

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
PROGRAMA DE PÓS-GRADUAÇÃO EM ARQUITETURA E URBANISMO
NÍVEL MESTRADO**

ANA PAULA MARTINI DALLE MOLLE

**APRENDIZADO DE MÁQUINA APLICADO A SIMULAÇÕES DE RADIAÇÃO
SOLAR EM EDIFICAÇÕES**

São Leopoldo

2024

ANA PAULA MARTINI DALLE MOLLE

**APRENDIZADO DE MÁQUINA APLICADO A SIMULAÇÕES DE RADIAÇÃO
SOLAR EM EDIFICAÇÕES**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Arquitetura e Urbanismo, pelo Programa de Pós-Graduação em Arquitetura e Urbanismo da Universidade do Vale do Rio dos Sinos – UNISINOS

Orientador: Prof. Dr. Marco Aurélio Stumpf González

São Leopoldo

2024

D146a

Dalle Molle, Ana Paula Martini.

Aprendizado de máquina aplicado a simulações de radiação solar em edificações / por Ana Paula Martini Dalle Molle. – São Leopoldo, 2024.

103 f. : il. color. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Arquitetura e Urbanismo, São Leopoldo, RS, 2024.

Orientação: Prof. Dr. Marco Aurélio Stumpf González, Escola Politécnica.

1.Arquitetura e radiação solar. 2.Arquitetura e clima. 3.Arquitetura e conservação de energia. 4.Construção com vidro. 5.Radiação solar – Medição. 6. Edifícios – Conservação de energia. 7.Projeto arquitetônico – Processamento de dados. 8.Arquitetura – Projeto auxiliado por computador. I.González, Marco Aurélio Stumpf. II.Título.

CDU 72:551.521.1
72:004

ANA PAULA MARTINI DALLE MOLLE

APRENDIZADO DE MÁQUINA APLICADO A SIMULAÇÕES DE RADIAÇÃO SOLAR
EM EDIFICAÇÕES

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Arquitetura e Urbanismo, pelo Programa de Pós-Graduação em Arquitetura e Urbanismo da Universidade do Vale do Rio dos Sinos – UNISINOS

Aprovado em 17 / 09 / 2024

BANCA EXAMINADORA

Prof. Dr. Marco Aurelio Stumpf Gonzalez (Orientador) – UNISINOS

Prof. Dr. André de Souza Silva (Avaliador) – UNISINOS

Prof. Dr. Rômulo Giralt (Avaliador) – UFRGS

RESUMO

Esta pesquisa teve como objetivo investigar a aplicação de uma técnica de aprendizado de máquina supervisionado afim de reduzir as atualizações e modificações do modelo de design paramétrico voltados para análise de radiação solar em edificações. Inicialmente, foi criada uma geometria complexa por meio da programação paramétrica, visando a versatilidade do modelo para diferentes situações. A análise da radiação solar incidente foi realizada para compreender o desempenho energético do projeto arquitetônico, verificando-se os dados de entrada e saída do modelo paramétrico para garantir a precisão das análises. Em seguida, foi proposta uma técnica de aprendizado de máquina supervisionado que aprimorou e acelerou a análise de radiação solar, automatizando parte do processo e reduzindo o tempo necessário para obter os resultados desejados. Por fim, foram comparados os tempos de execução entre os métodos propostos e os resultados, utilizando novos conjuntos de dados, a fim de avaliar a eficiência da técnica de aprendizado de máquina em comparação com o método tradicional de programação paramétrica. Os resultados obtidos contribuem para o avanço das práticas de projeto arquitetônico com foco na eficiência energética, proporcionando percepções importantes sobre a aplicação do aprendizado de máquina na otimização dos fluxos de trabalho paramétricos para análise de radiação solar em edificações.

Palavras-chave: aprendizado de máquina; projeto paramétrico; programação visual; análise de radiação solar; análise de dados na arquitetura.

ABSTRACT

This research aimed to investigate the application of a supervised machine learning technique to reduce updates and modifications to the parametric design model focused on solar radiation analysis in buildings. Initially, a complex geometry was created through parametric programming, aiming for the model's versatility in different situations. The analysis of incident solar radiation was conducted to understand the energy performance of the architectural design, verifying the input and output data of the parametric model to ensure the accuracy of the analyses. Subsequently, a supervised machine learning technique was proposed to improve and accelerate the solar radiation analysis, automating part of the process and reducing the time required to obtain the desired results. Finally, execution times between the proposed methods and the results were compared using new datasets to evaluate the efficiency of the machine learning technique compared to the traditional parametric programming method. The results obtained contribute to the advancement of architectural design practices with a focus on energy efficiency, providing valuable insights into the application of machine learning in optimizing parametric workflows for solar radiation analysis in buildings.

Key-words: machine learning; parametric design; visual programming; solar radiation analysis; data analysis in architecture.

LISTA DE FIGURAS

Figura 1 – Irradiação direta normal (Wh/m ² .dia)	17
Figura 2 – Representação dos tipos de radiação solar através da influência da atmosfera Fonte: Moita (1987).	18
Figura 3 – Zona bioclimática 1	19
Figura 4 – Carta solar no <i>LadyBug Tools</i>	21
Figura 5 – Desenho esquemático do ângulo de declinação solar.	22
Figura 6 – d’Orleans do Palais Royale	23
Figura 7 – Otimização do isolamento acústico com vidro duplo.....	24
Figura 8 – <i>The Mirror Houses</i>	25
Figura 9 – Sistema <i>stick</i>	27
Figura 10 – Sistema Unitizado	27
Figura 11 – O uso do <i>sketchpad</i>	29
Figura 12 – Modelo do estádio criado por Luigi Moretti em 1939.....	30
Figura 13 – Curva NURBS	31
Figura 14 – Exemplo do algoritmo visual no <i>Grasshopper</i>	32
Figura 15 – Integração entre arquivos e análises possíveis no <i>LadyBug</i>	33
Figura 16 – Hotel Morpheus.....	34
Figura 17 – Modelo desenvolvido no <i>Grasshopper</i> para criação do exoesqueleto ...	35
Figura 18 – Modelagem de fabricação para painéis de revestimento de estrutura do exoesqueleto curvo duplo.....	36
Figura 19 – Torre de Xangai.....	37
Figura 20 – Rotação da planta	38
Figura 21 – Imagem interna da estrutura da Torre de Xangai.....	38
Figura 22 – Ciclo de Vida BIM.....	39
Figura 23 – Tubos de raios catódicos utilizado para o URBAN5 em um IBM 2250, modelo 1	42
Figura 24 – Abordagem do Estudo de Máquina	43
Figura 25 – Regressão.....	45
Figura 26 – Aprendizado não supervisionado divide os dados não rotulados em subgrupos.....	46
Figura 27 – Exemplo visual de aprendizado por reforço	47
Figura 28 – Sobreajustamento, sub-ajustamento e ajuste correto	48

Figura 29 – Exemplo da estrutura de uma árvore de decisão	49
Figura 30 – Exemplo visual de florestas aleatórias	50
Figura 31 – (a) 3D (b) Plantas do edifício de estudo	52
Figura 32 – Treinamento GANG.....	53
Figura 33 – Fluxograma da dissertação	54
Figura 34 – Entorno do local	55
Figura 35 – Localização dos terrenos utilizados para este estudo	55
Figura 36 – Geometrias base no <i>Grasshopper</i>	57
Figura 37 – Geometria base no <i>Rhinoceros</i>	57
Figura 38 – Definições de pavimentos no <i>Grasshopper</i>	58
Figura 39 – Cópia de pavimentos e rotação da geometria no <i>Grasshopper</i>	58
Figura 40 – Pavimentos e rotação de geometria criados no <i>Rhinoceros</i>	59
Figura 41 – Criação dos pisos e envelope da edificação	60
Figura 42 – Fachada/ envelope no <i>Rhinoceros</i>	60
Figura 43 – <i>Sun Path</i> no <i>Rhinoceros</i>	61
Figura 44 – Hoys (horas do ano de incidência solar)	62
Figura 45 – Visualização da radiação incidente	63
Figura 46 – Armazenamento de dados no <i>Grasshopper</i>	64
Figura 47 – Exportação de dados do <i>Grasshopper</i> para o formato .xls	65
Figura 48 – Importação de pacotes em Python.....	65
Figura 49 – Importação tabela de dados de simulações do <i>Grasshopper</i>	66
Figura 50 – Definição de <i>Features</i> e <i>Target</i>	66
Figura 51 – Dados de treinamento e teste e filtros.....	67
Figura 52 – Definição dos filtros e criação das florestas aleatórias.....	68
Figura 53 – Criação e ajustes de hiperparâmetros.....	69
Figura 54 – Previsão de radiação solar e valores de entrada	71
Figura 55 – Incidência de radiação solar na modelagem inicial	73
Figura 56 – Posicionamento da edificação com azimute 35° e 120°	75
Figura 57 – Geometria com borda e eixo 10°	78
Figura 58 – Valores gerados pelo aprendizado de máquina	80
Figura 59 – Geometria final.....	80

LISTA DE TABELAS

Tabela 1 – Valores geométricos iniciais	73
Tabela 2 – Azimutes.....	74
Tabela 3 – Alteração de pé direito e azimute	75
Tabela 4 – Alteração no eixo de rotação	76
Tabela 5 – Alteração no ângulo de borda e eixo de rotação	77

LISTA DE SIGLAS

CAD	Computer Aided Design
CAM	Computer Aided Manufacturing
CLS	Concept Learning System
CSV	Comma-separated values
EPW	EnergyPlus Weather
GANs	Generative Adversarial Neural Networks
ID3	Iterative Dichotomizer three
IFC	Industry Foundation Classes
MAE	Erro Médio Absoluto
NURB	Non-Uniform Rational B-splines
RMSE	Raiz do Erro Quadrático Médio
SNARC	Stochastic Neural-Analog Reinforcement Computer
VLP	Linguagem de Programação Visual

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Tema	12
1.2 Delimitação do Tema	13
1.3 Problematização	13
1.3.1 Questão e Pressupostos	13
1.4 Objetivos	14
1.4.1 Objetivo Geral	14
1.4.2 Objetivos Específicos	14
1.5 Justificativa	14
2 FUNDAMENTAÇÃO TEÓRICA	17
2.1 Radiação solar	17
2.2 Zonas bioclimáticas	18
2.2.1 Geometria solar	20
2.3 Iluminação natural	21
2.4 Superfícies Envidraçadas	22
2.4.1 A história do vidro na construção civil	22
2.4.2 Tipos de vidro	23
2.4.3 A evolução das fachadas de vidro	26
2.4.4 Desempenho térmico e eficiência energética em fachadas envidraçadas	28
2.5 A evolução dos métodos de elaboração de projetos: do desenho manual à computação gráfica	28
2.6 Design paramétrico	29
2.6.1 Softwares de modelagem paramétrica	31
2.6.2 Plugin de programação visual	32
2.6.3 Ladybug	33
2.6.4 O design paramétrico do hotel morpheus de Zaha Hadid	34
2.6.5 O design paramétrico da torre de Xangai	36
2.7 Tecnologia BIM	39
2.8 A história da inteligência artificial	40
2.8.1 A origem do aprendizado de regras por árvores de decisão	41
2.8.2 A Inteligência artificial na arquitetura	42
2.9 Aprendizado de máquina	43

2.9.1 Estilos de aprendizado	44
2.9.2 Sobreajustamento e sub - ajustamento	47
2.9.3 Árvore de decisão	48
2.9.4 Florestas aleatórias (<i>Random Forests</i>)	49
2.9.5 Python	50
2.9.6 Biblioteca <i>scikit learn</i>	51
2.10 Exemplos da aplicação da IA em projetos arquitetônicos	51
2.10.1 Um modelo de previsão baseado em aprendizado de máquina do ciclo de vida de CO ₂ para renovação de envoltório de edifícios em Taiwan.....	51
2.10.2 Criando layouts de planta baixa com IA	52
3 METODOLOGIA	54
3.1 Modelagem paramétrica	56
3.2 Simulação de radiação solar	60
3.3 Criação de dados de treinamento.....	64
3.4 Criando o modelo de aprendizado de máquina.....	65
3.5 Métricas de desempenho.....	69
3.6 Comparativo final	71
4 APRESENTAÇÃO E DISCUSSÃO DE RESULTADOS	72
4.1 Análise de radiação solar na modelagem paramétrica	72
4.2 Análise de radiação no modelo de aprendizado de máquina.....	78
4.3 Comparação das alternativas geradas	80
5 CONCLUSÃO	82
5.1 Contribuições e trabalhos futuros	83
REFERÊNCIAS.....	84
APÊNDICE A – DADOS DE ANÁLISES DE RADIAÇÃO SOLAR.....	90
APÊNDICE B – ALGORITMO DE APRENDIZADO DE MÁQUINA	101

1 INTRODUÇÃO

Anualmente as atividades humanas são responsáveis pela emissão de 51 bilhões de toneladas de gases de efeito estufa na atmosfera. Aproximadamente 90% das casas americanas possuem sistema de refrigeração e aquecimento e existem no planeta 1,6 bilhões de aparelhos de condicionamento de ar em uso. No entanto a maioria se encontra em países ricos, cerca de 90%. Apenas 10% estão em países de terceiro mundo, sendo em sua maioria mais quentes. Conforme o desenvolvimento desses países e da economia haverá a necessidade de um aumento no consumo de ar-condicionado. Está previsto que até 2050 haverá cerca de 5 bilhões de aparelhos de ar-condicionado no planeta. Em edificações, a eletricidade total usada nos prédios com sistema de ar-condicionado, iluminação e computadores é equivalente a 14% dos gases de efeito estufa. E não só o sistema de resfriamento é nocivo, como um sistema de aquecimento colocando em pauta a grande necessidade de adaptação das edificações em relação a sua eficiência térmica e energética. Esses dados alarmantes são apresentados no livro “Como evitar um desastre climático”, escrito por Bill Gates (2021).

Essa situação leva à necessidade de alto desempenho das edificações, visando reduzir seu consumo energético e as emissões de carbono, além de proporcionar aos seus ocupantes maior conforto térmico e visual gerando maior produtividade, bem-estar e depender menos de sistemas mecânicos para geração desse conforto. Idealmente devem possuir opções de energias renováveis a fim de reduzir o uso de energia advinda de combustíveis fósseis. O desempenho desejado começa no ciclo de elaboração do projeto, onde muitas decisões são tomadas, especialmente aquelas que afetam diretamente a eficiência energética de uma edificação, como a orientação, envelope, iluminação, entre outros. Em média um edifício possui uma vida útil de 75 anos e ao longo desse tempo a população irá aumentar, e por consequência, a demanda de energia gerando maiores impactos ambientais. Esse processo acaba por ampliar as exigências dos requisitos de projetos, fazendo-se necessário projetar para o futuro (AIA, 2019).

Dentro dessa perspectiva de projetar para o futuro, destaca-se o desafio 2030, que busca a redução de mudanças climáticas através de metas e diminuição de emissões de gases de efeito estufa. Isso acelera a busca pelo alto desempenho das construções, que é conquistado através de simulações de desempenho do edifício,

cálculo do uso anual de energia e conforto térmico, além de simulações energéticas, solares, sombreamento e ventilação natural (AIA, 2019).

1.1 Tema

Com foco na sustentabilidade ambiental, engenheiros e arquitetos estão buscando projetar de maneira ambientalmente responsável, aliada ao conforto de seus usuários (Machado, 2018). Para Casals (2006) a eficiência energética é um requisito importante para a conquista da sustentabilidade, onde o maior potencial de aplicação em novas construções está dependente das melhorias e inovações na maneira de projetar. Carlo e Lamberts (2008) afirmam que os recursos computacionais são ótimos no auxílio de tomadas de decisões, sendo assim as simulações termo energéticas paramétricas são uma solução prática para conflitos relacionados à eficiência energética. No auxílio do desenvolvimento de projetos ambientalmente sustentáveis é possível adicionar o design paramétrico.

Pode-se definir o design paramétrico como um conjunto de parâmetros pré-definidos que possui como base um algoritmo e auxilia na elaboração de novas formas (Machado, 2018). Para as fases primárias dos projetos, as quais demandam escolhas que podem influenciar no desempenho e eficiência energética da edificação, o design paramétrico auxilia na tomada de decisões (Petersen; Svendsen, 2010).

As análises geradas por algoritmos paramétricos, aplicadas a diferentes designs de projetos, geram uma grande quantidade de dados (como geometria do design, inclinação de fachada, incidência solar) que podem ser tratados e analisados aplicando algumas técnicas de ciência de dados como agrupamento, regressão, análise de sequência e detecção de anomalias (Molina-Solana et al., 2017). Os dados gerados podem ser utilizados na criação de modelos de aprendizado supervisionado de máquina, onde através de modelos algorítmicos, o computador descobre padrões, cálculos e tendências com base nos dados fornecidos e pode ser utilizado para realização de previsões futuras sem a necessidade de alteração de inúmeras variáveis (Pierson, 2019).

Esses dados tratados por fim auxiliam em tomadas de decisões para uma melhor execução de projetos ambientalmente sustentáveis (Molina-Solana et al., 2017).

1.2 Delimitação do Tema

O presente trabalho se limita à aplicação do aprendizado de máquina para análise de radiação solar em uma edificação, em comparação à elaboração do design paramétrico para a mesma funcionalidade.

1.3 Problematização

Profissionais do setor de arquitetura, engenharia e construção buscam cada vez mais por estruturas que utilizem a menor quantidade possível de recursos, o que impulsiona a demanda por alto desempenho das edificações. Para análises de desempenho térmico e energético, muitos profissionais adotam o design paramétrico, uma abordagem na qual a modelagem é feita por meio de sequências de instruções individuais, utilizando programação visual. Esse processo proporciona maior flexibilidade ao projetista na criação de novas formas geométricas e na proposição de designs inovadores (Sebestyen, 2021).

As análises de desempenho de empreendimentos complexos e de grande porte podem demandar muito tempo dos projetistas, pois exigem várias atualizações e modificações nos processos. Os dados de entrada, como número de pavimentos, altura do pé direito, largura, profundidade, rotação e angulação da geometria, são os parâmetros que os projetistas inserem para definir as características da edificação. Ao alterar essas características, toda a sequência de instruções precisa ser atualizada para gerar os dados de saída, podem ser aos resultados da análise, como consumo energético, níveis de conforto térmico ou quantidade de radiação solar incidente. Esse processo de atualização demanda tempo e acaba exigindo alta capacidade computacional. Para acelerá-lo, muitos profissionais optam por segmentar a geometria ou simplificar o modelo de análise, o que pode comprometer a precisão dos resultados (Sebestyen, 2021).

1.3.1 Questão e Pressupostos

A questão problema dessa dissertação é: Como a aplicação do aprendizado de máquina pode auxiliar na redução de fluxos de trabalho paramétricos?

1.4 Objetivos

1.4.1 Objetivo Geral

Investigar a aplicação de uma técnica de aprendizado de máquina supervisionado a fim de reduzir as atualizações e modificações do modelo de design paramétrico voltados para análise de radiação solar em uma edificação.

1.4.2 Objetivos Específicos

- a) Analisar a radiação solar na geometria de uma edificação, proposta através da simulação de diferentes posicionamentos geométricos de fachada;
- b) Verificar o processo de obtenção de dados de entrada e saída do modelo paramétrico a fim de identificar possíveis inconsistências de dados;
- c) Aplicar uma técnica de aprendizado de máquina supervisionado para melhorar e acelerar a análise de radiação solar em edificações;

1.5 Justificativa

A radiação solar desempenha um papel fundamental como a principal fonte de energia da Terra. Compreender a quantidade de radiação solar que atinge uma determinada área é essencial, especialmente ao considerar a implantação de sistemas de energia solar, visando viabilizar o uso de fontes de energia renovável, como mencionado por Villegas-Mier et. al (2022). Além disso, o aproveitamento correto da radiação solar está diretamente relacionado ao desempenho térmico das edificações, uma vez que permite otimizar o conforto dos usuários através da aplicação de soluções arquitetônicas as quais utilizam de iluminação natural e procuram melhorar o desempenho das edificações sem a necessidade de sistemas de condicionamento artificial (Leone; Florio; 2021).

A NBR 15575 por sua vez, apresenta o requisito de desempenho térmico, que estabelece parâmetros e critérios para assegurar a qualidade térmica das edificações habitacionais. Desta forma, a análise da radiação solar torna-se fundamental para garantir o cumprimento desses requisitos, sendo esta, significativa na carga térmica

da edificação, impactando diretamente nos sistemas de climatização, na escolha de isolamento térmico apropriado e na implementação de proteções solares.

Na busca por concepções arquitetônicas corretas e bem aplicadas, as ferramentas de projeto ganham grande ênfase. Um exemplo é a modelagem paramétrica, na qual é possível simular diferentes edificações por meio da combinação de parâmetros, utilizando algoritmos para elaborar diversas opções de projeto e realizar inúmeras análises (Leone; Florio; 2021). Atualmente, é possível aprimorar e agilizar ainda mais a modelagem paramétrica por meio da aplicação do aprendizado de máquina. Esse avanço tecnológico permite reduzir trabalhos repetitivos os quais seriam realizados por projetistas, permitindo que os profissionais experimentem e alterem ativamente um modelo de design paramétrico (Sebestyen, 2021).

Um exemplo de aplicação do aprendizado de máquina na arquitetura no Brasil é no estudo realizado por Quevedo et al. (2023), onde três técnicas diferentes foram aplicadas, com o objetivo de desenvolver um *benchmark* de consumo de energia para edifícios de universidades a fim de melhorar sua eficiência energética. No banco de dados, gerado através de simulação paramétrica de energia predial, foram considerados parâmetros como densidade de ocupação, sombra e transmitância térmica entre elementos de envelope, gerando 23.256 casos os quais representavam as variações de edifícios universitários no país. Por possuir o melhor rendimento o método máquina de vetores de suporte foi adotado no desenvolvimento da escala de benchmark e eficiência.

Com o objetivo de aprimorar e agilizar as concepções arquitetônicas aplicadas para um melhor desempenho térmico e energético, bem como reduzir o trabalho do design paramétrico, este estudo apresenta a aplicação do aprendizado de máquina através do modelo de florestas aleatórias em dados de análise de radiação solar. Sendo florestas aleatórias um método de aprendizado de máquina que consiste em um conjunto de árvores de decisão, onde cada árvore contribui para a previsão final. Conhecido por sua capacidade de lidar com grandes volumes de dados e variáveis e redução do risco de superajuste, sendo assim uma opção eficiente para analisar a complexidade das variáveis envolvidas na radiação solar em edificações.

Para tal será elaborado a modelagem paramétrica de um edifício fictício, onde a viabilidade construtiva e os custos não serão considerados, em um terreno localizado na cidade de Caxias do Sul. Em seguida, serão realizadas análises de

radiação solar incidente na fachada, onde os valores de radiação incidentes gerados servirão como base de dados para o modelo de aprendizado de máquina, utilizando a técnica de florestas aleatórias.

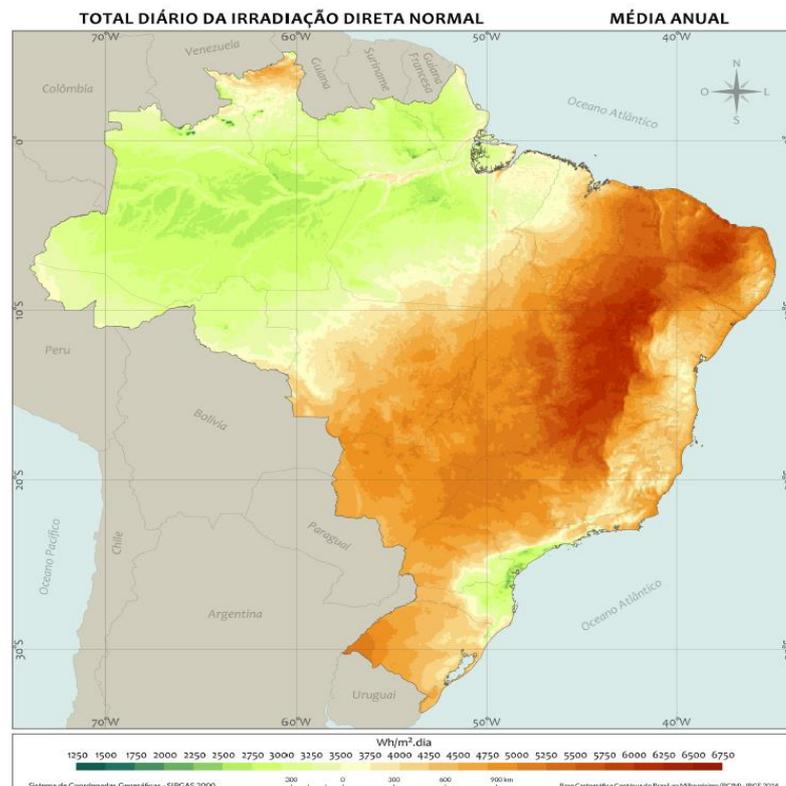
2 FUNDAMENTAÇÃO TEÓRICA

Com o objetivo de fornecer embasamento teórico para o desenvolvimento desta pesquisa, o capítulo foi dividido nas seguintes seções:

2.1 Radiação solar

A radiação solar desempenha um papel essencial no projeto e desempenho de edificações. Sua interação com os edifícios pode influenciar o conforto térmico dos ocupantes, o consumo de energia, a eficiência energética e até mesmo a durabilidade dos materiais de construção. Aproveitar de forma eficiente a energia solar para aquecimento, geração de energia e iluminação natural é fundamental. A orientação adequada do edifício permite a entrada de luz solar direta durante os meses frios, reduzindo a necessidade de aquecimento artificial ao fornecer calor natural. Por outro lado, o excesso de radiação solar pode causar desconforto térmico dentro da edificação, devido ao ganho excessivo de calor (Bainbridge; Haggard, 2011). A Figura 1 apresenta a média anual de irradiação diária no Brasil.

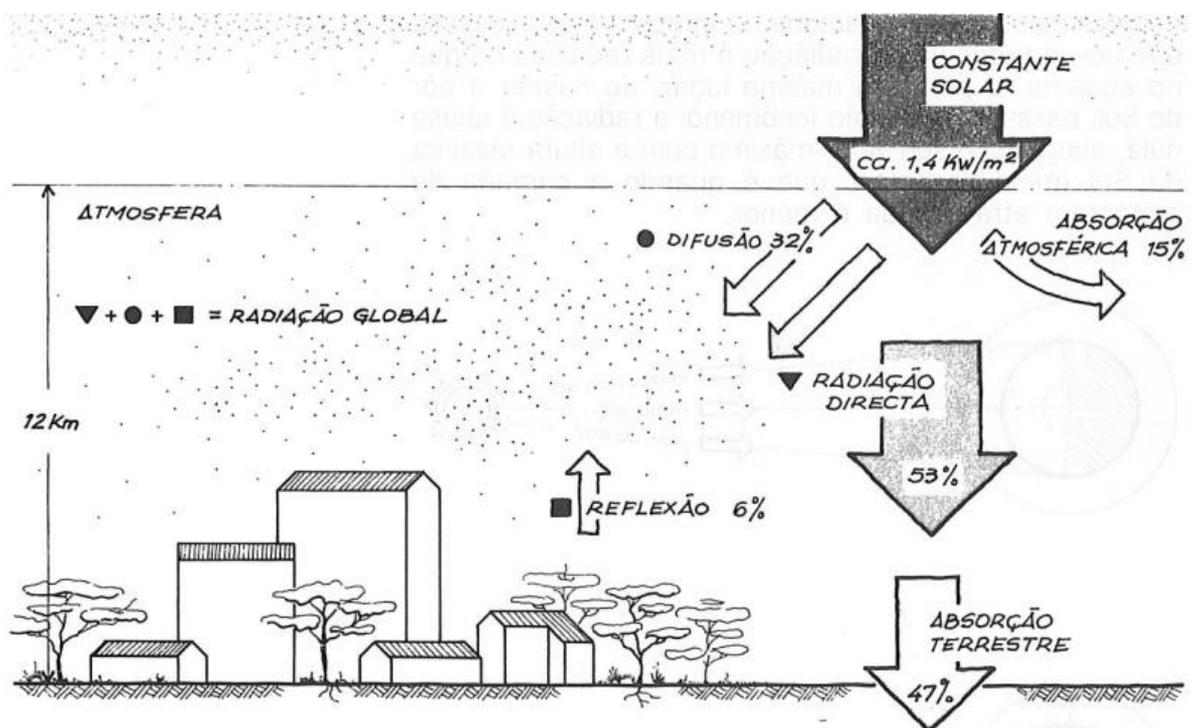
Figura 1 – Irradiação direta normal ($\text{Wh}/\text{m}^2.\text{dia}$)



Fonte: Atlas Brasileiro de Energia Solar (2017).

A radiação solar que atinge uma superfície pode ser dividida radiação direta, radiação difusa e radiação solar refletida. A soma da radiação direta e difusa é conhecida como radiação solar global. A radiação direta provém diretamente do sol, sem sofrer desvios significativos na atmosfera (Figura 2). Sua intensidade depende da altura solar e do ângulo de incidência dos raios solares em relação à superfície, e desempenha um papel fundamental no aquecimento das edificações. Por outro lado, a radiação difusa sofre desvios durante sua trajetória através da atmosfera, sendo menos intensa. A radiação solar refletida atinge a superfície terrestre e depois é refletida de volta para a atmosfera. A quantidade de radiação refletida depende das propriedades do material da superfície (albedo). Superfícies claras, como neve ou areia branca, refletem mais radiação, enquanto superfícies escuras, como florestas ou asfaltos, refletem menos. (Lamberts et.al, 2014).

