

MÉTODOS DE APOIO MULTICRITÉRIO À DECISÃO E MODELOS DE MACHINE LEARNING NA GESTÃO DE ESTOQUES: UM ESTUDO DE CASO EM UMA FERROVIA DE TRANSPORTE DE CARGAS

Guilherme Henrique de Paula Vidal

Programa de Pós-Graduação em Engenharia de Produção
Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio
R. Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ
guilherme.vidal@engenharia.ufjf.br

Dissertação de Mestrado

Defesa: 27 de abril de 2021

Orientador: Luiz Felipe Roris Rodriguez Scavarda do Carmo

Coorientador: Rodrigo Goyannes Gusmão Caiado

RESUMO

O mundo vive hoje uma era de transformação digital, onde as ferramentas de apoio à decisão têm exercido cada vez mais um papel estratégico no *Operations and Supply Chain Management* (OSCM). Entre as abordagens existentes, podem ser destacadas o *Multi-Criteria Decision-Making* (MCDM) e o *Machine Learning* (ML). O objetivo desta dissertação é de desenvolver um *framework* de apoio à decisão na gestão de estoques, combinando métodos de MCDM e ML, e aplicação em um estudo de caso conduzido em uma operadora ferroviária logística. O modelo proposto possui 3 etapas: ranqueamento dos SKUs a partir do método MCDM combinado Fuzzy AHP VIKOR, previsão de demanda dos itens mais críticos através do modelo de ML combinado GA-ANN e estruturação dos resultados em um *dashboard* gerencial. Os resultados permitiram considerável melhora na performance da previsão de demanda dos SKUs selecionados, através de um modelo semiautomático de tomada de decisão na gestão de estoques.

PALAVRAS CHAVE. Processo hierárquico analítico, Rede neural artificial, Algoritmo genético.

Tópicos: Gestão de Operação e da Cadeia de Suprimentos, *Machine learning*, Apoio multicritério à decisão.

ABSTRACT

The world is experiencing an era of digital transformation, where decision support tools have increasingly played a strategic role in Operations and Supply Chain Management (OSCM). Among the existing approaches, Multi-Criteria Decision-Making (MCDM) and Machine Learning (ML) can be highlighted. The objective of this dissertation is to develop a decision support framework for inventory management, combining MCDM and ML methods, and applies it in a case study conducted in a railway logistic operator. The proposed model has 3 steps: SKU ranking using the MCDM combined Fuzzy AHP VIKOR method, demand forecasting of the most critical items using the ML combined GA-ANN model, and structuring the results in a management dashboard. The results allowed considerable improvement in the demand forecast performance of the selected SKUs, through a semi-automatic inventory management decision making model.

KEYWORDS. Analytic Hierarchy Process, Artificial Neural Network, Genetic Algorithm.
Paper topics: Operations and Supply Chain Management, Machine learning, Multi-Criteria Decision Making

1. Introdução

Gestão de Operação e da Cadeia de Suprimentos, em inglês “*Operations and Supply Chain Management*” (OSCM), é um conceito amplo e complexo, que engloba os canais de suprimentos, de produção e de distribuição de produtos manufaturados e serviços, desde os fornecedores, fabricantes e distribuidores até o cliente final, tendo como objetivo atender a demanda do cliente, com responsividade e eficiência [Helo e Hao, 2021]. A natureza dinâmica atual da OSCM exige cada vez mais ferramentas de respostas inteligentes, eficazes e rápidas. Neste contexto, surge a associação da OSCM com a chamada Indústria 4.0, que trouxe grandes inovações tecnológicas, permitindo entregas cada vez mais ágeis, eficientes e sustentáveis [Koh et al., 2019]. Um importante campo da Indústria 4.0 são as técnicas baseadas em dados para a tomada de decisão, que tem aplicação direta em algumas áreas do OSCM, como a gestão de estoques [Aktepe et al., 2021].

Um dos principais elementos para uma gestão de estoques efetiva é a classificação dos SKUs de acordo com sua criticidade e importância. Devido ao alto número de SKUs presente na maioria das empresas, esta classificação pode servir de suporte a tomada de decisão [Kabir e Hasin, 2013]. Outro elemento chave para uma boa gestão de estoques é a realização de uma previsão de demanda com boa acurácia, sendo esta a base para o processo de planejamento de produção [Kück e Freitag, 2021].

