

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE ENGENHARIAS, CIÊNCIAS AGRÁRIAS E DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL

GREGORY ALMEIDA GRIZAFIS

ANÁLISE DE ORÇAMENTOS ESTIMATIVOS DE ESQUADRIAS DE PVC
ATRAVÉS DE MODELOS DE *MACHINE LEARNING*

PONTA GROSSA

2024

GREGORY ALMEIDA GRIZAFIS

ANÁLISE DE ORÇAMENTOS ESTIMATIVOS DE ESQUADRIAS DE PVC
ATRAVÉS DE MODELOS DE *MACHINE LEARNING*

Trabalho de Conclusão de Curso
apresentado para a obtenção do título de
Bacharel em Engenharia Civil pela
Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Elias Pereira

PONTA GROSSA

2024

GREGORY ALMEIDA GRIZAFIS

ANÁLISE DE ORÇAMENTOS ESTIMATIVOS DE ESQUADRIAS DE PVC
ATRAVÉS DE MODELOS DE *MACHINE LEARNING*

Este Trabalho de Conclusão de Curso foi julgado e aprovado como requisito para a obtenção do título de Bacharel em Engenharia Civil pela Universidade Estadual de Ponta Grossa.

BANCA EXAMINADORA

Prof. Dr. Elias Pereira

Departamento de Engenharia Civil – Universidade Estadual de Ponta Grossa

Prof^a. Dra. Eloise Aparecida Langaro

Departamento de Engenharia Civil – Universidade Estadual de Ponta Grossa

Prof. Msc. Marcelo Miranda Farias

Departamento de Engenharia Civil – Universidade Estadual de Ponta Grossa

Ponta Grossa, 29 de outubro de 2024

AGRADECIMENTOS

A realização deste trabalho só foi possível com o apoio e a colaboração de diversas pessoas, às quais gostaria de expressar minha profunda gratidão.

Primeiramente, agradeço a Deus, por me conceder força, saúde e sabedoria ao longo de todo este processo. Sem Sua presença em minha vida, não teria chegado até aqui.

Ao meu orientador, Prof. Dr. Elias Pereira, por toda orientação, paciência, e pelos valiosos ensinamentos que contribuíram diretamente para minha formação.

Aos meus colegas de curso e amigos, que estiveram ao meu lado durante essa jornada acadêmica, compartilhando desafios e conquistas, e me apoiando nos momentos difíceis. Vocês fizeram essa caminhada ser muito mais leve e gratificante.

Agradeço também à minha família, que sempre acreditou em mim, me motivou e me ofereceu o suporte necessário durante os momentos de maior necessidade. A paciência e o apoio incondicional de vocês foram fundamentais para que eu mantivesse o foco em meus objetivos.

Por fim, expresso minha gratidão à empresa Smart Center Comércio de Materiais de Construção EIRELI, pela disponibilização dos dados e pela confiança depositada, o que possibilitou a realização da parte prática deste estudo.

A todos vocês, meu muito obrigado!

RESUMO

A elaboração de orçamentos é essencial na construção civil para assegurar o controle dos custos e a viabilidade de projetos. Métodos convencionais nem sempre conseguem lidar com a complexidade dos dados e as diversas variáveis envolvidas, especialmente no setor de esquadrias de PVC, onde os custos variam de acordo com fatores como dimensões, acabamento, complexidade do modelo, condições climáticas e de transporte. Nesse contexto, técnicas de Machine Learning (ML) oferecem soluções inovadoras, permitindo a análise de grandes volumes de dados e a geração de previsões de custo. Este trabalho tem como objetivo analisar a aplicação de técnicas de ML na estimativa de orçamentos para esquadrias de PVC, avaliando sua eficácia e aplicabilidade prática. Utilizando um banco de dados real cedido pela empresa Smart Center Comércio de Materiais de Construção EIRELI, que contém informações de orçamentos entre 2019 e 2024, foram aplicados os algoritmos de árvore de decisão e floresta aleatória. A partir de métricas como o Erro Médio Absoluto (MAE) e o coeficiente de determinação (R^2), foi possível validar o desempenho dos modelos em relação aos métodos convencionais de orçamentação. Os resultados indicam que o modelo de floresta aleatória apresentou melhor desempenho, com um R^2 de 0,79 e um MAE de R\$ 30.543,33, enquanto o modelo de árvore de decisão obteve um R^2 de 0,68 e um MAE de R\$ 37.058,78, evidenciando a superioridade da floresta aleatória na precisão das previsões. No entanto, o modelo de floresta aleatória não alcançou um R^2 ainda maior devido a limitações como a variabilidade nos dados, ausência de variáveis que pudessem capturar melhor algumas condições específicas dos projetos e a influência de outliers nos dados de orçamentos. Esses fatores reduziram a capacidade do modelo de explicar completamente a variação nos custos, demonstrando que, embora o ML tenha um potencial significativo, ajustes e inclusão de novas variáveis podem ser necessários para uma previsão ainda mais precisa.

Palavras-chave: *Machine Learning*, Aprendizado de Máquina, Esquadrias de PVC, Árvore de Decisão, Floresta aleatória, Previsão de Custos.

LISTA DE FIGURA

Figura 1 - Quadro resumo das características básicas de cada tipo de orçamento ..	18
Figura 2 - Demonstração em corte de modelo de esquadria de PVC	20
Figura 3 - Redes neurais multicamadas.....	24
Figura 4 - Árvore de decisão	25
Figura 5 - Floresta aleatória.	26
Figura 6 - Curva logística	27
Figura 7 - Separação de classes no modelo SVM	28
Figura 8 - Vazão semanal prevista e vazão verificada	29
Figura 9 - Fluxo de etapas de metodologia	35
Figura 10 - Variáveis de entrada do modelo.....	38
Figura 11 - Código do modelo de <i>Machine Learning</i>	42
Figura 12 - Resultados do modelo árvore de decisão	43
Figura 13 – Gráfico de dispersão de erros por custo real (árvore de decisão).....	44
Figura 14 - Resultados do modelo floresta aleatória	45
Figura 15 - Dispersão de erros por custo real (floresta aleatória)	46

LISTAS DE TABELA

Tabela 1 - Comparação de resultados entre os métodos.....	47
---	----

LISTAS DE SIGLAS E ABREVIATURAS

ABNT – Associação Brasileira de Normas Técnicas

BDI – Benefícios e Despesas Indiretas

BIM – Building Information Modeling

CUB – Custo Unitário Básico da Construção Civil

IA – Inteligência Artificial

IPP – Índice de Preços ao Produtor

MAE – Erro Médio Absoluto

MAPE – Erro Percentual Absoluto Médio

ML – Machine Learning

PVC – Policloreto de Vinila

RNA – Rede Neural Artificial

R² – Coeficiente de Determinação

SVM – Support Vector Machine

WAPE – Erro Percentual Absoluto Médio Ponderado

SUMÁRIO

1. INTRODUÇÃO.....	10
1.1 OBJETIVOS	11
1.1.1 Objetivo Geral.....	11
1.1.2 Objetivos específicos	11
1.2 JUSTIFICATIVA.....	12
2. REVISÃO BIBLIOGRÁFICA	14
2.1 ESQUADRIAS NA CONSTRUÇÃO CIVIL	14
2.1.1 Evolução dos Materiais de Esquadrias	15
2.1.2 Características das Esquadrias de PVC	16
2.2 ORÇAMENTAÇÃO	17
2.2.1 Conceitos de orçamentação na construção civil.....	17
2.2.2 Componentes do orçamento na construção civil	19
2.3 ESQUADRIAS DE PVC E ORÇAMENTAÇÃO	20
2.3.1 Fatores que impactam o custo das esquadrias de PVC	21
2.4 INTELIGÊNCIA ARTIFICIAL (IA).....	22
2.4.1 Definição e evolução da IA	23
2.4.2 <i>Machine Learning</i> (ML)	24
2.4.3 IA na orçamentação de Obras	28
2.4.4 <i>Machine learning</i> e esquadrias	30
2.5 TECNOLOGIAS UTILIZADAS	31
2.6 DESENVOLVIMENTO DE MODELOS DE IA PARA ORÇAMENTAÇÃO.....	32

3.	MATERIAIS E MÉTODOS.....	34
3.1	DELINEAMENTO DA PESQUISA	34
3.2	COLETA E ANÁLISE DOS DADOS	35
3.3	MODELO DE ÁRVORE DE DECISÃO	37
3.4	MODELO DE FLORESTA ALEATÓRIA	38
3.5	TREINAMENTO DOS MODELOS	39
3.6	MÉTRICAS DE AVALIAÇÃO	40
4.	RESULTADOS E DISCUSSÕES	42
4.1	ÁRVORE DE DECISÃO.....	42
4.2	FLORESTA ALEATÓRIA.....	45
4.3	COMPARAÇÃO DOS MODELOS	47
4.3.1	Aplicação em orçamentos.....	48
5.	CONCLUSÕES.....	50
	REFERÊNCIAS.....	52

1. INTRODUÇÃO

Na construção civil, a elaboração do orçamento é uma das etapas de maior importância, pois permite a previsão e o controle dos gastos envolvidos durante a execução dos serviços. Para Gonzáles (2008), tradicionalmente, o orçamento corresponde a uma previsão do custo total de um projeto, sendo esse valor a soma de todos os gastos necessários para sua execução. O custo acrescido da margem de lucro corresponde ao preço final, sendo um fator determinante para a viabilidade do empreendimento.

A aplicação de métodos tradicionais de orçamentação, muitas vezes, se mostra limitada devido à complexidade e à quantidade de dados necessários para prever os custos com precisão (Santos, 2014). Isso se agrava nas etapas iniciais do processo, em que a falta de informações detalhadas pode resultar em erros significativos nas estimativas de custo. Para enfrentar esse desafio, novas tecnologias, como a Inteligência Artificial (IA) e o aprendizado de máquina (*Machine Learning*), têm sido introduzidas como ferramentas para solucionar esses problemas no setor de orçamentação. O *Machine Learning* (ML), como destacado por Santos (2020), foca no desenvolvimento de algoritmos capazes de aprender a partir de dados históricos, identificando padrões e tendências que ajudam a melhorar a precisão das previsões de custo.

No setor de esquadrias de PVC, essas tecnologias são úteis, pois os custos podem variar de acordo com diversos fatores, como o tamanho das esquadrias, o tipo de acabamento, a complexidade do modelo e até mesmo as condições climáticas e de transporte (Freire *et al.*, 2023). O uso de modelos de ML permite processar essas variáveis simultaneamente, gerando previsões estimadas, assim reduzindo o tempo de orçamento. Além disso, como destaca Freire *et al.* (2023), as esquadrias de PVC têm ganhado popularidade no mercado por suas propriedades de isolamento térmico e acústico, o que, por sua vez, torna crucial a precisão e velocidade no cálculo de custos para manter a competitividade do setor.

Além de otimizar o processo de orçamentação, a adoção de ML oferece benefícios como a automação de processos repetitivos, a redução de erros humanos e a melhoria na tomada de decisões. Segundo Santos (2020), a automação proporcionada por essas tecnologias permite que os orçamentos sejam elaborados de maneira mais ágil, oferecendo estimativas iniciais mais precisas, mesmo com

informações limitadas. Dessa forma, empresas podem se beneficiar de uma maior eficiência, reduzindo o tempo gasto na elaboração de orçamentos e focando em estratégias de execução e gerenciamento de obras.

Entretanto, a implementação dessas tecnologias também apresenta desafios. Para que o ML seja eficaz, é necessário dispor de uma infraestrutura tecnológica adequada e de profissionais capacitados para lidar com grandes volumes de dados e a complexidade dos algoritmos (Santos, 2020). Além disso, é fundamental garantir que os modelos preditivos sejam constantemente atualizados com novos dados, assegurando que suas previsões continuem refletindo as condições reais de mercado e de produção.