Figura 2 – Representação dos tipos de radiação solar através da influência da atmosfera



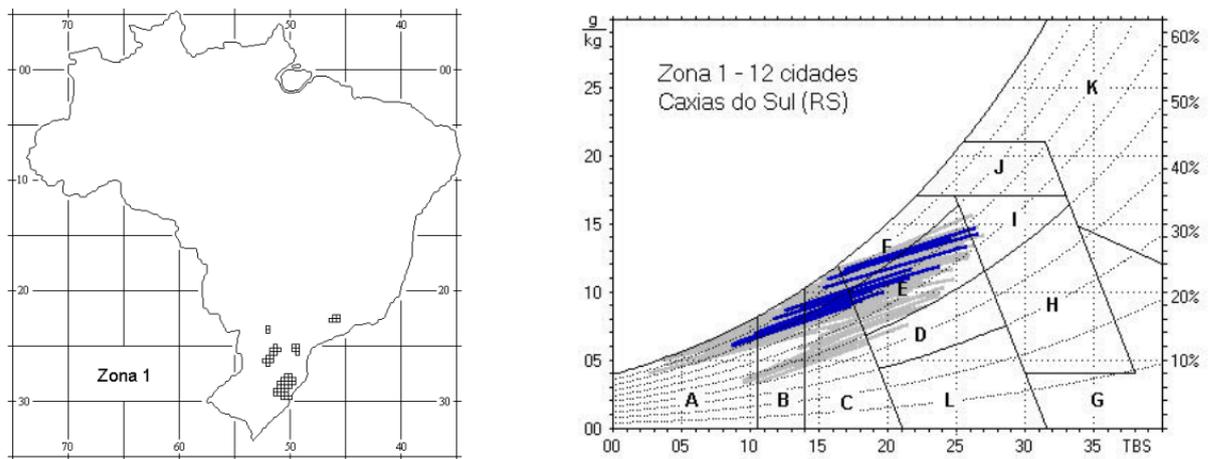
Fonte: Moita (1987).

2.2 Zonas bioclimáticas

A arquitetura bioclimática vem ganhando notoriedade, pois aplica condicionadores ambientais e técnicas passivas como forma de melhorar a eficiência da edificação. Para a melhoria do aproveitamento da edificação através da correta

orientação solar, na estratégia arquitetônica e correta aplicação das aberturas, é importante o conhecimento e determinação da zona climática e bioclimática. Para este estudo aplicado na cidade de Caxias do Sul, pertencente a zona bioclimática 1, conforme a NBR 15220, parte 3, sua zona climática fica em clima denominado subtropical, com características de temperatura média abaixo de 20°C, com amplitude térmica variando entre 9°C e 13°C, possuindo assim invernos rigorosos podendo haver ocorrência de neve, além de chuvas bem distribuídas e fartas (Lamberts et.al, 2014). Na Figura 3 é possível verificar os locais de mesma zona bioclimática da cidade.

Figura 3 – Zona bioclimática 1



Fonte: NBR 15220-3 (2003).

A NBR 15220-3 estabelece ainda para o território brasileiro a divisão de zonas bioclimáticas, sendo no total oito zonas diferentes, onde as regiões são agrupadas conforme suas características bioclimáticas em comum. Na zona bioclimática 1 está localizado Caxias do Sul, onde para tal é recomendado aberturas médias as quais permitam a entrada de radiação solar durante os períodos de frio, vedações externas leves e cobertura leve isolada. Como estratégias para o bom condicionamento térmico passivo da edificação a norma recomenda no inverno o aquecimento solar da edificação e vedações internas pesadas para inércia térmica. No entanto, ressalta que o condicionamento passivo não será o suficiente durante os períodos mais frios.

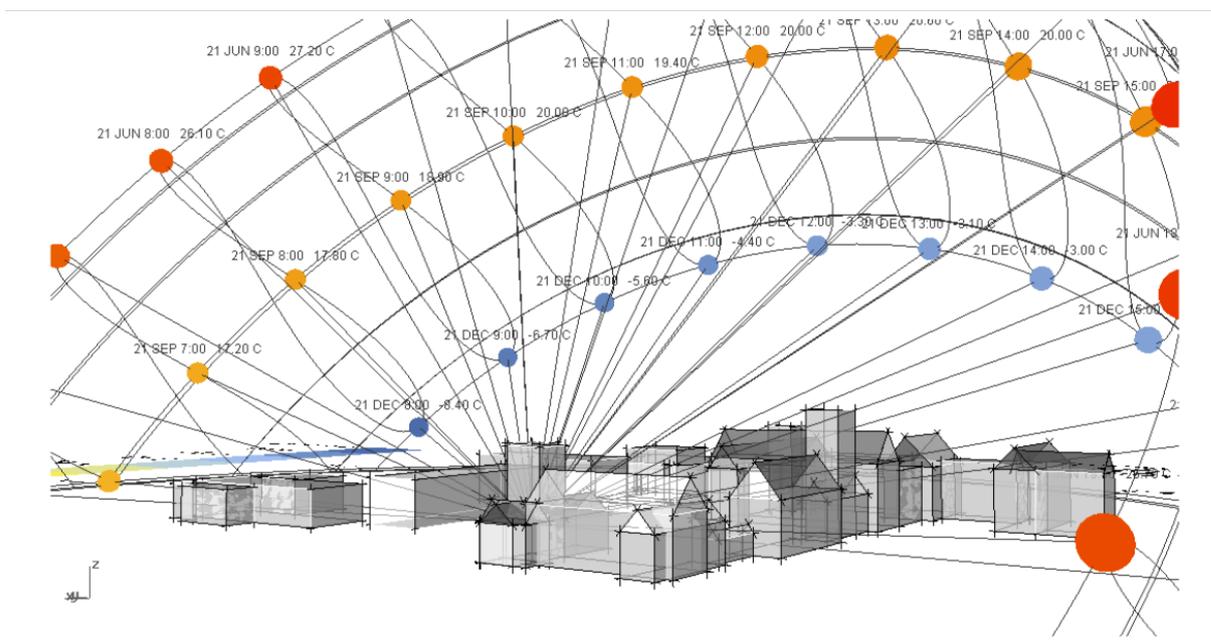
2.2.1 Geometria solar

A geometria solar é um conhecimento importante na concepção de projetos. Através dela é possível aplicar estudos de sombreamento do entorno, que gera influência sobre a forma do edifício e sistemas de proteção solar.

Considerando a zona bioclimática de Caxias do Sul sendo a mesma inserida na cidade de Curitiba, é possível verificar conforme uma análise apresentada por Lamberts et. al (2014) que apenas 37,3% de horas anuais no período diurno (4745 horas entre 6h da manhã e 18h da tarde) são necessárias para sombreamento da edificação contra 48,1% de insolação, por se tratar de uma região mais fria com necessidade de aproveitamento do sol como fonte de calor.

Machado (2018) afirma que a radiação solar tem fator determinante no conforto térmico da edificação, sendo esta no inverno importante para o aquecimento interno e no verão devendo ser evitada, além de grande relevância na iluminação natural, reduzindo o uso de iluminação artificial extremamente importante para o bem-estar dos usuários.

As cartas solares são ferramentas utilizadas no conhecimento da geometria solar. Elas permitem reconhecer a posição solar em um local específico e em horários determinados. Essas informações são essenciais para avaliar o sombreamento do entorno e a necessidade de proteções solares na edificação. Essas proteções podem incluir elementos como beirais, brises, telas, janelas estrategicamente posicionadas, entre outros, que visam controlar a quantidade de luz solar que entra no edifício, de acordo com as necessidades de conforto e eficiência energética. O conhecimento da geometria solar e o uso de cartas solares são fundamentais para projetar edificações que aproveitem os benefícios da radiação solar de forma adequada, equilibrando o conforto térmico, a iluminação natural e a eficiência energética. (Lamberts et.al, 2014). Na Figura 4 é possível uma carta solar realizada com o plugin *Ladybug*.

Figura 4 – Carta solar no *LadyBug Tools*

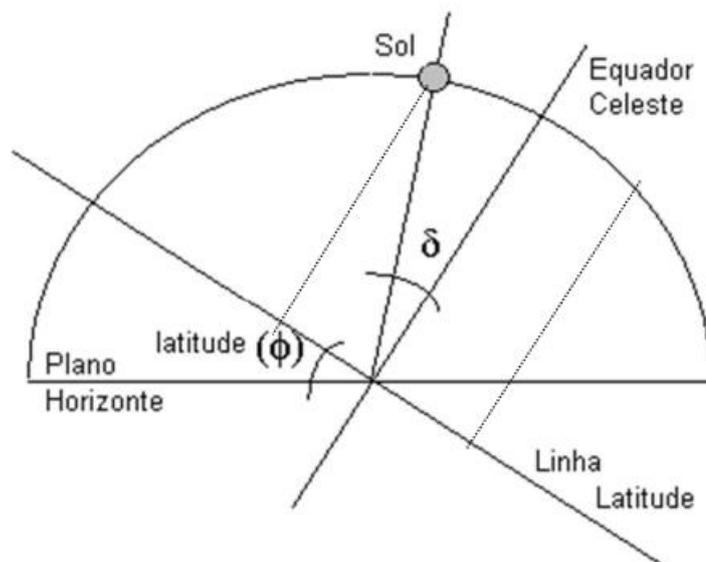
Fonte: Ladybug (2022).

2.3 Iluminação natural

A aplicação da luz natural em edificações é amplamente utilizada devido às inúmeras vantagens, como a qualidade da iluminação, a comunicação com o ambiente externo e os benefícios fisiológicos fornecidos aos usuários, além da eficiência energética. No entanto, é crucial analisar e garantir que o ambiente interno esteja livre de desconfortos que possam ser causados por um projeto incorreto de aberturas envidraçadas, como resfriamento excessivo em períodos frios ou superaquecimento em períodos quentes (Silva, 2009).

A NBR 15215 (2024) é essencial no aproveitamento de luz natural, pois apresenta diretrizes para garantir o máximo aproveitamento. Dividida em quatro partes, a primeira justifica a importância da eficiência energética, do bem-estar e do conforto visual dos ocupantes. A segunda parte estabelece métodos de cálculo para estimar a disponibilidade de luz natural em ambientes internos. Na terceira parte, são descritos procedimentos para a medição da iluminância interna (em lux). Por fim, a quarta parte oferece exemplos e demonstrações da aplicação dos métodos de cálculo e medições descritos na norma. Na Figura 5 é possível analisar o desenho esquemático do ângulo de declinação solar disponível na NBR 15215-2.

Figura 5 – Desenho esquemático do ângulo de declinação solar.



Fonte: NBR 15215-2 (2024).

2.4 Superfícies Envidraçadas

2.4.1 A história do vidro na construção civil

A descoberta do vidro ocorreu acidentalmente através da queima da areia pelos fenícios no ano de 3000 a.C, utilizado inicialmente apenas para a criação de vasos e copos. Em sua evolução o vidro passou a ser utilizado em espelhos e foi evoluindo para melhorias em sua cor e resistência. Por muitos anos o vidro foi considerado sinônimo de riqueza e na era renascentista já possuía maior resistência e uso. No século XX sua aplicação na construção civil começou a ser associada a aplicações estruturais e a resistência as intemperes do ambiente externo (Richards, 2006).

O arquiteto Pierre François Leonard Fontaine em 1829 apresentou a primeira grande obra em ferro e vidro, através da cobertura do *d' Orleans do Palais Royale* de Paris (Figura 6), uma galeria que ligava seus jardins ao palácio real (Garanito, 2018).

Figura 6 – d'Orleans do Palais Royale



Fonte: Wikimedia (2013).

2.4.2 Tipos de vidro

Na busca por novos revestimentos externos o vidro teve seu destaque por sua versatilidade, transparência e leveza, características as quais permitem a aplicação de tipos diferentes de vidros e fachadas únicas.

No Brasil a NBR 7199 classifica os vidros de acordo com suas características mecânicas e físicas, como transmissão de luz, isolamento térmico e acústico, resistência ao fogo e ao impacto, além de estabelecer alguns critérios para projetos como segurança afim de evitar acidentes em caso de quebra, resistência através do cálculo de espessura e dimensões corretas para suportar esforços como impactos, ventos e variações térmicas e requisitos necessários para o conforto térmico e luminoso através da transmissão de luz e energia.

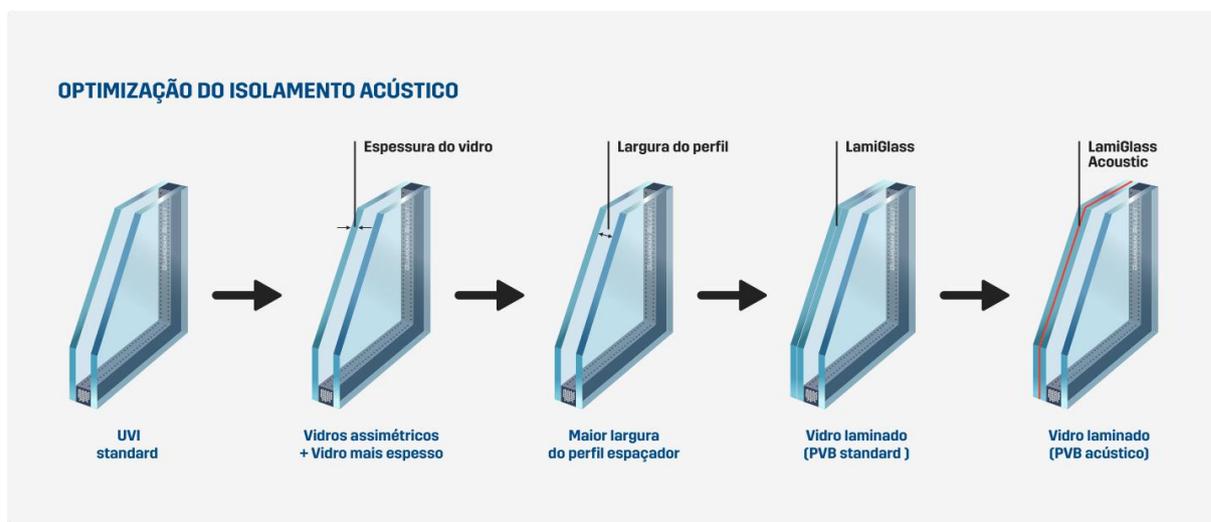
O vidro mais comumente utilizado na indústria da construção civil é o vidro do tipo simples, obtido por um processo chamado de Float, podendo ele ser monolítico

ou recozido. No Brasil os vidros simples podem variar de espessura entre 3 a 19mm. Já o vidro laminado é composto por duas ou mais placas de vidro, as quais são intercaladas com camadas de PVB (polivinil butiral), material plástico responsável por manter os fragmentos de vidro unidos no caso de eventual quebra, garantindo mais segurança. Aplicado em janelas, fachadas e guarda corpos (NBR 7199, 2016).

O vidro temperado é produzido a partir do vidro Float, que passa por um processo chamado têmpera, o qual aumenta sua resistência. Quando esse tipo de vidro se quebra, os fragmentos resultantes são menores e menos cortantes, diferenciando-o do vidro comum (Azeredo, 2004).

Para Azeredo (2004) o vidro duplo é uma solução eficiente no isolamento acústico e térmico por ser composto por duas camadas de vidros, as quais são separadas com uma câmara de ar ou gás, assim reduzindo a transmissão de som ou mesmo de calor. Muito utilizado em edificações que buscam maior eficiência energética e conforto em ambientes internos, mesmo possuindo elevado custo inicial o vidro duplo proporciona economia em longo prazo, através da redução de custos com climatização. Na Figura 7 é possível observar as modificações que possam otimizar o isolamento acústico de um ambiente através da utilização do vidro duplo.

Figura 7 – Otimização do isolamento acústico com vidro duplo



Fonte: Guardian Glass (2024).

Outro tipo de vidro muito utilizado na construção civil é o vidro reflexivo (ou também chamado de espelhado), desenvolvido para melhorar a eficiência energética através do controle de intensidade do calor e da luz transmitido ao ambiente interno.

Sua alta capacidade de bloquear o calor reduz cerca de 80% a transmissão de calor via radiação solar para o ambiente interno. Quando laminado possui uma barreira contra os raios UV, por vez gerando grande economia elétrica devido a diminuição do uso de climatização mecânica além do controle luminoso que incide no vidro. Para a criação do vidro refletido é necessário transformar o vidro tipo comum (*float*) através da aplicação em suas faces de uma camada metalizada, feita por uma câmara a vácuo ou um processo pirolítico (Westphal, 2016).

O processo realizado por câmara a vácuo apresenta vidros refletidos com melhor proteção solar, no entanto sua camada refletiva é mais superficial. Já o processo pirolítico possui mais resistência e filtro solar dado como baixo ou intermediário (Westphal, 2016). A Figura 8 apresenta um exemplo de aplicação do vidro refletido em um consagrado projeto do arquiteto italiano Peter Pischler, chamado *The Mirror Houses*.

Figura 8 – *The Mirror Houses*



Fonte: Archdaily (2014).

O vidro tipo *Low-e* (*low emissivity*) traduzido como baixa emissividade é bastante utilizado em países de clima frio os quais necessitam manter o interior de sua edificação aquecido. Para climas tropicais o mesmo ganhou uma camada de controle solar, que possui propriedades refletivas e permitem a passagem de luz. O

vidro é do tipo *float* o qual em uma de suas faces é adicionado um óxido metálico que forma uma camada de proteção para o ambiente interno de raios solares e ultravioletas. Por ser de baixa emissividade ele acaba por ter maior dificuldade em emitir o calor, mantendo sua temperatura baixa ou alta por um período maior, provocando assim menos desconforto térmico (Westphal, 2016).

2.4.3 A evolução das fachadas de vidro

A principal função de uma fachada é garantir condições adequadas de habitabilidade para a edificação, protegendo o ambiente interno de agentes externos como chuva, frio, calor, vento e ruídos, ao mesmo tempo em que considera fatores como custo, orientação, tamanho das aberturas, tipo de material aplicado e estética. Com o tempo, os sistemas de fachadas evoluíram, tornando-se mais industrializados, de rápida execução e mais eficientes. Esses avanços trazem benefícios significativos, como a diminuição do efeito de dilatação térmica na estrutura do edifício, redução do consumo de energia para o condicionamento de ar no interior, melhoria no isolamento acústico e maior facilidade de manutenção (Siqueira, 2003).

As fachadas envidraçadas acompanharam essa evolução. Anteriormente, as estruturas de alumínio ficavam aparentes hoje, é possível embuti-las internamente, deixando visível apenas o vidro, como nas populares peles de vidro (Abravidro, 2018). As fachadas de vidro podem ser classificadas em fachada cortina convencional, pele de vidro e *Structural Glazing*. Na fachada cortina convencional, as colunas de sustentação do vidro estão localizadas no lado externo, com o vidro fixado por perfis de alumínio e guarnições de EPDM. As peles de vidro, por sua vez, têm suas colunas de sustentação fixadas em vigas, e o vidro, embora encaixilhado, destaca-se visualmente, uma vez que os perfis de fixação são visíveis apenas no lado interno. Já na fachada cortina do tipo *Structural Glazing*, o vidro é colado diretamente na coluna de sustentação por meio de silicone estrutural, com a estrutura permanecendo oculta na face interna do edifício (Khoury, 2002).

Os sistemas de fachada cortina podem ser divididos em duas categorias principais: o sistema *Stick* e o sistema unitizado. No sistema *Stick*, que é o mais convencional, os perfis de alumínio são visíveis na fachada externa do edifício, e a instalação ocorre do lado externo da estrutura. A principal vantagem desse sistema é

sua flexibilidade para adaptações durante a construção (Khoury, 2002). A Figura 9 ilustra o sistema Stick.

Figura 9 – Sistema *stick*



Fonte: GMM (2020).

O sistema unitizado (Figura 10) é semelhante ao *Stick*, mas foi introduzido no Brasil em 2002, trazendo maior agilidade na instalação de fachadas de vidro. Ele é composto por quadros de elementos verticais, chamados montantes, separados como macho e fêmea, e travessas horizontais que são fixadas aos montantes. Os montantes neste sistema tendem a ser mais largos e profundos em comparação ao sistema *Stick* (Ludwing, 2014).

Figura 10 – Sistema Unitizado



Fonte: GMM (2020).

2.4.4 Desempenho térmico e eficiência energética em fachadas envidraçadas

Ao iniciar o projeto arquitetônico muitos fatores precisam ganhar atenção na busca pela eficiência energética e bom desempenho térmico da edificação. Deve-se analisar a área total das fachadas, bem como orientação solar e localização para auxílio na escolha correta do vidro a ser utilizado com as propriedades adequadas. Também é necessário levar em consideração características climáticas da região, incidência de radiação solar e temperatura externa do ar. Outro fator importante a ser avaliado é o percentual de abertura da fachada, que indica a proporção de fachadas envidraçadas na edificação, permitindo a entrada de luz natural nos ambientes internos. Elementos estruturais (lajes, vigas e pilares) são desconsiderados na abertura de fachadas por serem opacos (Andreis, Basen e Westphal, 2014).

A NBR 16023 (2020) considera algumas propriedades termo físicas importantes a serem consideradas na escolha do vidro como fator solar, transmissão e reflexão luminosas, além da espessura. Além dessas propriedades outro fator importante a ser analisado é a transmitância térmica (U) o qual é medido em $W/m^2.K$ que representa a quantidade de watts de calor atravessando o equivalente a $1m^2$ de um componente construtivo estando este submetido a uma diferença de temperatura (Westphal, 2016).

2.5 A evolução dos métodos de elaboração de projetos: do desenho manual à computação gráfica

Durante muitos anos, era comum a elaboração de projetos por meio de métodos manuais, até que o computador se popularizou de forma efetiva. Foi somente em 1957 que Patrick J. Hanratty criou o sistema CAM (*Computer Aided Manufacturing*), que consistia em manufatura assistida por computador, e que serviu como precursor do conhecido sistema CAD (*Computer-aided design*), que é o desenho assistido por computador (Monteiro, 2012).

Em 1960, Ivan Sutherland apresentou ao mundo o *Sketchpad* por meio de sua tese no Instituto de Tecnologia de Massachusetts (MIT). Ele introduziu o conceito revolucionário de desenhar em 2D na tela do computador usando uma caneta óptica, conhecida como Light Pen, com auxílio de uma caixa de botões de comandos. Esse marco histórico estabeleceu Ivan Sutherland como o pioneiro da computação gráfica (Segnini, 2002). Na Figura 11 é possível verificar o uso do *sketchpad*.

Figura 11 – O uso do *sketchpad*

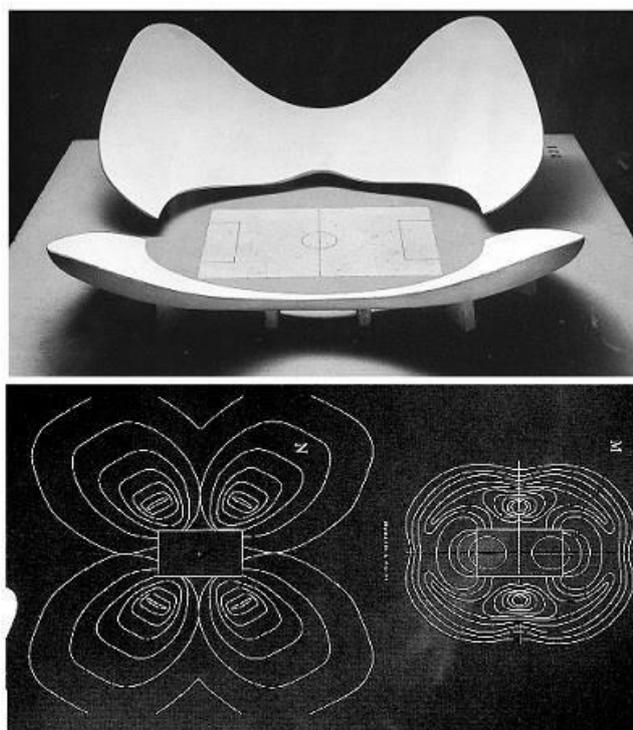
Fonte: Yares (2013).

2.6 Design paramétrico

Tarefas complexas e repetitivas, que podem ser simplificadas em conjuntos de regras, têm a possibilidade de serem codificadas em um programa para automatizar um longo processo de implementação manual. Esse avanço deu origem ao design paramétrico, em que uma tarefa pode ser expressa como um conjunto de comandos para o computador, e cabe ao projetista comunicar esses comandos ao software, enquanto isola os parâmetros que afetam o resultado. Após a conclusão da codificação, o projetista tem a capacidade de modificar os parâmetros, gerando diferentes cenários e, como resultado, produzindo diferentes saídas de projeto (Chaillou, 2019).

O termo design paramétrico possui sua origem na matemática e ainda é debatido sobre quando foi inicialmente utilizado pelos projetistas. Tedeschi (2011) acredita que a proveniência do termo veio de Luigi Moretti que definiu os termos “arquitetura paramétrica (*parametric architecture*)” em 1939, quando utilizou o projeto de um estádio de futebol para exemplificar, explicando que a forma do estádio poderia ser determinada por dezenove parâmetros associados a ângulos de visão e custos de concreto, conforme Figura 12 abaixo.

Figura 12 – Modelo do estádio criado por Luigi Moretti em 1939



Fonte: Gallo e Pellitteri (2018).

Para Tedeschi (2011) a história do design paramétrico pode ser dividida em três etapas. A primeira teve início na década de 60 através da criação do sistema CAD (*Computer-Aided Design*) no qual era possível a criação de modelos 3D e as alterações de geometrias eram realizadas através da modificação de parâmetros.

A segunda etapa iniciou entre os anos 90 e 2000 através do desenvolvimento de softwares de simulação e modelagem paramétrica, como por exemplo, o Grasshopper, permitindo que projetistas pudessem criar modelos mais precisos e complexos (Tedeschi, 2011).

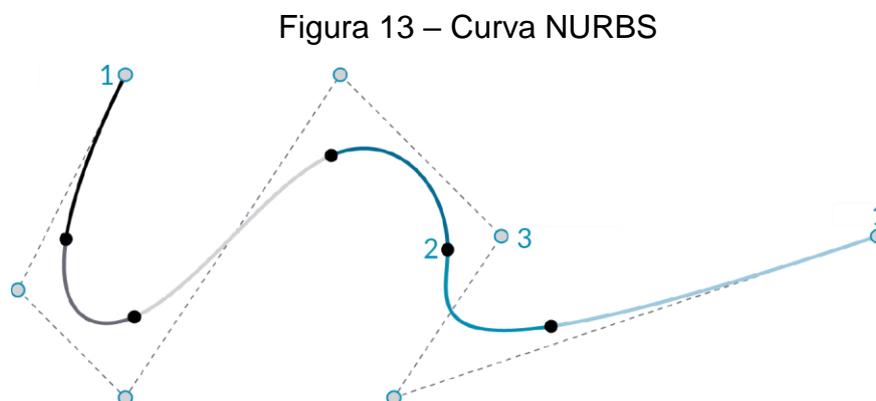
Por volta de 2010 teve início a terceira etapa da fabricação paramétrica através da criação de tecnologias como impressora 3D e robótica que auxiliaram no desenvolvimento da fabricação digital (Tedeschi, 2011).

O design paramétrico trata-se de uma modelagem com base em algoritmos que possibilita a elaboração de formatos complexos e orgânicos, através da definição de parâmetros e restrições aplicadas pelo projetista, que podem ser alteradas até o encontro do melhor design. Através de sua aplicação é possível a criação de edificações em formatos complexos e ao mesmo tempo mais eficientes, nas quais a

aplicação das técnicas convencionais de projeto demandariam grande quantidade de tempo empregado em sua elaboração (Schumacher, 2011).

2.6.1 Softwares de modelagem paramétrica

Nos últimos anos, a modelagem tridimensional tem se tornado uma ferramenta essencial em diversas áreas, como design industrial, arquitetura e engenharia. Entre os programas de modelagem disponíveis, o *Rhinceros* se destaca como um software paramétrico que utiliza o modelo matemático *NURBS* (*Non Uniform Rational Basis Spline*) para a geração de superfícies e curvas, oferecendo aos usuários a capacidade de criar modelos complexos e precisos, com base em curvas e superfícies matematicamente definidas ou através de pontos de controle. Essa abordagem paramétrica permite ajustar e modificar os modelos de forma flexível, facilitando o processo de design e possibilitando a criação de formas personalizadas (De Souza, 2020). A Figura 13 exemplifica a curva NURBS e seus pontos de controle.



