



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:**
Limitações e possibilidades



O USO DA INTELIGÊNCIA ARTIFICIAL NA GESTÃO DE ESTOQUES

MIRELLI DE CASTRO CESÁRIO – mirellicastro@yahoo.com.br
UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI

RAFAELA APARECIDA MENDONÇA MARQUES – rafaelaamm@hotmail.com
UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI

ANDERSON PAULO DE PAIVA – andersonppaiva@unifei.edu.br
UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI

LUCAS MANUEL FONSECA OLIVEIRA – lucas.manuel@aluno.ufop.edu.br
UNIVERSIDADE FEDERAL DE OURO PRETO - UFOP

ÁREA: 2. LOGÍSTICA
SUBÁREA: 2.2 GESTÃO DE ESTOQUES

RESUMO: ESTE ESTUDO APRESENTA A GESTÃO DE ESTOQUES EM UMA EMPRESA DE BEBIDAS. PARA REALIZAR A PREVISÃO DE DEMANDA É UTILIZADO O ALGORITMO DE APRENDIZADO DE MÁQUINA RANDOM FOREST. ESSA ABORDAGEM PERMITE UMA PREVISÃO MAIS PRECISA DAS NECESSIDADES DE REPOSIÇÃO DE PRODUTOS. EM SEGUIDA, OS ITENS SÃO CLASSIFICADOS ATRAVÉS DA METODOLOGIA ABC, QUE CATEGORIZA OS PRODUTOS COM BASE EM SUA IMPORTÂNCIA RELATIVA PARA O NEGÓCIO. ESSA CLASSIFICAÇÃO AJUDA NA PRIORIZAÇÃO DOS ESFORÇOS DE CONTROLE DE ESTOQUE, FOCANDO NOS ITENS QUE TÊM MAIOR IMPACTO NOS RESULTADOS FINANCEIROS DA EMPRESA. ALÉM DISSO, O ESTUDO CALCULA O LOTE ECONÔMICO DE COMPRA, UM MODELO MATEMÁTICO QUE DETERMINA A QUANTIDADE IDEAL A SER COMPRADA PARA MINIMIZAR OS CUSTOS TOTAIS DE ESTOQUE, LEVANDO EM CONSIDERAÇÃO OS CUSTOS DE ARMAZENAGEM, PEDIDO E FALTA DE ESTOQUE. A INTEGRAÇÃO DESSAS TÉCNICAS AVANÇADAS DE GESTÃO DE ESTOQUE NÃO APENAS MELHORA A EFICIÊNCIA OPERACIONAL, MAS TAMBÉM FORTALECE A COMPETITIVIDADE DA EMPRESA NO MERCADO. AO ADOPTAR UMA ABORDAGEM BASEADA EM DADOS PARA A GESTÃO DE ESTOQUES, A EMPRESA PODE NÃO APENAS REDUZIR OS CUSTOS OPERACIONAIS, MAS TAMBÉM AUMENTAR A DISPONIBILIDADE DE PRODUTOS, MELHORANDO A SATISFAÇÃO DO CLIENTE E IMPULSIONANDO O CRESCIMENTO SUSTENTÁVEL A LONGO PRAZO.

PALAVRAS-CHAVES: GESTÃO DE ESTOQUES; CLASSIFICAÇÃO ABC; PREVISÃO DE DEMANDA.

1. INTRODUÇÃO

A gestão de estoques preocupa-se principalmente com o planejamento e controle do estoque de uma indústria e é um componente importante da gestão da cadeia de suprimentos. Inclui questões como estimativa das necessidades de materiais em vários pontos da cadeia de abastecimento, determinação da quantidade de material necessária, frequência de pedidos e níveis de estoque de segurança.

A integração de tecnologias de inteligência artificial, como *machine learning* e algoritmos preditivos, permite realizar previsões de demanda mais precisas e otimização dos níveis de estoque, resultando em maior eficiência operacional e redução de custos. Além disso, a automação de processos de armazenamento e distribuição melhora significativamente a rapidez e a precisão das operações. Embora a implementação dessas técnicas traga desafios, como a necessidade de investimentos iniciais e a integração com sistemas legados, os benefícios superam essas dificuldades.

