

Previsão e Controle de Tempos das Entregas em Plataformas de Serviços com Inteligência Artificial

Guilherme Barrado Pereira, Rogério de Oliveira

Faculdade de Computação e Informática (FCI)
Universidade Presbiteriana Mackenzie (UPM) – São Paulo – SP – Brasil

gbp.guilherme@gmail.com, rogerio.oliveira@mackenzie.br

Abstract. *Delivery service platforms, or delivery platforms, play an increasingly pivotal role in the consumption of various products and services. This study utilizes data from a marketplace for the sale and distribution of household cooking gas to end consumers, aiming to build a machine learning model for predicting delivery times and enhancing data management. Different machine learning models are applied and compared, and the analysis allows the identification of the main offenders affecting delivery times for better control and informed business decision-making within the platform's operation. The final model uses the Extremely Randomized Trees algorithm and is more accurate than the method currently used by the company.*

Resumo. *Plataformas de serviços de entrega, ou plataformas de delivery, desempenham um papel cada vez mais importante no consumo de diferentes produtos e serviços. Este trabalho emprega dados de uma plataforma de venda e distribuição de gás de cozinha a consumidores finais para construir um modelo de aprendizado de máquina de previsão de tempos das entregas para uso na gestão dos serviços. Diferentes modelos de aprendizado de máquina são aplicados e comparados, e a análise permite identificar os principais ofensores para um melhor controle dos tempos de entrega e a tomada de decisões de negócio na operação da plataforma. O modelo final utiliza o algoritmo Extremely Randomized Trees e tem mais acurácia que o método empregado atualmente pela empresa.*

1. Introdução

O desenvolvimento do comércio eletrônico vem contribuindo para a mudança dos padrões de consumo e, cada vez mais, consumidores preferem utilizar plataformas online para encomendar produtos impulsionados pela expansão dos serviços de banda larga e dos meios de pagamentos eletrônicos. Isso é particularmente presente na entrega de comida, caracterizando as chamadas operações O2O, *online to offline*, em que a transação é iniciada de forma online e concluída de forma offline com a entrega da refeição (Shankar, et al., 2022; Li, et al. 2020).

Esse modelo surge como uma tendência popular e uma ferramenta para se chegar a um maior número de consumidores de forma rentável (Shankar, et al., 2022). Esse mesmo modelo de negócios vem sendo aplicado também a outros tipos de produtos, como compras de supermercado e remédios. Há empresas que optam por um aplicativo e serviços próprios, e outras que optam pelo emprego de uma plataforma agregadora de vários fornecedores e ajudando-as a chegar a um mercado mais amplo. Muito se discute e há muitos trabalhos sobre como essa *uberização* dos serviços impacta nos mercados, altera os comportamentos sociais e gera precarização do

trabalho. Mas parece haver poucos trabalhos sobre formas de se gerir essas complexas plataformas.

Atualmente mais de 90% da população brasileira depende da distribuição de gás GLP (botijões) todos os dias, seja em residências ou em atividades ligadas a indústria (Consigaz, 2023), e uma das importantes opções hoje disponíveis de venda é através de aplicativos online, trazendo praticidade para os consumidores, mas também desafios para gestão em um ambiente mais competitivo.

Este trabalho apresenta e implementa uma solução baseada em modelos de aprendizado de máquina para a previsão e controle de tempos das entregas em uma plataforma de venda e entrega de gás de cozinha. Busca, assim, fornecer mecanismos baseados em dados para melhor gestão dos serviços e fornecedores.

A plataforma consiste em um aplicativo móvel onde o usuário pode selecionar, a partir de um endereço, as revendas de gás mais próximas, os produtos desejados, e buscar o tempo de entrega mais rápido ou o menor preço. Os revendedores têm acesso à plataforma e podem aceitar ou rejeitar pedidos feitos pelos clientes.

2. Referencial Teórico

Neste projeto, são empregados vários conceitos e técnicas de inteligência artificial e aprendizado de máquina. Também são empregados conceitos utilizados no segmento de empresas e negócios. Técnicas e métricas utilizadas em outros artigos científicos com problemas correlatos a este projeto são analisadas. Esta seção fornece uma breve revisão de cada um desses temas.