Diante desse contexto, o presente trabalho busca investigar como o uso de *Machine Learning* pode contribuir para melhorar a precisão dos orçamentos estimativos de esquadrias de PVC, através de cenários reais de orçamentos, proporcionando uma abordagem inovadora para o setor da construção civil. Assim, espera-se que o uso dessas ferramentas possa aumentar a competitividade das empresas, reduzir desperdícios e otimizar o uso de recursos financeiros e materiais no setor.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Analisar a utilização de *Machine Learning* na estimativa de custos de esquadrias de PVC, avaliando sua eficácia e aplicabilidade prática na elaboração de orçamentos.

1.1.2 Objetivos específicos

- Organizar dados concebidos e variáveis com influência nos custos das esquadrias de PVC;
- Aplicar a técnica do *Machine Learning* através dos modelos de árvore de decisão e floresta aleatória para previsão de estimativa de custos de esquadrias de PVC;
- Treinar e testar os modelos utilizando os dados organizados.

- Examinar a eficácia dos modelos a partir de métricas de avaliação estatísticas;

1.2 JUSTIFICATIVA

A precisão e a eficiência nos processos de orçamentação são fatores importantes para a competitividade e sustentabilidade das empresas no setor da construção civil, especialmente no que se refere à orçamentação de esquadrias de PVC. Métodos tradicionais de orçamentação frequentemente apresentam falta de precisão devido à variabilidade dos fatores que influenciam os custos, como flutuações nos preços dos materiais, a complexidade dos projetos e a mão de obra envolvida (González, 2008). A análise estimativa de orçamentos, quando aliada ao *machine learning* (ML), oferece uma inovação significativa, permitindo o tratamento dessas variáveis de forma otimizada e mais precisa.

Com o advento da inteligência artificial (IA) e do *machine learning*, surgem novas oportunidades para aprimorar os processos de orçamentação. Segundo Santos (2020), o ML possibilita a análise de grandes volumes de dados históricos, identificando padrões e tendências que podem melhorar substancialmente a precisão das previsões orçamentárias. Para o caso específico das esquadrias de PVC, cujos custos podem variar consideravelmente em função de fatores como dimensões, tipo de acabamento e condições de instalação (Groth; Schreiber, 2023), o uso do ML pode automatizar e refinar o processo de estimativa de custos, gerando previsões mais confiáveis e eficientes.

A crescente adoção de tecnologias de *machine learning* (ML) tem revolucionado as operações empresariais, promovendo aumentos significativos de produtividade, alcançando até 40%, segundo McKinsey & Company (2020). A automatização de tarefas repetitivas e a análise de grandes volumes de dados proporcionam decisões mais rápidas e precisas, sendo o ML uma estratégia crucial para manter a competitividade. Além disso, a adoção de IA generativa pode aumentar a produtividade em até 25% na execução de trabalhos de conhecimento e melhorar a qualidade do trabalho em até 40% (Zao-Sanders, 2024). Portanto, a integração do *Machine Learning* nas operações empresariais é essencial para a excelência operacional e o crescimento sustentável em um mercado cada vez mais desafiador.

A adoção de ML não só eleva a precisão das estimativas, como também contribui para a redução de erros humanos e otimiza o tempo necessário para a elaboração de orçamentos. Pereira (2024) destaca que essas tecnologias permitem o

processamento simultâneo de múltiplas variáveis, o que é essencial em cenários onde a precisão é crítica para manter a competitividade. Além disso, em um ambiente cada vez mais pautado pela necessidade de agilidade e economia de recursos, o uso de ML responde à demanda por soluções que ofereçam eficiência e controle de custos, especialmente no contexto da construção civil, onde sustentabilidade e redução de desperdícios são bastante valorizadas (Freire *et al.*, 2023).

Portanto, a aplicação de *machine learning* na análise estimativa de orçamentos de esquadrias de PVC justifica-se pela necessidade de aprimorar a precisão e a eficiência das estimativas no setor. Além de proporcionar uma abordagem inovadora, a tecnologia oferece uma solução eficaz para a construção civil, alinhada às tendências contemporâneas de transformação digital. A relevância desse tema está diretamente ligada à busca por maior sustentabilidade, controle de custos e precisão, fatores imprescindíveis para garantir a competitividade das empresas e promover um futuro mais sustentável e eficiente no setor.

2. REVISÃO BIBLIOGRÁFICA

2.1 ESQUADRIAS NA CONSTRUÇÃO CIVIL

As esquadrias desempenham um papel central nas edificações, sendo responsáveis por conectar o ambiente interno ao externo, ao mesmo tempo em que asseguram diversas funcionalidades indispensáveis, como o isolamento térmico, acústico, segurança e estética. Conforme Vieira (2008), esses elementos contribuem diretamente para o conforto ambiental de uma construção, garantindo que fatores como a ventilação natural e a iluminação sejam adequadamente controlados, além disso, as esquadrias são fundamentais para evitar a entrada de ruídos externos e a dissipação de calor, promovendo maior eficiência energética nas edificações e, consequentemente, proporcionando economia no uso de sistemas de climatização.

No que diz respeito ao isolamento térmico, as esquadrias atuam como barreiras importantes contra a troca de calor entre o interior e o exterior de uma construção. Materiais como o alumínio, a madeira e o PVC têm desempenhos diferenciados nessa função. O PVC, por exemplo, é reconhecido pela sua alta capacidade de isolamento térmico, sendo uma opção bastante eficaz em regiões com grandes variações de temperatura. Já as esquadrias de alumínio, embora altamente duráveis, necessitam de tratamentos adicionais, como o uso de pinturas especiais, para melhorar sua eficiência térmica. Em termos de isolamento acústico, a escolha do material e o tipo de vidro associado à esquadria são essenciais para minimizar a entrada de ruídos, principalmente em áreas urbanas densamente povoadas (Pena, 2020).

A segurança proporcionada pelas esquadrias também é um fator relevante na construção civil. Além de oferecer vedação contra intempéries, elas são projetadas para evitar invasões e garantir a proteção do patrimônio e das pessoas. Segundo Silva e Emiliano (2017), esquadrias fabricadas com materiais robustos como o alumínio e o ferro são frequentemente escolhidas por sua resistência mecânica, sendo especialmente recomendadas para portas e janelas de segurança. No entanto, a madeira também pode ser uma opção segura, desde que sejam aplicados tratamentos adequados para aumentar sua durabilidade e resistência.

Esteticamente, as esquadrias desempenham um papel vital na definição do estilo arquitetônico de uma edificação. A madeira, por exemplo, é amplamente utilizada em projetos que buscam um acabamento mais sofisticado e natural, enquanto o alumínio é associado a uma estética mais moderna e minimalista. O PVC,

por sua vez, oferece uma ampla gama de acabamentos e cores, sendo uma escolha versátil para diferentes padrões construtivos. Assim, Silva e Emiliano (2017) ressaltam que a escolha das esquadrias deve equilibrar funcionalidade, custo e estética, conforme as necessidades e características específicas de cada projeto.

2.1.1 Evolução dos Materiais de Esquadrias

A evolução dos materiais utilizados em esquadrias tem acompanhado o desenvolvimento das técnicas construtivas, refletindo a busca por soluções que aliam durabilidade, estética e eficiência. Inicialmente, a madeira era amplamente utilizada, devido à sua disponibilidade e facilidade de manipulação, sendo ainda muito valorizada em projetos que prezam pela estética e sofisticação. No entanto, a necessidade de materiais mais resistentes e que exigem menos manutenção impulsionou o uso de metais como alumínio e ferro, especialmente em ambientes que demandam maior resistência às intempéries (Freire *et al.*, 2023).

O PVC tem se destacado entre os materiais para esquadrias, devido à sua leveza, fácil manutenção e excelentes propriedades de isolamento térmico e acústico. Essas características tornam o PVC especialmente adequado para edificações que buscam eficiência energética, já que sua alta capacidade de vedação ajuda a reduzir o uso de sistemas de aquecimento e resfriamento. Além disso, o material é altamente resistente a intempéries, corrosão e pragas, fatores que contribuem para sua baixa necessidade de manutenção e consequente redução de custos a longo prazo (Pena, 2020).

O PVC é um material derivado de recursos abundantes como o petróleo e o sal. Seu processo de fabricação envolve menor consumo de energia, e o material é 100% reciclável, o que o torna uma escolha atraente em mercados que valorizam a sustentabilidade. Essa combinação de fatores técnicos e econômicos tem feito com que as esquadrias de PVC se tornem cada vez mais comuns em projetos de construção civil (Freire *et al.*, 2023).

Portanto, o aumento do uso de esquadrias de PVC está diretamente ligado às suas vantagens técnicas, como alta durabilidade e eficiência energética, além dos benefícios econômicos, como seu baixo custo de manutenção. Essas qualidades têm impulsionado a popularidade do PVC em um mercado cada vez mais atento à sustentabilidade e ao custo-benefício, tornando-o uma das principais escolhas em termos de esquadrias para a construção civil.

2.1.2 Características das Esquadrias de PVC

O PVC (policloreto de vinila) é um material amplamente utilizado na construção civil, devido às suas propriedades técnicas. Sua composição química, que inclui uma alta porcentagem de cloro, o torna resistente à propagação de chamas e a condições climáticas adversas, além de facilitar a reciclagem. Comparado a materiais como o alumínio e a madeira, o PVC possui uma excelente resistência à corrosão, o que o torna ideal para ambientes úmidos ou com alta exposição a elementos externos, onde outros materiais poderiam se deteriorar mais rapidamente (Pena, 2020).

Em termos de eficiência energética, as esquadrias de PVC oferecem um excelente isolamento térmico, principalmente quando utilizadas em conjunto com vidros duplos ou insulados. Esse desempenho é superior ao das esquadrias de alumínio, que, por ser um metal, apresenta uma maior condutividade térmica. Dessa forma, o PVC contribui significativamente para a redução da troca de calor entre o ambiente interno e externo, promovendo um melhor controle da temperatura e, conseqüentemente, uma economia nos custos com climatização. Além disso, devido à sua capacidade de vedação eficiente, as esquadrias de PVC também desempenham um papel importante na isolação acústica, proporcionando maior conforto sonoro (Ferrarese *et al.*, 2024).

Outro aspecto que se destaca é a baixa necessidade de manutenção, diferentemente de materiais como madeira, que exige tratamentos constantes contra pragas e umidade, o PVC é praticamente livre de manutenção ao longo de sua vida útil. Mesmo em relação ao alumínio, que pode demandar cuidados com a corrosão dependendo do ambiente, o PVC se mantém inalterado em diversos tipos de clima, o que gera uma economia significativa a longo prazo, tanto em termos de tempo quanto de custos operacionais (Ferrarese *et al.*, 2024).

Portanto, ao considerar o impacto econômico, o PVC se apresenta como uma solução vantajosa não apenas pela sua durabilidade e baixa manutenção, mas também pelos custos competitivos em relação a outros materiais, especialmente quando se leva em conta o ciclo de vida do produto. A facilidade de instalação e o menor custo com reparos ao longo dos anos tornam o PVC uma escolha atrativa em processos de orçamentação para obras, consolidando sua aplicação em projetos residenciais e comerciais.

2.2 ORÇAMENTAÇÃO

O processo de orçamentação não é uma prática recente, Tavares (2000) comenta que ela começou a ganhar aceitação na metade do século XX nos Estados Unidos, quando o planejamento financeiro passou a ser mais valorizado. Esse processo, embora não seja exclusivo da construção civil, tem grande importância em diversos campos econômicos. No ramo da engenharia civil, a orçamentação envolve a estimativa dos custos necessários para a execução de um projeto de construção, devendo sempre avaliar e atribuir valores aos insumos como: mão de obra, materiais, equipamentos, tempo e custos indiretos (Santos, 2020).

