



ConBREpro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

Otimização Sequencial de Produção na Manufatura MTO utilizando métodos de Clusterização

Robespierre Diniz Almeida Mendes

Programa de Pós-Graduação em Engenharia de Produção - Universidade Federal do Paraná

Alan Bernardino

Programa de Pós-Graduação em Engenharia de Produção - Universidade Federal do Paraná

Mariana Kleina

Programa de Pós-Graduação em Engenharia de Produção - Universidade Federal do Paraná

Fabiano Drozda

Programa de Pós-Graduação em Engenharia de Produção - Universidade Federal do Paraná

Silvana Detto

Programa de Pós-Graduação em Engenharia de Produção - Universidade Federal do Paraná

Resumo: Com a crescente competitividade no setor automotivo e o aumento da demanda por peças de reposição em mercados emergentes, impulsionado pelo envelhecimento das frotas, as empresas estão enfrentando a necessidade de melhorar a flexibilidade de fabricação e redução de estoques. Neste cenário, muitas indústrias estão adotando uma abordagem de produção *Make-to-Order* (MTO). No entanto, a complexidade do mercado de reposição requer um planejamento de produção robusto e otimizado, visto que as demandas são distribuídas em uma maior variedade de peças e em lotes menores de produção. O estudo investiga como os algoritmos de clusterização podem ser aplicados para dividir pedidos com base nas características dos produtos, utilizando dados contínuos. Essa abordagem visa criar grupos de itens que possam melhorar o sequenciamento de produção MTO, com o objetivo de reduzir os tempos de espera relacionados aos *setups*. Analisando o planejamento de produção MTO em uma indústria de autopeças e confrontando os resultados obtidos com as técnicas de clusterização, identificou-se que o planejamento atual não considera adequadamente as semelhanças entre os produtos em termos de suas dimensões, o que resulta em desperdícios de tempo e recursos durante os *setups* de produção. Por fim, o estudo contribui para a compreensão de como técnicas de análise de dados podem ser aplicadas para melhorar a eficiência operacional e a competitividade das empresas no mercado de autopeças de reposição.

Palavras-chave: Clusterização, planejamento de produção, *setup*, *make-to-order*, mercado de reposição, *K-means*, *K-medoids*.

Sequential Production Optimization in MTO Manufacturing Using Clustering Methods

Abstract: With growing competitiveness in the automotive sector and increasing demand for spare parts in emerging markets, driven by ageing fleets, companies are facing the need to improve manufacturing flexibility and reduce inventories. In this scenario, many industries are adopting a *Make-to-Order* (MTO) production approach. However, the complexity of the aftermarket requires robust and optimized production planning, as demands are distributed over a greater variety of parts

and in smaller production batches. The study investigates how clustering algorithms can be applied to divide orders based on product characteristics, using continuous data. This approach aims to create groups of tens that can improve MTO production sequencing, with the aim of reducing setup-related waiting times. Analysing MTO production planning in an auto parts industry and comparing the results obtained with clustering techniques suggests that current planning does not adequately consider the similarities between products in terms of their dimensions, which results in wasted time and resources during production setups. Finally, the study contributes to the understanding of how advanced data analysis techniques can be applied to improve the operational efficiency and competitiveness of companies in the aftermarket auto parts market.

Keywords: Clustering, production planning, setup, make-to-order, aftermarket, K-means, K-medoids.

1. Introdução

Segundo Thompson e Zhang (2015), a fabricação sob demanda de autopeças é uma abordagem cada vez mais relevante na indústria automotiva, oferecendo diversos benefícios, mas também enfrentando desafios significativos. Entre esses desafios está a flexibilidade dos processos, que demanda uma alta complexidade de programação e planejamento da produção. Nesse contexto, a otimização sequencial de produção é fundamental, pois permite a alocação adequada dos recursos, a minimização dos custos e a maximização da satisfação do cliente.

