



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS TRINDADE
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS

Pedro Henrique Zomer Machado

**Predição da probabilidade de contratação de serviços de calibração utilizando
modelos de aprendizado de máquina**

Florianópolis
2024

Pedro Henrique Zomer Machado

Predição da probabilidade de contratação de serviços de calibração utilizando modelos de aprendizado de máquina

Trabalho de Conclusão de Curso submetida ao Departamento de Engenharia de Produção e Sistemas da Universidade Federal de Santa Catarina para a obtenção do título de Grau de Engenheiro Mecânico com habilitação em Engenharia de Produção.

Orientador: Prof. Mauricio Uriona Maldonado, Dr.

Coorientador: Eng. Miguel Burg Demay, Dr.

Florianópolis

2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Machado, Pedro Henrique Zomer

Predição da probabilidade de contratação de serviços de calibração utilizando modelos de aprendizado de máquina / Pedro Henrique Zomer Machado ; orientador, Mauricio Uriona Maldonado, coorientador, Miguel Burg Demay, 2024.

95 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Engenharia de Produção Mecânica, Florianópolis, 2024.

Inclui referências.

1. Engenharia de Produção Mecânica. 2. Precificação dinâmica. 3. Aprendizado de máquina. 4. Metrologia. I. Maldonado, Mauricio Uriona. II. Demay, Miguel Burg. III. Universidade Federal de Santa Catarina. Graduação em Engenharia de Produção Mecânica. IV. Título.

Pedro Henrique Zomer Machado

Predição da probabilidade de contratação de serviços de calibração utilizando modelos de aprendizado de máquina

O presente trabalho em nível de bacharelado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Mauricio Uriona Maldonado, Dr.
Universidade Federal de Santa Catarina

Prof. Guilherme Ernani Vieira, Dr.
Universidade Federal de Santa Catarina

Prof. Ricardo Villarroel Dávalos, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de Grau de Engenheiro Mecânico com habilitação em Engenharia de Produção.

Prof. Monica Mendes Luna, Dra.
Coordenadora do Programa

Prof. Mauricio Uriona Maldonado, Dr.
Orientador

Florianópolis, 11 de dezembro de 2024.

Este trabalho é dedicado à minha família.

AGRADECIMENTOS

Primeiramente, gostaria de agradecer aos meus pais, Cledonir e Adriana, por todo o amor e apoio dado durante a minha vida. As dificuldades enfrentadas por vocês para que pudessem garantir o futuro de seus filhos nunca será esquecida e eu serei eternamente grato por isso. Da mesma forma, agradeço ao meu irmão, João, pelos ensinamentos e companheirismo, sua figura foi primordial para que eu continuasse seguindo em frente e vencendo os obstáculos que a vida impõe.

Expresso também minha sincera gratidão a todos os meus colegas de trabalho pelas oportunidades de aprendizado que me proporcionaram ao longo dessa jornada. Cada um de vocês, de alguma forma, contribuiu significativamente para a conclusão desse trabalho, compartilhando seus conhecimentos e experiências.

Aos meus amigos e colegas de faculdade, agradeço pelo apoio e pelas conversas que tanto me ajudaram ao longo da graduação. Cada troca de ideia, desabafo, conselho e incentivo fez toda a diferença nesse processo.

Por fim, agradeço aos professores que me acompanharam ao longo dessa jornada acadêmica, em especial ao professor Mauricio Uriona Maldonado. Suas orientações, conhecimentos compartilhados e disponibilidade foram essenciais para a realização desse trabalho e para meu amadurecimento intelectual. Cada contribuição de vocês deixou uma marca valiosa no meu aprendizado e certamente estará presente na minha vida profissional.

RESUMO

A precificação de serviços de metrologia é um desafio crucial para laboratórios que buscam otimizar seus lucros e manter a competitividade em um mercado cada vez mais acirrado. Este trabalho propõe um modelo de aprendizado de máquina para estimar a probabilidade de aceitação de orçamentos, aplicando abordagens preditivas para otimizar o processo de precificação em um laboratório de metrologia em Santa Catarina. A metodologia incluiu a coleta, análise e tratamento de dados históricos do laboratório. Em seguida, foram treinados e ajustados modelos de Regressão Logística, Support Vector Machine (SVM) e XGBoost. O modelo XGBoost, após otimização de hiperparâmetros, apresentou o melhor desempenho, com AUC de 0,7982 e acurácia de 73,76%, superando os demais modelos. A ferramenta desenvolvida permite uma precificação dinâmica, adaptada às condições de mercado e ao perfil de cada cliente, proporcionando suporte para decisões mais estratégicas. Os resultados foram avaliados em conjunto com a equipe do laboratório, visando a integração do modelo ao sistema PowerBI. Essa integração permitirá o monitoramento de indicadores chave de desempenho e a melhoria da gestão do laboratório. As limitações do estudo, relacionadas à disponibilidade de dados, apontam para a necessidade de pesquisas futuras que explorem a influência dos preços dos serviços e suas interações na percepção do cliente.

Palavras-chave: Precificação dinâmica; Aprendizado de máquina; Metrologia; Regressão logística; *Support Vector Machine*; *XGBoost*.

ABSTRACT

Pricing metrology services is a crucial challenge for laboratories aiming to optimize profits and maintain competitiveness in an increasingly demanding market. This work proposes a machine learning model to estimate the probability of quote acceptance, applying predictive approaches to optimize the pricing process within a metrology laboratory in Santa Catarina, Brazil. The methodology involved collecting, analyzing, and processing historical data from the laboratory. Logistic Regression, Support Vector Machine (SVM), and XGBoost models were trained and fine-tuned. The XGBoost model, after hyperparameter optimization, exhibited the best performance, achieving an AUC of 0.7982 and accuracy of 73.76%, surpassing the other models. The developed tool enables dynamic pricing, adapted to market conditions and individual client profiles, supporting more strategic decision-making. The results were evaluated in collaboration with the laboratory team, aiming to integrate the model into the PowerBI system. This integration will allow monitoring of key performance indicators and improve laboratory management. Limitations of the study, related to data availability, highlight the need for future research exploring the influence of service prices and their interactions on client perception.

Keywords: Dynamic pricing; Machine learning; Metrology; Logistic regression; Support Vector Machine; XGBoost.

LISTA DE FIGURAS

Figura 1 – Variação anual do volume de serviços no Brasil de acordo com a PMS	15
Figura 2 – Relação do ML com a programação tradicional	28
Figura 3 – Processo padrão intersetorial para mineração de dados (CRISP-DM)	28
Figura 4 – Validação cruzada para $k = 10$	29
Figura 5 – Separação de parâmetros do modelo e hiperparâmetros	30
Figura 6 – Exemplo de regressão logística para uma variável	31
Figura 7 – Custo de uma instância de treinamento do modelo de regressão logística	33
Figura 8 – Exemplo de problema de classificação binária e hiperplanos	34
Figura 9 – Componentes do SVM	35
Figura 10 – Estrutura de uma árvore de decisão	36
Figura 11 – Diagrama do funcionamento dos métodos <i>bagging</i> e <i>boosting</i>	39
Figura 12 – Demonstração visual da influência do limiar de decisão	43
Figura 13 – Número anual de artigos indexados no Scopus com os termos " <i>Machine Learning</i> " e " <i>ROC Curve</i> "	43
Figura 14 – Construção da curva ROC com diferentes limiares de decisão	44
Figura 15 – Curvas ROC para diferentes casos	45
Figura 16 – Procedimento metodológico adotado	51
Figura 17 – Histograma dos itens em espera e tempo médio de calibração	61
Figura 18 – Histograma dos da complexidade dos serviços e quantidade histórica de itens por orçamento	62
Figura 19 – Relação entre o primeiro pedido e probabilidade de aceitação	63
Figura 20 – Relação de probabilidade de aceitação para cliente que já recusaram um orçamento no passado	63
Figura 21 – Relação de probabilidade de aceitação para cliente que recusaram o último orçamento	64
Figura 22 – Histograma do custo das cotações	65
Figura 23 – Histograma das margens de lucro de acordo com a reposta do cliente	66
Figura 24 – Histórico de conversão de pedidos em serviços	67
Figura 25 – Séries temporais da taxa Selic, ICE e cotação do dólar por média trimestral	68
Figura 26 – Média de orçamentos a cada mês	68
Figura 27 – Representação do visual do intervalo interquartil	69
Figura 28 – Divisão proporcional do conjunto de dados em subconjuntos de treino e teste	70
Figura 29 – Dados do <i>dataset</i> normalizados e adimensionais	72
Figura 30 – Importância das variáveis pelo Valor de Shapley - Regressão logística	77

Figura 31 – Importância das variáveis pelo Valor de Shapley - <i>XGBoost</i>	77
Figura 32 – Importância das variáveis pelo Valor de Shapley - SVM	78
Figura 33 – AUC por importância acumulada	79

LISTA DE QUADROS

Quadro 1 – Matriz de confusão	41
Quadro 2 – Métricas de avaliação para modelos de classificação	41
Quadro 3 – Lista das principais bibliotecas utilizadas	50
Quadro 4 – Descrição dos tipos de tabelas presentes no servidor	56
Quadro 4 – Descrição dos tipos de tabelas presentes no servidor (conclusão) .	57
Quadro 5 – Tabelas de dados utilizadas na pesquisa	58

LISTA DE TABELAS

Tabela 1 – Resultados da otimização de hiperparâmetros para a regressão logística	73
Tabela 2 – Resultados da otimização de hiperparâmetros para o <i>XGBoost</i> . . .	73
Tabela 2 – Resultados da otimização de hiperparâmetros para o <i>XGBoost</i> (conclusão)	74
Tabela 3 – Resultados da otimização de hiperparâmetros para o SVM	74
Tabela 4 – Resumo do desempenho dos modelos	75
Tabela 5 – Área sob a curva para os modelos <i>default</i> e otimizados	76

SUMÁRIO

1	INTRODUÇÃO	14
1.1	PROBLEMA DE PESQUISA	15
1.2	OBJETIVOS	17
1.2.1	Objetivo Geral	17
1.2.2	Objetivos Específicos	17
1.3	JUSTIFICATIVA	17
1.4	ESTRUTURA DO TRABALHO	19
2	REFERENCIAL TEÓRICO	20
2.1	DEFINIÇÃO DE SERVIÇO	20
2.1.1	Serviços de metrologia	21
2.1.2	Laboratórios acreditados	22
2.2	PRECIFICAÇÃO	23
2.2.1	Estratégias de precificação tradicionais	24
2.2.2	Precificação dinâmica	25
2.3	<i>MACHINE LEARNING</i>	26
2.3.1	Validação cruzada	29
2.3.2	Otimização dos hiperparâmetros	29
2.3.3	Modelos de aprendizado de máquina	30
2.3.3.1	Regressão logística	31
2.3.3.2	<i>Support Vector Machine (SVM)</i>	33
2.3.3.3	<i>XGBoost</i>	36
2.3.4	Valor de Shapley	38
2.3.5	Métricas de avaliação do desempenho de modelos de classificação	40
2.3.5.1	Matriz de confusão	40
2.3.5.2	ROC e AUC	42
2.4	ESTUDOS PERTINENTES AO TEMA	45
3	METODOLOGIA	48
3.1	ENQUADRAMENTO METODOLÓGICO	48
3.2	MATERIAIS E MÉTODOS	49
3.3	PROCEDIMENTO METODOLÓGICO	51
3.3.1	Coleta dos dados	52
3.3.2	Análise exploratória geral	52
3.3.3	Tratamento dos dados	52
3.3.4	Divisão do conjunto de dados em subconjuntos de treino e teste	53
3.3.5	Pré-processamento das características (<i>feature engineering</i>)	53
3.3.6	Modelagem dos algoritmos de ML	54
3.3.6.1	Treinamento dos modelos	54

3.3.6.2	Otimização dos hiperparâmetros	54
3.3.6.3	Avaliação da importância das <i>features</i>	55
3.3.7	Análise dos resultados	55
4	RESULTADOS	56
4.1	COLETA DOS DADOS	56
4.2	ANÁLISE EXPLORATÓRIA GERAL	59
4.2.1	Variáveis relacionadas ao tempo	60
4.2.2	Complexidade das calibrações	61
4.2.3	Histórico dos clientes	62
4.2.4	Custo e margem de lucro	64
4.2.5	Demanda do laboratório ao longo do tempo	66
4.3	TRATAMENTO INICIAL DOS DADOS	69
4.4	SEPARAÇÃO DOS DADOS EM SUBCONJUNTOS DE TREINO E TESTE	70
4.5	PRÉ-PROCESSAMENTO DOS DADOS	70
4.6	OTIMIZAÇÃO DE HIPERPARÂMETROS	71
4.7	ANÁLISE DE RESULTADOS	74
5	CONCLUSÃO E RECOMENDAÇÕES	80
	REFERÊNCIAS	82
	APÊNDICE A – CÓDIGOS	92

1 INTRODUÇÃO

O mercado de prestação de serviços no Brasil tem se consolidado como um dos pilares da economia, representando uma parcela significativa do Produto Interno Bruto (PIB). Com a crescente urbanização e a diversificação das atividades econômicas, a demanda por serviços especializados tem aumentado consideravelmente. No segundo trimestre de 2024, o setor de serviços se encontrava 12,7% acima do nível pré-pandemia, indicando uma recuperação rápida e alcançando uma parcela de quase 70% do PIB nacional (AGÊNCIA GOV, 2024; IBGE, 2024d).

Diante deste cenário dinâmico e competitivo, as empresas prestadoras de serviços enfrentam a necessidade de modernização para se manterem representativas no mercado. A precificação de serviços, em particular, tem se tornado um desafio, visto que envolve não apenas o cálculo dos custos operacionais, mas também a capacidade de adaptar-se rapidamente às oscilações do mercado, garantindo margens de lucro adequadas para a saúde das organizações ao passo que cumprem com o requisito de satisfazer os clientes.

O setor de serviços abrange uma ampla variedade de campos e áreas, cada um com suas demandas particulares, que vão desde serviços financeiros até os setores de saúde. Essa diversidade reflete a complexidade do ambiente de serviços, onde cada segmento precisa se adaptar às exigências do mercado e manter padrões elevados de qualidade. Dentro desse vasto panorama, o mercado de serviços de calibração se destaca por sua importância em garantir a precisão dos instrumentos de medição, especialmente em indústrias que dependem de níveis rigorosos de exatidão, como a aeroespacial, a farmacêutica e a automobilística.

A precificação adequada pode ser um forte aliado na competitividade do mercado, funcionando como uma ferramenta estratégica para as empresas se destacarem em relação aos concorrentes. Ao ajustar os preços de forma inteligente, levando em consideração não apenas os custos operacionais, mas também as condições de mercado, a demanda e as expectativas dos clientes, as empresas conseguem equilibrar margens de lucro saudáveis com uma oferta atraente.

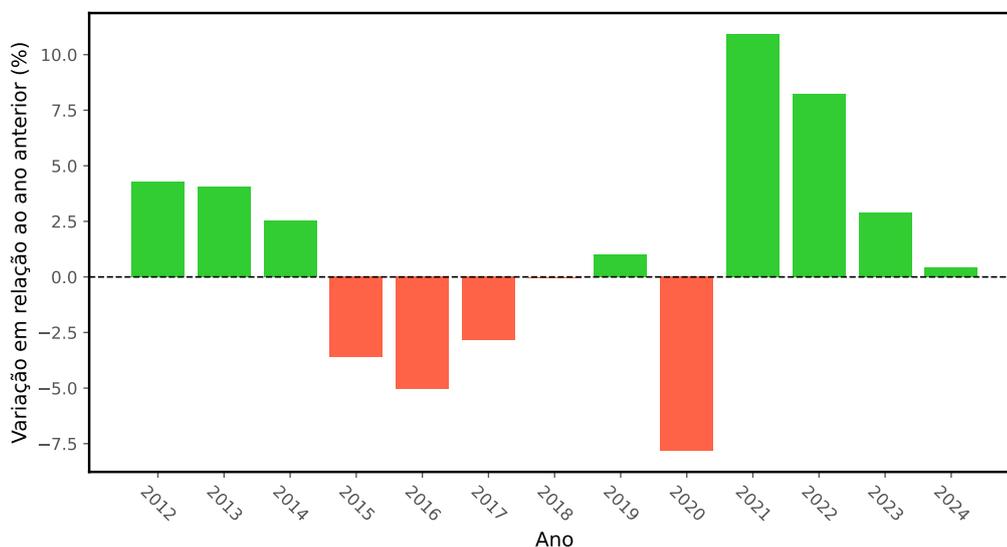
Tradicionalmente, a precificação de serviços de calibração tem seguido abordagens convencionais, onde fatores como a complexidade técnica do equipamento, a urgência do serviço e a disponibilidade de recursos são considerados de maneira estática e subjetiva. No entanto, o ambiente competitivo atual exige que as empresas respondam de forma mais precisa às flutuações de mercado enquanto levam em consideração as inúmeras variáveis internas e externas à organização. Essa multiplicidade de fatores torna a tomada de decisão extremamente complexa, muitas vezes dificultando o alcance de uma precificação que otimize tanto a competitividade quanto a lucratividade.

Nesse contexto, ferramentas computacionais surgem como uma solução promissora para lidar com a complexidade do processo de precificação dinâmica. Artefatos como o aprendizado de máquina oferecem a capacidade de analisar grandes volumes de dados históricos em tempo real, identificando padrões ocultos e inter-relações entre variáveis que seriam difíceis de capturar por meio de abordagens tradicionais.

1.1 PROBLEMA DE PESQUISA

O mercado de prestação de serviços é fundamental para a economia brasileira, representando a maior parcela do PIB nacional desde o primeiro registro do Sistema de Contas Nacionais Trimestrais (IBGE, 2024e). Sua importância vai além do impacto econômico direto, pois engloba atividades essenciais que sustentam o funcionamento de outros campos, como o comércio, a indústria e a agricultura. De acordo com o IBGE (2024b) em sua Pesquisa Mensal de Serviços (PMS), o setor de serviços tem apresentado uma recuperação gradual após a pandemia de COVID-19, acumulando sucessivos anos de crescimento e auxiliando na reconstrução econômica do país (Figura 1).

Figura 1 – Variação anual do volume de serviços no Brasil de acordo com a PMS



Fonte: Adaptado de IBGE (2024b)

Apesar de sua importância para a economia nacional, as empresas prestadoras de serviços enfrentam desafios significativos na precificação de suas atividades, uma área estratégica que impacta diretamente a competitividade e a sustentabilidade no mercado (NETTO, 2023). Além de considerar os custos operacionais e margens de lucro desejadas, é fundamental que as empresas ajustem seus preços de forma a se manterem atrativas para o cliente, evitando assim a perda de oportunidades de venda. O aumento dos preços, embora possa garantir margens de lucro mais altas, traz o

risco de afastar potenciais clientes, resultando em negociações não concretizadas (LORENZI; SOUZA, 2022).

Corroborando essa ideia, Demichurki, Kovaleski e Cruz (2014) destacam:

A precificação do serviço é uma tarefa de relevância alta, porém muitas vezes praticada sem nenhum critério, ou com um critério que é pouco relevante, abrindo espaço para possíveis prejuízos. [...] Pode-se colocar um preço elevado, acreditando que estaremos com uma boa margem de lucro, mas mesmo com um sistema eficiente de geração de lucro para a organização, isso não quer dizer que convencerá o cliente a utilizar o que lhe é ofertado ao invés de usar o que a concorrência oferece por um preço menor (DEMICHURKI; KOVALESKI; CRUZ, 2014, p. 6).

Somado a essa complexidade, Calabrese e De Francesco (2014) citam uma perspectiva errônea do mercado em avaliar a precificação de serviços sob a mesma ótica de produtos, com a extrapolação de métodos e abordagens baseados em custos materiais para uma categoria caracterizada por sua intangibilidade e presença de despesas fundamentalmente não monetárias. A diferença entre os dois setores é evidenciada também pela importância da percepção de valor no setor de serviços, onde o preço final não está necessariamente preso aos custos envolvidos durante sua execução, mas ao valor atribuído pelo cliente, destacando a necessidade de abordagens específicas para cada contexto.

Dessa forma, a complexidade do mercado de serviços exige que as empresas adotem estratégias inovadoras para se destacarem e manterem-se competitivas no cenário de atuação. Os fatores que influenciam o preço, como a complexidade técnica dos serviços, os custos operacionais e as condições de mercado, são altamente interconectadas e mutáveis, o que torna o processo de tomada de decisão cada vez mais desafiador para os gestores.

Ainda nesse contexto, a precificação tradicional, baseada em métodos guiados pelo conhecimento puramente empírico, revela-se insuficiente para lidar com o dinamismo das variáveis que impactam no desempenho econômico de uma organização. Os processos convencionais são caracterizados por sua limitação e ineficiência em providenciar uma otimização adequada, por conta de sua origem baseada em contextos e cenários de baixa complexidade, onde não havia a perspectiva, e necessidade, de explorar a capacidade computacional disponível nos tempos atuais (PETRY, 2022).

Todavia, observa-se na literatura um aumento das aplicações de métodos e abordagens mais modernas relacionadas à precificação no setor de serviços nos últimos anos, indicando uma importante mudança na perspectiva de atribuição de preços neste ramo. Apesar do volume de estudos e implementações bem-sucedidas, há uma lacuna significativa quando se trata da aplicação dessa estratégia em contextos mais específicos, como o mercado de serviços de calibração. A peculiaridade desse setor exige adaptações nas abordagens para modelagem do problema, o que ainda é pouco explorado tanto na prática quanto na academia. Diante das dificuldades e

problemas citados, este trabalho busca responder a seguinte pergunta: qual é a melhor abordagem para implementar um sistema de precificação dinâmica que maximize o lucro potencial em um laboratório prestador de serviços de metrologia?

1.2 OBJETIVOS

1.2.1 Objetivo Geral

O objetivo geral desse trabalho consiste em propor um modelo de precificação dinâmica para uma empresa prestadora de serviços de metrologia baseado na probabilidade de aceitação dos clientes para diferentes margens de lucro.

1.2.2 Objetivos Específicos

Para atender ao objetivo geral dessa pesquisa, propõem-se os seguintes objetivos específicos:

- Identificar as variáveis que influenciam na demanda de serviços de calibrações.
- Realizar análise, condicionamento e tratamento dos dados históricos do laboratório.
- Desenvolver um método de precificação dinâmica utilizando modelos de aprendizado de máquina.
- Validar o modelo computacional desenvolvido com os dados históricos da empresa.

1.3 JUSTIFICATIVA

A volatilidade de um ativo, seja ele um bem ou serviço, pode ser caracterizada pelas variações em seus preços devido a fatores relacionados tanto ao desempenho da empresa emitente, como mudanças na gestão, concorrência, custos e oferta de insumos, quanto à conjuntura econômica, incluindo inflação, taxas de juros, câmbio e fatores globais como recessão ou crescimento mundial (JUBERT *et al.*, 2008). Tal sistemática de preços se apresenta de forma complexa pois é influenciada por uma gama de fatores que interagem de maneira dinâmica e, muitas vezes, imprevisível. Mudanças repentinas no ambiente econômico, como crises financeiras, flutuações nas taxas de juros ou instabilidade política, podem gerar diferentes consequências no mercado e serem amplificadas pelo comportamento dos investidores, que muitas vezes reagem de forma emocional ou especulativa, tornando ainda mais difícil prever padrões consistentes.

Em um estudo realizado sobre a crise financeira internacional de 2008, Righi e Ceretta (2013) identificaram uma mudança das relações econômicas do Brasil com o comércio exterior. Em contrapartida do cenário global, o mercado brasileiro sofreu menos consequências com a crise, invertendo brevemente a dinâmica de transmissão de volatilidade e passando a ter maior influência sobre os preços em determinados cenários. Também pode-se citar o caso da pandemia da COVID-19, que afetou o mundo no ano de 2020. Nesse ano, a taxa de desemprego no Brasil alcançou uma marca histórica de 14,9%, junto a uma queda do PIB em 3,3%. Entretanto, devido ao isolamento social, formaram-se novos hábitos de consumo adaptados ao contexto da pandemia, resultando em um aumento de 47% no faturamento do *e-commerce* no primeiro semestre de 2020 comparado ao mesmo período do ano anterior (IBGE, 2024c,f; EBIT-NIELSEN, 2020).

Esses exemplos, embora representem eventos ocorridos em escala global, ilustram de maneira clara as complexas relações de causa e consequência que influenciam o comportamento dos mercados. Tanto a crise financeira de 2008 quanto a pandemia de COVID-19 demonstram como choques externos podem reconfigurar dinâmicas econômicas e provocar mudanças significativas específicas para cada contexto. Em ambos os casos, fatores externos desencadearam respostas rápidas nos mercados, refletindo a interconexão entre variáveis econômicas, o comportamento dos consumidores e as reações das empresas.

Diante dessa dinâmica complexa, a quantidade massiva de informações e a multiplicidade dos fatores citados anteriormente dificultam a identificação manual de padrões relevantes. Dessa forma, o uso de ferramentas computacionais avançadas torna-se indispensável. Essas tecnologias permitem identificar correlações ocultas e tendências que não seriam perceptíveis por meios tradicionais, oferecendo aos gestores uma visão mais abrangente. Nesse contexto, Jordan e Mitchell (2015) citam uma relação direta entre a crescente proeminência de dados em larga escala com o surgimento de novos algoritmos de aprendizado de máquina. Da mesma forma, Zhou (2021) destaca o avanço nos processos de aquisição, armazenamento, transmissão e processamento de dados nas últimas duas décadas, enfatizando a urgente necessidade de métodos que utilizem tais dados de maneira eficiente e eficaz.

A integração de algoritmos de aprendizado de máquina apresenta-se como uma solução promissora para enfrentar esses desafios. Ao permitir a análise de grandes volumes de dados e a identificação de padrões que influenciam a precificação, esses algoritmos possibilitam a criação de modelos dinâmicos que ajustam os preços de maneira mais ágil, precisa e com maior padronização. O emprego desses modelos de precificação são uma prática amplamente explorada por grandes empresas, especialmente em setores como varejo, onde a volatilidade da demanda e a elasticidade de preços são determinantes para a maximização dos lucros. Em um estudo sobre os

preços praticados pelas gigantes do varejo internacional, a empresa Profitero (2013) revelou que o comércio online da Amazon implementou uma média de 2,5 milhões de mudanças de preços nos seus produtos por dia em 2013. Em 2022, esse número foi alavancado para 250 milhões, segundo pesquisas da Omnia Retail (2022).

Ainda, a literatura acadêmica sobre o tema é extensa, abordando diversos modelos e estratégias para precificação dinâmica nos mais variados setores. Esses estudos fornecem uma base sólida de conhecimento, cujas perspectivas servem de aprendizado para o contexto deste trabalho. Portanto, essa pesquisa busca não apenas fornecer uma ferramenta computacional que auxilie a empresa nas suas tomadas de decisão, mas também seguir a tendência tecnológica do mercado e contribuir para o preenchimento da lacuna sobre essa área de conhecimento no setor onde a empresa está inserida.

1.4 ESTRUTURA DO TRABALHO

O trabalho é estrutura em cinco capítulos. O primeiro capítulo tem como objetivo fornecer uma contextualização sobre o tema, evidenciando os problemas que motivaram da pesquisa. Também são apresentados os objetivos e justificativa para a execução do trabalho.

O segundo capítulo é composto por uma revisão de todos os conceitos teóricos que compreendem a temática da pesquisa, desde o conceito de serviços até a os métodos de aprendizado de máquina utilizados.

Em seguida, o terceiro capítulo determina as metodologias utilizadas para o desenvolvimento do trabalho, demonstrando em uma sequência lógica de etapas os métodos, meios e ferramentas necessárias para a realização do estudo, assim como as premissas adotadas e decisões tomadas.

No quarto capítulo, são apresentados os resultados de cada etapa proposta no capítulo de metodologia do trabalho, comparando as saídas com as hipóteses iniciais e avaliando o desempenho dos modelos utilizados frente aos dados históricos da empresa.

Por fim, o quinto capítulo discorre de forma ampla o trabalho como um todo, relacionando os resultados com os objetivos delineados inicialmente, comparando a pesquisa com casos semelhantes da literatura e propondo discussões para trabalhos futuros baseado nas limitações atuais.

2 REFERENCIAL TEÓRICO

O referencial teórico serve como um meio de estabelecer a fundamentação conceitual necessária para embasar uma pesquisa. Neste capítulo, são discutidas as principais teorias, conceitos e estudos presentes na literatura que possuem relevância com o tema abordado, buscando inserir este trabalho no contexto acadêmico existente, ou seja, relacioná-lo ao estado da arte. A construção do referencial tem como objetivo demonstrar o domínio sobre o contexto do campo de conhecimento, além de justificar as escolhas metodológicas e a abordagem adotada, garantindo que o desenvolvimento da pesquisa esteja solidamente sustentado em bases teóricas consistentes.

2.1 DEFINIÇÃO DE SERVIÇO

Em uma reflexão sobre os fatores que contribuem na geração de riqueza para as nações, Smith (1776) caracterizou o serviço como um trabalho consumido no momento em que é realizado, sem deixar um objeto permanente que possa ser vendido ou usado posteriormente. Pesando a economia sob uma perspectiva de valor associado a bens físicos, Smith avalia esse tipo de atividade como um esforço improdutivo, baseado na ideia de que sua realização não gera um valor tangível e duradouro.

Ao longo do tempo, a visão sobre o serviço como uma atividade que não gera valor econômico começou a ser revista, especialmente com o avanço da sociedade pós-industrial. A ideia do serviço como um alicerce do desenvolvimento econômico foi consolidada com os trabalhos de Fisher (1935), Clark (1940) e Fourastié (1949) ao delinearem um modelo que divide as atividades econômicas em três setores:

- a) Setor primário: extração de matérias-primas;
- b) Setor secundário: transformação de matéria-prima em produtos;
- c) Setor terciário: prestação de serviços.

Esse modelo trouxe uma mudança na percepção da importância da prestação de serviços. A visão da economia clássica, onde o foco estava voltado para os setores primário (agricultura, extração de recursos) e secundário (indústria e manufatura), cedeu espaço para uma abordagem que reconhece a crescente complexidade das sociedades modernas e destaca o valor dos serviços como um elemento-chave para a geração de riqueza.