2.2.1 Conceitos de orçamentação na construção civil

A base para a orçamentação de obras de engenharia civil começa com o projeto, que é a apresentação gráfica e detalhada dos atributos técnicos da obra. Este projeto fornece uma definição qualitativa e quantitativa de todos os elementos necessários para a execução do trabalho. Também são incluídos documentos escritos como orçamento, memoriais, especificações técnicas, cronograma e contratos.

González (2008) classifica os projetos em diferentes tipos, cada um com seu propósito específico:

- **Anteprojeto:** Representa a fase da concepção inicial do projeto, onde são estabelecidas as principais diretrizes, porém com menor grau de detalhamento.
- **Projeto Básico:** Apresenta detalhamento suficiente para o entendimento da obra e contratação, incluindo alguns projetos complementares.
- **Projeto Legal:** Envolve a documentação necessária para atender às exigências legais e regulamentares dos órgãos públicos.
- **Projetos Complementares:** Projetos das diversas especialidades, tais como estruturas, instalações hidráulicas, elétricas, telefônicas, paisagismo, fachadas, climatização artificial, entre outros.
- **Projeto Executivo:** Contém todas as informações detalhadas necessárias para a execução da obra, incluindo planos, especificações técnicas e metodologias.

Para Mattos (2006), uma das mais importantes atividades de um orçamentista é o levantamento de quantitativos. Esse processo corresponde a uma etapa que possibilita a execução corretamente planejada da obra, através da quantificação e discriminação de materiais e serviços. Não somente para compor o custo de

orçamento, mas para auxiliar as posteriores etapas de compra de insumos, identificação de fornecedores, planejamento de pagamentos e alocação de recursos.

Segundo Valentini (2009), de acordo com o nível de informações nos projetos disponíveis, a assertividade esperada e a finalidade, podemos calcular um orçamento das seguintes formas:

- **Orçamento Tabelado:** Baseia-se na multiplicação da área construída por um custo unitário básico (CUB/m²). O Custo Unitário Básico da Construção Civil (CUB) é calculado conforme a ABNT NBR 12.721/2006, com base nas atualizações de novos projetos.
- **Orçamento Sintético:** Elaborado utilizando o método dos Índices de Construção. A partir de um projeto básico, todas as atividades macros mensuráveis são calculadas.
- **Orçamento Analítico:** Envolve o detalhamento completo de todas as etapas, o que garante a confiabilidade do preço final apresentado. Esse tipo de orçamento aplica toda a metodologia, considerando todos os recursos e variáveis. No orçamento analítico, o projeto é dividido em atividades, quantificado e composto por diversas composições para obter o custo direto. Em seguida, ao adicionar os custos indiretos e o BDI (Benefícios e Despesas Indiretas), chega-se ao preço de venda.

A Figura 1 ilustra um quadro que sintetiza as principais características dos diferentes tipos de orçamentação utilizados na construção civil, incluindo o orçamento tabelado, sintético e analítico.

Figura 1 - Quadro resumo das características básicas de cada tipo de orçamento

TIPOS	CARACTERÍSTICAS BÁSICAS		
	Informações	Metodologia	Finalidade
Tabelado	Área Construída (m ²)	* CUB - Sinduscon	Ordem de Grandeza
Sintético	Projeto Básico	Índices de construção	Estimativa
Analítico	Projetos Executivos	Apuração completa	Preço Real

* CUB – Custo Unitário Básico

Fonte: Valentini (2009, p.10).

Esse quadro resume o nível de detalhamento e precisão esperado para cada método, conforme discutido na seção de orçamentação de obras. A Figura 1 complementa a análise teórica ao demonstrar visualmente como o nível de detalhamento influencia diretamente a confiabilidade das estimativas de custo, reforçando a necessidade de se escolher o método adequado de acordo com a complexidade e o estágio do projeto. Os métodos de orçamentação apresentados permitem diferentes níveis de precisão e detalhamento, sendo escolhidos conforme a complexidade do projeto e a necessidade de informação. A escolha do método adequado é fundamental para garantir a viabilidade econômica do projeto.

2.2.2 Componentes do orçamento na construção civil

A composição de custos de um orçamento é resultado da soma de todos os insumos utilizados durante a execução da obra, como materiais, equipamentos e mão de obra (Valentini, 2009).

Os materiais de construção são um dos principais componentes do orçamento. Entre os materiais mais comuns estão cimento, areia, brita, tijolos e blocos, aço, madeiras, tubos e conexões, pisos e revestimentos (Gonzáles, 2018). A escolha correta dos materiais e a precisão na quantidade necessária são fundamentais para evitar desperdícios e custos adicionais.

A mão de obra abrange todos os custos relacionados aos trabalhadores que executarão a obra. Isso inclui salários, encargos trabalhistas, benefícios, treinamentos e segurança (Gonzáles, 2018). A eficiência e qualificação da mão de obra influenciam diretamente na produtividade e na qualidade da construção, sendo uma das composições que pode afetar significativamente na qualidade e velocidade de execução. (Valentini, 2009).

Os custos com equipamentos e ferramentas necessários para a execução da obra também são considerados. Isso pode incluir aluguel de máquinas e equipamentos, aquisição de ferramentas, manutenção de equipamentos e insumos indiretos (Valentini, 2009). Muitas vezes, é necessário contratar serviços de terceiros para a execução de partes específicas do projeto. Esses serviços podem incluir projetos e consultorias, serviços de topografia, ensaios laboratoriais, transporte de materiais e descarte de resíduos. A contratação de serviços especializados pode agregar qualidade e eficiência ao projeto, mas também representa um custo que deve ser previsto no orçamento.

Para Valentini (2009), os custos indiretos são aqueles que, embora não estejam diretamente ligados a uma atividade específica da obra, são necessários para a sua realização. Incluem despesas administrativas, custos com instalações temporárias, comunicação, transporte e seguro da obra. Esses custos devem ser considerados para não impactar negativamente o orçamento total. O Benefícios e Despesas Indiretas (BDI) é um componente que agrega ao orçamento uma margem de lucro, além de cobrir riscos e despesas adicionais. Ele é geralmente expresso como uma porcentagem dos custos diretos e indiretos e inclui margem de lucro, riscos e imprevistos, despesas financeiras e seguros e garantias (Gonzáles, 2018).

2.3 ESQUADRIAS DE PVC E ORÇAMENTAÇÃO

A orçamentação de esquadrias é um processo que envolve a análise detalhada dos custos de produção, permitindo às empresas avaliarem seus recursos e definir os preços de seus produtos de maneira competitiva e sustentável. De acordo com Groth e Schreiber (2019), a gestão eficaz dos custos é essencial para garantir que os materiais utilizados, como o PVC, reforços metálicos, vidros e acessórios, sejam devidamente contabilizados. O domínio dessa prática inclui a avaliação precisa do custo total dos materiais, levando em consideração as variações de mercado, como a flutuação cambial no caso de matérias-primas importadas, como perfis de PVC (Groth e Schreiber, 2019). A Figura 2 apresenta um corte esquemático de um modelo de giro de esquadria de PVC com perfis da fabricante Kömmerling, onde pode-se observar os detalhes dos componentes de fabricação.

Figura 2 - Demonstração em corte de modelo de esquadria de PVC



Fonte: Koemmerling (2024).

A mão de obra também desempenha um papel fundamental na orçamentação, sendo considerada um custo direto no processo de produção. Groth e Schreiber (2019) destacam a importância de calcular os custos relacionados aos funcionários, incluindo salários, encargos trabalhistas e outros benefícios. A eficiência na execução das atividades, como o corte de perfis e a montagem das esquadrias, pode impactar diretamente o custo final, exigindo que as empresas invistam em treinamento e monitoramento contínuos para minimizar perdas e aumentar a produtividade.

Além dos custos diretos, é necessário considerar os custos indiretos, que também influenciam significativamente o orçamento. Esses incluem despesas com energia elétrica, aluguel e manutenção de maquinário. Tais custos, embora não estejam diretamente ligados à produção, afetam a operação como um todo e, portanto, devem ser alocados adequadamente nos produtos, para que os preços de venda reflitam todas as despesas envolvidas no processo produtivo (Andrade; Wernke; Ritta, 2019)

Ademais, o PVC, sendo um material leve, facilita o transporte e a instalação, o que pode reduzir os custos logísticos em comparação a materiais mais pesados, como o alumínio. Isso faz com que as esquadrias de PVC se tornem uma opção atraente para grandes projetos. Silva e Emiliano (2017) apontam que esse material apresenta grande flexibilidade de design e pode ser facilmente adaptado a diferentes tipos de construção, o que também pode ser vantajoso no momento de orçar diferentes projetos.

2.3.1 Fatores que impactam o custo das esquadrias de PVC

Os custos das esquadrias de PVC podem ser influenciados por diversos fatores que impactam diretamente o orçamento de fabricação e instalação. Primeiramente, o tamanho da esquadria é um fator crucial, pois determina a quantidade de material necessário, bem como a complexidade do transporte e instalação. Esquadrias maiores exigem mais perfis de PVC, vidros e reforços metálicos, o que eleva o custo de produção. Além disso, a proporção entre a mão de obra empregada e o tempo de execução tende a aumentar à medida que o tamanho das estruturas cresce, afetando diretamente o valor final do produto (Groth e Schreiber, 2023).

Outro fator significativo que impacta o custo das esquadrias de PVC é o tipo de esquadria. Diferentes modelos, como janelas de correr, pivotantes ou portas deslizantes, possuem requisitos distintos tanto em termos de materiais quanto de

tecnologia empregada. Por exemplo, janelas com persianas integradas ou automatizadas demandam componentes adicionais, como motores e sistemas de controle, que encarecem o produto. Além disso, certos tipos de esquadrias exigem tratamentos específicos de acabamento, o que também pode gerar custos adicionais para o consumidor (Groth e Schreiber, 2023).

A complexidade da instalação é outro ponto a ser considerado no cálculo do custo total. Instalações mais simples, como em ambientes residenciais padrão, tendem a ser mais rápidas e com menor demanda de mão de obra especializada. No entanto, ambientes com condições adversas, como regiões com alta exposição à maresia, podem demandar materiais de maior resistência, reforços adicionais e técnicas mais sofisticadas de vedação, o que aumenta o tempo e o custo da instalação. Esse fator é especialmente relevante em projetos customizados, onde cada detalhe deve ser planejado minuciosamente (Groth e Schreiber, 2023).

Por isso, a gestão de custos é uma prática essencial para o sucesso de empresas que lidam com produção, especialmente em setores competitivos, como o de esquadrias de alumínio e PVC. De acordo com Frizon (2022), a contabilidade de custos torna-se um instrumento valioso para o planejamento e controle, permitindo uma avaliação precisa dos custos de fabricação. Essa gestão eficaz oferece às empresas a capacidade de identificar os principais componentes de custo, otimizando recursos e evitando desperdícios, o que resulta em tomadas de decisão para melhor alcançar a lucratividade desejada.

A formação do preço de venda é outro aspecto crítico abordado. O cálculo envolve a soma de todos os custos de produção, desde a matéria-prima até os custos indiretos, adicionando uma margem de lucro desejada. Entretanto, Frizon (2022) revela que muitas empresas, como a apresentada em seu estudo, enfrentam dificuldades em praticar o preço ideal devido à alta competitividade do mercado. Dessa forma, embora o preço de mercado seja inferior ao custo calculado, as empresas ainda podem manter sua lucratividade ao identificar e priorizar produtos com maior margem de contribuição.

2.4 INTELIGÊNCIA ARTIFICIAL (IA)

Segundo Oliveira (2024), a inteligência artificial (IA) utiliza os conhecimentos da computação para desenvolver máquinas com a capacidade de realizar tarefas com um nível de inteligência comparável ao humano. Isso é alcançado por meio de

programação focada em aprender, solucionar problemas e armazenar informações para uso futuro.