Este trabalho apresenta a importância da otimização sequencial de produção na indústria de autopeças *aftermarket* (Mercado de reposição), que se destaca pela fabricação sob demanda. Será discutida detalhadamente a relevância desse tema no contexto amplo e dinâmico das operações fabris, considerando os significativos impactos positivos que a aplicação de técnicas de clusterização K-Means e K-Medoids pode trazer para a eficiência, produtividade e competitividade dessas operações. O estudo visa fornecer uma visão abrangente e aprofundada sobre como a implementação dessas técnicas pode contribuir de forma substancial para a otimização dos processos industriais e, conseqüentemente, para o desenvolvimento e sucesso da indústria de autopeças *aftermarket*.

A estrutura do trabalho é composta por cinco capítulos principais, incluindo esta introdução. No segundo capítulo será apresentado o referencial teórico, abordando os fundamentos teóricos da otimização sequencial de produção e da manufatura *Make-To-Order* (MTO). Serão discutidos conceitos-chave, como sequenciamento de produção, customização em massa, tempo de ciclo e produtividade, serão introduzidos os métodos de clusterização K-Mean e K-Medoids, apresentando os algoritmos e técnicas utilizadas, bem como os principais resultados encontrados na literatura especializada. No Terceiro capítulo, será apresentado a metodologia aplicada a um estudo de caso que exemplifica a aplicação da otimização sequencial de produção e da clusterização K-Mean e K-Medoids na manufatura MTO. No quarto capítulo será apresentado os resultados obtidos. Por fim, serão feitas considerações finais sobre o trabalho, ressaltando a importância da otimização sequencial de produção na manufatura MTO e a relevância da clusterização K-Mean e K-Medoids como ferramentas para essa otimização.

2. Revisão da Literatura

Nesta seção serão abordados conceitos utilizados no desenvolvimento da pesquisa, tais como a manufatura MTO, duas técnicas de clusterização, um método para a escolha do número de clusters e um método para avaliar o desempenho da clusterização.

2.1 Manufatura MTO

segundo Jones e Smith (2011), a manufatura Make-to-Order (MTO) refere-se a um modelo de produção no qual os produtos são fabricados somente após a confirmação do pedido pelo cliente. Esse método de produção, diferentemente do modelo Make-to-Stock (MTS), permite que as empresas reduzam os custos de armazenagem, já que não é necessário manter um estoque de produtos prontos (JONES; SMITH, 2011). Essa característica é especialmente vantajosa para indústrias que lidam com produtos personalizados ou de alta variabilidade, pois permite que o cliente especifique características do produto antes que ele seja fabricado (GUNASEKARAN; NGAI, 2005).

No entanto, a manufatura MTO também pode resultar em tempos de espera mais longos para os clientes, uma vez que o ciclo de produção se inicia apenas após o pedido ser feito. Esse fator representa um desafio para empresas que desejam oferecer prazos de entrega competitivos, especialmente em mercados onde a agilidade é valorizada (ZAHEER; BEHERA, 2013). Portanto, a eficiência e a otimização dos processos de produção são fundamentais para garantir a satisfação do cliente e a competitividade no mercado (HILL; HILL, 2012). A adoção de metodologias como o Just-in-Time (JIT) e a implementação de ferramentas de controle de fluxo podem contribuir significativamente para a melhoria da resposta ao cliente no modelo MTO, ajudando a reduzir o tempo de produção sem sacrificar a customização (HIRANO, 2009).

2.2 Clusterização de Dados

A clusterização é uma técnica de análise de dados que tem como objetivo dividir um conjunto de elementos em grupos, de forma que os elementos dentro de um mesmo grupo sejam mais semelhantes entre si do que com elementos de outros grupos. Esse processo é muito utilizado em diversas áreas da ciência e da tecnologia, permitindo identificar padrões e estruturas nos dados que podem ser úteis para tomada de decisão e resolução de problemas.