Ainda, a revolução digital, com o constante desenvolvimento de tecnologias voltadas para a demanda sob medida, impactou diretamente no setor de serviços e sua participação na economia de países desenvolvidos nas últimas décadas. A mudança de perspectiva teve como consequência uma onda crescente de empresas que passaram a se caracterizar como prestadoras de serviço em vez de enfatizar seus

bens físicos produzidos. Tal mudança também se refletiu no aumento de estudos e pesquisas com foco no serviço para todos os campos de negócios (SCHWAB, 2017; HUANG; RUST, 2018; VARGO; LUSCH, 2018).

Levando em conta esse desenvolvimento tecnológico e econômico, Zeithaml, Bitner e Gremler (2023) definem a prestação de serviços nos tempos atuais como "ações, processos e desempenhos fornecidos, coproduzidos ou cocriados por uma entidade ou pessoa para e/ou com outra entidade ou pessoa". A ênfase em coprodução citada pelos autores explicita as relações modernas de participação dos clientes, onde a percepção de geração de valor para os serviços contratados é influenciada por todas as partes envolvidas no processo.

A questão da interdependência nas relações modernas de serviço se reflete na metrologia também em um contexto de compartilhamento de risco. Quando ocorrem erros, sejam eles relacionados à conformidade de um produto ou à precisão de uma medição, os impactos são distribuídos entre as partes. O cliente, que participa da tradução da sua demanda em serviço, também acaba absorvendo as consequências de decisões erradas, mesmo que o risco inicial esteja no fornecedor (LAZZARI *et al.*, 2017).

2.1.1 Serviços de metrologia

Os serviços de metrologia, ou calibrações, podem ser caracterizados como processos que envolvem o estudo das medições realizadas por um instrumento ou máquina, comparando-as com padrões de referência conhecidos e confiáveis. O objetivo de sua realização consiste em verificar quaisquer desvios ou imprecisões nos resultados obtidos por um equipamento e determinar o erro associado às suas medições, a fim de assegurar a sua qualidade e condições de operação.

Os desvios provenientes da comparação entre medições e seus referenciais são compostos por propriedades denominadas erro e incerteza, podendo ser classificadas como aleatórias ou sistemáticas. O erro está associado à diferença entre o valor real de um parâmetro e o valor obtido durante a sua medição, enquanto a incerteza estima os limites nos quais se espera encontrar esse erro (DIECK, 2017).

Quanto à sua classificação, a componente aleatória de um desvio possui essa designação por afetar os dados de forma imprevisível de uma medição para outra, causando dispersão nos resultados. Em contrapartida, a componente sistemática do desvio possui como característica a consistência, ocorrendo da mesma forma em todas as medições e, portanto, sem causar dispersão nos resultados (DIECK, 2017).

Dentre as causas de erros sistemáticos em medições, Donatelli e Konrath (2005) destacam as falhas no cumprimento das condições normais exigidas para sua realização, como o mau funcionamento do sistema de medição, a exposição do sistema a condições ambientais inadequadas e a influência involuntária do operador responsável

pela calibração no método de realização da mesma.

De forma geral, pode-se caracterizar um serviço de metrologia utilizando a definição proposta no Vocabulário Internacional de Metrologia (VIM), onde a calibração de máquinas, equipamentos e dispositivos é um processo descrito como:

Operação que estabelece, sob condições especificadas, numa primeira etapa, uma relação entre os valores e as incertezas de medição fornecidos por padrões e as indicações correspondentes com as incertezas associadas; numa segunda etapa, utiliza esta informação para estabelecer uma relação visando a obtenção dum resultado de medição a partir duma indicação (VIM, 2012, p. 27).

Para garantir essa confiabilidade, a metrologia busca fundamentar suas capacidades em uma característica denominada de rastreabilidade, sendo definida como uma “[...] propriedade dum resultado de medição pela qual tal resultado pode ser relacionado a uma referência através duma cadeia ininterrupta e documentada de calibrações, cada uma contribuindo para a incerteza de medição” (VIM, 2012, p. 28). Dessa forma, há um compromisso com o grau de confiança das medições realizadas, pois essa propriedade assegura que os resultados obtidos estejam sempre relacionados a padrões aceitos internacionalmente.

2.1.2 Laboratórios acreditados

Em mercados competitivos, especialmente no setor de serviços, onde não há um produto físico, a diferenciação entre empresas depende da capacidade de construir e manter relacionamentos com os clientes. Nesse contexto, além da qualidade do serviço em si, as empresas precisam oferecer um conjunto de benefícios adicionais, muitas vezes intangíveis, que reforçam a confiança e a fidelidade dos clientes (DOMINIC *et al.*, 2010).

No cenário da metrologia, uma das formas de agregar valor para o cliente é pela acreditação da empresa em normas de qualidade reconhecidas internacionalmente. De forma geral, o Inmetro (2024a) aborda o conceito de acreditação definindo-o como “[...] o reconhecimento formal da competência dos Organismos de Avaliação da Conformidade (OAC) para atenderem requisitos previamente definidos e realizar suas atividades com confiança”.

A obtenção do título de acreditação reflete a responsabilidade inerente de uma instituição perante os rigorosos requisitos normativos. Esse reconhecimento eleva ainda mais a reputação de um laboratório, destacando sua capacidade de realizar suas atividades com excelência técnica e imparcialidade. Grochau, Caten e Camargo Forte (2018) evidenciam em suas pesquisas os benefícios encontrados pelas empresas em seus processos de acreditação, destacando fatores como o aumento da credibilidade de seus resultados para as partes externas, consequentemente ampli-

ando a sua visibilidade, o incremento no faturamento e a elevação do nível satisfação dos clientes.

Dentre os possíveis padrões de verificação da qualidade na metrologia, destaca-se a norma ABNT NBR ISO/IEC 17025:2017, que determina os requisitos gerais para a competência de laboratórios de ensaio e calibração, sendo responsável pela acreditação de 526 laboratórios no Brasil atualmente (INMETRO, 2024b). Esse documento tem por objetivo guiar as atividades de um laboratório de forma a evidenciar a sua capacidade em operar um sistema de qualidade e a sua competência técnica para a realização de serviços de calibração e ensaio (SILVA; CAMPOS, 2001).

2.2 PRECIFICAÇÃO

O termo "preço" pode ser descrito de forma simples como o número de unidades monetárias necessárias para um consumidor adquirir uma unidade de um produto ou serviço (SIMON; FASSNACHT, 2019). De forma complementar a essa definição, o preço pode ser encarado como um fator que estabelece a relação de valor percebido pelas partes envolvidas em seu contexto, sendo esse valor caracterizado pela forma como molda a disposição de um cliente em sua aquisição. Nagle e Müller (2023) classificam o valor econômico em duas categorias:

- a) Monetário: refere-se à economia em custos ou aumento de receitas de um cliente como resultado da aquisição de um produto ou serviço;
- b) Psicológico: refere-se às formas como a aquisição de um produto ou serviço gera satisfação e prazer para um cliente.

Em muitas situações, as duas propriedades se mostram como componentes constituintes do valor de um mesmo produto, dificultando a interpretação da importância isolada de cada uma (NAGLE; MÜLLER, 2023). Essa relação denota a complexidade em realizar uma precificação que alinhe as características de um produto e às expectativas dos clientes. Ainda, Zeithaml, Bitner e Gremler (2023) destacam a intangibilidade de um serviço como um fator que amplifica essa complexidade, pois faz com que sua essência e benefícios sejam de difícil comunicação para os clientes.

Dessa forma, estratégias de precificação são fundamentais para as organizações lidarem com a complexidade do mercado. Hinterhuber e Liozu (2014) destacam o comportamento ultrapassado das empresas em encararem a precificação como uma relação antagonística com o cliente, onde uma parte ganha e outra perde, como um ciclo vicioso a ser quebrado. Nas relações atuais de negócio, estratégias de precificação eficazes são aquelas que ajudam a fortalecer as relações com os clientes e atingir as metas financeiras da empresa (GAO, 2023).

Para Lorenzi e Souza (2022), a precificação deve ser vista como uma prática estratégica que considera o grau de risco que a empresa está disposta a assumir. Dessa forma, a precificação deixa de ser apenas uma definição de valor e passa a integrar o planejamento de riscos, permitindo que a empresa alinhe suas metas financeiras com o nível de incerteza e o retorno esperado em suas operações. De forma análoga, Demichurki, Kovalski e Cruz (2014) e Netto (2023) destacam a importância do levantamento das despesas de uma empresa para que seja estabelecida uma metodologia de precificação de serviços adaptável e eficiente.

Por outro lado, Petry (2022) descreve a precificação como uma estratégia que concilia os conceitos de demanda e oferta, como uma forma de controlar a relação entre as necessidades do consumidor e os serviços oferecidos pela empresa. Dessa forma, a precificação serve como um nível, ajustando seu valor dinamicamente para acompanhar as variações no comportamento dos clientes, seja por tendências, fatores sazonais e até mesmo eventos aleatórios adversos.

2.2.1 Estratégias de precificação tradicionais

A estratégia de precificação consiste no conjunto de diretrizes e ações que uma empresa adota para definir o preço de seus produtos e serviços. Pode-se dizer, ainda, que a precificação é a definição de um método para utilizar os recursos de uma organização de forma a alcançar seu cenário de sobrevivência com maior lucro a longo prazo, pois possui impacto absoluto no equilíbrio financeiro, determinando a sua capacidade de reinvestimento (SAMMUT-BONNICI; CHANNON, 2015; SIMON; FASSNACHT, 2019).

Em um estudo sobre as práticas de precificação de novos produtos, Ingenbleek, Frambach e Verhallen (2013) identificaram as especificidades dos cenários quanto a implementação de diferentes métodos, demonstrando a importância da avaliação dos gestores quanto as circunstâncias que permeiam o contexto de sua organização. Ainda, os autores citam como a aplicação errônea de um método de precificação pode anular vantagens inerentes aos produtos lançados.

Zeithaml, Bitner e Gremler (2023) classificam as estratégias de precificação de produtos e serviços a partir de três abordagens, sendo elas:

- a) Precificação baseada em custos: nesse método, as empresas determinam os custos de matéria-prima, mão de obra e outras fontes associadas ao produto e adicionam uma margem de lucro sobre esse valor (LORENZI; SOUZA, 2022);
- b) Precificação baseada na concorrência: é uma abordagem que tem seu foco voltado para os preços praticados por outras empresas com produtos ou serviços similares. Dessa forma, os preços presentes no mercado se apresentam como um padrão de referência que guia a precificação;

- c) Precificação com base na demanda: diferente dos outros métodos, essa estratégia leva em consideração a percepção de valor do cliente, onde os preços são definidos de acordo com o que os consumidores pagariam por um produto ou serviço. Essa abordagem se assemelha a propriedade de valor psicológico descrita por Nagle e Müller (2023).

Em um estudo sobre a relação entre a precificação e o *marketing*, Gao (2023) destaca a importância da adequabilidade de um método quanto ao contexto de uma organização, pois as consequências de uma escolha incorreta podem prejudicar sua reputação e, conseqüentemente, seu desempenho. Portanto, a escolha de uma prática de precificação adequada deve levar em consideração fatores como o produto ou serviço a ser oferecido, o mercado alvo, os concorrentes e os objetivos da empresa.

2.2.2 Precificação dinâmica

A precificação dinâmica é uma abordagem estratégica que tem como princípio de funcionamento a flexibilização de preços de um produto ou serviço, em tempo real, a partir da análise de fatores internos e externos ao contexto da negociação, com o objetivo de maximizar o lucro obtido por uma empresa (POLÁČEK *et al.*, 2024). Dentre os fatores que influenciam essa abordagem, destacam-se os preços praticados por concorrentes, as dinâmicas de oferta e demanda, taxa de conversão de vendas, histórico e comportamento do cliente (SARKAR *et al.*, 2023; GAZI *et al.*, 2024).

No cenário atual de desenvolvimento tecnológico e conseqüente aumento das tomadas de decisão baseada em dados, a precificação dinâmica tem sido empregada com o uso de algoritmos e ferramentas de análise de dados de forma a simplificar a complexa relação entre os fatores que influenciam os preços de um produto ou serviço (KOPALLE *et al.*, 2023; VICTOR *et al.*, 2018). Diante desse contexto, Subbarayudu *et al.* (2023) destacam as vantagens de utilizar modelos de aprendizado de máquina, pois possuem uma maior capacidade em lidar com grandes volumes de dados e identificar padrões de difícil visualização para as pessoas.

Em seu livro sobre gerenciamento de receitas, Klein e Steinhardt (2008) abordam a precificação dinâmica identificando-a a partir de três propriedades inerentes a sua essência:

1. A precificação dinâmica não deve adotar uma diferenciação explícita de preços orientada pelos segmentos de atuação do cliente, ou seja, o momento deve ser o único fator a influenciar o preço de um produto ou serviço;
2. Um produto e serviço não devem ter seu preço fixado previamente, podendo ter variações positivas e negativas ao longo do tempo;

3. Em vez de oferecer combinações de preço e qualidade predeterminadas, as empresas devem apresentar os serviços ou produtos com preços atualizados, e os clientes têm a opção de aceitar ou não o preço proposto.

A primeira propriedade levanta muitas discussões quanto ao limite entre a diferenciação e discriminação dos clientes, sendo considerado um tópico sensível em geral. Com o crescente uso da internet e disponibilidade de informações sobre os consumidores, as oportunidades de realizar essa discriminação aumentam consideravelmente, assim como a tentação das empresas em adotarem tais estratégias em suas políticas de precificação a fim de maximizar seu lucro (SIMON, 2015). Dessa forma, faz-se necessário monitorar e realizar avaliações rigorosas dos algoritmos de precificação dinâmica continuamente, no intuito de garantir que seu julgamento seja justo e imparcial (GAZI *et al.*, 2024).

Por conta desse fator de diferenciação, os consumidores tendem a ver a precificação dinâmica de forma negativa. Entretanto, Neubert (2022) destaca como os efeitos colaterais de seu uso podem ser contornado a partir da adoção de estratégias de comunicação com o cliente por parte das empresas. Políticas como a transparência sobre a precificação não só aumentam a intenção de compra dos clientes, como também alteram a sua percepção sobre valor do produto ou serviço e os torna mais propensos a aceitarem preços maiores (HANNA; LEMON; SMITH, 2019; BOOM *et al.*, 2020).

2.3 MACHINE LEARNING

O *machine learning* (ML), ou aprendizado de máquina, é uma abordagem que visa melhorar o desempenho de sistemas por meio do aprendizado baseado em dados, utilizando métodos computacionais. Nessa perspectiva, os dados funcionam como a base da experiência, e seu objetivo central é desenvolver algoritmos capazes de construir modelos a partir dessas informações. Uma vez treinados com esses dados, esses algoritmos produzem modelos que permitem realizar previsões sobre novas informações ou situações futuras (ZHOU, 2021). Nesse sentido, o ML tem se destacado pela forma como seus algoritmos possuem a capacidade de realizar tarefas importantes e complexas a partir da generalização de exemplos, diante de premissas e interpretações adequadas para seu contexto de aplicação (DOMINGOS, 2012).

Nos últimos anos, modelos de ML tem sido amplamente aplicados em diversos setores, oferecendo soluções automatizadas para problemas complexos. Exemplos incluem a classificação de imagens em linhas de produção, detecção de tumores em exames médicos, previsão de receita empresarial, detecção de fraudes financeiras, recomendação de produtos personalizados e criação de assistentes virtuais, como *chatbots* (GÉRON, 2022).

Entretanto, existem especificidades nesses modelos que são inerentes à natureza da sua aplicação e devem ser levadas em consideração ao serem empregados na prática. De forma a diferenciar essas características, Kelleher, Mac Namee e D'arcy (2020) avaliam os algoritmos de ML a partir da forma como eles interagem com os dados e o tipo de resposta recebida durante o treinamento, classificando-os em três grandes grupos:

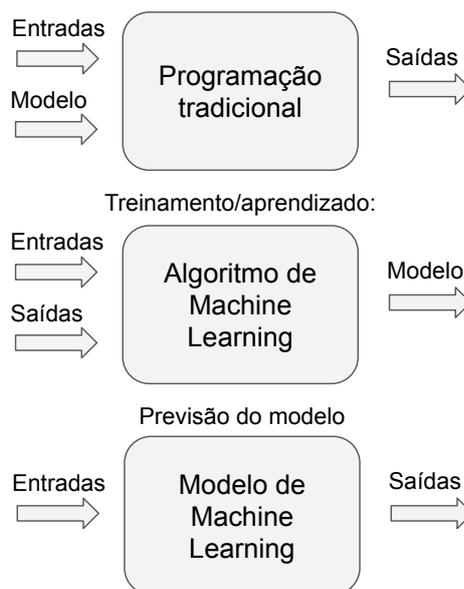
- a) Aprendizagem supervisionada: são os algoritmos que utilizam uma base histórica de recursos descritivos e uma variável alvo para estabelecer um modelo de relação entre eles;
- b) Aprendizagem não supervisionada: são algoritmos que modelam uma estrutura dentro de um conjunto de dados, sendo tipicamente utilizados para gerar novos recursos e aumentar esse conjunto;
- c) Aprendizagem por reforço: são algoritmos onde existe a predileção por um determinado resultado. Para isso, utilizam um esquema de recompensas para as mudanças de estado que possibilitem a maximização da saída desejada.

A Figura 2, adaptada de Natras e Schmidt (2021), demonstra uma comparação dos algoritmos supervisionados de ML em relação a programação tradicional a partir da sua visualização em diagramas de entradas, processos e saídas. Para a programação tradicional, as saídas são o resultado da utilização de dados de entrada e regras de operação propostas pelo usuário. Em contrapartida, um algoritmo de ML inverte a relação tradicional ao analisar as entradas e saídas de um modelo desconhecido, para então propor um conjunto de diretrizes que transformem essas entradas em saídas da forma mais precisa possível. Uma vez determinado o modelo de ML, novas informações de entrada podem ser fornecidas a fim de projetar as possíveis saídas em cenários desejados.

Para Kelleher, Mac Namee e D'arcy (2020), as etapas de um projeto de análise preditiva de dados podem ser baseadas no padrão metodológico proposto por Wirth e Hipp (2000) para a área de mineração de dados (Figura 3). Essa metodologia apresenta seis passos:

1. Compreender o problema organizacional, ou comercial, que está sendo abordado;
2. Entender as diversas fontes de dados disponíveis referentes à organização e seu contexto;
3. Preparar os dados para um formato que esteja de acordo com as entradas dos modelos de ML;

Figura 2 – Relação do ML com a programação tradicional



Fonte: Adaptado de Natras e Schmidt (2021)

4. Utilizar diferentes modelos de ML para treinar os dados;
5. Avaliar os resultados dos modelos de ML quanto a sua acurácia e adequabilidade ao propósito final;
6. Implementar o melhor modelo encontrado nos processos da organização.

Figura 3 – Processo padrão intersetorial para mineração de dados (CRISP-DM)



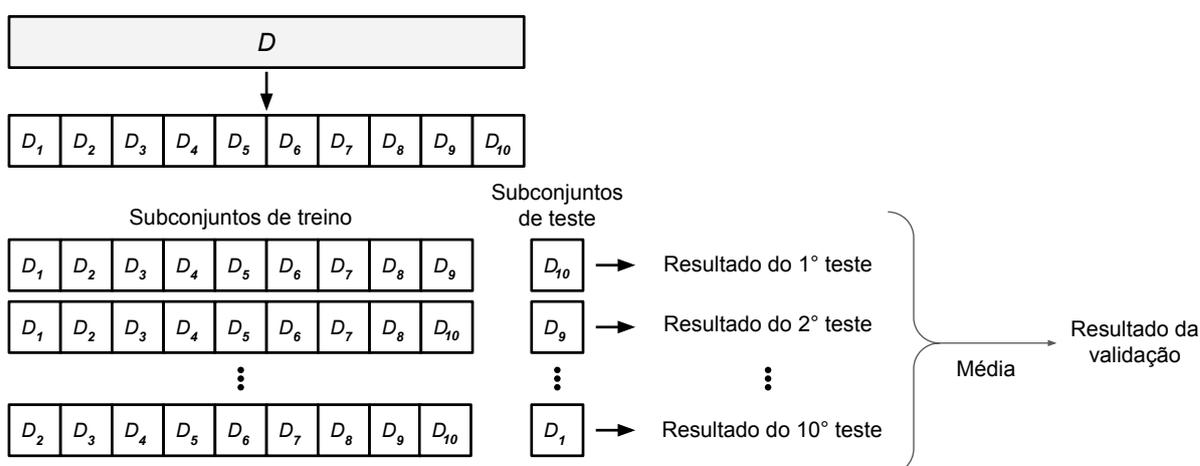
Fonte: Adaptado de Wirth e Hipp (2000)

2.3.1 Validação cruzada

A validação cruzada é um método de amostragem para treinamento de modelos de ML que tem como objetivo fazer uma melhor utilização do conjunto de dados disponível, a fim de evitar que a precisão de um modelo seja um resultado do acaso (KELLEHER; MAC NAMEE; D'ARCY, 2020). Para gerar uma validação cruzada, são feitas diversas iterações de treinamento do modelo, com o objetivo de avaliar a influência dos dados selecionados em sua performance (GÉRON, 2022).

Neste método, um conjunto de dados D é separado em k subconjuntos, de mesmo tamanho, representativos do conjunto inicial, tal que a combinação de todos os subconjuntos k resultem novamente em D . Após a divisão, $k - 1$ subconjuntos são utilizados para treinar o modelo de ML, enquanto o subconjunto remanescente serve como uma referência de teste para o modelo. O método é repetido k vezes, alterando o subconjunto de teste a cada iteração, e a métrica de avaliação final do modelo se torna a média da performance dos k modelos de ML gerados (ZHOU, 2021). Uma ilustração do método pode ser observada na Figura 4.

Figura 4 – Validação cruzada para $k = 10$



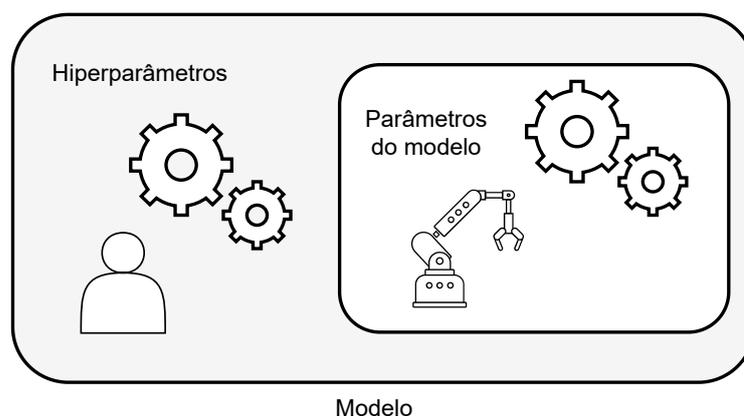
Fonte: Adaptado de Zhou (2021)

2.3.2 Otimização dos hiperparâmetros

A construção de modelos de ML eficazes envolve tanto a escolha adequada do algoritmo quanto a definição precisa de seus hiperparâmetros, cuja configuração pode impactar significativamente o seu desempenho. Estando presente na maior parte dos algoritmos de aprendizagem, esses hiperparâmetros precisam ser definidos antes do início de um treinamento de modelo e permanecem inalterados durante todo o processo de treinamento (ZHOU, 2021; GÉRON, 2022).

De forma geral, Agrawal (2021) divide as variáveis dos algoritmos de ML em duas categorias: parâmetros e hiperparâmetros. Os parâmetros são as configurações do algoritmo ajustadas de acordo com os dados fornecidos para treino, não havendo interação do usuário em sua definição. Por outro lado, os hiperparâmetros são parâmetros de nível superior escolhidos pelo usuário antes do treino, influenciando diretamente a capacidade de aprendizado do algoritmo. A relação de influência e interação entre usuário e modelo quanto as suas variáveis está ilustrado na Figura 5.

Figura 5 – Separação de parâmetros do modelo e hiperparâmetros



Fonte: Adaptado de Agrawal (2021)

Segundo Lavesson e Davidsson (2006), a otimização dos hiperparâmetros pode ter um impacto maior na performance do modelo final do que a própria escolha do algoritmo de ML. No entanto, encontrar a configuração ideal de um conjunto de hiperparâmetros pode exigir um custo computacional significativo. Nesse sentido, Zhou (2021) ressalta a escalabilidade das potenciais combinações de hiperparâmetros para algoritmos de aprendizado avançados como um obstáculo desafiador, fazendo com que a melhor escolha muitas vezes não seja a ideal, mas àquela factível de ser alcançada.

Diante desse contexto, o método *grid search* surge como uma alternativa para a escolha de hiperparâmetros, pois realiza os testes de forma otimizada e automatizada. Esse método consiste em utilizar um pequeno conjunto de dados para cada hiperparâmetro e testar a performance do modelo para cada possível combinação desses conjuntos. Ainda, o processo pode ser aprimorado ajustando os conjuntos de entrada com valores mais próximos ao ponto ótimo identificado na iteração anterior (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.3.3 Modelos de aprendizado de máquina

Os modelos de ML podem ser classificados em diferentes categorias, dependendo de suas abordagens e objetivos. Entre os diversos tipos de modelos disponíveis,

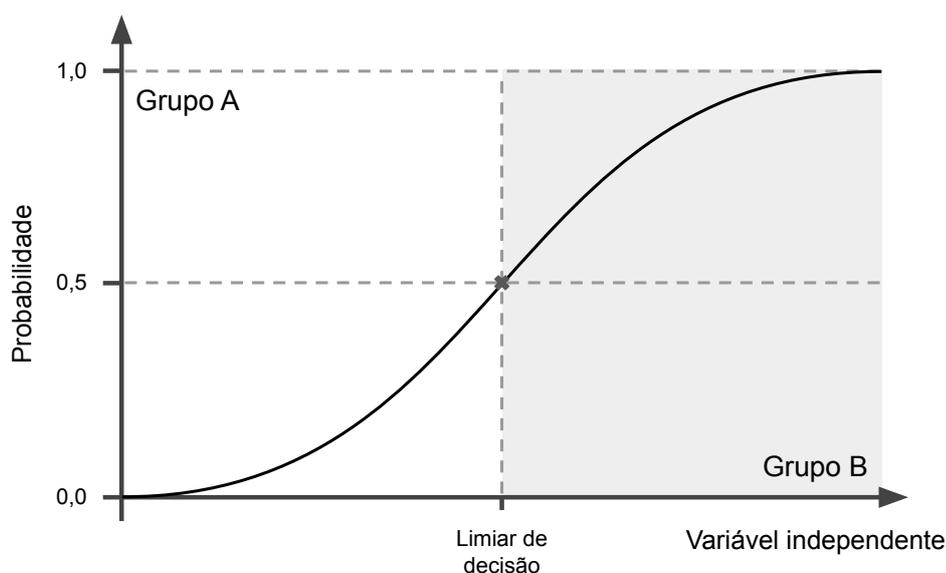
destacam-se os modelos lineares, como a regressão linear e logística, os modelos baseados em árvores de decisão, como o *Random Forest* e o *XGBoost*, e os modelos de aprendizagem profunda, como as redes neurais artificiais. Ainda, é possível treinar modelos de ML com abordagens baseadas em uma visualização geométrica do problema, onde há uma diferenciação espacial dos grupos a serem classificados, como o *Linear Discriminant Analysis* e o *Support Vector Machine* (ZHOU, 2021; RASCHKA; LIU; MIRJALILI, 2022)

Neste estudo, foram selecionados três modelos com abordagens distintas: a regressão logística, o *XGBoost* e o *Support Vector Machine* (SVM). A escolha foi fundamentada na diversidade de suas estratégias de aprendizado e na relevância de suas aplicações para o problema analisado.

2.3.3.1 Regressão logística

A regressão logística é um método de aprendizado de máquina supervisionado usado para classificações. Seu funcionamento baseia-se na modelagem da relação entre uma ou mais variáveis independentes e uma variável dependente categórica, geralmente binária. A ideia por trás deste modelo consiste em utilizar uma função logística para definir um espectro de valores contínuos em uma probabilidade entre 0 e 1 (Figura 6). Essa probabilidade pode então ser convertida de volta para o conceito de classificação a partir de um limiar de decisão, comumente definido em 50%, que divide o espectro novamente em dois grupos (GÉRON, 2022).

Figura 6 – Exemplo de regressão logística para uma variável



Fonte: Autor (2024)

Esse método é amplamente utilizado para modelar a probabilidade de uma amostra pertencer a um determinado grupo ou classe, destacando-se pela flexibilidade

em relação às premissas dos dados. Ao contrário de outros métodos, a regressão logística não exige que a distribuição dos dados siga padrões específicos, o que amplia suas possibilidades de aplicação em diferentes contextos. Ainda, essa abordagem se destaca pela capacidade de fornecer uma estimativa probabilística, e não apenas um rótulo fixo, permitindo que as decisões sejam tomadas com base em graus de confiabilidade (ZHOU, 2021).

Hagenaars, Kühnel e Andress (2024) generalizam a regressão logística como um modelo não-linear, onde as estimativas probabilísticas são encontradas conforme a formulação apresentada na Equação 1.

$$Pr(Y_i = 1|X_{1i}, \dots, X_{Ki}) = \frac{\exp(\beta_0 + \sum_{k=1}^K \beta_k X_{ki})}{1 + \exp(\beta_0 + \sum_{k=1}^K \beta_k X_{ki})} \quad (1)$$

Onde:

- X_{ki} é a k -ésima variável independente para uma determinada amostra i ;
- $Pr(Y_i = 1|X_{1i}, \dots, X_{Ki})$ é a probabilidade de $Y = 1$ dado um conjunto de variáveis independentes da i ;
- β_0 é o intercepto do modelo;
- β_k é o coeficiente associado à k -ésima variável no modelo de regressão logística.

Para ajustar uma curva de regressão logística, é utilizada uma função de custo, onde os resultados do modelo são comparados aos dados reais e calcula-se o desvio entre as duas grandezas. O custo, ou erro, de uma instância de treinamento do modelo pode ser observado na Equação 2, adaptada de Géron (2022), e está representado visualmente na Figura 7.

