



GUILHERME HENRIQUE DE PAULA VIDAL

**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**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo programa de pós-graduação em Engenharia de Produção, do Departamento de Engenharia Industrial da PUC-Rio.

Orientador: Prof. Luiz Felipe Roris Rodriguez Scavarda do Carmo
Co-orientador: Prof. Rodrigo Goyannes Gusmão Caiado



GUILHERME HENRIQUE DE PAULA VIDAL

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

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia de Produção da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

Prof. Luiz Felipe Roris Rodriguez Scavarda do Carmo
Orientador
Departamento de Engenharia Industrial - PUC-Rio

Prof. Rodrigo Goyannes Gusmão Caiado
Coorientador
PUC-Rio

Dr. Paulo Ivson Netto Santos
PUC-Rio

Prof. Gilson Brito Alves Lima
UFF

Rio de Janeiro, 27 de abril de 2021

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Guilherme Henrique de Paula Vidal

Graduado em Engenharia de Produção pela Universidade Federal de Juiz de Fora – UFJF (2017). Possui especialização em Finanças Aplicadas pela Pontifícia Universidade Católica de Minas Gerais – PUC Minas (2020). Atua como Analista de Segurança Operacional na MRS Logística S.A.

Ficha Catalográfica

Vidal, Guilherme Henrique de Paula

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; orientador: Luiz Felipe Roris Rodriguez Scavarda do Carmo; coorientador: Rodrigo Goyannes Gusmão Caiado. – 2021.

96 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2021.

Inclui bibliografia

1. Engenharia Industrial - Teses. 2. Processo Hierárquico Analítico (AHP). 3. Fuzzy. 4. Rede neural artificial. 5. Algoritmo genético. 6. Previsão de demanda. I. Carmo, Luiz Felipe Roris Rodriguez Scavarda do. II. Caiado, Rodrigo Goyannes Gusmão. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Agradecimentos

Agradeço primeiramente à Deus, por ter iluminado meu caminho e me dado forças para superar todos os momentos difíceis desse importante período de minha vida.

Aos meus pais, Rosângela e Elizeu, e à minha irmã Juliane, pelo carinho, amor e apoio que sempre me deram. Agradeço também pela compreensão dos momentos que precisei estar ausente para me dedicar aos estudos.

À minha namorada Raquel, por sempre estar ao meu lado, me dando força e motivação para superar cada desafio.

Ao meu professor e orientador Luiz Felipe Scavarda, pelos ensinamentos, pela paciência e pela grande contribuição na escolha do tema e no desenvolvimento desta dissertação.

Ao meu coorientador Rodrigo Caiado, pela transmissão de suas experiências, que foram primordiais para que eu conseguisse desenvolver esta dissertação, e pela disponibilidade e dedicação em me auxiliar.

Ao Paulo Ivson, pelos *feedbacks* dados em minha defesa de qualificação, que foram muito importantes para a elaboração desta dissertação.

Aos meus colegas de mestrado, em especial à Patrícia e ao Ramon, que estiveram sempre dispostos a me ajudar nos momentos que mais precisei. E também ao meu colega Adalton, que me ajudou na escolha do tema.

Agradeço também à Universidade Federal de Juiz de Fora e a PUC-Rio, por essa importante iniciativa de realização do MINTER, que foi um grande sucesso.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

O trabalho também foi realizado com apoio das agências de fomento à pesquisa CNPq e FAPERJ.

Resumo

Vidal, Guilherme Henrique de Paula; do Carmo, Luiz Felipe Roris Rodriguez Scavarda (orientador); Caiado, Rodrigo Goyannes Gusmão (coorientador). **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.** Rio de Janeiro, 2021. 96p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

O mundo vive hoje uma era de transformação digital resultante da chamada indústria 4.0 ou quarta revolução industrial. Nesta fase, a tecnologia tem exercido um papel cada vez mais estratégico no desempenho das organizações. Estes avanços tecnológicos têm revolucionado o processo de tomada de decisão na gestão e operação de cadeias de suprimentos. Neste contexto, esta dissertação apresenta uma metodologia de apoio à decisão na gestão de estoques, que combina *multi-criteria decision making* (MCDM) e *machine learning* (ML). A princípio, é realizada uma revisão sistemática da literatura para analisar como estas duas abordagens são aplicadas na gestão de estoques. Os resultados são complementados com um *scoping review* abrangendo a previsão de demanda. Inicia-se então um estudo de caso, aplicado em uma ferrovia de transporte de cargas. É aplicado, inicialmente, o método MCDM combinado *Fuzzy AHP* *Vikor* para ranquear os *stock keeping units* (SKUs) em ordem de criticidade. O passo seguinte é a aplicação do método de ML combinado GA-ANN, *artificial neural network* com *genetic algorithm*, com o objetivo de realizar a previsão de demanda em um piloto com alguns dos itens mais críticos. A etapa final consiste em estruturar um *dashboard* gerencial, integrando os resultados das etapas anteriores. Dentre os resultados alcançados, a partir do modelo proposto, observa-se considerável melhora na performance da previsão de demanda dos SKUs selecionados. Além disso, a integração entre as abordagens e implementação em um dashboard gerencial permitiu o desenvolvimento de um modelo semiautomático de tomada de decisão na gestão de estoques.

Palavras-chaves:

Processo hierárquico analítico (AHP), fuzzy, rede neural artificial, algoritmo genético, previsão de demanda

Abstract

Vidal, Guilherme Henrique de Paula; do Carmo, Luiz Felipe Roris Rodriguez Scavarda (supervisor); Caiado, Rodrigo Goyannes Gusmão (co-advisor). **Multi-criteria decision making methods and machine learning models in inventory management: a case study on a freight transport railway**. Rio de Janeiro, 2021. 96p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

The world is experiencing an era of digital transformation resulting from the industry 4.0 or fourth industrial revolution. In this period, technology has played an increasingly strategic role in the performance of organizations. These technological advances have revolutionized the decision-making process in the management and operation of supply chains. In this context, this dissertation presents a methodology to support decision-making in inventory management, which combines multi-criteria decision-making (MCDM) and machine learning (ML). At first, there is a systematic literature review in order to analyze how these two approaches are applied in inventory management. The results are complemented with a scoping review that includes the demand forecasting. A case study is then applied to a freight transport railway. Initially, the MCDM combined Fuzzy AHP Vikor method is applied to rank stock keeping units (SKUs) in degrees of criticality. The next step is the application of the ML combined GA-ANN method, artificial neural network with genetic algorithm, for the purpose of demand forecasting in a pilot with some of the most critical items. The final step is to structure a management dashboard, integrating the results of the previous steps. Among the results achieved from the proposed model, there is a considerable improvement in the performance of the demand forecasting for the selected SKUs. In addition, the integration between approaches and implementation in a management dashboard allowed the development of a semiautomatic model for decision-making in inventory management.

Keywords

Analytic hierarchy process (AHP), fuzzy, artificial neural network, genetic algorithm, demand forecast

Sumário

1	Introdução	13
2	Referencial teórico	16
2.1	Gestão de estoques	16
2.2	<i>Multi-criteria decision making</i> (MCDM)	17
2.3	<i>Machine learning</i> (ML)	22
3	Metodologia de pesquisa	24
3.1	SLR referente à aplicação de MCDM e ML na gestão de estoques	24
3.2	<i>Scoping review</i> sobre a aplicação de métodos de ML para previsão de demanda	27
3.3	Estudo de caso aplicado em uma ferrovia de transporte de cargas	29
4	Resultados teóricos	36
4.1	Resultados da SLR	36
4.1.1	Análise descritiva	36
4.1.2	MCDM na gestão de estoques	37
4.1.3	Modelos de ML na gestão de estoques	43
4.2	Resultados do <i>scoping review</i>	43
4.2.1	Análise descritiva	44
4.2.2	Métodos de ML na previsão de demanda	45
5	Estudo de Caso	53
5.1	Caracterização da empresa e escolha dos métodos MCDM e de ML	53
5.2	Metodologia multicritério <i>Fuzzy AHP</i> Vikor aplicada à classificação de SKUs	56
5.3	Modelo de <i>machine learning</i> GA-ANN para previsão de demanda	59
5.3.1	Resultados	59
5.3.2	Análise comparativa dos modelos de previsão	63
5.4	Apresentação dos dados em um <i>dashboard</i> gerencial	64
5.5	Análise dos resultados e considerações finais	65
6	Conclusão e oportunidades de pesquisas futuras	68
	Glossário	70
	Referências bibliográficas	71
	APÊNDICE 1 – Formulário de coleta de dados	80
	APÊNDICE 2 – <i>Fuzzy AHP</i> Vikor	81
a)	Método <i>Fuzzy AHP</i>	81
b)	Método Vikor	84

APÊNDICE 3 – <i>Artificial neural networks (ANN) com genetic algorithms (GA)</i>	86
APÊNDICE 4 – Avaliação dos critérios em escala linguística	90
APÊNDICE 5 – MCP com números TFN	92
APÊNDICE 6 – <i>Framework</i> Rapidminer: GA-ANN para previsão de demanda	93
APÊNDICE 7 – Consumo mensal SKUs selecionados	94
APÊNDICE 8 – <i>Dashboard</i> gestão de estoques	96

Lista de Siglas

ABS - *Association of Business Schools*

AHP - *analytic hierarchy process*

AJG - *Academic Journal Guide*

ANN - *artificial neural network*

ARMAE - *average relative mean absolute error*

ARME - *average relative mean error*

ARMSE - *average relative mean squared error*

BI - *business intelligence*

DEA - *data envelopment analysis*

Electre - *elimination et choice translation reality*

GA - *genetic algorithm*

GP - *genetic programming*

KNN - *k-nearest neighbors*

LEC - *lote econômico de compras*

Macbeth - *measuring attractiveness by a category based evaluation technique*

MADM - *multiple attribute decision making*

MAE - *mean absolute error*

MAPE - *mean absolute percentage error*

MASE - *mean absolute scaled error*

MAUT - *multiple attribute utility theory*

MCDM - *multi-criteria decision making*

MCIC - *multi-criteria inventory classification*

ME - *mean error*

ME/A - *non-scale dependent systematic error*

MGGP - *multi-gene genetic programming*

ML - *machine learning*

MLP - *multi-layer perceptron*

MODM - *multiple objective decision making*

MSE - *mean squared error*

PCM - *planejamento e controle da manutenção*

PB - *percentage best*

Promethee - *preference ranking organization method for enrichment evaluation*

RF - *random forest*
RGRMSE - *relative geometric root-mean-square error*
RMSE - *root mean square error*
SCM - *supply chain management*
SKU - *stock keeping unit*
SLR - *systematic literature review*
SMAPE - *symmetric mean absolute percentage error*
Smart - *simple multi attribute rating technique*
SSE - *sum of squared errors*
SVM - *support vector machine*
TC - *total cost*
TCS - *total cost for the supplier*
TCR - *total cost for the retailer*
TFN - *triangular fuzzy number*
Topsis - *technique for order preference by similarity to ideal solution*
Vikor - *visekriterijumska optimizacija i kompromisno resenje*
Waspas - *weighted aggregated sum product assessment*

Lista de Figuras

Figura 1 – Fluxo de Diagrama PRISMA: Pesquisa (1)	26
Figura 2 – Fluxo de Diagrama PRISMA: Pesquisa (2)	26
Figura 3 - Fluxo de Diagrama PRISMA: <i>scoping review</i>	28
Figura 4 – Fluxo de etapas para um estudo de caso	30
Figura 5 – <i>Framework</i> dos modelos do estudo de caso	32
Figura 6 - Etapas de aplicação do FAHP Vikor	33
Figura 7 – Etapas ANN	34
Figura 8 – SLR: Quantidade de artigos por ano e tipo de pesquisa	36
Figura 9 - <i>Scoping review</i> : Quantidade de artigos por ano e tipo de pesquisa	44
Figura 10 – Processo da demanda dependente da empresa estudada ...	54
Figura 11 – Estrutura hierárquica FAHP	56
Figura 12 – Demanda real e previsão base de validação: SKU N174020005	61
Figura 13 – Parte 1: Dashboard para gestão de estoques	64
Figura 14 – Parte 2: Dashboard para gestão de estoques	65
Figura 15 – Parte 3: Dashboard para gestão de estoques	65
Figura 16– Estrutura MLP	87
Figura 17 – Processo GA-ANN	88

Lista de Tabelas

Tabela 1 – Características de cada modelo de gestão de estoques	17
Tabela 2 - Principais técnicas MCDM	21
Tabela 3 – Pesquisas e <i>strings</i> de busca	25
Tabela 4 – SLR: Quantidade de artigos por periódico e ranking AJG/ABS do periódico.....	37
Tabela 5 - Estudos sobre MCDM para classificação de SKUs.....	42
Tabela 6 – Estudos sobre as técnicas de ML para gestão de estoques ..	43
Tabela 7 - <i>Scoping review</i> : Quantidade de artigos por periódico e ranking AJG/ABS do periódico.....	44
Tabela 8 - Modelos de previsão abordados nos estudos selecionados ...	46
Tabela 9 - Estudos sobre os modelos de ANN para previsão de demanda	52
Tabela 10 - Pesos <i>fuzzy</i> dos critérios.....	57
Tabela 11 - Pesos <i>crisp</i> dos critérios	57
Tabela 12 - Soluções positivas ideais e negativas ideais.....	57
Tabela 13 - Ranking dos 50 principais SKUs	59
Tabela 14 – Medidas de performance modelo ANN – base de validação	60
Tabela 15 – Configurações ótimas das ANNs.....	62
Tabela 16 – Medidas de performance – base de teste	62
Tabela 17 – <i>Triangular fuzzy numbers</i>	81
Tabela 18 - <i>Random índices</i> (RI)	83
Tabela 19 – <i>Parâmetros GA</i>	89
Tabela 20 – Limites superior e inferior das variáveis otimizadas	89

1 Introdução

A gestão da cadeia de suprimentos, do inglês *supply chain management* (SCM), é um campo que está assumindo uma posição estratégica no ambiente corporativo e que exerce influência direta no desempenho sustentável de um negócio (MELNYK et al., 2009). Um dos principais pilares do SCM é o processo de gestão de estoques, que segundo Lancioni (2000), pode representar até 50% dos custos referentes ao SCM de uma organização. Um grande desafio nesse campo é gerenciar o trade off entre a eficiência em custos, que envolve principalmente reduzir os níveis de estoque, e manter um nível de serviço adequado para atendimentos à demanda dos clientes, evitando com isso perda de vendas que afetam a lucratividade e imagem de uma empresa no mercado (SUSTROVA, 2016).

O gerenciamento de estoques exige cada vez mais dos gestores decisões ágeis e confiáveis e para isso diversas ferramentas têm sido aprimoradas ao longo do tempo visando dar suporte à essa tomada de decisão. Entre elas existe o “*multi-criteria decision making*” (MCDM), em português “apoio multicritério à decisão”, que trata-se de uma metodologia para a tomada de decisão envolvendo a análise de múltiplos critérios (SITORUS; CILLIERS; BRITO-PARADA, 2019). Sua aplicação nesse campo envolve principalmente classificar as unidades de manutenção de estoque (*stock keeping units* - SKUs) em níveis de criticidade e importância, de modo a direcionar esforços e investimentos para aqueles itens que têm maior impacto no negócio. Esta abordagem é uma evolução da tradicional classificação ABC, que agrupa os SKUs em 3 níveis de criticidade utilizando-se como critério o consumo anual do item em unidades monetárias (SARMAH; MOHARANA, 2015). Outra metodologia que pode auxiliar o processo de tomada de decisão na gestão de estoques é o “*machine learning*” (ML), traduzido como “aprendizado de máquina”. O ML trata-se de algoritmos computacionais que conseguem reconhecer padrões a partir de um aprendizado sobre os dados e realizar previsões (PRIORE et al., 2019).

Apesar da literatura abordar a aplicação dos temas de MCDM e ML na gestão de estoques, ainda são escassos trabalhos que busquem integrar estudos de ambos e sua aplicação neste problema de SCM. A aplicação simultânea das duas abordagens, MCDM e ML, pode trazer grandes benefícios para o processo de gestão de estoques (KABIR; HASIN, 2013). O MCDM tem aplicação na definição dos itens mais críticos, que auxilia na alocação do método de previsão e política de gestão de estoques mais adequados de acordo com seu nível de criticidade (BACCETTI et al., 2013). Já o ML tem aplicação em classificação, agrupamento, associação, seleção e regressão, a partir de um aprendizado sobre os dados (KARTAL et al., 2016). Dentre as aplicações do ML na gestão de estoques destaca-se a realização de previsões de demanda. A principal vantagem destes métodos, se comparados a métodos de previsão tradicionais, está em realizar previsões de demandas irregulares e intermitentes com boa acurácia devido à sua propriedade de tratar dados não lineares (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; JAIPURIA; MAHAPATRA, 2019). Uma boa previsão de demanda tem grande importância para o desempenho empresarial, pois ela é a base para o processo de planejamento de produção (KÜCK; FREITAG, 2021). A realização de previsões confiáveis e de boa acurácia é vital para o suporte ao

planejamento e tomada de decisão na cadeia de suprimentos, sendo este portanto um grande interesse das organizações (ABOLGHASEMI et al., 2020).

A partir do que foi exposto com relação à aplicação das metodologias de MCDM e ML na gestão de estoques, pode-se destacar o potencial que ambas têm de se complementar, sendo o MCDM, segundo Bacchetti et. al. (2013), aplicado na classificação dos itens de maior criticidade e o ML, de acordo com Chen (2012), pode ser aplicado em aprimorar a previsão de demanda, com foco nesses itens mais críticos. Portanto, considerando a relevância acadêmica e profissional dos temas, a potencialidade gerada a partir da combinação dos mesmos e a carência na literatura de estudos aplicados contando com esta combinação, a presente dissertação busca responder à seguinte pergunta de pesquisa:

- a) Como MCDM e ML poderiam ser aplicados simultaneamente para aprimorar a gestão de estoques?

A pergunta de pesquisa é trabalhada inicialmente através de uma *systematic literature review* (SLR), do português revisão sistemática da literatura, que analisa os estudos existentes na literatura acadêmica com relação à aplicação das duas abordagens na gestão de estoques. A análise literária é complementada com a realização de um *scoping review*, com o objetivo de mapear na literatura os principais métodos de ML utilizados para previsão de demanda, qual o desempenho desses modelos se comparados a métodos tradicionais de previsão e quais os principais parâmetros dos modelos aplicados, de maneira a otimizar o resultado de performance das previsões.