Hruschka e Ebecken (2001) definem a clusterização como um conjunto de n objetos $X = \{X_1, X_2, \dots, X_n\}$ onde cada $X_i \in \mathbb{R}^p$ é um vetor de p medidas reais que dimensionam as características do objeto, estes podem ser agrupados em k clusters, de modo que respeitem as condições:

- $C_1 \cup C_2 \cup \dots \cup C_k = X$ (a união dos grupos resulta no conjunto de dados)
- $C_i = \emptyset, \forall i, 1 \leq i \leq k$ (um cluster não pode ser vazio, devendo ter ao menos um objeto);
- $C_i \cap C_j \neq \emptyset, \forall i \neq j, 1 \leq i \leq k, 1 \leq j \leq k$ (um objeto não pode pertencer a mais de um cluster);

2.3 Clusterização K-means

O algoritmo K-Means é um método de agrupamento de dados que visa particionar um conjunto de dados em k clusters, onde cada ponto pertence ao cluster com a média mais próxima. O algoritmo inicia com k centroides aleatórios, e depois itera entre duas etapas: atribuir cada ponto ao centroide mais próximo e recalculá-lo com base nos pontos atribuídos. Esse processo continua até que os centroides não mudem significativamente. O K-Means é amplamente utilizado em áreas como reconhecimento de padrões, análise de imagens e mineração de dados. (ARYA, 2019).

Segundo Jain (2010), o campo de clusterização de dados evoluiu significativamente ao longo de 50 anos desde a introdução do K-means.

Segundo Bishop (2006) o método é dividido em quatro etapas, sendo:

- a) Randomização dos centroides iniciais: Quando o algoritmo K-Means começa a ser aplicado a primeira etapa é a seleção aleatória de k centroides para serem os centros iniciais dos clusters. Essa etapa é de grande importância para o método, pois o resultado da clusterização depende da escolha inicial dos centroides.
- b) Atribuição de amostras aos centroides mais próximos: logo após a randomização dos centroides iniciais o próximo passo a ser tomado é a atribuição de cada amostra para o centroide mais próximo. Nessa etapa, é definido para qual cluster cada amostra vai pertencer, levando em consideração a proximidade das amostras aos centroides;
- c) Com as amostras atribuídas aos centroides mais próximos a etapa final do algoritmo K-Means é a atualização dos centroides. Como esses centroides devem ser a posição média de todas as amostras atribuídas a eles, atualizações eficazes são feitas nos centros de cada cluster, garantindo que os dados sejam cada vez mais precisos;
- d) Após a atualização dos centroides, o algoritmo K-Means reitera a etapa de atribuição das amostras aos centroides mais próximos, seguida de uma atualização dos centroides. Esse processo é repetido até que a atribuição dos clusters não seja alterada ou até que o algoritmo atinja uma tolerância pré-definida quando se trata de uma atualização precisa ou um número máximo de iterações.

2.4 Clusterização K- Medoids

O Algoritmo K-Medoids é uma técnica de clusterização que visa agrupar os dados em k grupos, onde k é um número predefinido. Ele difere do K-Means por escolher medoides como representantes de cada cluster, em vez de médias, o que o torna mais robusto em relação a *outliers* e ruídos nos dados. O K-medoids foi proposto por Kauffman e Rousseeuw (2005), o objetivo do algoritmo é minimizar a dissimilaridade entre os pontos e os medoides, atribuindo cada ponto ao medoide mais próximo. Para selecionar os medoides, o algoritmo faz uso da técnica de busca exaustiva, calculando todas as possíveis combinações de medoides e pontos de dados e escolhendo aquela que minimiza a dissimilaridade total (SIQUEIRA JUNIOR, 2021).