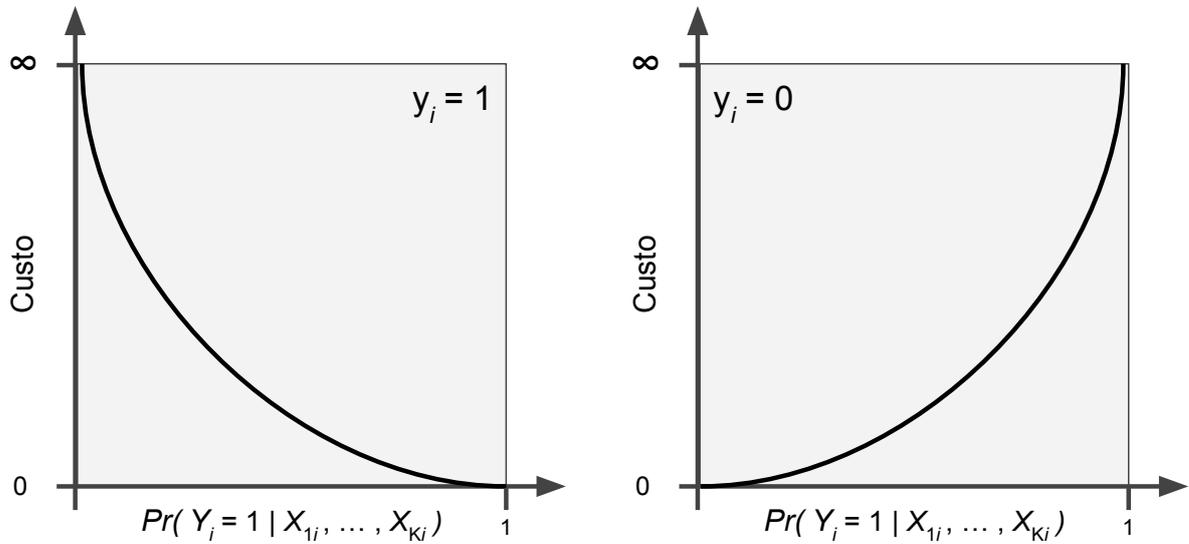
$$C(X_{1i}, \dots, X_{Ki}) = \begin{cases} -\log(Pr(Y_i = 1|X_{1i}, \dots, X_{Ki})) & \text{se } y_i = 1 \\ -\log(1 - Pr(Y_i = 1|X_{1i}, \dots, X_{Ki})) & \text{se } y_i = 0 \end{cases} \quad (2)$$

Onde:

- C é o custo do desvio entre a saída do modelo para uma amostra i em relação ao seu valor real;
- y_i é o valor real para o conjunto de variáveis independentes da amostra i .

Após caracterizar um desvio, a função de custo ($J(\theta)$) é calculada somando os custos individuais de todas as n amostras do conjunto de dados de treinamento em relação aos seus respectivos valores reais (GÉRON, 2022). O resultado dessa soma está representado na Equação 3, onde $\theta = X_{1i}, \dots, X_{Ki}$.

Figura 7 – Custo de uma instância de treinamento do modelo de regressão logística



Fonte: Adaptado de Bisong *et al.* (2019)

$$J(\theta) = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\text{Pr}(Y_i = 1|\theta)) + (1 - y_i) \log(1 - \text{Pr}(Y_i = 1|\theta))] \quad (3)$$

Por fim, são empregados algoritmos de otimização, como o método do gradiente, para encontrar os coeficientes β que minimizam a função de custo. Apesar de não possuir uma solução analítica, a função de custo apresenta um comportamento convexo, fazendo com que esses algoritmos garantam a convergência para o mínimo global, dado o tempo necessário (ZHOU, 2021; GÉRON, 2022; BISONG *et al.*, 2019).

2.3.3.2 Support Vector Machine (SVM)

O *Support Vector Machine* (SVM) é um algoritmo de ML supervisionado proposto inicialmente por Boser, Guyon e Vapnik (1992) com o objetivo de melhorar o equilíbrio entre erro e generalização dos modelos de classificação de sua época. O SVM é conhecido por sua alta capacidade de aprendizado e ampla flexibilidade, podendo lidar com problemas de classificação lineares e não-lineares, além de regressão e detecção de anomalias (GÉRON, 2022).

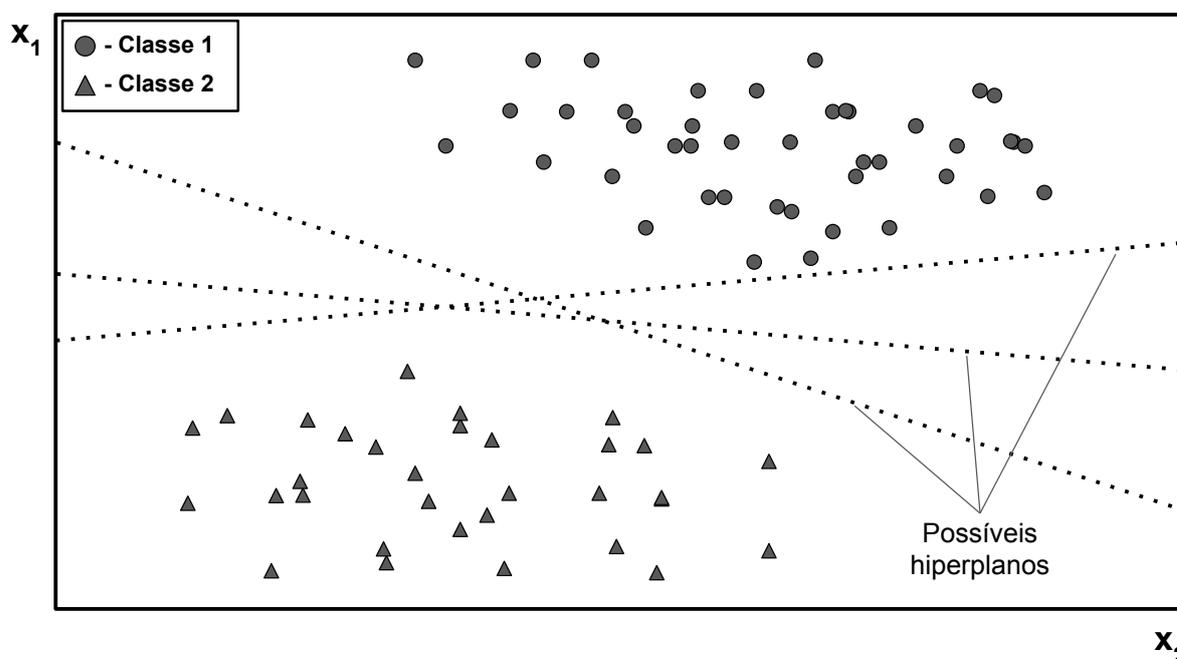
Como visto anteriormente, um problema de classificação é caracterizado pelas abordagens para se estabelecer uma divisão, ou limiar, entre as classes a serem preditas. Diante desse contexto, o SVM se destaca por possibilitar uma visualização do limiar de classificação com a utilização de recursos geométricos. James *et al.* (2023) demonstram a ideia por trás do SVM a partir da definição de um hiperplano, sendo este um subespaço afim e plano de dimensão $p - 1$, onde p representa a dimensão do espaço em questão. Dessa forma, para um espaço bidimensional, o hiperplano é

representado por uma linha, enquanto um espaço tridimensional possui hiperplanos de subespaços bidimensionais, ou seja, planos propriamente ditos. A generalização do hiperplano para um espaço de p dimensões pode ser observada na Equação 4.

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p = 0 \quad (4)$$

Portanto, sendo os coeficientes β responsáveis por parametrizar o hiperplano, pode-se afirmar que qualquer $X = (X_1, X_2, \dots, X_p)$, que satisfaça a Equação 4, se configura como um ponto pertencente àquele hiperplano. O gráfico da Figura 8 possibilita a visualização dos hiperplanos, já no contexto de um problema de classificação, a partir da apresentação um problema binário, onde as classes estão sendo avaliadas frente a duas variáveis independentes (X_1 e X_2) preditoras de seu comportamento.

Figura 8 – Exemplo de problema de classificação binária e hiperplanos

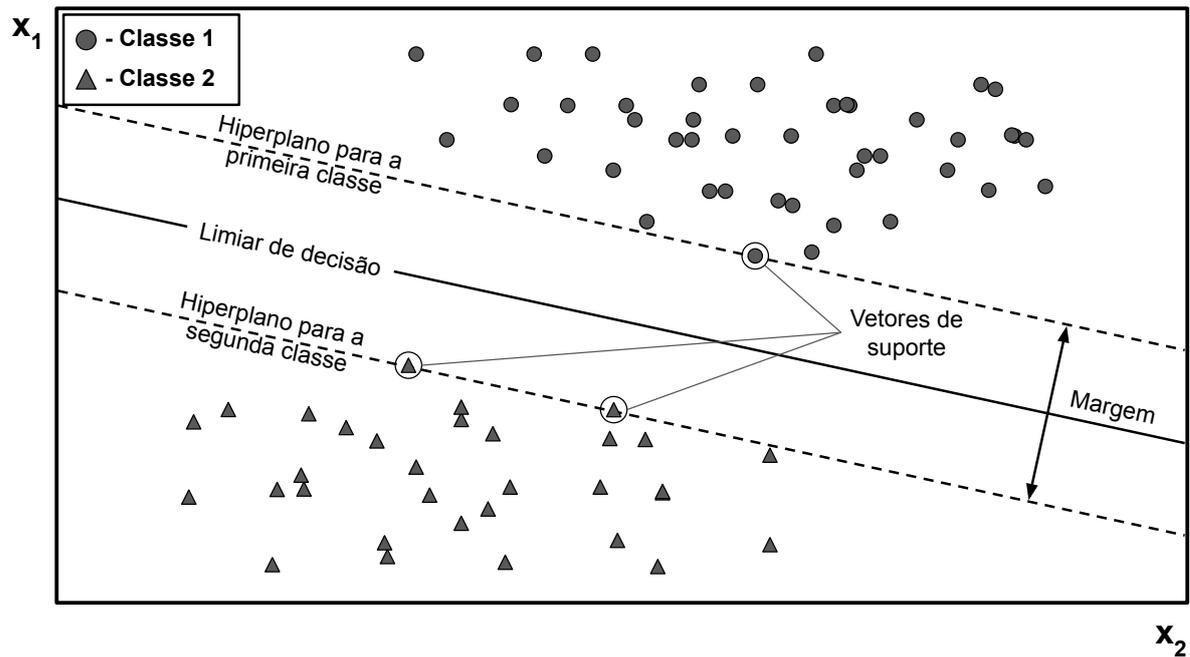


Fonte: Adaptado de Raschka, Liu e Mirjalili (2022)

Percebe-se pela Figura 8 que os dois grupos possuem uma infinidade de hiperplanos que são capazes de realizar uma separação perfeita de seus dados, dificultando uma definição que mantenha um potencial de generalização para a introdução de novas informações a serem classificadas. Diante do problema em questão, o SVM surge como uma opção para preencher essa lacuna ao utilizar uma métrica denominada "margem máxima", que representa a distância entre os hiperplanos paralelos limites para classificação, representados na Figura 9 (JAMES *et al.*, 2023; GÉRON, 2022).

Dessa forma, a definição do hiperplano do limiar de decisão passa a se tornar um problema de maximização da margem (M), demonstrado nas Equações 5, 6 e 7 (JAMES *et al.*, 2023).

Figura 9 – Componentes do SVM



Fonte: Adaptado de Raschka, Liu e Mirjalili (2022)

$$\underset{\beta_0, \beta_1, \dots, \beta_p, M}{\text{maximizar}} \quad M \quad (5)$$

$$\text{sujeito a} \quad \sum_{j=1}^p \beta_j^2 = 1, \quad (6)$$

$$y_i (\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip}) \geq M \quad \forall i = 1, \dots, n. \quad (7)$$

Onde

- M é o valor da margem entre os hiperplanos limite;
- B_j é o j -ésimo coeficiente da equação do hiperplano de dimensão p ;
- y_i é o valor da variável alvo (-1 ou 1) para i -ésima amostra, indicando sua classificação para um conjunto de variáveis independentes $X_i = (x_{i1}, x_{i2}, \dots, x_{ip})$.

Ainda, o SVM se destaca por ser capaz de lidar com conjuntos de dados que apresentam não linearidade e *outliers*, utilizando técnicas como a introdução do parâmetro de relaxamento, que resulta na criação de uma margem mais suave entre os grupos. Esse parâmetro equilibra a complexidade do modelo e a penalização por erros de classificação, permitindo uma maior presença de *outliers* ao passo em que a margem entre hiperplanos aumenta. Além disso, o SVM utiliza funções de *kernel* para transformar os dados em um espaço de maior dimensionalidade, no qual é possível

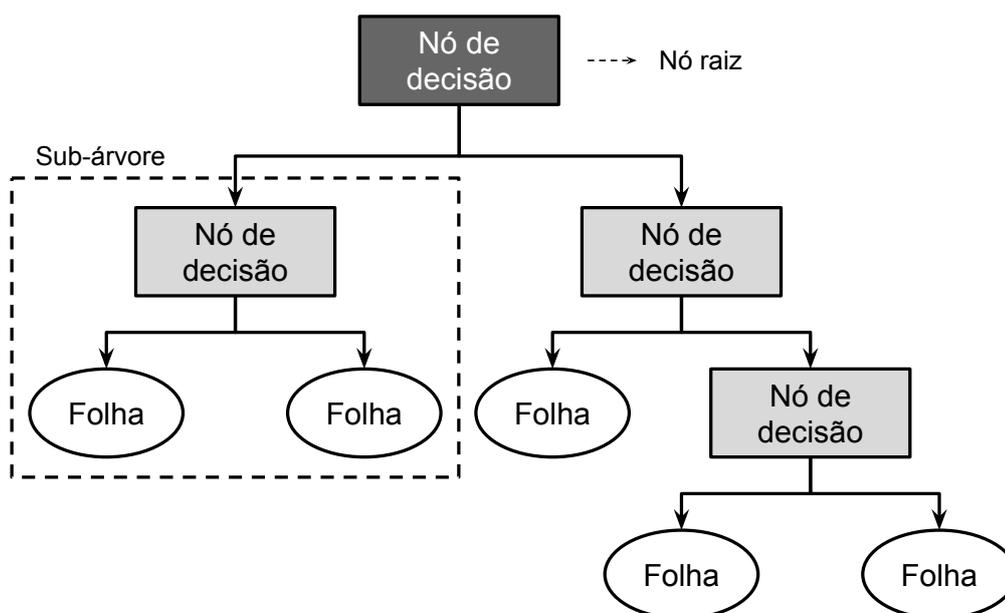
encontrar um hiperplano linear que separe de forma mais eficaz os diferentes grupos (ZHOU, 2021; RASCHKA; LIU; MIRJALILI, 2022).

2.3.3.3 XGBoost

O *XGBoost* é um algoritmo de ML supervisionado que possui como objetivo impulsionar o desempenho das regressões e classificações geradas por árvores de decisão (CHEN; GUESTRIN, 2016; GOHIYA; LOHIYA; PATIDAR, 2018). Para entender seu funcionamento, é necessário que sejam estabelecidas algumas definições quanto aos componentes que o constituem e sua estrutura de organização, como o conceito de "árvore de decisão" e os métodos de "ensemble".

Árvores de decisão são algoritmos de aprendizado de máquina baseados na estratificação, ou segmentação, da variável alvo em regiões mais simples de serem analisadas. Para isso, são definidas séries de regras, ou nós de decisão, que dividem os dados do conjunto de teste de forma consecutiva, baseado em sua compatibilidade com a condição imposta naquele nó. Ao fim de uma árvore de decisão, estão as folhas, ou nós terminais, que determinam a classificação encontrada, ou variável numérica, para um dado após seu condicionamento (JAMES *et al.*, 2023). O algoritmo recebe esse nome por conta de sua similaridade visual a uma árvore, onde a divisão dos nós de decisão apresenta um comportamento análogo a segmentação da mesma em ramos e galhos, até alcançar a folha, equivalente ao resultado final (Figura 10).

Figura 10 – Estrutura de uma árvore de decisão



Fonte: Adaptado de Hafeez *et al.* (2021)

Um algoritmo de árvore de decisão é elaborado selecionando as condições, ou regras, na ordem que proporcione a maior divisão dos dados em categorias únicas,

umentando sua pureza. Uma das formas mais usadas para medir a pureza de um nó de decisão, em modelos de classificação, consiste no "ganho de informação", um método baseada no cálculo da entropia, indicada na Equação 8 (ZHOU, 2021).

$$Ent(D) = - \sum_{k=1}^{|c|} p_k \log_2(p_k) \quad (8)$$

Onde:

- $Ent(D)$ representa a entropia de um conjunto de dados D ;
- p_k é a proporção da k -ésima classe dentro do conjunto de dados D ;
- $|c|$ é o número de classes presentes no conjunto de dados D .

A entropia apresenta uma relação inversamente proporcional à organização, ou seja, quando há uma baixa entropia para um conjunto de dados, pode-se esperar que há predominância de uma classe, para variáveis discretas, ou intervalo de valores, para variáveis contínuas.¹ No entanto, para uma árvore de decisão, a performance de um nó está atrelada a forma como os grupos resultantes de sua divisão se organizam, fazendo com que seja necessário avaliar simultaneamente a entropia de dois ou mais subconjuntos. Nesse contexto, utiliza-se o método do ganho de informação (Equação 9), que calcula a diferença de entropia entre o conjunto de dados original e os subconjuntos derivados de sua segmentação (ZHOU, 2021).

$$Ganho(D, a) = Ent(D) - \sum_{v=1}^V \frac{|D^v|}{|D|} Ent(D^v) \quad (9)$$

Onde:

- $Ganho(D, a)$ representa o ganho de informação dada a divisão de um conjunto D de acordo com as V classes de uma variável independente a ;
- D^v é o subconjunto da variável alvo que pertence a v -ésima classe de uma variável independente a ;
- $\frac{|D^v|}{|D|}$ é a proporção dos dados do conjunto D que está presente no subconjunto D^v .

Dessa forma, é possível definir a escolha que possibilita a diminuição da soma ponderada das entropias em cada nó de decisão, tornado o modelo cada vez mais preciso. Por fim, o processo é repetido ao longo da árvore de decisão até que finalize em algum resultado, ou folha. As condições para a ocorrência de uma folha são determinadas por Zhou (2021) em três casos:

¹ Para fins de simplificação, pode-se considerar a divisão de variáveis contínuas em intervalos, equivalentes a classes, a partir da comparação de sua grandeza com um valor de referência.

1. Todas as amostras do subconjunto resultante do nó de decisão pertencem a um mesmo grupo;
2. Todas as variáveis independentes foram utilizadas em algum nó de decisão de forma a esgotar as possibilidades, ou as variáveis independentes restantes não são capazes de dividir os dados em subconjuntos;
3. Não existem mais dados a serem divididos no nó atual.

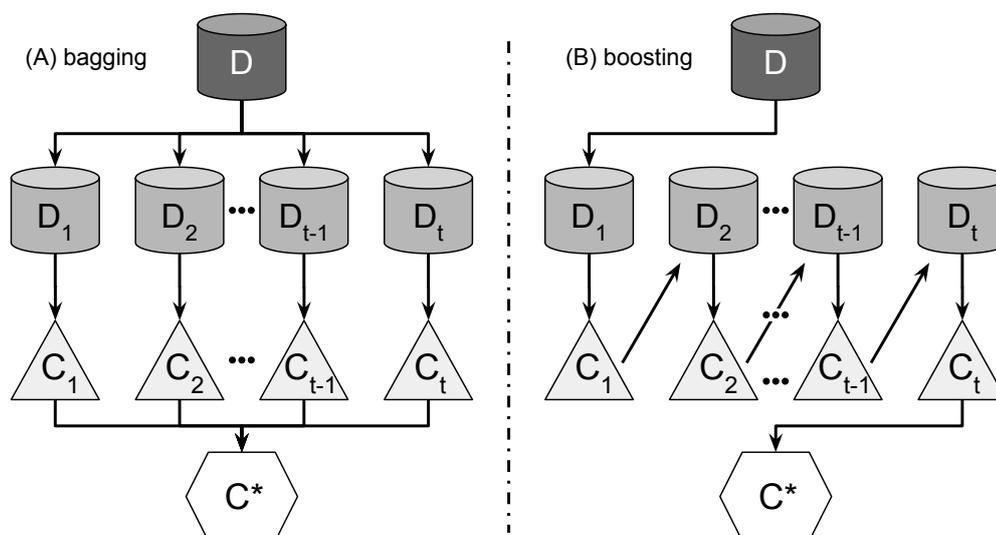
Entretanto, uma árvore de decisão isolada é considerada como um "aprendiz fraco", pois pode estar sujeita a um viés sobre os dados na qual foi treinada e possuir pouca utilidade quando aplicada na prática. Para contornar essa característica, foram desenvolvidos algoritmos que aproveitam a flexibilidade de uma árvore de decisão de forma a refinar as suas previsões. Esses algoritmos, denominados de métodos *ensemble*, utilizam diferentes abordagens para a combinação de diversas árvores com o objetivo de alcançar uma performance com maior capacidade de generalização do que as árvores individuais (JAMES *et al.*, 2023; RASCHKA; LIU; MIRJALILI, 2022).

No cenário dos métodos *ensemble* para modelos de classificação, duas abordagens se destacam: os métodos de *bagging* e *boosting* (Figura 11). Os métodos de *bagging* se caracterizam por simular a construção de múltiplas árvores de decisão (C_t) simultâneas a partir de diferentes amostragens (D_t), com reposição, do conjunto de dados inicial (D). Dessa forma, são treinados t modelos, cada um fornecendo uma previsão diferente, e o resultado final (C^*) é a previsão mais frequente entre os modelos (RASCHKA; LIU; MIRJALILI, 2022). Por outro lado, o método de *boosting* consiste em treinar modelos de classificação subsequentes, onde cada novo modelo atribui mais importância para as previsões incorretas do modelo anterior, até que se encontre um modelo perfeito ou um número máximo de modelos seja alcançado. O resultado final de um modelo ajustado pelo método de *boosting* consiste em uma combinação de todos os modelos gerados a partir da média ponderada de suas acurácias (YANG *et al.*, 2019).

No contexto de *boosting* para árvores de decisão, uma implementação do método tem se tornado popular nos últimos anos devido a sua capacidade de previsão e escalabilidade com conjuntos de dados massivos. Essa implementação, chamada de *XGBoost* (*eXtreme Gradient Boosting*), tem como principal premissa a utilização de aproximações e truques que aceleram o processo de cálculo do gradiente para a otimização de funções de perda (RASCHKA; LIU; MIRJALILI, 2022).

2.3.4 Valor de Shapley

Shapley (1953), ao estudar a teoria dos jogos cooperativos, propôs uma solução justa para a distribuição dos ganhos totais entre os participantes de cenários

Figura 11 – Diagrama do funcionamento dos métodos *bagging* e *boosting*

Fonte: Adaptado de Yang *et al.* (2019)

cooperativos. Seu algoritmo baseia-se na ideia da contribuição de cada jogador frente a uma coalizão, determinando sua influência no resultado final. A partir das diferentes combinações de coalizões, atribui-se a cada participante um valor final, refletindo o retorno esperado ao integrar-se ao jogo. Em termos conceituais, o conceito de "jogo" pode ser melhor compreendido pela explicação a seguir:

Devemos pensar em um "jogo" como um conjunto de regras com jogadores específicos nas posições de jogo. As regras, por si só, descrevem o que chamaremos de "jogo abstrato". Os jogos abstratos são jogados por papéis - como "dealer" ou "equipe visitante" - e não por jogadores externos ao jogo. A teoria dos jogos lida principalmente com jogos abstratos. Essa distinção será útil para que possamos afirmar de forma precisa que o valor de um "jogo" depende apenas de suas propriedades abstratas (SHAPLEY, 1953, p. 307–308).

Segundo Maschler, Zamir e Solan (2020), esse método, denominado de "Valor de Shapley" pode ser considerado um dos conceitos mais importantes já desenvolvidos dentro da teoria de jogos no contexto de soluções de valor único em jogos de coalizão. Sua performance se dá principalmente por conta da sua abordagem axiomática, onde a solução do método é a única que satisfaz suas propriedades fundamentais, sendo elas:

- a) Eficiência: a soma do valor de todos os participantes deve ser igual ao valor total do jogo;
- b) Simetria: o valor de cada participante deve depender apenas de sua contribuição. Logo, dois participantes que contribuem exatamente da mesma forma para todas as coalizões devem receber o mesmo valor;

- c) Jogador nulo: caso um participante não contribua em alguma das coalizões, então seu valor deve ser igual a zero;
- d) Aditividade: o valor final de um jogador em um jogo combinado é a soma dos seus valores calculados em cada jogo separado.

Apesar de ter sido proposto na década de 50, o Valor de Shapley tem se destacado nos últimos anos com o aumento do uso de modelos "caixa-preta", ou seja, aqueles que não possuem uma definição de seu funcionamento interno (JETHANI *et al.*, 2021). Nesse contexto, sua aplicação se apresenta como uma alternativa viável para conseguir explicar a complexa relação entre as variáveis de entrada de um modelo de ML e as suas saídas, o que fez com que seu uso se tornasse a base para a interpretação de diversos modelos (SUNDARARAJAN; NAJMI, 2020).

Para o Valor de Shapley, as variáveis de entrada de um modelo de ML são equivalentes aos participantes em um cenário cooperativo, enquanto o modelo em si pode ser comparado ao jogo e suas regras. Ao analisar a contribuição dos participantes em diferentes coalizões, é possível explicar a influência dos dados de entrada na pontuação final do jogo, ou seja, o seu impacto nos resultados de um modelo (LUNDBERG; LEE, 2017b).

2.3.5 Métricas de avaliação do desempenho de modelos de classificação

Uma métrica é uma medida utilizada para quantificar a capacidade de um modelo em generalizar seu aprendizado. Essas métricas avaliam o desempenho do modelo com base em diferentes aspectos, como precisão, erro, ou robustez, permitindo uma análise objetiva de sua performance. Para isso, esses indicadores fazem uma comparação entre os valores preditos e seus correspondentes reais, em um subconjunto de dados nunca antes visto pelo algoritmo de ML, de forma a avaliar seu comportamento fora das condições de treino (ZHOU, 2021; HOSSIN; SULAIMAN, 2015).

2.3.5.1 Matriz de confusão

No contexto classificação, destaca-se o uso da matriz de confusão para o levantamento de dados, pois seus componentes são a base de métricas amplamente utilizadas para a avaliação dos modelos desta categoria (RAINIO; TEUHO; KLÉN, 2024). A matriz de confusão para um problema de classificação binário está representada no Quadro 1.

Quadro 1 – Matriz de confusão

Classe real	Classe prevista	
	Positivo	Negativo
Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Adaptado de Zhou (2021)

As variáveis de uma matriz de confusão representam a relação entre os dados de teste de um modelo e suas previsões para as amostras correspondentes. A matriz organiza os resultados em quatro categorias: verdadeiro positivo (VP), quando o modelo identifica corretamente um resultado positivo; verdadeiro negativo (VN), quando um resultado negativo é previsto com precisão; falso positivo (FP), quando um resultado negativo é erroneamente classificado como positivo; e falso negativo (FN), quando um resultado positivo é incorretamente identificado como negativo (RAINIO; TEUHO; KLÉN, 2024).

Algumas das métricas que utilizam as variáveis da matriz de confusão, para um problema de classificação de duas classes, estão contidas no Quadro 2.

Quadro 2 – Métricas de avaliação para modelos de classificação

Métricas	Fórmula	Foco da Avaliação
Acurácia	$\frac{VP + VN}{VP + FP + VN + FN}$	A acurácia mede a proporção de previsões corretas sobre o número total de instâncias avaliadas.
Especificidade	$\frac{VN}{VN + FP}$	Esta métrica é usada para medir a fração de padrões negativos que são classificados corretamente.
Precisão (p)	$\frac{VP}{VP + FP}$	A precisão é usada para medir os padrões positivos previstos corretamente.
Revocação (r)	$\frac{VP}{VP + FN}$	A revocação é usada para medir a fração de padrões positivos corretamente classificados.
Medida F	$\frac{2 \cdot p \cdot r}{p + r}$	Esta métrica representa a média harmônica entre revocação e precisão.

Fonte: Adaptado de Hossin e Sulaiman (2015)

A exatidão é direta, refletindo a proporção de amostras classificadas corretamente, mas pode ser enganosa quando aplicada a conjuntos de dados desequilibrados,

em que a classe majoritária pode dominar o valor da métrica. A precisão enfatiza a exatidão das previsões positivas, o que a torna ideal para cenários em que os falsos positivos são particularmente caros. Entretanto, ela ignora os casos que são classificados incorretamente como negativos. Por outro lado, a revocação se concentra na identificação do maior número possível de casos positivos, o que é fundamental quando falsos negativos têm consequências significativas, embora possa ser inflada pela previsão de todas as instâncias como positivas. A medida F equilibra precisão e revocação, oferecendo uma média harmônica que é eficaz para conjuntos de dados desequilibrados, embora ignore os verdadeiros negativos, que podem ser essenciais em alguns contextos (MILLER *et al.*, 2024).

Por fim, a especificidade é uma métrica que mede a capacidade de identificar com precisão os casos em que um determinado critério não se aplica, garantindo que apenas os casos negativos sejam reconhecidos como tais. Quanto maior a especificidade, maior é a confiança de que os resultados negativos são precisos, ou seja, ela reflete a eficiência do processo em evitar classificações incorretas, especialmente no que diz respeito à ocorrência de falsos positivos (TREVETHAN, 2017).