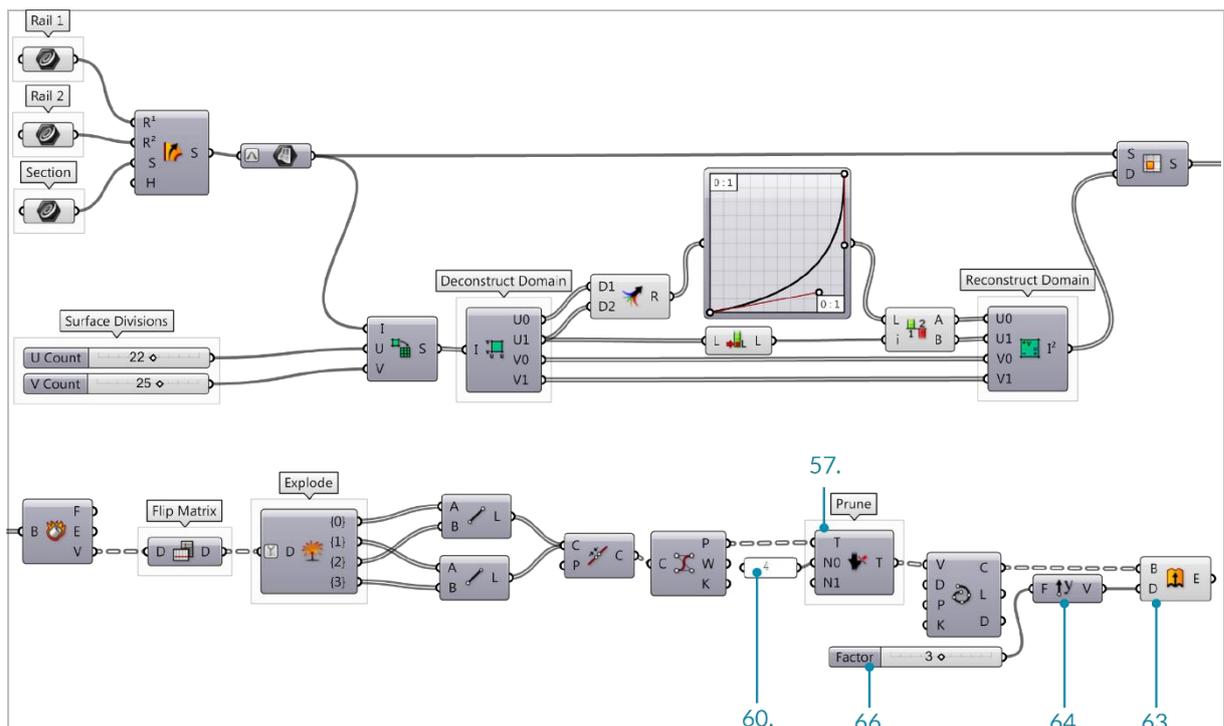
Fonte: Akos e Parsons (2015).

As curvas NURBS, têm sua origem nas pesquisas realizadas nos laboratórios das fabricantes de automóveis Renault e Citroen, na década de 1950. No entanto, somente a partir dos anos 1990 seu uso foi amplamente implementado em softwares comerciais de desenho assistido por computador (CAD) (Scheurer, 2010).

2.6.2 Plugin de programação visual

O *Grasshopper* é um plugin de programação visual (VLP) contido dentro do software *Rhino*, desenvolvido em 2014 por *David Rutten*, amplamente utilizado nas áreas de arquitetura, engenharia e design de produtos. O algoritmo é construído através de nós, onde cada um representa uma entrada e uma saída e são interligados através de fios, conforme Figura 14. No *Grasshopper* existem componentes e parâmetros, os quais representam funções ou elementos geométricos. Os componentes realizam operações com os dados provenientes de entradas e apresentam os dados de saída, assim em seguida é possível realizar uma ligação com outro componente de execução, visualização ou com um parâmetro de armazenamento de dados (Machado, 2018).

Figura 14 – Exemplo do algoritmo visual no *Grasshopper*



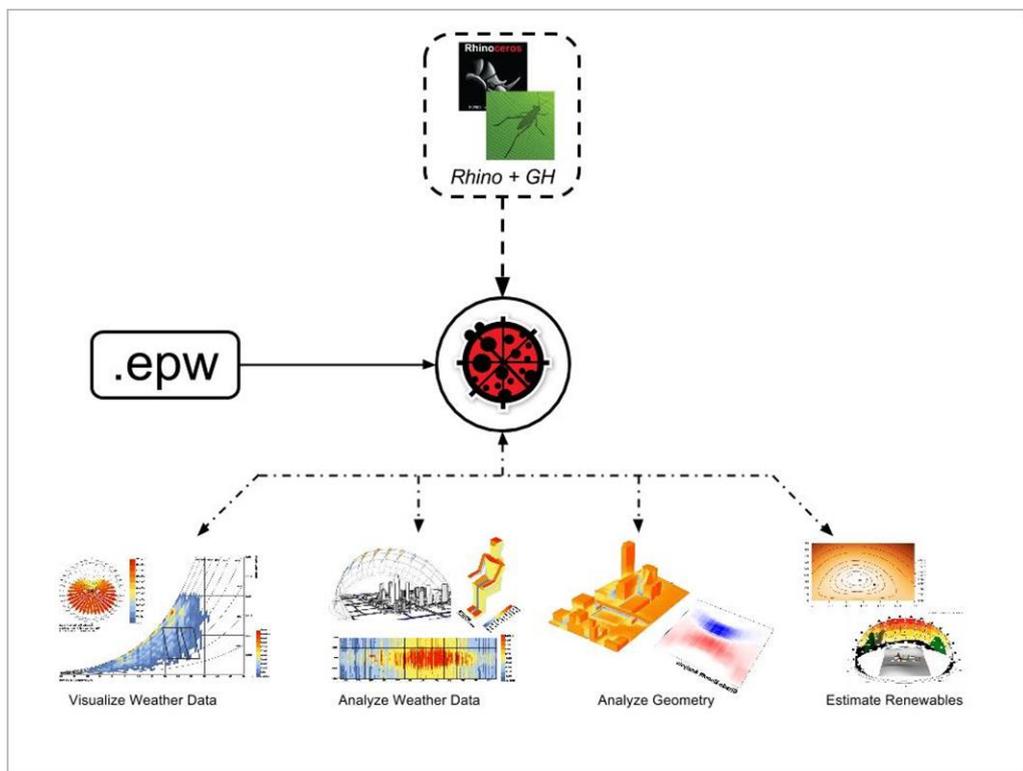
Fonte: Mcneel e Davidson (2023).

Os dados utilizados no *Grasshopper* possuem várias formas, tais como: números, texto, informações de origem de base de dados e geometrias. Seus parâmetros de entrada dinâmicos permitem modificações através de outros componentes nativos ou mesmo advindos de outros *plugins* como o *LadyBug* (Machado, 2018).

2.6.3 Ladybug

O *Ladybug* é um plugin de código aberto que oferece a possibilidade de realizar análises climáticas baseada em dados climáticos. Possui conexão com dados de arquivo *.epw que auxiliam na tomada de decisões logo em estágios iniciais de projetos. Possui componentes que ajudam nas análises de conforto térmico, análises de radiação solar, estimativas de geração de energia renováveis e análises de visualizações. Podemos visualizar este fluxo conforme a Figura 15 (Ladybug Tools, 2022).

Figura 15 – Integração entre arquivos e análises possíveis no *LadyBug*



Fonte: Mcneel (2023).

Sua integração com a modelagem paramétrica permite retorno instantâneo de informações sobre os impactos de alterações em projetos as quais podem impactar no desempenho da edificação (Ladybug Tools, 2022).

2.6.4 O design paramétrico do hotel morpheus de Zaha Hadid

A parametrização na arquitetura encontra um exemplo perfeito nos trabalhos realizados por Zaha Hadid Architects, segundo Chaillou (2019). Zaha Hadid, uma arquiteta iraquiana com formação também em matemática, buscava integrar a matemática ao design arquitetônico. Seus projetos eram fruto de regras e ajustes de parâmetros codificados em programas, possibilitando um alto nível de controle sobre a geometria das edificações.

Um exemplo notável dessa abordagem é o hotel Morpheus, concluído em 2018 como um projeto da Zaha Hadid Architects em parceria com Buro Happold. Situado em Macau, China, o hotel possui impressionantes 39 andares e uma altura de 160 metros. Uma característica marcante de sua arquitetura são as duas grandes aberturas de forma livre localizadas na parte central da edificação, que permitem a passagem de duas passarelas, como ilustrado na Figura 16 (Wortmann; Tunçer, 2017).

Figura 16 – Hotel Morpheus



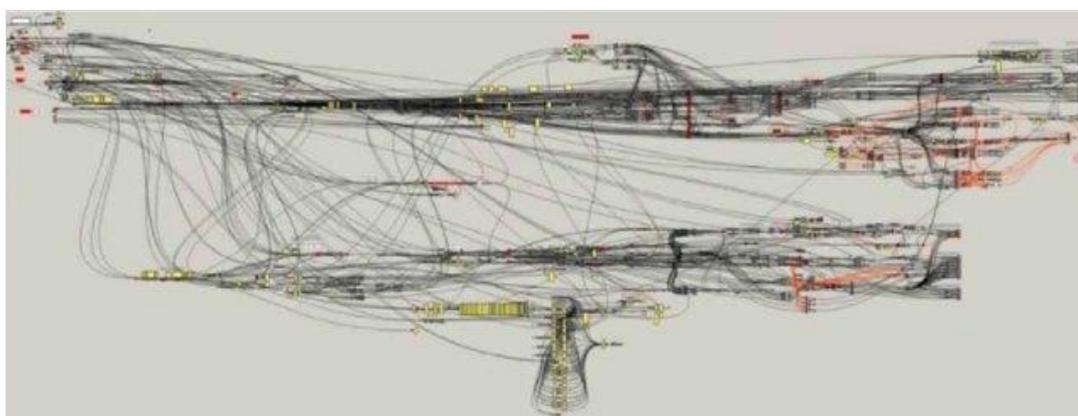
Fonte: Zaha Hadid Architects (2018).

O desenvolvimento desse projeto foi viabilizado pela utilização de um modelo paramétrico, o qual introduziu uma nova tipologia arquitetônica. A estrutura externa do hotel desempenha a função de suportar a carga de aço e possui um formato de exoesqueleto vertical, composto por uma casca de vidro entrelaçada. A criação desse

modelo foi realizada por meio de scripts e códigos personalizados para os softwares Rhinoceros e Grasshopper. Esse modelo permitiu a integração de requisitos formais, estruturais, estéticos e de fabricação, promovendo uma colaboração e comunicação coletiva eficaz. Aljukic (2020) destaca uma vantagem importante da aplicação de modelos paramétricos: o contínuo desenvolvimento do processo, desde o conceito até a construção, o que possibilitou a revisão de opções e geometrias previamente analisadas e exploradas ao longo do processo de desenvolvimento.

Na Figura 17, é possível obter uma visão geral do código utilizado (Aljukic, 2020).

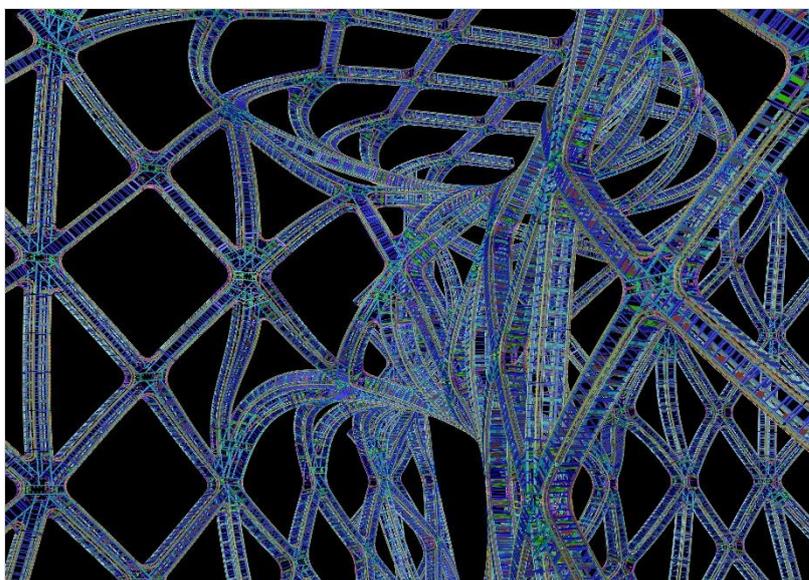
Figura 17 – Modelo desenvolvido no *Grasshopper* para criação do exoesqueleto



Fonte: Zaha Hadid Architects (2018).

Outro modelo paramétrico para a execução do Hotel Morpheus foi realizada pela empreiteira contratada *Front Inc*, que utilizou o modelo do exoesqueleto como base para o projeto detalhado de revestimentos, definição de juntas, reforços e conectores estruturais. A empresa adotou um modelo de dados distribuídos, que consiste em uma rede de centenas de arquivos de geometria e modelos. Uma única operação é executada por cada modelo paramétrico, e o resultado dessa operação é então guardado como geometria, tornando-se entrada para outro modelo paramétrico. Assim, geometrias e informações detalhadas são adicionadas conforme o fluxo de dados da rede. Visando facilitar o fluxo, a empresa desenvolveu o *Elefront*, plugin para que o usuário aumente as geometrias conforme as propriedades de sua própria definição, transformando a geometria em objetos BIM (Heijden, et.al, 2015). A Figura 18 apresenta o modelo gerado.

Figura 18 – Modelagem de fabricação para painéis de revestimento de estrutura do exoesqueleto curvo duplo



Fonte: Heijden (2016).

2.6.5 O design paramétrico da torre de Xangai

Localizada no distrito de Lujiazui, a torre de Xangai é uma das maiores estruturas com fachada dupla do mundo, possuindo 128 andares de formato triangular torcido e afinado, os quais minimizam cargas de vento. Xia e Peng (2014) afirmam que a abordagem paramétrica aplicada a edificação proporcionou otimizações de processos e uma economia de aproximadamente US\$58 milhões em aço estrutural. A fachada exterior da Torre de Xangai apresenta um perfil horizontal de triângulo equilátero com vértices arredondados e um entalhe em um dos vértices. Em termos de perfil vertical, a torre torce e afina à medida que se eleva, criando uma estética dinâmica e funcional, a Figura 19 apresenta suas características.

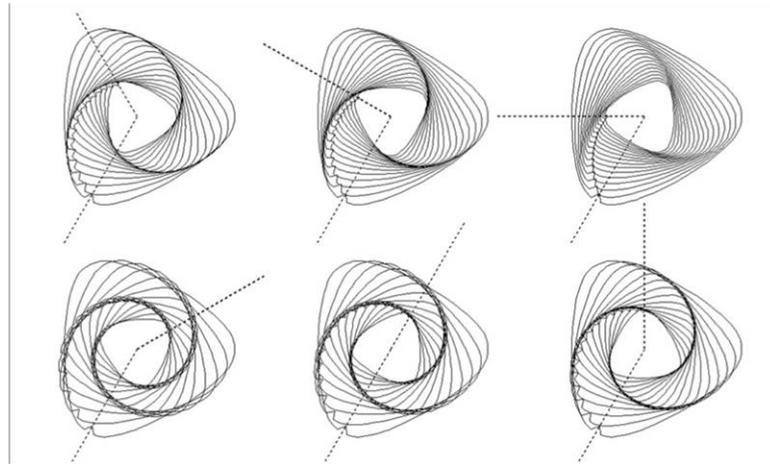
Figura 19 – Torre de Xangai



Fonte: Archdaily (2016).

Cada pavimento foi rotacionado 1% em relação ao andar inferior, logo sua escala foi diminuindo conforme a subida da edificação. Através do uso de software paramétrico, foi possível gerar uma economia também em vidros em comparação as edificações de fachada retangular, aproximadamente 130 mil metros quadrados de vidro foram distribuídos em mais de 25 mil painéis, além de facilitar a interação e os testes de opções de design, com maior agilidade, acelerando o desenvolvimento de perfis verticais completos a partir de um perfil horizontal padrão (Xia; Peng, 2014). A Figura 20 apresenta a rotação da planta da torre.

Figura 20 – Rotação da planta



Fonte: Fonte: Archdaily (2016).

A modelagem paramétrica da torre de Xangai não só auxiliou nos estudos de fachada como nos estudos da estrutura a qual resiste a cargas de vento, gravidade e terremotos, composto por vigas curvas, hastes de suspensão, travessas em X para estabilidade e escoras perpendiculares. Na Figura 21 é possível verificar sua estrutura interna. O plano triangular foi dividido em seis segmentos e cada um destes segmentos segmentado em outros 5, assim foram estabelecidos pontos de trabalho para conexão das vigas e ponto central do edifício. Os dados da modelagem paramétrica gerados pelo Grasshopper foram exportados para outros softwares com Excel e o Autodesk Revit através de um script em C# afim de automatizar essa etapa, permitindo assim a geração de plantas e a integração com a tecnologia BIM (Xia; Peng, 2014).

Figura 21 – Imagem interna da estrutura da Torre de Xangai



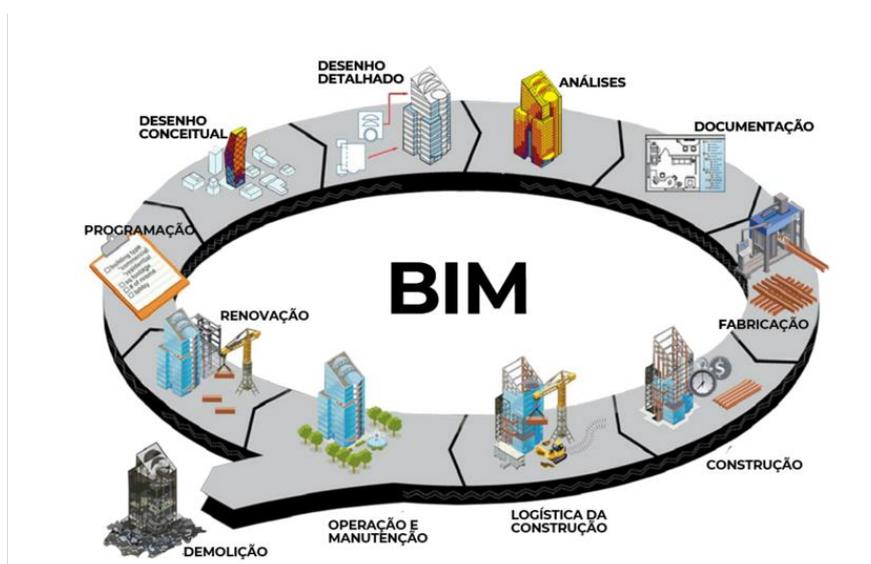
Fonte: Fonte: Archdaily (2016).

2.7 Tecnologia BIM

De acordo com Chaillou (2019), a parametrização oferece benefícios que vão além dos apresentados em softwares como o Grasshopper. A tecnologia *BIM* (*Building Information Modeling*) também se beneficia da aplicação de parâmetros. Na plataforma *BIM*, cada elemento 3D é definido por meio de parâmetros que orientam e documentam cada objeto presente no documento.

O conceito BIM conforme conhecido atualmente advém de um trabalho intitulado *Building Description System (BDS)* de 1975, criado por Chuck Eastman, onde ele explica que os desenhos deveriam fornecer informações de forma mais interativa, onde as modificações realizadas seriam feitas apenas uma vez e quantitativos e descrições dos objetos estariam conectados dentro de um banco de dados (EASTMAN, 1975). Através da utilização da tecnologia BIM, é possível representar digitalmente as características funcionais e físicas de edificações desde o estágio inicial de concepção até a sua demolição. Além disso, o BIM facilita a colaboração entre diferentes profissionais ao longo das diversas etapas do ciclo de vida do empreendimento (NIBS, 2022). A Figura 22 mostra o ciclo de vida do BIM.

Figura 22 – Ciclo de Vida BIM



Fonte: Crasa (2015).

Segundo Chaillou (2019), Philip Bernstein, ex-vice-presidente da Autodesk (fabricante do software Revit, o software BIM mais utilizado no mundo), desempenhou um papel fundamental na viabilização do BIM na indústria da construção civil.

2.8 A história da inteligência artificial

A Inteligência Artificial é um campo da ciência da computação que se dedica ao desenvolvimento de mecanismos físicos e digitais para simular o pensamento e as tomadas de decisão humanas. No contexto da inteligência artificial contemporânea, destaca-se o aprendizado de máquina, que permite que sistemas aprendam de forma autônoma a tomar decisões com base na identificação de padrões e no processamento de dados (Barbosa; Portes, 2019).

A história da inteligência artificial teve início em 1950 quando Marvin Minsky e Dean Edmonds na época estudantes de graduação em Harvard criaram o primeiro computador de rede neural, chamado de SNARC (*Stochastic Neural-Analog Reinforcement Computer*). Minsky em Princeton estudou a computação universal em redes neurais. Muitos trabalhos iniciais podem ser identificados com inteligência artificial, no entanto o mais influente foi o de Alan Turing ao introduzir o Teste de Turing, aprendizado de máquina, aprendizado por reforço e algoritmos genéticos (Russell; Norvig, 2014).

O conhecido teste de Turing, conforme comenta Koch (2022), tinha como propósito verificar se as máquinas poderiam pensar de forma inteligente e expressar emoções semelhantes às dos seres humanos. No entanto, esse teste recebeu críticas significativas por focar na capacidade de imitação das habilidades humanas pelas máquinas, em vez de comprovar sua própria inteligência.

Entre 1966 e 1973, a inteligência artificial (IA) enfrentou desafios significativos. A maioria dos programas nesse período não possuía conhecimento sobre os assuntos com os quais estavam lidando e alcançavam sucesso por meio de manipulações sintáticas simples. Os primeiros programas abordavam problemas tentando combinações diferentes de etapas até encontrar uma solução. Essa abordagem funcionava inicialmente para conjuntos de parâmetros menores, que exigiam poucas ações e sequências de soluções. Entretanto, quando se tratava de problemas mais complexos, o dimensionamento desses métodos se tornava muito mais desafiador. No ano de 1969, Minsky e Papert apresentaram o *Perceptrons*, uma forma de rede neural simples. Embora representasse um avanço, o *Perceptrons* apresentava limitações em termos de capacidade de aprendizado e representação (Russell; Norvig, 2014).

Até a década de 1980 a Inteligência Artificial (IA) passou por diversas adaptações até se tornar uma indústria em crescimento, com a utilização comercial de sistemas especializados. Nesse período, houve avanços significativos nas redes neurais, além da adoção do método científico, teorias probabilísticas e o tratamento de grandes volumes de dados, impulsionando assim o desenvolvimento da IA. (Russell; Norvig, 2014).

O algoritmo *Backpropagation* (Retropropagação do erro) também auxiliou no avanço da IA. Inicialmente desenvolvido para auxiliar as redes neurais no reconhecimento de padrões, ele posteriormente foi aplicado em diferentes áreas de aprendizado de máquina, aprimorando a generalização de conjuntos de dados e o desempenho dos modelos. Em 2006, ocorreu um marco no desenvolvimento da aprendizagem profunda, graças ao trabalho de Geoffrey Hinton. Além disso, em 2014, a empresa Meta criou o *DeepFace*, um sistema baseado em aprendizado profundo que superou o desempenho humano no reconhecimento facial. Hoje a aplicação da inteligência artificial é cada vez maior em inúmeros campos de aplicação, permitindo relacionamento entre dados, descoberta de padrões, além da extração de percepções e previsões de problemas complexos (Koch, 2022).

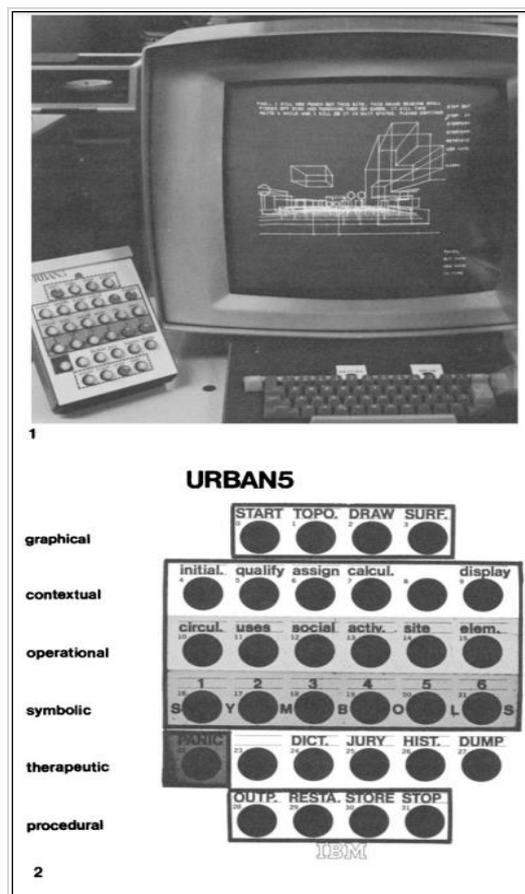
2.8.1 A origem do aprendizado de regras por árvores de decisão

Visando simular o comportamento humano, em 1966 foi desenvolvido o sistema *CLS (Concept Learning System)* o qual tinha como objetivo aprender árvores de decisão através de exemplos. O sistema foi submetido a uma ampla avaliação experimental. Uma contribuição muito significativa do sistema foi sua aplicação na geração de regras para diagnósticos de problema médicos. Baseado em conjuntos de exemplos e características, o sistema conseguia aprender a formular regras e identificar padrões. Além disso, o CLS serviu como inspiração no desenvolvimento do sistema *ID3 (Iterative Dichotomizer three)* projetado para gerar regras partindo de grande quantidade de dados, aplicado com sucesso em várias áreas como, por exemplo, na determinação da posição final e vencedora do jogo de xadrez. Trabalhando com cerca de 1,4 milhões de possíveis posições de peças no tabuleiro, o sistema foi capaz de analisar e aprender (Kononenko; Kukar, 2007).

2.8.2 A Inteligência artificial na arquitetura

O potencial da inteligência artificial na arquitetura foi previsto anteriormente, e em 1973, Negropte e Groisser desenvolveram o *Urban II* como um assistente de máquina. Posteriormente, lançaram o *Urban V*, que auxiliava os designers na adaptação de layouts dos cômodos, otimizando as condições de iluminação à medida que o usuário desenhava em uma grade modular. O *Urban V* era composto por duas camadas de informações: implícita e explícita, sendo que a camada implícita era deduzida pela máquina, enquanto a explícita era definida pelo usuário. A inteligência artificial do *Urban V*, presente na camada implícita, fazia sugestões de correção ao usuário caso houvesse um conjunto de cômodos posicionados incorretamente (Chaillou, 2019; Negropte, 1970). Na Figura 23 é possível verificar o uso do Urban V em um IBM 2250.

Figura 23 – Tubos de raios catódicos utilizado para o URBAN5 em um IBM 2250, modelo 1



Fonte: Negropte (1970, p.74).

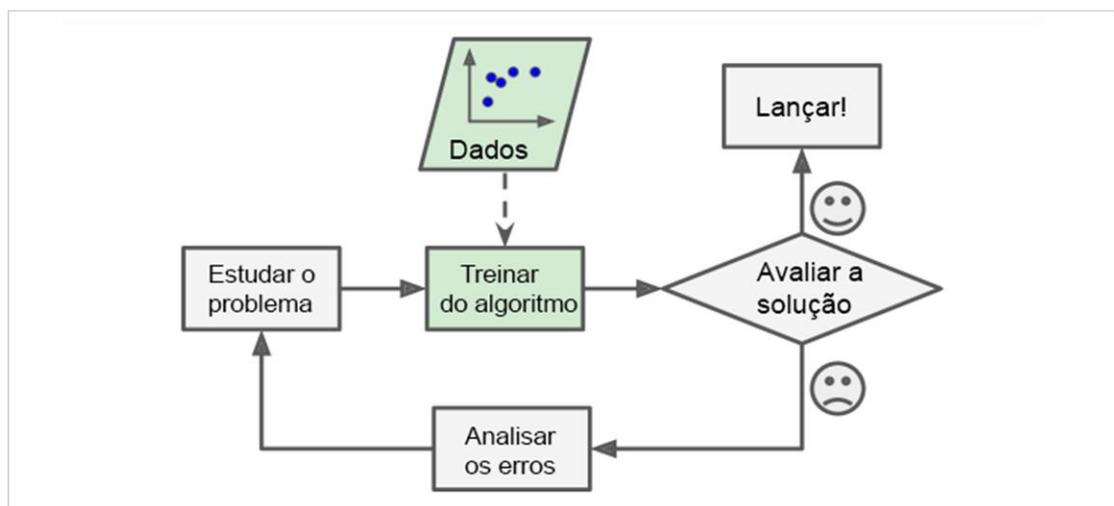
2.9 Aprendizado de máquina

A captura e armazenamento contínuo de dados em computadores ocorre globalmente. Exemplos incluem hospitais registrando informações de tratamentos, edifícios inteligentes coletando dados de comportamento dos usuários, dados energéticos e de consumo, entre outros. A complexidade e o volume desses dados tornam difícil para os seres humanos extraírem informações sem o auxílio de ferramentas tecnológicas. Algoritmos de aprendizado de máquina são utilizados para lidar com essa tarefa, já sendo aplicados em tecnologias comuns, como reconhecimento facial, otimização, gerenciamento do consumo de energia e controle de temperatura em edifícios e aprovação de empréstimos bancários (Marsland, 2015).