Uma das vantagens do algoritmo K-Medoids é a sua capacidade de lidar com a presença de ruído e *outliers* nos dados, permitindo uma clusterização mais robusta. Além disso, é uma técnica mais eficiente que o K-Means em conjuntos de dados de menor escala, pois reduz a sensibilidade à inicialização aleatória dos centroides. No entanto, o K-Medoids tem como desvantagem a sua resistência a grandes conjuntos de dados, já que sua complexidade computacional aumenta consideravelmente com o tamanho dos dados, tornando-o menos eficiente em comparação com outros algoritmos em grandes conjuntos de dados. (KAUFMAN; ROUSSEEUW, 2005)

2.4 Método do Cotovelo

O Método do Cotovelo é uma técnica bastante popular e amplamente utilizada em algoritmos de clusterização. Salientam Dos Santos et al. (2022) que o seu objetivo principal é estabelecer o número ideal de clusters em um determinado conjunto de dados, olhando para o percentual de variância em termos desse número de clusters. Em suma, o objetivo de tal abordagem é observar o ponto em que acrescentar mais clusters não ajuda substancialmente a diminuir a variância quanto os dados apresentados.

2.5 Método da silhueta

Rousseeuw (1987), define que silhueta na clusterização de dados está relacionada à medida de quanto um objeto se encaixa bem no seu próprio cluster em comparação com outros clusters. Esse conceito é fundamentado em técnicas estatísticas e matemáticas que permitem calcular de forma precisa a silhueta de cada objeto, levando em consideração a distância média entre o objeto e os demais pontos do mesmo cluster, bem como a distância média entre o objeto e os pontos dos clusters vizinhos.

A compreensão dos fundamentos teóricos por trás da silhueta é essencial para a correta aplicação e interpretação do método na clusterização. Ao obter a silhueta de todos os objetos, é possível calcular a silhueta média para toda a clusterização. Quanto mais próximo de 1 for o valor da silhueta média, melhor será a qualidade da clusterização (DE FREITAS, 2024).

Conforme Rousseeuw (1987), o coeficiente de silhueta é uma medida de quão semelhantes os objetos são ao seu próprio cluster em comparação com outros clusters. O valor varia de -1 a 1, onde:

- Um valor próximo a 1 indica que os dados estão bem agrupados e os clusters são bem definidos.
- Um valor próximo a 0 indica que os dados estão no limite dos clusters.

Um valor negativo indica que os dados podem ter sido agrupados de forma incorreta

3. Metodologia

Nesta seção serão detalhadas informações para o desenvolvimento da pesquisa, tal como a descrição do conjunto de dados, a definição do número de grupos, a forma como K-Means e k-Medoids foram aplicados e finalmente a avaliação das clusterizações. Todo o trabalho foi desenvolvido no software R.

3.1. Conjunto de dados

Nesta seção, serão detalhadas as bases de dados empregadas na pesquisa.

3.1.1 Conjunto de dados de características do produto

O conjunto de dados selecionado para o desenvolvimento deste trabalho é a lista de peças automotivas manufaturadas em uma multinacional, contendo as características dimensionais exigidas no processo gargalo do fluxo de valor. Adicionalmente, será utilizada uma base de dados do sequenciamento de produção no período de 1º de março de 2024 a 31 de março de 2024, com o objetivo de confrontar esses dados com os clusters criados, evidenciando o impacto do método no planejamento de produção.

O conjunto de dados é composto pelas características dimensionais, sendo 231 observações com 6 variáveis que afetam diretamente o *setup* na manufatura, denominadas:

- Produto – Identificação do produto;
- PSI – (*Pounds per Square Inch*), representando a variável que afeta diretamente uma característica de diâmetro do furo;
- Delta.PSI – Impacto no ângulo das furações;
- Delta.A – Diferença dimensional de comprimento;
- D.Saida – Diâmetro de saída;
- Compr.Furo – Comprimento do furo.

A Tabela 1 apresenta a estrutura do conjunto de dados.

Tabela 1 – Conjunto de dados e suas características dimensionais

Produto	PSI	Delta.PSI	Delta.A	D.Saida	Compr.Furo
A1	84,72	41,72	1,38	0,40	0,29
A2	85,13	30,73	1,40	0,00	0,26
A3	88,15	40,15	1,40	0,00	0,28
A4	90,25	41,48	1,46	0,32	0,23
A5	73,50	0	1,42	0,00	0,22
...	...	...	...	...	...