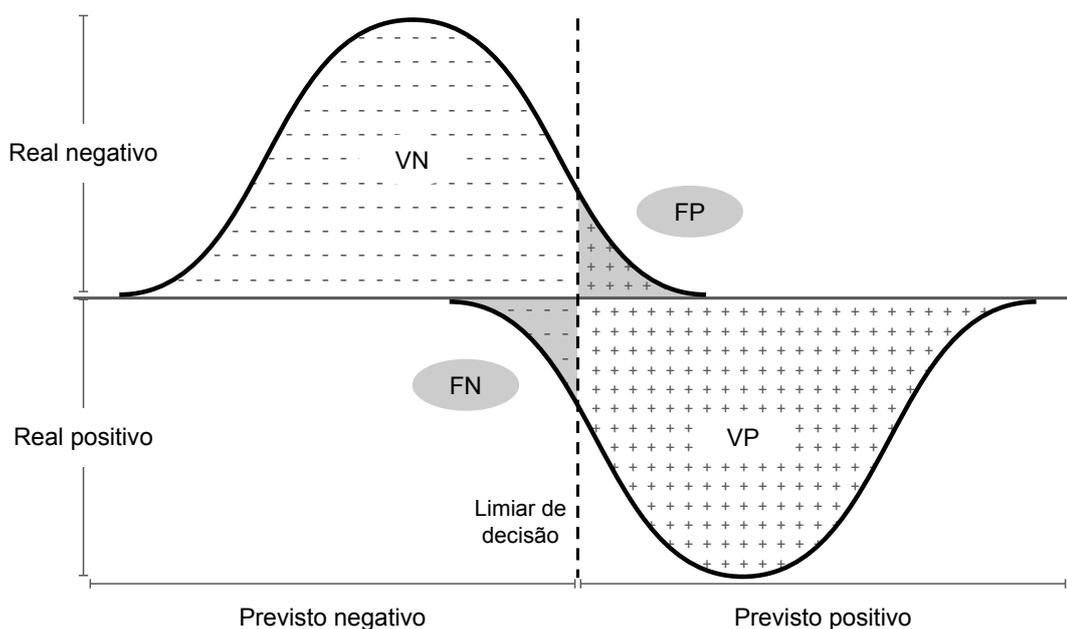
2.3.5.2 ROC e AUC

Conforme abordado na Seção 2.3.3.1, sobre regressão logística, a transformação de uma probabilidade em uma classificação binária é feita utilizando um limiar de decisão. Entretanto, a definição desse ponto de transição entre categorias se apresenta como uma operação complexa devido a sua grande influência na interpretação dos resultados de um modelo de classificação. A Figura 12 representa essa complexidade ao avaliar o limiar de decisão utilizando o exemplo de duas populações onde há sobreposição das condições que as classificam. Dessa forma, a escolha do ponto de transição possui uma espécie de *trade-off*, pois sua manipulação favorece determinados diagnósticos ao passo em que prejudica o desempenho em outros (JUNGE; DETTORI, 2018).

Para auxiliar na definição desse limiar, pode-se utilizar um método chamado "Curva Característica de Operação do Receptor", mais conhecida como curva ROC. Essa métrica foi desenvolvida durante a Segunda Guerra Mundial com o objetivo de estabelecer um critério de diferenciação entre os sinais de rádio e, conseqüentemente, melhorar a identificação de aeronaves inimigas (ZHOU, 2021). No entanto, seu uso se espalhou nas décadas posteriores à guerra para as mais diversas áreas de aplicação, desde a definição de diagnósticos médicos a análise de risco no setor bancário (GONÇALVES *et al.*, 2014).

Nos últimos anos, o uso da curva ROC tem se popularizado no cenário dos algoritmos de ML, devido a sua aplicabilidade para os modelos de classificação. A Figura 13 mostra esse aumento nos casos de utilização do método, destacando o número

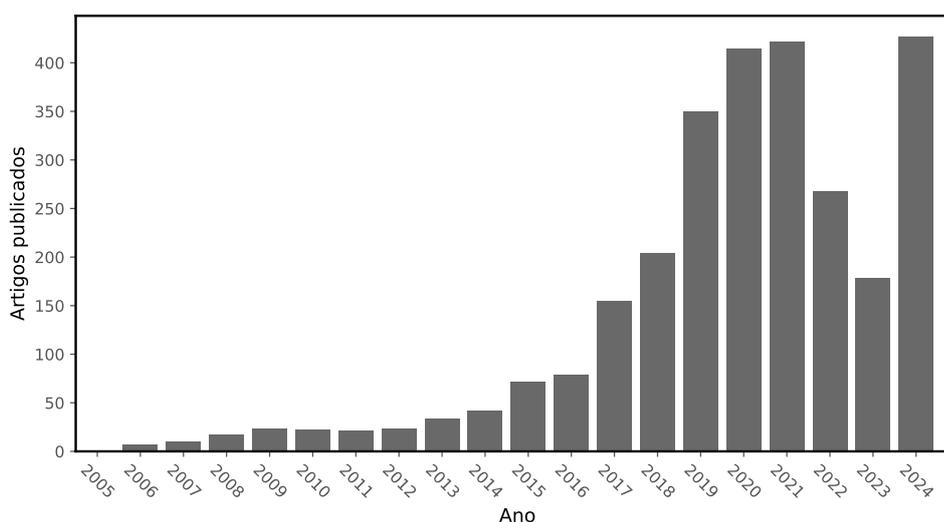
Figura 12 – Demonstração visual da influência do limiar de decisão



Fonte: Adaptado de Junge e Dettori (2018)

de artigos com as palavras-chave "*Machine Learning*" e "*ROC Curve*" indexados no Scopus, banco de dados de resumos e citações, ao longo dos últimas duas décadas.

Figura 13 – Número anual de artigos indexados no Scopus com os termos "*Machine Learning*" e "*ROC Curve*"

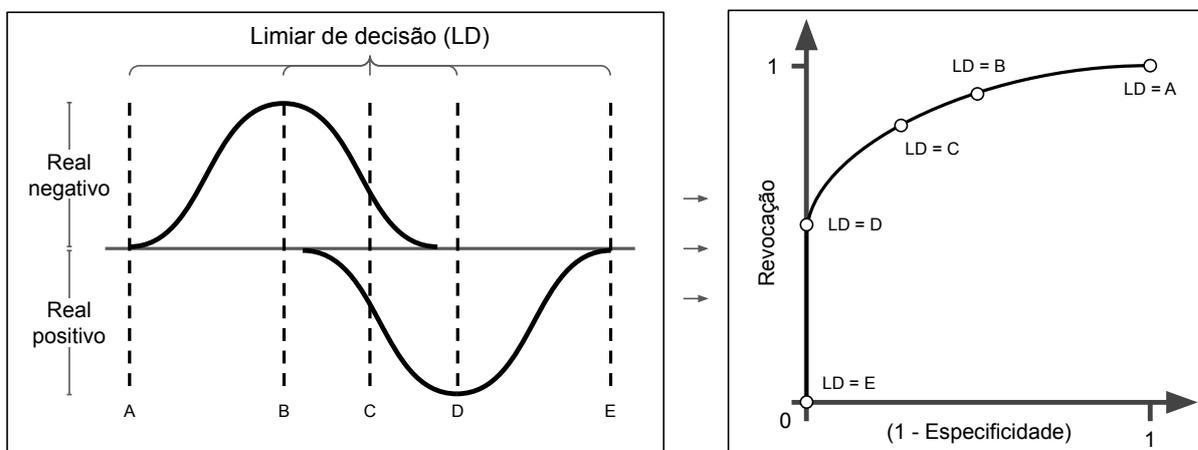


Fonte: Adaptado de Scopus (2024)

Quanto a sua construção, pode-se definir uma curva ROC como a relação de equilíbrio entre a taxa de verdadeiro positivo, ou revocação, e a taxa de falso positivo, equivalente a contraparte da especificidade, dada a variação do limiar de decisão ao longo de seus valores possíveis (ERICKSON; KITAMURA, 2021). Uma representação

gráfica dessa variação pode ser observada na Figura 14.

Figura 14 – Construção da curva ROC com diferentes limiares de decisão



Fonte: Adaptado de Junge e Dettori (2018)

A partir da análise da curva ROC, é possível identificar quais pontos representam um limiar de decisão mais apropriado ao contexto de aplicação do modelo de classificação. Para demonstrar a complexidade dessa relação, Junge e Dettori (2018) avaliam como cada zona indicada na curva ROC possui seus pontos positivos e negativos utilizando o exemplo do diagnóstico de uma doença:

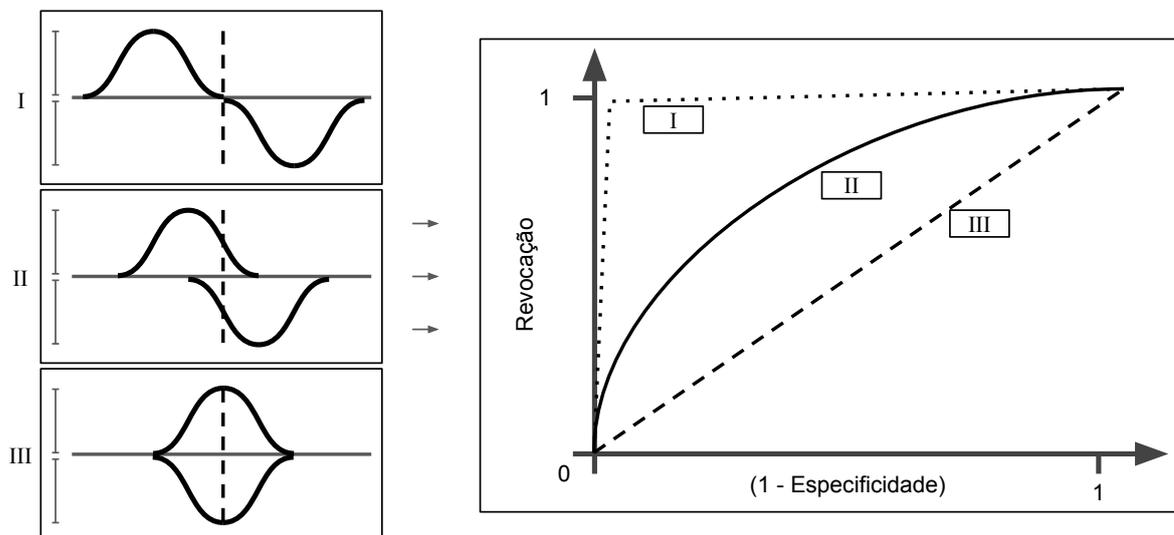
- Zona próxima ao ponto C (cerca de 50%): os erros são balanceados, distribuindo igualmente a ocorrência de falsos positivos e falsos negativos.
- Zona entre C e A (abaixo de 50%): o limiar configura uma estratégia mais conservadora, onde a maior parte dos pacientes portadores da doença seriam identificados, ao passo em que o número de pessoas diagnósticas erroneamente com a doença também aumentaria.
- Zona entre C e E (acima de 50%): usar um limiar nessa zona significaria uma diminuição do número de pacientes diagnosticados com a doença incorretamente, porém, mais pessoas doentes seguiriam sem o seu diagnóstico.

Além da escolha do limiar de decisão mais apropriado, um parâmetro fundamental na análise de uma curva ROC é a área a qual sua curva cobre, também conhecida como AUC (*Area Under the Curve*). A AUC possibilita a simplificação da curva ROC em um único valor, tornando a sua comparação mais prática e universal entre múltiplos modelos de classificação (ZHENG, 2015).

De forma geral, a qualidade de uma curva ROC é diretamente proporcional a sua AUC, visto que uma área maior é o resultado da especificidade aumentando seus valores enquanto a revocação permanece relativamente inalterada, ou seja, o modelo

possui uma maior capacidade de classificar as instâncias corretamente. A Figura 15 demonstra essa relação ao apresentar três tipos de curvas ROC: uma curva onde há diferenciação perfeita entre classificações (I), uma curva onde existe uma zona de incerteza (II) e uma representação do equivalente à escolha aleatória (III).

Figura 15 – Curvas ROC para diferentes casos



Fonte: Adaptado de Junge e Dettori (2018)

2.4 ESTUDOS PERTINENTES AO TEMA

Em um estudo voltado para a precificação no setor imobiliário, Zaghi (2023) explorou a aplicabilidade de modelos de ML na estimativa do valor de venda para diferentes tipos de imóveis, utilizando algoritmos como *Lasso Regression*, *Random Forest* e *XGBoost*. A partir de dados coletados via *web scraping* de portais imobiliários disponíveis na internet, o pesquisa direcionou seu foco para atributos como o número de quartos, banheiros e vagas de garagem, fatores estes utilizados para a caracterização dos ativos imobiliários a serem precificados. A estrutura da pesquisa incluiu etapas de validação cruzada e otimização de hiperparâmetros para maximizar a precisão das previsões, resultando no *Random Forest* como o modelo mais eficaz, com um R^2 de 0,82 e um erro percentual absoluto médio de 25,84%. Com uma abordagem baseada nos mesmos algoritmos e contexto de aplicação, Potrich (2024) obteve resultados indicativos da predominância do modelo *XGBoost* na predição de preços de imóveis, com um R^2 de 0,70 e um erro percentual absoluto médio de 24,12%. De forma complementar ao estudo inicial, o autor destacou a importância da segmentação dos dados em diferentes grupos para a melhora do desempenho dos modelos. Ao treinar os algoritmos utilizando apenas os dados de cada bairro individualmente, foi possível alcançar uma redução média de 9,3% no erro percentual absoluto médio, mostrando

como as diferentes localizações podem contribuir para a generalização do modelo ao custo de uma menor capacidade individual.

Simões (2021) desenvolveu um modelo de precificação dinâmica para produtos de curto ciclo de vida, baseado no problema do jornaleiro, utilizando técnicas de *machine learning* para ajustar preços em função da demanda e da variabilidade do mercado. O estudo empregou modelos de séries temporais e algoritmos preditivos para monitorar e ajustar os preços continuamente, maximizando a receita e minimizando as perdas associadas ao excesso ou falta de estoque. Apesar da ausência de uma aplicação prática evidenciada no trabalho, a abordagem utilizada evidencia o potencial do *machine learning* em adaptar preços de forma ágil, destacando-se em setores onde a demanda é volátil e os ciclos de vida dos produtos são curtos.

Fruchter e Sigué (2013) avaliaram estratégias de precificação para serviços de assinatura, enfocando a combinação de taxas de ativação, assinatura e cancelamento. Utilizando um modelo dinâmico específico para o contexto de assinaturas, eles analisaram como essas taxas impactam a aquisição e retenção de clientes ao longo do tempo. Com base em técnicas de controle ótimo, os autores maximizaram os lucros descontados ao ajustar as taxas conforme o crescimento da base de assinantes, reconhecendo a importância do efeito de boca a boca e das barreiras de saída. O modelo adotado permite que a taxa de ativação siga uma estratégia de penetração, começando baixa para atrair clientes iniciais, enquanto a taxa de cancelamento adota uma estratégia de *skimming*, começando alta e diminuindo à medida que a rede amadurece. Os resultados indicaram que essa abordagem incentiva a adesão inicial e limita a evasão, promovendo o crescimento e a consolidação da rede.

Saharan, Bawa e Kumar (2020) realizaram uma revisão sistemática sobre técnicas de precificação dinâmica aplicadas em sistemas de transporte inteligentes em cidades. O estudo destaca a relevância da precificação dinâmica para gerenciar congestionamentos, controlar a carga nos sistemas e otimizar o planejamento de rotas de veículos em áreas urbanas. Utilizando uma abordagem sistemática, os autores revisam diferentes metodologias de precificação e os fatores que influenciam sua eficiência, como condições ambientais, custos operacionais e a variação no fluxo de demanda. A análise inclui a categorização das técnicas de precificação segundo suas aplicações e discute suas vantagens e limitações, evidenciando os desafios da aplicação prática e a necessidade de planejamento para evitar problemas como aumento no tempo de espera e desperdício energético.

Fang *et al.* (2020) investigaram a aplicação de precificação dinâmica para o carregamento rápido de veículos elétricos, visando incentivar a expansão da infraestrutura de carregamento por meio de preços que otimizem a lucratividade ao longo do tempo. O estudo modela o problema como um Processo de Decisão de Markov, considerando a elasticidade da demanda frente a variações de preço e propondo algoritmos como

programação dinâmica, *Q-learning* e *actor-critic* para ajustar os preços em resposta à demanda e fatores ambientais. Esses métodos foram analisados em cenários simulados, demonstrando que a precificação dinâmica pode superar a abordagem de preços fixos, especialmente quando se considera a variabilidade na taxa de espera dos consumidores. O uso do aprendizado por reforço permitiu encontrar políticas de preço que se adaptam em tempo real, maximizando a receita e atendendo melhor à demanda em horários de pico e de baixa utilização.

Ulmer (2020) explora em seu trabalho estratégias de precificação e definição de rotas dinâmicas para entregas no mesmo dia no setor de *e-commerce*, visando aumentar a receita e a quantidade de clientes atendidos diariamente. O estudo modela o problema como um Processo de Decisão de Markov, utilizando uma política de precificação e roteamento antecipatória que adapta preços com base nos custos de oportunidade de cada cliente e opção de entrega. A metodologia envolve a aplicação de uma aproximação de função-valor para estimar o impacto das decisões no futuro, considerando a flexibilidade da frota. Em uma análise computacional, a política de precificação e roteamento antecipatória mostrou-se superior em termos de receita e número de clientes atendidos quando comparada com políticas de preços fixos ou dependentes da localização geográfica e do tempo.

Talón-Ballester, Nieto-García e González-Serrano (2022) examinaram o uso de preços dinâmicos como uma prática central para a gestão de receitas no setor hoteleiro, destacando o papel das tecnologias de *big data* para aperfeiçoar esse processo. Com uma abordagem qualitativa, o estudo analisa a implementação do conceito de "preços abertos" e a evolução em direção a preços personalizados que consideram o perfil individual de cada cliente. A pesquisa oferece evidências empíricas sobre as vantagens e desafios dessa abordagem centrada no cliente, além de propor um *framework* conceitual visual que representa a dinâmica dos preços no setor.

3 METODOLOGIA

O capítulo de metodologia tem como objetivo descrever de forma clara e objetiva os procedimentos adotados para a condução da pesquisa. Nele, são apresentados o enquadramento metodológico, os métodos de coleta de dados, a população e amostra envolvidas, bem como as ferramentas e técnicas de análise utilizadas. Essa seção garante a transparência e a reprodutibilidade do estudo, permitindo que outros pesquisadores compreendam como os dados foram tratados, além de assegurar a coerência entre os objetivos propostos e as abordagens escolhidas. Mattos (2020) destaca essa ideia ao descrever o método científico como:

[...] uma orientação geral que facilita ao pesquisador tomar decisões acertadas, formulando hipóteses, realizando experiências e, conseqüentemente, analisando e interpretando os dados da investigação de maneira coerente, clara e precisa, alcançando resultados verificáveis e confiáveis (MATTOS, 2020, p. 39).

3.1 ENQUADRAMENTO METODOLÓGICO

Segundo Miguel *et al.* (2018), o enquadramento metodológico de uma pesquisa é determinante para orientar a escolha dos métodos e técnicas apropriados, levando em consideração fatores como o tempo e os recursos disponíveis, a acessibilidade aos dados e a própria natureza do problema investigado. Nesse sentido, destaca-se a flexibilidade do processo, uma vez que uma mesma questão de pesquisa pode ser abordada por diferentes métodos, dependendo do contexto e objetivos do estudo. Dessa forma, a definição adequada da metodologia permite que o pesquisador tome decisões fundamentadas, otimizando o uso de recursos e aumentando a eficácia da investigação na busca por respostas confiáveis.

Diante dessa necessidade de um adequado enquadramento metodológico para a tomada de decisões fundamentadas, pode-se classificar esta pesquisa a partir de sua natureza aplicada, pois busca solucionar um problema prático ao maximizar o valor esperado dos orçamentos com base na probabilidade de aceite dos clientes. Com objetivos explicativos e descritivos, ela explora relações entre variáveis e se apoia na análise de dados históricos. Metodologicamente, trata-se de um misto entre estudo de caso e pesquisa *ex-post-facto*: tem características de estudo de caso por se concentrar em uma empresa específica e buscar compreender em profundidade seus processos; ao mesmo tempo, se aproxima da abordagem *ex-post-facto*, já que trabalha com dados previamente registrados, analisando fenômenos já ocorridos e inferindo relações entre variáveis sem intervenção direta do pesquisador. É predominantemente quantitativa, com elementos mistos, pois variáveis qualitativas foram operacionalizadas em métricas numéricas para viabilizar previsões e otimizações (GIL, 2019).

3.2 MATERIAIS E MÉTODOS

O estudo foi realizado em uma instituição de ciência e tecnologia referência no ramo de pesquisa e desenvolvimento, que também se destaca pela qualidade de seus serviços metrológicos prestados. A instituição, identificada nesse trabalho como "XYZ" por questões de confidencialidade, conta com quatro laboratórios: de metrologia dimensional (LMD), metrologia industrial (LMI), medição por coordenadas (LMC) e tomografia computadorizada (LTC). A estrutura departamental da instituição foi projetada para atender à complexidade das medições realizadas, exigindo isolamento térmico e controle de vibrações para garantir a precisão dos resultados.

A XYZ faz parte da Rede Brasileira de Calibração (RBC), ou seja, a infraestrutura e a organização interna da instituição seguem os rígidos padrões da norma ISO/IEC 17025:2017, assegurando sua competência na execução de ensaios e calibrações. Atualmente são oferecidos cerca de 100 tipos de serviços na área dimensional, com uma média de 1100 calibrações mensais.

Existem diversas formas de aplicar um modelo de ML, entretanto, as linguagens de programação surgem como uma opção ao oferecer maior flexibilidade, automatização e controle sobre o processo. Dentre elas, a linguagem *Python* se destaca como uma das melhores escolhas, pois combina simplicidade com um ecossistema robusto de bibliotecas especializadas que facilitam desde o carregamento e processamento de dados até a criação e ajuste de modelos complexos (MÜLLER; GUIDO, 2016).

Além disso, o *Python* possui integração com ferramentas interativas, como o *Jupyter Notebook*, amplamente utilizado nesta pesquisa, pois permite um fluxo ágil e interativo dos códigos, fundamental para experimentação em ML. Ainda, a possibilidade de criar interfaces gráficas, serviços web e se integrar a sistemas preexistentes torna o *Python* uma linguagem versátil, capaz de atender tanto à pesquisa quanto à implementação prática de soluções baseadas em aprendizado de máquina (MÜLLER; GUIDO, 2016).

Por se tratar de uma linguagem de programação popular no área de ciência de dados, com uma ampla comunidade de desenvolvedores trabalhando de forma *open-source*, há uma grande quantidade de bibliotecas voltadas para o desenvolvimento e aplicação de algoritmos de ML que podem ser facilmente acessadas (RASCHKA; LIU; MIRJALILI, 2022). As principais bibliotecas utilizadas durante a modelagem deste trabalho estão listadas no Quadro 3, assim como uma breve descrição e suas referências.

Quadro 3 – Lista das principais bibliotecas utilizadas

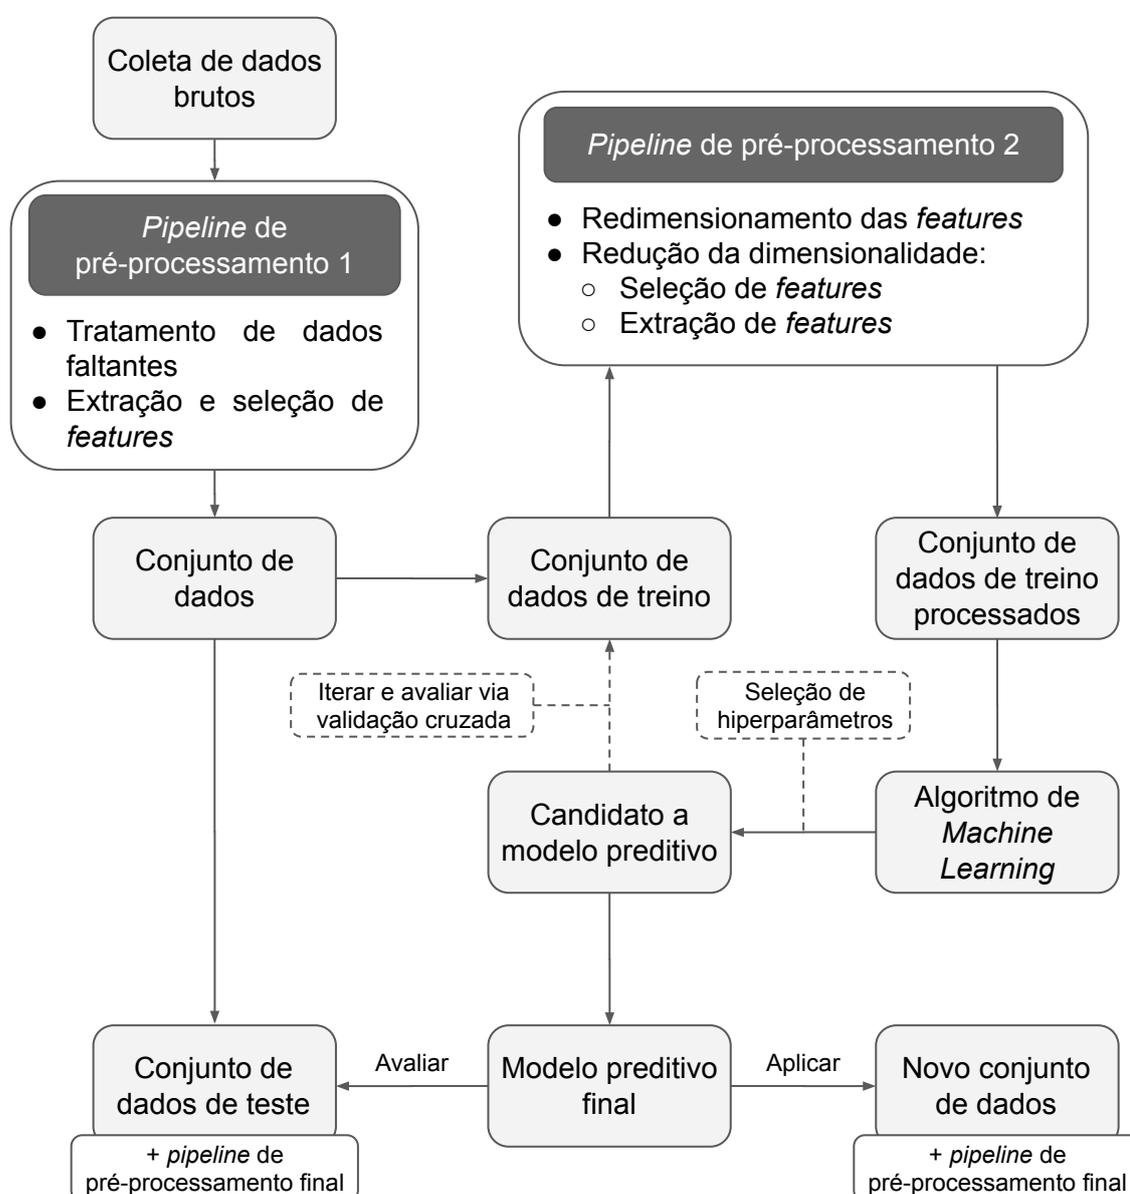
Biblioteca	Descrição	Referência
pyodbc	O pyodbc é um módulo Python de código aberto que simplifica o acesso a bancos de dados ODBC.	Kleehammer (2024)
pandas	O Pandas é uma biblioteca de código aberto, licenciada pela BSD, que fornece estruturas de dados e ferramentas de análise de dados de alto desempenho e fáceis de usar para a linguagem de programação Python.	McKinney (2010)
numpy	O NumPy é uma biblioteca de código aberto para computação numérica em Python que oferece arrays N-dimensionais eficientes e ferramentas matemáticas avançadas, sendo amplamente utilizada por sua performance e interoperabilidade em diversas plataformas.	Harris <i>et al.</i> (2020)
matplotlib	O Matplotlib é uma biblioteca abrangente para a criação de visualizações estáticas, animadas e interativas em Python.	Hunter (2007)
seaborn	O Seaborn é uma biblioteca de visualização de dados Python baseada no matplotlib. Ela fornece uma interface de alto nível para desenhar gráficos estatísticos atraentes e informativos.	Waskom (2021)
scipy	O SciPy é um software de código aberto para matemática, ciências e engenharia. Ele inclui módulos para estatística, otimização, integração, álgebra linear, transformadas de Fourier, processamento de sinais e imagens, solucionadores de EDOs e muito mais.	Virtanen <i>et al.</i> (2020)
sklearn	O Scikit-Learn é uma biblioteca de Python para aprendizado de máquina criado com base no SciPy, NumPy e Matplotlib.	Pedregosa <i>et al.</i> (2011)
shap	O SHAP (SHapley Additive exPlanations) é uma abordagem teórica de jogos para explicar o resultado de qualquer modelo de aprendizado de máquina. Ele conecta a alocação ideal de crédito com explicações locais usando os valores clássicos de Shapley da teoria dos jogos e suas extensões relacionadas.	Lundberg e Lee (2017a)
xgboost	O XGBoost é uma biblioteca otimizada de aumento de gradiente distribuído, projetada para ser altamente eficiente, flexível e portátil.	Chen e Guestrin (2016)

Fonte: Autor (2024)

3.3 PROCEDIMENTO METODOLÓGICO

O procedimento metodológico adotado para a realização desta pesquisa baseou-se no fluxo de trabalho para uso de ML em modelagem preditiva proposto por Raschka, Liu e Mirjalili (2022). Esse procedimento, apresentado na Figura 16, tem como principais componentes as etapas de condicionamento dos dados, denominadas de "*pipelines* de pré-processamento", onde as informações obtidas são analisadas e moldadas para melhorar sua adequabilidade aos modelos de ML e contexto de aplicação. As etapas para a concretização do fluxo estão descritas de forma detalhada nas subseções a seguir.

Figura 16 – Procedimento metodológico adotado



Fonte: Adaptado de Raschka, Liu e Mirjalili (2022)

3.3.1 Coleta dos dados

Os dados do laboratório foram acessados por meio de um banco de dados hospedado em um servidor que utiliza a linguagem *Structured Query Language* (SQL). Esses dados, apresentados em formato tabular, exigiam organização e exploração para se tornarem mais úteis como material de consulta. Portanto, para viabilizar essa tarefa, foi empregada a linguagem de programação *Python*, que permitiu tanto o acesso direto ao banco quanto a extração das informações disponíveis de forma estruturada.

Com os dados em mãos, foi realizada uma análise cruzada entre as diferentes tabelas presentes no SQL, com foco na identificação de colunas repetidas. A presença dessas colunas comuns indicou conexões relevantes entre os diversos conjuntos de dados, revelando pontos de intersecção e relações significativas entre as informações registradas. Por fim, foram criados *dataframes* específicos para consolidar e centralizar os dados obtidos e facilitar a manipulação dos registros dentro da plataforma de desenvolvimento de códigos.