Dentro do campo tecnológico a IA pode ser classificada em duas categorias principais: IA fraca (ou estreita) e IA forte (ou geral). A IA fraca é projetada para executar tarefas específicas, como reconhecimento de voz ou diagnóstico médico, enquanto a IA forte possui capacidades cognitivas amplas, com multifunções (Saracevic, 1996).

2.4.1 Definição e evolução da IA

Os neurônios, presentes no sistema nervoso humano, são unidades básicas que formam quase 100 trilhões de conexões através de sinapses. Devido à capacidade de transmitir impulsos elétricos, eles conseguem armazenar e processar informações. Similarmente, as redes neurais artificiais (RNA) têm a capacidade de processar dados por meio de conexões entre unidades básicas, simulando o sistema nervoso humano (Carvalho; Oliveira, 2018). As máquinas convencionais respondem a comandos específicos, seguindo instruções pré-definidas na programação, através de uma lógica de operações lineares e limitadas. Entretanto, nas RNAs, o processamento é realizado de forma múltipla e paralela, permitindo um aprendizado contínuo e mais sofisticado (Carvalho; Oliveira, 2018).

A Figura 3 representa a estrutura de uma rede neural multicamada, uma técnica fundamental de Inteligência artificial. Esta figura é essencial para visualizar como as redes neurais artificiais processam dados em várias camadas interligadas, simulando o comportamento do cérebro humano ao aprender com padrões.

Figura 3 - Redes neurais multicamadas



Fonte: Carvalho; Oliveira (2018, p.32).

A ideia de máquinas pensantes está presente desde os antigos filósofos gregos, mas a ideia moderna da IA começou a ser desenvolvida com o trabalho de Alan Turing, que criou o famoso "Teste de Turing" em 1950. Ele sugeriu que uma máquina poderia ser considerada inteligente se sua conversa não pudesse ser distinguida da de um humano (Lima, 2017). Durante o período dos anos 1970, a IA começou a enfrentar críticas por conta de seu progresso lento e expectativas elevadas relacionadas a tecnologia. Os "invernos da IA" ocorreram quando o financiamento e o interesse na pesquisa das inteligências diminuíram devido à percepção de que os resultados não estavam atendendo às expectativas criadas (Lima, 2019).

Para Oliveira (2024), nos últimos anos a inteligência artificial (IA) tem crescido rapidamente devido a avanços em algoritmos, processamento e armazenamento de dados. No entanto, esse avanço gera preocupações, como a substituição de empregos por máquinas inteligentes e questões éticas relacionadas à privacidade ao uso de dados.

2.4.2 Machine Learning (ML)

Traduzido para o português como aprendizado de máquina, o *Machine Learning* é uma área de estudo dentro da inteligência artificial (IA) que busca capacitar sistemas a aprenderem a partir do reconhecimento de padrões em conjuntos de dados. No processo de aprendizado da máquina, diversos métodos podem ser empregados conforme as características dos dados e o modelo a ser construído. Os


dados de entrada podem conter uma ou mais variáveis que influenciam na escolha do modelo adequado (Nelli 2015 *apud* Pereira, 2024, p.14).

Entre os modelos destacados por Pereira (2024), tem-se:

- **Árvore de Decisão:** Este método começa a partir de um nó e se ramifica de acordo com os resultados possíveis, seguindo uma sequência lógica de testes. A árvore de decisão é particularmente útil por sua simplicidade e clareza na interpretação dos resultados.

A Figura 4 apresenta o diagrama de uma árvore de decisão. Esta figura ajuda a ilustrar como decisões complexas podem ser decompostas em uma série de perguntas binárias, facilitando a previsão de custos com base em múltiplos critérios. A árvore de decisão é particularmente útil quando há a necessidade de tomar decisões baseadas em diferentes variáveis, como o tipo de material e o tamanho do projeto, permitindo uma previsão mais clara e objetiva dos custos no setor da construção.

Figura 4 - Árvore de decisão




Fonte: Pereira (2024).

- **Floresta aleatória:** consiste em um conjunto de árvores de decisão, onde cada árvore contribui para o resultado. Esse método se destaca por sua capacidade de lidar com a não linearidade dos dados e é amplamente utilizado tanto para tarefas de classificação quanto de regressão. Na classificação, a floresta aleatória realiza previsões com base no voto majoritário das árvores de decisão, onde cada árvore "vota" em uma classe e a classe com o maior número de votos é escolhida como a predição final. No caso da regressão, a predição é obtida pela média das saídas individuais de todas as árvores, proporcionando uma estimativa mais precisa e estável.

A Figura 5 representa o modelo de floresta aleatória. No contexto da orçamentação de esquadrias de PVC, o uso de florestas aleatórias aumenta a precisão das estimativas ao reduzir a variabilidade e o erro associados a decisões isoladas. A imagem facilita a compreensão de como cada árvore individual contribui para o modelo final, e como a média ou o voto majoritário entre essas árvores resulta em previsões mais confiáveis e estáveis para o setor de construção civil.

Figura 5 - Floresta aleatória.




Fonte: Ariza et al. (2023).

- **Regressão logística:** utilizado para modelar a probabilidade de ocorrência de um evento binário, ou seja, onde a variável de resposta pode assumir apenas dois valores: 0 ou 1. No contexto desse método, o valor 1 indica a ocorrência do evento de interesse, enquanto o valor 0 indica a ausência do evento. O modelo calcula a probabilidade de o evento ocorrer com base nos valores das variáveis independentes (ou preditoras). Se a probabilidade calculada for maior que 0,5, o modelo prevê que o resultado será 1, indicando a ocorrência do evento. Caso contrário, se a probabilidade for menor ou igual a 0,5, o modelo prevê que o resultado será 0, indicando a ausência do evento.

A Figura 6 ilustra a curva logística, um modelo matemático utilizado para prever eventos binários. Esta figura complementa a discussão sobre a aplicação de modelos de *Machine Learning* em cenários onde a resposta esperada é binária, ajudando a prever a ocorrência de eventos que podem influenciar diretamente o planejamento financeiro de uma obra.

Figura 6 - Curva logística




Fonte: HAIR *et al.* (2009).

- **Support Vector Machine (SVM):** esse modelo funciona classificando os dados ao identificar um hiperplano que melhor separa as diferentes classes de dados no espaço de características. Este hiperplano é escolhido de maneira a maximizar a margem entre as classes, ou seja, a distância entre os pontos de dados mais próximos de cada classe e o hiperplano. O algoritmo utiliza vetores de suporte, que são os pontos de dados mais próximos ao hiperplano, para definir a posição e a orientação do hiperplano. Esses vetores de suporte são cruciais, pois determinam a fronteira de decisão que será utilizada para classificar novos dados. Assim, quando novos dados são introduzidos, o SVM prediz a classe desses dados com base na posição relativa ao hiperplano definido pelos vetores de suporte.

A Figura 7 demonstra como o modelo de Máquina de Vetores de Suporte (SVM) realiza a separação de classes de dados, identificando um hiperplano ótimo para maximizar a margem entre diferentes grupos de dados. Esta figura ajuda a entender visualmente como o SVM lida com dados não lineares, oferecendo uma alternativa poderosa para aumentar a precisão em projetos de construção civil, onde a separação de categorias de custos é crucial para previsões eficazes.

Figura 7 - Separação de classes no modelo SVM



Fonte: Barbosa *et al.* (2019).


Para dados que apresentam distribuição desregular, o modelo SVM apresenta melhor desempenho, visto que a separação dos dados não é linear e independente (Coutinho, 2019 *apud* Pereira, 2024, p.18).

2.4.3 IA na orçamentação de Obras

Embora recente, a aplicação da inteligência artificial (IA) na engenharia civil vem ganhando cada vez mais espaço, proporcionando resultados confiáveis em diferentes setores de pesquisa. O uso de Redes Neurais Artificiais (RNA) é um exemplo notável dessa tendência. Na hidrologia, por exemplo, estudos realizados por Montenegro *et al.* (2010) compararam as vazões semanais de rios previstas com o uso de RNA às vazões observadas no ano 2000 no reservatório de Três Marias, localizado na Bacia do Rio São Francisco, demonstrando a precisão e eficácia das previsões baseadas em IA.

A Figura 8 compara a vazão prevista com a vazão real em um estudo hidrológico, oferecendo uma analogia direta para o uso de *Machine Learning* na construção civil. Esta imagem reforça a ideia central do trabalho de que modelos preditivos de IA podem alcançar grande precisão quando aplicados corretamente, ajustando-se constantemente com base nos dados reais.

Figura 8 - Vazão semanal prevista e vazão verificada



Fonte: MONTENEGRO *et al.* (2010).

Nas obras de terraplenagem, tem-se como exemplo do uso de RNA's o trabalho realizado por Silva (2021), que utilizou uma rede neural artificial (RNA) para estimar os custos mensais de obras de terraplenagem, utilizando dados de um condomínio horizontal. A análise por trecho resultou em um erro médio de 7% para o volume de corte, mas um erro maior para o aterro devido à falta de dados. A RNA demonstrou ser uma ferramenta promissora para estimativa de custos na engenharia civil.

Como exemplo de trabalhos utilizando inteligência artificial na orçamentação de obras, destaca-se o estudo de Dacoregio (2017). O autor empregou uma rede neural supervisionada e utilizou um banco de dados obtido pela Universidade Federal de Santa Catarina (UFSC), contendo informações de 40 obras prediais. O resultado alcançado foi um erro médio na estimativa de custo de 17,22%.

Em outro estudo, realizado por Biondi Neto *et al.* (2004), foram analisados 52 projetos, onde a previsão de custo do metro quadrado de obras residenciais foi feita através do uso de uma rede neural. Neste caso, a porcentagem de erro médio foi de apenas 1,5%.

Nos estudos de Santos (2020), foi analisada a aplicação de técnicas de *Machine Learning* na otimização de orçamentos de obras civis, utilizando dados históricos de 72 obras fornecidos por uma construtora. Dentre os modelos testados

foram a Regressão Linear, Árvore de Decisão, Floresta Aleatória e XGBoost. O modelo de Regressão Linear teve um Erro Absoluto Médio (MAE) de R\$ 265.933 e um Erro Percentual Absoluto Médio Ponderado (WAPE) de 24,357.

Essas pesquisas demonstram o potencial das redes neurais na construção civil, indicando ser uma ferramenta eficaz para a estimativa de custos. Além disso, incentivam o uso dessa tecnologia em novos estudos, possibilitando aprimoramentos contínuos nas técnicas de orçamentação.

2.4.4 *Machine learning* e esquadrias

As tecnologias digitais, como o uso de *machine learning* (ML) e algoritmos genéticos (AG), oferecem novas formas de otimizar a gestão de recursos na construção civil, conforme explorado por Simões, Vasconcelos e Melo (2020). Esses autores destacam que ferramentas como o ML podem automatizar processos de decisão, reduzindo o tempo de análise e permitindo uma gestão mais eficiente de materiais e recursos. Tais ferramentas, além de otimizarem processos, aumentam a produtividade e a colaboração em projetos complexos (Simões *et al.*, 2020).

Quando aplicamos o conceito de *machine learning* ao setor de esquadrias de PVC, é possível criar modelos preditivos para otimização de custos. O uso de ML permite que sejam analisadas variáveis complexas, como os custos de produção, transporte, instalação e manutenção das esquadrias. Com base em dados históricos, algoritmos de aprendizado podem identificar padrões de comportamento dos custos em diferentes cenários de mercado e condições ambientais, oferecendo previsões mais precisas sobre o orçamento necessário para cada projeto. Dessa forma, o ML pode não só prever os custos, mas também sugerir ajustes em materiais e métodos para otimizar o desempenho das esquadrias de PVC, diminuindo o impacto econômico ao longo do ciclo de vida do produto (Simões *et al.*, 2020).