Fonte: Os autores (2024)

Visando comparar o estudo de clusterização com o planejamento real de produção, o qual não observa as classes dos produtos, sendo a decisão de fabricação tomada pelo supervisor de produção e operador do processo. Será analisado adicionalmente um conjunto de dados referente ao sequenciamento real de produção MTO. O conjunto é composto por 46 observações, que contemplam 22 variáveis de produtos. Os dados foram coletados entre 1º de março de 2024 e 31 de março de 2024.

A Tabela 2 exemplifica a estrutura dos dados.

Tabela 2 – Conjunto de dados sequência de produção

Sequência	Produto	Data
1	A126	01/03/2024
2	A215	01/03/2024
3	A120	01/03/2024
4	A73	01/03/2024
5	A126	04/03/2024
6	A160	05/03/2024
...	...	...

Fonte: Os autores (2024)


Antecedendo a aplicação dos algoritmos de clusterização, os dados obtidos foram submetidos a um pré-processamento. Este envolveu a purificação dos dados (exclusão de dados com inconsistências, ou células vazias) e normalização de variáveis. Esse preparo foi crucial para assegurar a precisão dos resultados da após a etapa de clusterização.

3.2 Definição da quantidade de clusters

Para definir a quantidade de clusters adotados no estudo, foi aplicado o método do cotovelo, que identifica o ponto em que a inclusão de mais clusters não proporciona uma melhoria substancial na separação dos dados.

Executando o algoritmo de clusterização (o caso, será adotado o K-Means) para um intervalo de possíveis números de clusters k de 1 a 10, foi calculado a soma dos erros quadráticos internos (SSE), que mede a variabilidade dentro de cada cluster, e os valores foram plotados na Figura 1.

Figura 1 – Aplicação do método do cotovelo



Fonte: Os autores (2024)

Evidencia-se que o ponto 3 é onde a taxa de diminuição se estabiliza, formando um "cotovelo" no gráfico, após esse ponto a adição de mais clusters (k) não afeta significativamente a diminuição dos erros quadráticos. Dessa forma será adotado no estudo a quantidade de clusters (k) igual a 3.

3.3 Aplicação dos métodos de clusterização e avaliação de desempenho

Para a identificação de grupos ou clusters com padrões de produção similares, aplicou-se os algoritmos K-Means e K-Medoids nos dados pré-processados. Estes algoritmos foram escolhidos e utilizados pela sua capacidade de agrupar dados de maneira autônoma, facilitando a descoberta de padrões produtivos que podem melhorar a sequência de fabricação das autopeças na manufatura MTO.

A utilização desses algoritmos possibilita a exploração mais aprofundada dos dados e a identificação de relações antes não percebidas. Ao identificar padrões produtivos, é possível desenvolver estratégias mais eficientes para aprimorar a qualidade e produtividade das autopeças.

Adicionalmente foi aplicado o método da silhueta para analisar se as clusterizações encontradas eram significativas e os grupos estavam bem formados.


4. Análise dos Resultados

Os resultados alcançados com a utilização das técnicas de clusterização K-Means e K-Medoids foram divergentes. Entretanto identificou-se padrões nos dados e agrupou-se os produtos com base em suas características produtivas, o que potencializa a diminuição do *setup* e na maximização da capacidade produtiva. Ademais, um estudo comparativo entre os métodos K-Means e K-Medoids possibilitou a mensuração da eficácia de cada técnica na otimização da produção sequencial.

O método K-Mans, resultou na seguinte divisão de grupos:

- 9 observações inseridas no grupo 1;
- 135 observações inseridas no grupo 2;
- 87 observações inseridas no grupo 3.

Na Figura 2 é possível verificar a dispersão das variáveis plotadas duas a duas nos respectivos cluster. Para alguns pares de variáveis (tal como PSI x D.Saida) nota-se a separação bem definida entre os clusters, e para outros pares como Delta.A x D.Saida não ocorreu essa separação. Apesar do representação ser plotada em duas dimensões, a iteração foi realizada com todas as variáveis descritas na Tabela 1.