Após os resultados teóricos, a aplicação simultânea das metodologias é avaliada a partir de um estudo de caso, aplicado em uma empresa ferroviária de transporte de cargas localizada na região sudeste do Brasil. O setor de transporte ferroviário, devido à grande concorrência com outros modais de transporte, busca constantemente a eficiência em seus processos logísticos e a gestão de seus estoques tem um importante papel na redução de custos. Este setor é normalmente responsável pelo processo de manutenção de seus ativos, como locomotivas, vagões e via permanente, onde os itens de manutenção podem compor boa parte de seus custos com estocagem. Portanto as ferramentas de apoio para tomada de decisão têm papel fundamental nesse processo de ganho de eficiência em custos e diferencial competitivo. Além disso, a literatura ainda é carente de estudos voltados para a gestão de estoques no setor ferroviário, onde não foram identificados trabalhos empíricos de aplicação das metodologias de MCDM e ML na gestão de estoques deste setor, sendo esta uma das motivações deste estudo de caso.

A partir dos *gaps* identificados e expostos acima e visando responder às perguntas de pesquisa, 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. Este objetivo principal é desdobrado em quatro objetivos secundários:

- Identificar os principais conceitos e aplicações referentes ao MCDM e ML na tomada de decisão na gestão de estoques, revelando suas aplicações e finalidades;
- Desenvolver uma metodologia baseada na combinação de MCDM, para ranqueamento de alternativas, e ML, para previsões de demanda;
- Aplicar a metodologia na gestão de estoques de uma ferrovia de transporte de cargas para aprimorar e validar a mesma;
- Organizar os resultados em um *dashboard* para suporte à tomada de decisão.

Sendo assim, inicialmente é aplicado um método MCDM para ranqueamento dos itens de estoque de acordo com sua criticidade. A etapa seguinte consiste na aplicação de um método de ML na previsão de demanda em um piloto com os

itens mais críticos, de forma a auxiliar o gestor a definir a quantidade mensal de compras de determinado item. A etapa final consiste em elaborar um *dashboard*, consolidando os resultados das etapas anteriores e se transformando em uma ferramenta gerencial para a tomada de decisão na gestão de estoques.

Esta dissertação está organizada em 6 capítulos. No capítulo 1 são apresentadas as motivações e justificativas, as perguntas de pesquisa, os objetivos e estrutura proposta neste trabalho. No Capítulo 2 é desenvolvido o referencial teórico, abordando os principais conceitos relacionados à gestão de estoques, MCDM e ML. O capítulo 3 apresenta as metodologias de pesquisas empregadas. No capítulo 4 são abordados os resultados teóricos da dissertação, com a SLR referente à aplicação do MCDM e ML na gestão de estoques e com o *scoping review* referente à utilização de métodos de ML para previsão de demanda. O capítulo 5 apresenta o estudo de caso, onde uma técnica combinada de MCDM e um modelo combinado envolvendo duas técnicas de ML são aplicadas de forma combinada em uma empresa ferroviária de transporte de cargas. Por fim, o capítulo 6 apresenta a conclusão da dissertação, bem como as sugestões de pesquisas futuras.

2 Referencial teórico

O presente capítulo apresenta os conceitos que fundamentam a base teórica desta pesquisa. Primeiramente são abordadas as principais definições relacionados à gestão de estoques. Em seguida, é apresentado o MCDM, com seus objetivos, principais categorias e métodos. Finalmente é apresentado o ML, com seus principais conceitos, classificações e técnicas empregadas na literatura.

2.1 Gestão de estoques

A gestão de estoques é um dos processos empresariais mais importantes e que tem impacto direto no desempenho de uma organização. O *trade-off* entre manter baixos níveis de estocagem e manter um nível de serviço elevado para atender a demanda dos clientes é um desafio constante. Para solucionar essa questão, existem diversas políticas e metodologias de gerenciamento de estoques que permitem adotar um nível de serviço adequado mantendo os custos de estocagem controlados (SUSTROVA, 2016).

Segundo Placido dos Santos e Oliveira (2019), os diferentes modelos existentes na gestão de estoques são divididos em dois grupos: modelos determinísticos e modelos probabilísticos. O primeiro modelo considera que os parâmetros que envolvem o processo de gestão de estoques são conhecidos. Já o segundo considera que existe incerteza em um ou mais parâmetros, sendo este mais condizente com a realidade. Outra importante classificação dos modelos de gestão de estoque está associada ao seu período de revisão, existindo duas classificações possíveis para o sistema: revisão contínua e revisão periódica. No processo de revisão contínua o status do estoque é conhecido em qualquer momento, já na revisão periódica ele só é conhecido no período em que é revisado, previamente estabelecido (BABILONI; GUIJARRO, 2018).

O primeiro e mais conhecido modelo para gerenciamento de inventário foi introduzido por Ford W. Harris em 1913, chamado Lote Econômico de Compras (LEC). Trata-se de um modelo determinístico de revisão contínua, que tem como objetivo encontrar o tamanho ótimo de um lote de compras de determinado produto, chamado de Q , a partir do balanceamento entre o custo de pedido, custo unitário de produção e custo de manutenção de estoque (SUSTROVA, 2016). O modelo determinístico de revisão periódica, assim como o LEC, considera a demanda conhecida, porém variando entre os períodos. O objetivo é determinar o tamanho do lote ótimo de maneira a minimizar os custos, sendo que o tamanho desse lote em cada pedido não é fixo. O modelo estocástico de revisão contínua considera uma demanda probabilística e o pedido é realizado quando o estoque atinge determinado ponto de reabastecimento, que é determinado a partir do nível de serviço desejado. Por fim, o modelo estocástico de revisão periódica considera que a demanda é incerta e o sistema é monitorado periodicamente, sendo necessário estimar em cada período o tamanho do lote que minimize dos custos envolvidos e mantenha um risco de falta controlado (HILLIER; LIEBERMAN, 2001). A Tabela 1 resume as características de cada modelo de gestão de estoques a partir do tipo de demanda considerado e do sistema de revisão.

	Revisão contínua	Revisão periódica
Determinística	<ul style="list-style-type: none"> - Demanda conhecida e constante - Sem restrições para o tamanho do lote - Considera custos de pedido e de estocagem - Lead time constante e conhecido 	<ul style="list-style-type: none"> - Demanda conhecida, porém variando entre os períodos - Sistema monitorado periodicamente - Custo de manutenção do estoque calculado em relação ao estoque restante no final de cada período
Estocástica	<ul style="list-style-type: none"> - Demanda incerta - Nível de estoque controlado de forma contínua - Lead time pode ser variável - No caso de falta, demanda é atendida no próximo período e é acrescentada um custo de escassez 	<ul style="list-style-type: none"> - Demanda incerta e variando entre os períodos - Sistema monitorado periodicamente - No final de cada período o nível de estoque é determinado e decidido quanto pedir para ressuprimento para o próximo período

Tabela 1 – Características de cada modelo de gestão de estoques
 Fonte: Hillier e Lieberman (2001)

A escolha de qual das políticas de gestão de estoques citadas aplicar e os esforços destinados para seu controle está diretamente relacionado com o grau de importância que o tipo de estoque tem para os processos da empresa. A classificação dos SKUs gera grandes benefícios não apenas para a gestão de estoques, mas também para todo o seu planejamento de produção. Tradicionalmente os SKUs são agrupados em 3 classes, sendo A muito importante, B moderadamente importante e C menos importante (SOYLU; AKYOL, 2014). Segundo Shamsaddini, Vesal e Nawaser (2015) esse tradicional método ABC segue o princípio de Pareto, onde uma pequena parcela de SKUs é responsável pelo maior consumo anual do estoque. Esse princípio segue, portanto, apenas um critério para a definição das classes, que é o consumo anual do item em unidades monetárias, calculado a partir do custo unitário multiplicado pelo consumo em unidades.

2.2

Multi-criteria decision making (MCDM)

O MCDM é uma importante metodologia de resolução de problemas envolvendo múltiplos critérios, através de análises quantitativas e qualitativas (SITORUS, CILLIERS E BRITO-PARADA, 2019). De acordo com Roy (1996), o MCDM pode ser aplicado com 4 tipos de objetivos principais:

- I. Problemática de escolha: definir a melhor opção ou ação em uma série de alternativas;
- II. Problemática de classificação: alocar cada uma das opções em categorias previamente estabelecidas, de acordo com características em comum que se deseja agrupá-las para tomada de decisão;
- III. Problemática de ordenação: classifica as alternativas em um ranking decrescente de preferência;
- IV. Problemática de descrição: auxilia o tomador de decisões a avaliar as alternativas, os critérios de comparação e as consequências de suas ações, de maneira sistemática.

Em aplicações do MCDM na classificação de itens de estoque, objetivo de pesquisa do presente trabalho, eles são denominados com o termo Classificação

de Inventário Multicritério, em inglês *Multi-Criteria Inventory Classification* - MCIC (KABIR; HASIN, 2013).

Segundo Kahraman (2008), os métodos MCDM podem ser classificados em duas categorias: *multiple attribute decision making* (MADM) e *multiple objective decision making* (MODM). O MADM está associado a um espaço discreto e limitado de alternativas, que são ordenadas de acordo com a preferência, a partir dos pesos dados a cada um de seus atributos. Já o MODM é normalmente utilizado para um número ilimitado e contínuo de alternativas, onde a melhor é aquela que atende a diversas restrições previamente estabelecidas.

Com relação aos tipos de dados empregados, o MCDM pode ser classificado em: métodos de MCDM nítidos ou *Crisp* MCDM, e métodos de MCDM difusos, em inglês *Fuzzy* MCDM (FMCDM). Nos métodos *Crisp* MCDM todos os dados disponíveis são precisos e conhecidos, já no *Fuzzy* MCDM alguns dados utilizados não são claramente definidos (KAHRAMAN, 2008).

Uma outra classificação também muito utilizada para as técnicas de MCDM é com relação às fontes de conhecimento, agrupadas em 2 tipos: com base em julgamentos e estatístico. No primeiro, a classificação nos critérios é realizada principalmente através da opinião de especialistas. Já nos modelos estatísticos, a comparação é realizada a partir de análise dos dados e critérios definidos (VAN KAMPEN; AKKERMAN; VAN DONK, 2012).

Diversos métodos MCDM e MCIC foram propostos pela literatura ao longo dos anos. Eles se diferem principalmente com relação aos objetivos que são aplicados, às bases teóricas envolvidas em sua estrutura e tipos de resultados encontrados (SITORUS, CILLIERS E BRITO-PARADA, 2019). A Tabela 2 resume os principais métodos MCDM presentes na literatura, a origem de cada um e suas principais variações, caso possuam.

Método	Descrição	Principais variações	Origem
Matriz bi-critério	Primeira técnica envolvendo MCDM para classificação de SKUs. Trata-se de uma matriz, onde as colunas representam um critério e as linhas o outro critério. O cruzamento da matriz indica a criticidade do item.	-	Flores and Whybark (1986, 1987)
AHP - <i>Analytic hierarchy process</i>	Estrutura o problema multicritério de maneira hierárquica: objetivo; critérios e subcritérios; alternativas. Análise dos critérios é realizada através de uma comparação paritária, que utiliza os conhecimentos e experiências do tomador de decisão. Aplicada principalmente para estabelecimento de rankings.	-	Saaty (1980)
ELECTRE	Desenvolvido com o objetivo de suprir as limitações dos demais métodos com relação ao objetivo de escolha. Introduziu o conceito de superação, onde cada uma das alternativas é ordenada através de comparações entre elas para cada um dos critérios definidos. Possui algumas variações, que se diferem principalmente pelos seus estágios envolvidos e sua aplicação (SITORUS; CILLIERS; BRITO-PARADA, 2019).	ELECTRE I ELECTRE II ELECTRE III ELECTRE IV ELECTRE IS ELECTRE Tri	Roy (1968) Roy e Bertier (1971) Roy (1978) Roy e Hugonnard (1982) Roy e Bouyssou (1993) YU (1992)
PROMETHEE	Método de superação que é aplicado para um número finito de alternativas, principalmente nas problemáticas de ordenação e escolha. Cada um dos critérios é ponderado e as alternativas são avaliadas com base em uma função de preferência. Possui variações que se diferem, principalmente, pela problemática de aplicação.	PROMETHEE I PROMETHEE II PROMETHEE III PROMETHEE IV PROMETHEE V PROMETHEE VI	Brans (1982) Brans, Mareschal e Vincke (1984, 1886); Brans e Vincke (1985) Brans, Mareschal e Vincke (1984) Brans, Mareschal e Vincke (1984) Brans & Mareschal (1992) Brans & Mareschal (1995)

(Continua)

Método	Descrição	Principais variações	Origem
Modelos de otimização	Modelos MCDM voltados para a comparação de SKUs, também chamados de MCIC. Este método aplica modelos de otimização linear ponderada para determinar o peso ótimo dos critérios com relação ao resultado de cada alternativa. É um método exclusivamente matemático que não leva em consideração a opinião de especialistas. Possui algumas variações, que foram evoluindo e se aprimorando ao longo do tempo.	UTADIS R-Model ZF model Ng model Case-based model HV model PBB model	Doumpos e Zopounidis (2004) Ramanathan (2006) Zhou e Fan (2007) Ng (2007) Chen et al. (2008) Hadi-Vencheh (2010) Park, Bae e Bae (2014)
TOPSIS	Método MCDM que avalia uma alternativa a partir de sua distância com relação à solução considerada ideal. A melhor alternativa é aquela que está mais próxima da solução ideal positiva e mais longe da ideal negativa (SITORUS; CILLIERS; BRITO-PARADA, 2019).	-	Hwang e Yoon (1981)
VIKOR	Inicialmente desenvolvido para problemáticas de ordenação e escolha. Semelhante ao TOPSIS, neste método a melhor alternativa é aquela que mais se aproxima da solução ideal.	-	Opricovic (1998)
WASPAS	Técnica MCDM recente, principalmente se comparada aos métodos tradicionais, e utilizada para problemáticas de ordenação e escolha. Desenvolvido a partir da combinação dos métodos de "Modelos de Soma Ponderada - WSM" e "Modelos de Produto Ponderado - WPM".	-	Zavadskas, Turskis e Antucheviciene (2012)
MAUT	Teoria que considera que existe uma função utilidade específica, que pode ser de diferentes formas matemáticas, para cada um dos atributos que descrevem uma alternativa. Utilizada para as problemáticas de ordenação e escolha.	-	Fishburn (1970); Keeney e Raiffa (1976)

(Continua)

Método	Descrição	Principais variações	Origem
SMART	Método caracterizado por sua simplicidade, se comparado aos demais métodos. É baseado em um modelo aditivo linear, onde o valor de cada alternativa consiste na soma do produto do valor de cada critério por seu peso. Utilizado para classificações de alternativas.	-	Edwards (1977)
MACBETH	Baseada em julgamentos qualitativos da diferença de atratividade de um avaliador com relação a um par de alternativas, como seu próprio nome sugere, mede a atratividade por uma técnica de avaliação baseada em categorias.	-	Bana e Costa e Vansnick (1994)

Tabela 2 - Principais técnicas MCDM

Fonte: O autor

2.3

Machine learning (ML)

Segundo Priore et al. (2019), o ML trata-se de um campo da inteligência artificial onde algoritmos conseguem aprender com os dados e resolver problemas. As técnicas de ML têm como principal característica sua semelhança com a natureza humana em adquirir conhecimento e experiência, transformando em aprendizado. Estas técnicas foram motivadas pelo comportamento e fisiologia humana, como a função neurológica do nosso cérebro, processo de evolução e de adquirir conhecimento ou até mesmo pelo seu comportamento colaborativo (MIN, 2010).

O processo de aprendizagem do ML pode ser supervisionado, não supervisionado ou por reforço. O aprendizado supervisionado utiliza dados de entrada e respectivas saídas esperadas, chamadas de dados rotulados. O sistema realiza previsões iterativas e aprende à medida em que se ajusta automaticamente às saídas esperadas. Portanto nesse método o usuário indica a priori ao sistema o que deve ser aprendido. No aprendizado não supervisionado são fornecidos ao sistema apenas os dados de entrada, ou seja, dados não rotulados. O usuário não indica a priori quais são os resultados esperados. Cabe ao sistema identificar automaticamente padrões e correlações nos dados fornecidos. No aprendizado por reforço o sistema interage com o ambiente, que fornece feedbacks positivos ou negativos, induzindo ajustes no sistema de modo que ele aprende por repetidas tentativas e erros.

Uma das principais aplicações das técnicas de ML é a de realização de previsões. A partir de sua propriedade de auto aprendizado, os algoritmos podem reconhecer padrões em uma série de dados e prever, com determinado nível de precisão, seus resultados futuros. Comparado com métodos tradicionais de previsão de demanda, a grande vantagem dos modelos de ML é tratar dados não lineares, presentes principalmente em demandas irregulares e intermitentes (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; JAIPURIA; MAHAPATRA, 2019). Segundo Jaipuria e Mahapatra (2019), Kück e Freitag (2021) e Punia et al. (2020), algumas das principais técnicas de ML utilizadas para previsão de demanda são: *artificial neural network* (ANN), *support vector machine* (SVM), *k-nearest neighbors* (KNN) e *random forest* (RF). Uma breve apresentação de cada um deles é feita em seguida.

Artificial neural network (ANN), traduzido para o português como redes neurais artificiais, trata-se de um sistema que é inspirado no funcionamento dos neurônios humanos. É formada por um conjunto de nós organizados em camadas na forma de um grafo, que representa um fluxo de processamento de dados desde a entrada até a saída. Cada nó é responsável por aplicar pesos diferentes sobre seus dados de entrada, gerando um valor de saída que é passado adiante para a camada seguinte de processamento. Durante o aprendizado, o modelo ajusta os pesos de cada nó de acordo com o gradiente de uma função de perda, definida de acordo com o problema, em um processo chamado retropropagação. ANNs podem ser utilizadas para aprendizado supervisionado ou não-supervisionado (RUSSEL; NORVIG, 2003).

O modelo *support vector machine* (SVM), em português máquina de vetores de suporte, trata-se de um método de ML originalmente desenvolvido para problemas de classificação supervisionada. O SVM mapeia os dados no espaço, onde busca encontrar de forma iterativa um hiperplano separador de margem máxima, ou seja, de maior distância entre os pontos de dados que mais se aproximam, mas que pertencem a classes diferentes. As amostras de dados que se encontram na fronteira de separação são chamadas de vetores de suporte (RUSSEL; NORVIG, 2003).

O *k-nearest neighbors* (KNN) pode ser traduzido como k-vizinhos mais próximos e é um modelo de ML que pode ser utilizado tanto para problemas de classificação quanto de regressão, ambos supervisionados. Em problemas de regressão, dado uma série histórica T, um conjunto de instâncias são criadas e utilizadas para treinamento do modelo. Para prever uma nova instância, o método pesquisa no conjunto de treinamento as k instâncias (vizinhos) mais próximas dessa, sendo a saída do modelo a média dessas k instâncias encontradas.