Além disso, o *machine learning* pode ser utilizado para calcular o custo-benefício das esquadrias de PVC em relação a outros materiais. Ao reunir dados sobre o desempenho térmico e acústico, durabilidade e manutenção, os algoritmos podem criar um modelo que prevê o retorno sobre o investimento a longo prazo. Esses modelos ajudam engenheiros e arquitetos a tomar decisões informadas sobre qual material oferece o melhor desempenho para cada projeto, ao mesmo tempo em que otimiza os recursos financeiros disponíveis. A aplicação do ML neste contexto garante que as decisões de compra e instalação sejam baseadas em dados robustos,

minimizando riscos financeiros e aumentando a eficiência geral do projeto (Simões *et al.*, 2020).

Portanto, a incorporação de *machine learning* na criação de modelos de previsão de custos para esquadrias de PVC oferece uma abordagem inovadora e eficiente para o setor da construção civil. Essa tecnologia não só melhora a precisão das previsões de orçamentos estimativos, mas também permite a otimização dos recursos, reduzindo custos operacionais e aumentando a sustentabilidade dos projetos. Ao utilizar dados reais sobre o desempenho do PVC em diferentes cenários, o ML proporciona uma tomada de decisão mais segura e eficiente, garantindo maior confiabilidade e economia na instalação de esquadrias

2.5 TECNOLOGIAS UTILIZADAS

Algoritmos de aprendizado de máquina como floresta aleatória e XGBoost são utilizados para classificação e regressão, analisando variáveis simultaneamente e identificando padrões nos dados. Esses algoritmos são essenciais para prever custos de construção com base em variáveis como localização, materiais e condições (Santos, 2021). A flexibilidade desses algoritmos os torna aplicáveis a diversos tipos de projetos, proporcionando uma ferramenta versátil para engenheiros civis.

Além das RNAs e dos algoritmos de aprendizado de máquina, a integração de IA com sistemas de informações geográficas (SIG) também tem se mostrado eficaz na orçamentação de obras. A análise de dados espaciais e geográficos permite prever como a localização e as condições do terreno afetarão os custos de construção. Silva (2021) demonstra que a combinação de IA e SIG proporciona uma análise mais precisa e detalhada, considerando fatores que tradicionalmente poderiam ser negligenciados.

Ferramentas de programação como MATLAB e *Python* são amplamente utilizadas para desenvolver modelos de IA personalizados para orçamentação. Esses ambientes oferecem bibliotecas robustas para aprendizado de máquina e análise de dados, permitindo a criação de soluções sob medida para as necessidades específicas de cada projeto. Silva (2021) ressalta que o uso dessas ferramentas proporciona flexibilidade e precisão na análise de dados complexos, essencial para a elaboração de orçamentos detalhados e precisos.

Os sistemas de informação são fundamentais para a gestão e orçamentação de obras. Um exemplo significativo é o sistema desenvolvido por Sacco (2004), que

utiliza o software Clarion 5.5 para criar uma base de dados abrangente. Esse sistema permite o cadastro de clientes, serviços e a realização de orçamentos de forma eficiente, proporcionando consultas instantâneas e garantindo a equidade entre os orçamentos realizados.

O *Building Information Modeling* (BIM) é uma metodologia que utiliza modelos digitais tridimensionais para integrar todas as informações de um projeto de construção. O BIM permite simular e visualizar todas as etapas do ciclo de vida de um empreendimento, proporcionando uma estimativa de custos mais precisa. Essa tecnologia auxilia na identificação de conflitos e problemas potenciais antes do início da obra, resultando em economias significativas e na otimização do uso de recursos (Cavalcanti *et al.*, 2018).

Os softwares de orçamentação são ferramentas essenciais no processo de elaboração de orçamentos detalhados e precisos. Eles permitem a criação de planilhas complexas, a integração de dados de diversas fontes e a simulação de diferentes cenários. Tais funcionalidades facilitam a análise de custos e a tomada de decisões. O uso de programas como o MS Project exemplifica essa integração, combinando custos com o cronograma da obra e oferecendo uma visão mais completa do projeto (Valentini, 2009).

A utilização de ferramentas de visualização de dados como Tableau e Power BI facilita a interpretação e comunicação dos resultados das análises de IA. Essas ferramentas permitem que os gestores visualizem as previsões de custos de maneira clara e intuitiva, apoiando a tomada de decisões e a identificação de oportunidades de economia. A visualização eficiente dos dados financeiros complexos é fundamental para garantir a transparência e a precisão na gestão de projetos de construção (Cavalcanti *et al.*, 2018).

2.6 DESENVOLVIMENTO DE MODELOS DE IA PARA ORÇAMENTAÇÃO

A metodologia para o desenvolvimento de modelos de IA inicia-se com a coleta e preparação dos dados. Informações de projetos já realizados, que incluem custos e especificações técnicas, são coletados e organizados de forma que possam ser processados pela IA. A normalização dos dados é um dos passos essenciais, pois garante que todos os valores estejam em uma escala comparável, o que melhora o desempenho do modelo (Silva, 2021).

Em seguida, os dados são divididos em conjuntos de treinamento e teste, permitindo avaliar a precisão do modelo. A seleção de variáveis relevantes, como dimensões e condições específicas do projeto, são cruciais para a construção de um modelo robusto (Sacco *et al.*, 2004).

Diferentes modelos podem ser testados para identificar aquele que apresenta o melhor desempenho e menor erro. No trabalho de Silva (2021), várias arquiteturas de RNA foram estudadas, variando o número de camadas, neurônios e funções de ativação. O teste com diferentes configurações permite calibrar a rede para melhorar sua capacidade de previsão.

O treinamento do modelo envolve dependência de aprendizado supervisionado. Durante o treinamento, a rede neural é alimentada com os dados de treinamento, ajustando os parâmetros para minimizar o erro de previsão. Este processo é iterativo e pode requerer múltiplas iterações para alcançar a convergência. Técnicas como validação cruzada ajudam a prevenir o *overfitting* (ajuste excessivo), garantindo que o modelo seja generalizável e performe bem em novos dados (Silva, 2021). Durante o treinamento, a análise de métricas como o erro médio quadrático (MSE, da sigla em inglês *Mean Squared Error*) auxilia na avaliação do progresso do modelo.

Após o treinamento, a avaliação do modelo é importante para assegurar a eficácia. Os dados de teste são utilizados para medir a precisão das previsões e identificar possíveis ajustes necessários. A análise dos erros de previsão e a comparação com os valores reais fornecem insights sobre a necessidade de ajustes adicionais ou refinamento do modelo (Sacco *et al.*, 2004; Silva *et al.*, 2018).

Finalmente, a implementação do modelo em um ambiente de produção envolve a integração com sistemas de gerenciamento de projetos e orçamentação existentes. O modelo treinado pode fornecer estimativas de custo em tempo real, auxiliando na tomada de decisões e no planejamento financeiro das obras. Manter o modelo atualizado com novos dados é essencial para a precisão contínua. (Sacco *et al.*, 2004; Silva, 2021).

3. MATERIAIS E MÉTODOS

3.1 DELINEAMENTO DA PESQUISA

Esta pesquisa teve como objetivo analisar a aplicação de técnicas de *Machine Learning* (ML) na orçamentação estimativa de esquadrias de PVC, comparando a eficácia de diferentes algoritmos preditivos. Para isso, foram utilizados dois modelos: a árvore de decisão e a floresta aleatória. A árvore de decisão foi inicialmente fornecida pela empresa Smart Center Comércio de Materiais de Construção EIRELI, e posteriormente o modelo de floresta aleatória foi incorporado para melhorar a precisão das previsões, especialmente em cenários com maior variabilidade nos dados.

O estudo utiliza um banco de dados contendo 1032 registros de orçamentos de esquadrias de PVC, coletados entre 2019 e 2024. Esses dados passaram por um processo de tratamento e limpeza, onde registros inconsistentes e valores atípicos foram removidos para garantir a qualidade do treinamento dos modelos. Adicionalmente, foi aplicada uma correção monetária baseada no Índice de Preços ao Produtor (IPP), ajustando os valores dos orçamentos de acordo com a data em que foram realizados, assegurando a comparabilidade dos valores ao longo do tempo.

Dentre as etapas, inicialmente foi realizada a coleta e análise dos dados de orçamentos de esquadrias de PVC. Na sequência, realizou-se o treinamento dos modelos de *Machine Learning*, que se ajustam para identificar padrões e tendências relevantes nos dados. Após o treinamento, o modelo foi testado realizando previsões de orçamentos, que foram posteriormente comparadas com os valores obtidos por meio das técnicas tradicionais de orçamentação de esquadrias de PVC utilizadas no setor. O estudo foi conduzido em um ambiente de pesquisa estruturado pela empresa, utilizando ferramentas como *Google Colaboratory*, *Python* e suas bibliotecas.

Os modelos utilizados foram avaliados por meio de métricas de desempenho, como o Erro Médio Absoluto (MAE), o Erro Percentual Absoluto Médio (MAPE), o Erro Percentual Absoluto Médio Ponderado (WAPE) e o coeficiente de determinação (R^2). A pesquisa permitiu uma análise comparativa entre os resultados obtidos com o modelo de *Machine Learning* e os métodos tradicionais, fornecendo uma visão dos potenciais benefícios da IA aplicada à orçamentação.

A estruturação da pesquisa foi elaborada conforme a Figura 9.

Figura 9 - Fluxo de etapas de metodologia



Fonte: Elaborado pelo Autor. (2024).

3.2 COLETA E ANÁLISE DOS DADOS

O banco de dados utilizado neste trabalho foi cedido pela empresa Espaço Smart em formato de planilha .xlsx, contendo 1032 registros de orçamentos de esquadrias de PVC realizados entre o período de 2019 até o presente momento. Entre as informações contidas no banco de dados, cada orçamento inclui variáveis essenciais para a análise de estimativas de custos em projetos de esquadrias, como:

- **CUSTO:** Valor total do custo associado ao projeto. Refere-se ao orçamento do custo de materiais para a produção das esquadrias de PVC, considerando todas as especificações de esquadrias do projeto.
- **SECAO:** Categoria ou linha de produto relacionada. Define a linha técnica de perfis orçada (PLUS ou PREMIUM), o que ajuda a diferenciar a qualidade ou características dos perfis de PVC considerados no orçamento, que podem variar de acordo com as dimensões e do modelo considerados no orçamento.
- **PERSIANAS_QUARTOS:** Indica se as esquadrias incluem ou não persianas nos quartos. Essa variável classifica os projetos de acordo com a presença desse item adicional, que influencia o custo total do orçamento.
- **COR:** Cor das esquadrias de PVC. A cor pode variar entre branco ou colorido e tem impacto tanto no custo quanto na estética do projeto.
- **TELAS_MOSQUITEIRAS:** Presença ou ausência de telas mosquiteiras nas esquadrias. Essa variável pode variar entre telas em todas as esquadrias, telas

apenas nos quartos ou em nenhuma esquadria. Ela informa se o projeto inclui a instalação de telas para proteção contra insetos, o que agrega valor ao orçamento.

- VIDROS: Tipo de vidro utilizado nas esquadrias. Especifica o tipo de vidro empregado no projeto, como laminado, duplos ou simples, sendo um componente essencial para determinar o valor final do orçamento.
- AREA: Área total das esquadrias em metros quadrados. Essa variável mede a soma das áreas esquadrias incluídas no projeto, sendo uma das principais variáveis usadas para calcular o custo total.
- QTD_ESQUADRIAS: Quantidade de esquadrias em cada projeto. Refere-se ao número de unidades de esquadrias orçadas, um fator diretamente relacionado ao custo do projeto.

