

MACHINE LEARNING PARA DETERMINAÇÃO DE PREÇOS DE EQUIPAMENTOS: UM ESTUDO DE LEVANTAMENTO QUALITATIVO PARA A ONESUBSEA

Guilherme Rodrigues de Oliveira¹
Marcus Vinicius Kotviski Machado²
Christiane Bischof dos Santos³

RESUMO

A aprendizagem de máquina (*machine learning*) é uma subárea da inteligência artificial que utiliza algoritmos e modelos estatísticos para aprender com dados e fazer previsões ou tomar decisões automaticamente. Essa tecnologia tem sido aplicada em diversas áreas, trazendo benefícios como aumento de eficiência, redução de custos e melhorias na precisão de análises. O potencial da tecnologia é vasto e crescente, e a tendência é que cada vez mais empresas e indústrias passem a utilizá-la em suas operações. Uma das suas utilizações é no processo de precificação de equipamentos de alta complexidade, tais quais aqueles produzidos pela OneSubsea para armazenagem e tratamento submerso de óleo e gás, pois constituem-se de diversas peças e é preciso definir com base em diversos fatores para determinar um custo preciso. Haja vista este contexto, a precificação de um equipamento produzido pela OneSubsea demanda muito tempo. Por conta disso, o objetivo deste trabalho é indicar um ou mais modelos de machine learning para precificar projetos da árvore de Natal molhada, um dos produtos chaves da empresa, com planta em São José dos Pinhais - PR. Para atingir este objetivo, foi conduzido o levantamento de artigos científicos e relatórios referentes a aplicações de ML para processos similares. Posteriormente, as contribuições desses relatórios serão agrupadas em um quadro resumo com as aplicações. Por fim, mapa e análise serão compartilhados à empresa, que poderá consultá-lo como base para futuros desenvolvimentos.

Palavras-chave: Machine Learning. Precificação. Modelagem.

¹ Aluno do 3º período do curso de Ciência de Dados para Negócios da FAE Centro Universitário. Bolsista do Programa de Apoio à Iniciação Científica (PAIC 2023-2024). *E-mail:* oliveira.guilherme@mail.fae.edu

² Aluno do 5º período do curso de Administração da FAE Centro Universitário. Voluntário do Programa de Apoio à Iniciação Científica (PAIC 2023-2024). *E-mail:* marcus.machado@mail.fae.edu

³ Orientadora da Pesquisa. Doutora em Administração pela PUC-PR/Universit  di Bologna. Professora da FAE Centro Universit rio. *E-mail:* christiane.santos@fae.edu

INTRODUÇÃO

A aprendizagem de máquina (*machine learning*) é uma subárea da inteligência artificial que utiliza algoritmos e modelos estatísticos para aprender com dados e fazer previsões ou tomar decisões automaticamente (Mitchell, 1997). Essa tecnologia tem sido aplicada em diversas áreas, trazendo benefícios como aumento de eficiência, redução de custos e melhorias na precisão de análises.

O potencial da tecnologia é vasto e crescente, e a tendência é que cada vez mais empresas e indústrias passem a utilizá-la em suas operações e processos. Segundo Ambadipudi (2023) o *machine learning* está revolucionando a manufatura e diversos processos industriais. Na manufatura, é utilizado para manutenção preditiva, otimização de processos e controle de qualidade, reduzindo tempo de inatividade e melhorando a eficiência (McKinsey & Co., 2022; Ambadipudi, 2023). No setor de compras, ajuda na previsão de demanda, otimização de estoques e negociação automatizada, proporcionando melhor planejamento e custo-benefício (Agrawal et al., 2024; Soral et al., 2023).

Na precificação, o uso de *machine learning* permite ajustes dinâmicos de preços, segmentação de clientes e análise da concorrência, maximizando a receita e a competitividade (McKinsey & Co., 2022). Isso facilita e agiliza significativamente este processo, principalmente quando se considera produtos com grande número de componentes e customizações, tais quais aqueles produzidos pela OneSubsea para armazenagem e tratamento submerso de óleo e gás. O produto principal, denominada Árvore de Natal Molhada, constitui-se de centenas de peças e é preciso definir com base em diversos fatores para determinar um custo preciso. Portanto, a precificação de um equipamento deste tipo demanda muito tempo.