O *random forest* (RF) ou floresta aleatória trata-se de um algoritmo usado comumente para aprendizado supervisionado, desenvolvido por Breiman (2001) aplicado em problemas de classificação e regressão. Segundo o autor, o método trata-se de uma combinação de árvores de decisão que permite previsões de maior acurácia, através de um método de aprendizado chamado *bagging*. No caso de previsão de séries temporais, normalmente adota-se uma abordagem de janela deslizante para classificar os pontos de saída esperados (próximo instante de tempo) de acordo com os pontos de entrada (instante de tempo anterior).

Além dos principais métodos de ML citados para a realização de previsões, destaca-se o *genetic algorithm* (GA), que pode ser aplicado de maneira a otimizar parâmetros formando métodos combinados junto aos demais citados, como o ANN. O GA trata-se de um modelo que aplica princípios da evolução biológica para encontrar soluções ótimas globais (HECKERLING et al., 2004). Segundo Majdi e Beiki (2010), a ideia por trás deste método é de gerar uma população com um conjunto de possíveis soluções, chamados de cromossomos, que são avaliados a partir de uma função objetivo e comparados a partir de um critério de seleção de maneira a encontrar os melhores. Após essa seleção, eles passam por um processo de cruzamento e evolução e é gerado uma nova população, que passa novamente por essa etapa de seleção, repetindo o ciclo até que um critério de parada seja atendido. Segundo Benardos e Vosniakos (2007), o GA apresenta algumas vantagens com relação aos métodos tradicionais, como menor possibilidade de ficar preso a mínimos locais devido ao fato de iniciar com uma série de possíveis soluções e não uma única e de trabalhar com os parâmetros codificados das soluções. Além disso ele utiliza operadores genéticos, que são de natureza estocástica.

3 Metodologia de pesquisa

Este capítulo apresenta a metodologia de pesquisa aplicada na presente dissertação de mestrado. O primeiro método trata-se de uma SLR com o objetivo de analisar como MCDM é aplicado na classificação de SKUs e como o ML pode ser utilizado na gestão de estoques. Parte do conteúdo apresentado na seção 3.1 também está contido em Vidal, do Carmo e Caiado (2020). A seção seguinte detalha a metodologia de *scoping review*, que tem o propósito de abordar quais modelos de ML mais utilizados para previsão de demanda e como esses métodos são aplicados na literatura. Por fim, a seção 3.3 expõe a metodologia de estudo de caso, aplicando um método MCDM e uma técnica de ML na gestão de estoques de uma ferrovia de transporte de cargas, além da consolidação dessas informações em um *dashboard* gerencial.

3.1 SLR referente à aplicação de MCDM e ML na gestão de estoques

A SLR é uma metodologia que adota um rigoroso processo que identifica e seleciona estudos sobre um determinado tema, avalia contribuições e interpreta dados, permitindo conclusões sobre o que já é conhecido e o que ainda pode ser explorado (TRANFIELD; DENYER; SMART, 2003). A presente dissertação segue as etapas definidas por Thomé, Scavarda e Scavarda (2016) para SLR em gestão de operações.

A primeira etapa lida com o planejamento e formulação do problema, a definição de seu escopo e os objetivos. Os resultados desta etapa estão contidos na introdução deste trabalho. As bases de dados utilizadas na pesquisa são Scopus e Web of Science, devido a serem complementares e cobrirem os principais periódicos voltados para a gestão de operações (MAGON et al., 2018).

A revisão envolveu duas pesquisas distintas que estão listadas na Tabela 3. A pesquisa (1), que teve como tema a utilização de MCDM na gestão de estoques, teve a seleção de palavras-chave a partir de definições básicas de gestão de estoques, de acordo com Sarmah e Moharana (2015), as principais metodologias e definições relativas ao MCDM, ilustrados por Rodriguez, Costa e do Carmo (2013) e Sitorus, Cilliers e Brito-Parada (2019), e do multi-criteria inventory classification (MCIC), de acordo com Babai, Ladhari e Lajili (2015). Com relação à pesquisa 2, voltada para a utilização do ML na gestão de estoques, teve as palavras-chave selecionadas pelas definições de gestão de estoques informados na pesquisa (1) e as principais características e métodos de ML, de acordo com Priore et al. (2019).

Pesquisa	Combinação de palavras-chaves com expressões booleanas “OR” e “AND”
(1) Utilização de MCDM na gestão de estoques	((MCDM OR “ <i>multi-criteria decision making</i> ” OR “ <i>multiple criteria decision making</i> ” OR <i>multi-criteria</i> OR “ <i>multiple criteria</i> ” OR “ <i>multiple attribute decision making</i> ” OR MADM OR “ <i>multi-criteria decision</i> ” OR “ <i>multiple criteria decision</i> ” OR “ <i>multi-criteria decision analysis</i> ” OR “ <i>multiple criteria decision analysis</i> ” OR MCDA OR ELECTRE OR AHP OR PROMETHEE OR TOPSIS OR VIKOR OR WASPAS OR MACBETH OR ANP OR “ <i>Simple Multi Attribute Rating Technique</i> ” OR MAUT) AND (SKU’s OR “ <i>inventory management</i> ” OR “ <i>Stock Keeping Unit</i> ” OR “ <i>inventory classification</i> ” OR “ <i>stock classification</i> ”)) OR (“ <i>multi-criteria inventory classification</i> ” OR MCIC)
(2) Utilização de ML na gestão de estoques	(“ <i>machine learning</i> ” OR “ <i>inductive learning</i> ” OR “ <i>artificial neural networks</i> ” OR “ <i>case-based reasoning</i> ” OR “ <i>support vector machines</i> ” OR “ <i>reinforcement learning</i> ” OR “ <i>deep learning</i> ” OR “ <i>artificial intelligence</i> ” OR “ <i>decision trees</i> ” OR “ <i>random forests</i> ” OR “ <i>logistic regression</i> ” OR “ <i>ensemble methods</i> ” OR “ <i>unsupervised learning</i> ” OR “ <i>supervised learning</i> ” OR “ <i>data mining</i> ” OR “ <i>data analytics</i> ” OR “ <i>data science</i> ” OR “ <i>knowledge discovery in databases</i> ” OR “KDD”) AND (“ <i>inventory management</i> ” OR “ <i>replenishment policy</i> ” OR “ <i>inventory policy</i> ”)

Tabela 3 – Pesquisas e *strings* de busca

Fonte: Vidal, do Carmo e Caiado (2020)

As duas pesquisas foram realizadas em março de 2020 e foram direcionadas nos bancos de dados para títulos, resumo e palavras-chave. O primeiro passo foi a retirada dos documentos duplicados e na etapa seguinte foram feitos os filtros pelos títulos e resumos. Os critérios de exclusão para essa etapa nas pesquisas (1) e (2), foram:

a) Não adequação ao escopo definidos das pesquisas (1) e (2), que foram, respectivamente, a utilização de métodos MCDM para classificação de SKUs e métodos de ML na gestão de estoques. Para evitar subjetividade na interpretação, a avaliação foi feita por mais de 1 pesquisador (3 no total), conforme sugerido por Thomé, Scavarda e Scavarda (2016);

b) Documentos escritos em linguagem que não fosse a inglesa;

c) Artigos de periódicos que não se enquadraram no Academic Journal Guide, categoria “Operations and Technology Management”, publicado pela Association of Business Schools (lista AJG/ABS) em 2018. A lista AJG/ABS é um influente ranking de avaliação (DRIVAS; KREMMYDAS, 2020).

Dentre os 3 critérios citados acima, os mais dominantes em ambas as pesquisas foi o de adequação ao *ranking* ABS, sendo excluídos 387 artigos na pesquisa (1) e 355 na pesquisa (2). A última etapa do processo de inclusão/exclusão dos trabalhos foi a realização do *backward* e *forward search*. O *backward* consiste em avaliar a literatura citada pelos artigos selecionados e o *forward* trata-se da revisão dos artigos que citaram aqueles que foram encontrados pelas palavras-chave (THOMÉ; SCAVARDA; SCAVARDA, 2016). As Figuras 1 e 2 descrevem o processo de inclusão e exclusão dos artigos das pesquisas (1) e (2), respectivamente, seguindo o protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) (MOHER et al., 2009).

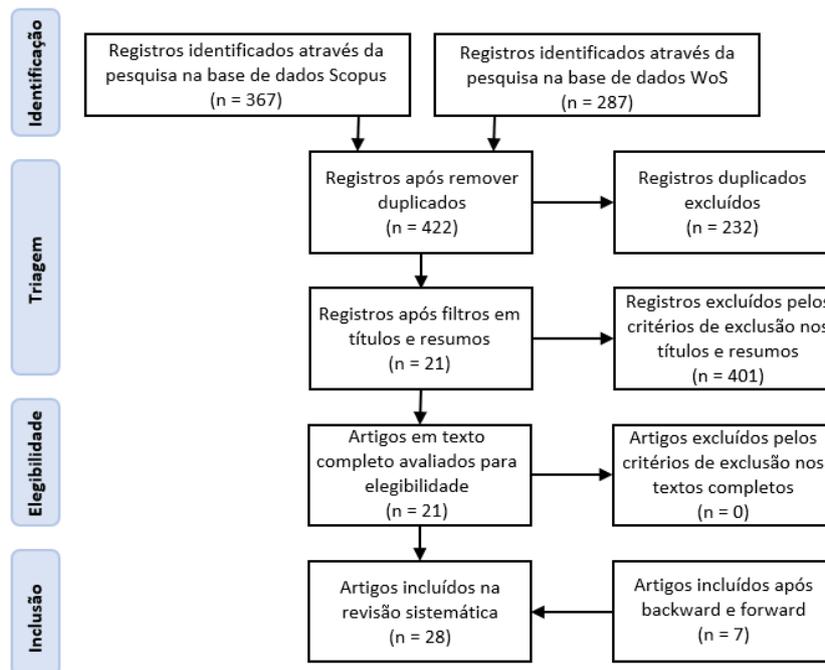


Figura 1 – Fluxo de Diagrama PRISMA: Pesquisa (1)
 Fonte: Vidal, do Carmo e Caiado (2020)

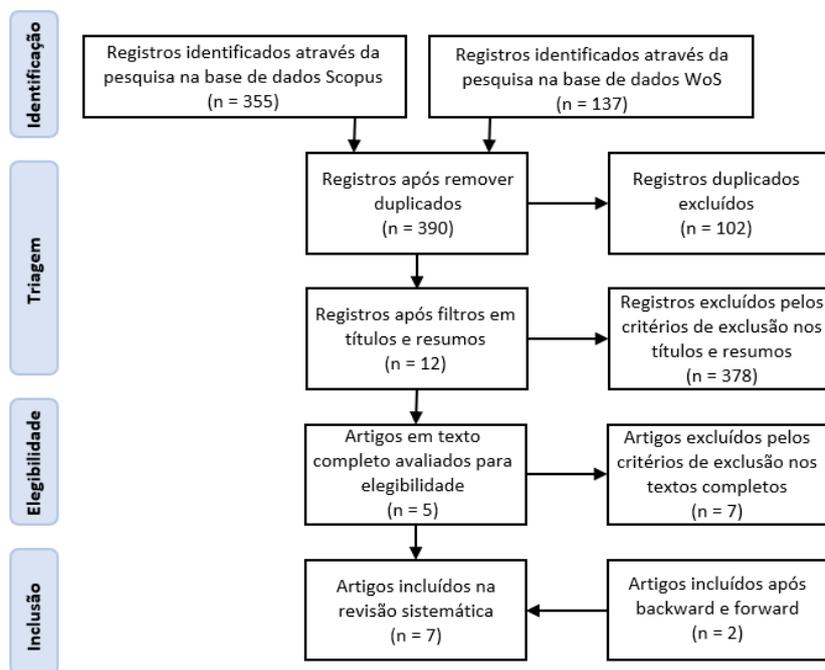


Figura 2 – Fluxo de Diagrama PRISMA: Pesquisa (2)
 Fonte: Vidal, do Carmo e Caiado (2020)

A etapa seguinte foi a coleta de dados e avaliação qualitativa. Para o levantamento dos dados foi elaborada uma matriz de informações que foram julgadas importantes para a interpretação e análise dos resultados. Nesta matriz foram incluídas as características do MCDM e ML, como as técnicas aplicadas, quais e quantos critérios foram avaliados, em que classes os SKUs foram agrupados, o *software* empregado e a quantidade de SKUs aplicadas no modelo. Também foram levantados dados relativos à empresa e características de seus

estoques, para os estudos empíricos, e as contribuições dos trabalhos e sugestões para pesquisas futuras.

A exclusão dos artigos de periódicos não listados na lista da AJG/ABS de 2018 é considerado o principal fator utilizado para avaliação qualitativa dos dados. Porém essas revistas não contemplam os achados da chamada “*grey literature*”, concentrando apenas artigos revisados por pares, o que pode favorecer apenas estudos com resultados positivos podendo gerar um viés (MAGON et al., 2018). Esta é considerada uma limitação de pesquisa desta revisão e deve ser endereçada em pesquisas futuras. Na seção 4.1 os resultados são avaliados, sintetizados e interpretados utilizando a análise de conteúdo guiada por Mayring (2004). O último passo de Thomé, Scavarda e Scavarda (2016) associado a atualização do SLR fica como recomendação para pesquisas futuras, principalmente no que tange a ML, pois esta é uma área muito nova com grande crescimento de publicações.

3.2

Scoping review sobre a aplicação de métodos de ML para previsão de demanda

Segundo Arksey e O'Malley (2005), um *scoping review* consiste em uma metodologia de pesquisa que mapeia os dados relevantes da literatura existente de um tema de interesse, resume e divulga os resultados encontrados e identifica *gaps* existentes. A principal diferença deste método com relação a métodos tradicionais de revisão sistemática está em tratar temas mais amplos que podem vir a abordar uma gama maior de estudos e, desta forma, ter uma menor probabilidade de responder perguntas de pesquisa muito específicas. Ainda segundo Arksey e O'Malley (2005), esta metodologia é composta de 5 etapas principais, que são: identificar as perguntas de pesquisa, identificar os estudos relevantes, seleção dos estudos, mapeamento dos dados e agrupamento, resumo e relato dos resultados.

A primeira etapa de identificação das perguntas de pesquisa está abordada na introdução desta dissertação. O tema de interesse e objetivo da aplicação do método foi de mapear os principais métodos de ML aplicados à previsão de demanda, suas características, escopo de aplicação e principais resultados encontrados. A motivação de escolha do tema está principalmente pelo baixo número de estudos encontrados na seção anterior de SLR de ML na gestão de estoques, motivando a realização de um trabalho com um tema mais amplo do que a gestão de estoques, porém com aplicação mais específica do uso do ML.

A identificação dos estudos relevantes foi realizada a partir da pesquisa nas bases de dados Scopus e Web of Science, conforme a mesma justificativa apresentada na seção 3.1. As palavras-chave de pesquisa foram selecionadas a partir da combinação de termos relacionados à previsão de demanda com as principais técnicas de ML para previsão, de acordo com Jaipuria e Mahapatra (2019), Kück e Freitag (2021), Punia et al. (2020) e da Veiga et al. (2016). As palavras chave utilizadas na pesquisa, relacionadas a partir dos operadores booleanos “AND” e “OR”, foram: ("*forecast*" OR "*time series*") AND ("*demand*") AND ("*machine learning*" OR "*KNN*" OR "*k-nearest neighbours*" OR "*random forest*" OR "*ANN*" OR "*artificial neural network*" OR "*neural network*" OR "*SVM*" OR "*support vector machine*" OR "*takagi-sugeno fuzzy system*" OR "*adaptive neuro-fuzzy inference system*" OR "*ANFIS*" OR "*genetic programming*" OR GP).

A pesquisa foi realizada em julho de 2020 sem restrição de anos de publicação e foram direcionadas nos bancos de dados para títulos, resumo e palavras-chave. A Figura 3, adaptada de Moher et al. (2009), descreve o processo

de seleção, triagem e inclusão dos artigos pesquisados. Conforme ilustra a figura, a pesquisa inicial registrou ao todo 8.677 estudos somando as duas bases, que passaram pelo primeiro critério de exclusão, referente aos documentos duplicados, restando 6.558 artigos. A segunda etapa consiste no filtro pelos títulos e resumos, onde foram aplicados os seguintes critérios de exclusão:

- Não adequação ao escopo de pesquisa, que foi a aplicação de modelos de ML para previsão de demanda;
- Documentos escritos em linguagem que não fosse a inglesa;
- Artigos de periódicos que não se enquadraram na avaliação de 2, 3 ou 4 estrelas do Academic Journal Guide, categoria “Operations and Technology Management”, publicado pela Association of Business Schools (lista AJG/ABS) em 2018.

O critério de adequação ao *ranking* ABS foi o maior responsável pelas exclusões, correspondendo a 6511 artigos. Após os filtros nos títulos e resumos, restaram 34 artigos, que tiveram a leitura completa, onde foi aplicado o último filtro, de adequação ao escopo após leitura de todo o texto. Após leitura completa foram excluídos 3 trabalhos, restando 31 artigos que foram considerados na revisão, finalizando a etapa de seleção dos estudos.