“[O aprendizado de máquina] é campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados.”
(Samuel, 1959, apud Géron, 2019, p.10)

O aprendizado de máquina é a elaboração e aplicação de modelos algoritmos aprendidos através de dados, afim de que a máquina (computador) elenque tendência e padrões ocultos os quais poderão ser utilizados para a realização de previsões. Pode ser utilizado em inúmeras áreas como, por exemplo, pesquisas na internet, mecanismos de recomendação, análise de durabilidade de equipamentos entre outros (Pierson, 2019). A Figura 24 aborda um organograma exemplificando a abordagem do estudo de máquina.

Figura 24 – Abordagem do Estudo de Máquina



Fonte: Géron (2019, p.11), adaptado pela autora.

Pierson (2019) aponta três etapas fundamentais no processo de aprendizado de máquina: configuração de dados, aprendizagem e implementação. Na primeira etapa é necessário realizar o levantamento e processamento dos dados, selecionar as variáveis adequadas para alimentar o modelo a ser criado e, por fim, dividir os dados em dois conjuntos: um de treinamento e outro de teste. O conjunto de dados de treinamento é utilizado para treinar o modelo, enquanto o conjunto de teste é utilizado para verificar a precisão das previsões realizadas pelo modelo criado. Na segunda etapa, o modelo é experimentado com os dados organizados, através do seu treinamento, elaboração e teste. Por fim, a última etapa consiste na implementação do modelo e na realização das previsões.

O uso de técnicas de aprendizado de máquina em grandes volumes de dados auxilia na descoberta de padrões, tendências e informações importantes, o que é conhecido como mineração de dados (Géron, 2019). A analogia com as minas é adequada, pois assim como na mineração de matéria-prima, na mineração de dados é necessário processar um grande volume de dados para extrair uma quantidade menor, porém de informações valiosas (Alpaydin, 2020).

Géron (2019) menciona os seguintes benefícios do aprendizado de máquina: simplificação e melhor desempenho na descoberta de soluções que anteriormente requeriam ajustes manuais, auxílio na resolução de problemas complexos que seriam difíceis de encontrar por meio de métodos tradicionais, além capacidade de lidar com grandes volumes de dados e adaptar-se a novos dados.

2.9.1 Estilos de aprendizado

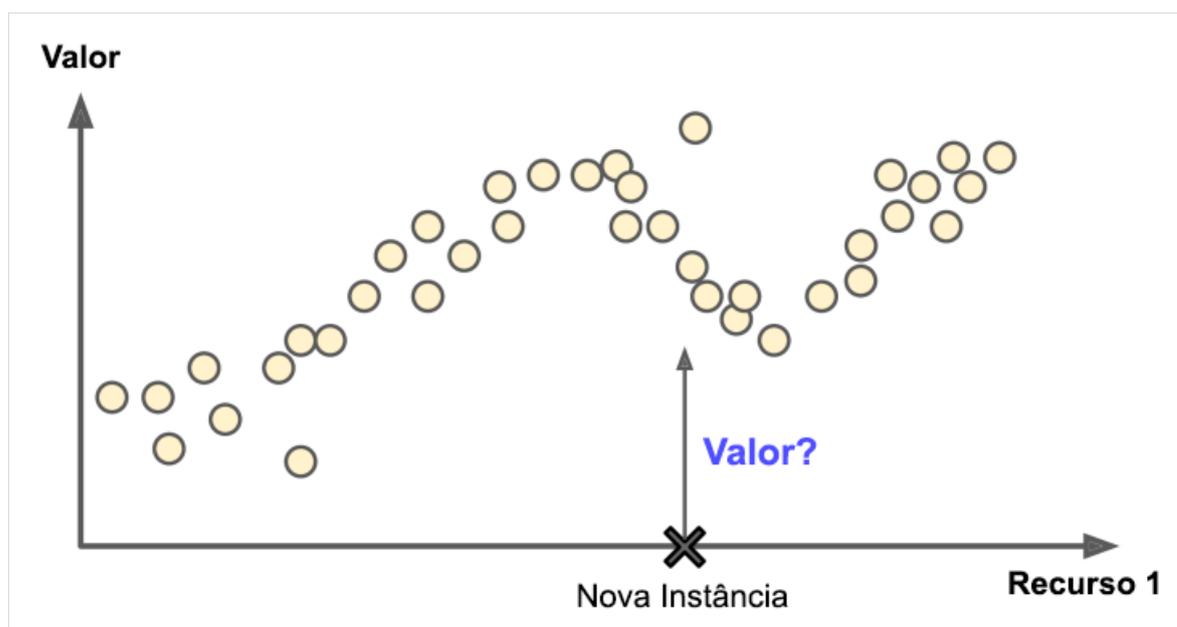
Existem três tipos principais de aprendizado de máquina: supervisionado, não supervisionado e por reforço.

No aprendizado supervisionado, o modelo é treinado com dados que já têm uma resposta conhecida, com o objetivo de aprender a relação entre as variáveis de entrada e as de saída. Esse tipo de aprendizado é comum porque permite que o modelo faça previsões precisas em novos dados de entrada. Alguns algoritmos de aprendizado supervisionado são regressão linear, árvores de decisão, *support vector machines* (SVMs) e redes neurais (Alpaydin, 2020).

Um exemplo típico de aplicação do aprendizado supervisionado é para fazer a previsão do valor numérico de destino, como o valor de um carro, cujo dado de

conjunto possui características como marca, quilometragem e idade, os quais são chamados de preditores. Essa técnica específica é chamada de regressão (Figura 25), que busca estabelecer uma relação entre os preditores e o valor numérico a ser previsto (Géron, 2019).

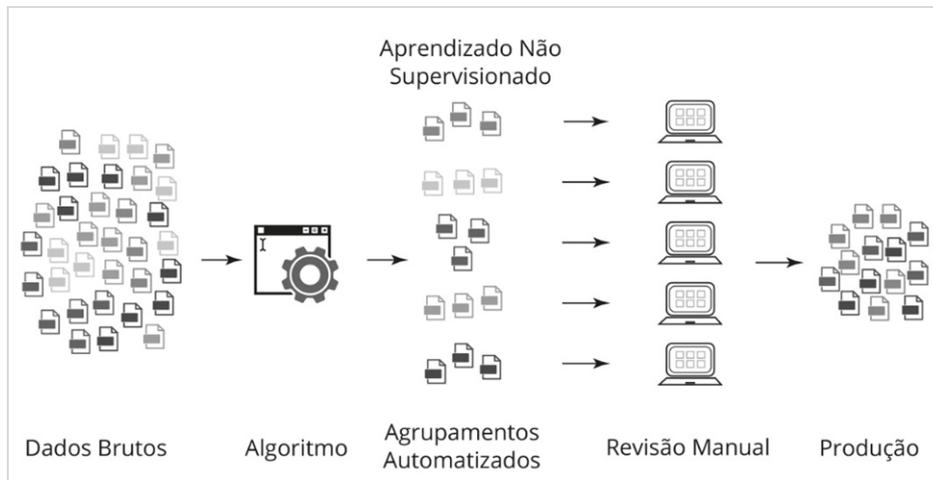
Figura 25 – Regressão



Fonte: Géron (2019, p.15), adaptado pela autora.

No aprendizado não supervisionado, o algoritmo recebe dados não rotulados e tenta encontrar padrões ou estruturas nos dados, agrupando-os ou segmentando-os em categorias com base em suas semelhanças. Algumas técnicas comuns de aprendizado não supervisionado incluem o agrupamento k-vizinhos mais próximos de análise de componentes principais e decomposição de valores singulares. Essas técnicas são úteis para explorar padrões ocultos em dados sem uma resposta conhecida (Pierson, 2019). Na Figura 26 é possível verificar o exemplo do funcionamento do aprendizado não supervisionado.

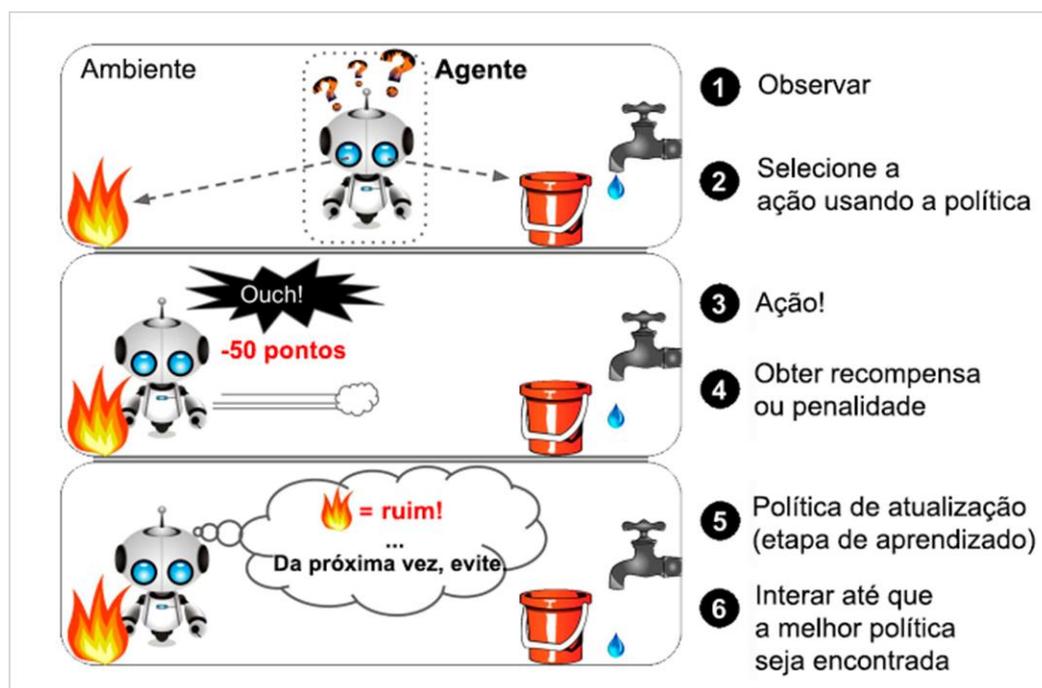
Figura 26 – Aprendizado não supervisionado divide os dados não rotulados em subgrupos



Fonte: Pierson (2019, p.54).

O aprendizado por reforço é um estilo de aprendizado de máquina presente em algoritmos como *Q-learning*, *Sarsa* e *Deep Reinforcement Learning*. Nesse estilo, o modelo é treinado a partir de recompensas ou punições recebidas em um ambiente, e o objetivo é que o modelo aprenda a escolher ações que maximizem a recompensa esperada (Alpaydin, 2020). O modelo é treinado através de tentativa e erro, e recebe feedback do ambiente em forma de recompensas ou punições para cada ação tomada. O aprendizado por reforço é útil em situações em que é necessário tomar decisões com base em um ambiente complexo e dinâmico, muito similar ao mecanismo de aprendizagem de animais (Pierson, 2019). Na Figura 27 é apresentado um exemplo visual do aprendizado por reforço.

Figura 27 – Exemplo visual de aprendizado por reforço



Fonte: Géron (2019, p.21) adaptado pela autora.

2.9.2 Sobreajustamento e sub - ajustamento

Grus (2016) cita dois problemas recorrentes em modelos de aprendizado de máquina, o *overfitting* e o *underfitting* traduzidos como sobreajustamento e sub-ajustamento. O sobreajustamento é quando o modelo acaba por se ajustar demasiadamente aos dados utilizados para treinamento, apresentando em dados de teste um desempenho excelente e em dados de teste um desempenho ruim.

Contrário ao sobreajustamento, tem o sub-ajustamento, ou seja, o modelo não aprende bem os padrões dos dados de treinamento, e como reflexo acaba gerando um desempenho ruim nos dados de treinamento e teste. Para ambos existem correções, no caso do sobreajustamento (*overfitting*) existem técnicas de regularização, validações cruzadas e seleção de recursos. Para o sub-ajustamento (*underfitting*) ampliar os dados de treinamento, elevar a complexidade do modelo e utilizar técnicas de seleção de recursos auxilia na sua eliminação (Grus, 2016). Na Figura 28 é possível verificar um exemplo claro sobre sobreajustamento e sub-ajustamento.

Figura 28 – Sobreajustamento, sub-ajustamento e ajuste correto

	Sub- Ajuste	Na medida	Sobreajuste
Sintomas	<ul style="list-style-type: none"> - Alto erro de treinamento - Erro de treinamento perto do erro de teste - Viés Alto 	<ul style="list-style-type: none"> - Erro de treinamento ligeiramente menor do que erro de teste 	<ul style="list-style-type: none"> - Erro de treinamento muito baixo - Erro de treinamento muito menor do que erro de teste - Alta variância
Ilustração de Regressão			
Ilustração de Classificação			
Ilustração de Aprendizado Profundo			
Possíveis Soluções	<ul style="list-style-type: none"> - Complexificar o modelo - Adicione mais recursos - Treine por mais tempo 		<ul style="list-style-type: none"> - Realizar regularização - Obtenha mais dados

Fonte: Shrivastava (2020), adaptado pela autora.

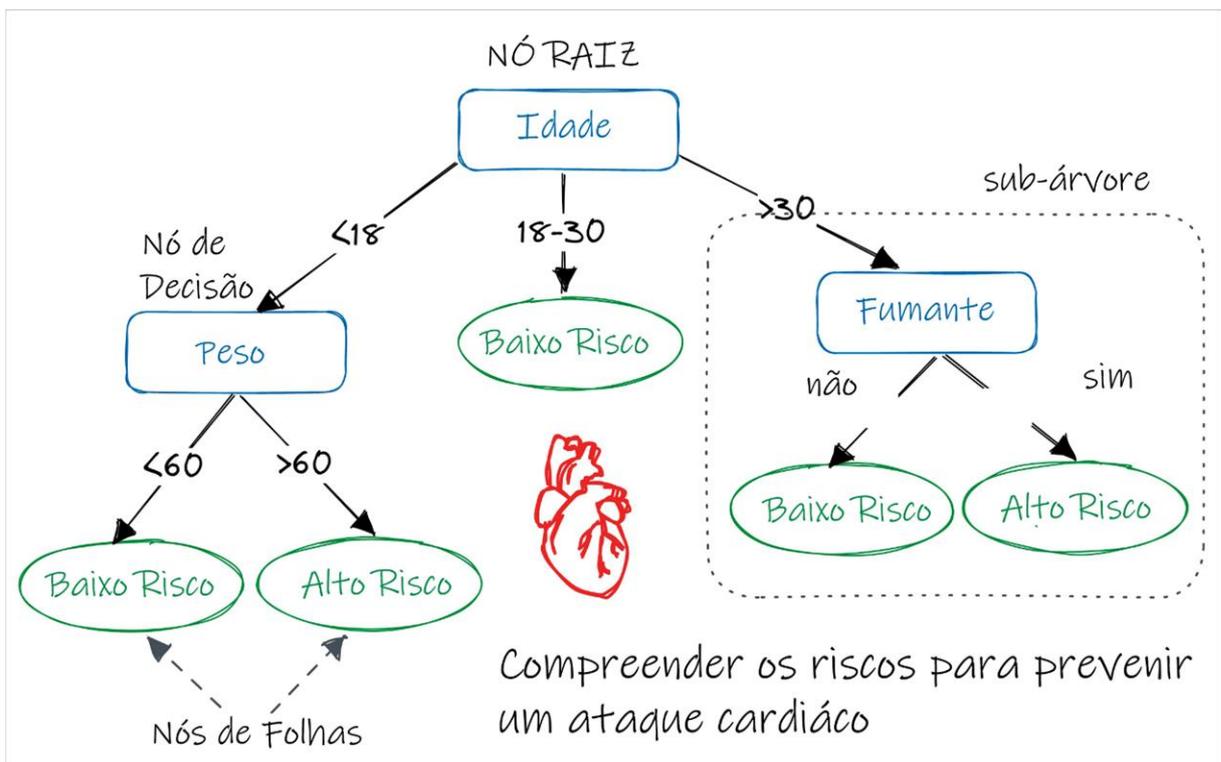
2.9.3 Árvore de decisão

Árvore de decisão (*decision tree*) é um modelo supervisionado de aprendizado de máquina, construída com a divisão de conjunto de dados em subconjuntos baseados em valores e características, assim reduzindo impurezas e ampliando as informações obtidas em cada divisão. Sua estrutura em formato de árvore possui nós internos, onde cada um representar um teste. Cada ramo é um resultado do teste e cada folha valor ou classe, utilizado para previsão de uma classe ou valor de destino baseado em um conjunto de características (Mitchell, 1997).

Grus (2016) destaca que elas são especialmente úteis por serem fáceis de entender e interpretar, tornando o processo de previsão totalmente transparente. No entanto, são propensas a sobreajustarem (*overfitting*). As árvores de decisão podem ser divididas em dois tipos principais: árvores de classificação e de regressão, cada uma com sua própria abordagem para a modelagem de dados.

A Figura 29 apresenta uma ideia clara da proposta de aplicação de uma árvore de decisão em uma análise de risco para pessoas com propensão a sofrer um ataque cardíaco.

Figura 29 – Exemplo da estrutura de uma árvore de decisão



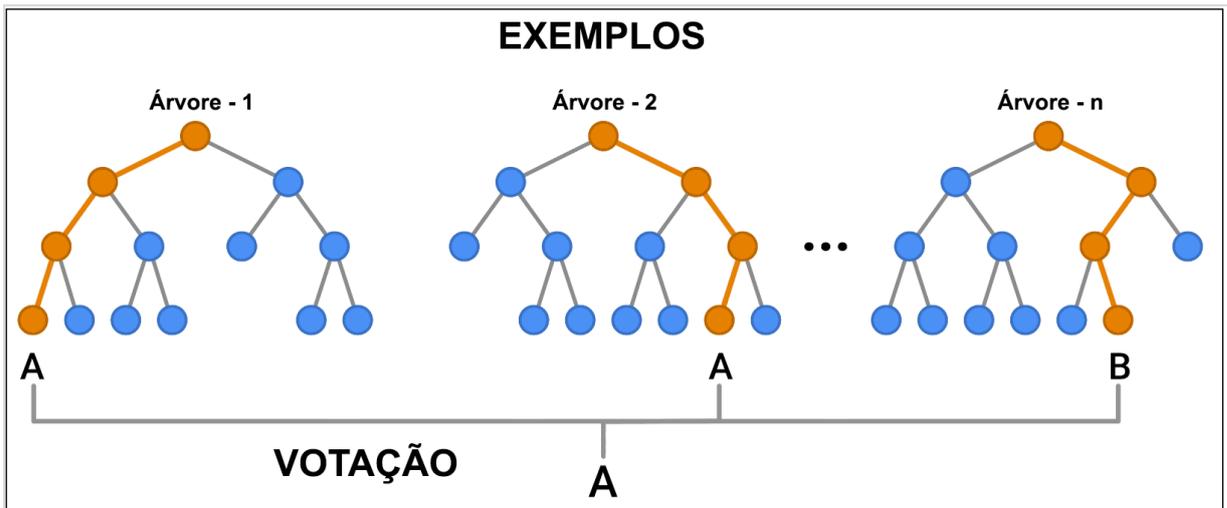
Fonte: Awan apud Navlani (2023), adaptado pela autora.

2.9.4 Florestas aleatórias (*Random Forests*)

As florestas aleatórias (*random forests*) são a combinação de várias árvores de decisão independentes com intuito de realizar previsões mais precisas. Cada uma cria uma coleção de árvores de decisão onde cada árvore individual é treinada com dados diferentes, aleatoriamente selecionada com reposição do conjunto de treinamento original. O resultado final da previsão das florestas aleatórias é realizado através de uma média (regressão) ou através do valor com maior número de repetições

(classificação) de cada árvore do modelo, como pode ser visualizado na Figura 29. Possuem como vantagem a redução de possíveis sobreajustamentos (*overfitting*), além de maior capacidade em lidar com dados desbalanceados e medir a correta importância das características no processo de tomada de decisão (Breiman, 2001). A Figura 30 mostra um exemplo visual de florestas aleatórias.

Figura 30 – Exemplo visual de florestas aleatórias



Fonte: Guillame-Bert et.al (2021), adaptado pela autora.

2.9.5 Python

O Python é uma linguagem de programação de computador, criado por Guido van Rossum. Sua concepção foi no ano de 1990 com o intuito de ser uma sucessora da linguagem ABC. Hoje a linguagem possui o código aberto e seu modelo de desenvolvimento é comunitário. Possuindo uma sintaxe clara que favorece a leitura do código fonte, incluindo estruturas de alto nível e uma vasta coleção de módulos prontos para utilizar. É um código portátil, interpretada através de *bytecode* pela máquina virtual do Python (Borges, 2014).

Para Matthes (2023) a linguagem Python é extremamente eficiente, onde os programas realizados através da aplicação da linguagem utilizam menos linhas de códigos, sendo fácil de ler e realizar alterações se comparado a outras linguagens. O Python é amplamente utilizado em pesquisas acadêmicas e em trabalhos aplicados.

2.9.6 Biblioteca *scikit learn*

A *scikit-learn* é uma biblioteca de aprendizado de máquina em linguagem de programação *Python*, sendo assim de código aberto, muito utilizada devido sua facilidade de uso e grande variedade algoritmos. Foi construída com base em outras bibliotecas muito conhecidas como *NumPy*, *SciPy* e *matplotlib* e oferece uma variedade de algoritmos de aprendizado de máquina como árvores de decisão, florestas aleatórias entre outros. Possui uma documentação abrangente, além de códigos claros (Müller; Guido; 2016).

2.10 Exemplos da aplicação da IA em projetos arquitetônicos

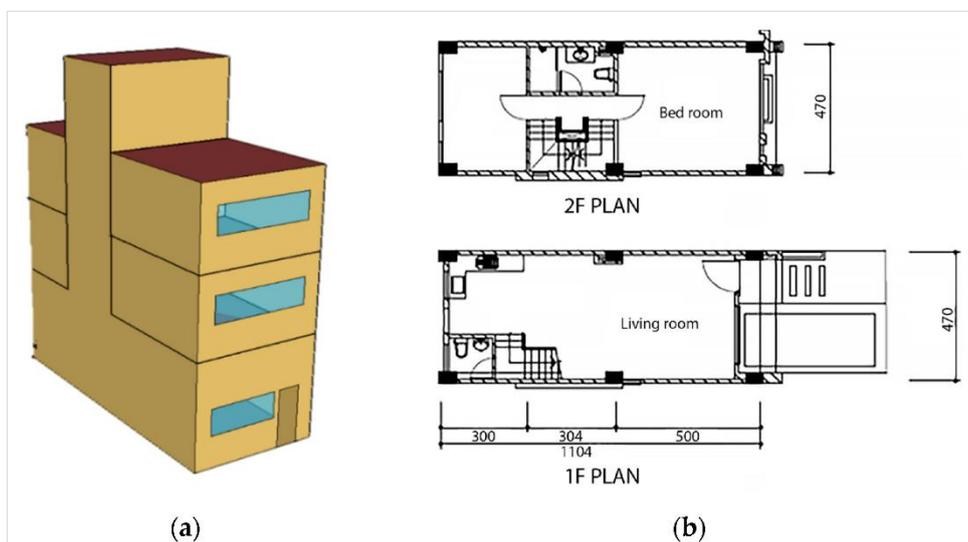
2.10.1 Um modelo de previsão baseado em aprendizado de máquina do ciclo de vida de CO₂ para renovação de envoltório de edifícios em Taiwan

O estudo apresentado por Tsay et al.(2021) realizado em Taiwan, retrata o desenvolvimento de um modelo de aprendizado de máquina com dados de emissões de CO₂ e o consumo anual de 744 edificações geminadas. O objetivo do estudo foi aplicar o aprendizado de máquina na previsão da pegada de carbono no ciclo de vida (Life-cycle CO₂ - LCCO₂) das casas geminadas e o consumo anual de energia, a fim de analisar o comportamento das edificações na renovação de fachadas. Na Figura 31 é possível verificar o 3D e as plantas de uma edificação geminada que representa 49,02% dos edifícios residenciais do país, alternando em orientação solar e tipos de isolamento. Em termos de aplicabilidade, condições climáticas e propriedades materiais simples foram inseridos, no quesito desempenho do modelo, ele teve alta precisão.

Os autores do estudo comentam que no total foram listadas apenas oito características de entrada do modelo de estudo, não sendo necessária a realização de modelos 3D robustos com propriedades detalhadas de materiais para obtenção dos resultados. O modelo preditivo foi realizado de maneira simples e rápida, porém Tsay et al.(2021) atentam que o modelo de aprendizado de máquina apresentado só pode ser usado na previsão da forma de casas geminadas. No caso em que a diversidade e conjunto de dados amostrais puderem ser ampliados a aplicação do modelo pode ser expandida. Para o comportamento comum da renovação das casas

geminadas em Taiwan, o modelo proposto pode prever o consumo anual de energia e a previsão da pegada de carbono no ciclo de vida de maneira mais rápida e conveniente que os métodos convencionais.

Figura 31 – (a) 3D (b) Plantas do edifício de estudo



Fonte: Tsay et al. (2021, p.5).

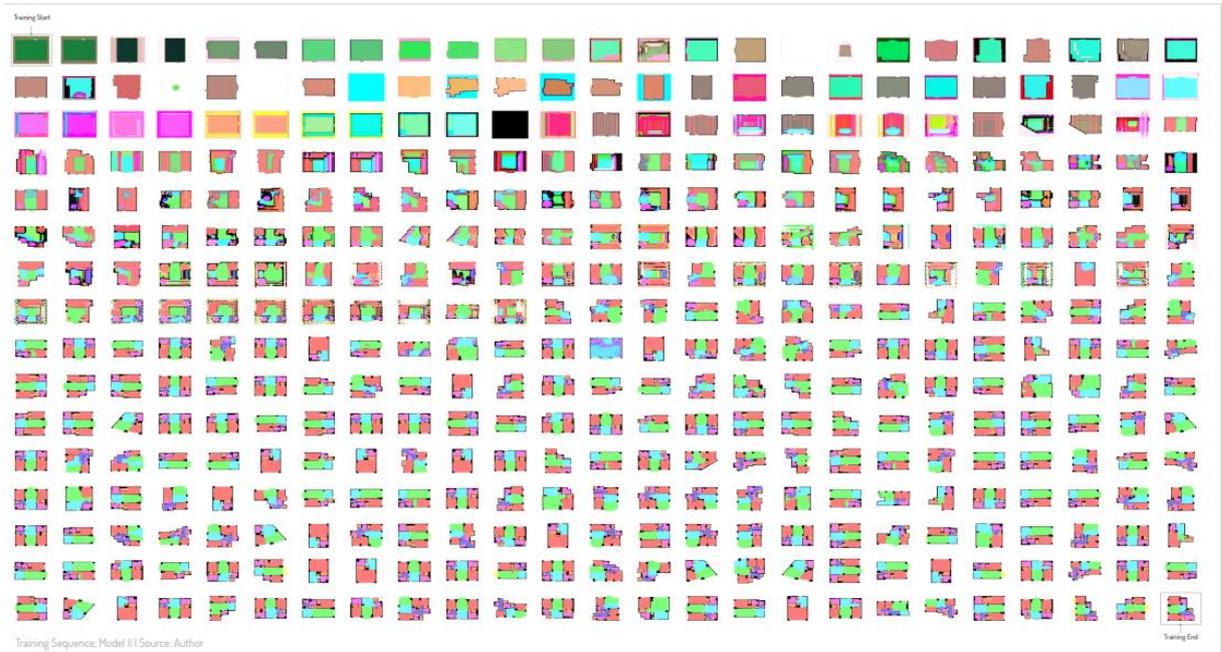
2.10.2 Criando layouts de planta baixa com IA

O projeto do arquiteto Stanislas Chaillou (2019) criado em Harvard foi desenvolvido através da aplicação de GANs (Generative Adversarial Neural Networks), onde buscou utilizar a aprendizagem de máquina para exploração do futuro do design generativo e os impactos na composição de plantas. O estudo inicial era referente à criação de plantas baixas por inteligência artificial, dando seqüência ao treinamento de inúmeros modelos de estilos arquitetônicos diferentes como casas geminadas, vitorianas e estilo barroco. Partindo disso foi possível conferir que cada estilo traz um conjunto base de regras de funcionalidade as quais acabam definindo o espaço e a organização da planta.

Dois modelos compõem o trabalho desenvolvido, um treinado para realizar o reconhecimento de imagens em conjuntos de dados e distinguir entre uma imagem falsa e uma real e outro modelo treinado para criar imagens semelhantes a do conjunto de dados. Assim é possível que um GAN desenvolva uma capacidade de criação de imagens através dos dados observados. Neste caso a estrutura Pix2PIX em modelo GAN padrão foi empregada, aplicando a tecnologia em desenhos de plantas baixas

utilizando representações de imagens como entradas e saída. O objetivo do projeto de Chaillou (2019) foi gerar um layout e o mobiliário dos ambientes de maneira coerente para auxiliar arquitetos, além de converter as plantas para estilos diferentes. Na Figura 32 é possível verificar o treinamento de um modelo com 250 interações.

Figura 32 – Treinamento GANG



Fonte: Chaillou (2019, p.28).