Haja vista este contexto, o objetivo deste trabalho é indicar um ou mais modelos de machine learning para precificar projetos da árvore de Natal molhada, um dos produtos chaves da empresa, produzida na planta da empresa em São José dos Pinhais - PR. Para atingir este objetivo, será conduzido o levantamento de artigos científicos referentes a aplicações de ML para processos similares. Posteriormente, as contribuições desses relatórios serão agrupadas em um mapa teórico-empírico com indicações de caminhos mais promissores para a empresa em questão. Por fim, o mapa e a análise serão compartilhados à empresa, que poderá consultá-lo como base para futuros desenvolvimentos.

1 FUNDAMENTAÇÃO TEÓRICA

O *machine learning* (ML) ou aprendizado de máquina (AM) surgiu na década de 1960 como uma área da inteligência artificial voltada para a identificação de padrões a partir de dados. Inicialmente, suas aplicações eram puramente computacionais. No entanto, desde o final dos anos 1990, o campo se expandiu significativamente, ganhando autonomia e abrangendo interseções importantes com a estatística (Izbicki; Santos, 2020). É um ramo da inteligência artificial que visa permitir que as máquinas desempenhem o trabalho com habilidade, usando software inteligente (Mohammed et al., 2017; Sharma et al., 2020). Conforme complementam Sharifani e Amini (2023), uma das principais vantagens do aprendizado de máquina é a capacidade de aprender com os dados de forma automatizada, sem necessidade de programação explícita. Isto torna esta ferramenta particularmente útil em aplicações onde grandes quantidades de dados estão disponíveis, como reconhecimento de imagem ou fala, processamento de linguagem, sistemas de recomendação.

1.1 PROCESSO DE APRENDIZAGEM DE MÁQUINA

Segundo Domingos (2012), o processo de aprendizado de máquina envolve várias etapas e preparações, pois é um sistema que necessita de muita informação para ter um funcionamento preciso. Considerando isso, a primeira etapa consiste em coletar dados sobre o ambiente e os processos nos quais o sistema estará inserido. Após a coleta, os dados devem ser tratados e formatados, eliminando suas inconsistências e preenchendo lacunas de informações, como preços altíssimos, preços baixíssimos e até mesmo a ausência de preço.

Após garantir uma fonte confiável de dados tratados, o próximo passo é escolher um modelo de aprendizado de máquina adequado com base nas características específicas do sistema a ser desenvolvido. O modelo representa a estrutura pela qual a máquina aprenderá e processará informações. Em seguida, é essencial selecionar as informações mais relevantes e organizá-las em três conjuntos distintos. O conjunto de treinamento é utilizado para alimentar o modelo e permitir que ele aprenda, enquanto o conjunto de validação é empregado para ajustar os parâmetros do modelo. Por fim, o conjunto de testes é reservado para avaliar o desempenho final do modelo e verificar se ele produz resultados consistentes com os dados previamente coletados (Domingos, 2012; Brownlee, 2020).

Após segmentar os dados, o modelo passa por um processo de treinamento para assimilar informações e capacitar-se a realizar previsões sobre o tema em análise. Posteriormente, os dados são validados e os parâmetros são ajustados com base nos

resultados obtidos, com o objetivo de melhorar a precisão do modelo. Por fim, realiza-se uma avaliação final do modelo para verificar a consistência das previsões em relação aos dados existentes e a adequação às expectativas de previsão (Domingos, 2012; Brownlee, 2020).

1.1.1 Categorias de Machine Learning

Dentre tipos comumente utilizados, existem duas grandes categorias: o aprendizado supervisionado e o aprendizado não supervisionado, definidas por Bishop (2006) e Izbicki e Santos (2020) como:

- O aprendizado supervisionado é utilizado para mapear o caminho das variáveis para resultados esperados, ou seja, os padrões e o comportamento da base de dados e do modelo são definidos antes de iniciar os testes. Rokach e Maimon (2014) complementam que as árvores de decisão podem ser utilizadas tanto em contextos preditivos ou exploratórios.
- No aprendizado não supervisionado, não há necessidade prévia de conhecimento sobre as relações entre as variáveis de entrada e saída, permitindo que o algoritmo descubra padrões ocultos nos dados ao reduzir a dimensionalidade, facilitando assim a análise exploratória. Neste caso, as técnicas abordadas incluem métodos para transformação de variáveis, redução de dimensionalidade, análise de agrupamento, análise de associação e desenvolvimento de sistemas de recomendação (Izbicki; Santos, 2020).