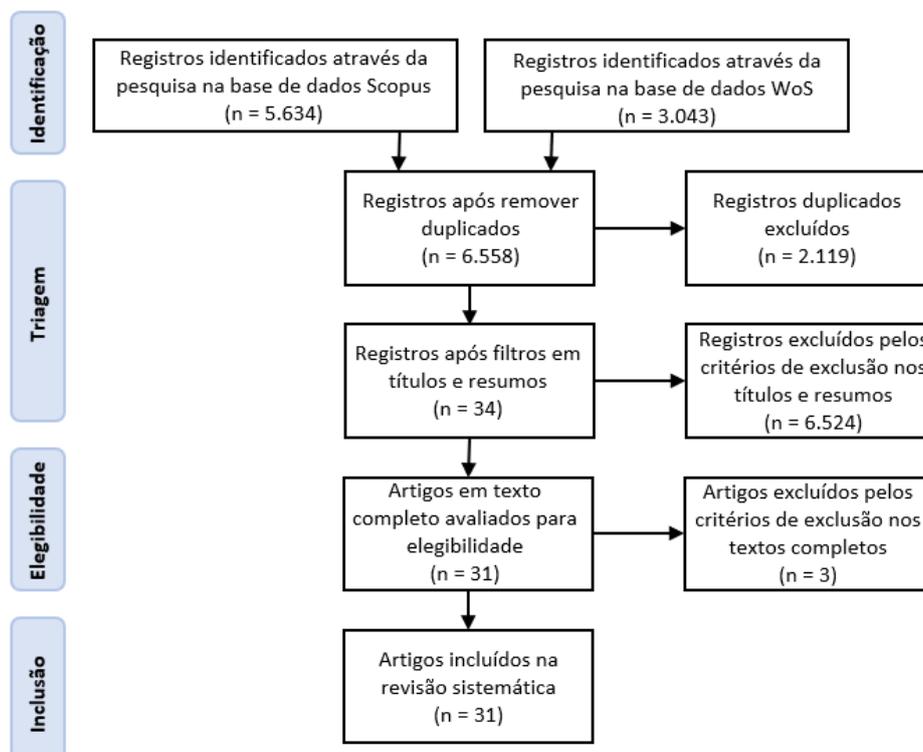


Figura 3 - Fluxo de Diagrama PRISMA: *scoping review*
Fonte: Adaptado de Moher et al. (2009)

Após finalizar a seleção dos estudos, inicia-se a etapa 4 do *scoping review*, que é o mapeamento das informações mais importantes a serem extraídas e analisadas em cada um dos trabalhos. Nesta etapa foi elaborada uma matriz com as principais informações a serem mapeadas, que foram:

- Método de previsão aplicado;
- Variáveis utilizadas na previsão e as características dos dados (contínuos, categóricos ou mistos);
- Métricas de avaliação de performance do modelo e resultados encontrados;
- Tipo de demanda que está sendo prevista;

- Técnicas de pré-processamento dos modelos e de tratamento de flutuações;
- Período de “janelamento” e horizonte de previsão;
- Software/linguagem utilizado para aplicação do modelo;
- Divisão utilizada para separação dos dados em treino e validação;
- Para os trabalhos que aplicaram ANN, principal técnica de ML identificada nos estudos, mapeamento de informações importantes do modelo, como o algoritmo de aprendizado, número de camadas ocultas e neurônios nessas camadas e outros parâmetros considerados pertinentes.

É relevante informar que nem todos os dados mapeados citados acima foram identificados em todos os 31 artigos. Conforme Arksey e O'Malley (2005), não são todos os dados que são disponibilizados de maneira acessível, sendo essa, portanto, uma limitação da presente revisão. A última etapa do método, de agrupamento, resumo e relato dos resultados, é abordada na seção 4.2 desta dissertação.

3.3

Estudo de caso aplicado em uma ferrovia de transporte de cargas

O estudo de caso é um método empírico que analisa e toma conclusões sobre um determinado fenômeno dentro de um contexto real de um objeto de análise, denominado de caso. Este método permite que novas teorias sejam criadas ou que os conhecimentos a respeito do comportamento de um fenômeno sobre eventos contemporâneos sejam melhor desenvolvidos (MIGUEL, 2012).

O presente trabalho conduz um estudo de caso, aplicando conceitos de MCDM e ML no processo de gestão de estoques de uma ferrovia de transporte de cargas. Utilizou-se como base as etapas para elaboração de um estudo de caso, apresentadas por Miguel (2012), Forza (2002), Croom (2005) e Sousa (2005), e detalhadas na Figura 4.

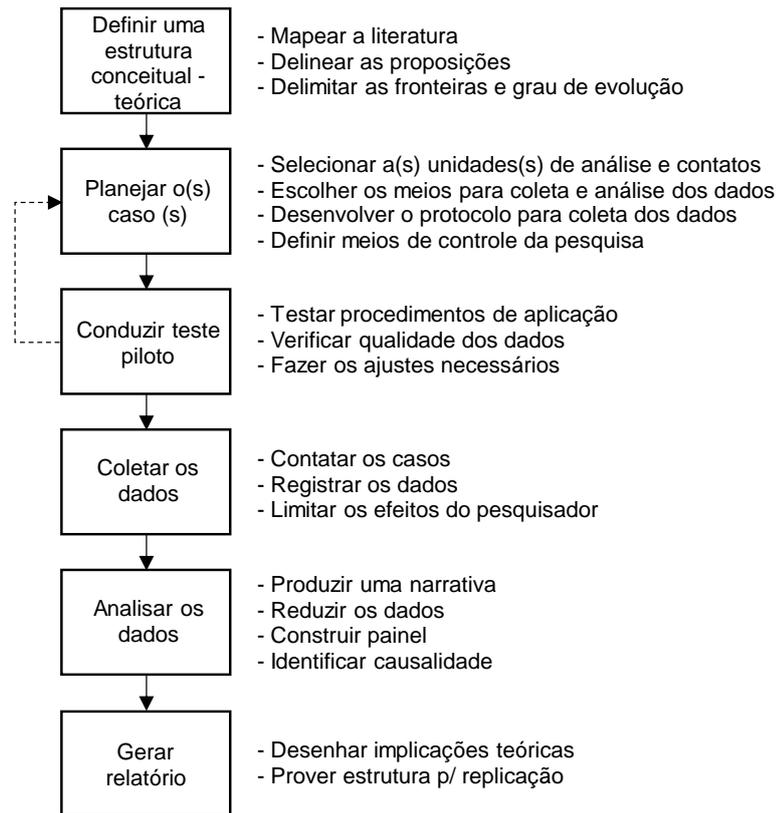


Figura 4 – Fluxo de etapas para um estudo de caso

Fonte: Adaptado de Miguel (2012), Forza (2002), Croom (2005) e Sousa (2005)

A primeira etapa, referente à definição dos referenciais teóricos, foi realizada a partir da SLR e do *scoping review*, no qual as metodologias são explicitadas nas seções 3.1 e 3.2. Esta etapa contempla o levantamento de como a literatura tem tratado o tema, sua evolução ao longo dos anos e *gaps* mapeados por estudo prévios cujos resultados já estão disponíveis na literatura. Também foram pesquisados os principais conceitos referentes à gestão de estoques, aos métodos de MCDM e técnicas de ML, com foco na aplicação na realização de previsões, e estão contidos no capítulo 2 desta dissertação.

A etapa seguinte consiste em planejar o estudo, onde definiu-se o setor e empresa que seria aplicado o caso, assim como os métodos a serem utilizados. Escolheu-se o setor de gestão de estoques de uma operadora ferroviária de cargas, responsável por definir e gerenciar o todo o processo de gestão de estoques e compras da empresa. A escolha da empresa foi motivada por alguns fatores, como a alta variedade de SKUs em estoque, aproximadamente 16 mil, dos mais variados tipos e finalidades como estoque de manutenção de seus ativos, estoque de materiais de suporte à operação e equipamentos de proteção individual. O MCDM tem grande auxílio na identificação dos SKUs críticos para priorização. Além disso, a previsão de demanda mensal para planejamento do processo de compras é um dos grandes *gaps* atualmente na empresa, gerando com isso falta ou excesso de material, que acarreta em muitos custos. A aplicação de um método de previsão adequado, como uma técnica de ML, pode auxiliar nesse processo de tomada de decisão. Nesta etapa também foram definidos os métodos de MCDM e ML que seriam utilizados. Para o MCDM, foi selecionado para aplicação o método AHP juntamente com a metodologia *Fuzzy* e com o método Vikor, formando um método combinado *Fuzzy AHP Vikor*. Para a previsão de demanda a técnica de ML empregada foi a de ANN com seus parâmetros otimizados através de GA, formando o método combinado GA-ANN. As próximas

subseções abordam as justificativas e características da escolha de ambos os métodos, que foram resultado da SLR e do *scoping review*. Todos os dados necessários foram previamente mapeados e definidos fatores como a periodicidade necessária para os históricos, tamanho das amostras e em quais softwares seriam trabalhados. Para aplicação do FAHP, foram definidos os profissionais que iriam realizar a comparação paritária entre os critérios.

Na terceira etapa foram realizados testes com os dados, de maneira a analisar a qualidade dos mesmos e identificação de necessidades de ajustes. Entre os aspectos observados, foram avaliados o formato dos dados fornecidos, a presença de campos/categorias sem informação e outras eventuais necessidades de pré-processamento dos dados.

Após a realização dos testes piloto, foram coletados os dados a serem utilizados nos modelos, o que corresponde à quarta etapa do estudo de caso. A coleta de dados foi realizada a partir de reuniões e entrevistas com os responsáveis pela gestão de estoques da empresa. Inicialmente foi realizada uma primeira reunião com o coordenador de gestão de estoques no formato de uma entrevista semiestruturada para entendimento dos processos, alinhamento dos objetivos da dissertação e de como esses objetivos seriam aplicados. Após esse alinhamento, foram realizadas reuniões com a equipe da gestão de estoques composta pelo coordenador e duas analistas, para coleta dos dados que seriam aplicados. Todos os dados foram disponibilizados no formato MS Excel e tratam-se de registros históricos e parâmetros relativos aos SKUs. Os dados disponibilizados pela empresa foram: histórico de consumo de todos os seus SKUs do período de janeiro de 2010 a dezembro de 2020 (132 meses), previsão de consumo planejada para 2020 pela empresa, dados de cada SKU, como o custo unitário, *lead time* em dias úteis e corridos, categoria do item em relação ao processo da empresa, política de estoques e criticidade/impacto da falta (classificação XYZ). Além disso, a partir dos dados primários fornecidos pela empresa, outros dados foram obtidos, como o consumo e frequência de utilização dos últimos 12 meses.

A aplicação do método FAHP Vikor foi realizada em um processo específico da empresa, que são os estoques de peças e componentes para manutenção de locomotivas. O motivo da escolha deste escopo foi sua criticidade e importância, devido a sua ampla variedade de itens, representando 47% de todos os SKUs, com 7526 itens. Este método tem como principal característica a utilização dos julgamentos e experiências de especialistas da área para a definição de criticidade dos itens. Para isso, foi elaborado um formulário para a coleta dos julgamentos de 3 tomadores de decisão, escolhidos devido à vivência e experiência na gestão de estoques da empresa, sendo eles o coordenador e dois analistas de gestão de estoques. O formulário se encontra no Apêndice 1 desta dissertação.

Para a aplicação do método GA-ANN para previsão de demanda, 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, ou seja, todos os itens que tiveram realização de demanda em todos os meses dentre os 50 itens mais críticos. Um total de 5 SKUs se encontram dentro desse critério e foram selecionados como prova de conceito para aplicação do método de previsão. Estes mesmos itens foram utilizados para a elaboração do *dashboard* de análise dos dados para tomada de decisão.

A quinta etapa contempla análise dos dados, a partir da escolha dos softwares adequados e aplicação dos métodos, que serão detalhados a frente. Por fim, a última etapa do processo consiste da geração de relatório, que ocorreu por meio desta presente dissertação, contendo toda a metodologia,

fundamentação teórica e resultados, fornecendo estrutura para o compartilhamento de informações.

A Figura 5 representa o framework do modelo de trabalho proposto, que compõe a etapa 5 do estudo de caso, referente à análise dos dados. O modelo inicia-se com a avaliação de criticidade dos SKUs a partir da aplicação do método FAHP Vikor. Após a definição dos itens mais importantes para a empresa, inicia-se a etapa seguinte, que consiste em elaborar um modelo de previsão de demanda a partir do método de ML de ANN, com a otimização dos parâmetros através de GA. Por fim, os resultados são consolidados em um *dashboard* gerencial para tomada de decisão.

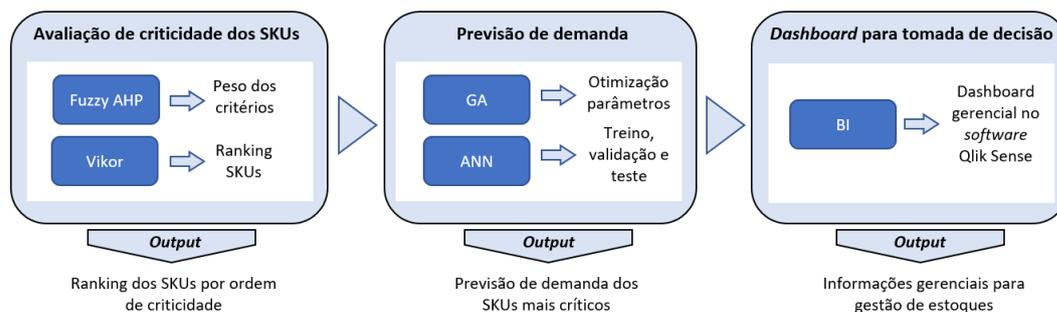


Figura 5 – *Framework* dos modelos do estudo de caso

Fonte: O autor

A aplicação do método FAHP Vikor segue as etapas ilustradas na Figura 6, adaptadas de Rezaie et al. (2014) e Wang et al. (2019). O *Fuzzy AHP* é aplicado com o objetivo de definir um peso para os critérios escolhidos, a partir da avaliação dos tomadores de decisão. O primeiro passo do método consiste na definição dos critérios e organização dos mesmos em uma estrutura hierárquica. Após os critérios estabelecidos, inicia-se a segunda etapa que consiste em compará-los dois a dois pelos tomadores de decisão, seguindo uma escala de importância. Na etapa 3 avalia-se a consistência dos julgamentos realizados. A quarta etapa consiste em definir os pesos *fuzzy* de cada critério. O método *fuzzy* aplicado é o *triangular fuzzy number* (TFN), em português número difuso triangular. O TFN é denotado por (l, m, u) , onde l corresponde ao menor valor possível, m o valor mais provável e u o maior valor possível. Desta forma o método possibilita trabalhar com as incertezas do tomador de decisão (KABIR; HASIN, 2013). Além disso, cada uma das TFNs são convertidas em variáveis linguísticas que representam o quanto um critério é superior ou inferior a outro em nível de importância. Na quinta etapa os pesos *fuzzy* são convertidos em números *crisp*, finalizando dessa forma o *Fuzzy AHP* e definindo o peso de cada um dos critérios.

Após a definição dos pesos de cada critério inicia-se o Vikor, que se trata de um método de ranqueamento e seleção de alternativas a partir da análise de múltiplos critérios baseada em uma medida particular de proximidade com a solução ideal. Na primeira etapa do Vikor são levantados os melhores e piores valores de cada critério no universo de alternativas analisadas. Na etapa 2 calcula-se os valores de S , denominado de grupo de utilidade máxima, e R , que é o peso individual mínimo. Na etapa 3 calcula-se o Q , que consiste em um cálculo de proximidade média de cada alternativa com a solução ideal. Por fim, na etapa 4 ranqueia-se as alternativas de acordo com os valores de S , R e Q . O ranking final dos SKUs foi obtido a partir de uma classificação dos valores de Q em ordem decrescente. O Apêndice 2 oferece um detalhamento das etapas do *Fuzzy AHP* Vikor.

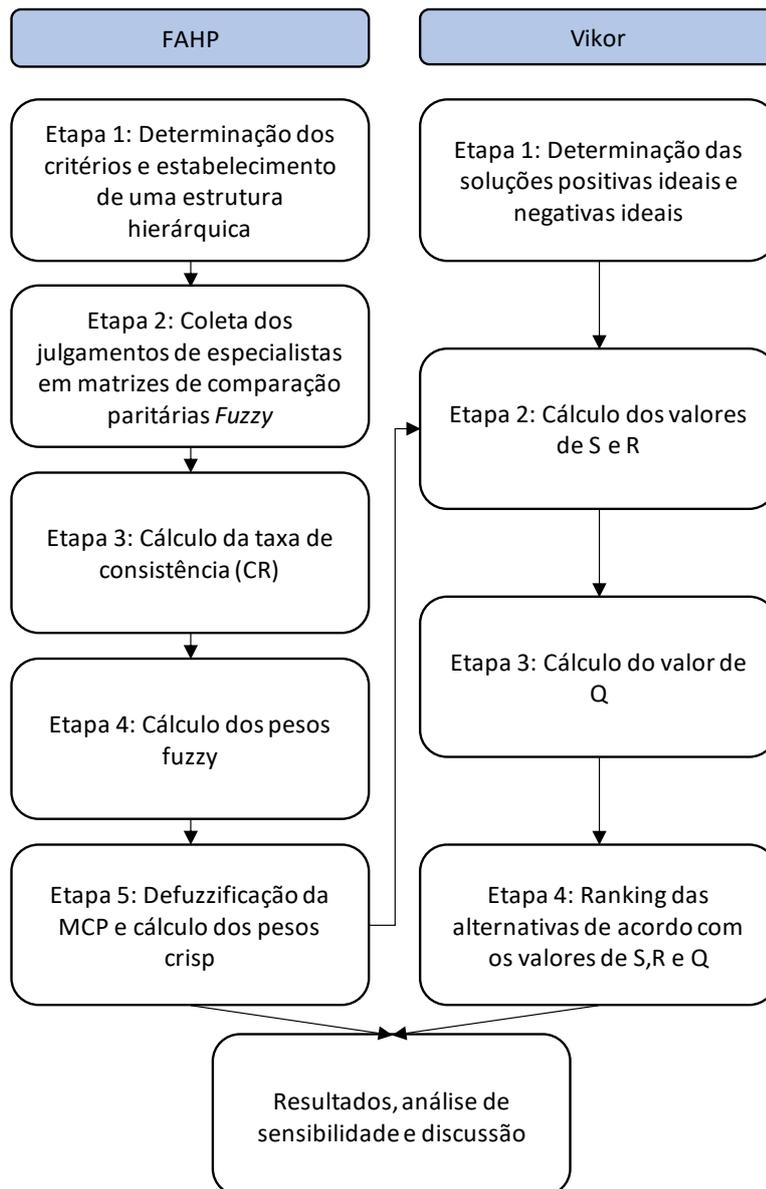


Figura 6 - Etapas de aplicação do FAHP VIKOR
 Fonte: Adaptado de Rezaie et al. (2014) e Wang et al. (2019)

Seguindo as etapas da Figura 5, após a definição dos SKUs o modelo GA-ANN é aplicado para previsão de demanda. Utilizou-se para aplicação do modelo e também para o pré-processamento dos dados o *software* RapidMiner. A Figura 7 sintetiza o processo de aplicação do GA-ANN, onde primeiro é realizado o treinamento e validação de diferentes configurações de redes e posteriormente a configuração de rede escolhida para cada SKU é aplicada a uma base de dados nunca vista, chamada de teste, com o objetivo de testar o poder de generalização do aprendizado. O processo de treino e validação se inicia com os dados de *input*, que consistem no consumo histórico no período de 114 meses compreendido entre janeiro de 2010 a junho de 2019. A primeira etapa do método constitui no pré-processamento desses dados de consumo, que tem como objetivo reduzir sua oscilação e melhorar o desempenho do modelo. Foram aplicadas simultaneamente dois métodos de pré-processamento: a remoção de *outliers* e a normalização. A segunda etapa trata-se do processamento do treino e validação

da rede, sendo os dados de 114 meses divididos em 80% para treino e 20% para validação, de maneira aleatória. Nesta etapa são processadas diferentes configurações de rede de maneira a identificar aquela ideal 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, que no caso desta dissertação foi de 1, dado que o objetivo foi de prever o período a frente. 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 uma modelo de otimização de GA.