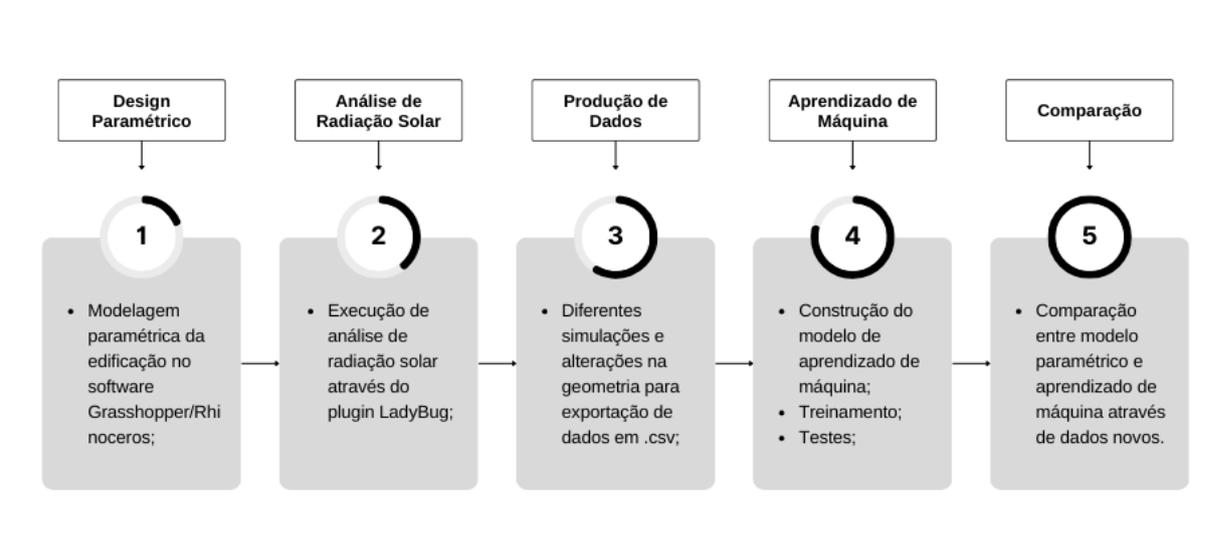
Os modelos foram aplicados em um empreendimento imobiliário de grande escala localizado em Manhattan e evidenciaram que os modelos GAN possuem capacidade para reunir uma enorme quantidade de informações arquitetônicas estando estas conectadas as características próprias de desenho e estilo.

3 METODOLOGIA

O objetivo deste estudo foi investigar a aplicação do uso do aprendizado de máquina supervisionado objetivando a redução de atualizações e alterações do modelo de design paramétrico aplicado a análise de radiação solar.

Para seu desenvolvimento foram definidas cinco etapas conforme pode ser verificado no fluxograma da Figura 33.

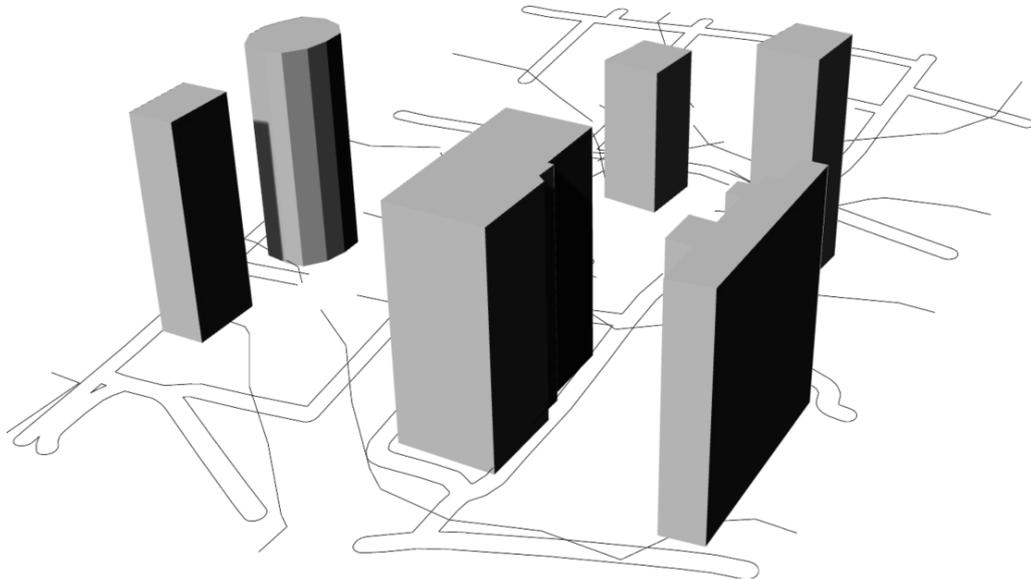
Figura 33 – Fluxograma da dissertação



Fonte: Elaborado pela autora (2023).

A primeira etapa para a realização deste estudo foi a elaboração de uma edificação paramétrica no *plugin grasshopper*, em seguida uma análise de radiação foi realizada com o *plugin Ladybug*, o qual exige um entorno para maior assertividade do estudo, através do modelo 3D criado com auxílio do site *cadmapper*. O arquivo de entorno foi importado como a base no software *Rhinoceros*. Na Figura 34 é possível verificar o entorno gerado através do *cadmapper*.

Figura 34 – Entorno do local



Fonte: Elaborado pela autora (2023).

A análise do projeto foi realizada com base em terrenos reais para gerar dados mais precisos. Os terrenos em questão estão localizados na Avenida Independência, bairro Panazzollo na cidade de Caxias do Sul no estado do Rio Grande do Sul. Na Figura 35 é possível verificar sua localização.

Figura 35 – Localização dos terrenos utilizados para este estudo



Fonte: Elaborado pela autora (2023).

Conforme as informações do site da prefeitura da cidade, juntos os terrenos possuem 892m², frente Sul. Nas informações urbanísticas não consta restrição de altura, somente necessário respeitar 4m de recuo frontal. Informados como terrenos baldios foram escolhidos por estarem localizados na área central da cidade com prédios em seu entorno.

Para a modelagem da edificação foram informadas medidas como largura, profundidade, pé direito, espessura de laje, ângulo das bordas, número de pavimentos, ângulo de rotação do eixo, ângulo de rotação em relação ao norte (azimute). Depois da geração da geometria foi possível realizar a análise de radiação solar incidente e através da alteração das medidas gerar dados os quais foram exportados em formato .csv.

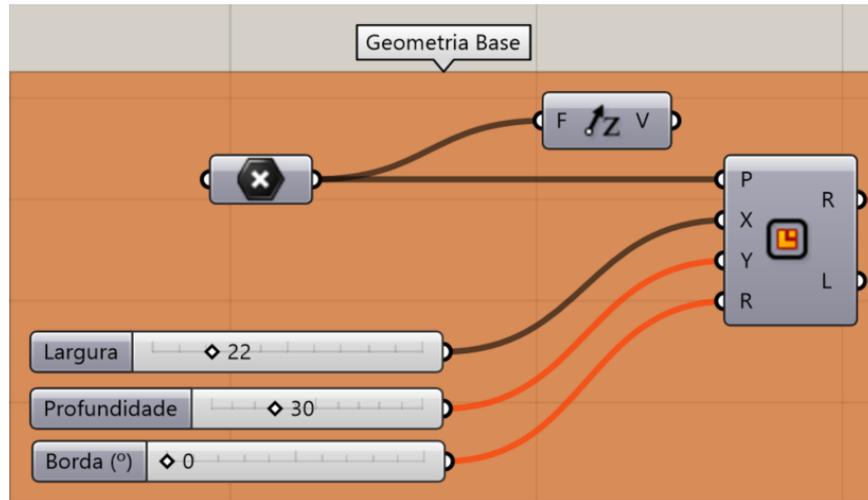
Na quarta etapa através da aplicação da linguagem *Python*, foi elaborado o algoritmo de aprendizado de máquina o qual através dos dados foi treinado e testado. Algumas métricas de avaliação do aprendizado foram aplicadas.

Por fim, na última etapa o algoritmo de aprendizado de máquina gerou dados os quais através de sua análise foram os de melhor aplicação para um bom aproveitamento da radiação incidente no local. Estes mesmos valores foram testados na simulação com o *Ladybug*.

3.1 Modelagem paramétrica

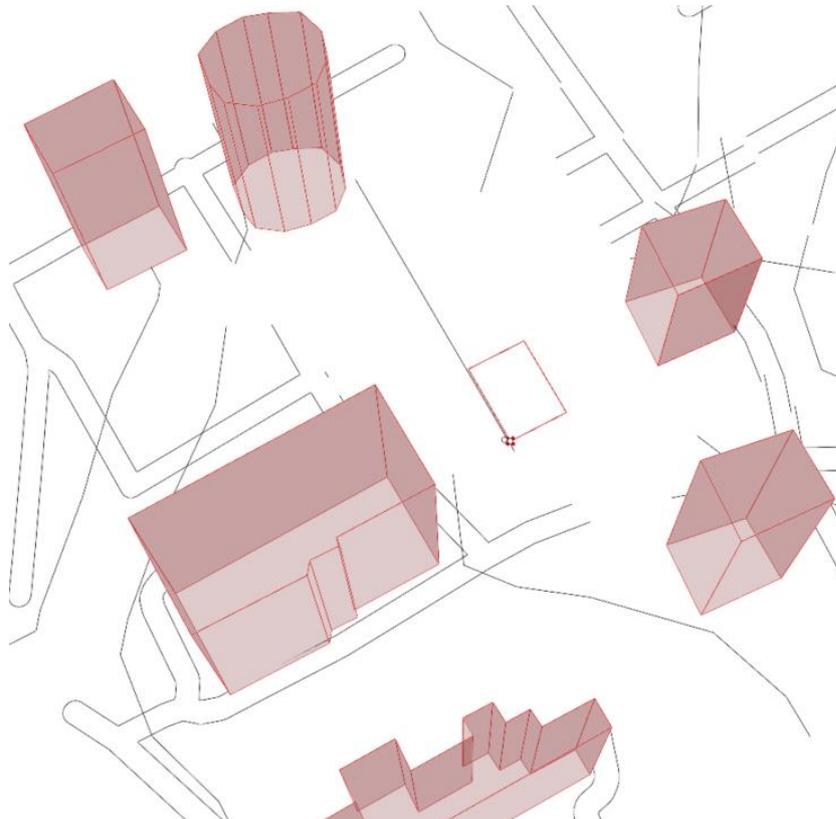
A modelagem paramétrica utilizada para a elaboração da edificação deste trabalho foi realizada no *software Rhinoceros* através de algoritmo visual programado no *plugin Grasshopper*. Para o início foi necessário a criação de uma geometria de base e a mesma foi rotacionada e alterada suas dimensões ao longo do estudo. Na Figura 36 é possível verificar o lançamento da geometria no *plugin Grasshopper* e na Figura 37 no *software Rhinoceros*.

Figura 36 – Geometrias base no *Grasshopper*



Fonte: Elaborado pela autora (2023).

Figura 37 – Geometria base no *Rhinoceros*

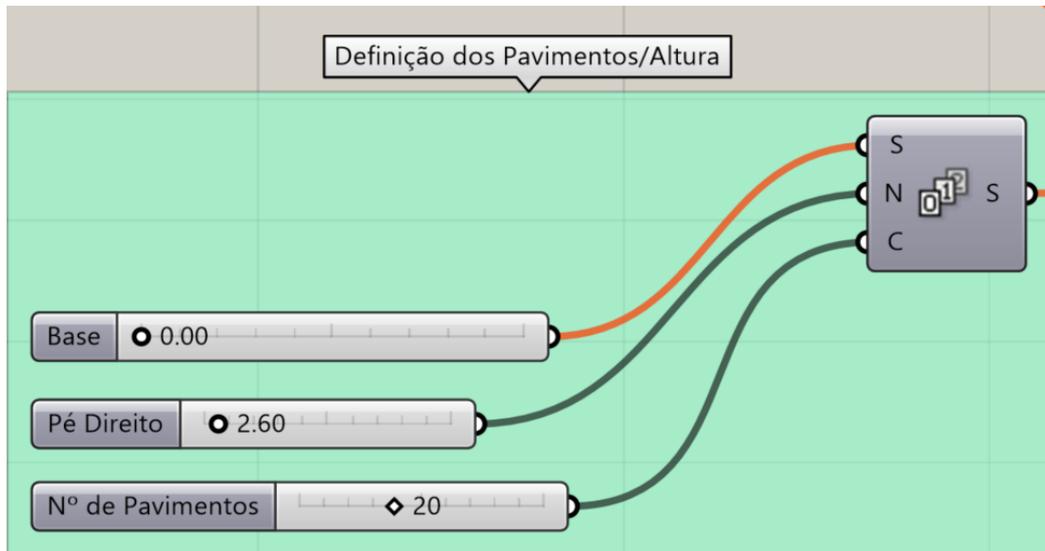


Fonte: Elaborado pela autora (2023).

Para a elaboração da geometria de base no *Grasshopper* o primeiro elemento utilizado é o retângulo o qual requer medidas para gerar a geometria. Posterior a sua criação foi dado início ao desenvolvimento da edificação, sendo necessário informar

itens como número de pavimentos desejados, altura entre os pavimentos e a quantidade de pavimentos, no *Grasshopper* foi possível realizar isso através do *Series* como pode ser verificado na Figura 38.

Figura 38 – Definições de pavimentos no *Grasshopper*

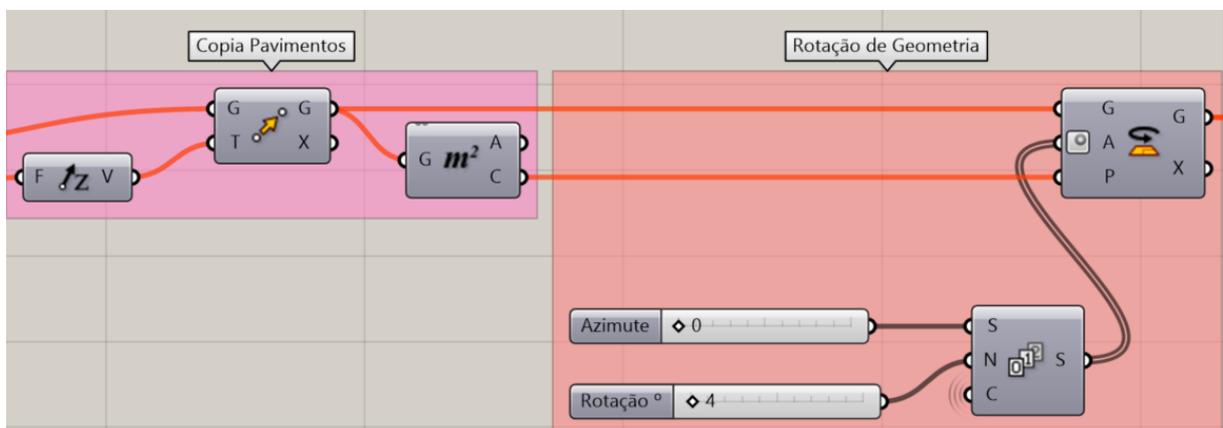


Fonte: Elaborado pela autora (2023).

Após as definições dos pavimentos foi necessário informar ao *Grasshopper* o eixo de sentido para as cópias dos pavimentos, possível através da utilização de *Move* e *Area*, bem como informações sobre sua rotação como o azimute e rotação do próprio eixo da edificação, isso foi possível através do *Series* conectado ao *Rotate*.

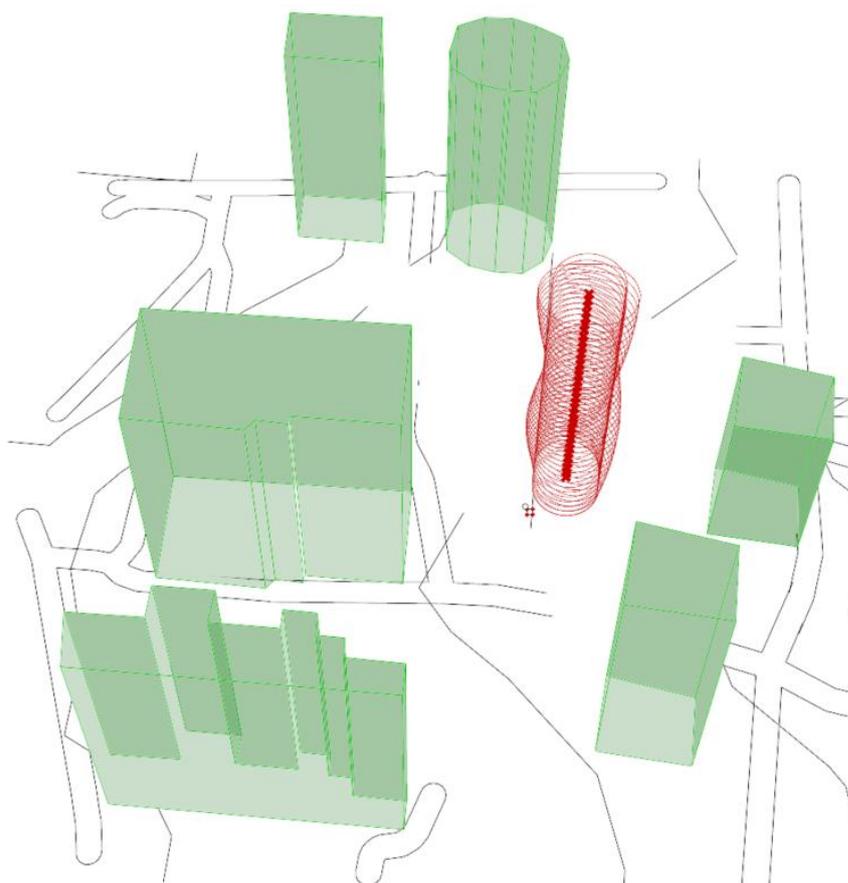
Esta etapa pode ser conferida na Figura 39 sua elaboração no *Grasshopper* e na Figura 40 sua execução no *Rhinoceros*.

Figura 39 – Cópia de pavimentos e rotação da geometria no *Grasshopper*



Fonte: Elaborado pela autora (2023).

Figura 40 – Pavimentos e rotação de geometria criados no *Rhinoceros*



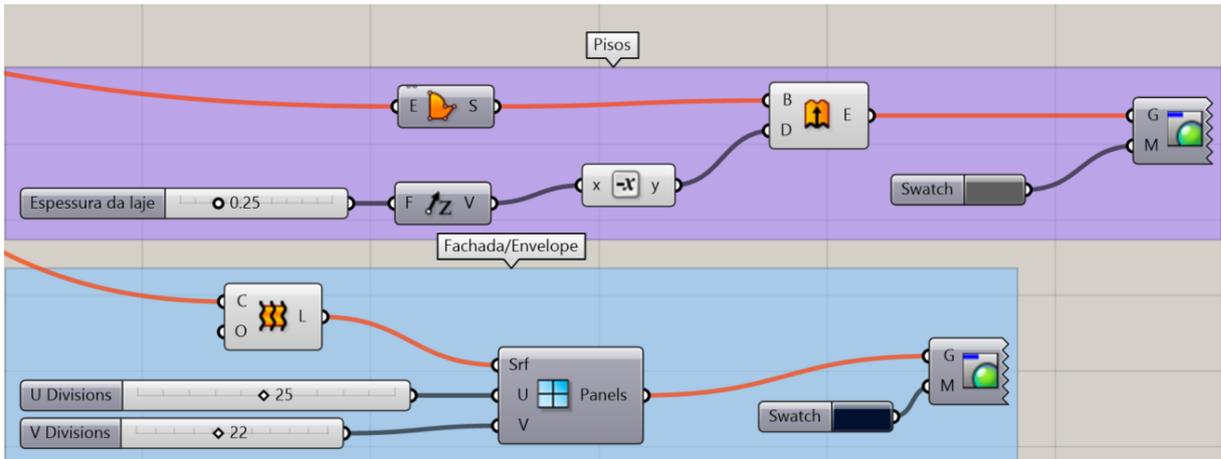
Fonte: Elaborado pela autora (2023).

Finalizada as definições de geometria foram criadas lajes e a fachada da edificação. Para as lajes as informações necessárias foram sua espessura e o sentido o qual elas devem criar sua espessura, realizado através do *Extrude*.

Para a fachada foi necessário informar a geometria a qual foi realizada o envoltório, realizada pelo *Loft*, e a mesma foi utilizada como base para a aplicação dos painéis de vidro, neste caso outro plugin dentro do *Grasshopper* foi utilizado o *Lunchbox* que auxilia na elaboração das fachadas de vidro de forma mais automática, bastando informar as medidas de recorte dos vidros.

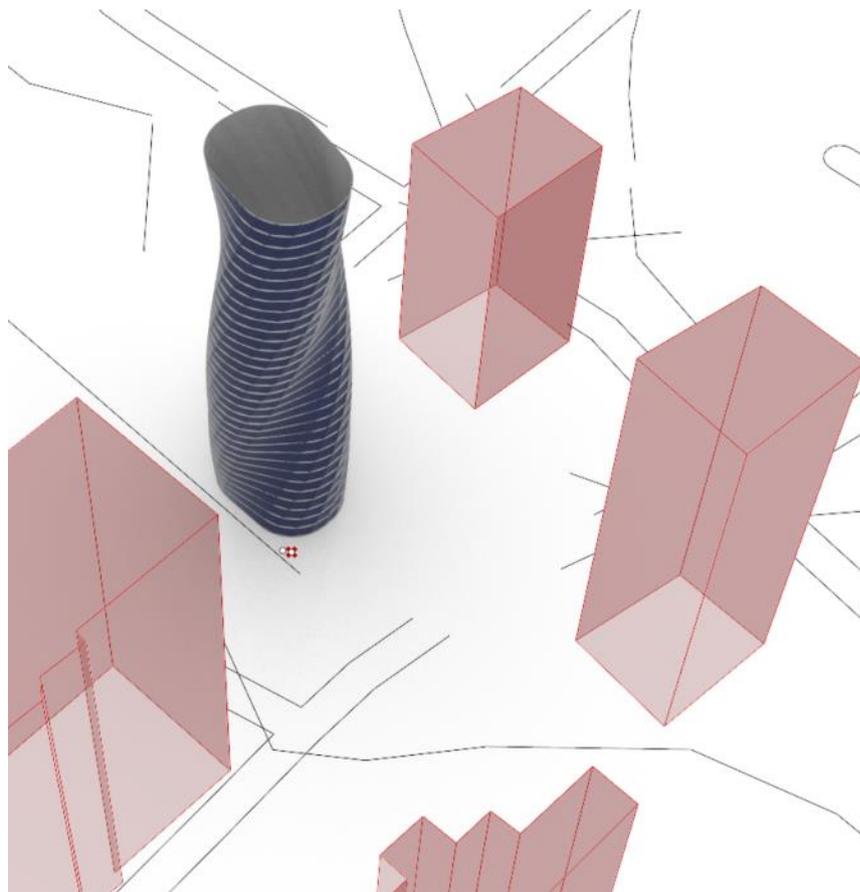
A Figura 41 demonstra a criação dessa etapa no *Grasshopper* e como ficou no *Rhinoceros* (Figura 42).

Figura 41 – Criação dos pisos e envelope da edificação



Fonte: Elaborado pela autora (2023).

Figura 42 – Fachada/ envelope no *Rhinceros*



Fonte: Elaborado pela autora (2023).

3.2 Simulação de radiação solar

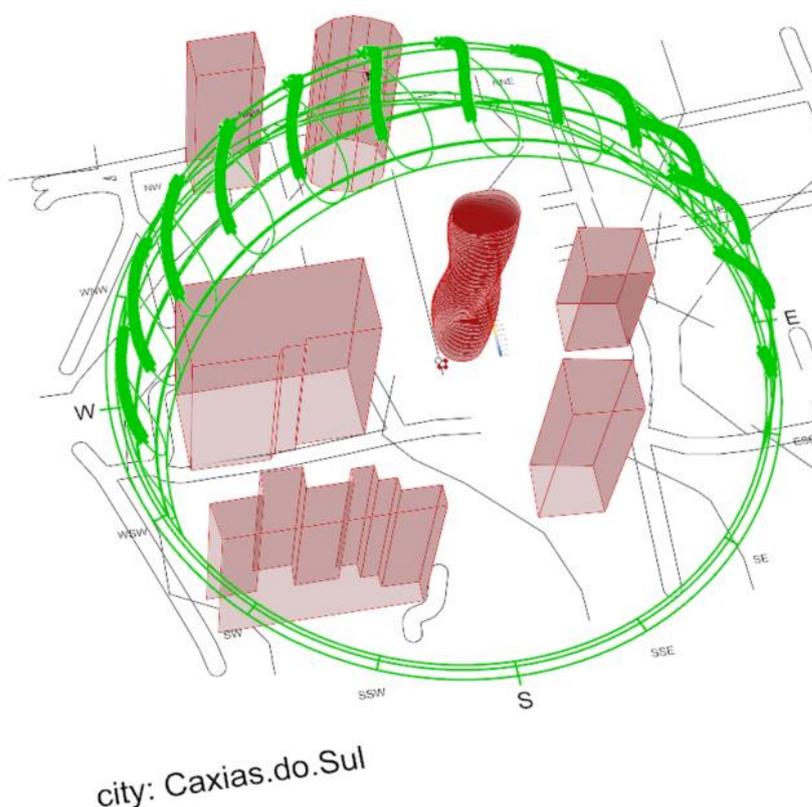
A segunda etapa deste estudo consiste na simulação de radiação solar da edificação através do uso do *plugin LadyBug*. Para a correta simulação foi executado

o entorno da edificação através do site *Cadmapper* onde as edificações vizinhas foram representadas em 3D e o arquivo exportado é nativo do software *Rhinoceros*. O entorno foi importado para o *Rhinoceros* e a edificação criada posicionada no terreno utilizado para a simulação deste trabalho.

O *Ladybug* faz uso de arquivos *EPW (EnergyPlus Weather)*, sendo assim através do site *Climate One Building (2023)* é possível baixar o arquivo da cidade de Caxias do Sul e importar para dentro do *plugin*. Para o correto desenvolvimento da simulação o norte do projeto foi indicado, através de um vetor conectado ao *Sun Path*.

O *Sun Path* cria um caminho solar acima da edificação, sendo possível determinar o período de radiação incidente. A Figura 43 apresenta o caminho solar no *Rhinoceros*.

Figura 43 – *Sun Path* no *Rhinoceros*

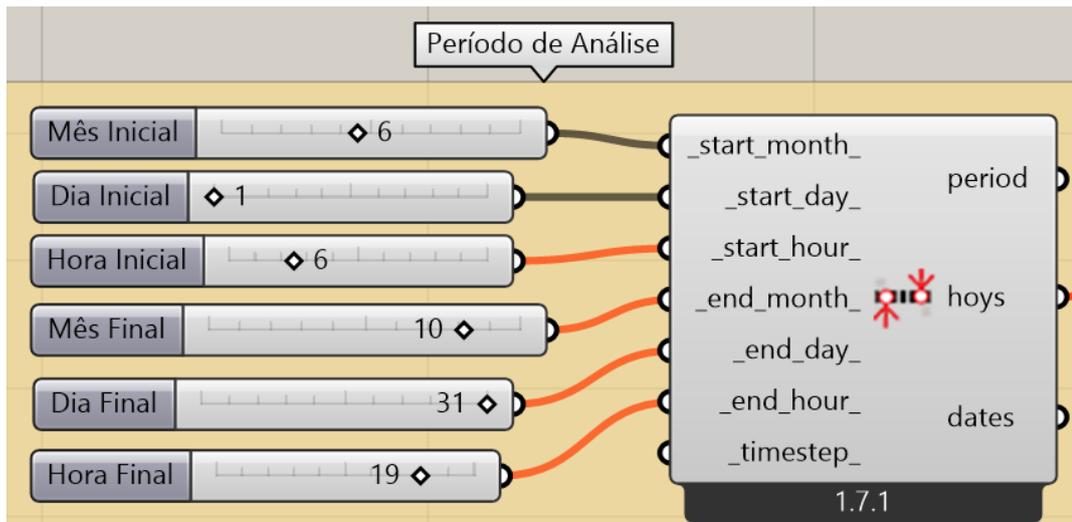


Fonte: Elaborado pela autora (2023).

O período de radiação incidente foi determinado através da entrega de informações ao parâmetro *Hoys (hours of the year)*. Neste caso foi determinado período de início da análise como dia primeiro do mês de junho, iniciando as 6h da manhã e terminando as 19h da noite e o mês final de análise foi informado o mês de outubro em seu último dia. Os períodos de análise escolhidos foram com base em

períodos de instabilidade climática (início da primavera em setembro), coincidentes com estações climáticas meteorológicas, quando ocorrem variações significativas de temperatura e níveis de chuva, e também em períodos de menor radiação solar incidente, como durante o inverno. Na figura 44 é possível verificar as informações fornecidas para o contorno com o período desejado.