A combinação da gestão de inventário com técnicas de inteligência artificial torna esse processo eficiente e flexível, com custos operacionais mais baixos, fornece tempos de resposta mais rápidos aos clientes, bem como informações mais contextuais. O gerenciamento de estoque é usado em diversos contextos, como varejo (SRIDHAR; VISHNU; SRIDHARAN, 2021), logística (GRANILLO-MACÍAS, 2020; NALLUSAMY, 2021), gerenciamento da cadeia de suprimentos (ACOSTA *et al.*, 2018), fontes múltiplas de suprimento (XIE; WANG; YANG, 2021), gerenciamento de estoque econômico (TIAN; WANG; ERJIANG, 2021), controle de estoque (DO REGO ; DE MESQUITA, 2015), previsão de estoque (TANGTISANON, 2018) e previsão de vendas (YU *et al.*, 2017).

Realizar uma previsão precisa da demanda é considerada uma necessidade para o gerenciamento adequado de estoque. Isso porque permite que as empresas aumentem os lucros, comercializem os seus produtos e melhora a satisfação do cliente (KUMAR; SHANKAR; ALJOHANI, 2020). Além disso, auxilia no desenvolvimento de uma estratégia de preços adaptativa para uma melhor gestão das receitas (SEYEDAN ; MAFAKHERI; WANG, 2022).

Algumas pesquisas já propõem a utilização de técnicas de *machine learning* para suporte em problemas relacionados à gestão de estoques. KANTASA-ARD *et al.* (2021) apresentam uma abordagem de previsão de demanda para cadeias de suprimentos complexas usando um modelo *Long Short-Term Memory (LSTM)*, com seus hiperparâmetros ajustados por um conjunto de algoritmos genéticos. KUMAR, MOOKERJEE e SHUBHAM (2018) propõem a aplicação de *No Code AI* no setor de varejo como uma solução econômica em termos de tempo

e custo. Nesse caso, o sistema pode prever necessidades futuras de estoque com base na quantidade de produção, evitando a geração de estoques sem necessidade. Liu *et al.* (2022) propõem uma abordagem preditiva para a produção em oficinas de fabricação sob encomenda, utilizando a Internet Industrial das Coisas para aquisição de dados de produção.

Podemos observar que está em ascensão a adoção de técnicas de aprendizado de máquina para aprimorar os processos de gestão de estoques e fabricação.

Neste estudo, o objetivo principal é classificar os itens estocados por uma empresa de bebidas usando a metodologia de classificação ABC. Além disso, é aplicado o algoritmo de aprendizado de máquina *Random Forest* para prever a demanda com precisão. Adicionalmente, é calculado o lote econômico de compra, visando otimizar a gestão de estoques e minimizar custos operacionais, proporcionando uma maior eficiência nos processos de negócios.

2. REVISÃO DE LITERATURA

2.1 Gestão de estoques

O estoque representa a acumulação de informações, clientes ou materiais (como insumos, produtos semiacabados ou finalizados), podendo estar em várias fases do processo produtivo (SLACK; BRANDON-JONES; JOHNSTON, 2018).

A gestão de estoques é essencial para atingir os objetivos de cadeias de abastecimento eficientes, controlar custos e entregar aos clientes com atrasos mínimos (PEREZ *et al.*, 2021). Inclui questões como estimativa das necessidades de materiais em vários pontos da cadeia de abastecimento, determinação da quantidade de material necessária, frequência de pedidos e níveis de estoque de segurança. Também inclui visibilidade, previsão e gerenciamento de estoques, *lead time*, custos de envio, previsão de preços futuros de estoque, gerenciamento de qualidade, devoluções e produtos defeituosos e previsão de demanda (SINGH; VERMA, 2018).

Slack, Brandon-Jones e Johnston (2018) enumeram diversos motivos para manter estoques, destacando:

- Estoque como garantia contra incertezas, proporcionando segurança diante de flutuações na demanda e na aquisição de suprimentos;
- Capacidade de neutralizar inflexibilidades, assegurando o suprimento enquanto o processo produtivo está focado em outras atividades;
- Uso para antecipar demandas futuras em sistemas com grandes variações de demanda, como durante a época de Páscoa para chocolates, por exemplo;

- Redução de custos globais ao adquirir grandes lotes de insumos com potenciais descontos por economia de escala;
- Ajuda na manutenção do equilíbrio entre capacidade e demanda, criando estoques de insumos no processo produtivo para garantir equilíbrio entre oferta e demanda.

Dada a importância estratégica dos estoques para as empresas, é crucial que possuam mecanismos e ferramentas para auxiliar nas decisões relacionadas ao controle de estoques. Oliveira, Barbosa e Andrade (2019) propõem o uso da curva ABC como uma ferramenta para auxiliar na classificação de clientes, além de permitir aos gestores a identificação de políticas de vendas, armazenagem, produção e outras informações pertinentes aos produtos.