Além dos aprendizados supervisionados e não supervisionados, há uma terceira abordagem, o aprendizado de reforço (*reinforcement learning*) que é aplicado quando a máquina ou o decisor interagem com o ambiente, executando ações e recebendo feedback na forma de recompensas ou penalidades. E toda ação tomada é pontuada, indicando o quão favorável ou abordável a ação foi para atingir o objetivo. A aprendizagem por reforço é adequada para problemas onde não há exemplos rotulados disponíveis, mas sim um sistema de recompensas que guia o comportamento do agente. Entre os principais modelos, pode-se citar o *Q-learning* e *deep Q-networks*, abreviada como “DQN” (Sutton; Barto, 2018).

1.1.2 Modelos Utilizados para *Machine Learning*

Os modelos a seguir são bastante comuns e amplamente utilizados em *machine learning*. Aqui está um resumo de cada um, com base em Murphy (2012), Domingos (2012), Sutton e Barto (2018) e Rokach e Maimon (2014):

Regressão Linear: Utilizada para prever valores contínuos. É útil para prever valores contínuos, como preços com base em variáveis independentes. É útil em problemas de previsão.

Regressão Logística: Usada para problemas de classificação binária, cujo objetivo é prever se uma observação pertence a uma classe ou não, como determinar se um *e-mail* é spam.

Árvores de Decisão: Modelos que dividem o conjunto de dados em subconjuntos menores com base em regras de decisão simples e valores definidos. São utilizadas em problemas de classificação e regressão. Existem dois tipos de árvore de decisão, as árvores de classificação, ou CART e árvores de regressão. A primeira, trabalha com categorias, com sets menores com o maior número de uma única classe possível (Song; Lu, 2015). Suas principais vantagens são a fácil interpretação e entendimento, no entanto, esse algoritmo pode se tornar muito complexo e causar um sobre ajuste nos dados de teste, ou seja, quando o modelo de machine learning é treinado com os detalhes e ruídos de uma base de dados, acaba em prejudicar o desempenho do algoritmo em dados novos (Dietterich, 1995).

Random Forest: Consiste em um conjunto de árvores de decisão que trabalham em conjunto para realizar previsões mais precisas do que uma única árvore, sendo especialmente útil para evitar overfitting⁴.

Support Vector Machines (SVM): Útil para problemas de classificação e regressão. Encontra o hiperplano que melhor separa os dados em classes distintas. Um hiperplano pode ser entendido como uma superfície de decisão que divide o espaço de características em duas regiões, uma para cada classe.

Redes Neurais Artificiais: Inspiradas no funcionamento do cérebro humano, são capazes de aprender e generalizar a partir de conjuntos de dados complexos, e podem ser utilizadas em uma variedade de problemas. As Redes Neurais são particularmente interessantes pois seus diversos algoritmos abrangem todos os tipos de Machine Learning, desde o aprendizado supervisionado, até o aprendizado de reforço. Quando utilizadas em um aprendizado supervisionado, são treinadas para aproximarem-se

⁴ Fenômeno em aprendizado de máquina no qual um modelo se ajusta muito bem aos dados de treinamento, mas não consegue generalizar bem para novos dados ou dados de teste (Bishop, 2006).

o máximo possível do resultado esperado pelo pesquisador, diminuindo o erro a cada rodada de saídas. Os aprendizados não supervisionados, são frequentemente utilizados para categorizar e encontrar correlações em grandes conjuntos de dados. Já o Aprendizado de Reforço é comumente utilizado para adaptar um objetivo complexo, que requer muitos passos e reavaliação constante destes passos. Essa reavaliação é feita através de um sistema de pontuação, que direciona o agente a aprimorar ou manter determinadas escolhas para uma performance (Mahesh, 2018).

Complementarmente, existem os algoritmos de Deep Learning como as Deep Neural Networks (DNNs) que executam trabalhos em modelos de dados maiores e muito mais complexos. Isso graças à excelente escalabilidade destes modelos, permitindo aumentar muito a quantidade de dados conforme o poder computacional aumenta. Os modelos de Deep Learning são principalmente utilizados em modelos de text-to-speech e identificação por imagem (Janiesch; Zschech; Heinrich, 2021).