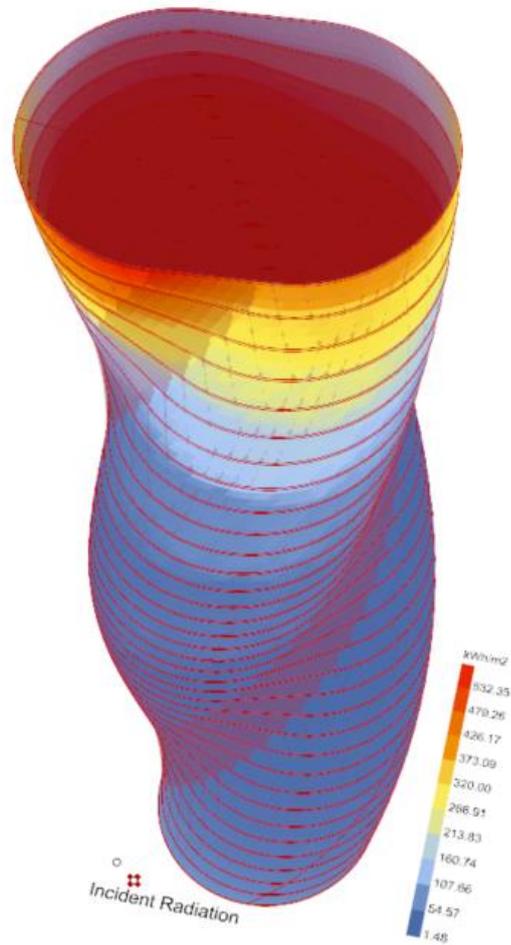
Figura 44 – Hoys (horas do ano de incidência solar)



Fonte: Elaborado pela autora (2024).

Por fim a análise de radiação solar foi realizada através da aplicação do *LB Incident Radiation*, onde foram informados localização, radiação direta e difusa, o período anteriormente consolidado e também o contexto onde a edificação está inserida. No contexto foi indicado os prédios vizinhos. Na Figura 45 é possível ver a representação da edificação rotacionada com sua incidência solar e na legenda o valor em KWh/m².

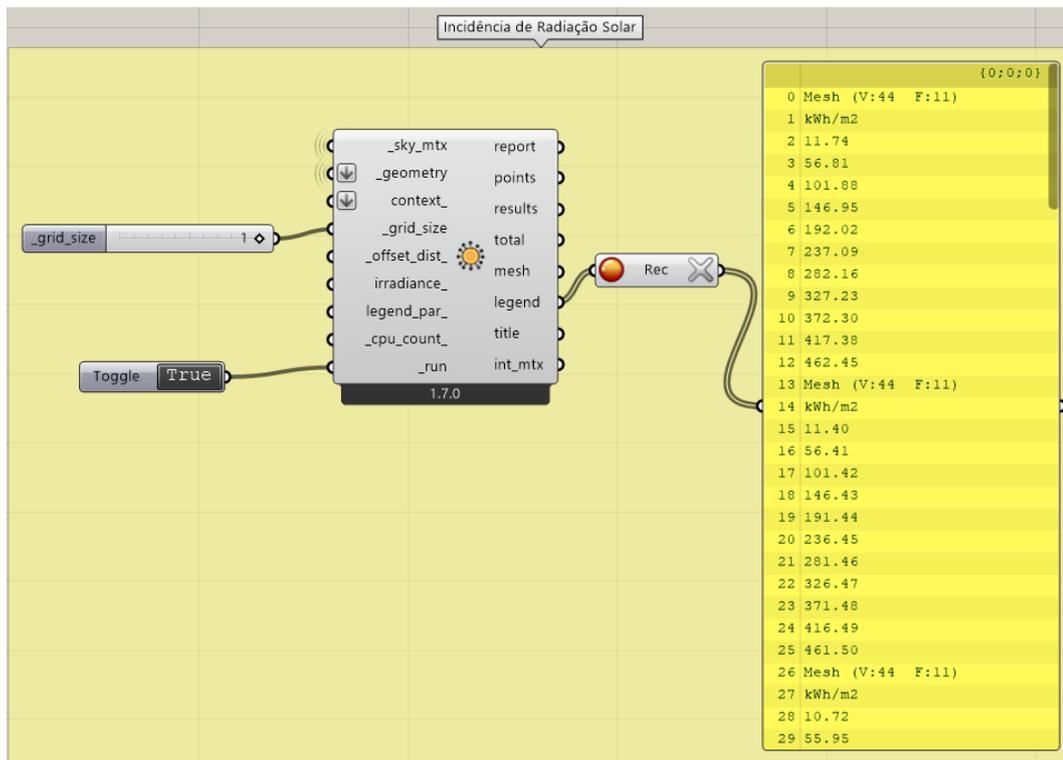
Figura 45 – Visualização da radiação incidente



Fonte: Elaborado pela autora (2023).

Para o levantamento dos dados fornecidos na modelagem que posteriormente foram utilizados na elaboração do algoritmo de florestas aleatórias, foi feita a aplicação de um item de gravação de dados do *Grasshopper* que permite armazenar os dados de diferentes simulações, como pode ser verificado na Figura 46.

Figura 46 – Armazenamento de dados no Grasshopper



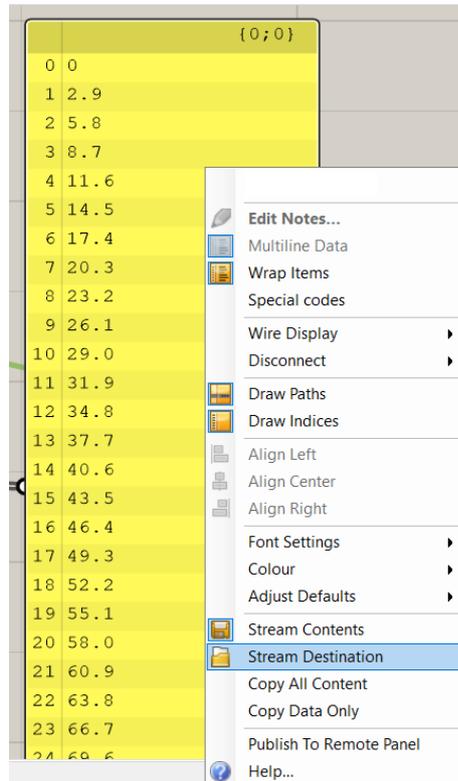
Fonte: Elaborado pela autora (2024).

3.3 Criação de dados de treinamento

A modelagem do edifício envolveu dados geométricos de entrada e dados de saída analíticos. Valores diferentes de entrada geométrica (número de pavimentos, pé direito (altura entre pavimentos), largura, profundidade, rotação, angulação, azimute) foram testados e exportados em formato .CSV usando um painel do Grasshopper. Da mesma forma, os dados de saída também foram exportados. Os dados foram limpos, tratando possíveis valores ausentes e normalizando as variáveis. Em seguida, foram divididos em conjuntos de treinamento e teste para serem utilizados no processo de criação do modelo de florestas aleatórias.

Na Figura 47 é possível verificar como foram realizadas as exportações dos dados do *Grasshopper*.

Figura 47 – Exportação de dados do *Grasshopper* para o formato *.xls*



Fonte: Elaborado pela autora (2023).

3.4 Criando o modelo de aprendizado de máquina

Para a programação do modelo foi utilizada a linguagem *Python*, aplicado o pacote *Pandas* para a manipulação dos dados, com a biblioteca *Scikit-Learn* foram importados *train_test_split* para a divisão de dados e *GridSearchCV* para a busca de hiperparâmetros. Para a realização do modelo de regressão foi realizada a importação do *RandomForestRegressor* e por fim para a avaliação de desempenho do modelo foram importados *r2_score*, *mean_squared_error*, e *mean_absolute_error*. Essas importações podem ser verificadas na Figura 48.

Figura 48 – Importação de pacotes em Python

```
import pandas as pd
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
```

Fonte: Elaborado pela autora (2023).

A importação *do train_test_split* foi especificamente importada da biblioteca *scikit-learn* para a divisão do conjunto de dados em dados de teste e treinamento, sua função facilita uma divisão aleatória e controlada, garantindo exclusividade mútua dos dados divididos, assim evitando o ocasionamento de um sobreajustamento (*overfitting*). O regressor de Floresta Aleatório (*RandomForestRegressor*) também foi importado da biblioteca *scikit-learn*, o qual foi utilizado para melhorar a robustez e precisão do modelo, onde ao longo do treinamento foi criando várias árvores e realizando a média das previsões das mesmas para a produção da estimativa final.

Seguindo as importações das bibliotecas, foi importado o conjunto de dados advindos das simulações do *Grasshopper*, importados em formato de tabela do excel (.xlsx). Para a verificação da leitura dos dados foi realizada a exibição das cinco primeiras linhas da tabela, como mostra a Figura 49.

Figura 49 – Importação tabela de dados de simulações do *Grasshopper*

```
# Importação dos dados
df = pd.read_excel('/content/dados_grasshopper.xlsx')

# Exibição das primeiras linhas de dados importados
print("Primeiras linhas do dataframe:")
print(df.head())
```

Fonte: Elaborado pela autora (2023).

As variáveis de entrada conhecidas como *features* e de saída *target*, sendo esta a previsão do modelo, foram definidas. Número de pavimentos, pé direito, Largura, Profundidade, Rotação, Angulação e Azimute foram informadas como *features* e a *target* como a Radiação Solar.

A Figura 50 apresenta a definição das variáveis.

Figura 50 – Definição de *Features* e *Target*

```
# Definição de features e target
features = df[['Número de Pavimentos', 'Pé Direito (m)', 'Largura (m)',
              'Profundidade (m)', 'Rotação (°)', 'Angulação (°)', 'Azimute (°)']]
target = df['Radiação Solar (kWh/m²)']
```

Fonte: Elaborado pela autora (2023).

Os dados gerados foram combinados em um conjunto único, em seguida entradas e saídas foram colocadas em seus próprios conjuntos, sendo X os valores de entrada e y os de saída. Cada conjunto ficou dividido em conjuntos de treinamento e teste, intitulados *X_train*, *X_test*, *y_train*, *y_test*.

Para treinar o modelo foi feito o uso do *X_train* e *y_train* sendo estes 80% dos dados totais. No teste do modelo foram utilizados *X_test* e *y_test* totalizando 20% dos dados. Foi estabelecido limites para os valores de entrada, buscando não ultrapassar os parâmetros definidos pelo código de obras da cidade. Para o número de pavimentos ficou estabelecido o limite mínimo de 10 pavimentos e o máximo de 40, na altura entre pavimentos (pé direito) valores entre 2.60m e 3.2m. Largura mínima de 15m e máxima de 22m, profundidade entre 20m e 34m. Rotação entre 1 a 10°, angulação das bordas entre 0 a 10° e por fim o azimute variando entre 0 e 120°.

Na Figura 51 é possível verificar a criação dessas definições.

Figura 51 – Dados de treinamento e teste e filtros

```
# Separação dos dados em conjuntos de treinamento e teste
X_train, X_test, y_train, y_test = train_test_split(features, target, test_size=0.2, random_state=42)

# Definição dos limites de entrada
X_train_filtered = X_train[
    (X_train['Número de Pavimentos'].between(10, 40)) &
    (X_train['Pé Direito (m)'].between(2.6, 3.2)) &
    (X_train['Largura (m)'].between(15, 22)) &
    (X_train['Profundidade (m)'].between(20, 34)) &
    (X_train['Rotação (°)'].between(0, 10)) &
    (X_train['Angulação (°)'].between(0, 10)) &
    (X_train['Azimute (°)'].between(0, 120))
]
```

Fonte: Elaborado pela autora (2023).

Foram definidos os filtros para o conjunto de teste e verificada suas dimensões. Em seguida foi realizada a criação de uma instancia do modelo, com *RandomForestRegressor* e *random_state=42* que garante que a divisão seja reproduzível, produzindo sempre a mesma sequência de números aleatórios, permitindo os mesmos resultados em cada execução do código, assim facilitando sua depuração de experimentos e reprodução. A Figura 52 apresenta a definição dos filtros e criação das florestas aleatórias.

Figura 52 – Definição dos filtros e criação das florestas aleatórias

```

# Ajuste y_train para corresponder às mesmas linhas de X_train_filtered
y_train_filtered = y_train.loc[X_train_filtered.index]

# Filtro dos dados para o conjunto de teste
X_test_filtered = X_test[
    (X_test['Número de Pavimentos'].between(10, 40)) &
    (X_test['Pé Direito (m)'].between(2.6, 3.2)) &
    (X_test['Largura (m)'].between(15, 22)) &
    (X_test['Profundidade (m)'].between(20, 34)) &
    (X_test['Rotação (°)'].between(0, 10)) &
    (X_test['Angulação (°)'].between(0, 10)) &
    (X_test['Azimute (°)'].between(0, 120))
]

y_test_filtered = y_test.loc[X_test_filtered.index]

# Verificação das dimensões após o filtro
print(f"Tamanho do X_train_filtered: {X_train_filtered.shape}")
print(f"Tamanho do y_train_filtered: {y_train_filtered.shape}")

# Modelo de Random Forest
rf = RandomForestRegressor(random_state=42)

```

Fonte: Elaborado pela autora (2023).

Os hiperparâmetros foram definidos e ajustados pelo GridSearchCV, que realiza uma busca de valores específicos em *param_grid*, através do número de árvores na floresta (*n_estimators*) e do *max_features* sendo o número máximo de características a serem consideradas na divisão de um nó, além da profundidade das árvores (*max_depth*). O número de árvores definido ficou 100, valores menores como 100 são o suficiente para a captura da maior parte do ganho de desempenho sem tornar lento ou complexo e 200 acaba permitindo que o aumento do número de árvores melhore o desempenho sem exagerar na quantidade. No número máximo de características, foi utilizado *auto*, padrão em muitos casos onde considera todas as *features*, *sqrt* tende a evitar o sobreajustamento mantendo a diversidade das árvores, considerando a raiz quadrado do número total de *features* e *log2* que considera o logaritmo de base 2 no número total de *feature*, permitindo o nivelamento entre a capacidade de generalização e a complexidade do modelo.

A profundidade máxima da árvore como o próprio título diz controla a profundidade de crescimento da árvore, *none* permitiu o crescimento das árvores até o momento que todas as suas folhas sejam puras ou possuam menos que um número mínimo de amostras, os valores de 10, 20, 30 são específicos para testar diferentes

níveis de restrições de profundidade, equilibrando entre o subajustamento e o sobreajustamento. Todos esses valores foram utilizados afim de buscar uma combinação entre parâmetros que qualifique o desempenho do modelo, sendo este medido em acuraria ou erro quadrático. Na Figura 53 é possível vê-los descritos no algoritmo.

Figura 53 – Criação e ajustes de hiperparâmetros

```
#Definição dos limites dos parâmetros para GridSearchCV
param_grid = {
    'n_estimators': [100, 200], # Número de árvores na floresta
    'max_features': ['auto', 'sqrt', 'log2'], # Número de features consideradas na divisão
    'max_depth': [None, 10, 20, 30], # Profundidade máxima da árvore
}

# Criação do GridSearchCV
grid_search = GridSearchCV(estimator=rf, param_grid=param_grid, cv=5, n_jobs=-1, scoring='neg_mean_squared_error')

# Treinamento o GridSearchCV
grid_search.fit(X_train, y_train)

# Obteção do melhor modelo
best_rf = grid_search.best_estimator_

# Previsões no conjunto de teste
y_pred = best_rf.predict(X_test)
```

Fonte: Elaborado pela autora (2023).

A Figura 53 mostra a atribuição do melhor modelo de Floresta aleatória ajustado aos melhores parâmetros na variável *best_rf* e em seguida ao *y_pred* é atribuído o modelo selecionado para prever a variável alvo no conjunto de teste, avaliando assim o desempenho do modelo.

3.5 Métricas de desempenho

Para otimizar o modelo de aprendizado de máquina, foram utilizadas métricas que permitem identificar possíveis problemas, validar o desempenho do modelo em dados de teste e ajustar hiperparâmetros. Para modelos de regressão é possível realizar a aplicação de métricas como erro médio absoluto, erro quadrático médio, raiz do erro quadrático médio e o coeficiente de determinação.

O erro médio absoluto (MAE - *Mean Absolute Error*) é a métrica que mede a média das diferenças absolutas partindo das previsões do próprio modelo e valores reais. Sua fórmula é representada por (1):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - p_i| \quad (1)$$

p_i = Previsão
 y_i = Valor Real (observado de cada amostra)
 n = Número Total de Entradas

Outra métrica de avaliação do modelo que foi aplicada é o erro quadrático médio raiz (RMSE) que é a raiz quadrada do valor médio dos quadrados das diferenças entre as previsões do modelo e os valores reais. Sua fórmula é representada por (2):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad (2)$$

n = Número Total de Entradas
 y_i = Valores Observados
 p_i = Previsões

A última métrica aplicada foi o coeficiente de determinação (R^2), a qual varia entre 0 e 1 e quantifica a proporção da variância na variável de destino que é explicada pelo modelo. Sua fórmula é representada por (3):

$$R^2 = 1 - \frac{RSS}{TSS} \quad (3)$$

RSS = soma dos quadrados das diferenças entre as previsões do modelo e a média dos valores reais

TSS = é a soma dos quadrados das diferenças entre os valores reais e a sua média

Na Figura 54 é possível verificar o cálculo das métricas de avaliação e a entrada com resultado de maior previsão e em seguida os dados correspondentes de entrada deste maior valor previsto. Os valores são então apresentados, sendo a melhor previsão o valor de maior radiação incidente estimada e os dados de entrada como número de pavimentos, altura entre pavimentos, largura, profundidade, rotação, angulação e azimute. Os melhores parâmetros encontrados pelo *GridSearchCV* e os valores das métricas de avaliação do modelo.

Figura 54 – Previsão de radiação solar e valores de entrada

```

# Métricas de avaliação
r2 = r2_score(y_test, y_pred)
rmse = mean_squared_error(y_test, y_pred, squared=False)
mae = mean_absolute_error(y_test, y_pred)

# Valor de entrada correspondente ao maior valor previsto
max_index = y_pred.argmax() # Índice do maior valor previsto
melhor_entrada = X_test.iloc[max_index] # Entradas correspondentes

# Exibir os resultados
print("\nMelhor Valor de Radiação Solar (kWh/m²) estimado:", y_pred.max())
print("Dados de Entrada que Geraram o Melhor Valor:")
print(melhor_entrada)
print("Melhores Parâmetros Encontrados:")
print(grid_search.best_params_)
print("\nMétricas de Avaliação do Modelo:")
print(f"R²: {r2:.4f}")
print(f"RMSE: {rmse:.4f} kWh/m²")
print(f"MAE: {mae:.4f} kWh/m²")

```

Fonte: Elaborado pela autora (2023).

3.6 Comparativo final

Após a definição dos melhores valores geométricos para a máxima captação de radiação solar incidente na edificação, obtidos por meio da execução do algoritmo de aprendizado de máquina, esses valores foram utilizados como entrada no algoritmo do *Grasshopper*, resultando na geração de uma nova geometria.

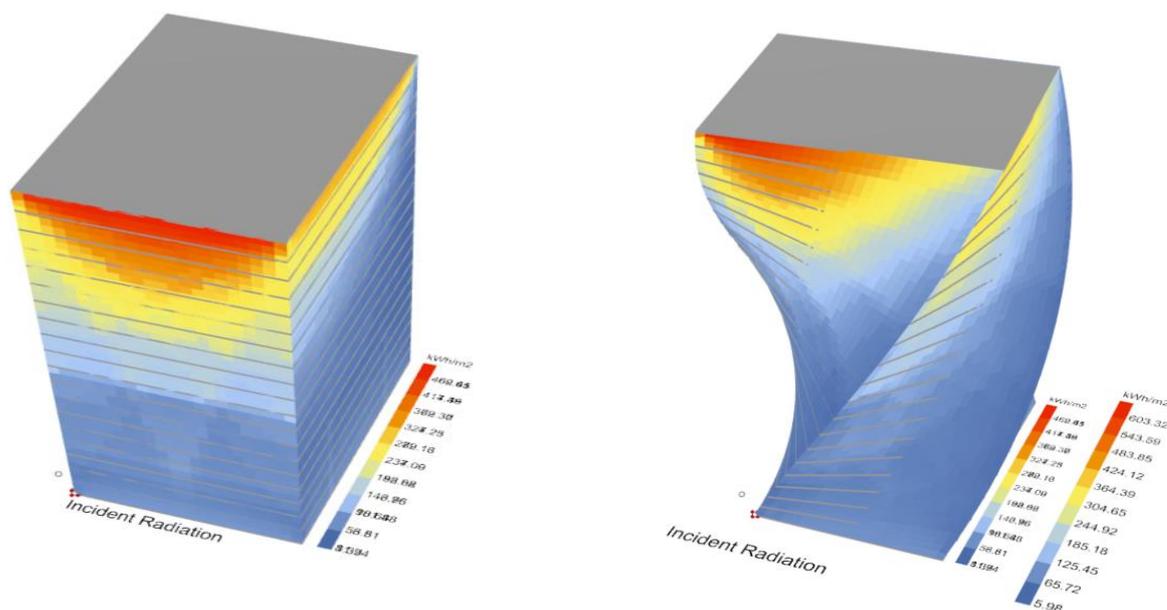
4 APRESENTAÇÃO E DISCUSSÃO DE RESULTADOS

Os resultados apresentados foram obtidos através da aplicação da metodologia especificada. O estudo visa aplicar aprendizado de máquina supervisionado para otimizar a análise de radiação solar em edificações, reduzindo a necessidade de atualizações manuais em modelos paramétricos. A pesquisa seguiu cinco etapas principais, iniciando com a criação de uma edificação paramétrica no *plugin Grasshopper* e análise de radiação com *Ladybug*, utilizando um entorno modelado no software *Rhinoceros*. A edificação foi inserida em um contexto real, com dados obtidos para simulação na Avenida Independência, Caxias do Sul. Após a modelagem, um algoritmo de aprendizado de máquina, desenvolvido em Python, foi treinado e testado com os dados geométricos e de radiação solar, gerando previsões que foram posteriormente aplicadas para melhorar a eficiência energética da edificação. A metodologia combinou modelagem paramétrica e aprendizado de máquina, culminando na identificação de parâmetros geométricos ideais para maximizar a captação de radiação solar, sendo estes aplicados no modelo final da edificação.

4.1 Análise de radiação solar na modelagem paramétrica

Os valores iniciais de geometria da edificação partiram de diretrizes do código de obras da cidade de Caxias do Sul onde é determinado o valor de no mínimo 2,6 metros de altura entre os pavimentos para edificações do tipo comercial. Por se tratar de uma região com prédios predominantemente comerciais a geometria elaborada foi trabalhada dentro desses parâmetros. Os dois terrenos possuem mais de 24 metros de frente e 38 metros de fundo, subtraindo o mínimo de 4 metros para afastamento frontal a medida de profundidade não passou de 34 metros e a largura, considerando 2,0 metros de afastamento de uma das laterais, 22 metros. A modelagem inicial foi realizada com os seguintes valores apresentados na Tabela 01 onde o valor de radiação máxima do intervalo foi extraído do *Grasshopper*. Na Figura 55 é possível verificar a incidência da radiação na primeira modelagem e ao lado após a alteração da rotação do eixo em 5°.

Figura 55 – Incidência de radiação solar na modelagem inicial



Fonte: Elaborado pela autora (2024).

Tabela 1 – Valores geométricos iniciais

Número de Pavimentos	Pé Direito (m)	Largura (m)	Profundidade (m)	Rotação (°)	Angulação (°)	Azimute (°)	Radiação Solar Máxima (kWh/m ²)
20	2.6	22	30	0	0	0	462.45
20	2.6	22	30	1	0	0	480.08
20	2.6	22	30	2	0	0	476.82
20	2.6	22	30	3	0	0	487.29
20	2.6	22	30	4	0	0	559.73
20	2.6	22	30	5	0	0	603.32
20	2.6	22	30	6	0	0	620.07
20	2.6	22	30	7	0	0	603.86
20	2.6	22	30	8	0	0	564.78
20	2.6	22	30	9	0	0	615.75
20	2.6	22	30	10	0	0	641.16

Fonte: Elaborado pela autora (2024).

Nos primeiros valores somente foram alterados os ângulos de rotação, variando de 1 até 10°. Na sequência os valores de azimute foram alterados, mantendo os valores para número de pavimentos, pé direito, largura, profundidade e rotação e angulação iguais e rotação 0°. A Tabela 02 apresenta esses valores. É possível notar que os valores de radiação oscilam aumentando e diminuindo conforme a variação do azimute. No azimute de 0° a radiação máxima captada é maior que o azimute de 120°.

Tabela 2 – Azimutes

Número de Pavimentos	Pé Direito (m)	Largura (m)	Profundidade (m)	Rotação (°)	Angulação (°)	Azimute (°)	Radiação Solar Máxima (kWh/m ²)
20	2.6	22	30	0	0	0	462.45
20	2.6	22	30	0	0	2	461.50
20	2.6	22	30	0	0	5	463.02
20	2.6	22	30	0	0	8	464.24
20	2.6	22	30	0	0	10	464.67
20	2.6	22	30	0	0	15	463.73
20	2.6	22	30	0	0	35	444.93
20	2.6	22	30	0	0	45	426.90
20	2.6	22	30	0	0	90	462.14
20	2.6	22	30	0	0	100	465.14
20	2.6	22	30	0	0	120	449.98

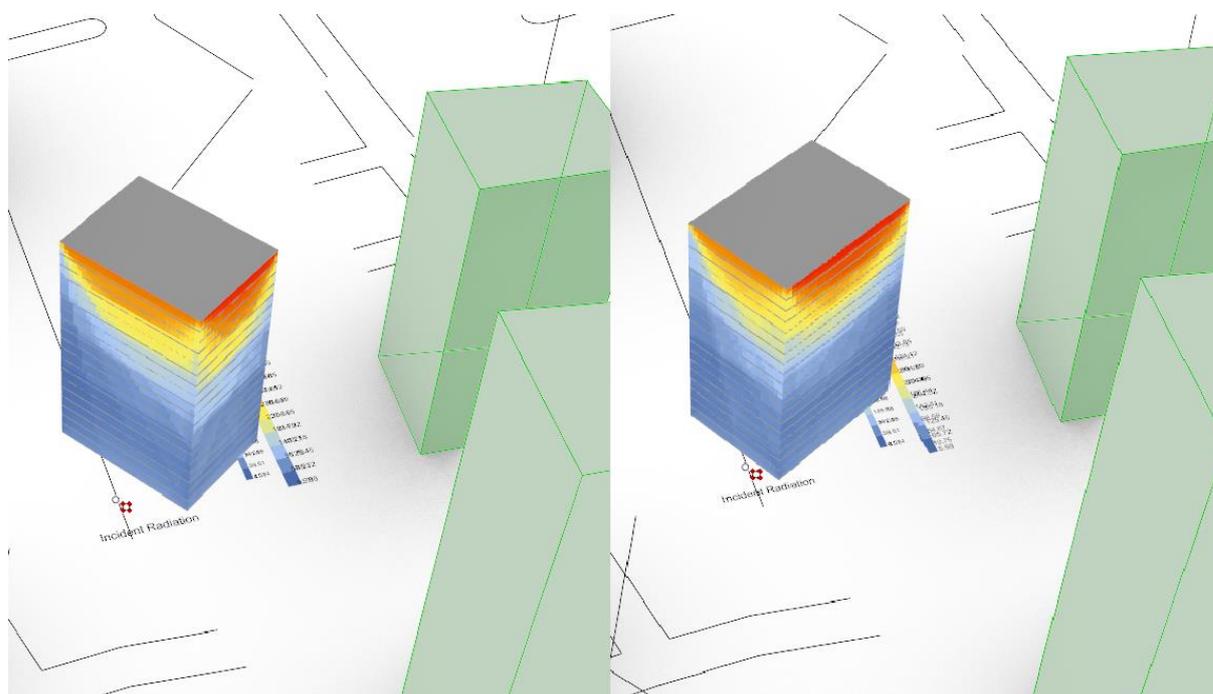
Fonte: Elaborado pela autora (2024).

É possível verificar que a radiação incidente não muda consideravelmente os valores com as alterações de valores de azimute, contraria as alterações de rotações do eixo que aumentaram 208,71 kWh/m² em comparação entre o valor inicial e o final.

Na Figura 56 é possível verificar o posicionamento da edificação com alterações do azimute em 35° e 120°.

A análise dos resultados revela que a rotação do eixo impactou significativamente a captação de radiação solar, com um aumento expressivo de radiação. Em contraste, as variações no azimute, embora apresentem oscilações nos valores de radiação captada, não mostraram alterações tão marcantes quanto as observadas nas rotações do eixo. A comparação entre os azimutes de 0° e 120° indica uma maior captação de radiação no azimute de 0°. Essas observações destacam a importância da rotação do eixo na otimização da captação de radiação solar em edificações, enquanto o azimute desempenha um papel secundário, mas ainda relevante.

Figura 56 – Posicionamento da edificação com azimute 35° e 120°



Fonte: Elaborado pela autora (2024).

Os valores de altura entre pavimentos (pé direito) foram alterados em combinação com o azimute variando entre os valores apresentados na Tabela 02. Foi possível observar que para a altura entre pavimentos de 2,60m para 3,10m, com azimute de 100° a radiação solar incidente diminui 1,17 kWh/m², possivelmente ocasionado devido as sombras dos edifícios vizinhos os quais tornam-se mais próximos devido ao aumento de altura. Os valores podem ser observados na Tabela 03.