Embora os dados tenham sido fornecidos em formato adequado, foi necessário realizar uma etapa de limpeza para garantir a qualidade e consistência dos registros antes da aplicação dos modelos de *machine learning*. Durante esse processo, foram removidos valores incongruentes, como orçamentos com metragens excessivamente altas para esquadrias e casos em que a quantidade descrita não correspondia ao contexto esperado, como, por exemplo, orçamentos com 1 unidade de esquadria com área de 200 m². Além disso, orçamentos com valores superiores a R\$ 500.000,00 foram considerados *outliers* e excluídos, devido à sua baixa representatividade no conjunto de dados e ao potencial impacto negativo sobre a precisão do modelo preditivo. Ao final desse processo de limpeza, foram aproveitados 961 registros, que serviram como base para o treinamento e teste dos modelos de *machine learning*.

Os dados utilizados no presente trabalho passaram por uma correção monetária com base no Índice de Preços ao Produtor (IPP), a fim de ajustar os valores dos orçamentos de esquadrias de PVC de acordo com a data em que foram realizados. Essa atualização foi essencial para garantir a comparabilidade dos registros ao longo do período analisado, que se estende de 2019 até o presente momento. Dessa forma, o impacto da inflação e das variações de preços dos insumos foi devidamente compensado, permitindo que os valores históricos fossem trazidos para uma base monetária comum, o que favorece a precisão dos modelos de *machine learning* aplicados na análise estimativa dos custos.

Esse banco de dados abrange uma grande variedade de tipos de projetos e especificações de esquadrias, oferecendo uma base rica para o treinamento de modelos de *machine learning*. A diversidade de variáveis contribui para uma análise detalhada e precisa dos fatores que influenciam os custos de esquadrias de PVC.

3.3 MODELO DE ARVORE DE DECISÃO

Para a análise estimativa de orçamentos de esquadrias de PVC, foi inicialmente utilizado o modelo de árvore de decisão fornecida pela empresa Espaço Smart. O modelo foi implementado em *Python* através do ambiente *Google Colaboratory*, utilizando bibliotecas como o *scikit-learn*, *pandas* e *numpy*. As variáveis utilizadas como entrada para o modelo, chamadas de *features*, incluem as principais características que impactam diretamente o custo das esquadrias. Entre elas estão a quantidade de esquadrias, a área total das esquadrias, o perfil da seção, a cor do PVC, a presença de persianas nos quartos, telas mosquiteiras e o tipo de vidro utilizado.

Variáveis numéricas, como a quantidade de esquadrias e a área, foram passadas diretamente para o modelo sem necessidade de transformações adicionais. Já as variáveis categóricas, como seção, cor e tipo de vidro, foram transformadas em valores numéricos binários por meio da técnica de *OneHotEncoder*. Esse processo converteu cada categoria em uma série de colunas binárias, permitindo que o modelo de árvore de decisão processasse adequadamente as variáveis. A Figura 10 demonstra as variáveis de entrada do modelo.

Figura 10 - Variáveis de entrada do modelo



Formulário de entrada de dados para o modelo, com os seguintes campos:

- Qtd Esqua...: 0
- Área (m²): 0
- Seção: ES SMART PLUS
- Cor: BRANCA
- Persianas: COM PERSIANA
- Telas: SEM TELA
- Vidros: DORM DUPLO

Fonte: Elaborado pelo Autor. (2024).

3.4 MODELO DE FLORESTA ALEATÓRIA

O segundo modelo adotado para a análise estimativa de orçamentos foi o de floresta aleatória. Esse modelo é uma evolução do conceito de árvore de decisão e consiste em um conjunto de várias árvores de decisão que, em conjunto, formam uma floresta. A principal característica desse modelo é a capacidade de aumentar a precisão das previsões ao reduzir o risco de *overfitting*, um problema comum em modelos de árvore única, onde o modelo pode se ajustar excessivamente aos dados de treinamento, comprometendo sua capacidade de generalização. Neste estudo, optou-se por utilizar 100 árvores na floresta aleatória, pois esse número foi suficiente para fornecer estabilidade e precisão nas previsões, atingindo um bom equilíbrio entre desempenho e custo computacional. Após testes iniciais, verificou-se que aumentos adicionais no número de árvores não trariam ganhos significativos em precisão, justificando a escolha.

A modificação do modelo para a floresta aleatória foi realizada de forma simples, devido à flexibilidade das bibliotecas utilizadas no projeto. O código original, que utilizava uma árvore de decisão, foi mantido quase em sua totalidade. A única mudança necessária foi a troca da biblioteca utilizada para implementar o modelo.

Inicialmente, o modelo de árvore de decisão foi importado através da classe *DecisionTreeRegressor*, da biblioteca *sklearn.tree*. Para a implementação da floresta aleatória, o código foi ajustado para utilizar a classe *RandomForestRegressor*, proveniente da biblioteca *sklearn.ensemble*.

Essa substituição permitiu que o modelo utilizasse múltiplas árvores de decisão de forma automática, sem a necessidade de alterar a lógica de pré-processamento de dados ou a estrutura das variáveis de entrada. Ou seja, todas as etapas de transformação de dados, como a codificação das variáveis categóricas e a divisão entre dados de treinamento e teste, permaneceram as mesmas. A modificação foi aplicada de maneira transparente, apenas alterando a maneira como o modelo faz as previsões, agora combinando os resultados de 100 árvores para gerar uma estimativa mais robusta e precisa.

3.5 TREINAMENTO DOS MODELOS

O conjunto de dados foi dividido em dois subconjuntos: 75% dos dados foram destinados ao treinamento do modelo, e os 25% restantes foram utilizados para testes e validação. Essa divisão foi realizada de forma aleatória e seguiu uma prática comum em *machine learning*, onde a maior parte dos dados é usada para ensinar o modelo a identificar padrões e realizar previsões, enquanto o subconjunto de teste é mantido separado para garantir uma avaliação imparcial do desempenho do modelo.

O treinamento do modelo de *machine learning* ocorre de forma totalmente automatizada, utilizando os dados históricos de orçamentos de esquadrias de PVC fornecidos. Quando o modelo acessa o banco de dados, ele inicia o processo de aprendizado, identificando as relações entre as variáveis de entrada e os custos finais dos orçamentos. Essa fase de treinamento permite que o modelo capture padrões relevantes e crie uma base sólida para realizar previsões precisas, ajustando-se às particularidades dos dados históricos.

Após o treinamento, o modelo está apto a receber novas variáveis de entrada e a gerar estimativas de maneira automática. Todo o processo, desde a leitura dos dados até a previsão dos custos e a avaliação do desempenho, é realizado internamente pela programação. Ao processar as variáveis de entrada, o modelo gera as estimativas de custos e, em seguida, compara automaticamente os valores previstos com os custos reais, utilizando como métricas principais: o Erro Médio Absoluto (MAE), o Erro Percentual Absoluto Médio (MAPE), o Erro Percentual

Absoluto Médio Ponderado (WAPE) e o coeficiente de determinação (R^2). Essas métricas são calculadas internamente, sem necessidade de intervenção manual, e os resultados são apresentados ao final, permitindo uma análise eficiente e precisa da performance do modelo em relação aos dados reais.

3.6 MÉTRICAS DE AVALIAÇÃO

A avaliação do desempenho dos modelos de *machine learning* utilizados neste estudo foi realizada por meio de quatro métricas amplamente empregadas em problemas de regressão: o Erro Absoluto Médio (MAE), o Erro Percentual Absoluto Médio (MAPE), o Erro Absoluto Ponderado (WAPE) e o Coeficiente de Determinação (R^2). A escolha dessas métricas visam garantir uma análise abrangente da precisão e da qualidade do modelo no contexto de orçamentação de esquadrias de PVC.

O MAE é uma métrica que calcula a média dos erros absolutos entre as previsões e os valores reais, sendo reconhecida por sua simplicidade e interpretação direta. De acordo com Hyndman e Koehler (2006), o MAE é particularmente eficaz em contextos em que não se deseja penalizar erros grandes de maneira exagerada, sendo mais utilizado em situações onde o impacto de cada erro tem o mesmo peso. Por ser uma métrica baseada em valores absolutos, o MAE não considera a direção do erro, mas apenas sua magnitude, o que facilita a análise de modelos de previsão de curto prazo.

O MAPE, por outro lado, expressa o erro em termos percentuais, o que facilita a comparação entre diferentes conjuntos de dados e tamanhos de amostras. Esta métrica é amplamente empregada em previsões de vendas e demanda, conforme destacado por Makridakis *et al.* (1998), por proporcionar uma visão clara do erro relativo em relação aos valores observados. No entanto, o MAPE pode apresentar limitações em casos em que há valores reais próximos de zero, resultando em erros percentuais exageradamente altos, o que pode distorcer a interpretação dos resultados.

O WAPE é uma variação do MAPE que pondera os erros em relação ao total observado, proporcionando uma visão mais equilibrada e justa do desempenho do modelo, especialmente em cenários onde os dados apresentam grande variação. Essa métrica é amplamente utilizada em situações em que os dados possuem diferentes pesos ou significâncias, ajudando a atenuar o impacto de outliers nos

resultados. Como resultado, o WAPE é especialmente útil em análises de séries temporais e em estudos onde há uma variação significativa nos dados observados.

Por fim, o coeficiente de determinação (R^2) foi adotado como uma métrica adicional para medir a qualidade do ajuste do modelo. O R^2 reflete a proporção da variabilidade dos dados que é explicada pelo modelo, sendo crucial para avaliar o quanto o modelo captura da realidade observada. Como apontado por Montgomery *et al.* (2012), valores de R^2 próximos a 1 indicam um bom ajuste do modelo, enquanto valores mais baixos sugerem a necessidade de ajustes ou melhorias no modelo.

4. RESULTADOS E DISCUSSÕES

4.1 ÁRVORE DE DECISÃO

A saída gerada pelo modelo de *machine learning* corresponde ao custo estimado do orçamento de materiais para a produção das esquadrias de PVC. A partir das variáveis de entrada, como área total das esquadrias, quantidade de peças e características específicas (como cor, tipo de vidro, presença de persianas e telas mosquiteiras), o modelo processa esses dados e fornece uma previsão do valor total do projeto. A Figura 11 demonstra o código do modelo desenvolvido.

Figura 11 - Código do modelo de *Machine Learning*

```
# Pipeline de Machine Learning
features = ['QTD_ESQUADRIAS', 'AREA', 'SECAO', 'COR', 'PERSIANAS_QUARTOS', 'TELAS_MOSQUITEI
target = 'CUSTO'

# Preparação das colunas numéricas e categóricas
preprocessor = ColumnTransformer(
    transformers=[
        ('num', 'passthrough', ['QTD_ESQUADRIAS', 'AREA']),
        ('cat', OneHotEncoder(), ['SECAO', 'COR', 'PERSIANAS_QUARTOS', 'TELAS_MOSQUITEIRAS'
    ]
)

X = df[features]
y = df[target]

# Separando os dados em treino e teste
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=0)

# Usando o modelo de Árvore de Decisão
model = Pipeline(steps=[('preprocessor', preprocessor),
                        ('regressor', DecisionTreeRegressor(random_state=42))])

# Treinando o modelo
model.fit(X_train, y_train)

# Fazendo previsões nos dados de teste
y_pred = model.predict(X_test)

# Calculando métricas
r2 = r2_score(y_test, y_pred)
mae = mean_absolute_error(y_test, y_pred)
mape = np.mean(np.abs((y_test - y_pred) / y_test)) * 100
wape = np.sum(np.abs(y_test - y_pred)) / np.sum(y_test) * 100

# Exibindo as métricas
print(f"(R²) Coeficiente de Determinação : {r2:.2f}")
print("(MAE) Erro Médio Absoluto : R$ {:.2f}".format(mae))
print("(MAPE) Erro Percentual Absoluto Médio : {:.2f}%".format(mape))
print(f"(WAPE) Erro Percentual Absoluto Médio Ponderado : {wape}%")
print(f" ")
```

Fonte: Elaborado pelo Autor. (2024).