K-Means: Um algoritmo de agrupamento (clustering) amplamente utilizado em aprendizado de máquina não supervisionado que agrupa dados com base na similaridade entre eles.

Principal Component Analysis (PCA): Técnica de redução de dimensionalidade usada para representar um grande conjunto de dados em dimensões menores, mantendo a maior parte da variação original dos dados.

2 METODOLOGIA

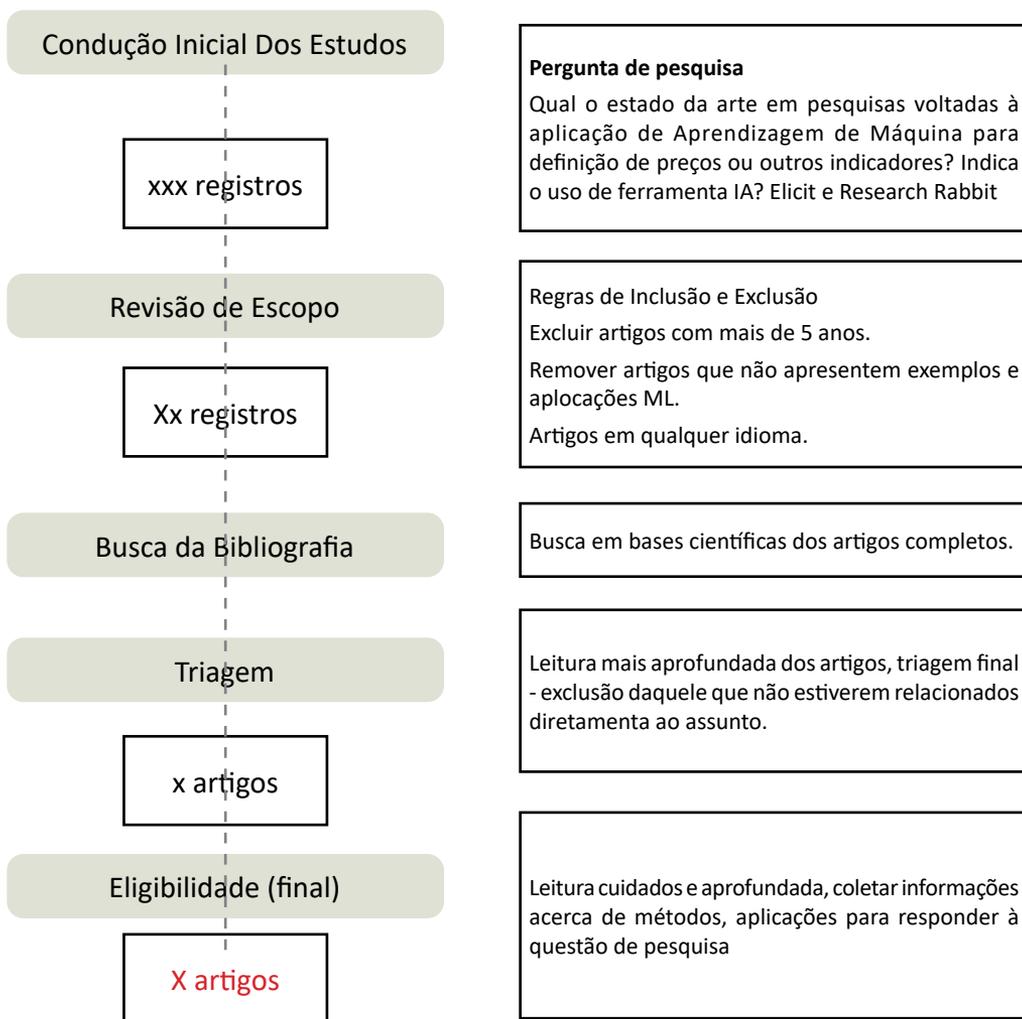
Este estudo adota uma revisão sistemática de literatura de artigos científicos, conforme sugerido por Babbie (2016), com o objetivo de identificar tendências e padrões nas aplicações de aprendizagem de máquina para cálculo de precificação. De acordo com Booth, Sutton e Papaioannou (2021), há cinco etapas principais de uma revisão sistemática de literatura que são: condução dos estudos, revisão do escopo, busca da bibliografia, triagem e verificação da elegibilidade e avaliação final para extração de dados.