2.1 Decisões orientadas a Dados

Diversas empresas ao redor do mundo têm corrido contra o tempo para modernizarem-se ao digitalizar suas operações para tornarem-se orientadas à dados, pois as empresas que saíram na dianteira dessa corrida tornaram-se mais competitivas que as demais (Henke et al., 2016; Bughin et al., 2018).

O conhecimento extraído destes dados é utilizado para a tomada estratégica de decisões e para automação e melhoria de diversas atividades em toda cadeia industrial, demonstrando casos de sucesso com a aplicação de diferentes técnicas de Inteligência Artificial nos mais variados segmentos de negócio, seja no desenvolvimento de carros autônomos, no reconhecimento de imagem aplicada a diagnósticos de saúde, na tradução de textos e de fala, em sistemas de recomendação etc (Oluyisola et al., 2020; Marr, 2020; Ludermir, 2020).

2.2 Aprendizado de Máquina Supervisionado

Envolve o uso de estatística e métodos de otimização que permitem com que conjuntos de dados rotulados sejam analisados em busca de padrões para a construção de modelos matemáticos que são avaliados com base na capacidade preditiva em relação às medidas de variância dos próprios dados (Nasteski, 2017). É composto por técnicas de classificação em que os dados são classificados de acordo com uma classe pré-definida e por técnicas de regressão que preveem um valor numérico a partir da análise (Salian, 2018). Devido à natureza do algoritmo que se atualiza de forma autônoma, a taxa de

erro é reduzida a cada execução, ou seja, o algoritmo é capaz de aprender a partir dos dados analisados (IBM Cloud Education; 2020).

A seleção do algoritmo a ser utilizado é uma etapa importante do projeto e é feita através da comparação de métricas como Erro Percentual Absoluto Médio (MAPE), o Erro Absoluto Médio (MAE) e Erro Quadrático Médio (MSE). *Gradient Boosting*, *Decision Tree*, *Random Forest* e *Support Vector Machines* (SVM) estão entre as técnicas mais utilizadas por apresentarem melhor performance em métodos de regressão (Almaghrebi et al., 2020).

2.3 Decision Tree, Ensemble Methods e Recursive Feature Elimination

Decision Tree ou árvore de decisão, é um algoritmo recursivo que possui nós relacionados de forma hierárquica em um formato que lembra uma árvore. Cada nó representa uma decisão tomada em cima de uma variável do conjunto de dados e o nó raiz representa a variável mais importante. *Ensemble Methods* fazem a combinação de diversas técnicas de ranqueamento de variáveis, com objetivo de melhorar a seleção.

Random Forest é uma técnica que utiliza conjuntos de árvores de decisão que são geradas utilizando uma amostra aleatória dos dados. As variáveis de corte, para formação dos nós, são escolhidas de forma aleatória e a combinação de todas as árvores é utilizada para obtenção dos resultados (Hartshorn, 2016). A técnica *Recursive Feature Elimination* emprega modelos de *Random Forest* para a seleção de variáveis que são mais interpretáveis e têm menos custo de treinamento (Kuhn et al., 2018, Seijo-Pardo et al., 2015). Por fim, *Extremely Randomized Trees* as árvores da floresta são construídas de modo totalmente aleatório e suas estruturas são independentes dos valores de saída da amostra de aprendizagem (Geurts et al., 2006).

2.4 Trabalhos correlatos

Já há algum tempo algoritmos de aprendizado de máquina vem sendo empregados também junto a modelos tradicionais estatísticos e de previsão de séries temporais nos mais diversos segmentos (Rundo, 2019). Alguns desses trabalhos empregados para a previsão de tempos de viagens, tempos de deslocamento etc. são relacionados a seguir.

Técnicas de regressão, entre elas *Random Forest* e *SVM* foram aplicadas para a previsão do tempo de viagem em transporte de passageiros na cidade do Porto, em Portugal. O trabalho utiliza o Erro Quadrático Médio como métrica e conclui que para o problema apresentado e os dados utilizados para treinamento, a técnica *Random Forest* foi superior a técnica *SVM* (Moreira et al., 2005).