Segundo Lyra e Lazer (2017), a curva ABC é um método que possibilita aos gestores identificar quais itens requerem atenção prioritária em compras e vendas, determinar os produtos de maior rotatividade na empresa e reorganizar o estoque. Chagas e Loos (2019) corroboram, afirmando que essa ferramenta também oferece controle facilitado na busca e movimentação dos produtos estocados.

Inicialmente, a classificação dos itens era realizada com base no critério de uso anual do dólar (DICKIE, 1951). Com o passar dos anos a classificação ABC passou a ser usada tanto para valor movimentado em determinado período quanto considerando o giro de estoque. Porém, apesar de serem os dois critérios mais comuns para classificar estoque, outros critérios podem contribuir nessa classificação, como: consequência da falta de estoque (deve-se priorizar itens que atrasariam ou interromperiam a produção); incerteza de fornecimento (itens que demandarão maior atenção se o fornecimento for incerto); itens com alta obsolescência ou risco de deterioração (SLACK; BRANDON-JONES; JOHNSTON, 2018).

Trabalhos mais recentes como Yiğit e Esnaf (2021) consideram outros critérios como base para a classificação dos itens, podendo incluir custo unitário, variabilidade do lead time de reposição, escassez, substitutibilidade, etc.

Os itens com valor movimentado particularmente alto demandam controle cuidadoso, enquanto os de baixo valor movimentado não precisam ser controlados com tanto rigor. Geralmente, uma proporção relativamente pequena dos itens estocados representará grande proporção do valor movimentado total.

O controle de estoque ABC permite aos gerentes de estoque concentrarem seus esforços no controle dos itens mais significativos do estoque:


- Itens classe A são aqueles 20% de itens de alto valor que representam cerca de 80% do valor total do estoque.

- Itens classe B são aqueles de valor médio, normalmente os 30% de itens seguintes que representam cerca de 10% do valor total.
- Itens classe C são aqueles de baixo valor que, não obstante compreender cerca de 50% do total de tipos de itens estocados, provavelmente representam apenas 10% do valor total dos itens estocados.

Na gestão de estoques é muito importante evitar incertezas, que geralmente ocorrem nas previsões de demanda durante o *lead time*. As previsões de demanda constituem a base de todas as atividades de planejamento, pois são a base para muitas decisões operacionais (ABBASIMEHR; SHABANI; YOUSEFI, 2020).

O método mais comum para decidir quanto de um item particular pedir, quando o estoque precisa ser reabastecido, é a técnica do lote econômico de compra, representado na Figura 1. Essa abordagem tenta encontrar o melhor equilíbrio entre os custos de falta, custos de manutenção e custos de pedidos, determinando a quantidade de pedido que minimiza o custo total desses três componentes (SLACK; BRANDON-JONES; JOHNSTON, 2018).

FIGURA 1: Representação gráfica do lote econômico de compra



Fonte: Slack, Brandon-Jones e Johnston (2018)

Em síntese, ele auxilia as empresas a decidirem quantos itens devem ser comprados para manter um nível adequado de estoque, sem incorrer em excessos que aumentem os custos de armazenamento, nem em faltas que possam resultar em perdas financeiras ou insatisfação dos clientes.

Para simplificar a modelagem do LEC alguns pressupostos são necessários, como assumir que a demanda é estável, que existe um custo fixo e definido para cada pedido, que os custos de manutenção de estoque podem ser representados por uma função linear, que os custos de falta de estoque são identificáveis, entre outras suposições similares (SLACK; BRANDON-JONES; JOHNSTON, 2018).

A fórmula do lote econômico de compra é dada por:

$$LEC = \sqrt{\frac{2 * \text{Custo do Pedido} * \text{Demanda}}{\text{Custo de armazenagem}}} \quad (1)$$

No setor de bebidas, o pressuposto de demanda constante não se aplica amplamente, dada a natureza variável dos padrões de consumo. Por exemplo, enquanto um distribuidor pode usar o modelo de lote econômico de compra para produtos estáveis como marcas populares consolidadas, como vinhos de safras renomadas, outras bebidas podem ter demanda mais imprevisível, influenciada por tendências sazonais, promoções ou novos lançamentos. Portanto, em contextos em que a demanda pode ser volátil, como para cervejas artesanais ou licores sazonais, a aplicação do modelo LEC pode ser inadequada e exigir abordagens mais flexíveis na gestão de estoques.