3.3.2 Análise exploratória geral

A análise exploratória geral consiste em compreender e sintetizar as principais características do conjunto de dados em análise. Nessa fase, foram aplicadas técnicas estatísticas, além do emprego de recursos visuais, com o objetivo de identificar comportamentos, tendências e possíveis interações entre as variáveis. Esse processo proporcionou uma visão mais aprofundada dos dados, permitindo um maior entendimento do contexto no qual a pesquisa está situada. A exploração permitiu examinar a distribuição das variáveis, detectar anomalias e investigar de forma mais detalhada as relações entre as características presentes no conjunto de dados. Além disso, essa análise orientou as escolhas sobre as técnicas analíticas e modelos de *ML* mais adequadas para alcançar os objetivos da pesquisa.

3.3.3 Tratamento dos dados

Durante o processo de tratamento dos dados, diversas etapas foram realizadas para assegurar a validade das informações utilizadas na análise, sendo essas medidas voltadas para o preparo adequado dos dados de entradas de forma que não prejudiquem as etapas analíticas e modelagens subsequentes. Primeiramente, foram eliminadas as duplicatas que surgiram devido a erros no *software* de gestão do laboratório ou por pedidos repetidos registrados por diferentes colaboradores do almoxarifado, garantindo que apenas registros únicos fossem considerados, evitando assim vieses ou redundâncias.

Além disso, as colunas contendo valores numéricos e dados textuais foram identificadas e devidamente formatadas para assegurar que os códigos empregados

pudessem realizar o condicionamento correto dos dados, sem erros de leitura e inconsistências ao longo do processo. Outra etapa importante foi a exclusão dos registros de orçamento e calibração que não possuíam cliente associado. Segundo o gestor do laboratório, esses casos geralmente correspondem a cadastros incompletos de pedidos, nos quais o colaborador responsável não preencheu o nome do cliente, requisito indispensável para a emissão do certificado de calibração. Nesses cenários, é comum que o colaborador realize um novo registro completo, abandonando o anterior incompleto.

Ainda, foram removidos da análise os registros referentes a serviços de calibração prestados para universidades locais. Em certas ocasiões, o laboratório oferece esses serviços gratuitamente para alunos de graduação e pós-graduação como forma de incentivo à pesquisa. No entanto, esses registros não representam o propósito deste estudo, que tem seu foco voltado para transações comerciais, e por isso foram excluídos.

3.3.4 Divisão do conjunto de dados em subconjuntos de treino e teste

Para avaliar um modelo de ML, é comum que seja feita divisão no conjunto de dados original em dois subconjuntos derivados: subconjunto de treino e subconjunto de teste. O subconjunto de treinamento é empregado para o ajuste dos parâmetros internos do modelo, enquanto o subconjunto de validação é reservado para a verificação de sua capacidade preditiva em dados não observados previamente. Esse processo permite avaliar se o modelo apresenta capacidade de generalização, garantindo que o desempenho observado durante o treinamento não se deve exclusivamente ao aprendizado de padrões específicos ou a *overfitting* nos dados originais.

Nesta pesquisa, foi adotada uma proporção "80/20" para a divisão do conjunto de dados, em busca de um equilíbrio entre a quantidade de dados necessários para a construção do modelo e a necessidade de uma avaliação robusta de seu desempenho. Com 80% dos dados destinados ao treinamento e 20% à validação, busca-se assegurar que o modelo tenha acesso a um volume suficiente de informações para identificar padrões significativos, ao mesmo tempo em que se preserva uma amostra representativa para verificar sua eficácia em previsões futuras.

3.3.5 Pré-processamento das características (*feature engineering*)

Nesta etapa, o foco esteve na manipulação dos dados de forma contribuir para o desempenho dos modelos a serem treinados. Para isso, foram criados novos atributos, ou *features*, a partir da combinação de variáveis existentes, buscando revelar padrões e tornar o conjunto de dados mais informativo. Essa estratégia visou não apenas enriquecer o modelo, mas também garantir que ele pudesse capturar relações relevantes entre os dados, contribuindo para previsões mais precisas.

Ainda, por conta do funcionamento interno da maior parte dos modelos de ML, foi necessário realizar uma transformação das escalas dos dados de entrada. As variáveis contínuas foram convertidas para um intervalo entre 0 e 1, o que garante que todas as variáveis estejam na mesma ordem de magnitude, permitindo uma avaliação inicial do modelo com a mesma importância atribuída igualmente entre as *features* (GÉRON, 2022). As variáveis categóricas, por sua natureza binária, foram substituídas por 0 ou -1 (representando "não") e 1 (representando "sim"), para que possam fazer parte das formulações dos diferentes modelos de ML.

3.3.6 Modelagem dos algoritmos de ML

3.3.6.1 Treinamento dos modelos

Nesta etapa, três modelos de ML foram empregados: regressão logística, *Support Vector Machine* (SVM) e *XGBoost*. A escolha desses algoritmos se baseou em suas abordagens distintas na construção de modelos preditivos, garantindo diversidade nos candidatos finais. A regressão logística é amplamente utilizada para tarefas de classificação binária e fornece uma modelagem probabilística, atribuindo a cada instância uma probabilidade de pertencer a uma classe específica. Por outro lado, o SVM adota uma abordagem geométrica, procurando maximizar a margem entre as classes no espaço de características. Já o XGBoost se destaca por utilizar uma modelagem baseada em árvores de decisão, combinando múltiplas árvores de maneira iterativa e eficiente para minimizar erros residuais.

3.3.6.2 Otimização dos hiperparâmetros

A próxima etapa consistiu em ajustar os hiperparâmetros dos modelos de ML para melhorar seus desempenhos. Esse processo é realizado para garantir que o modelo alcance níveis de performance maiores ao encontrar uma combinação de hiperparâmetros adequada. O método empregado foi o *random search*, que consiste em testar combinações aleatórias de hiperparâmetros dentro de um intervalo predefinido. Embora o *random search* possa não garantir resultados tão otimizados quanto aqueles alcançados pelo método de *grid search*, ele apresenta uma implementação mais eficiente em termos de custo computacional.

No método *grid search*, todas as combinações possíveis de hiperparâmetros são testadas de forma exaustiva, garantindo que o modelo seja avaliado em todas as configurações dentro de um dado intervalo de possibilidades. No entanto, esse método pode ser inviável para espaços de busca maiores devido a escalada exponencialmente de combinações para teste. Em contrapartida, o *random search* permite explorar um intervalo mais amplo de combinações de forma aleatória, aumentando a probabilidade

de encontrar boas soluções, especialmente em espaços de busca de grande dimensão, com menor tempo de processamento.

3.3.6.3 Avaliação da importância das *features*

Esta etapa consistiu em um processo iterativo com as outras etapas do treinamento dos modelos de ML, onde avaliou-se o impacto da variação das *features* nos resultados finais de cada modelo, utilizando o método do Valor de Shapley. Essa abordagem permitiu visualizar quais variáveis de entrada do modelo possuem baixa contribuição para seu desempenho, indicando que podem estar apenas introduzindo ruído ao longo do treinamento. Ou seja, ao analisar a relevância das *features*, o Valor de Shapley fornece uma medida clara e intuitiva da influência de cada variável na predição final, garantindo maior interpretabilidade do modelo. Além disso, a metodologia permite identificar oportunidades de simplificação, eliminando variáveis redundantes ou irrelevantes, o que contribui tanto para a eficiência computacional quanto para a robustez dos resultados obtidos.

3.3.7 Análise dos resultados

O último passo consistiu em analisar os resultados dos modelos utilizando o conjunto de dados de teste, conforme apontado anteriormente. Para garantir a consistência com o processo de treinamento, o subconjunto de teste passou pelas mesmas etapas de tratamento e pré-processamento aplicadas aos dados originais. Isso permitiu que esses dados fossem adequadamente utilizados como entrada nos modelos, viabilizando a avaliação e a comparação dos resultados preditivos com os valores reais observados.

Essa análise se baseou nas métricas derivadas da matriz de confusão (Quadros 1 e 2) e as curvas ROC indicadas nas subseções 2.3.5.1 e 2.3.5.2, respectivamente. Essas métricas são importantes para medir a eficácia dos modelos ao trabalhar com dados nunca antes vistos, simulando uma situação prática de uso. A utilização dessas métricas permitiu identificar não apenas o desempenho geral, mas também os pontos fortes e fracos dos modelos em relação à capacidade de fazer previsões adequadas para o contexto de aplicação da pesquisa. A comparação entre os valores preditos e os reais revelou o grau de aderência das previsões aos padrões presentes nos dados de teste, destacando situações onde o modelo pode ter sido enviesado ou apresentado limitações.

4 RESULTADOS

O capítulo de resultados apresenta as análises e descobertas realizadas após a aplicação do procedimento metodológico. Inicialmente, foram coletados os dados e conduzida uma análise exploratória para obter uma compreensão inicial do conjunto de dados. Em seguida, os dados passaram por um processo de tratamento e pré-processamento das características, para então treinar os algoritmos de *machine learning*, com a otimização de hiperparâmetros e avaliação da importância das *features*. Por fim, os resultados obtidos foram analisados para validar as hipóteses e responder aos objetivos do estudo. Para isso, as saídas da pesquisa estão apresentados neste capítulo majoritariamente na forma de gráficos e tabelas, buscando representar as descobertas de maneira objetiva. Esses recursos visuais foram escolhidos para facilitar a compreensão das análises realizadas e evidenciar as relações entre as variáveis e o desempenho dos modelos.

4.1 COLETA DOS DADOS

A coleta de dados foi realizada utilizando a base de dados do *software* de gestão do laboratório. Esta base de dados está armazenada em um servidor SQL e pode ser acessada por meio do programa *Microsoft SQL Server Management Studio*. Nesse ambiente, é possível visualizar as várias tabelas que compõem o servidor, cada uma identificada pelo seu código específico e suas colunas de dados. Entretanto, o acesso aos dados propriamente ditos necessita de *softwares* externos, como a biblioteca *pyodbc* da linguagem *Python*.

Para iniciar a coleta, foi realizada uma análise geral do conteúdo das 248 tabelas presentes no servidor, com o objetivo de identificar a estrutura da base de dados e as relações existentes entre elas. Apesar da quantidade elevada de tabelas, percebe-se pelo Quadro 4 que a maior parte delas não possui relevância imediata, servindo apenas como tabelas de apoio ou, em alguns casos, estando sem conteúdo. Essa estrutura indica que apenas um subconjunto específico das tabelas apresenta dados diretamente relacionados para as análises planejadas.

Quadro 4 – Descrição dos tipos de tabelas presentes no servidor

Categoria	Descrição	Número de tabelas
Dados de histórico de calibração	Essas tabelas possuem registros sobre informações relacionadas a calibrações, como os serviços e data de sua realização.	10

Quadro 4 – Descrição dos tipos de tabelas presentes no servidor (conclusão)

Categoria	Descrição	Número de tabelas
Dados de clientes	Tabelas com dados referentes a clientes cadastrados no sistema, com informações como a localização da sede, porte financeiro e data do último pedido.	4
Dados de cotações	Nestas tabelas estão registrados os orçamentos realizados ao longo do tempo, com dados sobre seu valor, margem de lucro e resposta do cliente.	2
Dados de instrumentos calibrados	Tabela com informações sobre os instrumentos calibrados, como o tempo entre as principais etapas da realização do serviço.	2
Tabelas de referência	Essas tabelas não possuem um conteúdo que se atualiza com o tempo, servindo apenas de apoio com códigos de identificação para serem referenciados pelas outras tabelas.	187
Tabelas sem conteúdo	Essas tabelas se caracterizam por terem sido removidas em algum momento, entretanto, seu nome ainda consta no servidor como obsoleta.	39
Tabelas com acesso restrito	Tabelas de configuração do servidor, fechadas para usuários externos a manutenção do sistema do <i>software</i> de gestão	4

Fonte: Autor (2024)

A partir da análise das informações contidas nas tabelas e do cruzamento entre colunas, foi possível identificar e selecionar um conjunto específico de tabelas que apresentam dados relevantes e integrados, formando assim o conjunto de dados inicial para tratamento e posterior análise. A relação entre as tabelas selecionadas para o estudo está listada no Quadro 5 junto a sua descrição.

Quadro 5 – Tabelas de dados utilizadas na pesquisa

Código de identificação	Descrição	Principais informações
COTACAO	Tabela principal sobre os pedidos orçados para o laboratório.	Código do cliente, data do pedido, custo estimado do pedido e margem de lucro cobrada.
ITEMCOTACAO	Informações gerais sobre cada cotação.	Equipamentos a serem calibrados, tipo de serviço e quantia solicitada.
CLIENTE	Dados dos clientes do laboratório	Histórico de pedidos por cliente.
SITUACAOITEM	Tabela de registros sobre o estado de cada item do pedido ao longo do tempo.	Data da realização do pedido, da confirmação do valor pelo cliente e finalização da calibração.
SERVICO	Tabela de referência para os tipos de serviços oferecidos.	Código da calibração e grau de complexidade.

Fonte: Autor (2024)

Além dos dados provenientes da base histórica do laboratório, também foram levantados indicadores econômicos nacionais, pois estes desempenham um papel importante na avaliação de cenários econômicos e na prospecção de demanda, oferecendo dados objetivos para analisar a saúde financeira de setores, mercados e economias em geral. Esses indicadores, como inflação, taxa de juros, e índices de confiança, fornecem uma visão estruturada das tendências econômicas, permitindo que empresas e governos tomem decisões estratégicas com maior previsibilidade. De forma geral, um indicador pode ser definido tanto como uma medida numérica específica quanto uma descrição geral de um fenômeno econômico. A construção de um indicador envolve etapas como a definição dos fenômenos a serem analisados, os métodos de avaliação, a classificação dos dados e a identificação das fontes de informação necessárias para obter resultados abrangentes (SIBIRSKAYA *et al.*, 2019).

No cenário nacional, um dos índices mais relevantes é o Índice de Preços ao Consumidor Amplo (IPCA), calculado pelo Instituto Brasileiro de Geografia e Estatística (IBGE). O IPCA tem como objetivo medir a variação dos preços de um conjunto de bens e serviços consumidos pelas famílias com rendimentos mensais entre 1 e 40

salários mínimos, independentemente da fonte de renda (IBGE, 2024a). Esse índice serve como o principal indicador da inflação no Brasil, refletindo o custo de vida para a maior parte da população urbana. Ele é utilizado como referência tanto para a definição das metas de inflação pelo Banco Central quanto para a correção de salários, aluguéis e outros contratos (BANCO CENTRAL DO BRASIL, 2024a; SANTOS; KAPPES, 2023).

Ainda, em um contexto econômico voltado para empresas e indústrias no Brasil, destacam-se dois indicadores: a taxa Selic e o Índice de Confiança Empresarial (ICE). A taxa Selic, definida pelo Banco Central, regula o custo do crédito e influencia o comportamento do consumo e dos investimentos. Um aumento na Selic encarece o crédito e desestimula o consumo, ajudando a controlar a inflação, enquanto uma redução incentiva o crescimento econômico ao baratear o crédito. Já o ICE, índice levantado pelo Instituto Brasileiro de Economia (FGV IBRE), mede a confiança dos empresários em diferentes setores, como indústria, comércio e serviços, orientando expectativas sobre o desempenho futuro da economia. Esse índice serve como um indicativo relevante para a demanda de serviços pois influencia diretamente nas decisões de investimento e produção: otimismo geralmente impulsiona a atividade econômica, enquanto pessimismo pode levar à retração (BANCO CENTRAL DO BRASIL, 2024b; INSTITUTO BRASILEIRO DE ECONOMIA, 2024).

4.2 ANÁLISE EXPLORATÓRIA GERAL

A análise exploratória dos dados representa uma das etapas mais importantes no processo de implementação de modelos de ML. A qualidade de uma metodologia de predição adequada ao contexto de sua aplicação é diretamente proporcional ao nível de conhecimento do analista que a desenvolve. Nesse estudo, a análise exploratória serve como base para identificar e compreender os fatores que influenciam a aceitação de cotações por clientes, facilitando o desenvolvimento de um modelo que possa prever essas decisões com maior precisão.

O contexto em que essa análise se insere é particularmente influenciado pelo papel do gestor do laboratório, pois sua percepção sobre as condições do laboratório e da economia impactam diretamente na definição da margem de lucro em cada orçamento. Essa decisão, pautada em um julgamento subjetivo, adiciona uma camada complexa ao processo, pois implica que as condições para aceitação de uma cotação pelo cliente não se limitam a variáveis objetivas. A inclusão dessa perspectiva gerencial na análise permite uma visão mais abrangente das influências sobre o comportamento dos clientes, fornecendo subsídios para a construção de um modelo preditivo mais robusto e alinhado à realidade do laboratório.

Dessa forma, a análise exploratória dos dados, aliada à percepção do gestor, levou à definição das variáveis de entrada para os modelos de ML, considerando tanto aspectos objetivos quanto subjetivos. Essas variáveis refletem fatores possivelmente

relevantes para a aceitação de cotações pelos clientes, incluindo elementos operacionais do laboratório e decisões estratégicas sobre a margem de lucro, garantindo que o modelo capture de maneira abrangente as nuances do contexto analisado. As variáveis definidas foram:

- Tempo estimado médio para completar o orçamento;
- Número de calibrações em espera no laboratório;
- Número de itens no pedido;
- Complexidade média dos itens;
- Informações gerais sobre o cliente, como seu histórico de pedidos;
- Custo estimado do serviço;
- Margem de lucro aplicada sobre o custo.

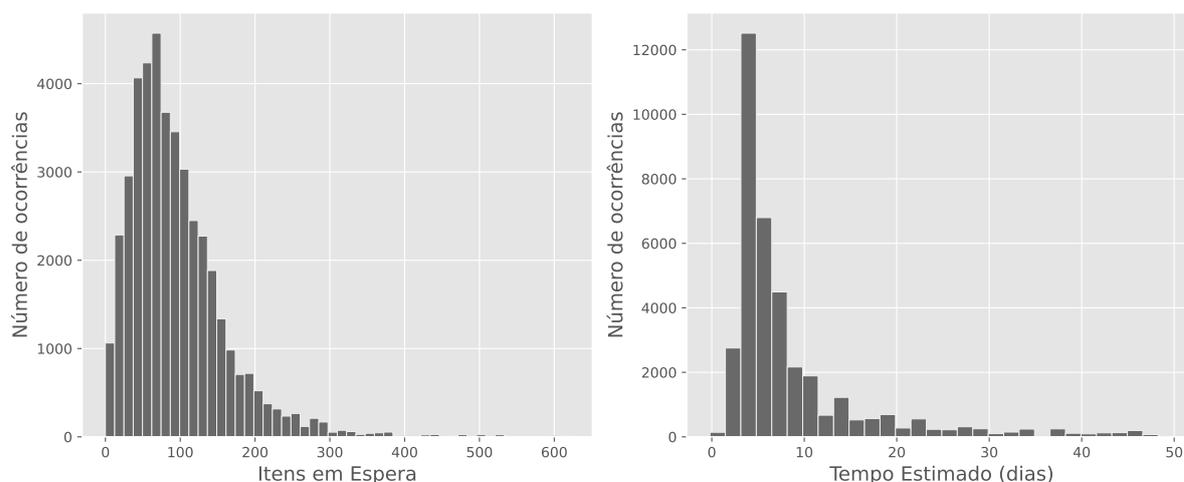
4.2.1 Variáveis relacionadas ao tempo

As duas primeiras variáveis elencadas na lista anterior foram selecionadas com o objetivo de representar uma estimativa geral do tempo necessário para a conclusão de um pedido de calibração. Para isso, o tempo médio de cada tipo de calibração foi calculado com base no histórico do banco de dados, considerando a diferença entre a data de faturamento dos pedidos e a data de finalização, conforme registrado no sistema. Essa análise fornece uma visão geral da capacidade média do laboratório ao longo do tempo, permitindo uma estimativa da duração dos processos. Por outro lado, o número de calibrações em espera no laboratório apresenta uma complexidade adicional para ser convertido em tempo exato, uma vez que o fluxo de calibrações é irregular, variando conforme a prioridade dos pedidos e a capacidade momentânea do laboratório. O comportamento geral do histórico dessas variáveis está apresentado na Figura 17.

No gráfico a esquerda da Figura 17, observa-se a distribuição do número de ocorrências associadas aos itens em espera no laboratório, onde o eixo horizontal representa a quantidade de itens aguardando atendimento ou processamento, e o eixo vertical exibe o número de vezes que essa situação ocorre. Este gráfico evidencia uma concentração significativa de itens que permanecem em estado de espera, sugerindo a existência de possíveis gargalos ou ineficiências operacionais, além de uma variabilidade relevante, indicando que o prazo para entrega de um pedido pode oscilar de forma considerável.

Já para o segundo gráfico da figura, o foco recai sobre o tempo estimado para a conclusão dos processos relacionados aos serviços metrológicos fornecidos pelo

Figura 17 – Histograma dos itens em espera e tempo médio de calibração



Fonte: Autor (2024)

laboratório. Percebe-se que uma grande parte dos itens se concentra em faixas de tempo específicas, o que aponta para um padrão de processamento ou um tempo médio de espera recorrente. Os valores na cauda direita da distribuição representam demandas específicas feitas por clientes que resultaram em uma criação de um novo serviço no sistema, aumentando consideravelmente o tempo necessário para a sua concretização, visto que a nova metodologia de calibração precisa ser desenvolvida pelos técnicos metrologistas.

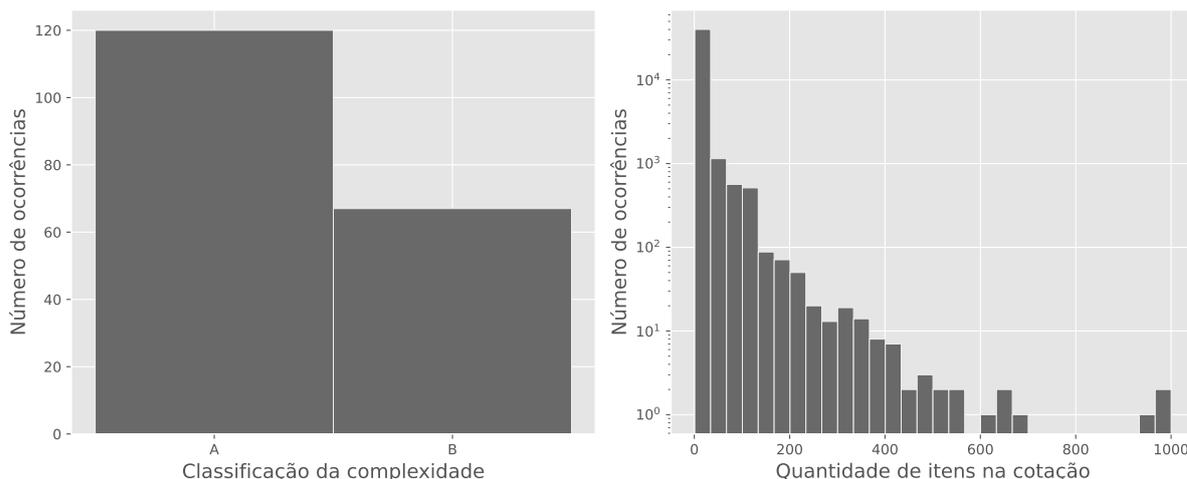
4.2.2 Complexidade das calibrações

As variáveis de número de itens no pedido e complexidade média dos itens são diretamente relacionadas à probabilidade de aceitação de uma cotação pelo cliente. Esse efeito ocorre porque calibrações mais simples, geralmente, possuem uma maior oferta de fornecedores no mercado, o que aumenta a competitividade e oferece ao cliente alternativas para escolher. Dessa forma, pedidos que envolvem calibrações menos complexas tendem a enfrentar maior concorrência, reduzindo a probabilidade de que o cliente opte por aceitar a cotação inicial oferecida pelo laboratório. Por outro lado, calibrações que demandam maior complexidade técnica e conhecimento especializado representam um diferencial competitivo para o laboratório, limitando a quantidade de fornecedores disponíveis e aumentando as chances de aceitação da cotação. Os histogramas do comportamento dessas variáveis estão presentes na Figura 18.

Dessa forma, laboratório classifica seus serviços de calibração em duas camadas de complexidade, alta e baixa, seguindo as diretrizes estabelecidas na norma ABNT NBR ISO/IEC 17025:2017 e conforme apontado pelo Instituto Nacional de Metrologia (2021) no documento normativo NIT-DICLA-026. Essa classificação é realizada com base nas partes significativas do escopo de acreditação, que abrangem aspectos

como as grandezas medidas, os métodos de ensaio e calibração, a complexidade técnica, os tipos de padrões e instrumentos utilizados, a faixa de medição, entre outros. O intuito dessa classificação surge a partir da ideia da divisão entre os diferenciais do laboratório mesmo entre seu escopo acreditado, destacando os níveis de qualidade e precisão alcançados.

Figura 18 – Histograma dos da complexidade dos serviços e quantidade histórica de itens por orçamento



Fonte: Autor (2024)

Percebe-se pela Figura 18, que há uma maior concentração das variações de serviços oferecidas pelo laboratório em um grau de complexidade alto, denotando a capacidade da instituição em lidar com calibrações de nível técnico elevado e a necessidade de padrões de referência de alta precisão. Na outra parte da figura, está destacada a quantidade de itens presentes nas cotações registradas no *software* de gestão, representada em uma escala logarítmica para melhor visualização. Esse comportamento mostra que, apesar da alta variabilidade na quantidade de itens em um pedido, a concentração está majoritariamente presente em quantias menores do que 20 itens (cerca de 90% dos casos).

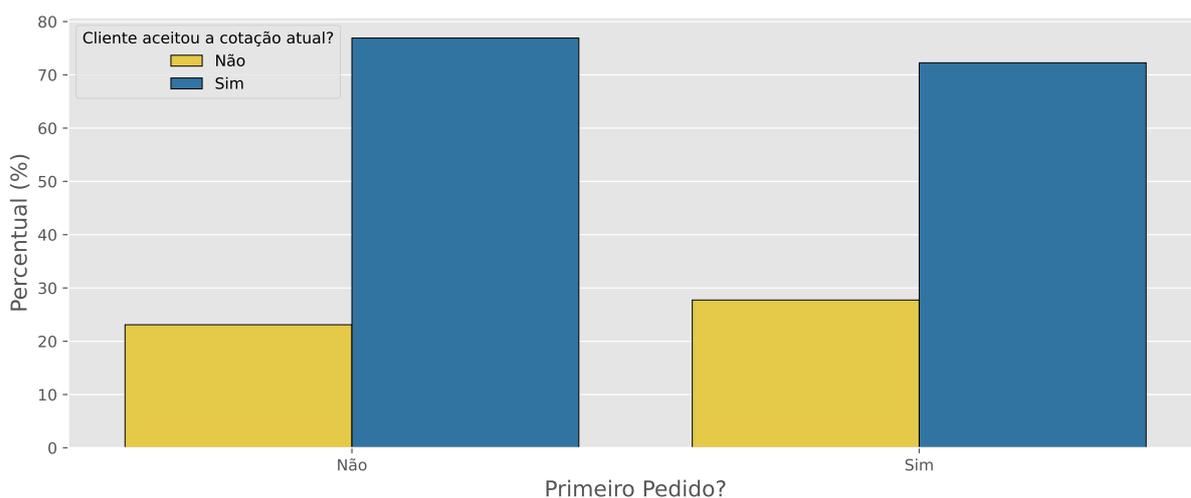
4.2.3 Histórico dos clientes

O comportamento do cliente em relação ao seu histórico de pedidos é um fator significativo que pode influenciar sua disposição para aceitar uma cotação. Esse histórico permite identificar padrões de interação e preferência, possibilitando ao laboratório antecipar a probabilidade de aceitação de novos orçamentos com base em comportamentos passados.

Clientes que realizam seu primeiro pedido podem estar mais abertos a novas cotações, devido ao interesse inicial em experimentar o serviço, ao mesmo passo em que podem estar apenas recolhendo orçamentos. Em contrapartida, clientes que já

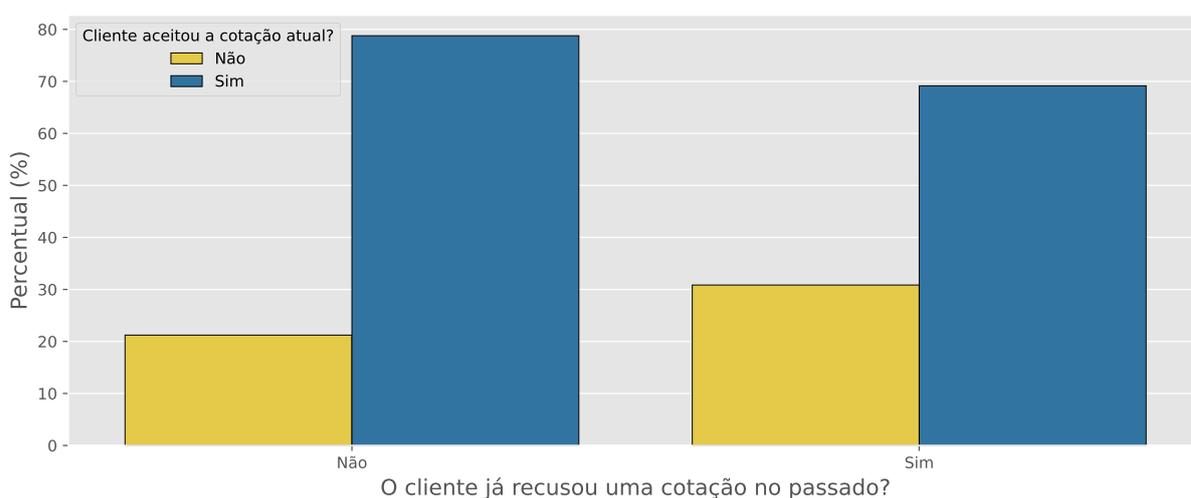
recusaram orçamentos anteriormente, especialmente o último apresentado, podem demonstrar uma tendência de menor aceitação em novas propostas, indicando uma possível insatisfação ou expectativa não atendida. A relação entre histórico do cliente e sua disposição para aceitação de um orçamento estão apresentados nas Figuras 19, 20 e 21.