O Apoio Multicritério à Decisão, em inglês “*Multi-Criteria Decision Making*” (MCDM), trata-se de um importante método utilizado para classificação e ranqueamento de SKUs [Kartal et al., 2016]. Um dos principais métodos de MCDM utilizados para esse fim é o *Analytic Hierarchy Process* (AHP), que permite a coleta de opiniões de especialistas para tomada de decisão. No entanto, essa abordagem apresenta deficiências relacionadas ao uso de uma escala de julgamento desequilibrada, muitas vezes imprecisa e subjetiva, que pode ser aprimorada por meio de sua combinação com a lógica *fuzzy* (Kabir e Hasin, 2013), a chamada *Fuzzy AHP* (FAHP). Esta é uma combinação importante para definir os pesos dos critérios, mas não é viável para classificação quando há um número elevado de SKUs (Kabir e Hasin, 2013). Para superar essa lacuna, outros métodos podem ser aplicados para classificar as alternativas com base nos critérios ponderados determinados pelo FAHP, como o VIKOR (*VIseKriterijumska Optimizacija I Kompromisno Resenje*). VIKOR consiste em uma solução de otimização e compromisso multicritério, que reside na sua capacidade de classificar alternativas usando critérios conflitantes, de acordo com sua proximidade com a solução ideal [Chen e Wang, 2009].

A definição dos SKUs mais críticos a partir de métodos MCDM permite direcionar esforços para garantir uma maior confiabilidade dos itens mais importantes para uma organização. Este processo está diretamente relacionado à métodos de previsão robustos e de boa acurácia, destacando entre eles os modelos de Aprendizado de Máquina, em inglês *Machine Learning* (ML), que se tratam de algoritmos computacionais que conseguem reconhecer padrões a partir de um aprendizado sobre os dados e realizar previsões [Priore et al., 2019]. O ML realiza previsões de demanda irregular com boa precisão devido à sua propriedade de modelar relações não lineares entre variáveis [Gutierrez et al., 2008]. Um dos modelos de ML mais populares e eficazes na previsão de demanda é o *Artificial Neural Network* (ANN), mas uma deficiência nesse modelo é a necessidade de testes exaustivos de tentativa e erro para encontrar sua configuração ideal, que pode ser abordada com sua combinação com métodos de computação evolutiva e meta-heurísticas, como *Genetic Algorithms* (AG) formando o modelo combinado GA-ANN. O GA apresenta algumas vantagens em relação aos métodos tradicionais, como menor possibilidade de aprisionamento em um mínimo local devido ao fato de iniciar com uma série de soluções possíveis e não uma única e trabalhar com os parâmetros codificados das soluções. Além disso, utiliza operadores genéticos, que são de natureza estocástica [Benardos e Vosniakos, 2007].

Apesar da literatura abordar a aplicação dos temas de MCDM e ML na gestão de estoques, ainda são escassos trabalhos que busquem combinar e aplicar essas abordagens para propor uma solução integrada, mais robusta e semiautomática para este problema de OSCM [Lolli et al., 2019]. A aplicação simultânea das duas abordagens, MCDM e ML, pode trazer grandes benefícios para o processo de gestão de estoques [Kartal et al., 2016], com o MCDM aprimorando a seleção dos SKUs críticos [Bacchetti et al., 2013] e o ML aprimorando a acurácia da previsão de demanda destes SKUs [Kourentzes, 2013]. Portanto, considerando a relevância acadêmica e profissional dos temas e a potencialidade gerada a partir da combinação dos mesmos, a presente dissertação busca responder à seguinte pergunta de pesquisa: Como MCDM e ML poderiam ser aplicados simultaneamente para aprimorar a gestão de estoques?