Após o fim do treino e validação inicia-se o teste do modelo utilizando como *input* a base de dados de teste, que consiste do consumo no período de julho de 2019 a dezembro de 2020. Os *outputs* do teste do modelo foram a previsão de demanda de 6 meses compreendidos entre julho e dezembro de 2020 e a performance dessa previsão, com o objetivo de comparar com a de outros métodos de previsão e também com a previsão realizada pela própria empresa para o período. O Apêndice 3 oferece um detalhamento das etapas envolvidas no treinamento, validação e teste da ANN, bem como o processo e variáveis utilizadas no método de otimização GA.

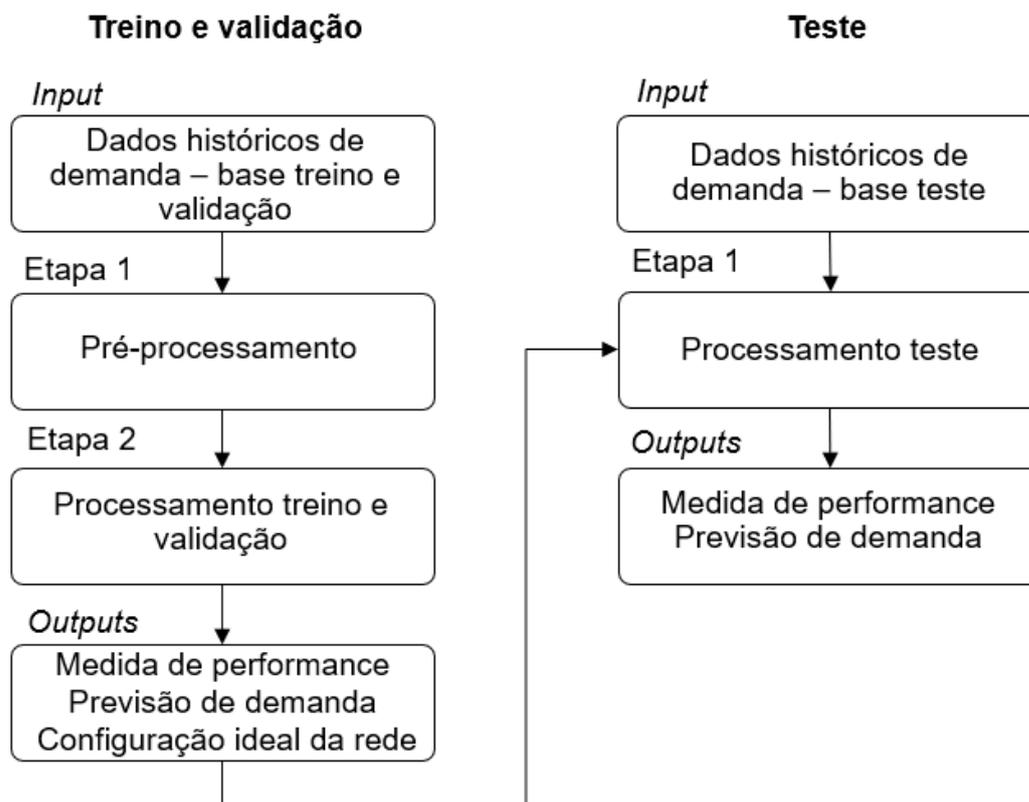


Figura 7 – Etapas ANN
Fonte: O autor

Por fim, um *dashboard* gerencial é elaborado com o objetivo de consolidar todas as informações necessárias para tomada de decisão na gestão de estoques da organização. O desenvolvimento desta ferramenta baseia-se no conceito do *business intelligence* (BI) que segundo Lapa, Bernardino e Figueiredo (2014), trata-se do processo de estruturação dos dados, análise e compartilhamento de informações para tomada de decisão. A ferramenta de BI aplicada nesta dissertação é o Qlik Sense, que segundo Qlik (2015, apud GEORG, 2017), trata-

se de uma plataforma interativa que permite, a partir de fontes de dados distintas, gerar informações e visualizações de dados em tempo real.

A elaboração do modelo de dashboard de visualização dos dados foi realizada a partir do *output* da aplicação do FAHP Vikor para ranqueamento dos SKUs com base nos critérios estabelecidos e da previsão de demanda a partir do modelo GA-ANN. Portanto a ferramenta trata-se de uma prova de conceito, elaborado para os 5 SKUs selecionados.

4 Resultados teóricos

4.1 Resultados da SLR

Este capítulo apresenta os resultados da revisão sistemática da literatura referente à utilização do MCDM e ML aplicado à gestão de estoques, cuja metodologia foi abordada na seção 3.1. Parte do conteúdo apresentado também está contido na SLR de Vidal, do Carmo e Caiado (2020).

4.1.1 Análise descritiva

A Figura 8 ilustra a evolução anual do número de artigos publicados referente a cada uma das pesquisas realizadas. Pode-se observar que o número de publicações referentes a ambos temas ganhou regularidade e volume a partir de 2012, com 68% de todo o histórico de publicações a partir deste ano para a pesquisa (1) e 86% para a pesquisa (2), que se consolida como um tema ainda incipiente reforçando, a partir dos artigos selecionados de acordo com os critérios definidos, que a aplicação do *machine learning* na gestão de estoques tende a ser um tema ainda em evolução na literatura.

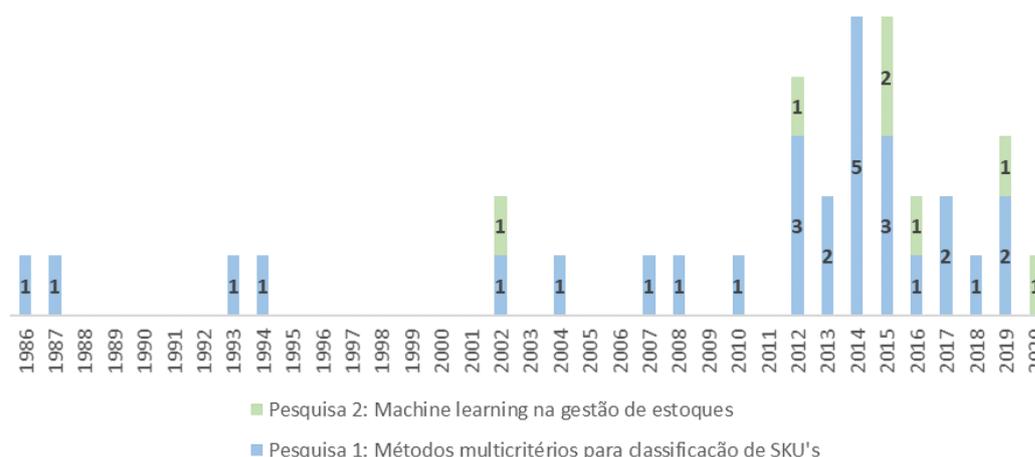


Figura 8 – SLR: Quantidade de artigos por ano e tipo de pesquisa
Fonte: Vidal, do Carmo e Caiado (2020)

A Tabela 4 representa a quantidade de estudos por periódico, além da classificação desse periódico no ranking da AJG/ABS de 2018. Conforme pode-se observar, destaca-se a qualidade dos periódicos em que os trabalhos foram publicados, onde 83% dos artigos concentram-se em periódicos de 2, 3 ou 4 estrelas deste ranking.

Título do Periódico	Pesq. (1)	Pesq. (2)	Ranking AJG/ABS
International Journal of Production Research	5	4	3
International Journal of Production Economics	6	1	3
Computers and Industrial Engineering	7	0	2
Journal of Quality in Maintenance Engineering	2	0	1
International Journal of Industrial and Systems Engineering	2	0	1
International Journal of Operations and Production Management	2	0	4
International Journal of Engineering Business Management	0	2	2
Production Planning and Control	1	0	3
Journal of Operations Management	1	0	4*
Journal of Manufacturing Systems	1	0	1
Journal of Manufacturing Technology Management	1	0	1

Tabela 4 – SLR: Quantidade de artigos por periódico e ranking AJG/ABS do periódico
Fonte: Vidal, do Carmo e Caiado (2020)

4.1.2 MCDM na gestão de estoques

Esta subseção analisa os resultados da pesquisa (1), onde 28 artigos foram selecionados referente à aplicação de MCDM na classificação de SKUs. Em todos os trabalhos identificou-se que o método foi utilizado para classificar as unidades de estoque em classes ou categorias, sendo que em 23 dos 28 estudos eles foram agrupados em 3 níveis de importância.

A Tabela 5 indica a técnica multicritério e sua respectiva fonte de conhecimento para cada um dos estudos. A partir de sua análise observa-se um equilíbrio entre as fontes de conhecimento, com 53% da amostra utilizando técnicas estatísticas e 47% aplicando métodos de julgamento dos tomadores de decisão. Em um dos artigos da amostra foi aplicado mais de um método, portanto a soma das técnicas utilizadas supera os 28 artigos considerados nessa revisão.

Pode-se verificar também que a utilização de alguns métodos se sobrepõe aos demais. O AHP esteve presente em 40% da amostra de dados, com 12 citações, sendo 7 em que foi utilizado somente este método e outros 5 trabalhos em que foi aplicada em conjunto com outra técnica ou ferramenta de tomada de decisão, formando modelos combinados. Conclui-se a partir desses dados que o AHP é um dos principais métodos utilizados na classificação de SKUs.

Em relação às técnicas estatísticas, os modelos de otimização se destacam com a aplicação em 8 trabalhos. Diferentes modelos foram aplicados e suas estruturas, como função objetivo e restrições, foram evoluindo ao longo dos estudos, de forma a encontrar resultados cada vez mais satisfatórios. Entre os modelos aplicados estão aqueles baseados no método de Análise Envoltória de

Dados, do inglês *data envelopment analysis* (DEA), além dos modelos R-model, ZF-model, Ng-model, HV-model, PBB-model, e suas variações (IQBAL; MALZAHN, 2017).

Um outro fator analisado nos artigos foi com relação à natureza dos critérios de comparação utilizados, que podem ser classificados em qualitativos, que são aqueles que são identificados em termos linguísticos, ou quantitativos, caracterizados pela capacidade de serem enumerados (TORABI, HATEFI E SALECK PAY, 2012). A Tabela 5 ilustra quais artigos empregaram critérios quantitativos, qualitativos ou ambos. Pode-se observar que para aqueles que usam técnicas estatísticas existe uma concentração de critérios quantitativos, com 50% utilizando esse tipo de critério. Já para as técnicas de julgamento, 86% abordam também critérios qualitativos.

Com relação à quantidade de critérios e subcritérios utilizados, observa-se que eles variaram entre 2 e 21, porém 79% dos estudos aplicaram entre 3 e 6. Apenas os casos em que aplicaram o AHP apresentam subcritérios, que pode ser explicado pela estrutura hierárquica que este método apresenta. Além disso, a quantidade média de critérios/subcritérios utilizada no AHP é 59% superior aos demais métodos. Em contrapartida, o coeficiente de variação da quantidade de critérios/subcritérios desses estudos é 43% superior aos demais, mostrando maior dispersão dos dados.

Conforme pode ser consultado na Tabela 5, foram 73 critérios/subcritérios diferentes citados nos 28 estudos selecionados, sendo que os 12 mais citados, 16% do total, acumulam 61% da quantidade de citações. Os 3 principais critérios/subcritérios, com sua respectiva quantidade de citações, foram: lead time (24), preço/custo unitário (19) e criticidade/impacto da falta (14).

Na Tabela 5 também são listados os tipos de estoques em que os métodos foram aplicados, para os estudos empíricos. O destaque são os estoques de peças de reposição, presente em 43% dos estudos, sendo que destes, 67% utilizaram o AHP, puro ou combinado com outra técnica. O AHP é o principal método utilizado para classificar peças de reposição devido a alguns fatores, como sua simplicidade de uso, sendo possível aplica-lo por exemplo no Microsoft Excel, sua estrutura hierárquica que permite visualizar mais facilmente todos os fatores envolvidos para tomada de decisão e por permitir o uso de critérios qualitativos, que em alguns outros métodos não podem ser empregados, como por exemplo os modelos de otimização (AYU NARISWARI; BAMFORD; DEHE, 2019). Apesar das vantagens da aplicação do AHP, tornando este método um dos mais utilizados para classificação de itens de estoque, ele também possui algumas desvantagens que precisam ser avaliadas ou gerenciadas pelo tomador de decisão. Entre as suas deficiências está a utilização de uma escala de julgamento desequilibrada, não considerar a incerteza no julgamento, que é muitas vezes impreciso e subjetivo, com grande influência das preferências dos tomadores de decisão (KABIR; HASIN, 2013). Visando solucionar parte destas deficiências Kabir e Hasin (2013) e Shamsaddini, Vesal e Nawaser (2015) abordaram a metodologia *fuzzy* para a comparação paritária entre os critérios, formando um modelo combinado *Fuzzy AHP*. Este método se mostrou eficiente principalmente em aprimorar a imprecisão e subjetividade de avaliação que o método AHP apresenta, de maneira estruturada e simples.

Estudo	Técnica	Fonte de conhecimento	Tipos de critérios	Critérios e subcritérios	Tipo de estoque
Flores e Whybark (1986)	Matriz bi-critério	Estatística	Quantitativo	uso de dólar anual: demanda anual x custo unitário; <i>lead time</i>	Matéria-prima
Flores e Whybark (1987)	Matriz bi-critério	Estatística	Qualitativo e quantitativo	uso de dólar anual: demanda anual x custo unitário; criticidade	Estoque de manutenção
Partovi e Burton (1993)	AHP	Julgamento	Qualitativo e quantitativo	criticidade; custo de pedido; demanda; <i>lead time</i>	Peças de reposição
Gajpal, Ganesh e Rajendran (1994)	AHP	Julgamento	Qualitativo e quantitativo	status de disponibilidade da instalação de produção; tipo de peça necessária; <i>lead time</i>	Peças de reposição
Partovi e Anandarajan (2002)	Redes Neurais Artificiais	Estatística	Quantitativo	preço / custo unitário; custo de pedido; demanda; <i>lead time</i>	Peças de reposição
Braglia, Grassi e Montanari (2004)	Combinado: RCM e AHP	Julgamento	Qualitativo e quantitativo	criticidade da planta; características de fornecimento de reposição; problemas de estoque; taxa de uso; problema de qualidade; perda de produção; efeito dominó; segurança interna e ambiental; segurança externa e ambiental; tempo mascarado; canibalismo; <i>lead time</i> ; número de fornecedores; custo da possibilidade de reparo interno; preço / custo unitário; espaço necessário; obsolescência; problemas de deterioração; número de componentes idênticos na planta; redundâncias; frequência de falha/problemas	Peças de reposição
Bhattacharya, Sarkar e Mukherjee (2007)	TOPSIS	Julgamento	Quantitativo	preço / custo unitário; <i>lead time</i> ; taxa de consumo; perecibilidade dos itens; custo de armazenamento/manutenção de estoque	Matéria-prima
Chu, Liang e Liao (2008)	Lógica fuzzy	Estatística	Qualitativo e quantitativo	preço / custo unitário; frequência de uso; <i>lead time</i> ; status atual do item; criticidade; impacto da falta	Peças de reposição

(continua)

Estudo	Técnica	Fonte de conhecimento	Tipos de critérios	Critérios e subcritérios	Tipo de estoque
Rezaei e Dowlatshahi (2010)	Lógica fuzzy	Estatística	Quantitativo	preço / custo unitário; demanda; <i>lead time</i> ; durabilidade	Produto acabado, estoque em processo, matéria prima e MRO
Torabi, Hatefi e Saleck (2012)	Modelos de otimização	Estatística	Qualitativo e quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i> ; criticidade	Estoque hospitalar
Chen (2012)	Combinado: Otimização com TOPSIS	Estatística	Quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i>	Estoque hospitalar
Molenaers et al. (2012)	AHP	Julgamento	Qualitativo e quantitativo	criticidade do equipamento; probabilidade de falha; <i>lead time</i> ; número de fornecedores; disponibilidade de especificações técnicas; tipo de manutenção	Peças de reposição
Bacchetti et al. (2013)	Esquema hierárquico	Estatística	Qualitativo	fase do ciclo de vendas; <i>lead time</i> ; número de pedidos; frequência da demanda; criticidade; preço / custo unitário	Peças de reposição
Kabir e Hasin (2013)	Combinado: <i>Fuzzy</i> AHP e Redes Neurais Artificiais	Julgamento	Qualitativo e quantitativo	preço / custo unitário; demanda; criticidade; data da última utilização; durabilidade	Matéria-prima
Soylu e Akyol (2014)	Modelos de otimização	Estatística	Qualitativo e quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i> ; criticidade	Estoque hospitalar
Hatefi, Torabi e Bagheri (2014)	Modelos de otimização	Estatística	Qualitativo e quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i> ; criticidade	Estoque hospitalar

(continua)

Estudo	Técnica	Fonte de conhecimento	Tipos de critérios	Critérios e subcritérios	Tipo de estoque
Lolli, Ishizaka e Gamberini (2014)	Combinado: AHP K - means	Julgamento	Qualitativo e quantitativo	uso de dólar anual: demanda anual x custo unitário; criticidade; <i>lead time</i>	Produto acabado
Park, Bae e Bae (2014)	Modelos de otimização	Estatística	Quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i>	Estoque hospitalar
Roda, Macchi e Fumagalli (2014)	AHP	Julgamento	Qualitativo e quantitativo	<i>lead time</i> ; preço / custo unitário; taxa de rotatividade; custo de <i>stock out</i> ; especificidade	Peças de reposição
Sarmah e Moharana (2015)	Lógica fuzzy	Estatística	Qualitativo e quantitativo	valor de consumo; preço / custo unitário; <i>lead time</i> ; comunalidade; criticidade	Peças de reposição
Babai, Ladhari e Lajili (2015)	Modelos de otimização	Estatística	Quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i>	Produto acabado
Shamsaddini, Vesal e Nawaser (2015)	Combinado: Fuzzy AHP	Julgamento	Qualitativo e quantitativo	escassez; taxa de decaimento; consumo	Matéria-prima
Kartal et al. (2016)	SAW AHP VIKOR	Julgamento Julgamento Estatística	Qualitativo e quantitativo	criticidade; demanda; fornecedor; risco; flutuação / desvio padrão da demanda; estoque médio; uso médio diário; <i>lead time</i> ; estoque em consignação; tamanho unitário; preço / custo unitário	Estoque industrial
Yang et al. (2017)	Modelos de otimização	Estatística	Quantitativo	demanda; flutuação / desvio padrão da demanda; lucro bruto unitário; preço / custo unitário; custo de armazenamento/manutenção de estoque; <i>lead time</i>	Produto acabado
Iqbal e Malzahn (2017)	Modelos de otimização	Estatística	Quantitativo	uso de dólar anual: demanda anual x custo unitário; preço / custo unitário; <i>lead time</i>	Estoque hospitalar

(continua)

Estudo	Técnica	Fonte de conhecimento	Tipos de critérios	Critérios e subcritérios	Tipo de estoque
Ishizaka et al. (2018)	Combinado: Otimização com AHP	Julgamento	Quantitativo	uso de dólar anual: demanda anual x custo unitário; frequência de falha/problemas; valor do estoque atual	Peças de reposição
Ayu Nariswari, Bamford e Dehe (2019)	AHP	Julgamento	Qualitativo e quantitativo	criticidade; características técnicas; características de suprimento; essencialidade da peça; prioridade da aeronave; demanda (não programada); demanda (programada); problema de confiabilidade; clima regional; taxa de sucata; <i>lead time</i> ; número de fornecedores; especificidade; capacidade de reparo; rota da aeronave	Peças de reposição
Antosz e Ratnayake (2019)	AHP	Julgamento	Qualitativo e quantitativo	manutenção; logística; categoria da máquina; tempo de substituição; complexidade do processo de substituição; tipo de falha; frequência de falha/problemas; qualificações necessárias para que um funcionário substitua uma peça; preço / custo unitário; <i>lead time</i> ; armazenamento; número de fornecedores	Peças de reposição

Tabela 5 - Estudos sobre MCDM para classificação de SKUs
 Fonte: Vidal, do Carmo e Caiado (2020)

4.1.3 Modelos de ML na gestão de estoques

Nesta subseção são analisados os resultados da pesquisa (2), referente a aplicação do ML na gestão de estoques. Foram selecionados 7 estudos, que abordaram 5 diferentes métodos de ML: redes neurais artificiais, algoritmos genéticos, *reinforcement learning*, *inductive learning* e *long short-term memory* (LSTM) com *random forest* (RF). Conforme pode ser observado na Tabela 6, se destaca a utilização de redes neurais artificiais, com 3 aplicações, sendo as demais técnicas aplicadas em um único estudo cada.