Tabela 3 – Alteração de pé direito e azimute

Número de Pavimentos	Pé Direito (m)	Largura (m)	Profundidade (m)	Rotação (°)	Angulação (°)	Azimute (°)	Radiação Solar Máxima (kWh/m ²)
20	2.6	22	30	0	0	0	462.45
20	2.6	22	30	0	0	2	461.50
20	2.6	22	30	0	0	5	463.02
20	2.6	22	30	0	0	8	464.24
20	2.6	22	30	0	0	10	464.67
20	2.6	22	30	0	0	15	463.73
20	2.6	22	30	0	0	35	444.93
20	2.6	22	30	0	0	45	426.90
20	2.6	22	30	0	0	90	462.14

20	2.6	22	30	0	0	100	465.14
20	2.6	22	30	0	0	120	449.98
20	3.10	22	30	0	0	0	459.61
20	3.10	22	30	0	0	2	461.34
20	3.10	22	30	0	0	5	462.88
20	3.10	22	30	0	0	8	464.11
20	3.10	22	30	0	0	10	464.55
20	3.10	22	30	0	0	15	463.64
20	3.10	22	30	0	0	35	444.90
20	3.10	22	30	0	0	45	425.79
20	3.10	22	30	0	0	90	461.31
20	3.10	22	30	0	0	100	463.97
20	3.10	22	30	0	0	120	448.92

Fonte: Elaborado pela autora (2024).

Alterando o eixo de rotação da geometria com valores variando de 1 a 10° e comparando os valores encontrados para a altura entre pavimentos de 2.60 m e 3.10 m e o número de pavimentos sendo 20 e 30, foi possível verificar que a incidência de radiação solar aumentou 18,78kWh/m² comparando os valores de angulação 10°, no entanto os valores comparados em outros ângulos não apresentaram um comportamento ascendente. Na Tabela 04 é possível verificar esses valores.

Tabela 4 – Alteração no eixo de rotação

Número de Pavimentos	Pé Direito (m)	Largura (m)	Profundidade (m)	Rotação (°)	Angulação (°)	Azimute (°)	Radiação Solar Máxima (kWh/m ²)
20	2.6	22	30	1	0	0	480.08
20	2.6	22	30	2	0	0	476.82
20	2.6	22	30	3	0	0	487.29
20	2.6	22	30	4	0	0	559.73
20	2.6	22	30	5	0	0	603.32
20	2.6	22	30	6	0	0	620.07
20	2.6	22	30	7	0	0	603.86
20	2.6	22	30	8	0	0	564.78
20	2.6	22	30	9	0	0	615.75
20	2.6	22	30	10	0	0	641.16
30	3.10	22	30	1	0	0	466.99
30	3.10	22	30	2	0	0	450.93
30	3.10	22	30	3	0	0	532.27
30	3.10	22	30	4	0	0	553.61
30	3.10	22	30	5	0	0	514.76
30	3.10	22	30	6	0	0	558.40

30	3.10	22	30	7	0	0	574.68
30	3.10	22	30	8	0	0	553.63
30	3.10	22	30	9	0	0	635.07
30	3.10	22	30	10	0	0	659.94

Fonte: Elaborado pela autora (2024).

Outras análises de radiação solar foram realizadas, com alterações da angulação das bordas da planta, tornando-a mais arredondada. Em comparação a planta retangular, alterando a rotação do eixo, foi possível observar que a incidência de radiação solar diminuiu em todos os testes com ângulo de borda. Representando que a planta sendo mais oval não aumenta a radiação incidente. A Tabela 05 apresenta os valores analisados.

Tabela 5 – Alteração no ângulo de borda e eixo de rotação

Número de Pavimentos	Pé Direito (m)	Largura (m)	Profundidade (m)	Rotação (°)	Angulação (°)	Azimute (°)	Radiação Solar Máxima (kWh/m ²)
30	3.10	22	30	1	0	0	466.99
30	3.10	22	30	2	0	0	450.93
30	3.10	22	30	3	0	0	532.27
30	3.10	22	30	4	0	0	553.61
30	3.10	22	30	5	0	0	514.76
30	3.10	22	30	6	0	0	558.40
30	3.10	22	30	7	0	0	574.68
30	3.10	22	30	8	0	0	553.63
30	3.10	22	30	9	0	0	635.07
30	3.10	22	30	10	0	0	659.94
30	3.10	22	30	1	1	0	466.89
30	3.10	22	30	2	2	0	449.70
30	3.10	22	30	3	3	0	528.71
30	3.10	22	30	4	4	0	549.63
30	3.10	22	30	5	5	0	524.34
30	3.10	22	30	6	6	0	515.18
30	3.10	22	30	7	7	0	520.15
30	3.10	22	30	8	8	0	491.36
30	3.10	22	30	9	9	0	557.36
30	3.10	22	30	10	10	0	571.27

Fonte: Elaborado pela autora (2024).

Na Figura 57 é possível avaliar como a geometria se apresenta com a borda e rotação do eixo em 10°.

Figura 57 – Geometria com borda e eixo 10°



Fonte: Elaborado pela autora (2024).

No total foram 500 linhas de dados (Anexo A) gerados os quais foram exportados e importados dentro do algoritmo de aprendizado de máquina.

Os valores de altura entre pavimentos foram ajustados, variando entre 2,60m e 3,10m, enquanto o azimute foi modificado conforme a Tabela 02. Observou-se uma pequena redução de radiação solar incidente ao passar de um azimute de 100°, atribuída às sombras de edifícios vizinhos que se aproximaram devido ao aumento da altura. Além disso, ao rotacionar a geometria em ângulos de 1° a 10°, verificou-se um aumento de radiação para uma inclinação de 10°. Contudo, a rotação adicional não apresentou um padrão ascendente. Os dados gerados foram integrados ao algoritmo de aprendizado de máquina.

4.2 Análise de radiação no modelo de aprendizado de máquina

Os dados gerados pelas diferentes análises de geometria no *Grasshopper* foram utilizados dentro do modelo de aprendizado de máquina e através da aplicação da técnica de florestas aleatórias. O modelo dividiu os dados em dados de teste e

treinamento e apresentou o seguinte valor de maior radiação incidente na edificação 631.99 kWh/m². Para a obtenção deste valor os valores de entrada foram os seguintes:

1. Número de pavimentos: 32
2. Altura entre pavimentos (pé direito m): 2.90
3. Largura (m): 22
4. Profundidade (m): 34
5. Rotação (°): 8
6. Angulação (Borda) (°): 5
7. Azimute (°): 35

As métricas de avaliação também foram geradas. Para o coeficiente de determinação R² o valor foi 0,9746, sugerindo que aproximadamente 97,46% da variação dos dados de radiação solar podem ser explicados pelo modelo, sendo um bom ajuste. No entanto 2,54% da variação não foi possível ser explicada através do modelo, podendo este ser aprimorado. O erro quadrático médio da raiz (RMSE), mede a média dos erros entre os valores previstos e os valores reais, apresentou um valor de 9,1999 kWh/m² indicando que, em média, cerca de 9,2 kWh/m² das previsões realizadas pelo modelo estão errados em relação aos valores reais trabalhados. O MAE (erro absoluto médio) apresentou o valor de 5,7331 kWh/m² indicando que a média das diferenças absolutas entre os valores previstos e os reais possui 5,7 kWh/m² de erro em suas previsões. Esses valores sugerem que o modelo está realizando um bom trabalho ao prever a radiação solar incidente, porém abre espaço para melhorias em precisões. A Figura 58 apresenta os valores gerados pelo modelo.

Os dados gerados pelas diferentes análises de geometria no Grasshopper foram integrados ao modelo de aprendizado de máquina por meio da técnica de florestas aleatórias. O modelo foi calibrado com divisão de dados em conjuntos de teste e treinamento, resultando em uma estimativa de radiação incidente máxima acima de 630 kWh/m². A avaliação estatística do modelo revelou um significativo coeficiente de determinação indicando que quase toda a variação nos dados de radiação solar é explicada pelo modelo.

Figura 58 – Valores gerados pelo aprendizado de máquina

Maior Valor de Radiação Solar Incidente (kWh/m²) estimado: 631.9971000000004

Valores de Entradas Geométricas:

Número de Pavimentos	32.0
Pé Direito (m)	2.9
Largura (m)	22.0
Profundidade (m)	34.0
Rotação (°)	8.0
Angulação (°)	5.0
Azimute (°)	35.0
Name: 290, dtype: float64	

Melhores Parâmetros Encontrados:

```
{'max_depth': 20, 'max_features': 'sqrt', 'n_estimators': 100}
```

Métricas de Avaliação do Modelo:

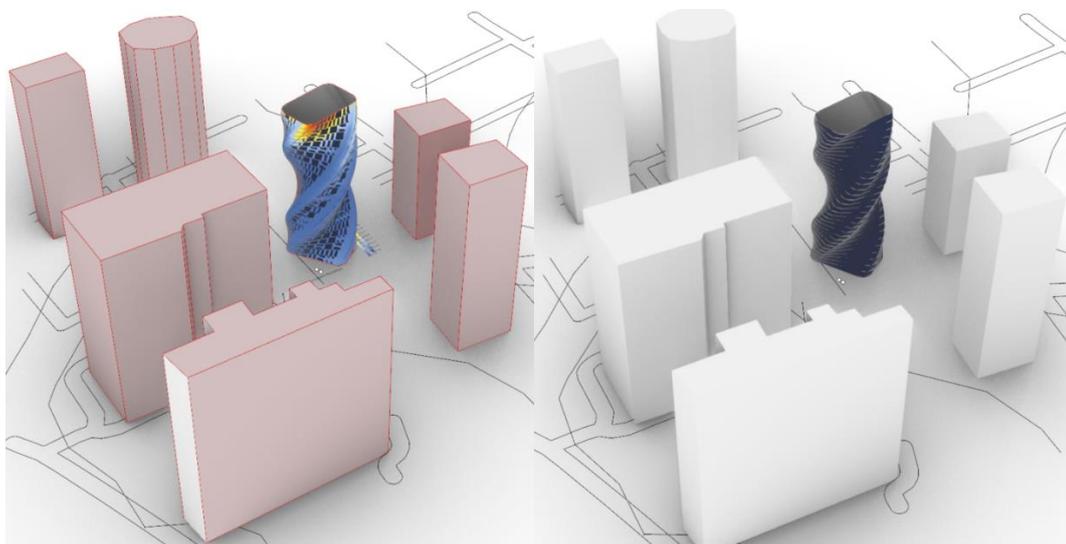
R²: 0.9746
RMSE: 9.1999 kWh/m²
MAE: 5.7331 kWh/m²

Fonte: Elaborado pela autora (2024).

4.3 Comparação das alternativas geradas

Os dados de entrada informados pelo modelo de árvores aleatórias foram utilizados no modelo paramétrico. O valor encontrado para a incidência de radiação solar foi 644,63 kWh/m² próximo ao valor apresentado pelo algoritmo de aprendizado de máquina. Na Figura 59 é possível observar como ficou a geometria com os dados calculados.

Figura 59 – Geometria final



Fonte: Elaborado pela autora (2024).

As análises geradas por algoritmos paramétricos em simulações de radiação solar fornecem uma base rica para a aplicação de técnicas de aprendizado de máquina. Ao processar dados como geometria, inclinação de fachadas e incidência solar, modelos supervisionados podem identificar padrões complexos e gerar previsões precisas. Esse processo otimiza o desempenho energético das edificações ao prever o comportamento solar sem a necessidade de ajustes manuais constantes. Assim, a integração entre aprendizado de máquina e simulações de radiação solar não só aprimora a eficiência das análises, mas também facilita decisões de projeto mais informadas e sustentáveis.

5 CONCLUSÃO

A aplicação do aprendizado de máquina para a análise de radiação solar em edificações provou ser eficiente no alcance do objetivo principal desta dissertação, o qual era investigar a utilização de uma técnica de aprendizado de máquina supervisionado para a redução de atualizações e alterações do modelo de design paramétrico. Através do uso de florestas aleatórias foi possível obter maior agilidade no processo de análise, mesmo havendo a necessidade de gerar dados através de diferentes modelagens paramétricas para alimentação do modelo.

O uso de florestas aleatórias como modelo de aprendizado de máquina deste trabalho apresentou um bom equilíbrio na interpretação dos dados, robustez, desempenho e flexibilidade. Apresentou previsões sem a exigência de uma quantidade excessiva de ajustes de parâmetros.

Durante o desenvolvimento deste estudo, ficou claro que a integração entre o aprendizado de máquina e a modelagem paramétrica otimiza o tempo e o trabalho necessário nos ajustes de parâmetros do modelo, além de melhorar a precisão das previsões de radiação solar, assim contribuindo na eficiência do processo de projeto arquitetônico, permitindo que o profissional envolvido tome decisões baseadas em dados. Também foi possível verificar que a abordagem proposta demonstrou flexibilidade e adaptação em diferentes configurações geométricas, demonstrando assim que o aprendizado de máquina é uma ferramenta promissora na aplicação de técnicas avançadas que otimizam os processos de design.

Embora os benefícios da aplicação do aprendizado de máquina tenham ficado evidentes, é importante ressaltar alguns desafios que acompanharam o desenvolvimento dessa metodologia, como a necessidade de conhecimentos específicos em programação, neste caso especialmente na linguagem Python e conhecimentos em aprendizado de máquina, podendo limitar o acesso de alguns profissionais a essa abordagem. Além disso, a execução das análises geométricas no *Grasshopper* exigiu, além dos conhecimentos no uso do plugin um computador de bom desempenho, o qual precisou lidar com modelos mais complexos e um processamento alto de dados. Fatores os quais podem representar barreiras para a adoção da metodologia.

5.1 Contribuições e trabalhos futuros

Este estudo contribuiu na demonstração da eficácia da aplicação de florestas aleatórias na análise de radiação solar incidente em edificações. Evidenciando não somente a capacidade das técnicas em acelerar o processo de modelagem e avaliação da radiação, mas demonstrar como o aprendizado de máquina pode reduzir o tempo de atualizações manuais e frequentes alterações de modelos paramétricos, destacando um caminho valioso para o uso da inteligência artificial em projetos arquitetônicos, possibilitando uma abordagem eficiente e precisa em análises ambientais durante a fase de design da edificação.

Existe uma ampla gama de oportunidades e expansão de estudo no que se refere a aplicação do aprendizado de máquina aplicado a projetos arquitetônicos. Futuras investigações podem aprofundar e aprimorar a aplicação de outros algoritmos de aprendizado como redes neurais profundas, buscando uma precisão e eficiência maior na análise de radiação solar, ou mesmo expandir o modelo para a análise de edificações com materiais e soluções construtivas diferentes.

REFERÊNCIAS

ABRAVIDRO. **Os segredos por trás das fachadas**, 29 jan. 2018. Disponível em: <https://abravidro.org.br/os-segredos-por-tras-das-fachadas>. Acesso em: 18 ago .2024

AIA. THE AMERICAN INSTITUTE OF ARCHITECTS. **Architect's Guide to Building Performance: Integrating performance simulation in the design process**. 91 p. Disponível em: https://content.aia.org/sites/default/files/2019-06/Energy_Design_Modeling_Guide_v4.pdf. Acesso em: 30 abr. 2023.

AKOS, G.; PARSONS, R. **Foundations: The Grasshopper Primer**. Third Edition. New York, 2015. Disponível em: http://grasshopperprimer.com/en/1-foundations/1-4/1_curve-geometry.html. Acesso em: 21 maio 2023.

ALJUKIC, Melika. Design of towers with parametric data models. **Architecture Bulletin**, Austrália, p. 33-35, dez. 2020. Disponível em: https://www.architecture.com.au/wp-content/uploads/NSW-Bulletin-VOL-77-_-No.2-_-December-2020_.pdf. Acesso em: 28 mai. 2023

ALPAYDIN, Ethem. **Introduction to Machine Learning**. 4. ed. Cambridge, Massachusetts: MIT Press, 2020. 709 p. (v. 1, f. 355).

ANDREIS, C.; BASEN, P.; WESTPHAL, F. S. **Desempenho energético de fachadas envidraçadas em climas brasileiros**. Entac. Maceió. 2014.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15215-1**: Iluminação natural – Parte 1: Conceitos básicos e definições. Rio de Janeiro, 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15215-2**: Iluminação natural – Parte 2: Procedimentos de cálculo para a estimativa da disponibilidade de luz natural e para a distribuição espacial da luz. Rio de Janeiro, 2022.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15215-3**: Iluminação natural – Parte 3: Procedimentos para avaliação da iluminação natural em ambientes internos. Rio de Janeiro, 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15215-4**: Iluminação natural – Parte 4: Verificação experimental das condições de iluminação natural interna. Rio de Janeiro, 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15220-3**: Desempenho térmico de edificações – Parte 3: Zoneamento bioclimático brasileiro e diretrizes construtivas para habitações unifamiliares de interesse social. Rio de Janeiro, 2005.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15575**: Edificações habitacionais – Desempenho. Rio de Janeiro, 2021.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 7199**: Vidros na construção civil — Projeto, execução e aplicações. Rio de Janeiro, 2016.

AZEREDO, Hélio Alves. **O edifício e seu acabamento**. São Paulo: Blucher, 2004

BAINBRIDGE, David; HAGGARD, Ken. **Passive Solar Architecture: Heating, Cooling, Ventilation, Daylighting and More Using Natural Flows**. 1. ed. Chelsea Green Publishing, 2011. 306 p. (v. 3, f. 153).

BARBOSA, L. M.; PORTES, L. A. F. A Inteligência Artificial. **Revista Tecnologia Educacional**, Rio de Janeiro, v. 236. 83p, Jan. 2019. Disponível em: http://abt-br.org.br/wp-content/uploads/2023/03/RTE_236.pdf#page=16. Acesso em: 4 abr. 2023.

BORGES, L. E. **Python para Desenvolvedores**: Aborda Python 3.3. 1 ed. Novatec Editora, 2014. 320 p.

BREIMAN, L. Random forests. **Machine learning**, v. 45, p. 5-32, 2001.

CADMAPPER, LLC. **Instant CAD files for any location on earth**. Cadmapper. 2020. Disponível em: <https://cadmapper.com/>. Acesso em: 1 abr. 2023.

CARLO, J; LAMBERTS, R. Development of envelope efficiency labels for commercial buildings: Effect of different variables on electricity consumption. **Energy and Buildings**, v. 40, n. 11, p. 2002-2008, 2008.

CASALS, X. G. Analysis of building energy regulations and certification in Europe: their role, limitations and differences. **Energy and Buildings**, v.38, p.381-392, 2006.

CHAILLOU, Stanislas. **AI + Architecture: Towards a New Approach**. 2019. 188 p. Master's Thesis – Graduate School of Design, Harvard University, 2019.

CRASA. **Entendendo a Modelagem de Informação da Construção (BIM)**. Crasa

Infraestrutura. 2015. Disponível em: <https://www.crasainfra.com/post/entendendo-amodelagem-de-informa%C3%A7%C3%A3o-da-constru%C3%A7%C3%A3o-bim>.

Acesso em: 27 mai. 2023.

DE SOUZA, L. P. **Avaliação do potencial de inserção de simulações termo-energéticas em fases iniciais de projeto: proposta de método de ensino e estudo de caso**. Florianópolis, 2020. 163 p Dissertação (Programa de Pós-Graduação em Arquitetura e Urbanismo) - Universidade Federal de Santa Catarina.

EASTMAN, Charles. The use of computers instead of drawings in building design. **AIA journal**, v. 63, n. 3, p. 46-50, 1975.

GALERIE OF THE PALAIS ROYAL - INTERIOR, 1831. [S. I.]: Wikimedia Commons, 2013. Fotografia. Disponível em: https://commons.wikimedia.org/wiki/File:Galerie_of_the_Palais_Royal_-_interior,_1831.jpg. Acesso em: 7 ago. 2024.

GALLO, G; PELLITTERI, G. Luigi Moretti, from history to parametric architecture. *In: LEARNING, PROTOTYPING, AND ADAPTING, SHORT PAPER PROCEEDINGS OF THE 23RD INTERNATIONAL CONFERENCE ON COMPUTER-AIDED ARCHITECTURAL DESIGN RESEARCH IN ASIA. Proceedings[...]*, 2018.

GARANITO, V. M. G. **O vidro na indústria da construção**. 2018. Dissertação (Mestrado em Engenharia Civil). Universidade da Madeira (Portugal).

GATES, B. **Como evitar um desastre climático**: As soluções que temos e as inovações necessárias. *Companhia das Letras*, v. 2, f. 160, 2021. 320 p.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow**: Concepts, Tools, and Techniques to Build Intelligent Systems. O'Reilly Media, v. 1, f. 426, 2019. 277 p.

GMM Engenharia E Construção. **Pele De Vidro**. Disponível em: <https://gmm.com.br/pele-vidro-descricao/>. Acessado em: 27 ago. 2024.

GRUS, J. **Data Science Do Zero**: Primeiras Regras com o Python. 1 ed. Rio de Janeiro: Alta Books, 2016. 336 p.

GUARDIAN Glass. **Como escolher um vidro acústico para as minhas janelas**. Disponível em: <https://www.guardiansun.pt/entenda-o-jargao-tecnico/como-escolher-um-vidro-acustico-para-as-minhas-janelas>. Acesso em: 17 ago. 2024.

GUILLAME-BERT, M. *et al.* **Introducing TensorFlow Decision Forests**. Tensorflow. 2021. Disponível em: <https://blog.tensorflow.org/2021/05/introducing-tensorflow-decision-forests.html>. Acesso em: 16 jun. 2023.

HEIJDEN, R. V. D. **Fabrication modeling for cladding panels of double curved exoskeleton structure**. Grasshopper3d. 2016. Disponível em: <https://www.grasshopper3d.com/profiles/blogs/fabrication-modeling-for-cladding-panels-of-double-curved>. Acesso em: 28 mai. 2023.

HEIJDEN, R.V. D.; LEVELLE, E.; REISE, M. Parametric building information generation for design and construction. *In: Computational Ecologies: Design in the Anthropocene-35th Annual Conference of the Association for Computer Aided Design in Architecture. Proceedings [...]*. 2015. p. 417-429.

KHOURY, J. **Curtain Walls**. *In: KOHN, A. E.; KATZ, P. Building type basics for office buildings*. New York: John Wiley & Sons, 2002. P. 139-181

KOCH, R. **History of Machine Learning – A Journey through the Timeline**. Clickworker. 2022. Disponível em: <https://www.clickworker.com/customer-blog/history-of-machine-learning/>. Acesso em: 3 jun. 2023.

KONONENKO, I.; KUKAR, M. **Machine Learning and Data Mining**. Elsevier, v. 3, f. 240, 2007. 480 p.

LADYBUG TOOLS LLC. **What is Ladybug Tools?** Ladybug Tools.2022 Disponível em: <https://www.ladybug.tools/>. Acesso em: 1 abr. 2023.

LAMBERTS, R.; DUTRA, L.; PEREIRA, F. **Eficiência energética na Arquitetura**. 3. ed. Rio de Janeiro: Eletrobras/Ministério de Minas e Energia. 2014. Disponível em: https://labeee.ufsc.br/sites/default/files/apostilas/eficiencia_energetica_na_arquitetura.pdf Acesso em: 21 de maio de 2023.

LEONE, C.; FLORIO, W. Análise paramétrica de iluminação natural e de proteção solar de edifícios torcidos. **Ambiente Construído**, v. 21, p. 247-270, 2021.

LUDWING, B.Z. **Análise entre sistemas de fachadas cortina à luz dos princípios de projeto para manufatura e montagem**. Curitiba, 2014. Monografia de Especialização – Universidade Tecnológica Federal do Paraná, Curitiba, 2014.

MACHADO, A. P. V. **Design Generativo aplicado à Conceção de Edifícios para Otimização do Desempenho Energético**. Braga, Portugal, 2018. 129 p Dissertação (Mestrado em Engenharia Civil) - Universidade do Minho, 2018.

MARSLAND, S. **Machine Learning: An Algorithmic Perspective**. 2 ed. CRC Press, v. 3, f. 229, 2015. 457 p.

MATTHES, E. **Curso Intensivo de Python: Uma Introdução Prática e Baseada em Projetos à Programação**. 3 ed. Novatec Editora, f. 375, 2023. 750 p.

MCNEEL EUROPE. **LADYBUG TOOLS**. Food4Rhino. Disponível em: <https://www.food4rhino.com/en/app/ladybug-tools>. Acesso em: 7 abr. 2023.

MCNEEL, B.; DAVIDSON, S. **The Grasshopper Primer**. Modelab Gitbooks. 2015. Disponível em: <https://modelab.gitbooks.io/grasshopper-primer/content/>. Acesso em: 29 abr. 2023.

MITCHELL, T. M. **Machine Learning**. 1 ed. McGraw-Hill Science/Engineering/Math, f. 207, 1997. 414 p.

MOLINA-SOLANA, M. *et al.* Data science for building energy management: A review. **Renewable and Sustainable Energy Review**, v. 70, p. 598-609, Abril 2017.

MONTEIRO, I.M. **O uso dos sistemas BIM em projeto de arquitetura: diversificação de soluções versus padronização**. Brasília, 2012. f. 140 Dissertação (Mestrado em Arquitetura e Urbanismo) - Universidade de Brasília, 2012.

MÜLLER, A. C.; GUIDO, Sarah. **Introduction to Machine Learning with Python: A Guide for Data Scientists**. 1 ed. O'Reilly Media, Inc., v. 3, f. 200, 2016. 400 p.

NAVLANI, A. **Decision Tree Classification in Python Tutorial**. Datacamp. 2023. Disponível em: <https://www.datacamp.com/tutorial/decision-tree-classification-python>. Acesso em: 3 jun. 2023.

NEGROPONTE, N. **The Architecture Machine: Toward a More Human Environment**. The MIT Press, 1970. 164 p.

PETER Pichler Architecture. The Mirror Houses. **ArchDaily**, 2014. Disponível em: <https://www.archdaily.com/577551/the-mirror-houses-peter-pichler-architecture>. Acesso em: 18 ago. 2024.

PETERSEN, S.; SVENDSEN, S. Method and simulation program informed decisions in the early stages of building design. **Energy and Buildings**, v. 42, n. 7, p. 1113-1119, Julho 2010.

PIERSON, L. **Data science para leigos**. 2 ed. Rio de Janeiro: Alta Books, 2019. 384 p.

PREFEITURA MUNICIPAL DE CAXIAS DO SUL. **Código de Obras do Município de Caxias do Sul**. Lei n.º 636, de 22 de dezembro de 2010. Disponível em: <https://gcpstorage.caxias.rs.gov.br/documents/2021/03/38b8479a-923b-4f63-8ac6-947ce4e34a7b.pdf>. Acesso em: 21 jul. 2024.

PREFEITURA MUNICIPAL DE CAXIAS DO SUL. **Mapa Digital GeoCaxias**. GeoCaxias. Disponível em: <https://gis.caxias.rs.gov.br/portal/apps/webappviewer/index.html?id=136b9a0f5541425b91c6c9b4562be410>. Acesso em: 10 mar. 2023.

QUEVEDO, T.C.; GERALDI, M.S.; MELO, A.P. Applying machine learning to develop energy benchmarking for university buildings in Brazil. **Journal of Building Engineering**, v. 63, n. A. 105468 p, 1 Jan. 2023.

RICHARDS, B. **New glass architecture**. North America, Yale University Press, 2006.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3 ed. Pearson, f. 573, 2014. 1145 p.

SCHEURER, F. Materialising Complexity. **Architectural Design**, Londres, v. 80, n. 4, p. 86-93, jul/ago. 2010.

SCHUMACHER, P. **The Autopoiesis of Architecture**, Volume I: A New Framework for Architecture. 1 ed. John Wiley & Sons, v. 3, f. 239, 2011. 478 p.

SEBESTYEN, A. Machine learning for architects and designers: Implementing machine learning into the digital design process. *In: SCHOOL OF ARCHITECTURE SYMPOSIA*. 2021, **Proceedings [...]**, p. 295-306.

SEGNINI JUNIOR, F. **A prática profissional do arquiteto em discussão**. São Paulo. 244 p Tese (Doutorado em Estruturas Ambientais Urbanas) - Faculdade de Arquitetura e Urbanismo - Universidade de São Paulo, 2002.

SHRIVASTAVA, A. **Underfitting Vs Just right Vs Overfitting in Machine learning**. Kaggle. 2020. Disponível em: <https://www.kaggle.com/discussions/getting-started/166897>. Acesso em: 13 mai. 2023.

SILVA, S. M. A **Sustentabilidade e o Conforto das Construções**. 2009. Tese (Doutorado) – Universidade do Minho, Guimarães, 2009.

SIQUEIRA JUNIOR, A. A. de. **Tecnologia de fachada: cortina com placas de grês porcelanato**. 2003. Tese de Doutorado. Universidade de São Paulo, 2003.

TEDESCHI, A. **Parametric Architecture with Grasshopper**: Primer. Le Penseur, f. 103, 2011. 206 p.

TSAY, Y. et al. A Machine Learning-Based Prediction Model of LCCO₂ for Building Envelope Renovation in Taiwan. **Sustainability**, v. 13, n. 15, p. 8209, 2021.

VILLEGAS-MIER, C. G. et al. Optimized Random Forest for Solar Radiation Prediction Using Sunshine Hours. **Micromachines**, v. 13, n. 9, p. 1406, 2022.