O objetivo da dissertação é o de apresentar uma metodologia de apoio à decisão para aprimorar a gestão de estoques que combine métodos MCDM e de ML, tendo como objetivos secundários: (i) desenvolver de uma metodologia semiautomática e híbrida baseada na combinação de MCDM, para ranqueamento de alternativas, considerando múltiplos critérios e a subjetividade na priorização destes por um grupo de gestores, e ML, com parâmetros otimizados com uso de metaheurística, para previsões de demanda, (ii) aplicar a metodologia em um caso real, na gestão de estoques de uma ferrovia de transporte de cargas, para aprimorar e validar a mesma e (iii) organizar os resultados em um dashboard para suporte à tomada de decisão.

2. Metodologia e *framework*

A metodologia da pesquisa será multi-método, sendo aplicado um estudo de caso com múltiplas fontes de coleta e análise de dados, seguindo as etapas apresentadas por Miguel [2012]. Inicialmente houve pesquisa teórica com métodos de revisão sistemática da literatura (RSL) e de *scoping review*. Duas pesquisas de RSL foram aplicadas, sendo a primeira com o objetivo de analisar o MCDM na classificação de SKUs e a segunda em como o ML pode ser utilizado na gestão de estoques. A aplicação do método seguiu as etapas de Thomé et al. [2016] para SLR em gestão de operações. Com relação ao *scoping review*, o mesmo foi aplicado com o propósito de abordar quais modelos de ML mais utilizados para previsão de demanda e como esses métodos são abordados na literatura, e para isso, foram utilizadas as etapas propostas por Arksey e O'Malley [2005]. Os resultados das pesquisas permitiram direcionar a definição dos métodos abordados no estudo de caso e definição do *framework* do modelo de trabalho proposto.

Após os resultados teóricos, foi utilizada a pesquisa empírica, em que um *framework* combinando as abordagens MCDM e ML é aplicado em uma ferrovia de transporte de cargas. Esse artefato gerencial começa com uma avaliação de criticidade dos SKUs a partir da aplicação do método FAHP-VIKOR, sendo o FAHP composto por 5 etapas e o VIKOR 4 etapas, tendo como principal *output* o ranking dos SKUs por ordem de criticidade. Após definir os itens mais importantes para a empresa, o próximo passo consiste em elaborar um modelo de previsão de demanda utilizando GA-ANN para os SKUs mais críticos, inicialmente realizando o treino e validação do modelo, que posteriormente é testado em uma base de dados nunca vista. Este modelo foi aplicado a partir da ferramenta RapidMiner. Por fim, os resultados são consolidados em um *dashboard* para apoiar o processo de tomada de decisão na gestão de estoques, através da ferramenta Qlik Sense. A Figura 1 detalha o *framework* do modelo de trabalho proposto.




Figura 1 – Framework dos modelos do estudo de caso

3. Estudo de caso

O estudo de caso é desenvolvido em uma operadora ferroviária logística brasileira de transporte de cargas. Atualmente a empresa apresenta em seus estoques aproximadamente 16 mil SKUs, que são distribuídos em 12 armazéns, e mantém uma quantidade excessiva de materiais de baixo giro, onde aproximadamente 20% do valor total estocado da empresa são materiais que não foram utilizados nos últimos 12 meses, gerando custos significantes. Não é aplicado nenhum método multicritério para avaliação de criticidade dos seus itens de estoque e sua aderência entre demanda planejada e realizada é baixa. As próximas seções detalham os resultados do estudo de caso e aplicação do *framework* envolvendo MCDM e ML na gestão de estoques.

3.1 FAHP-VIKOR aplicado no ranqueamento dos SKUs

A Figura 2 representa a estrutura hierárquica do FAHP aplicada neste estudo, onde é detalhado o objetivo, os critérios empregados e alternativas ranqueadas. A escolha dos critérios foi realizada a partir de discussões com especialistas da empresa e também dos resultados da RSL, onde os critérios de *lead time*, criticidade/impacto da falta e custo total da demanda foram, respectivamente, o 1º, 3º e 4º critérios mais citados nos 28 artigos analisados no *scoping review*. Com relação às alternativas, tratam-se de 7.526 SKUs, utilizados em um processo específico da empresa, de manutenção de locomotivas.