Conforme também é ilustrado na Tabela 6, o ML foi empregado nos estudos com 2 objetivos principais: seleção da política de estoques/gestão dos pedidos e previsão de demanda. O primeiro está relacionado com a definição do tamanho do lote, estoque de segurança e ponto de ressuprimento ótimos, de maneira a otimizar os custos relacionados a gestão de estoques, como custo de pedidos e custo de manutenção do estoque. Foram ao todo 5 trabalhos que empregaram o ML com esse objetivo e, apesar das diferentes estratégias e modelos aplicadas em cada um, todos obtiveram melhores resultados se comparados aos métodos anteriormente utilizados em que o ML não era aplicado.

A utilização do ML para previsão de demanda esteve presente em 2 estudos. Principalmente quando se trata de dimensões com muitas variáveis, alguns métodos de ML como ANN e RF têm melhores resultados do que métodos tradicionais de previsão, como séries temporais (PUNIA et al., 2020). A acurácia na previsão é um fator crítico na gestão de estoques, onde a falha nesse processo pode gerar excesso de estoque ou até mesmo não atendimento à demanda, que compromete a imagem da empresa perante seus clientes.

Estudo	Técnica	Finalidade de aplicação da metodologia
Giannoccaro e Pontrandolfo (2002)	<i>Reinforcement learning</i>	Seleção da política de estoques e tomada de decisão na gestão dos pedidos
Prestwich et al. (2012)	ANN	Seleção da política de estoques e tomada de decisão na gestão dos pedidos
Lee, Na e Kit (2015)	ANN	Previsão de demanda
Borade e Sweeney (2015)	Algoritmos genéticos	Seleção da política de estoques e tomada de decisão na gestão dos pedidos
Sustrova (2016)	ANN	Seleção da política de estoques e tomada de decisão na gestão dos pedidos
Priore et al. (2019)	<i>Inductive learning</i>	Seleção da política de estoques e tomada de decisão na gestão dos pedidos
Punia et al. (2020)	LSTM com <i>random forest</i> (RF)	Previsão de demanda

Tabela 6 – Estudos sobre as técnicas de ML para gestão de estoques

Fonte: Vidal, do Carmo e Caiado (2020)

4.2 Resultados do *scoping review*

Esta seção aborda os resultados do *scoping review*, que teve como tema a aplicação de modelos de ML para previsão de demanda. A aplicação deste

método foi motivada pelo baixo número de artigos identificados na pesquisa (2) da SLR, que buscou avaliar a aplicação de métodos de ML na gestão de estoques, conforme resultados e análises apresentados na subseção 4.1.3.

4.2.1 Análise descritiva

Pode-se observar na Figura 9 a evolução da publicação ao longo dos anos dos 31 artigos considerados. O primeiro artigo publicado aparece em 2006, porém o tema tornou-se mais recorrente e ganhou importância principalmente a partir de 2016, com 65% de toda a amostra de trabalhos sendo publicados a partir desse ano. Isso demonstra o amadurecimento deste tópico no meio acadêmico e sua constante evolução ao longo dos anos, tendo ganhado destaque nos anos recentes.

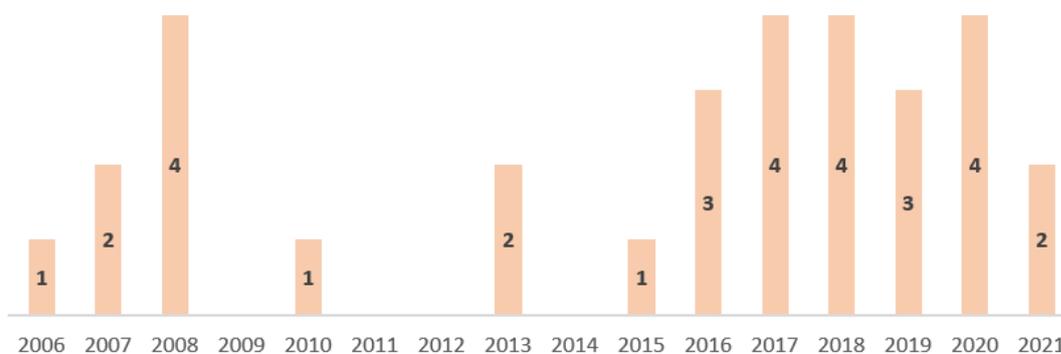


Figura 9 - *Scoping review*: Quantidade de artigos por ano e tipo de pesquisa
Fonte: O autor

Na Tabela 7 pode-se analisar os estudos de acordo com o periódico em que foram publicados. Foram ao todo 7 diferentes periódicos, com 2, 3 ou 4 estrelas do ranking da AJG/ABS de 2018. Um fato relevante analisado é que 74% dos artigos estão concentrados em apenas 2 revistas, *Computers and Industrial Engineering* e *International Journal of Production Economics*, podendo, portanto, considerar esses dois periódicos como os principais canais de disseminação do tema, de acordo com o escopo considerado.

Título do Periódico	Quantidade de artigos	Ranking AJG/ABS
<i>Computers and Industrial Engineering</i>	12	3
<i>International Journal of Production Economics</i>	11	2
<i>International Journal of Production Research</i>	3	3
<i>Production Planning and Control</i>	2	3
<i>Manufacturing and Service Operations</i>	1	3
<i>IEEE Transactions on Engineering Management</i>	1	3
<i>Production and Operations Management</i>	1	4

Tabela 7 - *Scoping review*: Quantidade de artigos por periódico e ranking AJG/ABS do periódico

Fonte: O autor

4.2.2 Métodos de ML na previsão de demanda

Esta subseção aborda o mapeamento de *scoping review* referente aos métodos de ML para previsão de demanda e suas principais características. Ao todo foram utilizados 71 métodos diferentes de previsão de demanda ou combinados nos 31 artigos selecionados, incluindo métodos de ML e métodos tradicionais de previsão. A Tabela 8 sintetiza os métodos que foram empregados para cada um dos diferentes estudos abordados. Observa-se que um método de destaque foi o ANN, que esteve presente em 84% dos artigos, sendo empregado em alguns estudos em seu modelo tradicional e em outros trabalhos formando modelos combinados ou a partir de evoluções do tradicional ANN, como o *evolutionary neural network* (ENN) ou o *wavelet neural networks*. Além de ser o método mais popular empregado entre os artigos analisados, os modelos de ANN também se destacaram por sua boa acurácia de previsão. Para os trabalhos que aplicaram outros métodos de previsão além do ANN, em 80% deles os modelos de ANN apresentaram melhor performance frente aos outros modelos aplicados.

Estudo	Método de Previsão
Lee et al. (2006)	ANN
Co e Boosarawongse (2007)	ANN; <i>Box–Jenkins models</i> ; <i>exponential smoothing</i>
González-Romera, Jaramillo-Morán e Carmona-Fernández (2007)	ANN
Doganis, Aggelogiannaki e SARIMVEIS (2008)	<i>Model predictive control</i> (MPC); <i>linear AR</i> ; Holt-Winters; ANN; <i>radial basis function</i> (RBF) neural network
Au, Choi e Yu (2008)	ENN; SARIMA
Abdel-Aal (2008)	ANN; <i>abductive networks</i> ; naive
Gutierrez, Solis e Mukhopadhyay (2008)	ANN; <i>exponential smoothing</i> ; <i>Croston's method</i> ; <i>Syntetos–Boylan</i> (SBA)
Wong e Guo (2010)	Combinado: <i>harmony search algorithm</i> (HS) com <i>neural net ELM</i> (<i>extreme learning machine</i>) - HS-ELM; ARIMA; ELME; ENN; <i>autoregressive</i> (AR)
Kourentzes (2013)	ANN; Naive; moving average; SES; CR-Naive; CR-moving average; CR-moving average-SB; CR-SES; CR-SES-SB; CR-SES-SH; ANN-GSM; ANN-Dual; ANN-Rate
Kheirkhah et al. (2013)	Combinado: ANN, <i>principal component analysis</i> e DEA; ARIMA; <i>genetic algorithm</i> (GA); <i>fuzzy linear regression</i> ; <i>adaptive neuro fuzzy inference systems</i> (ANFIS); ANN
Arunraj e Ahrens (2015)	Combinado: SARIMA e <i>quantile regression</i> (SARIMA-QR); Combinado: SARIMA e <i>multiple linear regression</i> (SARIMA-MLR); <i>seasonal naïve forecasting</i> ; SARIMA; ANN
Ferreira, Lee e Simchi-Levi (2016)	<i>Regression trees</i>
Pan, Pavur e Pohlen (2016)	<i>Moving average</i> ; <i>double exponential smoothing</i> ; Winters; SARIMA; GARCH; ANN
Lee e Chiang (2016)	<i>Linear regression</i> ; <i>autoregressive</i> (AR); ANN
Chong et al. (2017)	ANN

(continua)

Estudo	Método de Previsão
Guo et al. (2017)	Combinado: ANN com <i>genetic algorithm</i> ; <i>linear exponential smoothing</i> (LES); <i>secondary exponential smoothing</i> (SES); <i>cubic exponential smoothing</i> (CES); <i>grey forecast</i> (GM)
Lolli et al. (2017)	ANN
Hou et al. (2017)	ANN
Puchalsky et al. (2018)	Híbrido: <i>wavelet neural networks</i> com <i>metaheuristic optimization</i>
Villegas, Pedregal e Trapero (2018)	SVM
Cui et al. (2018)	<i>Linear regression</i> ; <i>linear regression with forward selection</i> ; SVM; <i>lasso regression</i> ; <i>gradient boosting model</i> (GBM); <i>random forest</i> (RF)
Dombi, Jónás e Tóth (2018)	<i>Demand model function</i> ; ARIMA; <i>exponential smoothing</i> ; <i>adaptive neuro fuzzy inference systems</i> (ANFIS); ANN
Fu e Chien (2019)	Modelo combinado: <i>Syntetos-Boylan approximation</i> , ARIMA e <i>recurrent neural network</i> (RNN); MAPA; CR; <i>Syntetos-Boylan</i> (SBA); TSB; <i>moving average</i> ; ARIMA; KNN; SVM; RNN
Boutselis e Mcnaught (2019)	<i>Bayesian network models</i>
Gao e Lee (2019)	Combinado: <i>fuzzy C-means</i> (FCM), <i>genetic algorithm</i> (GA) e ANN
Güven e Şimşir (2020)	ANN; SVM
Abbasimehr, Shabani e Yousefi (2020)	ARIMA; ETS; ANN; KNN; RNN; SVM; LSTM (<i>single layer e multi-layer</i>)
Abolghasemi et al. (2020)	ANN; ARIMA; ARIMAX; COM; <i>dynamic linear regression</i> (DLR); <i>exponential smoothing</i> ; ETSX; HR-ARIMA; SVR; <i>Theta</i>
Punia et al. (2020)	Combinado: LSTM e <i>random forest</i> (RF); ANN; <i>multiple regression</i> ; ARIMAX; LSTM networks; <i>random forest</i>
Kück e Freitag (2021)	KNN
Huber e Stuckenschmidt (2021)	<i>S-Naïve</i> ; <i>s-mean</i> ; <i>s-median</i> ; <i>exponential smoothing</i> ; ANN

Tabela 8 - Modelos de previsão abordados nos estudos selecionados

Fonte: O autor

Algumas características do método de ANN e suas variações justificam sua ampla utilização para previsão de demanda. Métodos tradicionais de previsão com séries temporais muitas vezes não têm a capacidade de interpretar padrões de dados não lineares (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008), sendo essa uma das principais características do método de ANN, que é um modelo de regressão não linear e não paramétrico (CO; BOOSARAWONGSE, 2007). Modelos de ANN também têm como característica ser um modelo flexível e facilmente adaptável, sem ser necessário supor previamente nenhuma distribuição dos dados para realização da previsão (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008). Por fim, este método não exige comportamentos entre os dados como normalidade, homocedasticidade ou linearidade para que ele possa ser aplicado (ABUBAKAR et al., 2017).

Devido à ampla utilização do método de ANN nos artigos selecionados, se sobrepondo aos demais métodos para previsão de demanda, e também devido às vantagens desse método com relação aos demais, conforme listadas no parágrafo anterior, as análises seguintes serão concentradas nos 26 estudos que empregaram métodos de redes neurais e suas variações para previsões de demanda. Com relação a estes artigos, ao avaliar as variáveis que foram utilizadas para a realização das previsões, observa-se que 69% da amostra utilizou como *input* do modelo exclusivamente o histórico de consumo dos itens, sendo, portanto, modelos de previsão de séries temporais.

A Tabela 9 sintetiza características do modelo de previsão dos 26 estudos que aplicaram redes neurais, sendo o modelo tradicional de ANN, suas variações ou modelos combinados. A aplicação de um modelo de ML requer a divisão dos dados em dois conjuntos, de treino do modelo e de validação. Os dados de treino são utilizados para a construção do modelo e estimação dos parâmetros, como os pesos que cada elemento de *input* da rede deve assumir. Já os dados de validação têm como objetivo medir a performance, determinando a capacidade da rede criada de generalizar o processo de previsão para diferentes dados, tendo papel fundamental em evitar o *overfit* do modelo sobre os dados de treinamento (FU; CHIEN, 2019). A partir da Tabela 9, observa-se que não existe um padrão adotado pelos autores para a divisão entre treino e validação, sendo que os dados de treino variaram entre 64,5% e 99% nos trabalhos e, conseqüentemente, os de validação variaram entre 1% a 35,5% dos dados. As divisões mais utilizadas pelos autores para treino/validação foram de 80/20 (3 artigos), 70/30 (3 artigos) e 90/10 (2 artigos), sendo todas as demais divisões presentes em apenas um artigo cada.

Com relação ao tipo de rede utilizada, segundo Kourentzes (2013), o *multi-layer perceptron* (MLP) é considerado o principal e mais comum modelo de ANN utilizado para previsão de demanda. A amostra de dados corrobora com o autor, onde 82% dos artigos que citaram esse dado aplicaram o MLP, conforme pode ser observado na Tabela 9. Entre as principais características que justificam o amplo uso desta rede está a sua capacidade de generalizar relacionamentos lineares e não lineares e por ser uma técnica não paramétrica, sem restrição sobre as variáveis de aprendizado (GARDNER; DORLING, 1998; CHONG et al., 2016). Segundo Abdel-Aal (2008), o modelo MLP trata-se de uma rede dividida em camadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, que irá gerar o resultado do modelo.

O número de camadas ocultas e a quantidade de neurônios nestas camadas tratam-se de outra importante característica da rede que tem influência direta na performance, podendo ser definida a partir de métodos empíricos ou a partir de referências da literatura (GÜVEN; ŞİMŞİR, 2020). Segundo Zhang, Patuwo e Hu (1998), alguns autores sugerem métodos para o cálculo do número de neurônios nas camadas ocultas, sendo alguns deles o “n”, “n/2”, “2n” e “2n+1”, sendo n o número de nós na camada de entrada, porém não existe nenhum modelo que seja o melhor para todos os tipos de dados. Na Tabela 9 pode ser observada o número de camadas ocultas e nós nas camadas ocultas em cada um dos artigos que aplicaram modelos de ANN. Com relação ao número de camadas escondidas, 81% dos modelos aplicados que informaram esse dado utilizaram uma única camada, concluindo-se, portanto, que esta é uma configuração que na maioria das redes gera um resultado de performance satisfatório. Entretanto, avaliando o número de neurônios nas camadas escondidas, não se observa grande concentração de um modelo, o que reforça a ideia de que não existe estrutura de neurônios ideal para todos os tipos de dados.

Outra importante característica de uma rede neural consiste em seu algoritmo de aprendizado, que segundo Zhang, Patuwo e Hu (1998) tem como método mais popular o *backpropagation*, que pode ser reforçado pela

concentração desse método nos estudos abordados, conforme observado na Tabela 9.

Após testar um modelo de ANN, é necessário aplicar medidas de performance, que tem como objetivo avaliar o desempenho do modelo para a realização de previsões, além de compará-lo com demais modelos conhecidos. Existem diferentes métricas para medida de performance e cada uma dessas medidas utilizadas pelos estudos que aplicaram ANN são listadas na Tabela 9. Observa-se que os artigos utilizaram, em média, duas medidas de performance cada e 71% das medidas utilizadas concentram-se em 5, sendo elas: *root mean square error* – RMSE (20%), *mean absolute percentage error* – MAPE (18%), *mean absolute error* – MAE (12%), *mean squared error* – MSE (12%) e *mean absolute scaled error* – MASE (8%).