SVM e outras técnicas de regressão foram aplicadas para a previsão do tempo de viagem em empresas de transporte multimodal de cargas. Este trabalho utilizou o Erro Absoluto Médio como métrica e demonstra a importância da seleção de variáveis para melhorar a acurácia dos modelos comparando modelos criados com diferentes “arquiteturas” de dados. A técnica *SVM* se mostrou superior após ser treinada e comparada com as demais (Servos et al., 2020).

Decision Trees, *Extremely Randomized Trees*, Redes Neurais Artificiais e técnicas de aprendizado profundo, como Redes Neurais Recorrentes foram aplicados para a previsão do tempo de deslocamento para corridas de táxi com bom desempenho,

comparando e demonstrando os diferentes resultados obtidos a partir da melhor seleção de variáveis e diferentes configurações dos modelos (Joshi et al., 2017; Lam et al., 2015).

Este trabalho utiliza dados rotulados com os tempos de entregas reais, de modo que o modelo supervisionado de aprendizado de máquina é empregado para as previsões. Dada a natureza do problema, são utilizadas técnicas de regressão como *Decision Tree*, *Random Forest*, *Extremely Randomized Trees*, *SVM* e *Gradient Boosting*. Neste estudo, interessa não só a previsão dos tempos de entrega, mas também a identificação das variáveis mais predictoras.

3. Metodologia da pesquisa

Apresenta-se a seguir as tarefas e métodos utilizados neste trabalho. É apresentado o conjunto inicial de dados brutos que foram utilizados para análise exploratória. O processo de preparação é descrito e detalha tarefas como derivação de variáveis e remoção de *outliers*. Os modelos e as métricas utilizadas são apresentadas assim como a estratégia de treinamento.

3.1 Dados

Os dados utilizados no desenvolvimento do projeto foram disponibilizados pela empresa em um arquivo no formato .CSV. Dados pessoais e/ou sensíveis foram ofuscados previamente por questões de privacidade e confidencialidade. Os dados totalizam 8.421 instâncias distribuídos ao longo de um período de 13 meses. A figura 1 apresenta uma amostra dos dados brutos empregados no trabalho.

quantity	holiday	time_elapsed	ongoing_orders	waze_avg_time	waze_avg_distance	datetime	reseller
1	False	18.459633	1	8.583333	3.136	2022-09-01 10:50:00	B
1	False	31.472517	0	11.183333	5.397	2022-09-01 13:21:00	A
1	False	29.343333	0	8.400000	3.123	2022-09-01 17:51:00	A
1	False	46.103800	0	12.733333	4.536	2022-09-01 18:35:00	B
1	False	20.950450	0	8.866667	3.524	2022-09-02 10:13:00	D

Figura 01: Dados brutos para treinamento

O repositório de código deste projeto disponibiliza o dicionário de dados com mais detalhes de cada variável assim como os próprios dados brutos. Os arquivos estão disponíveis em <https://github.com/gbpereira/time_prediction/tree/main/data>.

3.2 Análise Exploratória

A análise exploratória é uma etapa crucial do trabalho e visa investigar o conjunto de dados para entender as principais características com objetivo de revelar padrões, tendências e relações que podem orientar análises mais aprofundadas que podem evidenciar a necessidade de derivação de variáveis já existentes ou até mesmo a necessidade de adicionar novas variáveis ao conjunto inicial.

A figura 2 ilustra os gráficos com a distribuição dos pedidos e os tempos médios de entrega ao longo do dia e ao longo da semana. Os gráficos superiores demonstram a

relação entre o menor número de pedidos que coincide com menor tempo médio de entrega ao longo da semana. A distribuição da quantidade de pedidos e os tempos médios de entrega são demonstrados nos gráficos inferiores. A quantidade de pedidos varia ao longo do dia com dois picos em horários de refeição, enquanto os picos dos tempos médios ocorrem em horários de trânsito intenso de veículos.