Fonte: Os autores (2024)


Aplicando o método da silhueta no resultado gerado pelo K-Means, obteve-se um coeficiente de 0,75116, o que evidencia uma forte coesão e separação dos dados nos grupos gerados, sugerindo que os clusters gerados pelo método K-Means são bem definidos.

A aplicação do método K-Medoids, resultou em uma diferente segregação de dados, sendo:

- 87 observações inseridas no grupo 1;
- 61 observações inseridas no grupo 2;
- 83 observações inseridas no grupo 3.

Observa-se uma maior distribuição das observações nos clusters, a Figura 3 descreve as relações entre as variáveis.

Figura 3 – Aplicação do método K-Medoids



Fonte: Os autores (2024)

Com o objetivo de avaliar a coesão dos dados nos grupos, aplicando o método da silhueta nos clusters gerados pelo K-Medoids, obteve-se um coeficiente de 0,57128, o valor é significativamente maior que 0, o que indica que os clusters são bem formados, embora haja espaço para melhoria. O resultado evidencia que os clusters gerados pelo método K-Medoids têm uma qualidade de agrupamento razoavelmente boa, com uma coesão interna forte, entretanto uma separação entre clusters moderada.

Após a aplicação dos métodos de clusterização os grupos foram consolidados no conjunto de dados.

Tabela 3 – Dados consolidados após clusterização

Produto	PSI	Delta.PSI	Delta.A	D.Saida	Compr.Furo	K-Medoid	k-Means
A1	84,72	41,72	1,38	0,40	0,29	1	3
A2	85,13	30,73	1,40	0,00	0,26	1	3
A3	88,15	40,15	1,40	0,00	0,28	1	3
A4	90,25	41,48	1,46	0,32	0,23	1	3
A5	73,50	0	1,42	0,00	0,22	1	3
...	...	...	...	...	...	...	...

Fonte: Os autores (2024)

Compilando os resultados obtidos pelos métodos de clusterização (Tabela 3), com o sequenciamento real de produção (Tabela 2), é possível constatar que não é utilizada a similaridade de características dimensionais no planejamento de produção, critério observado no conjunto de comparação de resultados (Tabela 4).

Tabela 4 – Conjunto de Comparação de resultados

Sequência	Produto	Data	Cluster K-Means	Cluster K-Medoids
1	A126	01/03/2024	3	1
2	A215	01/03/2024	2	2
3	A120	01/03/2024	2	3
4	A73	01/03/2024	3	1
...	...	...	...	...

Fonte: Os autores (2024)

Observando os quatro primeiros produtos produzidos (A126, A215, A120 e A73) e tomando o resultado da clusterização do K-Means, nota-se que após a produção de A126 (pertencente ao cluster 3) houve a produção de A215 (pertencente ao cluster 2), ou seja, foram produzidos dois produtos com características distintas, contabilizando uma alteração de grupo. Após a produção de A215 (cluster 2) houve a produção de A120 (cluster 2), significando manutenção de produções semelhantes. Após a produção de A120 (cluster 2), houve a produção de A73 (cluster3), contabilizando mais uma alteração de grupo.

Consolidando os dados de sequenciamento e comparando com os grupos resultantes do método K-Means, evidencia-se que ocorreram 21 alterações de grupos, das 46 possíveis no período. Quando comparado com os grupos resultantes do método K-Medoids, o sequenciamento de produção gerou 30 alterações de grupos. Essas observações sugerem que o planejamento atual não considera adequadamente as semelhanças entre os produtos em termos de suas dimensões, o que poderia potencialmente otimizar o processo de produção com a redução de *setup*.