A pesquisa foi realizada utilizando buscas no Google Scholar e ferramentas de busca em IA (Elicit e Research Rabbit). Todas serão verificadas a fim de se assegurar que somente fontes confiáveis serão utilizadas, conforme preconiza Creswell (2014).

Foram utilizadas palavras-chave relevantes como “aprendizagem de máquina”, “precificação”, “estudo de caso”, entre outras. Os critérios de seleção (filtros) incluem a relevância do tema (aplicações de aprendizagem de máquina), a presença de estudos de caso em empresas, o foco específico em aprendizagem de máquina para cálculo de

precificação e a atualidade dos artigos (últimos 5 anos). De acordo com Boeije (2010), estabelecer critérios de seleção claros e objetivos é essencial para garantir a qualidade e a relevância dos dados coletados. O processo que será realizado para esta coleta e análise dos dados encontra-se na Figura 1 a seguir.

FIGURA 1 — Modelo para revisão de literatura



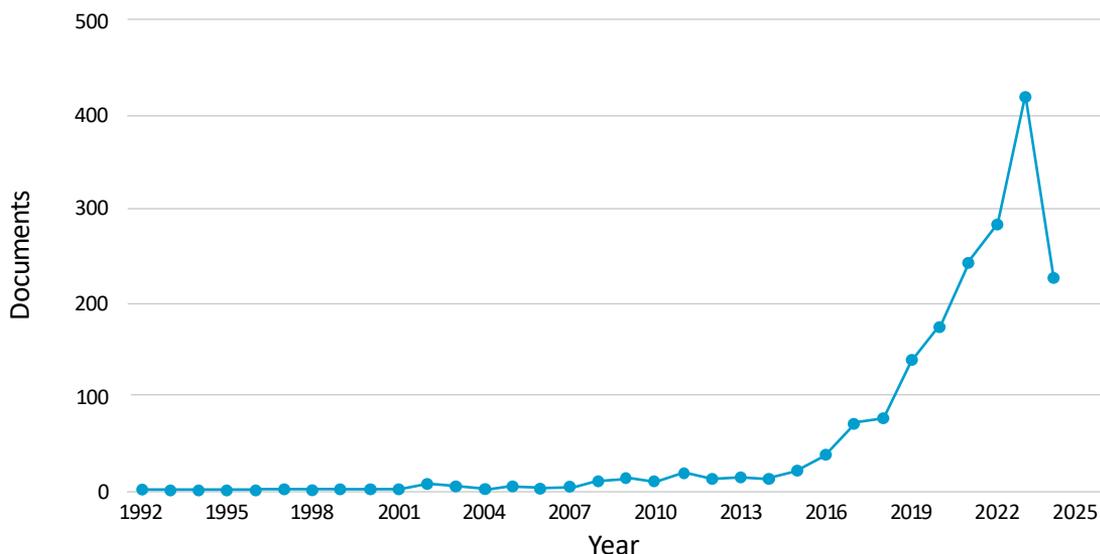
FONTE: Booth, Papaioannou e Sutton (2012, adaptado)

3 ANÁLISE DOS RESULTADOS

As técnicas de machine learning (ML) estão sendo cada vez mais aplicadas para otimizar estratégias de precificação na manufatura e no comércio eletrônico. Nos últimos anos, diversos artigos foram publicados com este foco. Como é possível verificar no

GRÁF. 1 a seguir, houve um aumento significativo dos trabalhos acadêmicos em Machine Learning com foco em precificação (em diversas perspectivas). Em 2023, mais de 400 artigos foram publicados com esta temática. Em junho de 2024, já foram publicados mais de 220 artigos.

GRÁFICO 1 — Artigos acadêmicos publicados com tema “uso de *machine learning* para precificação”



FONTE: Base Scopus - Elsevier (2024)

Este crescimento indica que é uma temática relevante tanto para a Academia quanto para fins gerenciais. Afinal, essas abordagens oferecem um potencial significativo para otimizar estratégias de precificação e melhorar o desempenho geral dos negócios tanto na manufatura quanto no comércio eletrônico. Modelos de ML podem prever custos de manufatura, custos de envio, preços de concorrentes, comportamento do cliente, melhorar a qualidade do produto e reduzir custos operacionais entre outras diversas funcionalidades (Shafkhan et al., 2022; Acosta et al., 2020; Wuest et al., 2016).