WESTPHAL, F. S. Manual técnico do vidro plano para edificações. **Abividro**, p. 190, 2016.

WORTMANN, T.; TUNÇER, B. Differentiating parametric design: Digital workflows in contemporary architecture and construction. **Design Studies**, v. 52, p. 173-197, 2017.

XIA, J.; PENG, M. The parametric design of Shanghai towers: form and facade. **Journal of Architecture and Urbanism**, v. 38, n. 4, p. 221-232, 2014. Disponível em: <https://global.ctbuh.org/resources/papers/2217->

XIA, Jun. The parametric design of Shanghai Tower's form and facade. **Architectural Design**, v. 84, n. 2, p. 32-37, 2014.

YARES, E. **50 Years of CAD**. Design World Online. 2013. Disponível em: <https://www.designworldonline.com/50-years-of-cad/>. Acesso em: 31 mai. 2023.

ZAHA HADID ARCHITECTS. **Morpheus Hotel and Resort at City of Dreams**. Zaha Hadid. Disponível em: <https://www.zaha-hadid.com/architecture/city-of-dreams-hotel-tower-cotai-macau/>. Acesso em: 1 fev. 2023.

APÊNDICE A – DADOS DE ANÁLISES DE RADIAÇÃO SOLAR

Número de Pavimentos	Pé Direito (m)	Largura (m)	Profundidade (m)	Rotação (°)	Angulação (°)	Azimute (°)	Radiação Solar (kWh/m ²)
20	2.6	22	30	0	0	0	462.45
20	2.6	22	30	1	0	0	480.08
20	2.6	22	30	2	0	0	476.82
20	2.6	22	30	3	0	0	487.29
20	2.6	22	30	4	0	0	559.73
20	2.6	22	30	5	0	0	603.32
20	2.6	22	30	6	0	0	620.07
20	2.6	22	30	7	0	0	603.86
20	2.6	22	30	8	0	0	564.78
20	2.6	22	30	9	0	0	615.75
20	2.6	22	30	10	0	0	641.16
20	2.6	22	30	0	0	0	462.45
20	2.6	22	30	0	0	2	461.50
20	2.6	22	30	0	0	5	463.02
20	2.6	22	30	0	0	8	464.24
20	2.6	22	30	0	0	10	464.67
20	2.6	22	30	0	0	15	463.73
20	2.6	22	30	0	0	35	444.93
20	2.6	22	30	0	0	45	426.90
20	2.6	22	30	0	0	90	462.14
20	2.6	22	30	0	0	100	465.14
20	2.6	22	30	0	0	120	449.98
20	2.62	22	30	0	0	0	462.45
20	2.62	22	30	0	0	2	461.50
20	2.62	22	30	0	0	5	463.02
20	2.62	22	30	0	0	8	464.24
20	2.62	22	30	0	0	10	464.67
20	2.62	22	30	0	0	15	463.73
20	2.62	22	30	0	0	35	444.93
20	2.62	22	30	0	0	45	426.90
20	2.62	22	30	0	0	90	462.14
20	2.62	22	30	0	0	100	464.54
20	2.62	22	30	0	0	120	449.97
20	2.63	22	30	0	0	0	462.45
20	2.63	22	30	0	0	2	461.50
20	2.63	22	30	0	0	5	463.02
20	2.63	22	30	0	0	8	464.24
20	2.63	22	30	0	0	10	464.67
20	2.63	22	30	0	0	15	463.73
20	2.63	22	30	0	0	35	444.92
20	2.63	22	30	0	0	45	426.90

20	2.63	22	30	0	0	90	462.14
20	2.63	22	30	0	0	100	464.54
20	2.63	22	30	0	0	120	449.98
20	2.64	22	30	0	0	0	462.45
20	2.64	22	30	0	0	2	461.50
20	2.64	22	30	0	0	5	463.02
20	2.64	22	30	0	0	8	464.24
20	2.64	22	30	0	0	10	464.67
20	2.64	22	30	0	0	15	463.73
20	2.64	22	30	0	0	35	444.92
20	2.64	22	30	0	0	45	425.88
20	2.64	22	30	0	0	90	462.14
20	2.64	22	30	0	0	100	464.54
20	2.64	22	30	0	0	120	449.98
20	2.65	22	30	0	0	0	462.45
20	2.65	22	30	0	0	2	461.50
20	2.65	22	30	0	0	5	463.02
20	2.65	22	30	0	0	8	464.24
20	2.65	22	30	0	0	10	464.67
20	2.65	22	30	0	0	15	463.73
20	2.65	22	30	0	0	35	444.92
20	2.65	22	30	0	0	45	425.88
20	2.65	22	30	0	0	90	462.14
20	2.65	22	30	0	0	100	464.54
20	2.65	22	30	0	0	120	449.98
20	2.66	22	30	0	0	0	462.45
20	2.66	22	30	0	0	2	461.50
20	2.66	22	30	0	0	5	463.02
20	2.66	22	30	0	0	8	464.24
20	2.66	22	30	0	0	10	464.67
20	2.66	22	30	0	0	15	463.73
20	2.66	22	30	0	0	35	444.92
20	2.66	22	30	0	0	45	425.88
20	2.66	22	30	0	0	90	462.14
20	2.66	22	30	0	0	100	464.54
20	2.66	22	30	0	0	120	449.98
20	2.67	22	30	0	0	0	459.61
20	2.67	22	30	0	0	2	461.50
20	2.67	22	30	0	0	5	463.02
20	2.67	22	30	0	0	8	464.24
20	2.67	22	30	0	0	10	464.67
20	2.67	22	30	0	0	15	463.73
20	2.67	22	30	0	0	35	444.92
20	2.67	22	30	0	0	45	425.88
20	2.67	22	30	0	0	90	462.14
20	2.67	22	30	0	0	100	464.54

20	2.67	22	30	0	0	120	449.98
20	2.68	22	30	0	0	0	459.61
20	2.68	22	30	0	0	2	461.50
20	2.68	22	30	0	0	5	463.02
20	2.68	22	30	0	0	8	464.24
20	2.68	22	30	0	0	10	464.67
20	2.68	22	30	0	0	15	463.73
20	2.68	22	30	0	0	35	444.92
20	2.68	22	30	0	0	45	425.88
20	2.68	22	30	0	0	90	462.14
20	2.68	22	30	0	0	100	464.54
20	2.68	22	30	0	0	120	449.98
20	2.69	22	30	0	0	0	459.61
20	2.69	22	30	0	0	2	461.50
20	2.69	22	30	0	0	5	463.02
20	2.69	22	30	0	0	8	464.11
20	2.69	22	30	0	0	10	464.55
20	2.69	22	30	0	0	15	463.73
20	2.69	22	30	0	0	35	444.92
20	2.69	22	30	0	0	45	425.88
20	2.69	22	30	0	0	90	462.14
20	2.69	22	30	0	0	100	464.54
20	2.69	22	30	0	0	120	449.98
20	2.7	22	30	0	0	0	459.61
20	2.7	22	30	0	0	2	461.34
20	2.7	22	30	0	0	5	463.02
20	2.7	22	30	0	0	8	464.11
20	2.7	22	30	0	0	10	464.67
20	2.7	22	30	0	0	15	463.73
20	2.7	22	30	0	0	35	444.92
20	2.7	22	30	0	0	45	425.88
20	2.7	22	30	0	0	90	462.14
20	2.7	22	30	0	0	100	464.54
20	2.7	22	30	0	0	120	449.98
20	2.71	22	30	0	0	0	459.61
20	2.71	22	30	0	0	2	461.34
20	2.71	22	30	0	0	5	463.02
20	2.71	22	30	0	0	8	464.11
20	2.71	22	30	0	0	10	464.55
20	2.71	22	30	0	0	15	463.73
20	2.71	22	30	0	0	35	444.92
20	2.71	22	30	0	0	45	425.88
20	2.71	22	30	0	0	90	462.14
20	2.71	22	30	0	0	100	464.54
20	2.71	22	30	0	0	120	449.98
20	2.75	22	30	0	0	0	459.61

20	2.75	22	30	0	0	2	461.34
20	2.75	22	30	0	0	5	462.88
20	2.75	22	30	0	0	8	464.11
20	2.75	22	30	0	0	10	464.55
20	2.75	22	30	0	0	15	463.73
20	2.75	22	30	0	0	35	444.92
20	2.75	22	30	0	0	45	425.88
20	2.75	22	30	0	0	90	462.14
20	2.75	22	30	0	0	100	463.97
20	2.75	22	30	0	0	120	449.98
20	2.80	22	30	0	0	0	459.61
20	2.80	22	30	0	0	2	461.34
20	2.80	22	30	0	0	5	462.88
20	2.80	22	30	0	0	8	464.11
20	2.80	22	30	0	0	10	464.55
20	2.80	22	30	0	0	15	463.73
20	2.80	22	30	0	0	35	444.92
20	2.80	22	30	0	0	45	425.88
20	2.80	22	30	0	0	90	462.14
20	2.80	22	30	0	0	100	463.97
20	2.80	22	30	0	0	120	449.98
20	3.00	22	30	0	0	0	459.61
20	3.00	22	30	0	0	2	461.34
20	3.00	22	30	0	0	5	462.88
20	3.00	22	30	0	0	8	464.11
20	3.00	22	30	0	0	10	464.55
20	3.00	22	30	0	0	15	463.64
20	3.00	22	30	0	0	35	444.90
20	3.00	22	30	0	0	45	425.79
20	3.00	22	30	0	0	90	461.31
20	3.00	22	30	0	0	100	463.97
20	3.00	22	30	0	0	120	448.92
20	3.10	22	30	0	0	0	459.61
20	3.10	22	30	0	0	2	461.34
20	3.10	22	30	0	0	5	462.88
20	3.10	22	30	0	0	8	464.11
20	3.10	22	30	0	0	10	464.55
20	3.10	22	30	0	0	15	463.64
20	3.10	22	30	0	0	35	444.90
20	3.10	22	30	0	0	45	425.79
20	3.10	22	30	0	0	90	461.31
20	3.10	22	30	0	0	100	463.97
20	3.10	22	30	0	0	120	448.92
30	3.10	22	30	0	0	0	458.30
30	3.10	22	30	0	0	2	460.01
30	3.10	22	30	0	0	5	461.52

30	3.10	22	30	0	0	8	462.73
30	3.10	22	30	0	0	10	463.16
30	3.10	22	30	0	0	15	462.22
30	3.10	22	30	0	0	35	443.45
30	3.10	22	30	0	0	45	424.37
30	3.10	22	30	0	0	90	458.99
30	3.10	22	30	0	0	100	463.38
30	3.10	22	30	0	0	120	448.92
30	3.10	22	30	0	0	0	458.30
30	3.10	22	30	0	0	2	460.01
30	3.10	22	30	0	0	5	461.52
30	3.10	22	30	0	0	8	462.73
30	3.10	22	30	0	0	10	463.16
30	3.10	22	30	0	0	15	462.22
30	3.10	22	30	0	0	35	443.45
30	3.10	22	30	0	0	45	424.37
30	3.10	22	30	0	0	90	458.99
30	3.10	22	30	0	0	100	463.38
30	3.10	22	30	0	0	120	448.92
30	3.10	22	30	1	0	0	466.99
30	3.10	22	30	2	0	0	450.93
30	3.10	22	30	3	0	0	532.27
30	3.10	22	30	4	0	0	553.61
30	3.10	22	30	5	0	0	514.76
30	3.10	22	30	6	0	0	558.40
30	3.10	22	30	7	0	0	574.68
30	3.10	22	30	8	0	0	553.63
30	3.10	22	30	9	0	0	635.07
30	3.10	22	30	10	0	0	659.94
30	3.10	22	30	1	1	0	466.89
30	3.10	22	30	2	2	0	449.70
30	3.10	22	30	3	3	0	528.71
30	3.10	22	30	4	4	0	549.63
30	3.10	22	30	5	5	0	524.34
30	3.10	22	30	6	6	0	515.18
30	3.10	22	30	7	7	0	520.15
30	3.10	22	30	8	8	0	491.36
30	3.10	22	30	9	9	0	557.36
30	3.10	22	30	10	10	0	571.27
30	3.10	22	31	0	0	0	458.30
30	3.10	22	31	1	0	0	467.00
30	3.10	22	31	2	0	0	453.11
30	3.10	22	31	3	0	0	535.63
30	3.10	22	31	4	0	0	557.27
30	3.10	22	31	5	0	0	518.54
30	3.10	22	31	6	0	0	558.33

30	3.10	22	31	7	0	0	574.59
30	3.10	22	31	8	0	0	557.64
30	3.10	22	31	9	0	0	639.39
30	3.10	22	31	10	0	0	663.17
30	3.10	22	32	0	0	0	458.30
30	3.10	22	32	1	0	0	466.99
30	3.10	22	32	2	0	0	455.32
30	3.10	22	32	3	0	0	538.95
30	3.10	22	32	4	0	0	560.86
30	3.10	22	32	5	0	0	522.19
30	3.10	22	32	6	0	0	558.29
30	3.10	22	32	7	0	0	574.49
30	3.10	22	32	8	0	0	561.41
30	3.10	22	32	9	0	0	643.43
30	3.10	22	32	10	0	0	666.10
30	3.10	22	33	0	0	0	458.30
30	3.10	22	33	1	0	0	466.99
30	3.10	22	33	2	0	0	457.49
30	3.10	22	33	3	0	0	542.22
30	3.10	22	33	4	0	0	564.42
30	3.10	22	33	5	0	0	525.78
30	3.10	22	33	6	0	0	558.25
30	3.10	22	33	7	0	0	574.41
30	3.10	22	33	8	0	0	564.99
30	3.10	22	33	9	0	0	647.16
30	3.10	22	33	10	0	0	668.77
30	3.10	22	34	0	0	0	458.30
30	3.10	22	34	1	0	0	466.98
30	3.10	22	34	2	0	0	459.64
30	3.10	22	34	3	0	0	545.47
30	3.10	22	34	4	0	0	567.90
30	3.10	22	34	5	0	0	529.22
30	3.10	22	34	6	0	0	558.17
30	3.10	22	34	7	0	0	574.32
30	3.10	22	34	8	0	0	571.66
30	3.10	22	34	9	0	0	650.62
30	3.10	22	34	10	0	0	674.84
30	2.8	22	34	0	0	0	458.30
30	2.8	22	34	1	0	0	468.78
30	2.8	22	34	2	0	0	465.98
30	2.8	22	34	3	0	0	553.68
30	2.8	22	34	4	0	0	578.26
30	2.8	22	34	5	0	0	540.30
30	2.8	22	34	6	0	0	568.39
30	2.8	22	34	7	0	0	584.50
30	2.8	22	34	8	0	0	581.15

30	2.8	22	34	9	0	0	658.94
30	2.8	22	34	10	0	0	682.13
30	2.9	22	34	0	0	0	458.30
30	2.9	22	34	1	0	0	468.15
30	2.9	22	34	2	0	0	463.74
30	2.9	22	34	3	0	0	550.79
30	2.9	22	34	4	0	0	574.66
30	2.9	22	34	5	0	0	535.98
30	2.9	22	34	6	0	0	508.31
30	2.9	22	34	7	0	0	580.95
30	2.9	22	34	8	0	0	577.87
30	2.9	22	34	9	0	0	656.49
30	2.9	22	34	10	0	0	678.86
32	2.9	22	34	8	5	0	598.88
32	2.9	22	34	8	5	2	605.36
32	2.9	22	34	8	5	5	611.82
32	2.9	22	34	8	5	8	617.59
32	2.9	22	34	8	5	10	621.35
32	2.9	22	34	8	5	15	630.78
32	2.9	22	34	8	5	35	644.63
32	2.9	22	34	8	5	45	642.33
32	2.9	22	34	8	5	90	568.07
32	2.9	22	34	8	5	100	544.71
32	2.9	22	34	8	5	120	565.27
35	2.9	22	34	8	5	0	640.47
35	2.9	22	34	8	5	2	642.45
35	2.9	22	34	8	5	5	643.92
35	2.9	22	34	8	5	8	644.75
35	2.9	22	34	8	5	10	644.86
35	2.9	22	34	8	5	15	646.48
35	2.9	22	34	8	5	35	625.16
35	2.9	22	34	8	5	45	610.93
35	2.9	22	34	8	5	90	563.10
35	2.9	22	34	8	5	100	567.49
35	2.9	22	34	8	5	120	549.52
35	2.95	20	30	8	1	0	640.05
35	2.95	20	30	8	2	0	640.41
35	2.95	20	30	8	3	0	636.04
35	2.95	20	30	8	4	0	629.31
35	2.95	20	30	8	5	0	617.22
35	2.95	20	30	8	6	0	610.01
35	2.95	20	30	8	7	0	597.42
35	2.95	20	30	8	8	0	584.26
35	2.95	20	30	8	9	0	568.53
35	2.95	20	30	8	10	0	552.52
32	2.95	20	30	8	0	0	604.97

32	2.95	20	30	8	1	0	602.78
32	2.95	20	30	8	2	0	600.29
32	2.95	20	30	8	3	0	594.91
32	2.95	20	30	8	4	0	587.62
32	2.95	20	30	8	5	0	575.56
32	2.95	20	30	8	6	0	567.86
32	2.95	20	30	8	7	0	551.80
32	2.95	20	30	8	8	0	541.25
32	2.95	20	30	8	9	0	523.55
32	2.95	20	30	8	10	0	510.19
32	2.6	20	30	8	0	0	616.36
32	2.6	20	30	8	1	0	614.56
32	2.6	20	30	8	2	0	615.00
32	2.6	20	30	8	3	0	607.51
32	2.6	20	30	8	4	0	603.16
32	2.6	20	30	8	5	0	588.62
32	2.6	20	30	8	6	0	580.78
32	2.6	20	30	8	7	0	564.42
32	2.6	20	30	8	8	0	553.24
32	2.6	20	30	8	9	0	534.13
32	2.6	20	30	8	10	0	519.98
28	2.85	22	22	8	0	0	579.30
28	2.85	22	22	8	1	0	578.60
28	2.85	22	22	8	2	0	579.33
28	2.85	22	22	8	3	0	572.21
28	2.85	22	22	8	4	0	566.67
28	2.85	22	22	8	5	0	551.43
28	2.85	22	22	8	6	0	536.04
28	2.85	22	22	8	7	0	521.19
28	2.85	22	22	8	8	0	504.04
28	2.85	22	22	8	9	0	487.00
28	2.85	22	22	8	10	0	471.59
25	2.85	22	22	8	5	0	572.07
25	2.85	22	22	8	5	1	571.85
25	2.85	22	22	8	5	2	571.54
25	2.85	22	22	8	5	3	571.16
25	2.85	22	22	8	5	4	570.74
25	2.85	22	22	8	5	5	573.56
25	2.85	22	22	8	5	6	573.13
25	2.85	22	22	8	5	7	572.57
25	2.85	22	22	8	5	8	571.89
25	2.85	22	22	8	5	9	571.08
25	2.85	22	22	8	5	10	570.04
25	2.85	22	25	8	5	0	571.18
25	2.85	22	25	8	5	1	570.96
25	2.85	22	25	8	5	2	570.65

25	2.85	22	25	8	5	3	570.28
25	2.85	22	25	8	5	4	569.85
25	2.85	22	25	8	5	5	572.67
25	2.85	22	25	8	5	6	572.17
25	2.85	22	25	8	5	7	571.68
25	2.85	22	25	8	5	8	570.98
25	2.85	22	25	8	5	9	570.17
25	2.85	22	25	8	5	10	569.12
10	2.85	22	25	8	5	0	560.59
10	2.85	22	25	8	5	1	562.58
10	2.85	22	25	8	5	2	564.85
10	2.85	22	25	8	5	3	566.64
10	2.85	22	25	8	5	4	568.38
10	2.85	22	25	8	5	5	570.07
10	2.85	22	25	8	5	6	571.63
10	2.85	22	25	8	5	7	576.60
10	2.85	22	25	8	5	8	578.10
10	2.85	22	25	8	5	9	579.63
10	2.85	22	25	8	5	10	581.23
15	2.85	22	25	8	5	0	591.44
15	2.85	22	25	8	5	1	590.39
15	2.85	22	25	8	5	2	589.20
15	2.85	22	25	8	5	3	589.81
15	2.85	22	25	8	5	4	588.62
15	2.85	22	25	8	5	5	587.21
15	2.85	22	25	8	5	6	585.79
15	2.85	22	25	8	5	7	584.27
15	2.85	22	25	8	5	8	582.78
15	2.85	22	25	8	5	9	581.53
15	2.85	22	25	8	5	10	580.28
18	2.85	22	25	8	5	0	557.81
18	2.85	22	25	8	5	1	555.67
18	2.85	22	25	8	5	2	554.09
18	2.85	22	25	8	5	3	551.95
18	2.85	22	25	8	5	4	549.63
18	2.85	22	25	8	5	5	547.30
18	2.85	22	25	8	5	6	544.94
18	2.85	22	25	8	5	7	542.46
18	2.85	22	25	8	5	8	539.89
18	2.85	22	25	8	5	9	538.00
18	2.85	22	25	8	5	10	535.99
18	2.85	22	25	8	5	11	534.07
18	2.85	22	25	8	5	12	532.02
18	2.85	22	25	8	5	13	529.86
18	2.85	22	25	8	5	14	527.73
18	2.85	22	25	8	5	15	526.98

18	2.85	22	25	8	5	16	524.62
18	2.85	22	25	8	5	17	521.24
18	2.85	22	25	8	5	18	518.88
18	2.85	22	25	8	5	19	516.54
18	2.85	22	25	8	5	20	518.04
18	3.00	22	25	8	5	20	513.83
18	3.00	22	25	8	5	21	516.15
18	3.00	22	25	8	5	22	518.36
18	3.00	22	25	8	5	23	520.47
18	3.00	22	25	8	5	24	522.49
18	3.00	22	25	8	5	25	527.60
18	3.00	22	25	8	5	26	529.68
18	3.00	22	25	8	5	27	532.19
18	3.00	22	25	8	5	28	534.26
18	3.00	22	25	8	5	29	536.21
18	3.00	22	25	8	5	30	537.98
18	3.00	22	25	8	5	31	539.75
18	3.00	22	25	8	5	32	541.39
18	3.00	22	25	8	5	33	542.90
18	3.00	22	25	8	5	34	544.30
18	3.00	22	25	8	5	35	545.65
18	3.00	22	25	8	5	36	546.89
18	3.00	22	25	8	5	37	552.11
18	3.00	22	25	8	5	38	553.30
18	3.00	22	25	8	5	39	554.79
18	3.00	22	25	8	5	40	556.06
19	3.00	22	25	8	5	30	553.30
19	3.00	22	25	8	5	31	554.81
19	3.00	22	25	8	5	32	556.08
19	3.00	22	25	8	5	33	557.23
19	3.00	22	25	8	5	34	558.23
19	3.00	22	25	8	5	35	559.22
19	3.00	22	25	8	5	36	560.08
19	3.00	22	25	8	5	37	560.81
19	3.00	22	25	8	5	38	561.43
19	3.00	22	25	8	5	39	562.00
19	3.00	22	25	8	5	40	562.44
19	3.00	22	25	8	5	41	566.00
19	3.00	22	25	8	5	42	566.34
19	3.00	22	25	8	5	43	566.91
19	3.00	22	25	8	5	44	567.14
19	3.00	22	25	8	5	45	567.24
19	3.00	22	25	8	5	46	567.14
19	3.00	22	25	8	5	47	567.09
19	3.00	22	25	8	5	48	566.93
19	3.00	22	25	8	5	49	566.72

19	3.00	22	25	8	5	50	566.39
26	3.00	22	25	0	5	0	458.30
26	3.00	22	25	1	5	0	468.82
26	3.00	22	25	2	5	0	461.11
26	3.00	22	25	3	5	0	489.25
26	3.00	22	25	4	5	0	532.42
26	3.00	22	25	5	5	0	530.86
26	3.00	22	25	6	5	0	502.52
26	3.00	22	25	7	5	0	543.32
26	3.00	22	25	8	5	0	566.50
26	3.00	22	25	9	5	0	537.93
26	3.00	22	25	10	5	0	565.74
27	3.00	22	25	0	6	0	460.60
27	3.00	22	25	1	6	0	469.69
27	3.00	22	25	2	6	0	461.48
27	3.00	22	25	3	6	0	487.34
27	3.00	22	25	4	6	0	523.46
27	3.00	22	25	5	6	0	517.84
27	3.00	22	25	6	6	0	484.76
27	3.00	22	25	7	6	0	538.25
27	3.00	22	25	8	6	0	543.14
27	3.00	22	25	9	6	0	503.51
27	3.00	22	25	10	6	0	577.41
27	3.00	22	25	0	3	0	458.30
27	3.00	22	25	1	3	0	469.98
27	3.00	22	25	2	3	0	453.92
27	3.00	22	25	3	3	0	500.16
27	3.00	22	25	4	3	0	543.48
27	3.00	22	25	5	3	0	530.06
27	3.00	22	25	6	3	0	514.83
27	3.00	22	25	7	3	0	570.27
27	3.00	22	25	8	3	0	582.25
27	3.00	22	25	9	3	0	540.05
27	3.00	22	25	10	3	0	613.35
13	3.00	22	25	0	3	0	461.13
13	3.00	22	25	1	3	0	479.93
13	3.00	22	25	2	3	0	492.68
13	3.00	22	25	3	3	0	494.70
13	3.00	22	25	4	3	0	487.44
13	3.00	22	25	5	3	0	498.06
13	3.00	22	25	6	3	0	541.85
13	3.00	22	25	7	3	0	583.07
13	3.00	22	25	8	3	0	607.80
13	3.00	22	25	9	3	0	619.90
13	3.00	22	25	10	3	0	626.50

APÊNDICE B – ALGORITMO DE APRENDIZADO DE MÁQUINA

```
import pandas as pd
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import r2_score, mean_squared_error,
mean_absolute_error

df = pd.read_excel('/content/dados grasshopper- R01.xlsx')

print("Primeiras linhas do dataframe:")
print(df.head())

features = df[['Número de Pavimentos', 'Pé Direito (m)', 'Largura (m)',
'Profundidade (m)', 'Rotação (°)', 'Angulação (°)', 'Azimute (°)']]
target = df['Radiação Solar (kWh/m²)']

X_train, X_test, y_train, y_test = train_test_split(features, target, test_size=0.2,
random_state=42)

X_train_filtered = X_train[
    (X_train['Número de Pavimentos'].between(10, 40)) &
    (X_train['Pé Direito (m)'].between(2.6, 3.2)) &
    (X_train['Largura (m)'].between(15, 22)) &
    (X_train['Profundidade (m)'].between(20, 34)) &
    (X_train['Rotação (°)'].between(0, 10)) &
    (X_train['Angulação (°)'].between(0, 10)) &
    (X_train['Azimute (°)'].between(0, 120))
]
```

```
y_train_filtered = y_train.loc[X_train_filtered.index]
```

```
X_test_filtered = X_test[
    (X_test['Número de Pavimentos'].between(10, 40)) &
    (X_test['Pé Direito (m)'].between(2.6, 3.2)) &
    (X_test['Largura (m)'].between(15, 22)) &
    (X_test['Profundidade (m)'].between(20, 34)) &
    (X_test['Rotação (°)'].between(0, 10)) &
    (X_test['Angulação (°)'].between(0, 10)) &
    (X_test['Azimute (°)'].between(0, 120))
]
```

```
y_test_filtered = y_test.loc[X_test_filtered.index]
```

```
print(f"Tamanho do X_train_filtered: {X_train_filtered.shape}")
print(f"Tamanho do y_train_filtered: {y_train_filtered.shape}")
```

```
rf = RandomForestRegressor(random_state=42)
```

```
param_grid = {
    'n_estimators': [100, 200], # Número de árvores na floresta
    'max_features': ['auto', 'sqrt', 'log2'], # Número de features a serem
consideradas na divisão
    'max_depth': [None, 10, 20, 30], # Profundidade máxima da árvore
}
```

```
grid_search = GridSearchCV(estimator=rf, param_grid=param_grid, cv=5,  
n_jobs=-1, scoring='neg_mean_squared_error')
```

```
grid_search.fit(X_train_filtered, y_train_filtered)
```

```
best_rf = grid_search.best_estimator_
```

```
y_pred = best_rf.predict(X_test_filtered)
```

```
best_index = y_pred.argmax()
```

```
best_features = X_test_filtered.iloc[best_index]
```

```
r2 = r2_score(y_test_filtered, y_pred)
```

```
rmse = mean_squared_error(y_test_filtered, y_pred, squared=False)
```

```
mae = mean_absolute_error(y_test_filtered, y_pred)
```

```
print("\nMaior Valor de Radiação Solar Incidente (kWh/m2) estimado:",  
y_pred[best_index])
```

```
print("\nValores de Entradas Geométricas:")
```

```
print(best_features)
```

```
print("\nMelhores Parâmetros Encontrados:")
```

```
print(grid_search.best_params_)
```

```
print("\nMétricas de Avaliação do Modelo:")
```

```
print(f"R2: {r2:.4f}")
```

```
print(f"RMSE: {rmse:.4f} kWh/m2")
```

```
print(f"MAE: {mae:.4f} kWh/m2")
```