Figura 19 – Relação entre o primeiro pedido e probabilidade de aceitação



Fonte: Autor (2024)

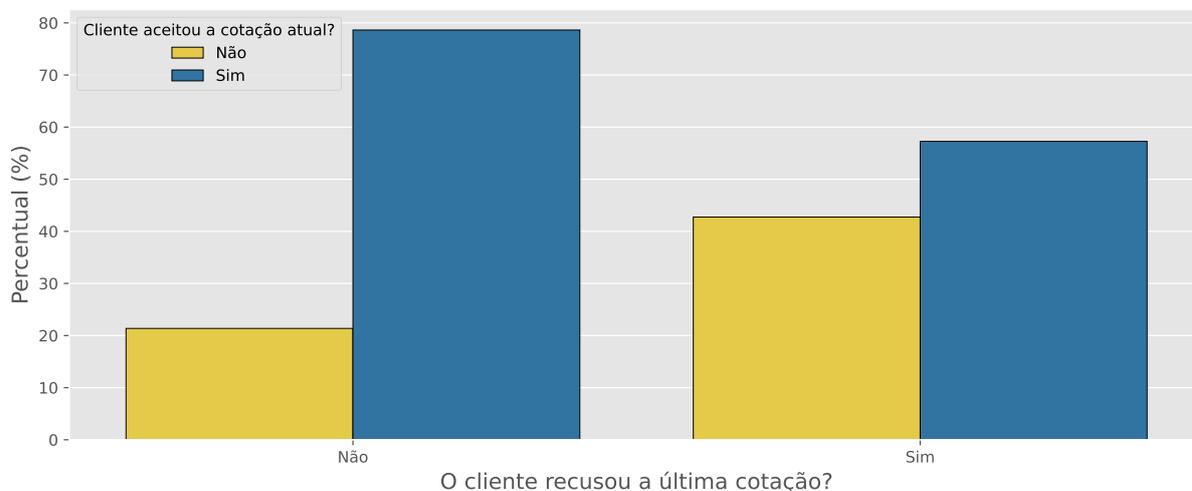
Figura 20 – Relação de probabilidade de aceitação para cliente que já recusaram um orçamento no passado



Fonte: Autor (2024)

Na Figura 19, observa-se a relação entre a probabilidade de aceitação e o fato de o cliente estar fazendo o primeiro pedido. É possível perceber que clientes que estão realizando seu primeiro pedido demonstram uma propensão levemente menor a aceitar um orçamento, mas em uma margem curta o suficiente para ser considerado uma questão de amostragem.

Figura 21 – Relação de probabilidade de aceitação para cliente que recusaram o último orçamento



Fonte: Autor (2024)

A Figura 20 explora a probabilidade de aceitação para clientes que já recusaram uma cotação no passado. A análise desse gráfico mostra que clientes com um histórico de recusa tendem a manter uma postura mais reticente em relação a novas cotações, indicando que a experiência anterior pode ter gerado alguma insatisfação ou uma expectativa não atendida. A disposição para aceitar novas propostas é significativamente menor, com uma predominância na recusa de cotações atuais entre esses clientes.

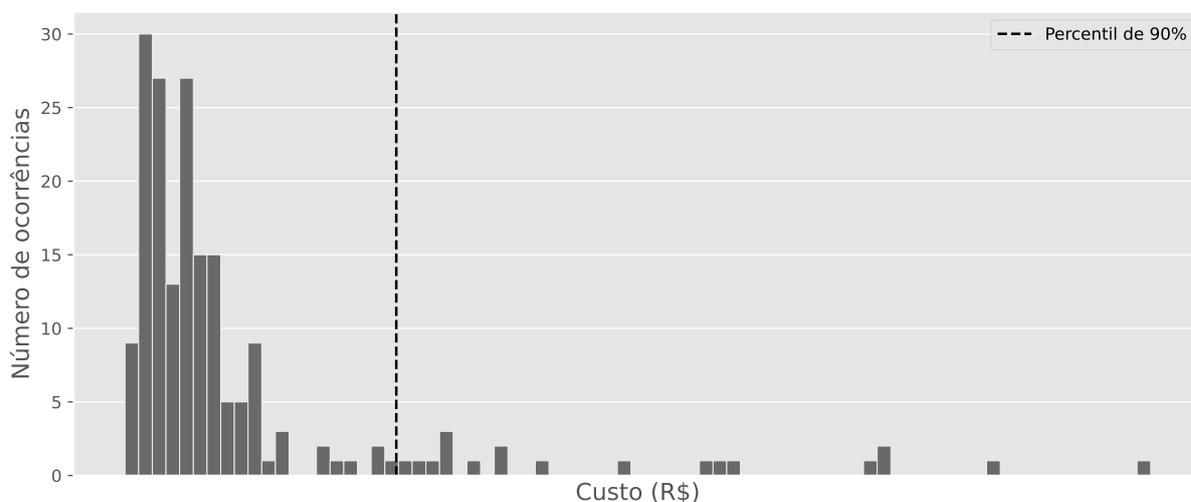
Por fim, a Figura 21 detalha a probabilidade de aceitação considerando se o cliente recusou a última cotação. A tendência de recusa é ainda mais evidente, reforçando a ideia de que a experiência mais recente de recusa influencia negativamente a disposição para novas aceitações. Esse padrão pode sugerir uma insatisfação persistente ou uma falta de alinhamento entre o que o cliente espera e o que foi oferecido, destacando a importância de um acompanhamento e entendimento das expectativas do cliente para melhorar a taxa de aceitação futura.

4.2.4 Custo e margem de lucro

O custo é um dos principais elementos que compõem o valor final oferecido ao cliente e, portanto, desempenha um papel importante na decisão de aceitar ou recusar uma cotação. Esse valor representa o montante necessário para cobrir os gastos envolvidos no processo de calibração, incluindo recursos materiais, como materiais de limpeza e manutenção, e mão de obra. Atualmente, o banco de dados do laboratório conta com uma estimativa geral de gastos para cada tipo de serviço, conforme indicado pela Figura 22.

Os valores de custo absolutos foram ocultados no gráfico para garantir a confidencialidade das informações financeiras do laboratório. Mesmo com essa precaução,

Figura 22 – Histograma do custo das cotações



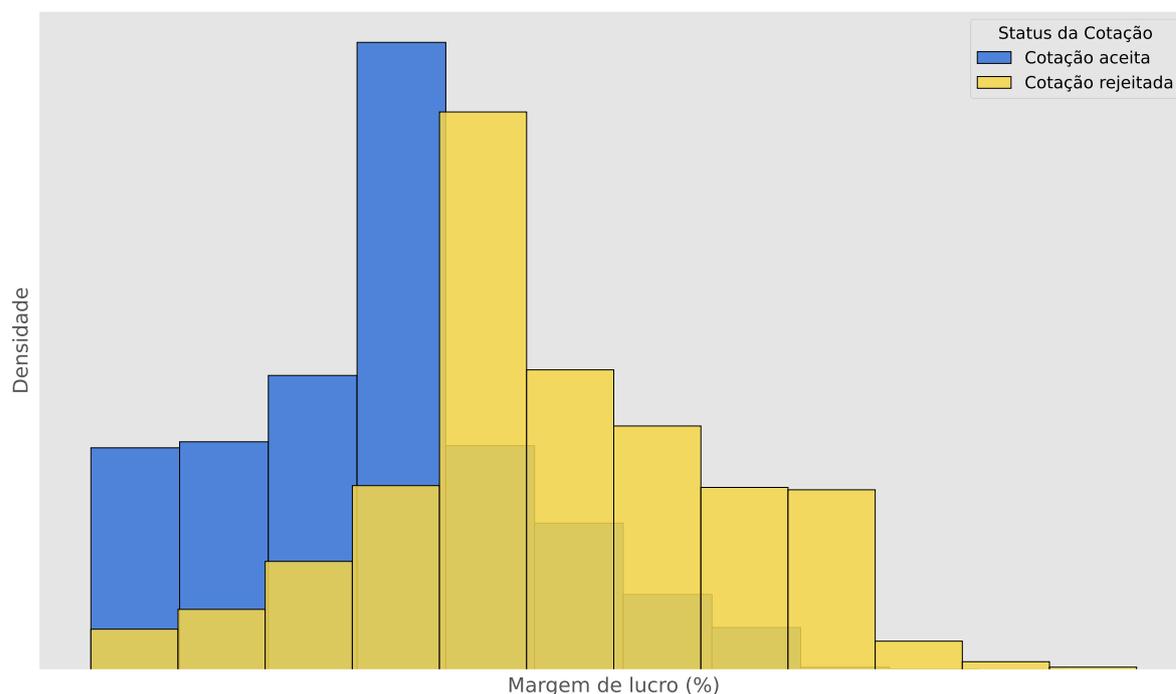
Fonte: Autor (2024)

a análise permite inferir que o laboratório possui uma gama diversificada de serviços, com variações consideráveis nos custos, indicadas pela cauda a direita do gráfico. Entretanto, seu comportamento denota uma distribuição concentrada em valores mais baixos, com uma quantidade significativa de calibrações ocorrendo em faixas de menor custo. Portanto, apesar da alta variabilidade, a análise pode ser simplificada para a seção de maior representatividade do laboratório, como a seção ilustrada na figura pelo percentil de 90%, onde as calibrações fazem parte de um portfólio já conhecido e rotineiro.

Além do custo, a margem de lucro adicionada pelo gestor do laboratório é um fator determinante para o preço final apresentado ao cliente. Atualmente, essa margem é definida em intervalos fixos de 5%, o que reflete uma certa limitação na capacidade de ajuste do valor para cada cliente e situação específica. Essa abordagem restritiva, subsidiada por um julgamento subjetivo, pode afetar a percepção de valor do cliente e, em alguns casos, reduzir as chances de aceitação do orçamento. A relação de margem de lucro de acordo com a resposta do cliente está indicada na Figura 23.

Assim como para o custo, a margem de lucro também teve seus valores absolutos removidos do gráfico por questões de confidencialidade. Apesar dessa remoção, a figura mostra de forma clara uma distinção entre as distribuições de margem de lucro aplicadas a uma cotação quando separadas pela resposta do cliente. Observa-se que há uma diminuição da probabilidade de aceite do cliente conforme as margens de lucro aumentam, com uma zona de transição situada no meio do caminho.

Figura 23 – Histograma das margens de lucro de acordo com a resposta do cliente



Fonte: Autor (2024)

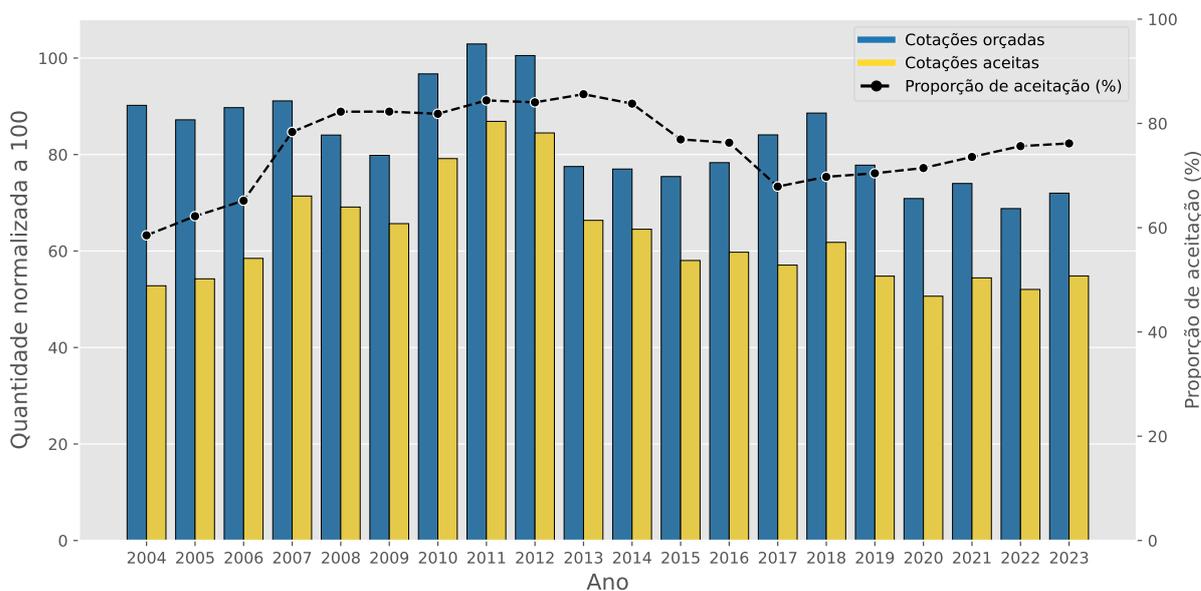
4.2.5 Demanda do laboratório ao longo do tempo

Outro fator relevante para a modelagem do algoritmo consiste na análise do comportamento da demanda do laboratório no tempo. As variações relacionadas a determinados períodos do ano e fatores externos circunstanciais tendem a influenciar diretamente o comportamento dos clientes frente a decisão de adquirir, ou não, um serviço. Para analisar uma escala geral da conversão de cotações do laboratório em serviços efetivados, utilizou-se um gráfico de barras, apontado na Figura 24.

Percebe-se pelo histórico presente na imagem que o laboratório oscilou nas últimas duas décadas entre uma margem de 60% e 80% de conversão dos orçamentos em serviços, com uma subida lenta nos últimos anos. Outro ponto que chama atenção é a baixa significativa após o ano de 2012, com uma queda da taxa de conversão, que volta a subir apenas em 2018. Também é possível perceber o efeito da pandemia no ano de 2020, onde houve uma queda da demanda por serviços de metrologia por conta da incerteza econômica da época, entretanto, a conversão das cotações em calibrações efetuadas seguiu seu ritmo dos anos anteriores e continuou a crescer mesmo no cenário citado.

Essas flutuações na demanda do laboratório ao longo do tempo podem ser explicadas, em parte, por fenômenos externos, sendo evidenciadas quando comparadas a indicadores econômicos, como a taxa Selic, o Índice de Confiança Empresarial e a cotação do dólar. A taxa Selic, que influencia diretamente o custo do crédito, pode

Figura 24 – Histórico de conversão de pedidos em serviços



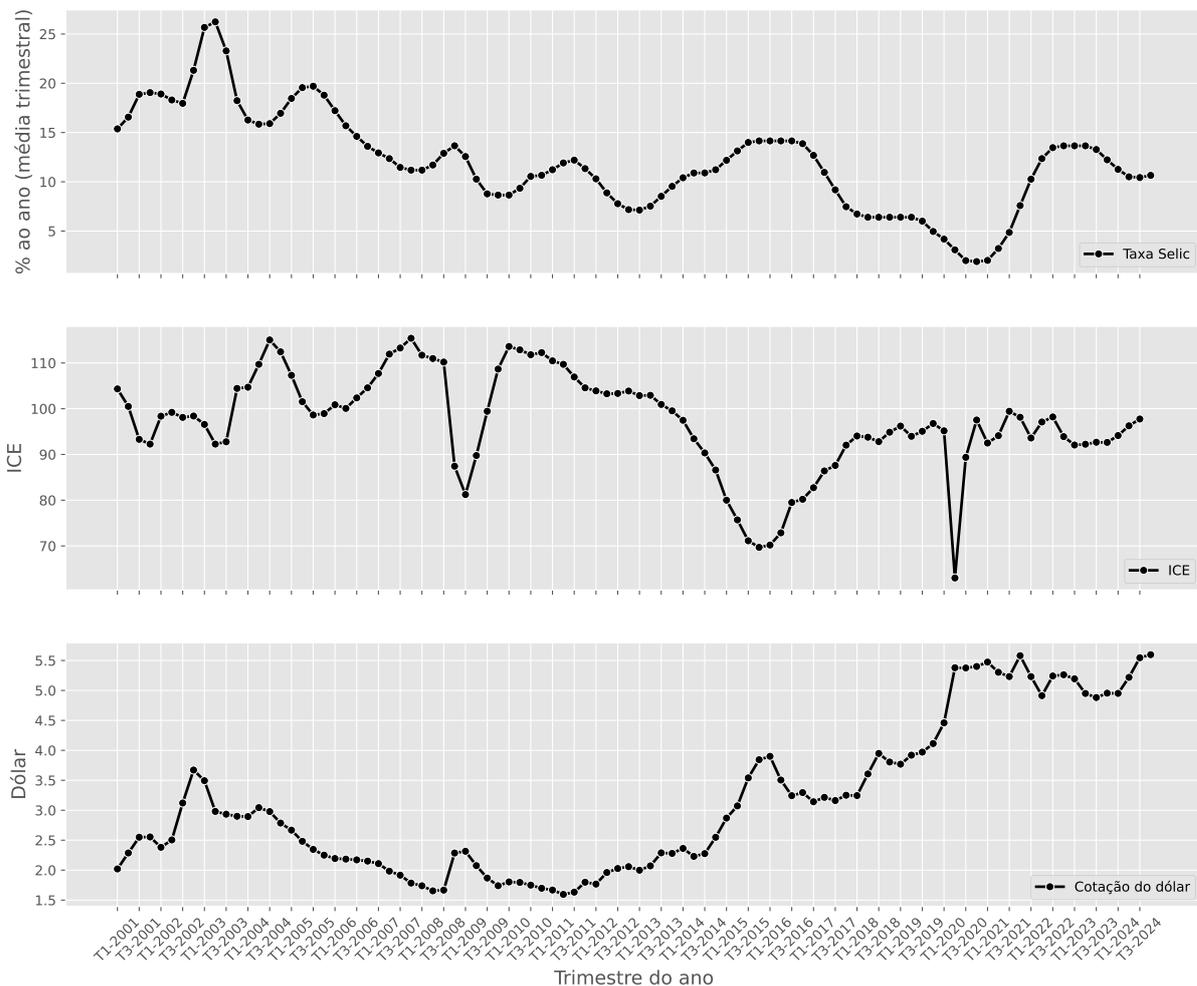
Fonte: Autor (2024)

impactar a capacidade das empresas de investir em serviços de metrologia, pois períodos de alta na Selic costumam reduzir a propensão das empresas a gastos não essenciais. Já o ICE, que mede o nível de confiança dos empresários na economia, tende a influenciar as decisões de investimento em serviços em períodos de alta incerteza econômica. E, por fim, a cotação do dólar serve como um termômetro geral da economia ao reagir a acontecimentos globais que impactam o país e também a situações econômicas internas, como a mudança de políticas fiscais. As séries temporais desses indicadores estão apontadas na Figura 25.

Ainda, para um entendimento mais completo da demanda do laboratório, além da análise geral ao longo dos anos, faz-se necessário explorar também as flutuações mensais. Ao examinar a demanda em uma escala mais específica, como a variação mês a mês, é possível identificar padrões sazonais e tendências que poderiam passar despercebidas em uma análise anual. Essa análise se mostra relevante pois um comportamento do cliente atrelado ao período do ano no qual ele efetua o seu pedido pode ser um ponto alvo para que a gestão estratégica do laboratório atue. A média de cotações orçadas em cada mês está indicada na Figura 26.

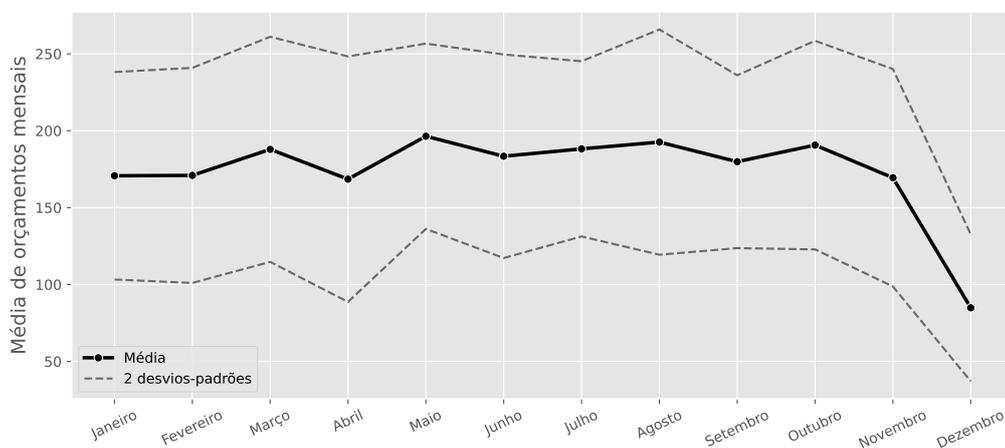
A figura representa uma média realizada para cada mês do ano entre 2004 e 2023, indicando também um intervalo baseado em dois desvios-padrões com os dados daquele mês. Percebe-se pelo gráfico que o laboratório mantém um nível de demanda por serviços relativamente constante na maior parte do ano, com poucas oscilações aparentes. Entretanto, o período do final do ano, principalmente em dezembro, apresenta uma queda brusca da demanda, caindo para uma média de menos de 100 contatos por serviços ao longo do mês, enquanto a maior parte do ano se

Figura 25 – Séries temporais da taxa Selic, ICE e cotação do dólar por média trimestral



Fonte: Autor (2024)

Figura 26 – Média de orçamentos a cada mês



Fonte: Autor (2024)

situa em cerca de 170 contatos. Esse comportamento abre margem para a avaliação da influência do mês do ano na modelagem do algoritmo de previsão, conforme será apresentado nas próximas subseções.

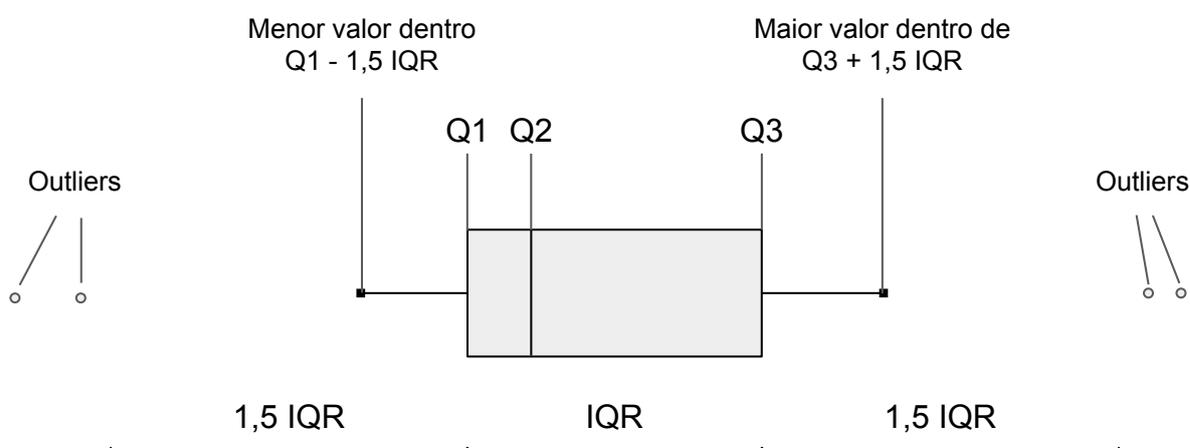
4.3 TRATAMENTO INICIAL DOS DADOS

Nesta etapa foram realizadas limpezas da base de dados, para garantir a consistência das informações a serem analisadas. Primeiramente, procedeu-se com a remoção de duplicatas, eliminando entradas redundantes que poderiam causar distorções nos resultados. Esse passo assegura que cada registro seja único, evitando que repetições interfiram nas análises de forma a tornar o modelo superajustado.

Além disso, foram identificados e removidos campos sem valores, também conhecidos como nulos. A presença de dados incompletos poderia comprometer a precisão dos resultados, uma vez que lacunas podem gerar interpretações equivocadas e introduzir incertezas na modelagem. Também faz-se necessário remover esses valores para que os algoritmos de ML consigam lidar com os dados de entrada sem problemas.

Por fim, aplicou-se o conceito do intervalo interquartil (IQR) para remover os *outliers* das variáveis obtidas. O conceito de IQR consiste na avaliação de um intervalo de valores representativos, analisando o comportamento de uma variável em grupos percentuais. Em um diagrama de caixa, o IQR é a área central do gráfico, entre o primeiro quartil (Q1) e o terceiro quartil (Q3), que representa a maioria dos dados. As extremidades mostram o alcance dos dados até 1,5 vezes o IQR. Valores além disso são considerados *outliers*, enquanto aqueles mais distantes (acima de 3 vezes o IQR) são chamados de *outliers* extremos (MONTGOMERY; RUNGER, 2020).

Figura 27 – Representação do visual do intervalo interquartil



Fonte: Adaptado de Montgomery e Runger (2020)

Após a aplicação do IQR para identificar e remover *outliers*, houve uma redução

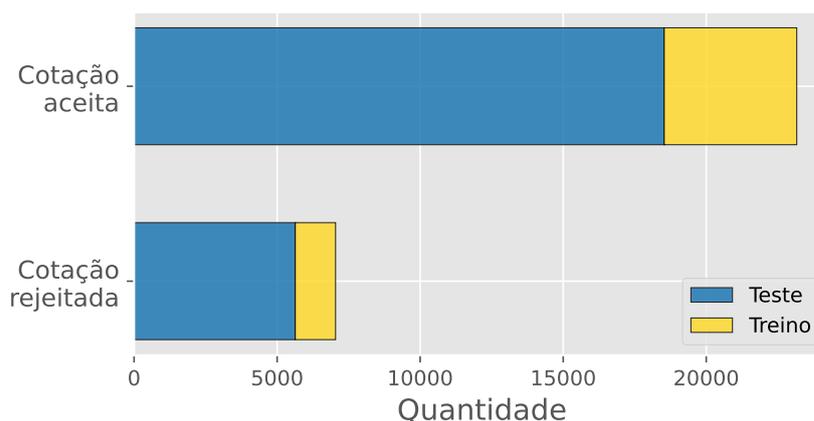
significativa no conjunto de dados, diminuindo de 41.765 para 30.206 registros. Essa limpeza representou uma redução de aproximadamente 27,7% no volume total de dados, que, apesar de expressiva, permite que os modelos de ML consigam definir de forma mais precisa as relações entre variáveis de entrada e saídas desejadas.

4.4 SEPARAÇÃO DOS DADOS EM SUBCONJUNTOS DE TREINO E TESTE

Em seguida, o conjunto de dados de entrada filtrados foi dividido em subconjuntos de treino e teste, em uma proporção de 80% e 20%, respectivamente. Essa etapa foi realizada para garantir que o modelo pudesse generalizar adequadamente ao ser exposto a novos dados, minimizando a possibilidade de superajuste aos dados de treinamento. A divisão dos dados em conjuntos de treino e teste permite avaliar o desempenho do modelo em dados que ele ainda não viu, fornecendo uma métrica mais confiável sobre sua capacidade de prever corretamente em situações reais.

Para realizar divisão, levou-se em consideração a natureza da variável objetivo da predição, que representa o aceite ou não de um pedido. Conforme apontado na Seção 4.2.5, há um desequilíbrio entre o número de pedidos aceitos e rejeitados pelos clientes, havendo uma predominância do resultado positivo. Esse desequilíbrio pode dificultar a avaliação precisa do modelo, uma vez que ele poderia se inclinar a favorecer a classe majoritária. Para lidar com essa questão, foi realizada uma amostragem proporcional entre as classes, conforme apontado na Figura 28.

Figura 28 – Divisão proporcional do conjunto de dados em subconjuntos de treino e teste



Fonte: Autor (2024)

4.5 PRÉ-PROCESSAMENTO DOS DADOS

Nesta etapa, aplicaram-se transformações as variáveis de entrada quantitativas, para que estejam todas na mesma escala, facilitando o aprendizado dos modelos

de ML. Muitos algoritmos não apresentam bom desempenho quando suas *features* possuem escalas muito discrepantes, o que pode distorcer os resultados e o foco do modelo (GÉRON, 2022).

Dentre as técnicas utilizadas para esse fim, destaca-se o escalonamento *min-max*, que redimensiona os valores de cada variável para um intervalo específico, geralmente entre 0 e 1, o que ajuda o modelo a interpretar os dados de maneira uniforme, evitando que uma característica com escala maior influencie mais do que outras com escalas menores. O escalonamento *min-max* utilizado para deixar as variáveis adimensionais e equiparáveis está proposto na Equação 10.

$$X_{escalonado} = \frac{X_{original} - X_{mínimo}}{X_{máximo} - X_{mínimo}} \quad (10)$$

Para as variáveis qualitativas, como as referentes ao histórico do cliente, optou-se por transformá-las em variáveis binárias, iguais a 0 e 1, representando as atribuições negativas e positivas daquela variável, respectivamente. A Figura 29 apresenta a distribuição de valores das variáveis do conjunto de dados processado após a normalização.