O Quadro 1 a seguir apresenta um resumo dos artigos mais relevantes para o objetivo deste estudo, após aplicação da metodologia previamente apresentada na Figura 1. Foi feito um levantamento inicial de artigos, que resultou em aproximadamente 1800 arquivos e, após exaustivas seleções e filtros, chegou-se a seis artigos que apresentam contribuições relevantes ao contexto da OneSubsea. Importante salientar que a maior parte dos artigos focam na precificação dinâmica para e-commerce, o que não está diretamente relacionado ao objeto da pesquisa. Portanto, houve um extenso processo de “limpeza” da base até que se chegou aos artigos apresentados.

QUADRO 1 — Artigos que apresentam aplicações de ML para precificação continua

Autores/ano	Título	Aplicação de ML	Foco(s) da aplicação	Modelo ML utilizado
Shafkhan et al. (2022)	<i>Price Optimisation and Management</i>	Prever os principais fatores de precificação e, otimizar os preços para minimizar custos e maximizar lucros em empresas de médio a grande porte no Sri Lanka.	Prever Custo de fabricação, custo de envio, preços dos concorrentes e comportamento dos clientes para minimizar custos e maximizar lucros.	A solução proposta inclui componentes de ML que são alimentados com dados históricos dos quatro fatores apontados para sua previsão, além de um componente de otimização que possibilita minimizar os custos e maximizar os lucros. Utilizou-se para isso modelos de previsão em séries temporais (ARIMA, LSTM e ProphetFB) além do modelo de <i>clustering</i> (agrupamento).
Bilal (2017)	<i>A machine learning approach to pricing in expansive businesses</i>	Otimizar estratégias de precificação em empresas comerciais durante a expansão dos negócios.	Foco em determinar qual método de precificação pode trazer o máximo lucro para o negócio.	Uso de Redes neurais artificiais (ANN): modelos que ajudam as máquinas a aprenderem com experiências passadas.
Boyko; Lukash (2023)	<i>Methodology for Estimating the Cost of Construction Equipment Based on the Analysis of Important Characteristics Using Machine Learning Methods</i>	Estimar o custo de equipamentos de construção com base em características críticas.	Estimar custos a partir de dados estruturados sobre a venda de equipamentos pesados (três tipos de equipamentos: carregadeiras, escavadeiras e tratores de esteira) com base na geolocalização e características essenciais.	Detalha as etapas de pré-processamento dos dados que inclui, remoção de dados discrepantes, codificação de dados categóricos, estatísticas descritivas e verificação da normalidade (teste Kolmogorov-Smirnov). Análise de modelos de ML incluindo regressão linear e polinomial, árvores de decisão, floresta aleatória, máquina de vetores de suporte e rede neural.
Dolgov, Lyukevich e Dolgov (2022)	<i>Application of machine learning methods in pricing</i>	Modelos para otimizar estratégias de precificação podendo ser adaptados e aplicados para resolver uma ampla gama de tarefas em diferentes setores.	Determinar o preço de mercado de um produto com alta precisão, sem envolvimento humano.	Uso de múltiplos métodos simultaneamente e selecionar o modelo com o maior coeficiente de determinação e o menor erro quadrático. Neste trabalho, foram utilizados: regressão linear; regressão logística; clustering árvores de decisão, Random forest e redes neurais.

QUADRO 1 — Artigos que apresentam aplicações de ML para precificação conclusão

Autores/ano	Título	Aplicação de ML	Foco(s) da aplicação	Modelo ML utilizado
Toma; Abdeen; Ibrahim (2024)	<i>Predicting construction equipment resale price: machine learning model</i>	Proposição de modelo para prever com precisão os preços de revenda de equipamentos de construção	Facilitar a previsão do preço de revenda do equipamento que pode ser usado para calcular elementos do equipamento que são essenciais para desenvolver um plano confiável de substituição de equipamentos.	Levantados os fatores influentes no preço de revenda dos equipamentos para 1.700 peças de equipamento e seus preços de revenda correspondentes. Utilizados três algoritmos para ML: regressor de random forest, o regressor de árvores extras e o regressor de árvore de decisão. Os três algoritmos foram verificados e testados com dados de 340 peças de equipamento.
Gonçalves et al. (2023)	<i>Integrating Machine Learning for Predicting Future Automobile Prices: A Practical Solution for Enhanced Decision-Making in the Automotive Industry</i>	Usado para prever preços de venda de veículos a fim de propiciar estratégias eficientes de preços, gestão do inventário e tomar decisões acuradas.	Implementar um modelo que utiliza técnicas de PCP (Planejamento e Controle da Produção) e Machine Learning para prever o preço de venda de veículos.	Inicialmente foi analisado o procedimento atual da empresa através de um diagrama BPM (Business Process Model), coletar dados dos 5 veículos com maior rotatividade na empresa. O estudo resultou na implementação de um fluxo (incluindo árvore de decisão) de PCP e ML automatizado que alavancou as vendas da empresa.