3. MATERIAIS E MÉTODOS

O Aprendizado de Máquina é um subcampo da inteligência artificial que se destaca por identificar padrões complexos em grandes volumes de dados utilizando métodos computacionais e estatísticos (ALPAYDIN, 2020).

Este estudo utiliza o *random forest* para realizar previsão de demanda de produtos do setor de bebidas. Para isso, foram analisados os dados de 7658 bebidas de um depósito. A base de dados contém informações como descrição da bebida, volume (em mililitros), preço unitário, quantidade disponível em estoque e marca.

Nessa pesquisa, o modelo foi testado e avaliado usando o método de validação cruzada estratificada, o qual cada subconjunto de dados foi usado para treinar e testar os modelos de acordo com a divisão de dados. A vantagem de utilizar esse tipo de validação cruzada é que a

divisão dos dados é feita de forma a preservar a proporção de cada classe. Assim, caso as classes estejam desbalanceadas nos dados, será mantida uma proporção representativa de cada classe.

De acordo com Géron (2019) e Alpaydin (2020), o *Random Forest* consiste em um conjunto de árvores internas construídas a partir de subconjuntos aleatórios de dados pertencentes ao conjunto de treinamento principal. Para problemas de regressão, a média das previsões de todas as árvores é usada como a previsão final.

Para otimização de hiperparâmetros foi utilizado o *GridSearch* no processo de treinamento, a fim de encontrar o conjunto ótimo de hiperparâmetros para cada um dos modelos testados. Considerando a divisão do conjunto em treinamento e testes, a proporção escolhida foi 80% para treino e 20% para teste.


Após a previsão de demanda, foi realizada a classificação ABC para os produtos estocados, auxiliando na identificação dos itens mais importantes para a organização. Por fim, utilizando o lote econômico de compra foi possível identificar o tamanho ideal para reposição dos itens, permitindo aos gestores identificar a quantidade ideal a ser adquirida para evitar custos de falta de produtos ou custo de estoque desnecessário.

4. RESULTADOS E DISCUSSÕES

Conforme apresentado na seção anterior, o método de aprendizado de máquina escolhido para essa análise foi o *random forest*. Essa técnica de *machine learning* pode capturar relações complexas entre as variáveis e a demanda. Além disso, são capazes de lidar com a não-linearidade e a interação entre variáveis, o que pode ser vantajoso para modelar padrões sazonais.

O gráfico de quantidade prevista *versus* quantidade vendida, representado na Figura 2, oferece uma visão clara da performance do modelo de previsão. Embora o modelo de *Random Forest* consiga capturar a tendência geral das vendas de bebidas, ainda existem discrepâncias em períodos específicos que indicam a necessidade de refinamento.

FIGURA 2- Previsão de vendas



Fonte: Autores (2024)

Foram consideradas duas métricas para comparar os modelos: R^2 e MAPE (*Mean Absolute Percentage Error*). O R^2 avalia o quanto a variabilidade na variável dependente é explicada pelas variáveis independentes do modelo. Já o MAPE representa a média das diferenças absolutas entre os valores previstos e observados, expressa como uma porcentagem dos valores observados. Essas métricas são fundamentais para entender tanto a precisão quanto a capacidade explicativa dos modelos avaliados.

Os resultados da análise indicaram que o modelo de *Random Forest* apresentou um R^2 de 0.796, sugerindo que aproximadamente 79.6% da variabilidade na demanda por bebidas pode ser explicada pelas variáveis independentes utilizadas no modelo. Este é um bom indicador de que o modelo possui um ajuste sólido aos dados, capturando uma grande parte das variações na demanda.

No entanto, o MAPE aponta para uma margem de erro relativamente alta nas previsões, com uma discrepância média de aproximadamente 29,17% entre os valores previstos e os valores reais de demanda. Este nível de erro sugere que, embora o modelo seja eficaz em explicar a variabilidade geral, ele ainda pode ser melhorado em termos de precisão absoluta das previsões.


Para o setor de vendas de bebidas, onde a precisão das previsões de demanda é crucial para otimizar estoques e minimizar perdas, é importante buscar formas de aprimorar o modelo. Aspectos relacionados à questões sazonais e campanhas promocionais devem ser analisadas de maneira mais detalhada de modo a identificar a influência desses fatores na previsão da demanda.