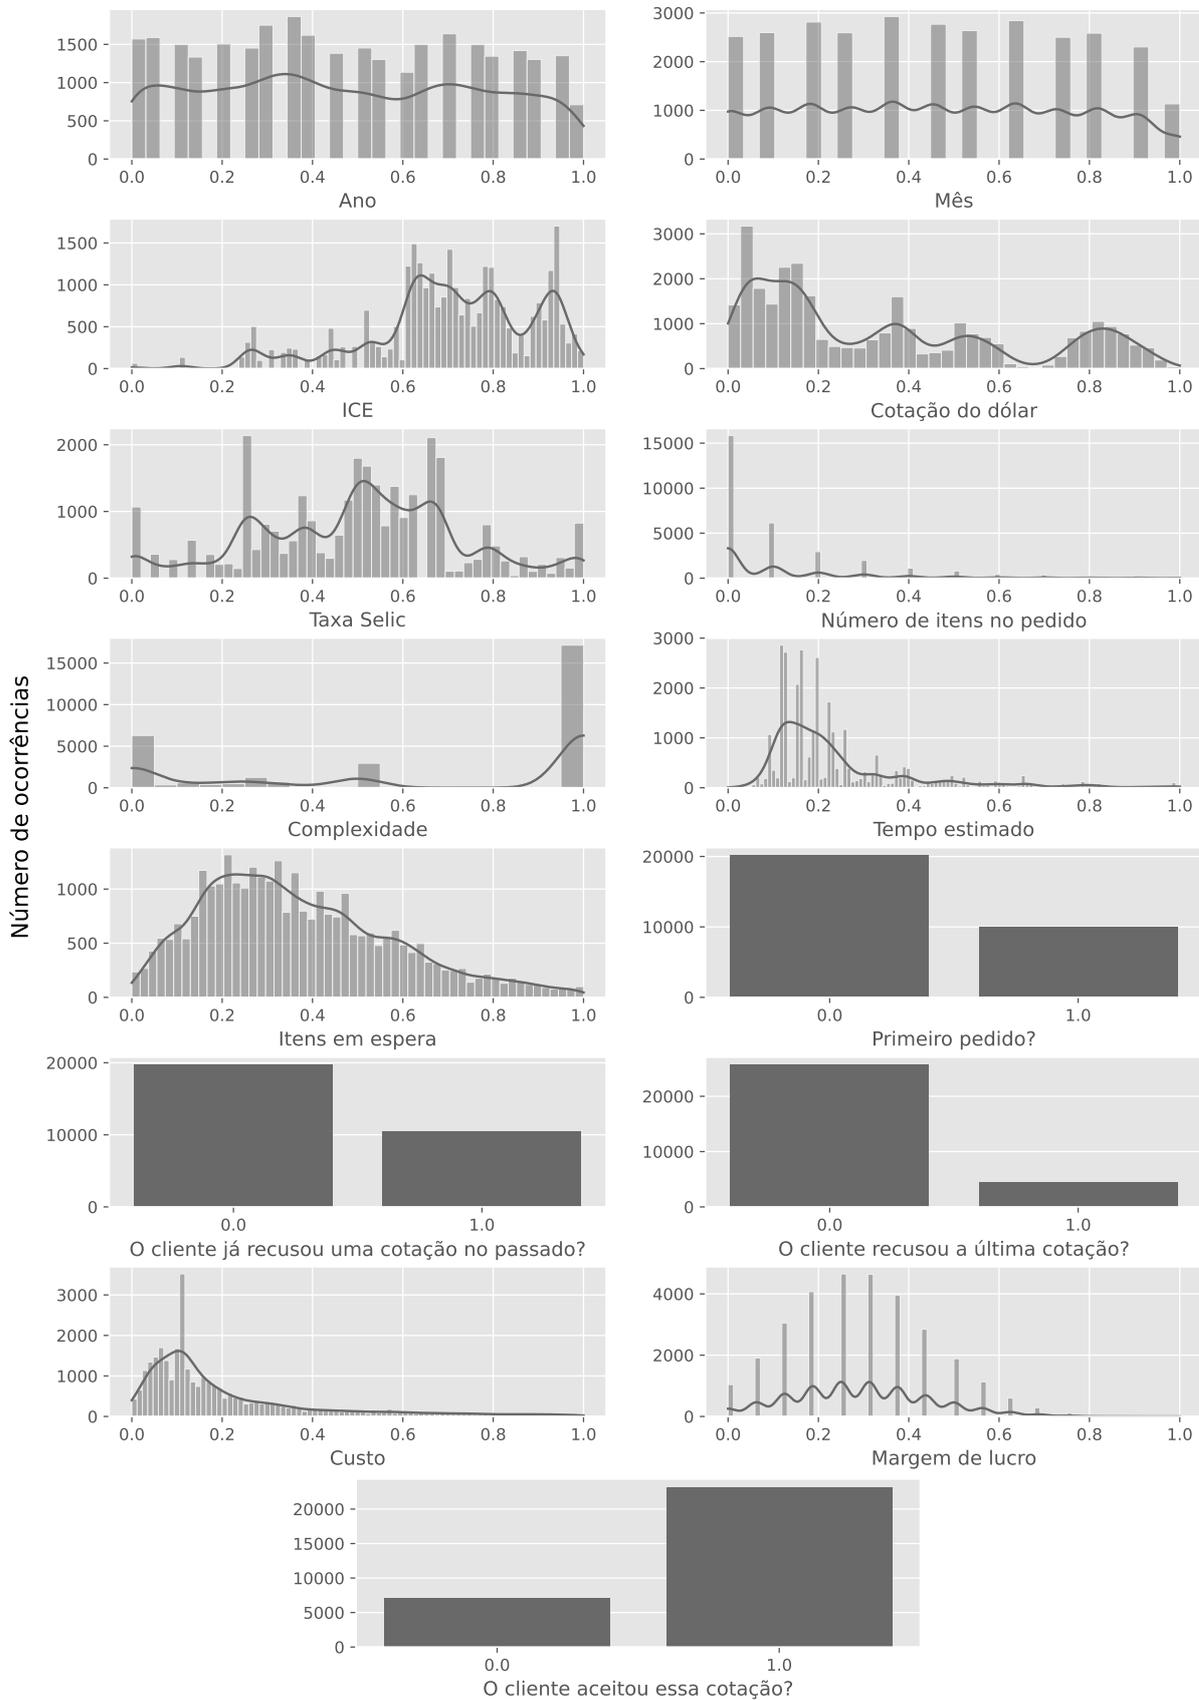
Além da normalização, transformações específicas foram aplicadas a algumas variáveis para refiná-las como características associadas a uma determinada cotação. Por exemplo, a variável de complexidade, que reflete a característica de cada tipo de calibração, foi transformada em uma média ponderada das calibrações de um pedido, com pesos correspondentes à quantidade de cada tipo de calibração. Dessa forma, uma pontuação de complexidade próxima a 1 indica que a maioria das calibrações está classificada com alta complexidade, enquanto uma pontuação próxima a 0 sugere uma cotação predominantemente de complexidade baixa.

Outra variável que passou por um processamento distinto foi o tempo estimado de uma cotação. Para isso, escolheu-se o maior tempo dentre todos os itens da cotação após multiplicado pela sua quantidade, uma vez que as cotações geralmente têm seus serviços executados em paralelo, sendo sujeitas ao gargalo da calibração mais demorada.

4.6 OTIMIZAÇÃO DE HIPERPARÂMETROS

Durante o treinamento dos modelos de ML, foi empregado o método *random search* para estimar o ponto ótimo dos hiperparâmetros e melhorar o desempenho de cada algoritmo. A escolha do *random search*, em vez do método *grid search*, se justificou pelo custo computacional significativamente menor. Enquanto o *grid search* explora todas as combinações possíveis de hiperparâmetros, o que pode ser altamente demorado e inviável para grandes espaços de busca, o *random search* faz uma amos-

Figura 29 – Dados do *dataset* normalizados e adimensionais



Fonte: Autor (2024)

tragem aleatória, permitindo que se explore uma variedade suficiente de combinações de forma mais eficiente.

Nesta etapa, utilizou-se a métrica de AUC, descrita na seção Seção 2.3.5.2, como referência para avaliar e encontrar o ponto ótimo para cada modelo. Essa métrica foi escolhida por sua capacidade de medir a performance de classificação de forma robusta, diminuindo os vieses de determinadas métricas quando analisadas isoladamente. Os intervalos de teste para os hiperparâmetros de cada modelo, assim como o ponto ótimo encontrado, estão apresentados nas Tabelas 1, 2 e 3.

Tabela 1 – Resultados da otimização de hiperparâmetros para a regressão logística

Hiperparâmetro	Intervalo	Ponto ótimo
<i>penalty</i>	['l1', 'l2', 'elasticnet', 'none']	'l1'
<i>C</i>	[-10, 10]	4,7368
<i>solver</i>	['newton-cg', 'lbfgs', 'liblinear', 'sag', 'saga']	'saga'
<i>max_iter</i>	[50, 100, 200, 500]	500
<i>l1_ratio</i>	[0, 1]	0,3333
<i>fit_intercept</i>	[True, False]	True
<i>dual</i>	[True, False]	False
<i>intercept_scaling</i>	[1, 10, 100]	10
<i>multi_class</i>	['auto', 'ovr', 'multinomial']	'auto'
<i>tol</i>	[1e-4, 1e-3, 1e-2, 1e-1]	1e-4
<i>verbose</i>	[0, 1, 2]	1
<i>warm_start</i>	[True, False]	True

Fonte: Autor (2024)

Tabela 2 – Resultados da otimização de hiperparâmetros para o *XGBoost*

Hiperparâmetro	Intervalo	Ponto ótimo
<i>n_estimators</i>	[50, 100, 200, 300, 500]	50
<i>max_depth</i>	[3, 5, 7, 10, 15]	3
<i>learning_rate</i>	[0, 2, 4, 6, 8, 10]	2

Tabela 2 – Resultados da otimização de hiperparâmetros para o *XGBoost* (conclusão)

Hiperparâmetro	Intervalo	Ponto ótimo
<i>subsample</i>	[0,5, 0,7, 0,8, 0,9, 1]	0,9
<i>colsample_bytree</i>	[0,5, 0,7, 0,8, 0,9, 1]	0,9
<i>colsample_bylevel</i>	[0,5, 0,7, 0,8, 0,9, 1]	0,9
<i>colsample_bynode</i>	[0,5, 0,7, 0,8, 0,9, 1]	0,8
<i>gamma</i>	[0, 0,1, 0,3, 0,5, 1]	0
<i>min_child_weight</i>	[1, 3, 5, 7]	7
<i>reg_alpha</i>	[0, 20]	17,8947
<i>reg_lambda</i>	[0, 20]	17,8947
<i>eval_metric</i>	['mlogloss', 'auc']	'auc'

Fonte: Autor (2024)

Tabela 3 – Resultados da otimização de hiperparâmetros para o SVM

Hiperparâmetro	Intervalo	Ponto ótimo
<i>C</i>	[-3, 3]	0
<i>kernel</i>	['linear', 'poly', 'rbf', 'sigmoid']	'rbf'
<i>degree</i>	[2, 3, 4, 5]	4
<i>gamma</i>	['scale', 'auto']	'scale'
<i>coef0</i>	[0, 0,1, 0,5, 1, 2]	2
<i>shrinking</i>	[True, False]	False
<i>tol</i>	[1e-4, 1e-3, 1e-2, 1e-1]	1e-1
<i>max_iter</i>	[-1, 100, 200, 500]	-1

Fonte: Autor (2024)

4.7 ANÁLISE DE RESULTADOS

Primeiramente, os algoritmos de ML foram treinados e comparados ao subconjunto de testes utilizando os hiperparâmetros *default* das suas respectivas bibliotecas.

Essa etapa serviu para avaliar o desempenho inicial dos modelos quando não há a interação do usuário nos parâmetros do treinamento. Posteriormente, os algoritmos foram treinados repetidas vezes com a variação dos hiperparâmetros de forma a encontrar o ponto que resultasse na maior AUC (área sob a curva ROC) para cada modelo. O resultado desses treinamentos está indicado nas Tabelas 4 e 5, com as métricas para cada modelo.

Tabela 4 – Resumo do desempenho dos modelos

Modelo	Acur.	Espec.	Prec.	Revoc.	Med. F
Regressão logística	0,7192	0,7044	0,8880	0,7237	0,7975
Regressão logística (otimizada)	0,7188	0,7053	0,8882	0,7230	0,7971
<i>XGBoost</i>	0,7258	0,6982	0,8874	0,7343	0,8036
<i>XGBoost</i> (otimizado)	0,7376	0,7079	0,8922	0,7467	0,8130
SVM	0,8077	0,3579	0,8268	0,9466	0,8827
SVM (otimizado)	0,7167	0,7105	0,8894	0,7186	0,7949

Fonte: Autor (2024)

Com base nos resultados apresentados na Tabela 4, observa-se que, de forma geral, os modelos tiveram desempenhos muito próximos na maior parte das métricas. No entanto, a otimização dos hiperparâmetros teve um impacto variado entre os modelos a partir de diferentes tipos de correções, mas podendo ser generalizada como benéfica no quesito de balanceamento dos algoritmos. Os modelos de regressão logística e SVM, por exemplo, demonstraram uma melhoria no equilíbrio das métricas após a otimização dos hiperparâmetros. Esse ajuste ajudou a alinhar os resultados dos modelos, que passaram a se tornar mais uniformes nas suas versões otimizadas.

Entretanto, o modelo SVM apresentou um desbalanceamento significativo das métricas em seu primeiro treino (sem otimização), onde houve uma tendência do modelo em classificar as cotações predominantemente como aceitas. Essa inclinação resultou em uma elevação das métricas de acurácia, precisão e revocação, mas deixou a especificidade consideravelmente baixa, evidenciando o desbalanceamento na proporção entre as classes. Por outro lado, o modelo de *XGBoost* teve um aumento geral em suas métricas após a otimização, indicando que essa melhoria nos hiperparâmetros resultou em um modelo objetivamente superior em relação ao seu desempenho inicial. Essa evolução sugere que o *XGBoost* responde bem à variação dos hiperparâmetros, destacando sua sensibilidade as entradas do usuário e resultando em um desempenho mais robusto após o ajuste.

A Tabela 5 apresenta os valores encontrados de AUC para cada rodada de treinos, com os hiperparâmetros originais e os hiperparâmetros encontrados para

otimizar o seu valor.

Tabela 5 – Área sob a curva para os modelos *default* e otimizados

Modelo	AUC (modelo <i>default</i>)	AUC (modelo otimizado)
Regressão logística	0,7888	0,7889
XGBoost	0,7881	0,7982
SVM	0,7913	0,7925

Fonte: Autor (2024)

Após a otimização dos hiperparâmetros, os modelos apresentaram um aumento ligeiro nos valores de AUC, conforme apontado na tabela. Esse ganho marginal reflete a sensibilidade dos modelos de classificação aos ajustes em seus parâmetros, mas também indica que, embora a otimização melhore a curva de probabilidade de cada um, o impacto final na métrica AUC pode ser limitado após a conversão das probabilidades em classes. Isso ocorre porque a AUC mede a área sob a curva ROC, e ajustes finos nos hiperparâmetros costumam afetar apenas uma região de transição entre as classes, tendo pouca influência nas previsões situadas no extremo das probabilidades.

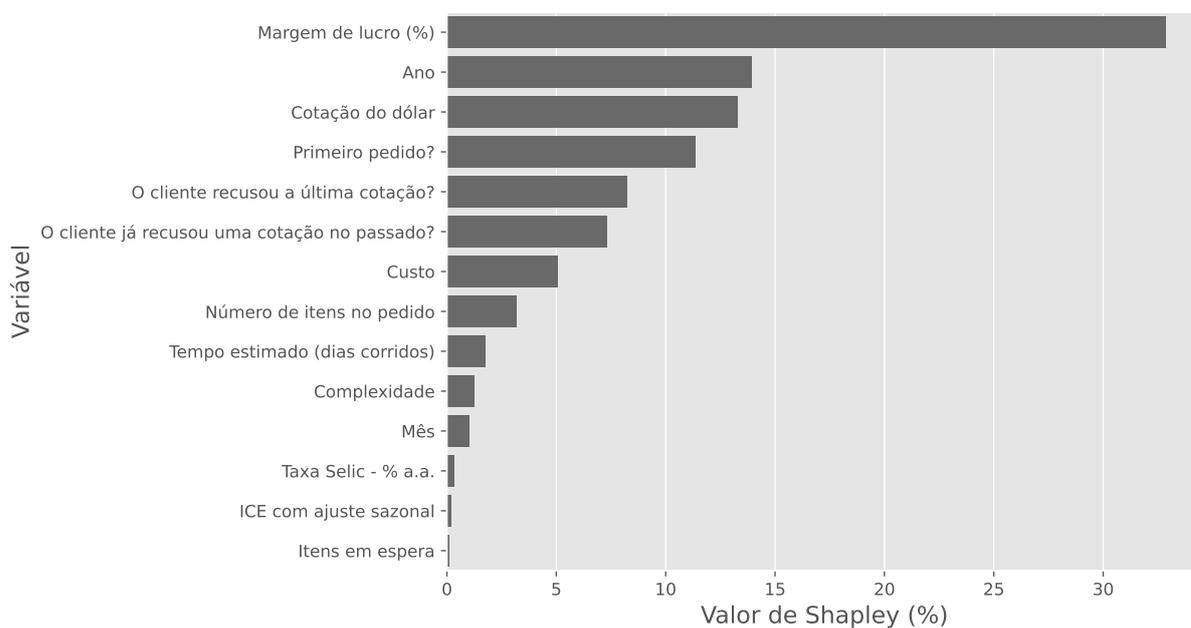
No entanto, destaca-se o comportamento do modelo *XGBoost*, que inicialmente tinha o menor valor de AUC e demonstrou uma resposta notável à otimização dos hiperparâmetros, superando os outros dois modelos após o ajuste. Isso destaca ainda mais a sensibilidade do *XGBoost* à configuração de seus parâmetros, confirmando que a otimização permitiu um ajuste mais eficaz na curva de probabilidade, refletindo-se na melhora da capacidade de discriminação entre as classes.

Na sequência, foi realizada a aplicação do Valor de Shapley para aumentar a interpretabilidade dos modelos otimizados. Esse passo permitiu a visualização da contribuição de cada variável para os resultados dos modelos, evidenciando os fatores mais influentes nas previsões, conforme apontado nas Figuras 30, 31 e 32.

A análise dos Valores de Shapley para os três modelos revela que a margem de lucro é consistentemente a mais influente em todos os casos, sendo responsável pela maior contribuição na previsão das classes. Isso destaca a relevância do preço das cotações como um fator preditivo fundamental, justamente por representar a atratividade econômica das cotações.

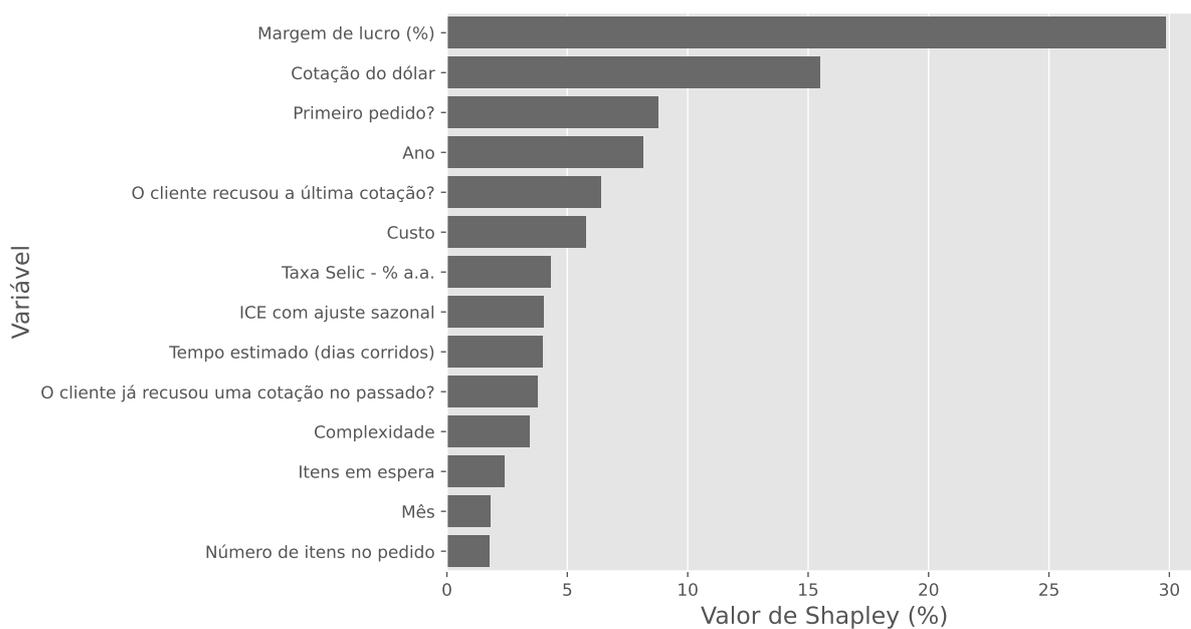
Além da margem de lucro, outras variáveis que frequentemente apareceram entre as primeiras colocações foram a cotação do dólar, o ano do pedido, a condição de primeiro pedido e a última resposta do cliente a uma cotação. Essa combinação sugere que os modelos valorizam fatores macroeconômicos, como variações cambiais e temporais, e o comportamento dos clientes como seus principais explicadores. Entretanto, a oscilação de demanda mensal do laboratório se mostrou pouco influenciadora

Figura 30 – Importância das variáveis pelo Valor de Shapley - Regressão logística



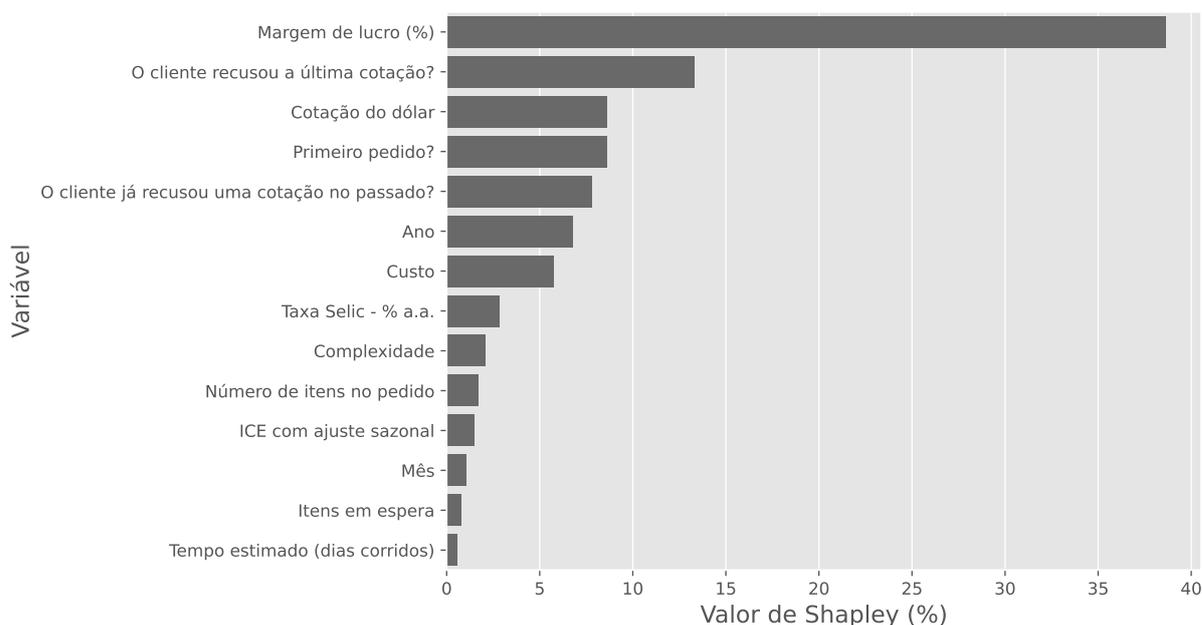
Fonte: Autor (2024)

Figura 31 – Importância das variáveis pelo Valor de Shapley - XGBoost



Fonte: Autor (2024)

Figura 32 – Importância das variáveis pelo Valor de Shapley - SVM



Fonte: Autor (2024)

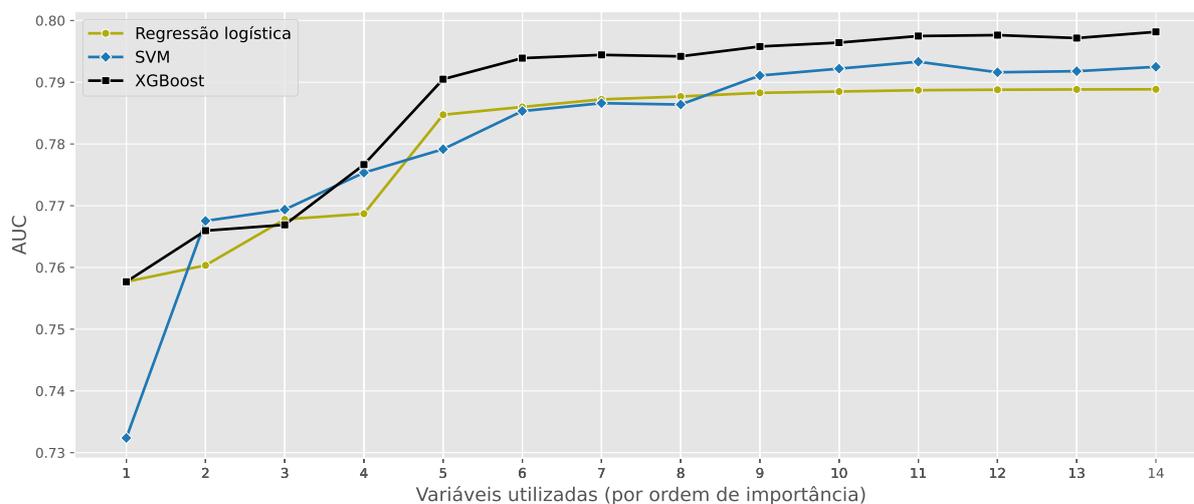
da aceitação, indicando uma menor procura de serviços e não necessariamente uma menor taxa de conversão dos pedidos.

Também destaca-se a importância baixa das características das cotações, como complexidade e número de itens no pedido, e das características operacionais do laboratório, como o tempo estimado e número de itens em espera. Esse parecer sugere que a situação interna da empresa, apesar de se traduzir em uma questão de tempo, não resulta em uma mudança expressiva do comportamento dos clientes, evidenciando ainda mais a perspectiva econômica como prioridade dos mesmos.

Apesar da presença de variáveis de pouca importância para os modelos, o que poderia indicar um certo ruído no tratamento dos dados, pode-se observar pela Figura 33 que a adição dessas variáveis ainda possui o potencial de aumentar o desempenho dos modelos. O gráfico da figura mostra o AUC resultante do modelo quando o mesmo é treinado com combinações diferentes de variáveis, onde o eixo X representa a adição de mais uma variável conforme sua importância para o modelo.

Entretanto, ao observar o comportamento dos modelos após o treinamento com suas 10 variáveis mais importantes, é possível perceber que a adição de mais variáveis não se converte diretamente em uma melhora do desempenho, indicando que estas podem representar sim um ruído no algoritmo. Esse comportamento fica mais evidente no modelo SVM, com uma baixa do valor do AUC ao adicionar a variável do mês do pedido nas colunas de treinamento. Mesmo assim, é notável que a remoção deste ruído não faria com que esse modelo conseguisse superar o *XGBoost* em termos de desempenho.

Figura 33 – AUC por importância acumulada



Fonte: Autor (2024)

Devido a estes resultados, o *XGBoost* foi escolhido como o modelo preditivo final. Sua capacidade de generalização após ajuste foi ligeiramente superior aos outros modelos, ao passo em que manteve uma boa especificidade. Essa métrica é muito importante no caso da predição de probabilidade de aceite de cotações devido ao custo de um julgamento errado para essa categoria. Ao predizer uma probabilidade alta de aceite para casos onde há a rejeição de um pedido, a expectativa é revertida e o relacionamento com o cliente pode ser comprometido.

5 CONCLUSÃO E RECOMENDAÇÕES

Este trabalho se propôs a responder ao desafio de precificação dinâmica no setor de serviços de calibração, focando na criação de um modelo preditivo que pudesse estimar a probabilidade de contratação dos serviços oferecidos pelo laboratório com base em diversos fatores relacionados à demanda e ao comportamento do cliente. O objetivo geral do estudo foi propor uma metodologia para desenvolver um modelo de aprendizado de máquina que auxilie na definição de preços otimizados, baseado nos dados e premissas citadas.

Com base nos resultados obtidos, é possível afirmar que o objetivo foi alcançado, pois o modelo alcança níveis de precisão relevantes, entretanto, ainda se faz necessário destacar a importância da experiência do usuário ao analisar as suas saídas. Diferentes modelos de aprendizado de máquina foram treinados, como a regressão logística, SVM e *XGBoost*, com uma seleção dos hiperparâmetros para garantir o melhor desempenho. O modelo *XGBoost*, após o processo de otimização, apresentou os melhores resultados em termos de precisão e capacidade preditiva, com uma AUC de 0,7982 e acurácia de 73,76%, destacando-se como a solução mais robusta para o problema de precificação dinâmica.

Adicionalmente, realizou-se uma análise da importância das *features* no resultado dos modelos utilizando o Valor de Shapley, onde algumas variáveis demonstraram ser fundamentais para o aumento da probabilidade de contratação dos serviços de calibração. A variável de margem de lucro, por exemplo, apresentou um impacto acentuado nas saídas dos modelos, evidenciando a percepção natural de que margens mais altas podem reduzir a disposição dos clientes em contratar um serviço. Outro fator relevante foi o histórico de interação do cliente, principalmente em relação à aceitação ou recusa da última cotação oferecida. Clientes com histórico de recusas tendem a ser mais reticentes, sendo recomendado um acompanhamento personalizado para ajustar as propostas de acordo com suas expectativas e necessidades. Além disso, observa-se uma alta correlação da probabilidade de aceite com a cotação do dólar durante a negociação, evidenciando sua eficácia em traduzir o contexto econômico nacional para um indicador numérico.

Dessa forma, uma possível estratégia de gerenciamento consiste em adotar margens de lucro variáveis, ajustadas de acordo com o perfil e histórico de cada cliente. Ao invés de estabelecer uma margem fixa para todos os contratos, essa abordagem permitiria personalizar as propostas, aumentando a taxa de aceitação ao adaptar-se à sensibilidade de cada cliente em relação ao preço. Clientes com histórico de recorrência ou alto volume de serviços, por exemplo, poderiam receber propostas com margens ajustadas para fortalecer o relacionamento e incentivar a fidelização, ao passo que clientes novos, ou com menor frequência de contratações, poderiam ser atraídos

com margens mais competitivas em sua primeira experiência com a empresa. Esse ajuste permitiria ao laboratório não apenas otimizar o retorno financeiro ao maximizar a probabilidade de fechamento de cada contrato, mas também equilibrar a lucratividade geral ao considerar a propensão de cada cliente a aceitar cotações diferentes.

A metodologia e os resultados foram discutidos com os membros do laboratório, abrindo caminho para uma implementação contínua do modelo. Existe, inclusive, a possibilidade de integrar essa ferramenta ao sistema atual de monitoramento da empresa, que utiliza o *software PowerBI* para acompanhar os indicadores econômicos internos. Essa integração não apenas garantiria uma visualização centralizada, mas também agilizaria a aplicação dos *insights* gerados pelo modelo no contexto operacional do laboratório.