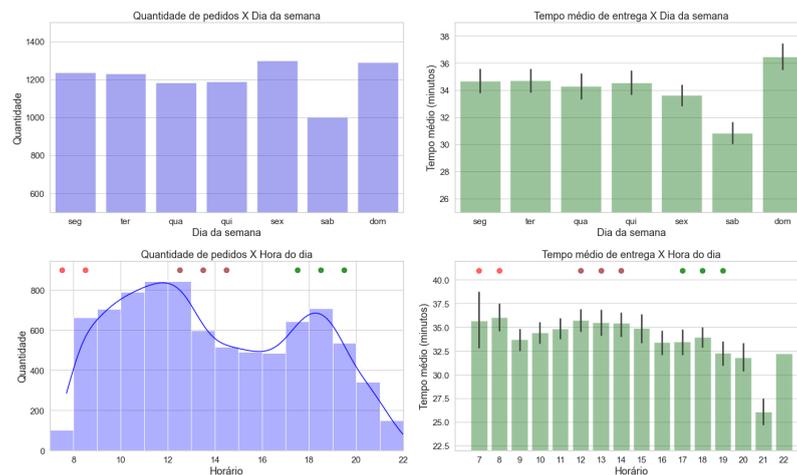


Figura 02: Tempos médios e quantidade de pedidos por dia da semana e horário

A variação da quantidade de pedidos e do tempo médio de entrega ao longo dos dias da semana e horários do dia foram fatores que indicaram a necessidade de derivação da variável “*datetime*” em outras variáveis que foram utilizadas no treinamento com a finalidade de aumentar a explicabilidade e melhorar a robustez dos modelos.

3.3 Preparação dos dados

Na preparação dos dados foi feito o levantamento do tempo e distância média entre as rotas disponíveis entre o endereço da revenda e o endereço do pedido. As duas informações foram calculadas utilizando a biblioteca *WazeRouteCalculator*. A partir deste cálculo, as informações foram adicionadas ao conjunto de dados com os rótulos “*waze_avg_time*” e “*waze_avg_distance*”, contendo o tempo e distância média respectivamente. Por questões de confidencialidade e privacidade, as informações contendo as coordenadas geográficas foram removidas previamente do conjunto de dados.

A figura 3 representa um histograma comparando os tempos médios de rota calculados com a média do tempo de entrega real. A diferença entre os valores é decorrente do tempo operacional da revenda entre aceitar o pedido, fazer a separação do(s) produto e realizar a entrega dele.

A variável “*datetime*”, que contém a data e hora de criação do pedido, foi convertida nas variáveis “*day*”, “*hour*” e “*weekday*”, contendo respectivamente o dia do mês, a hora do dia e o dia da semana. Os atributos “*holiday*” e “*reseller*” passaram pelo

processo de *encoding*, que converte valores categóricos em valores numéricos capazes de serem utilizados pelos modelos.

O conjunto de dados também foi analisado com a finalidade de remover *outliers*, que interferem no treinamento dos modelos. Para isso foi calculado o Intervalo Interquartil (IRQ) e foram removidas todas as instâncias com *time_elapsed* acima do limite superior ou abaixo do limite inferior. O conjunto de dados ficou com 8.063 instâncias após este processo.

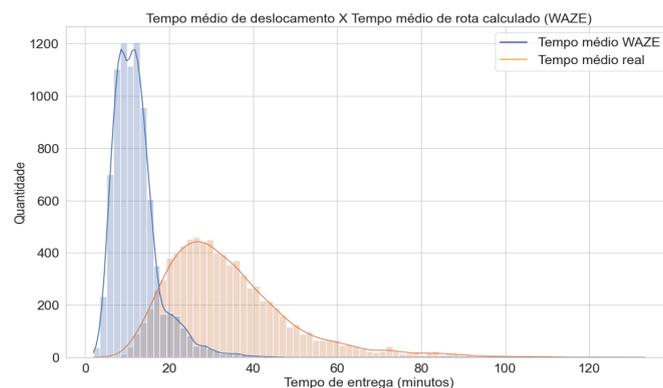


Figura 03: Comparação entre os tempos de entrega e o tempo de deslocamento médio para a rota de entrega

O conjunto de dados também foi analisado com a finalidade de remover *outliers*, que interferem no treinamento dos modelos. Para isso foi calculado o Intervalo Interquartil (IRQ) e foram removidas todas as instâncias com *time_elapsed* acima do limite superior ou abaixo do limite inferior. O conjunto de dados ficou com 8.063 instâncias após este processo.