A aplicação do modelo de árvore de decisão para a estimativa dos orçamentos de esquadrias de PVC apresentou os seguintes resultados presentes na Figura 12.

Figura 12 - Resultados do modelo árvore de decisão

```
(R²) Coeficiente de Determinação : 0.68  
(MAE) Erro Médio Absoluto : R$ 37058.78  
(MAPE) Erro Percentual Absoluto Médio : 46.78%  
(WAPE) Erro Percentual Absoluto Médio Ponderado : 35.434344932453875%
```

Fonte: Elaborado pelo Autor. (2024).

O coeficiente de determinação (R^2) foi de 0,68, indicando que 68% da variação nos custos das esquadrias de PVC foi explicada pelo modelo. Esse resultado demonstra que o modelo conseguiu capturar boa parte das variações nos dados, embora ainda existam fatores externos não considerados que impactam os custos finais. Entre os pontos não incluídos nas variáveis estão o sistema das esquadrias, como correr, fixo ou giro, já que um projeto pode abranger diversos modelos, cada um com diferentes complexidades e componentes específicos. Além disso, dentro da categoria de vidros, há variações de composições, como vidros duplos, espessuras distintas e a presença de pinázios, que influenciam diretamente no custo, mas não foram considerados no modelo. A ausência dessas variáveis limita a precisão das previsões, indicando a necessidade de um ajuste para contemplar essas influências.


No entanto, o erro médio absoluto (MAE) obtido foi de R\$ 37.058,78, o que revela uma margem significativa de erro entre os valores estimados pelo modelo e os valores reais dos orçamentos. Esse erro absoluto médio reflete o quanto, em termos monetários, as estimativas podem se distanciar do valor real, sendo um ponto de atenção na aplicação prática do modelo, especialmente em orçamentos de grande porte onde a precisão é crucial.

Adicionalmente, o modelo apresentou um erro percentual absoluto médio (MAPE) de 46,78%, o que significa que, em média, as previsões realizadas pelo modelo apresentam uma diferença percentual de cerca de 46,78% em relação aos valores reais. Esse resultado indica que o modelo de árvore de decisão, apesar de explicar parte da variabilidade dos dados, ainda possui uma margem de erro considerável em termos percentuais.

O erro percentual absoluto médio ponderado (WAPE) foi de 35,43%, o que demonstra uma melhora na previsão quando são atribuídos pesos proporcionais à

relevância de cada dado. Essa métrica ponderada oferece uma visão mais ajustada das discrepâncias do modelo, levando em consideração a importância de diferentes variáveis.

A Figura 13, a seguir, ilustra o gráfico de dispersão dos erros das estimativas em relação ao custo real dos orçamentos analisados, utilizando o modelo de árvore de decisão. Cada ponto no gráfico representa a porcentagem de erro calculada para um orçamento específico, enquanto a linha vermelha tracejada indica a tendência geral dos erros em relação ao aumento dos custos reais.



Fonte: Elaborado pelo Autor. (2024).

O gráfico de dispersão indica que o modelo de árvore de decisão apresenta uma tendência de maior erro percentual em orçamentos de menor valor, com dispersão significativa dos dados, e melhora sua precisão conforme o custo real aumenta. A linha de tendência sugere uma leve redução nos erros à medida que o valor dos orçamentos cresce, indicando que o modelo é mais confiável para projetos de maior porte. No entanto, a alta variabilidade nos menores custos aponta para a necessidade de ajustes no modelo para reduzir esses erros e melhorar a precisão em todas as faixas de valor.

4.2 FLORESTA ALEATÓRIA

Um benefício importante da floresta aleatória é sua resistência a *outliers*. Como cada árvore trabalha com diferentes amostras dos dados, a influência de valores extremos ou inconsistentes é diluída, minimizando o impacto desses valores no resultado. No contexto dos orçamentos de esquadrias de PVC, onde *outliers* como orçamentos muito elevados poderiam distorcer as previsões, o uso da floresta aleatória foi particularmente eficaz para garantir previsões mais estáveis e precisas em comparação com o modelo de árvore de decisão unitária.

A utilização do modelo de floresta aleatória para a estimativa de orçamentos de esquadrias de PVC apresentou os seguintes resultados presentes na Figura 14.

Figura 14 - Resultados do modelo floresta aleatória

```
(R²) Coeficiente de Determinação : 0.79  
(MAE) Erro Médio Absoluto : R$ 30543.33  
(MAPE) Erro Percentual Absoluto Médio : 40.87%  
(WAPE) Erro Percentual Absoluto Médio Ponderado : 29.204497184298862%
```

Fonte: Elaborado pelo Autor. (2024).


O coeficiente de determinação (R^2) obtido foi de 0,79, indicando que 79% da variação nos custos das esquadrias de PVC foi explicada pelo modelo. Este resultado demonstra que o modelo de floresta aleatória conseguiu capturar uma parcela maior da complexidade dos dados em relação à árvore de decisão, revelando-se mais eficaz para esse tipo de análise.

Em termos de erro absoluto, o modelo apresentou um erro médio absoluto (MAE) de R\$ 30.543,33, que é 17,58% menor do que o obtido com a árvore de decisão. Esse valor indica que, em média, a diferença entre os valores estimados e os valores reais dos orçamentos é menor, tornando as previsões mais precisas e reduzindo a margem de erro monetário nas estimativas.

O erro percentual absoluto médio (MAPE) foi de 40,87%, o que também representa uma melhoria em relação à árvore de decisão. Embora esse valor ainda demonstre uma diferença percentual considerável entre os valores estimados e os reais, ele sugere uma maior precisão do modelo na previsão dos custos, especialmente quando comparado ao modelo anterior. Essa redução no MAPE implica que as estimativas estão se aproximando mais dos valores reais de forma consistente.

Além disso, o erro percentual absoluto médio ponderado (WAPE) de 29,20% reforça a robustez do modelo de floresta aleatória. O WAPE, ao considerar pesos proporcionais à importância dos dados, mostra que o modelo teve um desempenho mais ajustado, minimizando as discrepâncias nas previsões ao ponderar corretamente as variáveis com maior impacto nos orçamentos.

A Figura 15, a seguir, ilustra o gráfico de dispersão dos erros percentuais das estimativas conforme os valores crescentes dos orçamentos reais para o modelo de floresta aleatória. Cada ponto verde reflete a diferença entre o valor real e o valor previsto para um orçamento específico, enquanto a linha vermelha tracejada indica a tendência geral de erro à medida que os custos aumentam.



Fonte: Elaborado pelo Autor. (2024).

A análise dos dados indica que o modelo de floresta aleatória segue uma tendência similar ao observado no modelo de árvore de decisão, com erros mais concentrados em orçamentos de menor valor e uma leve diminuição dos erros para orçamentos maiores, conforme evidenciado pela linha de tendência. Entretanto, o modelo parece apresentar uma distribuição de erros mais balanceada em relação aos valores reais, sugerindo que a floresta aleatória oferece uma performance ligeiramente mais estável e consistente em comparação com o modelo anterior.

4.3 COMPARAÇÃO DOS MODELOS

A escolha de mais de um modelo foi motivada pela necessidade de comparar diferentes abordagens e identificar qual delas oferecia melhor desempenho em termos de precisão e robustez. Cada modelo apresenta vantagens e limitações próprias, que influenciam diretamente a qualidade das previsões e a interpretação dos resultados. A Tabela 1 resume os resultados obtidos para cada modelo:

Tabela 1 - Comparação de resultados entre os métodos

Métrica	Árvore de Decisão	Floresta Aleatória
(R ²) Coeficiente de Determinação	0,68	0,79
(MAE) Erro Médio Absoluto	R\$ 37.058,78	R\$ 30.543,33
(MAPE) Erro Percentual Absoluto Médio	46,78 %	40,87 %
(WAPE) Erro Percentual Absoluto Médio Ponderado	35,43 %	29,20 %

Fonte: Elaborado pelo Autor. (2024).

Os resultados mostram que o modelo de floresta aleatória superou o de árvore de decisão em todas as métricas avaliadas. O Coeficiente de Determinação (R²), que mede a proporção da variabilidade explicada pelo modelo, foi mais alto para a floresta aleatória (0,79), indicando maior precisão na explicação das variáveis de custo. Além disso, o MAE da floresta aleatória foi consideravelmente menor, refletindo em uma menor diferença média entre os valores previstos e os valores reais. O MAPE e o WAPE, que indicam a precisão percentual dos modelos, também apontaram uma performance mais eficaz da floresta aleatória, com erros percentuais menores, o que reforça sua robustez.

Comparando os dois modelos, conforme os gráficos de dispersão apresentados, é possível observar que tanto o modelo de árvore de decisão quanto o de floresta aleatória apresentam erros percentuais mais elevados para orçamentos de menor valor, com uma leve tendência de diminuição dos erros conforme o custo real aumenta. No entanto, o modelo de floresta aleatória exibe uma distribuição de erros mais equilibrada e menos dispersa do que o modelo de árvore de decisão, especialmente em orçamentos menores. A linha de tendência no gráfico da floresta aleatória é ligeiramente mais estável, indicando que esse modelo tem um desempenho mais consistente e pode oferecer maior precisão, principalmente em faixas de custos mais amplas, quando comparado à árvore de decisão.

As equações das retas dos dois modelos indicam uma inclinação negativa de $-0,0001$, com uma leve tendência de redução do erro percentual conforme o custo real aumenta. No entanto, a principal diferença está no valor do intercepto: o modelo de floresta aleatória apresenta um intercepto maior (27,7405) em comparação ao modelo de árvore de decisão (17,8409). Esse valor mais alto sugere que o modelo de floresta aleatória tende a iniciar com um erro percentual mais elevado em relação ao modelo de árvore de decisão, o que pode indicar uma diferença na forma como cada modelo lida com a variação dos dados de custo.

4.3.1 Aplicação em orçamentos

Os resultados apresentados são comparáveis aos resultados de autores que estudaram a aplicação de IA na construção civil. Da mesma forma, Santos (2020) utilizou uma abordagem de *Machine Learning* para otimizar orçamentos de obras civis, obtendo um erro percentual absoluto médio ponderado (WAPE) de 24,357%. No presente estudo, o WAPE da Floresta Aleatória foi de 29,20%, o que demonstra uma proximidade em termos de precisão, considerando a complexidade das variáveis envolvidas.

Uma possível melhoria na precisão das previsões seria dividir os dados de treinamento em grupos com características similares, como faixas de valor ou especificações de esquadrias, e treinar diferentes modelos de machine learning para cada grupo individualmente. Essa abordagem permitiria que cada modelo fosse otimizado para um conjunto mais homogêneo de dados, reduzindo a variabilidade nos resultados e melhorando a precisão das estimativas. Com isso, seria possível minimizar os erros observados nos gráficos, especialmente em orçamentos de menor valor, onde os modelos atuais apresentam maior dispersão nos erros percentuais. A segmentação dos dados, aliada ao uso de modelos especializados, poderia resultar em previsões mais acuradas e consistentes para cada grupo de orçamentos.

A implementação do modelo de ML também trouxe benefícios no tempo de processamento, permitindo que estimativas fossem geradas em tempo real a partir de dados atualizados, uma característica fundamental para aumentar a competitividade das empresas no setor de construção civil. Como observado por Groth e Schreiber (2019), a capacidade de gerar estimativas rápidas e precisas é crucial, especialmente quando se considera a variabilidade dos custos dos insumos, como perfis de PVC e vidro. Assim, o uso de *Machine Learning* oferece uma abordagem mais eficiente em

comparação aos métodos tradicionais de orçamentação, que, segundo Gonzáles (2008), muitas vezes são limitados pela dificuldade de integrar grandes volumes de dados e prever custos com exatidão.