FONTE: Os autores (2024)

CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi indicar um ou mais modelos de machine learning para precificar projetos da árvore de Natal molhada, um dos produtos chaves da empresa, produzida na planta da empresa em São José dos Pinhais - PR. Para atingir este objetivo, foi conduzido um levantamento de artigos científicos referentes a aplicações de ML para processos similares. Foi feito um levantamento inicial de artigos, que resultou em aproximadamente 1800 arquivos e, após exaustivas seleções e filtros, chegou-se a seis artigos que apresentam contribuições relevantes ao contexto apresentado. Todos os seis artigos discutem sobre aplicações *de machine learning* para otimização na precificação, alguns mais especificamente para produtos de grande porte e maior complexidade.

Apresentaram-se assim possibilidades que devem ser devidamente adequadas para utilização na empresa. Em qualquer alternativa que se apresente, é importante

que se tenha a participação de um cientista de dados competente para se extrair o resultado mais significativo para a empresa.

Como sugestão para estudos futuros, é importante recortar ainda mais o escopo de análise, buscando em artigos voltados especificamente para o setor de óleo e gás. Também, um estudo voltado a definir quais as variáveis apresentam maior impacto na formação de preços no contexto brasileiro.

REFERÊNCIAS

ACOSTA, P. C. et al. Machine learning in intelligent manufacturing system for optimization of production costs and overall effectiveness of equipment in fabrication models. **Journal of Physics: Conference Series**, v. 1432, n. 1, p. 012085, 2020.

AGRAWAL, N. et al. How machine learning will transform supply chain management. **Harvard Business Review**, mar./abr. 2024. Disponível em: <https://hbr.org/2024/03/how-machine-learning-will-transform-supply-chain-management>. Acesso em: 30 jun. 2024.

AMBADIPUDI, R. How machine learning will transform your industry. **Forbes**, 27 fev. 2023. Disponível em: <https://www.forbes.com/sites/forbestechcouncil/2023/02/27/how-machine-learning-will-transform-your-industry/#:~:text=Machine%20learning%20is%20a%20rapidly>. Acesso em: 9 jul. 2024.

BABBIE, E. R. **The practice of social research**. Belmont, CA: Wadsworth Cengage Learning, 2016.

BASE SCOPUS – Elsevier Analyze search results.(2023) Disponível em: <https://www.periodicos.capes.gov.br> Acesso em: 15 mai. 2024.

BILAL, M. A machine learning approach to pricing in expansive businesses. In: INTERNATIONAL CONFERENCE ON COMPUTER COMMUNICATION AND INFORMATICS (ICCCI), 2017. **Anais [...]**, IEEE, 2017. Disponível em: <https://ieeexplore.ieee.org/document/8117691>. Acesso em: 10 jul. 2024.

BISHOP, C. M. **Pattern recognition and machine learning**. Singapore: Springer, 2006.

BOEIJE, H. **Analysis in qualitative research**. London: Sage, 2010.

BOOTH, A.; SUTTON, A.; PAPAIOANNOU, D. **Systematic approaches to a successful literature review**. 2. ed. [s.l.]: Sage Publications, 2021.

BOYKO, N.; LUKASH, O. Methodology for estimating the cost of construction equipment based on the analysis of important characteristics using machine learning methods. **Journal of engineering**, v. 2023, n. 1, p. 1–27, set. 2023.

BROWNLEE, J. **Data preparation for machine learning**: data cleaning, feature selection, and data transforms in Python. 2020. Disponível em: [https://github.com/aaastark/Data-Scientist-Books/blob/main/Data%20Preparation%20for%20Machine%20Learning%20Data%20Cleaning%2C%20Feature%20Selection%2C%20and%20Data%20Transforms%20in%20Python%20by%20Jason%20Brownlee%20\(z-lib.org\).pdf](https://github.com/aaastark/Data-Scientist-Books/blob/main/Data%20Preparation%20for%20Machine%20Learning%20Data%20Cleaning%2C%20Feature%20Selection%2C%20and%20Data%20Transforms%20in%20Python%20by%20Jason%20Brownlee%20(z-lib.org).pdf). Acesso em: 2 jul. 2024.