Com o objetivo de melhorar a performance dos modelos, alguns artigos aplicaram técnicas de pré-processamento dos dados. Uma das técnicas mais utilizadas foi a de normalização, presente em 10 dos estudos, sendo este importante para a estabilidade numérica da rede durante o processo de aprendizado. Dentre os métodos de normalização utilizados, destaca-se a normalização Min-Max que transforma os dados de input no intervalo [0,1], utilizado por Co e Boosarawongse (2007), Güven e Şimşir (2020), Abbasimehr, Shabani e Yousefi (2020) e Abolghasemi et al. (2020). Wong e Guo (2010) aplicou três métodos de pré-processamento dos dados com o objetivo de tratar dados inconsistentes e não confiáveis, que foram: 1- detecção e remoção de *outliers*; 2- preenchimento dos *missing values*, ou dados faltantes, pela média dos dois últimos dados da série temporal; 3- normalização dos dados pelo método de normalização z-score.

Estudo	Divisão treino/validação	Algoritmos envolvidos	Tipo de rede	Número de camadas ocultas	Neurônios nas camadas ocultas	Medida de Performance
Lee et al. (2006)	Não se aplica / Não informado	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Duas camadas	Seis neurônios	Não se aplica / Não informado
Co e Boosarawongse (2007)	90 / 10	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Cinco neurônios	MAE; MSE; MAPE; RMSE
González-Romera, Jaramillo-Morán e Carmona-Fernández (2007)	82 / 18	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Dois neurônios	MAPE
Doganis, Aggelogiannaki e SARIMVEIS (2008)	Não se aplica / Não informado	Não se aplica / Não informado	ANN com Função de base radial (RBF)	Não se aplica / Não informado	Não se aplica / Não informado	Erro de previsão médio (%); SSE
Au, Choi e Yu (2008)	80 / 20	<i>Evolutionary algorithm</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Um neurônio	MSE
Abdel-Aal (2008)	80 / 20	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Testados 4, 5 e 6 neurônios/modelo Modelo 1: Cinco neurônios Modelo 2: Seis neurônios	MAPE
Gutierrez, Solis e Mukhopadhyay (2008)	64,5 / 35,5	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Três neurônios	MAPE; RGRMSE; PB

(Continua)

Estudo	Divisão treino/validação	Algoritmos envolvidos	Tipo de rede	Número de camadas ocultas	Neurônios nas camadas ocultas	Medida de Performance
Wong e Guo (2010)	Não se aplica / Não informado	<i>Extreme learning machine (ELM)</i>	<i>Single-hidden-layer</i>	Uma camada	Número máximo de neurônios testados Modelo 1: 10 Modelo 2: 50 Modelo 3: 15 Modelo 4: 10	RMSE; MAPE; MASE
Kourentzes (2013)	Não se aplica / Não informado	<i>Levenberg–Marquardt algorithm</i>	Não se aplica / Não informado	Uma camada	Testados 1, 2 e 3 neurônios	MAE; ME
Kheirkhah et al. (2013)	91 / 9	<i>Bayesian regularization back-propagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Testados 1 a 20 neurônios	MAPE
Arunraj e Ahrens (2015)	70 / 30	<i>Gradient descent algorithm</i>	<i>Multi-layer perception (MLP)</i>	Modelo 1: Uma camada Modelo 2: Duas camadas	Modelo 1: Nove neurônios Modelo 2: Nove e doze neurônios	MAPE; RMSE
Pan, Pavur e Pohlen (2016)	71 / 29	Não se aplica / Não informado	<i>Multi-layer perception (MLP)</i>	Uma camada	Sete neurônios	TCS; TCR; TC
Lee e Chiang (2016)	70 / 30	<i>Levenberg–Marquardt backpropagation algorithm</i>	Não se aplica / Não informado	Não se aplica / Não informado	Não se aplica / Não informado	MSE
Chong et al. (2017)	90 / 10	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Seis neurônios	RMSE
Guo et al. (2017)	Não se aplica / Não informado	<i>Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Nove neurônios	MAE; MSE; Theil IC

(Continua)

Estudo	Divisão treino/validação	Algoritmos envolvidos	Tipo de rede	Número de camadas ocultas	Neurônios nas camadas ocultas	Medida de Performance
Lolli et al. (2017)	65 / 35	<i>Backpropagation gradient-descent algorithm</i> <i>Extreme learning machine</i>	<i>Single-hidden-layer</i>	Uma camada	Três neurônios	MAPE; ME/A
Hou et al. (2017)	70 / 30	Não se aplica / Não informado	<i>Multi-layer perception (MLP)</i>	Não se aplica / Não informado	Quatro neurônios	RMSE
Puchalsky et al. (2018)	99 / 1 89 / 11	<i>Wavelet Neural Networks – WNN</i>	Não se aplica / Não informado	Uma camada	80 neurônios (testados 5, 10, 20, 40 e 80)	MSE; MAPE
Dombi, Jónás e Tóth (2018)	92 / 8	Não se aplica / Não informado	Não se aplica / Não informado	Não se aplica / Não informado	Não se aplica / Não informado	MSE
Fu e Chien (2019)	75 / 25	<i>Backpropagation</i>	Não se aplica / Não informado	Quatro camadas	Não se aplica / Não informado	RMSE; MAE; MASE
Gao e Lee (2019)	Não se aplica / Não informado	<i>Backpropagation gradient-descent algorithm</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	Não se aplica / Não informado	RMSE; MAE
Güven e Şimşir (2020)	Não se aplica / Não informado	<i>Resilient Backpropagation</i>	<i>Multi-layer perception (MLP)</i>	Uma camada	6 neurônios (testados 25 diferentes neurônios)	RMSE
Abbasimehr, Shabani e Yousefi (2020)	80 / 20	<i>Multi-layer LSTM networks</i>	Não se aplica / Não informado	Duas camadas (testados 2, 3 e 4 camadas)	64 neurônios (testados 4, 8, 16, 32, 64 e 128)	RMSE; SMAPE
Abolghasemi et al. (2020)	93 / 7	<i>Backpropagation</i>	Não se aplica / Não informado	Uma camada	Testados diferentes tamanhos, de 1 a 50	MASE

(Continua)

Estudo	Divisão treino/validação	Algoritmos envolvidos	Tipo de rede	Número de camadas ocultas	Neurônios nas camadas ocultas	Medida de Performance
Punia et al. (2020)	Não se aplica / Não informado	<i>Backpropagation</i>	Não se aplica / Não informado	Não se aplica / Não informado	Não se aplica / Não informado	ARME; ARMAE; ARMSE
Huber e Stuckenschmidt (2021)	78 / 22	<i>Backpropagation</i>	Não se aplica / Não informado	Não se aplica / Não informado	Não se aplica / Não informado	MASE; MAE; RMSE

Tabela 9 - Estudos sobre os modelos de ANN para previsão de demanda

Fonte: O autor

5 Estudo de Caso

Este capítulo apresenta os resultados do estudo de caso de aplicação dos métodos MCDM e ML na gestão de estoques de uma empresa do setor ferroviário de transporte de cargas. A primeira seção caracteriza a empresa e seu processo de gestão de estoques e apresenta os métodos de MCDM e ML escolhidos para a aplicação e a justificativa de suas escolhas como resultado da SLR, do *scoping review* e das características da empresa estudada. Na segunda seção, o método MCDM é aplicado nos SKUs da empresa, a partir dos critérios selecionados, de forma a ranqueá-los de acordo com a importância e criticidade. Na terceira seção é aplicado o método de ML em um piloto com os itens considerados mais críticos, definidos na etapa anterior, com o objetivo de realizar sua previsão de demanda mensal. Na quarta seção os resultados são organizados em um *dashboard* para suporte à tomada de decisão. Finalmente, a última seção aborda uma análise dos resultados do estudo de caso e suas considerações finais.

5.1 Caracterização da empresa e escolha dos métodos MCDM e de ML

O estudo de caso é desenvolvido em uma operadora ferroviária logística brasileira. Entre suas principais cargas transportadas, destacam-se: contêineres, siderúrgicos, cimento, bauxita, agrícolas, coque, carvão e minério de ferro.

A busca constante em aprimorar a eficiência de seus processos, atendendo as necessidades dos clientes com excelência, é uma das principais diretrizes da empresa. Nesse contexto, a gestão de estoques tem um importante papel, pois gera custos significativos e seu nível de serviço afeta diretamente as áreas de manutenção e operação da empresa, tendo assim influência no atendimento à demanda dos seus clientes.

Atualmente a empresa apresenta em seus estoques aproximadamente 16 mil SKUs, que são distribuídos em 12 armazéns. Esses materiais são utilizados para diferentes setores e processos da empresa, conforme listados abaixo:

- Peças/materiais para manutenção dos seus principais ativos: locomotivas, vagões, via permanente, equipamentos e sinalização ferroviária;
- Equipamentos de proteção individual (EPIs) e uniformes operacionais fornecidos aos colaboradores;
- Materiais para suporte à operação;
- Materiais indiretos diversos.

Todo o processo de gestão relacionado aos estoques, como a previsão das compras, definição do estoque de segurança e ponto de ressuprimento é realizado pela Coordenação de Gestão de Estoques. A demanda provém exclusivamente de clientes internos da empresa, que são outras áreas que utilizam esses itens para os diferentes processos listados acima. Ainda com relação à demanda, ela é dividida pela empresa em dois tipos distintos: demanda dependente e demanda independente.

A demanda dependente corresponde à demanda de manutenção dos ativos da empresa, como locomotivas, vagões e via permanente, que são

diretamente relacionados ao atendimento dos clientes. Essa demanda, portanto, depende do volume de produção que a empresa planeja transportar no ano. Para atender esse volume, a área de Planejamento e Controle de Manutenção (PCM) elabora anualmente um plano de manutenção dos ativos e, com base nesse plano, estima o chamado *Bill of Material* (BOM), em português Lista de Materiais, que consiste em todos os materiais, peças e componentes necessários para atendimento ao plano de manutenção. O PCM transmite essa demanda para a Coordenação de Gestão de Estoques, que é responsável pelo planejamento das compras dos materiais e quantidade estocada, definição do ponto de ressuprimento e estoque de segurança e todas as demais atividades relacionadas à gestão dos estoques. A Figura 10 apresenta uma síntese do processo de definição da demanda dependente da empresa.

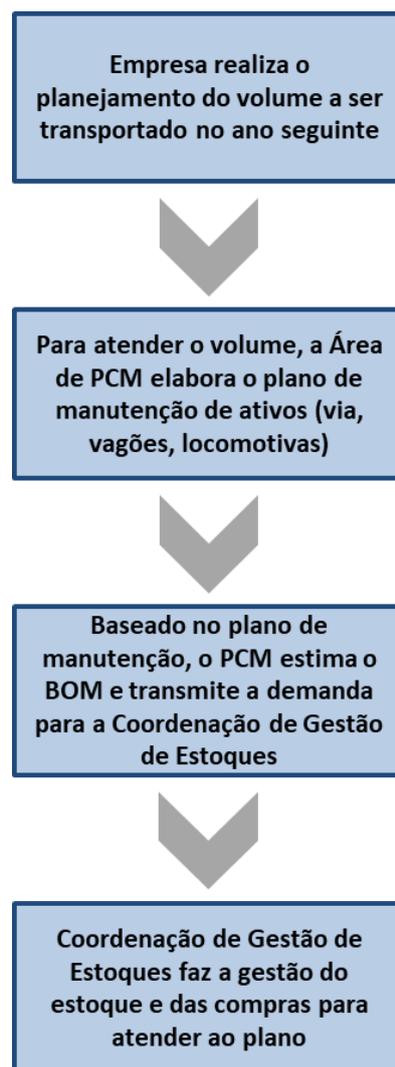


Figura 10 – Processo da demanda dependente da empresa estudada
Fonte: O autor

A demanda independente é referente a todos os demais itens que não fazem parte da BOM dos ativos. Essa demanda é realizada ao longo do ano com base em requisições de materiais (RMs) realizadas pelas áreas, no sistema Oracle.

O processo de gestão de estoques da empresa apresenta algumas oportunidades a serem trabalhadas. Para a demanda dependente, a aderência entre o planejado pelo PCM e o realizado mensal é baixa, sendo que em alguns

meses essa demanda ultrapassa o planejado em alguns itens e em outros ela é abaixo do previsto. Isso prejudica o processo de planejamento de compras dos materiais, que pode gerar estoque em excesso, ocasionando custos para a empresa ou até mesmo não atendimento a demandas, o que pode afetar diretamente sua operação. A área responsável pelo gerenciamento dos estoques não aplica nenhuma metodologia tradicional de previsão de demanda que possa auxiliar no planejamento de compras mensal com maior aderência e assertividade e não possui ferramentas automatizadas que deem suporte a tomada de decisão.

A empresa mantém em seus estoques uma quantidade excessiva de materiais de baixo giro, que contribuem para a elevação do custo de estocagem e obsolescência. Aproximadamente 20% do valor total estocado da empresa são materiais considerados sem giro, que não foram utilizados nos últimos 12 meses. Quanto à classificação de criticidade de seus SKUs, a empresa utiliza métodos tradicionais com base em um critério, sendo eles as classificações ABC, PQR, XYZ e 123, porém não aplica nenhum método multicritério para avaliação de criticidade dos seus itens de estoque.

A partir das características da empresa e dos resultados da SLR e do *scoping review*, definiu-se as ferramentas MCDM e ML a serem aplicadas no estudo de caso. Para a comparação de criticidade dos critérios é aplicado o modelo combinado *Fuzzy AHP Vikor*. A escolha do método AHP ocorreu devido à sua ampla utilização para o processo de ranqueamento de SKUs dentre os modelos que se adequavam à proposta do estudo de caso. Além de ter sido o principal método aplicado nos estudos identificados pela SLR, sua escolha foi motivada por suas principais características, como a possibilidade de utilização de critérios qualitativos e habilidade de absorver os conhecimentos e experiências do tomador de decisão. Apesar de todas essas características, este método também apresenta algumas deficiências, como a subjetividade e imprecisão do julgamento dos critérios (KABIR; HASIN, 2013). A metodologia *fuzzy* foi aplicada junto ao AHP na comparação paritária e definição do peso dos critérios, visando solucionar parte dessas deficiências. Por fim, para a ordenação das alternativas foi utilizado o método Vikor, que se trata de um importante método de ranqueamento a partir de uma medida de proximidade com a solução ideal. Maiores detalhes encontram-se na seção 3.3 da metodologia de estudo de caso desta dissertação e no Apêndice 2.

Com relação à previsão de demanda, o método aplicado é o de ANN otimizado através de GA, formando o método combinado GA-ANN. O ANN trata-se de uma importante ferramenta de ML utilizada em previsões, sendo o principal método de previsão aplicado nos estudos do *scoping review* e com performance superior aos outros métodos aplicados na maior parte dos estudos analisados que testaram diferentes métodos. Além disso, trata-se de um método capaz de interpretar a não linearidade dos dados com boa precisão (CO; BOOSARAWONGSE, 2007), além de ser um modelo flexível e facilmente adaptável (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008). O objetivo é determinar a previsão mensal de consumo dos itens, a partir do histórico de utilização que será utilizado como *input* do modelo. O método GA tem como aplicação a otimização de alguns parâmetros da rede, de maneira a melhorar os resultados de performance. Maiores detalhes encontram-se na seção 3.3 da metodologia de estudo de caso desta dissertação e no Apêndice 3.

5.2

Metodologia multicritério *Fuzzy AHP Vikor* aplicada à classificação de SKUs

Esta seção apresenta os resultados da aplicação da metodologia combinada *Fuzzy AHP Vikor* com o objetivo de ranquear e selecionar os SKUs da empresa de acordo com sua importância. O processo de aplicação do método segue os passos listados na seção 3.3 da metodologia e detalhados no Apêndice 2.

A primeira etapa consiste na determinação dos critérios e estabelecimento de uma estrutura hierárquica. A Figura 11 representa a estrutura hierárquica do FAHP aplicada neste estudo. O objetivo geral é ranquear os SKUs da empresa de acordo com sua ordem de criticidade e importância. Para esse ranking, foram utilizados 4 critérios, que são:

- *Lead time* médio de entrega de um item pelo fornecedor;
- Criticidade/impacto que a falta de um item no estoque gera para a empresa;
- Custo total da demanda no período de 12 meses anteriores à coleta de dados (jul/19 a jun/20), calculado a partir da fórmula: custo unitário x demanda no período;
- Frequência de utilização do item no período de 12 meses anteriores à coleta de dados (jul/19 a jun/20). Esse critério indica em quantos meses, dos últimos 12, o SKU foi utilizado pela empresa, sendo 0 caso ele não tenha sido utilizado em nenhum mês e 12 caso tenha sido utilizado em todos os meses.

A escolha dos critérios foi realizada a partir dos resultados da SLR, ilustrados na subseção 4.1.2 desta dissertação, além de *brainstorming* com os especialistas em gestão de estoques da empresa. 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 na SLR, o que mostra a importância dos mesmos para classificação de SKUs a partir de métodos MCDM, além de terem sido validados pelos especialistas da empresa como importantes critérios aplicáveis aos seus processos, juntamente com o critério frequência de utilização.

O último nível da estrutura hierárquica representa cada SKU que será analisado e ranqueado. São 7.526 itens utilizados no processo de manutenção de locomotivas.

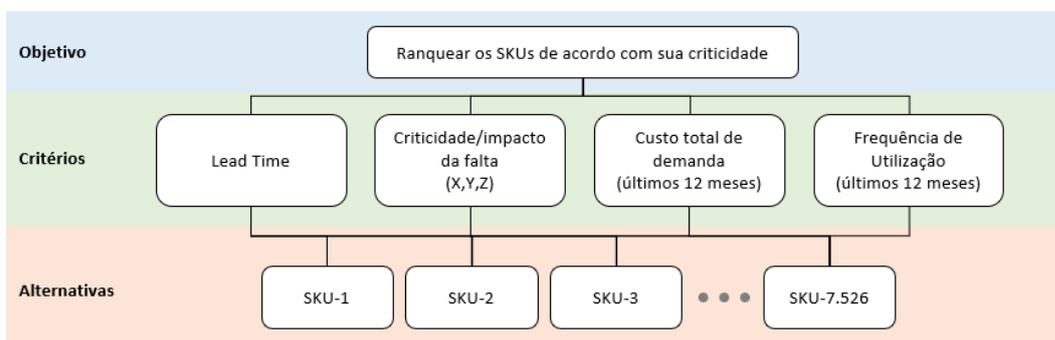


Figura 11 – Estrutura hierárquica FAHP

Fonte: O autor

Na etapa 2, referente a coleta dos julgamentos dos especialistas em matrizes de comparação paritária *fuzzy*, cada um dos 3 tomadores de decisão realizou a comparação entre cada par de critérios a partir das variáveis linguísticas definidas e este resultado se encontra no Apêndice 4. No Apêndice 5 é exibido a MCP, com os valores linguísticos convertidos em TFN, referente ao julgamento de

cada tomador de decisão e a matriz agregada a partir do método de média geométrica.