Devido ao grande volume de itens estocados, as informações relacionadas ao conjunto de dados e o agrupamento dos itens seguindo a classificação ABC não serão detalhadas nessa pesquisa. No entanto, a Figura 3 apresenta o gráfico equivalente à distribuição desses itens.

Na análise do estoque de bebidas, observa-se que os itens foram classificados em três categorias de acordo com sua importância relativa para o negócio. Os itens de maior valor foram agrupados na Classe A, representando 21,31% do total de itens estocados. A Classe B compreende 28,95% dos itens, enquanto os itens da Classe C correspondem a 49,74% do total.

Esses resultados estão alinhados com o que é discutido na literatura especializada sobre gestão de estoques, destacando a distribuição variada de valor e a importância de estratégias diferenciadas para cada categoria.

FIGURA 3 – Classificação ABC



Fonte: Elaborado pelos autores

Por fim, foi calculado o lote econômico de compras para esses produtos. O tamanho calculado, para um período de dois meses, é de 636 unidades. Este valor foi determinado considerando os custos de pedido e os custos de manutenção de estoque, visando minimizar os gastos totais durante o período analisado.

Na análise dos resultados da pesquisa, optou-se por não incluir a classificação ABC no cálculo do lote econômico de compras neste momento. Isso se deve à complexidade adicional que a integração da classificação ABC acarretaria. O cálculo do lote econômico já envolve considerações complexas de custos, tornando-o um processo complexo por si só.

5. CONSIDERAÇÕES FINAIS

Esse estudo apresentou algumas técnicas para auxiliar na gestão de estoques de uma empresa do ramo de bebidas. A escolha do método *Random Forest* para previsão de demanda apresentou os resultados significativos com $R^2=79,6\%$ e $MAPE=29$, indicando uma influência substancial da sazonalidade no setor de bebidas.

Em certos períodos, como semanas específicas ou fins de semana, as vendas reais podem mostrar padrões sazonais ou eventos que não foram completamente capturados pelo modelo. Incorporar variáveis sazonais e fatores exógenos pode ajudar a reduzir esses erros de previsão, tornando o modelo mais preciso e útil para a tomada de decisões no gerenciamento de estoque e planejamento de vendas.

Para pesquisas futuras, sugere-se explorar métodos complementares de previsão que possam ajudar a melhorar os indicadores de desempenho como $MAPE$ e R^2 . A integração de técnicas avançadas de *machine learning*, ajustes nos modelos estatísticos considerando especificidades sazonais mais detalhadas, e o aprimoramento contínuo dos dados utilizados para treinamento e validação dos modelos são estratégias recomendadas. Além disso, a implementação de sistemas de monitoramento contínuo e adaptação dinâmica dos modelos às mudanças nas condições de mercado pode ser crucial para manter a precisão das previsões ao longo do tempo.

Em relação à classificação ABC, para o cálculo do lote econômico seria necessário um estudo mais aprofundado e específico para cada categoria de itens. Isso inclui a análise da variabilidade da demanda, o impacto nos processos de produção ou distribuição, e a determinação da frequência ideal de revisão de estoque para cada classe. Portanto, reservou-se essa análise para trabalhos futuros, nos quais será possível dedicar recursos e tempo suficientes para coletar dados mais detalhados e realizar uma avaliação mais precisa.

Em suma, este estudo não apenas contribui para uma gestão mais eficiente de estoques no setor de bebidas, mas também oferece um ponto de partida para futuras pesquisas e desenvolvimentos na área de previsão de demanda, com potencial para impactar positivamente a tomada de decisão estratégica e a competitividade da empresa no mercado.

6. AGRADECIMENTOS

Os autores agradecem à Universidade Federal de Itajubá (UNIFEI), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

REFERÊNCIAS

ABBASIMEHR H., SHABANI M., YOUSEFI M. Um modelo otimizado usando rede LSTM para previsão de demanda. *Eng Ind Computação* 143, 2020.

ACOSTA I. C. G. *et al.* Desenho de um sistema de gestão de estoques em uma cadeia de abastecimento agrícola considerando a deterioração do produto: o caso de pequenos produtores de citros em um país em desenvolvimento. *J Appl Eng Sci* 16(4):523–537, 2018.

ALPAYDIN, E. *Introduction to Machine Learning*. Mit Press, fourth edition, 2020.

CHAGAS, P. O. C.; LOOS, M. J. Organização do estoque com aplicação do Kaizen 3P e da Curva ABC: um estudo de caso em uma indústria têxtil. *Revista de Gestão Industrial*. Ponta Grossa, v. 15, n. 11, 2019.

