1460		0,2		
Absortância Térmica	0,05		0,2		
Absortância Solar	0,05		0,2		
Absortância Visível	0,05		0,2		
	Laje Treliçada				
	Manta Aluminizada	Concreto	Isopor	Concreto	
Rugosidade	Liso	Liso	Liso	Liso	
Espessura {m}	0,003	0,04	0,09	0,04	
Condutividade {W/m.K}	0,23	1,75	0,032	1,75	
Densidade {kg/m ³ }	1000	2200	40	2200	
Calor Específico {J/kg.K}	1460	1000	1420	1000	
Absortância Térmica	0,05	0,05	0,05	0,05	
Absortância Solar	0,05	0,05	0,05	0,05	
Absortância Visível	0,05	0,05	0,05	0,05	
	Telhado Verde				
	Vegetação e Terra	Ar	Água	Manta Impermeável	Madeira Laminada
Rugosidade	Liso	Liso	Liso	Liso	Liso
Espessura {m}	0,105	0,02	0,05	0,003	0,2
Condutividade {W/m.K}	1,0	0,023	0,6	0,23	0,13
Densidade {kg/m ³ }	1460	1,2	1000	1000	550
Calor Específico {J/kg.K}	880	1012	4190	1460	2100
Absortância Térmica	0,05	0,05	0,05	0,05	0,9
Absortância Solar	0,05	0,05	0,05	0,05	0,7
Absortância Visível	0,05	0,05	0,05	0,05	0,7

Tabela A.2: Propriedades de blocos e argamassas utilizadas durante simulações.

	Tipo de Bloco			Tipo de Argamassa		
	Cerâmico	Concreto	Solo-cimento	Celular	Gesso	Tradicional
Rugosidade	Liso	Liso	Liso	Liso	Liso	Liso
Espessura (m)	0,01	0,02	0,02	0,025	0,025	0,025
Conductividade (W/m.K)	0,9	0,91	0,78	0,3	0,7	1,15
Densidade (kg/m ³)	1300	1000	600	600	1000	2100
Calor Específico (J/kg.K)	920	1700	2000	1047	857	1000
Absortância Térmica	0,9	0,7	0,7	0,2	0,2	0,2
Absortância Solar	0,7	0,7	0,7	0,2	0,2	0,2
Absortância Visível	0,7	0,7	0,7	0,2	0,2	0,2