Por fim, todas as variáveis, agora com tipo numérico, passaram pelo processo de normalização com objetivo de ajustar a escala dos valores. Esta etapa é necessária para deixar os modelos mais robustos e menos sensíveis a *outliers*.

3.4 Treinamento e Seleção dos modelos

Os algoritmos para treinamento foram selecionados a partir da análise do *MAPE* (Erro percentual absoluto médio) com o treinamento de toda a base de dados utilizando validação cruzada (*Cross-validation*). Os seguintes modelos foram treinados e comparados: *Decision Tree*, *Random Forest*, *Recursive Feature Elimination*, *Extremely Randomized Trees*, *SVM*, *AdaBoost*, *Gradient Boosting*, *Histogram-based Gradient Boosting* e *Bagging*.

A figura 4 demonstra a comparação entre os modelos ordenados pelo *MAPE*. Além do *MAPE*, também foram comparados o Erro absoluto médio (*MAE*) e Erro quadrático médio (*MSE*). Os três (3) modelos mais bem classificados foram escolhidos, sendo: *Extremely Randomized Trees*, *Recursive Feature Elimination* (RFE) e *Random Forest*.

O tempo médio de entrega de cada revenda é calculado sempre com base nos últimos noventa (90) dias e flutua ao longo do tempo com a empresa fazendo esforços contínuos para torná-los cada vez menores. Dada essa variação, dados muito antigos acabam por gerar ruídos nos resultados dos modelos e por isso a estratégia de treinamento consistiu em treinar o modelo com dados de noventa (90) dias para testá-lo em seguida com dados dos próximos trinta (30) e analisar os resultados.

Regressor	mae	mse	mape
extra trees	5.007639	37.657613	0.162562
rfe	5.025565	37.782627	0.163192
random forest	5.028963	37.813240	0.163287
svm	5.137934	40.689942	0.164663
decision tree	5.088653	39.147300	0.165164
grad boosting	5.061172	38.246626	0.165454
bagging	5.140261	39.601932	0.167118
hist grad boosting	5.084300	38.649263	0.167784
ada boost	5.210779	39.713190	0.174214

Figura 04: Comparação entre métricas dos algoritmos de regressão treinados com toda a base de dados

4. Resultados

Esta seção apresenta os resultados do trabalho, onde os modelos foram comparados buscando aquele com maior acurácia dentro das métricas estabelecidas. Foi feita uma análise da explicabilidade do melhor modelo fornecendo *insights* para a empresa.

4.1 Previsão do tempo de entrega

Para cada um dos três (3) modelos selecionados, foi calculado o Erro percentual absoluto médio (*MAPE*) e Erro quadrático médio (*MSE*) utilizando como treinamento os dados que compreendem o período entre 01/07/2023 e 31/09/2023. Os dados utilizados para previsão compreendem o período entre 01/10/2023 e 30/10/2023. A figura 5 demonstra os resultados de cada modelo, *Extremely Randomized Trees* continuou tendo o melhor desempenho com *MAPE* de 0.164471 e *MAE* de 4.376498 superando o método atual utilizado pela empresa.

Regressor	M.A.P.E.	M.A.E.
Extra Trees	0.164471	4.376498
Random Forest	0.161812	4.314617
Recursive Feature Elimination	0.161812	4.314617
Método atual	0.202354	4.572104

Figura 05: Comparação entre métricas dos modelos treinados com 90 dias

4.2 Explicabilidade do modelo

Cada modelo faz seu próprio ranqueamento de variáveis que têm mais impacto no tempo de entrega e aquelas variáveis que são irrelevantes durante o treinamento. A explicabilidade dos modelos foi analisada a procura de *insights* que possam auxiliar a empresa na tomada de decisões. As variáveis e suas importâncias foram determinadas pelo modelo *Extremely Randomized Trees*, aquele que teve o menor Erro percentual absoluto médio (MAPE) no treinamento com todo o conjunto de dados. O tempo de rota e a distância entre os endereços são os principais ofensores no tempo de entrega dos pedidos, com 76% e 17% respectivamente de importância.