Figura 2 – Estrutura hierárquica FAHP

A etapa seguinte é a realização da coleta dos julgamentos dos especialistas para cada par de critérios em matrizes de comparação paritária *Fuzzy*. Em seguida calcula-se as taxas de consistência (CR) dos julgamentos, que foram ambas inferiores a 0,1. Finalmente são calculados os pesos (*fuzzy* e *crisp*) de cada critério. O peso final de cada critério foi de 0,52 para criticidade/impacto da falta, 0,20 para frequência de utilização, 0,18 para *lead time* de entrega dos fornecedores e 0,10 para custo total de demanda.

Inicia-se então a aplicação do método VIKOR, com sua primeira etapa consistindo no cálculo das soluções positiva ideal (f_i^*) e negativa ideal (f_i^-) para cada critério. O passo seguinte consiste no cálculo dos valores de S (grupo de utilidade máxima), R (peso individual mínimo) e Q. Por fim, o VIKOR é finalizado com o ranqueamento dos SKUs por ordem crescente do valor de Q. A Tabela 1 contém os 50 SKUs ranqueados como mais críticos a partir da aplicação do método FAHP-VIKOR e seus respectivos valores de Q.

Qj	Ranking	Qj	Ranking	Qj	Ranking	Qj	Ranking	Qj	Ranking
0,000	1	0,110	11	0,128	21	0,162	31	0,172	41
0,066	2	0,112	12	0,131	22	0,163	32	0,174	42
0,081	3	0,112	13	0,145	23	0,165	33	0,174	43
0,083	4	0,113	14	0,148	24	0,167	34	0,174	44
0,088	5	0,119	15	0,153	25	0,168	35	0,175	45
0,097	6	0,126	16	0,154	26	0,168	36	0,176	46
0,103	7	0,128	17	0,155	27	0,168	37	0,178	47
0,103	8	0,128	18	0,155	28	0,169	38	0,178	48
0,103	9	0,128	19	0,156	29	0,170	39	0,179	49
0,106	10	0,128	20	0,157	30	0,170	40	0,179	50

Tabela 1 – Ranking dos 50 principais SKUs

Fonte: Elaborado pelos autores

3.2 GA-ANN

Para a aplicação do método GA-ANN foram selecionados, dentro dos 50 SKUs de maior criticidade do ranking relativo ao FAHP VIKOR, aqueles que tiveram frequência de utilização de 100% no período de janeiro de 2010 a dezembro de 2020, correspondendo a um total de 5 SKUs (23, 29, 43, 46, e 48). A primeira etapa consiste no pré-processamento da base de *input*, onde foram removidos os *outliers* e normalizados os dados. O passo seguinte consiste no processamento do treino e validação, onde para cada um dos SKUs foram definidos os parâmetros que apresentasse a melhor performance de desempenho. Foram utilizados o período de jan/10 a jun/19 para treino e

validação do modelo. A Tabela 2 ilustra os parâmetros de cada uma das configurações ideais encontradas para cada SKU. Entre essas configurações que foram testadas, está a quantidade de nós no *input layer*, ou camada de entrada, a quantidade e número de nós nos *hidden layers*, em português camadas escondidas e o número de nós no *output layer* ou camada de saída. Além disso, outros três importantes parâmetros são o *training cycles*, o *learning rate* e o *momentum*, sendo a configuração ideal destes definida a partir de um modelo de otimização de GA.

Ranking criticidade	Nós de input	Camadas ocultas	Nós ocultos	Training Cycles	Learning rate	Momentum
23	6	1	1	3652	0,18	0,19
29	12	1	3	786	0,03	0,47
43	8	2	1	2856	0,24	0,46
46	10	2	2	539	0,21	0,12
48	8	1	2	2140	0,19	0,52

Tabela 2 – Configurações ótimas das ANNs

Após o treinamento e validação inicia-se a aplicação do modelo treinado em uma base de teste, considerado o período de jul/19 a dez/20. Nesse período considerado foram aplicados outros métodos tradicionais de previsão de demanda e de ML com a finalidade de comparar com o modelo proposto: *Support Vector Machine* (SVM), *Exponential Smoothing* (ES) e a previsão da própria empresa. A Tabela 3 ilustra a medida de performance de cada SKU para a base de teste.