5. CONCLUSÕES

Com base nos resultados apresentados neste trabalho, conclui-se que a aplicação de técnicas de *machine learning* na orçamentação de esquadrias de PVC oferece um método promissor para aumentar a precisão das estimativas de custo. Os modelos testados, como a árvore de decisão e a floresta aleatória, demonstraram que, apesar de ambos apresentarem resultados promissores, o modelo de floresta aleatória superou o de árvore de decisão em termos de precisão e robustez das previsões, com um coeficiente de determinação (R^2) de 79% e menor erro absoluto médio (MAE). Embora esses resultados sejam promissores, ainda não são perfeitos e mostram que há espaço para melhorias, uma vez que são demonstrados erros consideráveis.

Além disso, a utilização do *machine learning* permite automatizar o processo de orçamentação, diminuindo o tempo de processamento e reduzindo a margem de erro humano. Isso é particularmente relevante em um setor como o de esquadrias de PVC, onde pequenos desvios nos cálculos podem resultar em significativas variações de custo. Em suma, a implementação de *machine learning* na orçamentação de esquadrias de PVC não apenas pode melhorar a precisão das estimativas, mas também oferecer uma solução inovadora para otimizar recursos e aumentar a competitividade no setor da construção civil. Isso demonstra que a adoção de tecnologias como a inteligência artificial é fundamental para acompanhar as demandas atuais de precisão e eficiência no mercado.

No entanto, algumas limitações observadas neste estudo indicam que melhorias são necessárias. A ausência de variáveis que considerem o sistema das esquadrias (como modelos de correr, fixo ou giro), bem como a falta de detalhamento sobre as especificações de vidro, como composições duplas, espessuras variadas e a presença de pinázios, limitaram o potencial dos modelos em explicar a totalidade das variações de custo. Essas variáveis adicionais poderiam reduzir o erro das estimativas, melhorando a precisão das previsões de custos.

Estudos futuros também podem focar na automatização completa da orçamentação, criando sistemas que realizem todas as etapas do processo, desde a entrada de dados até a geração de relatórios, proporcionando estimativas em tempo real e aumentando a competitividade do setor. O uso de *machine learning* pode ser ampliado para outros materiais de construção, como alumínio e madeira, permitindo

uma comparação abrangente entre diferentes materiais e seus custos. Assim, as futuras pesquisas sobre o uso de ML na construção civil têm potencial para transformar a maneira como orçamentos são gerados e geridos.

REFERÊNCIAS

ANDRADE, J. P. M. de; WERNKE, R.; RITTA, C. de O. **Análise da lucratividade em indústria de produção por encomenda: estudo de caso em pequena fábrica de esquadrias de PVC.** In: XXVI Congresso Brasileiro de Custos, 2019, Curitiba, PR. Anais [...]. Curitiba, 2019

ARIZA, V. M. P.; NASCIMENTO, M. M. do; MALANDRINO, P. P.; SANTOS, B.S. dos. Uso do algoritmo "Floresta Aleatória" na identificação do comportamento da população na busca por serviços de saúde após o início da pandemia do novo coronavírus. **AtoZ: Novas práticas em informação e conhecimento**, v. 11, p. 1-15, 2022. Disponível em: <http://dx.doi.org/10.5380/atoz.v11.84017>. Acesso em: 20 out. 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 12721: Avaliação de custos unitários de construção para incorporação imobiliária e outras disposições para condomínios edifícios.** Rio de Janeiro, 2006.

ARAÚJO, M. B.; REBOLEDO, A. Análise comparativa de orçamentos de custos: um estudo de caso. **Sinergia**, São Paulo, v. 19, n. 2, p. 106-114, jul./dez. 2018.

BARBOSA, G. N. N.; BEZERRA, G. M. G.; MEDEIROS, D. S. V.; LOPEZ, M. A.; MATTOS, D. M. F. **Segurança em Redes 5G: Oportunidades e Desafios em Detecção de Anomalias e Predição de Tráfego Baseadas em Aprendizado de Máquina.** In: XXI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg 2021). Sociedade Brasileira de Computação, 2021. p. 145-163.

BIONDI NETO, L. *et al.* **Redes neurais artificiais para estimativa de custos de construção civil.** Rio de Janeiro: VII Simpósio de Pesquisa Operacional e Logística da Marinha, 2004.

CARVALHO, M. W. M. L. de; OLIVEIRA, B. de A. S. Considerações gerais sobre a aplicação das redes neurais artificiais na engenharia civil. **Obras Civis**, n. 8, p. 30-36, jun. 2018.

CBCS - CONSELHO BRASILEIRO DE CONSTRUÇÃO SUSTENTÁVEL. **Plataforma global de sustentabilidade.** São Paulo, 2014. Disponível em: http://www.cbcs.org.br/_5dotSystem/userFiles/posicionamentos/CBCS_Posicionamentos_Plataforma%20global.pdf. Acesso em: 14 jun. 2024.

DACOREGIO, F. A. **Estimativa preliminar de custos de obras utilizando redes neurais artificiais.** 2017. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2017.

DATA CAMP. **SVM Classification with Scikit-learn – A Tutorial on Support Vector Machines in Python.** Datacamp. 2019. Disponível em: <https://www.datacamp.com/tutorial/svm-classification-scikit-learn-python>. Acesso em: 14 jun. 2024.

DILIGENTI, M. *et al.* Habitação Unifamiliar Sustentável: Projeto de Casa Laboratório. In: **Congresso Internacional de Sustentabilidade e Habitação de Interesse Social**. Porto Alegre, de 04 a 07 de maio, 2010.

FERRARESE, P. C.; AMARIO, M.; STOLZ, C. M. Estudo comparativo do desempenho acústico de esquadrias de PVC e de alumínio. **Boletim do Gerenciamento**, [S.l.], v. 44, n. 44, set. 2024. Disponível em: <https://nppg.org.br/revistas/boletimdoGerenciamento/article/view/1284>. Acesso em: 04 out. 2024.

FRIZON, N. G. Gestão de Custos – **Um Estudo de Caso em uma Empresa de Esquadrias de Alumínio e PVC na Cidade de Veranópolis/RS**. Trabalho de Conclusão de Curso (Bacharelado em Ciências Contábeis) – Universidade de Caxias do Sul, Caxias do Sul, 2022.

FREIRE, A. S. D. *et al.* **Esquadrias para a construção civil**. 2023. Trabalho de Conclusão de Curso (Técnico em Edificações) – Centro Paula Souza, Etec Itaquera II, São Paulo, 2023.

GONZÁLEZ, M. A. S. **Noções de Orçamento e Planejamento de Obras**. 2008. UNISINOS - Universidade do Vale do Rio dos Sinos, Ciências Exatas e Tecnológicas. São Leopoldo – 2008.

GROTH, D. L.; SCHREIBER, D. Estudo sobre os custos de produção das esquadrias de pvc da empresa beta. **Anais do Congresso Brasileiro de Custos - ABC**, [S. l.], Disponível em: <https://anaiscbc.emnuvens.com.br/anais/article/view/4674>. Acesso em: 03 out. 2024.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2nd ed. New York: Springer, 2009.

HAIR, J. F. *et al.* **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman Editora, 2009.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v. 22, n. 4, p. 679–688, 2006.

KOEMMERLING. 70 mm Systems - Sistema Projetante. Disponível em: <https://www.koemmerling.com/br/pt/produtos/sistema-projetante/70-mm-systems/>. Acesso em: 17 out. 2024.

LIMA, C. A. de. **Algoritmos para a paz: a disputa pela liderança da inteligência artificial entre China e Estados Unidos da América pela lente do paradigma da corrida espacial durante a Guerra Fria**. 2019. 99 f. Dissertação (Mestrado em Defesa e Segurança Civil) – Universidade Federal Fluminense, Niterói, 2019.

LIMA, W. D. de. **Computadores e mentes: uma analogia filosófica**. 2017. 99 f. Dissertação (Mestrado em Filosofia) – Universidade do Vale do Rio dos Sinos, São Leopoldo, 2017.

MAKRIDAKIS, S. *et al.* The M3-Competition: Results, conclusions, and implications. **International Journal of Forecasting**, v. 14, n. 4, p. 491-504, 1998.

MCKINSEY & COMPANY. **Global survey: the state of AI in 2020**. Disponível em: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/global-survey-the-state-of-ai-in-2020>. Acesso em: 17 out. 2024.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 5th ed. Hoboken: John Wiley & Sons, 2012.

MONTENEGRO, S. M. G. L.; GOMES, L. F. C.; VALENÇA, M. J. S. Modelo baseado na técnica de redes neurais para previsão de vazões na bacia do Rio São Francisco. **Revista Brasileira de Recursos Hídricos**, v. 15, n. 1, p. 5-15, 2010.

OLIVEIRA, T.H.G.de et al. Transformação da Engenharia Civil Através da Inteligência Artificial: Um Novo Horizonte de Inovação. **Revista Nativa**, Revista de Ciências Sociais do Norte de Mato Grosso, v. 13, n. 1, p. 3-25, mar. 2024.

PENA, A. F. dos S. **Estudo comparativo sobre o isolamento acústico entre esquadrias de alumínio e esquadrias de PVC**. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – UNIFASIPE Centro Universitário, Sinop, MT, 2020

PEREIRA, R. C. de O. **Uso de machine learning na predição do risco de movimentos de massa no município de Ouro Preto - MG**. 2024. Monografia (Graduação em Engenharia de Controle e Automação) – Universidade Federal de Ouro Preto, Escola de Minas, Ouro Preto, 2024.

PINHEIRO, A. B.; CRIVELARO, M. **Planejamento e Controle de Obras**. 8. ed. São Paulo: Érica, 2010.

SANTOS, L. M. V. dos. **Técnicas de estimativa de custo de obra: do orçamento paramétrico ao machine learning**. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade São Judas Tadeu, São Paulo, 2020.

SARACEVIC, T. Ciência da informação: origem, evolução e relações. **Perspectivas em Ciência da Informação**, [S. l.], v. 1, n. 1, 2008.

SILVA, B. S. da. **Estimativa de desembolso mensal em obras de terraplenagem com uso de rede neural artificial**. 2021. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, Campina Grande, 2021.

SILVA, L. B. da; EMILIANO, J. M. **Sistemas de esquadrias: relação custo e benefício**. 2017. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Universidade do Sul de Santa Catarina, Tubarão, 2017.

SIMÕES, G. S.; VASCONCELOS, P. A. C. de; MELO, F. T. V. **Uso do machine learning e algoritmos genéticos como recursos de tomada de decisão em gestão de recursos da construção civil**. Porto Velho: Centro Universitário São Lucas, Faculdade Porto/FGV, 2021.

TAVARES, M. C. **Gestão estratégica**. 1. ed. São Paulo: Atlas, 2009.

VALENTINI, J. **Metodologia para elaboração de orçamentos de obras civis**. 2009. Monografia (Especialização em Construção Civil) – Universidade Federal de Minas Gerais, Belo Horizonte, 2009.

VIEIRA, C. C. **Conforto térmico e iluminação natural no edifício administrativo da Escola de Engenharia de São Carlos / USP – o Bloco E1**. 2008. Dissertação (Mestrado) – Departamento de Arquitetura e Urbanismo, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2008

ZAO-SANDERS, M. **How AI can change the way your company gets work done**. Harvard Business Review, 03 jul. 2024. Disponível em: <https://hbr.org/2024/07/how-ai-can-change-the-way-your-company-gets-work-done>. Acesso em: 17 out. 2024.