As variáveis referentes ao tempo e distância de rota foram removidas do conjunto e as variáveis restantes foram normalizadas para uma nova análise de importância. O maior ofensor, “*reseller_label*”, com aproximadamente 31% de importância evidencia os diferentes “tempos operacionais” de cada revendedor. O segundo ofensor, “*ongoing_orders*”, mostra como a quantidade de pedidos em andamento impacta nos tempos de entrega e evidencia a necessidade de entregadores suficientes em horários de pico para garantir que os pedidos sejam entregues dentro do tempo previsto.

Features	Importances
waze_avg_time	0.763503
waze_avg_distance	0.178882
reseller_label	0.020250
ongoing_orders	0.014076
hour	0.006652
weekday	0.006543
day	0.006405
quantity	0.001955
holiday_label	0.001734

Features	Importances
reseller_label	31.751388
ongoing_orders	19.069918
day	16.098059
hour	15.296113
weekday	13.851388
quantity	3.546000
holiday_label	0.387134

Figura 06: Relevâncias de cada variável para o tempo de entrega

A figura 6 contém as relações de variáveis e suas importâncias. A tabela à esquerda representa a relação completa de variáveis, enquanto a tabela à direita representa a relação sem levar em consideração variáveis de tempo e distância de rota (segunda análise).

5. Conclusão e Trabalhos futuros

O objetivo geral deste trabalho foi criar um modelo utilizando técnicas de aprendizado de máquina, capaz de prever os tempos de entrega dos pedidos no marketplace da empresa, fornecendo informação mais confiável aos clientes finais. Durante o desenvolvimento, também foi possível identificar aquelas variáveis que tem maior impacto no tempo de entrega dos pedidos.

Os 3 melhores modelos foram analisados e treinados utilizando o mesmo conjunto de dados e, utilizando o *MAPE* como métrica, foi escolhido o algoritmo *Extremely Randomized Trees* como aquele que faz previsões com maior acurácia. Com

MAPE de 0.164471, este modelo se mostra superior ao método empregado atualmente pela empresa com *MAPE* de 0.202354 calculado no mesmo período.

Trabalhos futuros podem envolver o uso de outras técnicas e algoritmos com intuito de chegar a modelos com ainda mais acurácia. Dada a natureza do negócio da empresa (marketplace), o trabalho também pode ser adaptado e utilizado como base para modelos de previsão em outras plataformas que possuem entregas feitas por terceiros. Outra possibilidade é buscar novas variáveis ou novas variáveis derivadas que possam ser adicionadas aos modelos aumentando sua acurácia.

Todo este projeto, dados e artefatos podem ser acessados de modo livre no repositório disponível em <https://github.com/gbpereira/time_prediction>.