Ranking criticidade	GA-ANN		SVM		ES		Empresa	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
23	22,45%	3,29	38,54%	4,92	27,10%	3,89	40,57%	5,01
29	4,53%	100,43	5,57%	89,21	5,75%	92,69	26,21%	430,18
43	16,47%	40,81	38,90%	70,67	19,96%	41,77	52,35%	108,46
46	9,74%	101,26	23,35%	165,30	10,69%	106,08	19,94%	139,86
48	19,02%	9,13	22,86%	8,70	21,44%	9,25	21,74%	8,06

Tabela 3 – Medidas de performance – base de teste

Comparando os resultados de previsão, observa-se que o GA-ANN tem a melhor medida de MAPE em todos os 5 SKUs. Com relação ao RMSE, o GA-ANN é o melhor em três dos cinco SKUs testados. O MAPE médio dos cinco SKUs no modelo GA-ANN é de 14,44%, muito inferior ao resultado obtido pela previsão da empresa, que foi de 32,16%, e também ao resultado do SVM e do ES, que foram de 25,84% e 16,99%, respectivamente. A superioridade da performance do modelo proposto tem grandes implicações econômicas e de qualidade no negócio da empresa. A partir dos resultados encontrados com o FAHP VIKOR e a partir dos métodos de previsão de demanda aplicados, foi desenvolvido um *dashboard* gerencial de maneira a concentrar em um único local e de maneira visual importantes informações que servirão de insumo para o planejamento e controle dos estoques da empresa e consulta de maneira acessível e de fácil análise.

5. Conclusão

Esta dissertação apresenta um estudo teórico e empírico de como o MCDM e o ML podem auxiliar na tomada de decisão na gestão de estoques. Seu primeiro objetivo foi alcançado a partir do desenvolvimento de um modelo híbrido que combinasse o MCDM para ranqueamento dos SKUs e ML para previsão de demanda. O segundo objetivo foi alcançado com a aplicação das metodologias em uma empresa ferroviária de transporte de cargas. Os resultados encontrados permitiram concluir que a aplicação simultânea do FAHP-VIKOR e do GA-ANN pode trazer

importantes melhorias no processo de gestão de estoques, sendo que o FAHP-VIKOR permitiu ranquear em escala de importância os itens da empresa, em um universo complexo com mais de 16 mil SKUs. Já o GA-ANN mostrou-se muito superior aos demais métodos em termos de acurácia de previsão, que tem como consequência maior probabilidade de atendimento às demandas de manutenção e menor necessidade de elevados estoques de segurança que geram alto custo para a empresa. Por fim, o último objetivo alcançado foi a organização dos resultados da aplicação dos métodos em um *dashboard* gerencial.

Dentre as principais contribuições desta dissertação, pode-se citar os impactos teóricos da combinação destes diferentes métodos para as áreas de Pesquisa Operacional e Inteligência Artificial, formando uma importante ferramenta gerencial para a tomada de decisão na gestão de estoques. Com relação às contribuições práticas, observa-se que os resultados obtidos foram positivos e houve uma considerável melhora comparada com a acurácia de previsão anteriormente utilizada pela empresa, demonstrando que esta combinação pode ser desdobrada para os demais SKUs e até mesmo testada em outros estudos de caso.

6. Submissões e publicações

Quatro artigos foram desenvolvidos com resultados da dissertação, conforme abaixo:

1. **Título:** Métodos de apoio multicritério à decisão e modelos de *machine learning* na gestão de estoques: fundamentos e aplicabilidade
Autores: Guilherme Henrique de Paula Vidal, Luiz Felipe Scavarda e Rodrigo Goyannes Gusmão Caiado
Evento: Encontro Nacional de Engenharia de Produção – ENEGEP 2020
Data do evento: 20 a 23 de outubro de 2020 **Status:** Publicado
2. **Título:** *Decision support framework for inventory management combining fuzzy multicriteria methods, genetic algorithm, and artificial neural network*
Autores: Guilherme Henrique de Paula Vidal, Rodrigo Goyannes Gusmão Caiado, Luiz Felipe Scavarda, Paulo Ivson e Jose Arturo Garza-Reyes
Periódico: *Computers & Industrial Engineering*
Data de submissão: 14 de março de 2022
Data de envio do R1: 02 de julho de 2022 **Status:** Resubmetido
3. **Título:** *MRO inventory demand forecast using support vector machine - A case study*
Autores: Guilherme Henrique de Paula Vidal, Rodrigo Goyannes Gusmão Caiado, Luiz Felipe Scavarda, Renan Silva Santos
Evento: *International Joint Conference on Industrial Engineering and Operations Management – IJCIEOM 2022*
Data do evento: 17 a 20 de julho de 2022 **Status:** Aprovado
4. **Título:** Modelo Híbrido de Apoio Multicritério à Decisão na Gestão de Estoques: Um Estudo de Caso em uma Ferrovia de Transporte de Cargas
Autores: Guilherme Henrique de Paula Vidal, Rodrigo Goyannes Gusmão Caiado, Renan Silva Santos, Luiz Felipe Scavarda
Evento: Simpósio Brasileiro de Pesquisa Operacional
Data do evento: 8 a 11 de novembro de 2022 **Status:** Submetido

Referências

Aktepe, A., Yanık, E. e Ersöz, S. (2021). Demand forecasting application with regression and artificial intelligence methods in a construction machinery company. *Journal of Intelligent Manufacturing*, 32(6):1587–1604.

Arksey, H. e O'Malley, L. (2005). Scoping studies: Towards a methodological framework. *International Journal of Social Research Methodology: Theory and Practice*, 8(1):19–32.

Bacchetti, A., Plebani, F., Saccani, N. e Syntetos, A. A. (2013). Empirically-driven hierarchical classification of stock keeping units. *International Journal of Production Economics*, 143(2): 263–274.

Benardos, P.G. e Vosniakos, G.C. (2007). Optimizing feedforward artificial neural network architecture. *Engineering Applications of Artificial Intelligence*, 20(3), 365–382.

Chen, L.Y. e Wang, T.C. (2009). Optimizing partners' choice in IS/IT outsourcing projects: The strategic decision of fuzzy VIKOR. *International Journal of Production Economics*, 120(1), 233–242.

Gutierrez, R. S., Solis, A. O. e Mukhopadhyay, S. (2008). Lumpy demand forecasting using neural networks. *International Journal of Production Economics*, 111(2): 409–420.

Helo, P. e Hao, Y. (2021). Artificial intelligence in operations management and supply chain management: an exploratory case study. *Production Planning and Control*, 1–18.

Kabir, G. e Hasin, M. A. A. (2013). Multi-criteria inventory classification through integration of fuzzy analytic hierarchy process and artificial neural network. *International Journal of Industrial and Systems Engineering*, 14(1):74–103.

Kartal, H., Oztekin, A., Gunasekaran, A. e Cebi, F. (2016). An integrated decision analytic framework of machine learning with multi-criteria decision making for multi-attribute inventory classification. *Computers and Industrial Engineering*, 101, 599–613.

Koh, L., Orzes, G. e Jia, F. (2019). The fourth industrial revolution (Industry 4.0): technologies disruption on operations and supply chain management. *International Journal of Operations and Production Management*, 39(6), 817–828.

Kourentzes, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, 143(1):198–206.

Kück, M. e Freitag, M. (2021). Forecasting of customer demands for production planning by local k-nearest neighbor models. *International Journal of Production Economics*, 231.

Lolli, F., Balugani, E., Ishizaka, A., Gamberini, R., Rimini, B. e Regattieri, A. (2019). Machine learning for multi-criteria inventory classification applied to intermittent demand. *Production Planning and Control*, 30(1), 76–89. <https://doi.org/10.1080/09537287.2018.1525506>

Miguel, C. (2012). *Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações*. Elsevier, Rio de Janeiro.

Priore, P., Ponte, B., Rosillo, R. e de la Fuente, D. (2019). Applying machine learning to the dynamic selection of replenishment policies in fast-changing supply chain environments. *International Journal of Production Research*, 57(11):3663–3677.

Thomé, A. M. T., Scavarda, L. F. e Scavarda, A. J. (2016). Conducting systematic literature review in operations management. *Production Planning and Control*, 27(5): 408–420.