DICKIE, HF A análise de estoque da ABC busca dólares, não centavos. *Facto. Gerenciar. Manutenção*. 109, 92–94, 1951.

DO REGO J.R., DE MESQUITA M.A.. Previsão de demanda e controle de estoque: um estudo de simulação em peças de reposição automotivas. *Int J Prod Economia* 161:1–16, 2015.

GÉRON, A. O cenário do aprendizado de máquinas. *Mãos à obra aprendizado de máquina com Scikit-Learn & TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes*. Rio de Janeiro: Alta Books, 2019.

GRANILLO-MACÍAS R. Gestão de estoques e otimização logística: uma abordagem prática de mineração de dados. *LogForum* 16(4):535–547, 2020.

KANTASA-ARD, A., NOUIRI, M., BEKRAR, A., AIT EL CADI, A., SALLEZ, Y. Aprendizado de máquina para previsão de demanda na internet física: um estudo de caso de produtos agrícolas na Tailândia. *International Journal of Production Research*, 59 (24), 7491–7515, 2020.

KUMAR A., SHANKAR R., ALJOHANI N.R. Uma estrutura orientada por big data para previsões orientadas pela demanda com efeitos de variáveis do mix de marketing. *Ind Mark Gerenciar* 90:493–507, 2020.

KUMAR, S.; MOOKERJEE, V.; SHUBHAM, A. Pesquisa em gestão de operações e interface de sistemas de informação. *Production and Operations Management*, v. 27, n. 11, p. 1893-1905, 2018.

- LIU, C. et al. A Transfer Learning CNN-LSTM Network-based Production Progress Prediction Approach in IIoT-enabled Manufacturing. *International Journal of Production Research* 61:4045–4068, 2022.
- LYRA, A. S.; LAZER, M.T. A importância do controle de estoque, utilizando o método de Curva ABC, em uma concessionária de veículos na cidade de Botucatu-SP. *Tekhne e Logos*, 8 (4), 16-26, 2017.
- NALLUSAMY S. Medição de desempenho em gestão de estoques e logística por meio de diversas técnicas de previsão. *Int J Executar Eng* 17(2):216–228, 2021.
- OLIVEIRA, F. S; BARBOSA, M. F. H.; ANDRADE, G. V. A classificação ABC no gerenciamento de estoque: um estudo de caso na Jota Pinto Distribuidora. *REVEXT - Revista De Extensão Da Universidade Estadual De Alagoas - UNEAL*, 2019.
- PERES, H.D. *et al.* Abordagens algorítmicas para otimização do gerenciamento de estoque. *Processos* 9(1):102, 2021.
- SEYEDAN M, MAFAKHERI F, Wang C. Previsão de demanda baseada em cluster usando média de modelo bayesiano: uma abordagem de aprendizagem em conjunto. *Decis Anal J* 3:100033, 2022.
- SINGH D, VERMA A. Gestão de estoque na cadeia de suprimentos. *Mater Hoje* 5(2):3867–3872, 2018.
- SLACK, N.; BRANDON-JONES, A.; JOHNSTON, R. *Administração da Produção*. 8. ed. São Paulo: Atlas, 2018. 856 p.
- SRIDHAR, P.; VISHNU, C.; SRIDHARAN, R. Simulação de sistemas de gestão de estoque em lojas de varejo: um estudo de caso. *Mater Hoje* 47:5130–5134, 2021.
- TANGTISANON, P. Gerenciamento de estoque de aditivos alimentares baseado em serviço web com sistema de previsão. em 2018 3ª Conferência Internacional sobre Sistemas de Computação e Comunicação 2018.
- TIAN, X.; WANG, H.; ERJIANG, E. Previsão de demanda intermitente para gestão de estoque por varejistas: uma nova abordagem. *J Varejo Atendimento ao Consumidor* 62:102662, 2021.
- XIE, C.; WANG, L.; YANG, C. Gerenciamento robusto de estoque com múltiplas fontes de fornecimento. *Eur J Oper Res* 295(2):463–474, 2021.
- YIĞIT, F.; ESNAF, Ş. Uma nova abordagem trifásica baseada em Fuzzy C-Means e AHP para classificação de inventário ABC de múltiplos critérios. *J. Intel. Fabrico.* 2021 , 32 , 1517–1528.
- YU, Q. *et al.* Aplicação de rede neural de memória de longo e curto prazo à previsão de vendas no varejo – um estudo de caso. no Workshop Internacional de Manufatura Avançada e Automação, 2017.