5. Conclusão

Para concluir, este estudo evidenciou a utilidade das técnicas de clusterização K-Means e K-Medoids para a otimização sequencial na produção MTO. A investigação ressaltou a importância destas metodologias para o aprimoramento dos processos produtivos e para a detecção de padrões operacionais. Quanto a iniciativas futuras, é aconselhável a execução de estudos adicionais focados em diferentes segmentos da indústria manufatureira MTO, com o objetivo de verificar a eficácia da clusterização em ambientes diversos.

A interpretação dos resultados obtidos a partir da aplicação dos métodos de clusterização K-Means e K-Medoids no contexto da manufatura MTO permitiu identificar padrões de agrupamento significativos nos dados de produção. Esta análise possibilitou a compreensão dos diferentes perfis de demanda. Além disso, a análise dos resultados também revelou fragilidades na distribuição sequencial da produção, auxiliando na identificação de possíveis oportunidades de melhoria no processo produtivo. Portanto, a aplicação de métodos de clusterização, podem facilitar a compreensão dos dados de produção, e auxiliar em decisões estratégicas do sequenciamento de produção MTO.

Referências

- ARYA, Divya; SINGH, Nidhi. **A survey of clustering algorithms and K-means**. International Journal of Science and Research (IJSR), v. 8, n. 8, p. 1472-1476, 2019.
- BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.
- DOS SANTOS, P. A.; DA SILVA, I. L.; DA SILVA, F. L. C.; PINHEIRO, H. S. K.; JÚNIOR, W. D. C. **Métodos de interpretação, validação e clusterização usando dados VIS-IR MSI/Sentinel-2A para análise de agrupamento**. Disponível em: <https://www.researchgate.net>. Acesso em: 20 out. 2024.
- GUNASEKARAN, A.; NGAI, E. W. T. **Build-to-order supply chain management: a literature review and framework for development**. Journal of Operations Management, v. 23, n. 5, p. 423-451, 2005.
- HILL, T.; HILL, A. **Manufacturing operations strategy**. London: Palgrave Macmillan, 2012.
- HIRANO, H. **JIT Implementation Manual: Volume 1**. Boca Raton: CRC Press, 2009.
- HRUSCHKA, E. R.; EBECKEN, N. F. F. **A genetic algorithm for cluster analysis**. IEEE Transactions on Evolutionary Computation, 2001.
- JAIN, A. K. **Data clustering: 50 years beyond K-means**. Pattern Recognition Letters, v. 31, n. 8, p. 651-666, 2010.
- JONES, M.; SMITH, A. **Make-to-order production in the automotive industry**. Journal of Manufacturing Systems, v. 29, n. 3, p. 202-215, 2011.
- KAUFMAN, Leonard; ROUSSEEUW, Peter J. **Finding Groups in Data: An Introduction to Cluster Analysis**. Hoboken: Wiley, 2005.
- RASCHKA, S. **Python Machine Learning: Unlock deeper insights into machine learning with this vital guide to cutting-edge predictive analytics**. Birmingham: Packt Publishing Ltd, 2015.
- ROUSSEEUW, P. J. **Silhouettes: a graphical aid to the interpretation and validation of cluster analysis**. Journal of Computational and Applied Mathematics, v. 20, p. 53-65, 1987.
- SIQUEIRA JUNIOR, L. A. **Uso de machine learning para classificação de fornecedores no contexto da data science**. 2021. Disponível em: <https://www.unifei.edu.br>. Acesso em: 20 out. 2024.
- THOMPSON, J.; ZHANG, W. **Challenges and benefits of make-to-order manufacturing in the automotive industry**. International Journal of Production Research, v. 52, n. 8, p. 2403-2415, 2015.
- UNGAR, L.; FOSTER, D. **Clustering methods for collaborative filtering**. 2000.

VICENTE, C. W. **Divulgação voluntária: um estudo de casos múltiplos em empresas multinacionais do setor automotivo no Brasil.** 2021. Disponível em: <https://www.uninove.br>. Acesso em: 20 out. 2024.

ZAHEER, A.; BEHERA, P. **Production Systems and Practices in Manufacturing.** London: Routledge, 2013