Referências

- Almaghrebi, A., Aljuheshi, F., Rafaie, M., James, K. e Alahmad, M. (2020) “Data-Driven Charging Demand Prediction at Public Charging Stations Using Supervised Machine Learning Regression Methods”, *Energies*, vol. 13, no. 16. Disponível em <<https://doi.org/10.3390/en13164231>>. Acesso em 12/11/2023.
- Bughin, J., Seong, J., Manyika, J., Chui, M. e Joshi, R. (2018), “Notes from the AI Frontier Modeling the Impact of AI On The World Economy”, McKinsey Global Institute.
- Geurts, P., Ernst, D., Wehenkel, L. (2006), “Extremely Randomized Trees”. *Machine Learning*. 63. 3-42. 10.1007/s10994-006-6226-1. Disponível em <<http://dx.doi.org/10.1007/s10994-006-6226-1>>. Acesso em 07/12/2023.
- GLP – Gás Liquefeito de Petróleo, Consigaz, 2023. Disponível em: <<https://www.consigaz.com.br/gas-glp/>>. Acesso em 10/11/2023.
- Hartshorn, S. (2016), “Machine Learning With Random Forests And Decision Trees”.
- Henke, N., Bughin, J., Chui, M., Manyika, J., Saleh, T., Wiseman, B. e Sethupathy, G. (2016), “The Age Of Analytics: Competing In A Data-Driven World”, McKinsey Global Institute.
- Joshi, N., Hotalappa, M. e Gadade, K. (2017) “A Study on Travel Time Estimation for Taxi Trips”, *International Education & Research Journal (IERJ)*, vol. 3. Disponível em: <<https://www.academia.edu/36968291>>. Acesso em 09/11/2023.
- Kuhn, M. e Johnson, K. (2018) “Applied Predictive Modeling”, Springer, 2a. edição.
- Lam, H. T., Diaz-Aviles, E., Pascale, A., Gkoufas, Y. e Chen, B. (2015) “Taxi Destination and Trip Time Prediction from Partial Trajectories”, arXiv. Disponível em: <<https://arxiv.org/abs/1509.05257>>. Acesso em 09/11/2023.
- Li, C., Miroso, M., & Bremer, P. (2020). Review of online food delivery platforms and their impacts on sustainability. *Sustainability*, 12(14), 5528.
- Ludermir, T. (2021) “Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências”. Disponível em: <<https://doi.org/10.1590/s0103-4014.2021.35101.007>>. Acesso em 18/11/2023.

- “Machine Learning”, IBM Cloud Education, 2020. Disponível em: <<https://www.ibm.com/cloud/learn/machine-learning>>. Acesso em 09/11/2023.
- Marr, B. (2016) “A Short History of Machine Learning Every Manager Should Read”, Forbes. Disponível em <<https://www.forbes.com/sites/bernardmarr/2016/02/19/a-short-history-of-machine-learning-every-manager-should-read>>. Acesso em: 18/11/2023.
- Moreira, J. M., Jorge, A., Sousa, J. F. e Soares, C. (2005) “Trip Time Prediction In Mass Transit Companies. A Machine Learning Approach”, Advanced OR and AI methods in transportation. Disponível em: <<https://hdl.handle.net/10216/6749>>. Acesso em 09/11/2023.
- Nasteski, V. (2017) “An overview of the supervised machine learning methods”. Disponível em: <https://www.researchgate.net/publication/328146111_An_overview_of_the_supervised_machine_learning_methods>. Acesso em 10/11/2023.
- Oluyisola, O. E., Sgarbossa, F. e Strandhagen, J. O. (2020) “Smart Production Planning and Control: Concept, Use-Cases and Sustainability Implications”. Disponível em <<https://doi.org/10.3390/su12093791>>. Acesso em 18/11/2023.
- Rundo, F., Trenta, F., di Stallo, A. L. e Battiato, S. (2019) “Machine Learning for Quantitative Finance Applications: A Survey”. Disponível em: <<https://doi.org/10.3390/app9245574>>. Acesso em 02/11/2023.
- Salian, I. (2018) “SuperVize Me: What’s the Difference Between Supervised, Unsupervised, Semi-Supervised and Reinforcement Learning?”, NVIDIA Blog. Disponível em: <<https://blogs.nvidia.com/blog/2018/08/02/supervised-unsupervised-learning/>>. Acesso em 10/11/2023.
- Seijo-Pardo, B., Bolón-Canedo, V., Porto-Díaz, I. e Alonso-Betanzos, A. (2015) “Ensemble Feature Selection for Rankings of Features”. Disponível em <https://www.researchgate.net/publication/300786598_Ensemble_Feature_Selection_for_Rankings_of_Features>. Acesso em: 18/11/2023.
- Servos, N., Liu, X., Teucke, M. e Freitag, M. (2020) “Travel Time Prediction in a Multimodal Freight Transport Relation Using Machine Learning Algorithms”, Logistics 2020. Disponível em: <<https://doi.org/10.3390/logistics4010001>>. Acesso em 08/11/2023.
- Shankar, A., Jebarajakirthy, C., Nayal, P., Maseeh, H. I., Kumar, A., & Sivapalan, A. (2022). Online food delivery: A systematic synthesis of literature and a framework development. International Journal of Hospitality Management, 104, 103240.