Há, no entanto, perspectivas de melhoria para a metodologia proposta. Uma possível evolução seria aprofundar o estudo sobre a influência do preço isolado dos serviços na probabilidade de aceitação do cliente, bem como explorar a interação entre diferentes serviços ofertados. Para isso, seria necessário um banco de dados com um maior número de registros e uma diferenciação mais precisa das informações, o que proporcionaria uma base sólida para uma análise mais detalhada das dinâmicas de precificação.

Ainda, recomenda-se a implementação de métodos mais sofisticados, como as redes neurais profundas, que possuem a capacidade de capturar relações complexas entre variáveis e melhorar a precisão dos resultados. Essa abordagem permitiria ao modelo ajustar-se automaticamente a padrões mais sutis e dinâmicos nos dados, especialmente quando combinada com outras técnicas de aprendizado não supervisionado, como o agrupamento de clientes a partir de *clusters*. Esse método poderia segmentar os clientes em grupos com comportamentos semelhantes, possibilitando uma personalização ainda mais precisa das estratégias de precificação e abordagem comercial. Além disso, a incorporação de dados específicos sobre satisfação e experiência do cliente, por meio de pesquisas e *feedbacks* estruturados, pode ser uma alternativa interessante para o enriquecimento da base de dados, permitindo um modelo mais ajustado ao comportamento real dos clientes.

REFERÊNCIAS

- AGÊNCIA GOV. **Setor de serviços tem crescimento contínuo nos primeiros meses do ano.** [S.l.], 2024. Acesso em: 30 set. 2024. Disponível em: <https://agenciagov.ebc.com.br/noticias/202407/apos-dois-meses-de-alta-volume-de-servicos-fica-estavel-em-maio>.
- AGRAWAL, Tanay. **Hyperparameter optimization in machine learning: make your machine learning and deep learning models more efficient.** [S.l.]: Springer, 2021.
- BANCO CENTRAL DO BRASIL. **O que é inflação.** [S.l.], 2024. Acesso em: 29 out. 2024. Disponível em: <https://www.bcb.gov.br/controleinflacao/oqueinflacao>.
- BANCO CENTRAL DO BRASIL. **Taxa Selic.** [S.l.], 2024. Acesso em: 29 out. 2024. Disponível em: <https://www.bcb.gov.br/controleinflacao/taxaselic>.
- BISONG, Ekaba *et al.* **Building machine learning and deep learning models on Google cloud platform.** [S.l.]: Springer, 2019.
- BOOM, Willem H van *et al.* Consumers beware: Online personalized pricing in action! How the framing of a mandated discriminatory pricing disclosure influences intention to purchase. **Social Justice Research**, Springer, v. 33, p. 331–351, 2020.
- BOSER, Bernhard E; GUYON, Isabelle M; VAPNIK, Vladimir N. A training algorithm for optimal margin classifiers. *In: PROCEEDINGS of the fifth annual workshop on Computational learning theory.* [S.l.: s.n.], 1992. P. 144–152.
- CALABRESE, Armando; DE FRANCESCO, Federico. A pricing approach for service companies: service blueprint as a tool of demand-based pricing. **Business Process Management Journal**, Emerald Group Publishing Limited, v. 20, n. 6, p. 906–921, 2014.
- CHEN, Tianqi; GUESTRIN, Carlos. Xgboost: A scalable tree boosting system. *In: PROCEEDINGS of the 22nd acm sigkdd international conference on knowledge discovery and data mining.* [S.l.: s.n.], 2016. P. 785–794.
- CLARK, Colin. **The Conditions of Economic Progress.** [S.l.]: Macmillan e Company, limited, 1940.
- DEMICHURKI, R; KOVALESKI, J; CRUZ, C. Análise de custos para o estabelecimento de um sistema de precificação de serviços: um estudo de caso. *In: CONBREPPO-CONGRESSO brasileiro de engenharia de produção.* [S.l.: s.n.], 2014.
- DIECK, Ronald H. **Measurement uncertainty: methods and applications.** [S.l.]: ISA, 2017.

DOMINGOS, Pedro. A few useful things to know about machine learning. **Communications of the ACM**, ACM New York, NY, USA, v. 55, n. 10, p. 78–87, 2012.

DOMINIC, PDD *et al.* The importance of service quality for competitive advantage—with special reference to industrial product. **International Journal of Business Information Systems**, Inderscience Publishers, v. 6, n. 3, p. 378–397, 2010.

DONATELLI, Gustavo Daniel; KONRATH, Andrea Cristina. Simulação de Monte Carlo na avaliação de incertezas de medição. **Revista de Ciência & Tecnologia**, 2005.

EBIT-NIELSEN. **E-commerce no Brasil cresce 47% no primeiro semestre, maior alta em 20 anos**. [S.l.], 2020. Acesso em: 30 set. 2024. Disponível em: <https://static.poder360.com.br/2020/08/EBIT-ecommerce-Brasil-1semestre2020.pdf>.

ERICKSON, Bradley J; KITAMURA, Felipe. **Magician’s corner: 9. Performance metrics for machine learning models**. v. 3. [S.l.]: Radiological Society of North America, 2021. e200126.

FANG, Cheng *et al.* Dynamic pricing for electric vehicle extreme fast charging. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 22, n. 1, p. 531–541, 2020.

FISHER, Allan George Barnard. **The Clash of Progress and Security**. [S.l.]: Macmillan, 1935.

FOURASTIÉ, Jean. **Le Grand Espoir du XXe siècle: Progrès technique, progrès économique, progrès social**. Paris, France: Presses Universitaires de France, 1949.

FRUCHTER, Gila E; SIGUÉ, Simon P. Dynamic pricing for subscription services. **Journal of Economic Dynamics and Control**, Elsevier, v. 37, n. 11, p. 2180–2194, 2013.

GAO, Runtng. On the importance of pricing strategy in marketing strategy: A case study of lululemon. **Frontiers in Business, Economics and Management**, v. 10, n. 1, p. 158–161, 2023.

GAZI, Md Sumon *et al.* Ethical Considerations in AI-driven Dynamic Pricing in the USA: Balancing Profit Maximization with Consumer Fairness and Transparency. **Journal of Economics, Finance and Accounting Studies**, v. 6, n. 2, p. 100–111, 2024.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. [S.l.]: "O'Reilly Media, Inc.", 2022.

GIL, Antonio Carlos. **Métodos e Técnicas de Pesquisa Social**. 7ª. São Paulo: Atlas, 2019. P. 248.

GOHIYA, H; LOHIYA, H; PATIDAR, K. A Survey of Xgboost system. **Int. J. Adv. Technol. Eng. Res**, v. 8, p. 25–30, 2018.

GONÇALVES, Luzia *et al.* ROC curve estimation: An overview. **REVSTAT-Statistical journal**, v. 12, n. 1, p. 1–20, 2014.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S./]: MIT Press, 2016. (Adaptive Computation and Machine Learning series).

GROCHAU, Inês Hexsel; CATEN, Carla Schwengber ten; CAMARGO FORTE, Maria Madalena de. Motivations, benefits and challenges on ISO/IEC 17025 accreditation of higher education institution laboratories. **Accreditation and Quality Assurance**, Springer, v. 23, p. 183–188, 2018.

HAFEEZ, Muhammad Asfand *et al.* Performance improvement of decision tree: A robust classifier using tabu search algorithm. **Applied Sciences**, MDPI, v. 11, n. 15, p. 6728, 2021.

HAGENAARS, Jacques AP; KÜHNEL, Steffen; ANDRESS, Hans-Jürgen. **Interpreting and Comparing Effects in Logistic, Probit, and Logit Regression**. [S./]: Sage Publications, 2024.

HANNA, Richard C; LEMON, Katherine N; SMITH, Gerald E. Is transparency a good thing? How online price transparency and variability can benefit firms and influence consumer decision making. **Business Horizons**, Elsevier, v. 62, n. 2, p. 227–236, 2019.

HARRIS, Charles R. *et al.* Array programming with NumPy. **Nature**, Springer Science e Business Media LLC, v. 585, n. 7825, p. 357–362, set. 2020. DOI: 10.1038/s41586-020-2649-2. Disponível em: <https://doi.org/10.1038/s41586-020-2649-2>.

HINTERHUBER, Andreas; LIOZU, Stephan M. Is innovation in pricing your next source of competitive advantage? **Business Horizons**, v. 57, n. 3, p. 413–423, 2014. ISSN 0007-6813. DOI: <https://doi.org/10.1016/j.bushor.2014.01.002>.

HOSSIN, Mohammad; SULAIMAN, Md Nasir. A review on evaluation metrics for data classification evaluations. **International journal of data mining & knowledge management process**, Academy & Industry Research Collaboration Center (AIRCC), v. 5, n. 2, p. 1, 2015.

HUANG, Ming-Hui; RUST, Roland T. Artificial intelligence in service. **Journal of service research**, Sage Publications Sage CA: Los Angeles, CA, v. 21, n. 2, p. 155–172, 2018.

HUNTER, J. D. Matplotlib: A 2D graphics environment. **Computing in Science & Engineering**, IEEE COMPUTER SOC, v. 9, n. 3, p. 90–95, 2007. DOI: 10.1109/MCSE.2007.55.

IBGE. **IPCA - Índice Nacional de Preços ao Consumidor Amplo**. [S./], 2024. Acesso em: 29 out. 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/precos-e-custos/9256-indice-nacional-de-precos-ao-consumidor-amplo.html?=&t=conceitos-e-metodos>.

IBGE. **Pesquisa mensal de serviços**. [S./], 2024. Acesso em: 11 nov. 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/servicos/9229-pesquisa-mensal-de-servicos.html?=&t=series-historicas>.

IBGE. **Pesquisa Nacional por Amostra de Domicílios Contínua**. [S./], 2024. Acesso em: 30 set. 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/trabalho/9173-pesquisa-nacional-por-amostra-de-domicilios-continua-trimestral.html?=&t=series-historicas>.

IBGE. **Produto Interno Bruto - PIB**. [S./], 2024. Acesso em: 30 set. 2024. Disponível em: <https://www.ibge.gov.br/explica/pib.php>.

IBGE. **Produto Interno Bruto por setores**. [S./], 2024. Acesso em: 11 nov. 2024. Disponível em: <https://sidra.ibge.gov.br/tabela/1846#/n1/all/v/all/p/all/c11255/90687,90691,90696,90705,90706,90707,93404,93405,93406,93407,93408,102880/1/v,c11255,t+p/resultado>.

IBGE. **Sistema de Contas Nacionais Trimestrais**. [S./], 2024. Acesso em: 30 set. 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9300-contas-nacionais-trimestrais.html?=&t=series-historicas#evolucao-taxa>.

INGENBLEEK, Paul TM; FRAMBACH, Ruud T; VERHALLEN, Theo MM. Best practices for new product pricing: Impact on market performance and price level under different conditions. **Journal of Product Innovation Management**, Wiley Online Library, v. 30, n. 3, p. 560–573, 2013.

INMETRO. **Acreditação**. [S./], 2024. Disponível em: <https://www.gov.br/inmetro/pt-br/assuntos/acreditacao/cgcre/acreditacao>.

INMETRO. **Sistema de Consulta aos Escopos de Acreditação dos Laboratórios de Calibração Acreditados segundo a ABNT NBR ISO/IEC 17025: 2017 (Rede Brasileira de Calibração - RBC)**. [S./], 2024. Disponível em: http://inmetro.gov.br/laboratorios/rbc/lista_laboratorios.asp.

INSTITUTO BRASILEIRO DE ECONOMIA. **Índice de Confiança Empresarial**. [S.l.], 2024. Acesso em: 29 out. 2024. Disponível em: <https://portalibre.fgv.br/indice-de-confianca-empresarial>.

INSTITUTO NACIONAL DE METROLOGIA, Qualidade e Tecnologia (Inmetro). **NIT-DICLA-026: Requisitos para a participação de laboratórios em atividades de ensaio de proficiência**. Rio de Janeiro, Brasil, 2021. Acesso em: 31 out. 2024. Disponível em: http://www.inmetro.gov.br/credenciamento/organismos/doc_organismos.asp?tOrganismo=CalibEnsaio.

JAMES, Gareth *et al.* **An introduction to statistical learning: With applications in python**. [S.l.]: Springer Nature, 2023.

JETHANI, Neil *et al.* Fastshap: Real-time shapley value estimation. *In*: INTERNATIONAL conference on learning representations. [S.l.: s.n.], 2021.

JORDAN, Michael I; MITCHELL, Tom M. Machine learning: Trends, perspectives, and prospects. **Science**, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015.

JUBERT, Roberto Wagner *et al.* Um estudo do padrão de volatilidade dos principais índices financeiros do Bovespa: uma aplicação de modelos ARCH. **Contabilidade Gestão e Governança**, v. 11, n. 1-2, 2008.

JUNGE, Mark RJ; DETTORI, Joseph R. ROC solid: Receiver operator characteristic (ROC) curves as a foundation for better diagnostic tests. **Global Spine Journal**, SAGE Publications Sage CA: Los Angeles, CA, v. 8, n. 4, p. 424–429, 2018.

KELLEHER, John D; MAC NAMEE, Brian; D'ARCY, Aoife. **Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies**. [S.l.]: MIT press, 2020.

KLEEHAMMER, Michael. **pyodbc: Python ODBC Bridge**. [S.l.: s.n.], 2024. Version 5.2.0, accessed: 2024-10-31. Disponível em: <https://github.com/mkleehammer/pyodbc>.

KLEIN, Robert; STEINHARDT, Claudius. **Revenue management: Grundlagen und mathematische Methoden**. [S.l.]: Springer-Verlag, 2008.

KOPALLE, Praveen K *et al.* Dynamic pricing: Definition, implications for managers, and future research directions. **Journal of Retailing**, Elsevier, v. 99, n. 4, p. 580–593, 2023.

LAVESSON, Niklas; DAVIDSSON, Paul. Quantifying the impact of learning algorithm parameter tuning. *In*: AAAI. [S.l.: s.n.], 2006. P. 395–400.

LAZZARI, Annarita *et al.* Smart metrology: The importance of metrology of decisions in the big data era. **IEEE Instrumentation & Measurement Magazine**, IEEE, v. 20, n. 6, p. 22–29, 2017.

LORENZI, Vinicius; SOUZA, Alceu. Estratégias para precificação em empresas prestadoras de serviços de engenharia de fundações. *In: ANAIS do Congresso Brasileiro de Custos-ABC*. [S.l.: s.n.], 2022.

LUNDBERG, Scott M; LEE, Su-In. A Unified Approach to Interpreting Model Predictions. *In: GUYON, I. et al. (Ed.). Advances in Neural Information Processing Systems 30*. [S.l.]: Curran Associates, Inc., 2017. P. 4765–4774. Disponível em: <http://papers.nips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions.pdf>.

LUNDBERG, Scott M; LEE, Su-In. A unified approach to interpreting model predictions. **Advances in neural information processing systems**, Curran Associates, Inc, v. 30, p. 4765–4774, 2017.

MASCHLER, Michael; ZAMIR, Shmuel; SOLAN, Eilon. **Game theory**. [S.l.]: Cambridge University Press, 2020.

MATTOS, Sandra Maria Nascimento de. **Conversando sobre metodologia da pesquisa científica**. [S.l.]: Editora Fi, 2020.

MCKINNEY, Wes. Data Structures for Statistical Computing in Python. *In: WALT, Stéfan van der; MILLMAN, Jarrod (Ed.). Proceedings of the 9th Python in Science Conference*. [S.l.: s.n.], 2010. P. 56–61. DOI: 10.25080/ajora-92bf1922-00a.

MIGUEL, Paulo Augusto Cauchick *et al.* **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. 3. ed. Rio de Janeiro, 2018.

MILLER, Catriona *et al.* A review of model evaluation metrics for machine learning in genetics and genomics. **Frontiers in Bioinformatics**, Frontiers Media SA, v. 4, p. 1457619, 2024.

MONTGOMERY, Douglas C; RUNGER, George C. **Applied statistics and probability for engineers**. [S.l.]: John wiley & sons, 2020.

MÜLLER, Andreas C; GUIDO, Sarah. **Introduction to machine learning with Python: a guide for data scientists**. [S.l.]: "O'Reilly Media, Inc.", 2016.

NAGLE, T.T.; MÜLLER, G. **The Strategy and Tactics of Pricing: A Guide to Growing More Profitably**. [S.l.]: Routledge, 2023.

NATRAS, Randa; SCHMIDT, Michael. Machine Learning Model Development for Space Weather Forecasting in the Ionosphere. *In: CIKM Workshops*. [S.l.: s.n.], 2021.

NETTO, Paulo Holanda Ribeiro. **Estratégia de precificação: caso aplicado para uma empresa prestadora de serviços de engenharia elétrica**. 2023. B.S. thesis – Universidade Federal do Rio Grande do Norte.

NEUBERT, Michael. A systematic literature review of dynamic pricing strategies. **International Business Research**, v. 15, n. 4, p. 1–17, 2022.

OMNIA RETAIL. **An Introduction to Amazon Pricing in 2022**. [S.l.], 2022. Acesso em: 30 set. 2024. Disponível em: <https://www.omniaretail.com/blog/an-introduction-to-amazon-pricing>.

PEDREGOSA, F. *et al.* Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PETRY, Felipe Morgado. Precificação dinâmica baseada em reinforcement learning: um experimento no varejo supermercadista, 2022.

POLÁČEK, Lukáš *et al.* Dynamic Pricing in E-commerce: Bibliometric Analysis. **Acta Informatica Pragensia**, Acta Informatica Pragensia, v. 13, n. 1, p. 114–133, 2024.

POTRICH, Yuri Balczareki. Precificação de imóveis em Florianópolis utilizando técnicas de aprendizado de máquina. Florianópolis, SC., 2024.

PROFITERO. **Profitero Price Intelligence: Amazon makes more than 2.5 million daily price changes**. [S.l.], 2013. Acesso em: 30 set. 2024. Disponível em: <https://www.profitero.com/blog/2013/12/profitero-reveals-that-amazon-com-makes-more-than-2-5-million-price-changes-every-day>.

RAINIO, Oona; TEUHO, Jarmo; KLÉN, Riku. Evaluation metrics and statistical tests for machine learning. **Scientific Reports**, Nature Publishing Group UK London, v. 14, n. 1, p. 6086, 2024.

RASCHKA, Sebastian; LIU, Yuxi Hayden; MIRJALILI, Vahid. **Machine Learning with PyTorch and Scikit-Learn: Develop machine learning and deep learning models with Python**. [S.l.]: Packt Publishing Ltd, 2022.

RIGHI, Marcelo Brutti; CERETTA, Paulo Sérgio. Efeito da crise de 2007/2008 na transmissão internacional de volatilidade no mercado de capitais brasileiro. **REAd. Revista Eletrônica de Administração (Porto Alegre)**, SciELO Brasil, v. 19, p. 384–400, 2013.

SAHARAN, Sandeep; BAWA, Seema; KUMAR, Neeraj. Dynamic pricing techniques for Intelligent Transportation System in smart cities: A systematic review. **Computer Communications**, Elsevier, v. 150, p. 603–625, 2020.

SAMMUT-BONNICI, Tanya; CHANNON, Derek F. Pricing strategy. **Wiley encyclopedia of management**, Wiley Online Library, p. 1–3, 2015.

SANTOS, Raphael Pereira dos; KAPPES, Sylvio. Uma análise da inflação brasileira na pandemia a partir dos dados do IPCA. **Cadernos CEPEC**, v. 11, n. 2, 2023.

SARKAR, Malay *et al.* Optimizing e-commerce profits: A comprehensive machine learning framework for dynamic pricing and predicting online purchases. **Journal of Computer Science and Technology Studies**, v. 5, n. 4, p. 186–193, 2023.

SCHWAB, Klaus. **The fourth industrial revolution**. [S.l.]: Crown Currency, 2017.

SCOPUS. **Search Results for "ROC curve"AND "machine learning"on Scopus**.

[S.l.: s.n.], 2024. Acesso em: 15 out. 2024. Disponível em:

<https://www.scopus.com/results/results.uri?sort=plf-f&src=s&st1=%22roc+curve%22&st2=%22machine+learning%22&sid=0be5294707ecc820518e9e25ff41f1c2&sot=b&sdt=cl&sl=46&s=%28KEY%28%22roc+curve%22%29+AND+KEY%28%22machine+learning%22%29%29&origin=resultslist&editSaveSearch=&yearFrom=1989&yearTo=2024&sessionSearchId=0be5294707ecc820518e9e25ff41f1c2&limit=10&cluster=scosubtype%2C%22ar%22%2Ct%2C%22cp%22%2Ct>.

SHAPLEY, Lloyd S. A value for n-person games. **Contribution to the Theory of Games**, v. 2, 1953.

SIBIRSKAYA, Elena V *et al.* **Economic Systems Analysis: Statistical Indicators**. [S.l.]: Springer, 2019.

SILVA, Eduardo Abreu da; CAMPOS, Renato de. A importância da metrologia na gestão empresarial e na competitividade do país. **Encontro Nacional de Engenharia de Produção**, 2001.

SIMÕES, Wagner Lourenzi. Modelo de precificação dinâmica de produtos com curto ciclo de vida baseado no problema do jornaleiro. Universidade do Vale do Rio dos Sinos, 2021.

SIMON, H.; FASSNACHT, M. **Price Management: Strategy, Analysis, Decision, Implementation**. [S.l.]: Springer International Publishing, 2019.

SIMON, Hermann. **Confessions of the pricing man**. [S.l.]: Springer, 2015.

SMITH, Adam. **An Inquiry into the Nature and Causes of the Wealth of Nations**. London: W. Strahan e T. Cadell, 1776.

SUBBARAYUDU, Yerragudipadu *et al.* An efficient novel approach to E-commerce retail price optimization through machine learning. *In: EDP SCIENCES. E3S Web of Conferences.* [S.l.: s.n.], 2023. P. 01104.

SUNDARARAJAN, Mukund; NAJMI, Amir. The many Shapley values for model explanation. *In: PMLR. INTERNATIONAL conference on machine learning.* [S.l.: s.n.], 2020. P. 9269–9278.

TALÓN-BALLESTERO, Pilar; NIETO-GARCÍA, Marta; GONZÁLEZ-SERRANO, Lydia. The wheel of dynamic pricing: Towards open pricing and one to one pricing in hotel revenue management. **International journal of hospitality management**, Elsevier, v. 102, p. 103184, 2022.

TREVETHAN, Robert. Sensitivity, specificity, and predictive values: foundations, plabilities, and pitfalls in research and practice. **Frontiers in public health**, Frontiers Media SA, v. 5, p. 307, 2017.

ULMER, Marlin W. Dynamic pricing and routing for same-day delivery. **Transportation Science**, INFORMS, v. 54, n. 4, p. 1016–1033, 2020.

VARGO, Stephen L; LUSCH, Robert F. **The SAGE handbook of service-dominant logic**. [S.l.]: Sage, 2018.

VICTOR, Vijay *et al.* Factors influencing consumer behavior and prospective purchase decisions in a dynamic pricing environment—an exploratory factor analysis approach. **Social Sciences**, MDPI, v. 7, n. 9, p. 153, 2018.

VIM. **Vocabulário Internacional de Metrologia: Conceitos Fundamentais e Gerais e Termos Associados**. 3. ed. [S.l.], 2012. Disponível em: https://www.gov.br/inmetro/pt-br/centrais-de-conteudo/publicacoes/documentos-tecnicos-em-metrologia/vim_2012.pdf/view.

VIRTANEN, Pauli *et al.* SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. **Nature Methods**, v. 17, p. 261–272, 2020. DOI: 10.1038/s41592-019-0686-2.

WASKOM, Michael L. seaborn: statistical data visualization. **Journal of Open Source Software**, The Open Journal, v. 6, n. 60, p. 3021, 2021. DOI: 10.21105/joss.03021. Disponível em: <https://doi.org/10.21105/joss.03021>.

WIRTH, Rüdiger; HIPPE, Jochen. CRISP-DM: Towards a standard process model for data mining. *In: MANCHESTER. PROCEEDINGS of the 4th international conference on the practical applications of knowledge discovery and data mining.* [S.l.: s.n.], 2000. P. 29–39.

YANG, Xin *et al.* Concepts of artificial intelligence for computer-assisted drug discovery. **Chemical reviews**, ACS Publications, v. 119, n. 18, p. 10520–10594, 2019.

ZAGHI, Lucca Magri. Modelo de previsão de preços de imóveis na cidade de Florianópolis/SC a partir de técnicas de machine learning. Florianópolis, SC., 2023.

ZEITHAML, Valarie A; BITNER, Mary Jo; GREMLER, Dwayne D. **Services marketing: Integrating customer focus across the firm.** [S./]: McGraw-Hill, 2023.

ZHENG, Alice. **Evaluating machine learning models: a beginner's guide to key concepts and pitfalls.** [S./]: O'Reilly Media, 2015.

ZHOU, Zhi-Hua. **Machine learning.** [S./]: Springer nature, 2021.

APÊNDICE A – CÓDIGOS

```

from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
import xgboost as xgb
from sklearn.svm import SVC
from sklearn.metrics import accuracy_score, confusion_matrix
from sklearn.model_selection import RandomizedSearchCV

##### TREINO INICIAL DOS MODELOS-----
# Divisão inicial dos dados em subconjuntos de treino e teste final -----
df_inicial_filtrado, df_inicial_filtrado = train_test_split(
    df_inicial,
    test_size = 0.2,
    stratify = df_inicial['0 cliente aceitou essa cotação?']
)

# Divisão do subconjunto de treino em parte de treino e parte teste para
otimização de hiperparâmetros -----
X_inicial = df_inicial_filtrado.drop('0 cliente aceitou essa cotação?')
y_inicial = df_inicial_filtrado['0 cliente aceitou essa cotação?']
X_train, X_test, y_train, y_test = train_test_split(
    X_inicial,
    y_inicial,
    test_size=0.2
)

# Treino inicial dos modelos de machine learning -----
# Regressão logística
model_LR = LogisticRegression()
model_LR.fit(X_train, y_train)
y_pred_LR = model_LR.predict_proba(X_test)[: , 1]

# XGBoost
dtrain_XGB = xgb.DMatrix(X_train, label=y_train)
dtest_XGB = xgb.DMatrix(X_test, label=y_test)
model_XGB = xgb.train(dtrain_XGB)
y_pred_XGB = model_XGB.predict(dtest_XGB)

```

```

# SVM
model_SVM = SVC(probability=True)
model_SVM.fit(X_train, y_train)
y_pred_SVM = model_SVM.predict_proba(X_test)[: ,1]

# Retorno da matriz de confusão e AUC -----
accuracy_LR = accuracy_score(y_test, y_pred_LR)
accuracy_XGB = accuracy_score(y_test, y_pred_XGB)
accuracy_SVM = accuracy_score(y_test, y_pred_SVM)

confusion_matrix_LR = confusion_matrix(y_test, y_pred_LR)
confusion_matrix_XGB = confusion_matrix(y_test, y_pred_XGB)
confusion_matrix_SVM = confusion_matrix(y_test, y_pred_SVM)

##### OTIMIZAÇÃO DE HIPERPARÂMETROS -----
# Regressão logística -----
param_distributions = {
    'penalty': ['l1', 'l2', 'elasticnet', 'none'],
    'C': np.linspace(-10, 10, 20),
    'solver': ['newton-cg', 'lbfgs', 'liblinear', 'sag', 'saga'],
    'max_iter': [50, 100, 200, 500],
    'l1_ratio': np.linspace(0, 1),
    'fit_intercept': [True, False],
    'dual': [True, False],
    'intercept_scaling': [1, 10, 100],
    'multi_class': ['auto', 'ovr', 'multinomial'],
    'tol': [1e-4, 1e-3, 1e-2, 1e-1],
    'verbose': [0, 1, 2],
    'warm_start': [True, False]
}

random_search = RandomizedSearchCV(
    estimator = model_LR,
    param_distributions = param_distributions,
    n_iter = 200,
    scoring = 'roc_auc',
    cv = 20
)

```

```

random_search.fit(X_train, y_train)
best_model_LR = random_search.best_estimator_
y_pred_LR_optimized = best_model_LR.predict(X_test)

# XGBoost -----
param_distributions = {
    'n_estimators': [50, 100, 200, 300, 500],
    'max_depth': [3, 5, 7, 10, 15],
    'learning_rate': [0, 2, 4, 6, 8, 10],
    'subsample': [0.5, 0.7, 0.8, 0.9, 1.0],
    'colsample_bytree': [0.5, 0.7, 0.8, 0.9, 1.0],
    'colsample_bylevel': [0.5, 0.7, 0.8, 0.9, 1.0],
    'colsample_bynode': [0.5, 0.7, 0.8, 0.9, 1.0],
    'gamma': [0, 0.1, 0.3, 0.5, 1.0],
    'min_child_weight': [1, 3, 5, 7],
    'reg_alpha': np.linspace(0, 20, 20),
    'reg_lambda': np.linspace(0, 20, 20),
    'eval_metric': ['mlogloss', 'auc']
}

random_search = RandomizedSearchCV(
    estimator = model_XGB,
    param_distributions = param_distributions,
    n_iter = 200,
    scoring = 'roc_auc',
    cv = 20
)

random_search.fit(dtrain_XGB, dtest_XGB)

best_model_XGB = random_search.best_estimator_
y_pred_XGB_optimized = best_model_XGB.predict(dtest_XGB)
y_pred_proba_XGB_optimized = best_model_XGB.predict_proba(dtest_XGB)[:, 1]

# SVM -----

```

```
param_distributions = {
    'C': np.logspace(-3, 3, 10),
    'kernel': ['linear', 'poly', 'rbf', 'sigmoid'],
    'degree': [2, 3, 4, 5],
    'gamma': ['scale', 'auto'],
    'coef0': [0, 0.1, 0.5, 1, 2],
    'shrinking': [True, False],
    'tol': [1e-4, 1e-3, 1e-2, 1e-1],
    'max_iter': [-1, 100, 200, 500]
}

random_search = RandomizedSearchCV(
    estimator = model_SVM,
    param_distributions=param_distributions,
    n_iter = 200,
    scoring = 'roc_auc',
    cv = 20
)

random_search.fit(X_train, y_train)

best_model_SVM = random_search.best_estimator_
y_pred_SVM_optimized = best_model_SVM.predict(X_test)
y_pred_proba_SVM_optimized = best_model_SVM.predict_proba(X_test)[:, 1]
```