CRESWELL, J. W. **Research design**: qualitative, quantitative, and mixed methods approaches. 4. ed. London: Sage Publications, 2014.

DIETTERICH, T. Overfitting and undercomputing in machine learning. **ACM Computing Surveys**, v. 27, n. 3, p. 326-327, set. 1995.

DOLGOV, A. M.; LYUKEVICH, I. N.; DOLGOV, V. M. Application of machine learning methods in pricing. **Vestnik Altai Academy of Economics and Law**, v. 1, n. 4, p. 52-59, jan. 2022.

DOMINGOS, P. A few useful things to know about machine learning. **Communications of the ACM**, v. 55, n. 10, p. 78, 1 out. 2012.

GONÇALVES, M. C. et al. Integrating Machine Learning for Predicting Future Automobile Prices: A Practical Solution for Enhanced Decision-Making in the Automotive Industry. **Lecture Notes in Computer Science**, v. 14316, n. I3E 2023, p. 91–103, 15 dez. 2023.

IZBICKI, R.; SANTOS, T. M. DOS. **Aprendizado de máquina: uma abordagem estatística**. 1a. Ed. ed. SP: UICLAP, 2020.

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, n. 31, p. 685–695, 8 abr. 2021.

MAHESH, B. Machine Learning Algorithms -A Review. **International Journal of Science and Research (IJSR) ResearchGate Impact Factor**, v. 9, n. 1, 2018.

MCKINSEY & CO. **Technology Trends Outlook 2022 Industrializing machine learning** McKinsey.com. [s.l.: s.n.]. Disponível em: <<https://www.mckinsey.com/spContent/bespoke/tech-trends/pdfs/mckinsey-tech-trends-outlook-2022-industrializing-ml.pdf>>. Acesso em: 2022.

MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997.

MOHAMMED, M.; MUHAMMAD BADRUDDIN KHAN; BASHIER, M. **Machine learning : algorithms and applications**. Boca Raton: CRC Press, 2017.

MURPHY, K. P. **Machine learning : a probabilistic perspective**. Cambridge (Ma): Mit Press, 2012.

ROKACH, L.; MAIMON, O. **Data Mining With Decision Trees: Theory And Applications**. 2a. ed. Hackensack, NJ: World Scientific, 2014.

SHAFKHAN, M. T. M. et al. **Price Optimisation and Management**. IEEE Xplore. **Anais...** In: 2021 3RD INTERNATIONAL CONFERENCE ON ADVANCEMENTS IN COMPUTING (ICAC). IEEE, 11 jan. 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9671224/authors#authors>>. Acesso em: 6 abr. 2024

SHARIFANI, K.; AMINI, M. **Machine Learning and Deep Learning: A Review of Methods and Applications**. Disponível em: <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4458723>. Acesso em: 2023.

SHARMA, R. et al. A Systematic Literature Review on Machine Learning Applications for Sustainable Agriculture Supply Chain Performance. **Computers & Operations Research**, v. 119, p. 104926, fev. 2020.

SONG, Y.-Y.; LU, Y. Decision tree methods: applications for classification and prediction. **Shanghai Archives of Psychiatry**, v. 27, n. 2, abr. 2015.

SORAL, S. et al. **Unlocking the power of AI**. Disponível em: <<https://www2.deloitte.com/us/en/insights/focus/cognitive-technologies/ai-and-machine-learning.html>>. Acesso em: 20 dez. 2023.

SUTTON, R. S.; BARTO, A. **Reinforcement learning : an introduction**. Cambridge, Ma ; Lodon: The Mit Press, 2018.

TOMA, H. M.; ABDEEN, A. H.; IBRAHIM, A. Predicting construction equipment resale price: machine learning model. **Engineering construction and architectural management**, 16 fev. 2024.

WUEST, T. et al. Machine learning in manufacturing: advantages, challenges, and applications. **Production & Manufacturing Research**, v. 4, n. 1, p. 23–45, jan. 2016.