Após a análise dos critérios pelos especialistas inicia-se a etapa 3 do FAHP, com o cálculo de duas taxas de consistência (CR) dos julgamentos: a partir dos valores médios de cada TFN (CR^m) e com a média geométrica dos valores menores e maiores (CR^g). Os valores de CR encontrados foram: $CR^m = 0,007$ e $CR^g = 0,015$, sendo ambos inferiores a 0,1. Segundo Gogus e Boucher (1998) isto significa que a avaliação foi consistente e, portanto, não precisa ser revista. A quarta etapa consiste no cálculo dos pesos *fuzzy*, apresentados na Tabela 10.

Critério	Pesos fuzzy
Lead Time de entrega dos fornecedores	(0.13, 0.18, 0.26)
Criticidade/impacto da falta	(0.39, 0.52, 0.69)
Custo total de demanda	(0.07, 0.10, 0.13)
Frequência de utilização	(0.14, 0.20, 0.29)

Tabela 10 - Pesos *fuzzy* dos critérios

Fonte: O autor

Na etapa 5 do FAHP os pesos são então desfuzzificados, sendo transformados em pesos *crisp*, onde o peso de cada critério assume um único valor numérico. A Tabela 11 representa os pesos *crisp* para cada um dos critérios, obtidos a partir da avaliação dos 3 tomadores de decisão.

Critério	Peso
Lead Time de entrega dos fornecedores	0,18
Criticidade/impacto da falta	0,52
Custo total de demanda	0,10
Frequência de utilização	0,20

Tabela 11 - Pesos *crisp* dos critérios

Fonte: O autor

Após o cálculo do peso dos critérios, inicia-se a aplicação do método Vikor. Sua primeira etapa consiste no cálculo das soluções positiva ideal (f_i^*) e negativa ideal (f_i^-) para cada critério, sendo elas resumidas na Tabela 12.

Critério	f_i^*	f_i^-
Lead Time de entrega dos fornecedores	587	15
Criticidade/impacto da falta	3	1
Custo total de demanda	R\$ 1.894.460	R\$ 0,00
Frequência de utilização	12	0

Tabela 12 - Soluções positivas ideais e negativas ideais

Fonte: O autor

Inicia-se então a etapa 2 do Vikor, que consiste no cálculo dos valores de S (grupo de utilidade máxima) e R (peso individual mínimo), e da etapa 3,

correspondente ao cálculo do valor de Q, que caracteriza-se pela proximidade de um item da solução ideal. Portanto, quanto menor o valor de Q de um item, melhor seu resultado no ranking e mais próximo ele se encontra da solução ideal. Por fim, o Vikor é finalizado com a etapa 4, onde as alternativas foram ranqueadas por ordem crescente do valor de Q. O SKU classificado como o de maior criticidade apresentou $Q = 0$, ou seja, foi aquele que mostrou o melhor resultado de R e S, portanto tendo os critérios com resultados mais próximos da solução ideal do que os das demais alternativas. A Tabela 13 contém os 50 SKUs classificados como mais críticos a partir da aplicação do método *Fuzzy AHP Vikor* e seus respectivos valores de S, R e Q. Por questões de sigilo o nome dos itens não foi revelado, mas sim o código que cada um possui.

ITEM	Sj	Rj	Qj	Ranking
N512024009	0,117793	0,050692	0,000000	1
N575220006	0,158366	0,090777	0,065835	2
N578265018	0,178455	0,09397	0,080677	3
N575301026	0,184543	0,092497	0,082573	4
N576028330	0,194168	0,092786	0,088361	5
N574460015	0,191585	0,102718	0,097479	6
N575701041	0,214292	0,096013	0,103259	7
N571640103	0,21432	0,096041	0,103305	8
N579110013	0,214367	0,096088	0,103381	9
N612226000	0,218844	0,096117	0,105961	10
N578235850	0,203387	0,108054	0,109887	11
N578501049	0,230724	0,095549	0,112119	12
N578235079	0,230928	0,095752	0,112452	13
N575280125	0,231209	0,096033	0,112912	14
N578060014	0,196193	0,120505	0,119065	15
N578063013	0,243699	0,10138	0,125723	16
N579765021	0,247376	0,10138	0,127817	17
N579765020	0,247523	0,10138	0,1279	18
N578235059	0,25849	0,095745	0,128137	19
N576910034	0,248148	0,10138	0,128256	20
N575280124	0,248182	0,10138	0,128275	21
N618532029	0,238074	0,108944	0,130584	22
N574260284	0,223777	0,129843	0,144726	23
N579318083	0,225219	0,132067	0,147917	24
N578235859	0,237921	0,129843	0,152779	25
N576825093	0,260866	0,118277	0,153511	26
N579760821	0,228839	0,136513	0,154719	27
N570330034	0,263594	0,118277	0,155064	28

(Continua)

ITEM	Sj	Rj	Qj	Ranking
N174020005	0,189229	0,158747	0,155871	29
N646709004	0,232487	0,136513	0,156796	30
N570514004	0,235743	0,139626	0,161968	31
N570514080	0,291679	0,111167	0,163475	32
N578570098	0,259389	0,129843	0,165001	33
N575220007	0,235227	0,144517	0,166889	34
N570360179	0,239158	0,143183	0,167705	35
N574260246	0,239247	0,143183	0,167756	36
N570360014	0,239282	0,143183	0,167776	37
N573950805	0,23682	0,145407	0,168745	38
N571560017	0,232238	0,148964	0,169928	39
N495005185	0,233161	0,148964	0,170453	40
N579710006	0,234909	0,149409	0,171923	41
N562120054	0,253864	0,14096	0,173707	42
N573045004	0,220917	0,158747	0,173912	43
N571560016	0,239777	0,148964	0,17422	44
N575701163	0,276591	0,129843	0,174795	45
N512027068	0,220075	0,161415	0,176277	46
N576825849	0,233527	0,155634	0,177773	47
N575440022	0,244618	0,149853	0,177925	48
N572120106	0,245711	0,149853	0,178547	49
N575240018	0,245749	0,149853	0,178569	50

Tabela 13 - Ranking dos 50 principais SKUs

Fonte: O autor

5.3

Modelo de *machine learning* GA-ANN para previsão de demanda

5.3.1

Resultados

Esta subseção apresenta os resultados do modelo de redes neurais artificiais com algoritmos genéticos (GA-ANN) para previsão de demanda dos 5 SKUs selecionados da subseção anterior (N574260284, N174020005, N573045004, N512027068 e N575440022). Conforme já relatado na seção 3.3, o critério de seleção dos desses 5 SKUs foi porque foram aqueles que tiveram frequência de utilização de 100% no período de janeiro de 2010 a dezembro de 2020, dentro dos 50 SKUs de maior criticidade do ranking relativo ao FAHP Vikor. O processo de aplicação do modelo GA-ANN seguiu as etapas e parâmetros listados na seção 3.3 de metodologia e detalhados no Apêndice 3 e foi desenvolvido e aplicado a partir do *software* Rapidminer. O Apêndice 6 ilustra o *framework* do sistema, aplicado a cada um dos SKUs. O *software* é formado por diversos operadores, que são configurados de maneira a realizar a leitura e pré-

processamento dos dados de *input*, processamento do treinamento do modelo, validação e teste, e tem como *outputs* principais o valor previsto mensal e as medidas de performance.

O processo inicia-se com o treino e validação do modelo e posteriormente o modelo é testado em outra base de maneira a avaliar sua capacidade de aprendizado e generalização. Conforme já relatado na seção 3.3 de metodologia, a base de treino e validação corresponde ao período de janeiro de 2010 a junho de 2019 e a base de teste corresponde ao período de julho de 2019 a dezembro de 2020. No Apêndice 7 é apresentado esse histórico de consumo de cada um desses itens. Pode-se observar a partir da demanda histórica que nenhum dos SKUs aparenta ter comportamento de tendência ou sazonalidade. Além disso, os gráficos deixam claro a grande oscilação e variabilidade dos dados ao longo dos meses, o que torna ainda mais difícil a realização de uma previsão de demanda com grande precisão e baixa taxa de erro. Esse comportamento dos dados justificam a aplicação do modelo GA-ANN, dado que são modelos capazes de capturar padrões não lineares dos dados, o que muitas vezes não é possível em modelos tradicionais de previsão de demanda.

A primeira etapa do processo de treino e validação consiste no pré-processamento da base de *input*, onde foram removidos os *outliers* e normalizados os dados, com os detalhes contidos no Apêndice 3. A quantidade de outliers encontrados para os 5 SKUs corresponde a, em média, 3% dos dados. Posteriormente inicia-se a etapa 2, que consiste no processamento do treino e validação. Para cada um dos SKUs foram definidos a melhor arquitetura de rede e parâmetros que apresentassem a melhor performance de desempenho. Como output do treinamento e validação, a Tabela 14 apresenta os resultados de validação dos melhores modelos de GA-ANN encontrados para cada SKU com relação aos dois indicadores de performance utilizados. Já a Tabela 15 ilustra os parâmetros de cada uma das configurações ideais encontradas para cada SKU. Por fim, a última saída da etapa de treinamento e validação trata-se da previsão de demanda da base de validação, correspondente a 20% das janelas de meses consecutivos, escolhidos de maneira aleatória pelo próprio operador do Rapidminer. A Figura 12 compara o histórico de consumo real da base utilizada para validação do SKU N174020005 com o valor previsto pelo GA-ANN.

Cod. SKU	Ranking criticidade	MAPE	RMSE
N574260284	23	23,83%	6,202
N174020005	29	6,51%	116,325
N573045004	43	14,05%	52,015
N512027068	46	7,01%	100,278
N575440022	48	15,52%	15,492

Tabela 14 – Medidas de performance modelo ANN – base de validação

Fonte: O autor

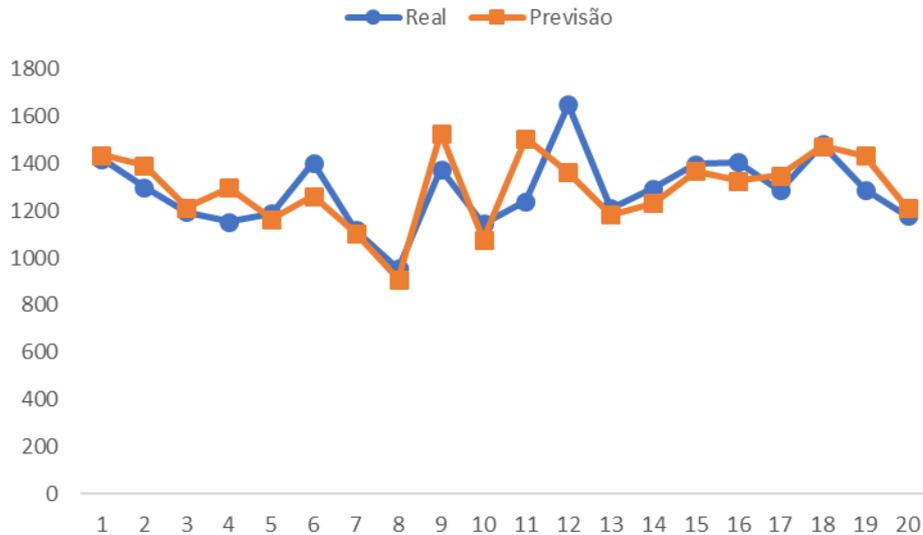


Figura 12 – Demanda real e previsão base de validação: SKU N174020005
 Fonte: O autor

Após o treinamento e validação inicia-se a aplicação do modelo treinado em uma base de teste. A etapa 1 desse método corresponde ao processamento do teste, a partir do modelo ótimo configurado na etapa de validação. Os *outputs* do teste correspondem à medida de performance dos modelos e a previsão de demanda do período. Além disso, nesse período considerado foram aplicados outros métodos tradicionais de previsão de demanda e de ML com a finalidade de comparar com o modelo proposto. Um dos métodos aplicados para comparação foi o SVM, utilizado para previsão de demanda nos trabalhos de Fu e Chien (2019), Güven e Şimşir (2020) e Abbasimehr, Shabani e Yousefi (2020). Além disso, também se aplicou para comparação com a ANN o método tradicional de previsão de demanda *exponential smoothing*, do português amortecimento exponencial, conforme Co e Boosarawongse (2007), Gutierrez, Solis e Mukhopadhyay (2008), Guo et al. (2017), Dombi, Jónás e Tóth (2018) e Huber e Stuckenschmidt (2021). Por fim, também foi considerado para comparação a performance da demanda prevista pela própria empresa para o período. A Tabela 16 ilustra a medida de performance de cada SKU para a base de teste, no modelo proposto GA-ANN e nos modelos para comparação SVM, *exponential smoothing* e o método da empresa.

Cod. SKU	Ranking criticidade	Nós de <i>input</i>	Camadas ocultas	Nós nas camadas ocultas	<i>Training Cycles</i>	<i>Learning rate</i>	<i>Momentum</i>
N574260284	23	6	1	1	3652	0,18	0,19
N174020005	29	12	1	3	786	0,03	0,47
N573045004	43	8	2	1	2856	0,24	0,46
N512027068	46	10	2	2	539	0,21	0,12
N575440022	48	8	1	2	2140	0,19	0,52

Tabela 15 – Configurações ótimas das ANNs
Fonte: O autor

Cod. SKU	Ranking criticidade	GA-ANN		SVM		<i>exponential smoothing</i>		<i>Modelo da empresa</i>	
		MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
N574260284	23	22,45%	3,29	38,54%	4,92	27,10%	3,89	40,95%	5,06
N174020005	29	4,53%	100,43	5,57%	89,21	5,75%	92,69	26,21%	430,18
N573045004	43	16,47%	40,81	38,90%	70,67	19,96%	41,77	33,77%	95,62
N512027068	46	9,74%	101,26	23,35%	165,30	10,69%	106,08	20,18%	144,80
N575440022	48	19,02%	9,13	22,86%	8,70	21,44%	9,25	21,74%	8,06

Tabela 16 – Medidas de performance – base de teste
Fonte: O autor

5.3.2 Análise comparativa dos modelos de previsão

Nesta subseção são analisados os resultados encontrados na subseção 5.3.1, referente aos modelos de previsão de demanda dos 5 SKUs selecionados, onde 114 meses foram utilizados para o processo de treino e validação, que posteriormente foi aplicado em uma base de teste com 18 meses. Analisando os resultados de performance da base de validação dos modelos GA-ANN, observa-se que o melhor resultado possui um MAPE de 6,51% referente ao SKU N174020005, número 29 do ranking de criticidade. Referente ao RMSE essa análise comparativa entre SKUs diferentes para um mesmo método de previsão não é aplicável, dado que se trata de um método que calcula a raiz quadrática média entre os erros dos valores previstos com relação aos reais. Portanto, SKUs com maior magnitude dos dados tendem a ter maior RMSE do que SKUs de menor magnitude, o que explica a grande diferença de RMSE entre os SKUs. Ainda referente aos resultados do MAPE dos modelos de validação, observa-se grande variabilidade dessas medidas, variando de 6,51% do melhor modelo a 23,83% do pior. Esses resultados demonstram que o tipo de previsão e desempenho do modelo tem grande dependência do tipo de dado que está sendo previsto.

Ainda avaliando os resultados de validação e teste dos 5 SKUs selecionados, um fato relevante observado é referente às configurações da rede que foram testados e otimizados a partir de GA. A maior parte dos parâmetros variam muito para cada SKU, principalmente aos parâmetros otimizados *Training Cycles*, *Learning rate* e *Momentum*, o que reforça a importância da aplicação de um modelo de otimização para cada SKU. Alguns padrões podem ser observados com relação ao número de nós em cada camada oculta, onde foram testados de 1 a 6 nós, sendo as configurações com 1 e 2 nós presentes em 4 dos 5 SKUs. Apesar desse padrão encontrado, é evidente pela análise dos parâmetros que não existe modelo e configuração ideal de rede que atenda a todo tipo de série temporal.

Avaliando os resultados da performance do teste da GA-ANN, um fato relevante observado é que o MAPE médio dos 5 SKUs piorou 7,9% da base de validação para a base de teste e o RMSE médio melhorou 12,19%. A variação dos resultados da performance do teste comparado à validação pode ser considerada baixa, o que se pode concluir que os modelos apresentaram boa capacidade de generalização, com resultados em uma base de dados nunca vistas (teste) semelhante ao resultado na base de dados utilizada no processo de treinamento (validação).

Comparando os resultados do modelo GA-ANN proposta nesta dissertação com o método SVM, com o *exponential smoothing* e com a previsão da empresa, observa-se que o GA-ANN tem a melhor medida de MAPE em todos os 5 SKUs comparados com os demais modelos. Com relação ao RMSE, o GA-ANN é o melhor em 3 dos 5 SKUs testados, com desempenho pior apenas em relação ao método SVM no SKU N174020005 e em relação à previsão da própria empresa, referente ao SKU N575440022. Portanto isso deixa evidente a superioridade do modelo proposto neste trabalho em relação a outro conhecido e importante método de ML, a um método tradicional e à metodologia atual da empresa. O MAPE médio dos 5 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 *exponential smoothing*, que foram de 25,84% e 16,99%, respectivamente.

5.4 Apresentação dos dados em um *dashboard* gerencial

Esta seção apresenta o *dashboard* gerencial de gestão de estoques, elaborado no *software* Qlik Sense. Seu objetivo é de consolidar os resultados encontrados nas etapas anteriores, de análise de criticidade pelo FAHP Vikor e previsão de demanda por GA-ANN, 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 suas informações de maneira acessível e de fácil análise. Todos os resultados apresentados são obtidos a partir de bases de dados no formato MS Excel que são processados pelo programa.

A Figura 13 ilustra a parte 1 do *dashboard*. O primeiro filtro tem como objetivo selecionar a faixa de intervalo dos SKUs que se deseja visualizar, a partir de sua ordem de criticidade encontrada pelo FAHP Vikor. O segundo filtro tem o objetivo de selecionar dessa faixa um SKU específico para análise. O gráfico de velocímetro ao lado indica o ranking de criticidade do item filtrado e por fim é apresentado o detalhamento dos resultados dos critérios utilizados para o ranking, na cor verde para os indicadores com valor considerado de criticidade mais baixa e na cor vermelha para aqueles indicadores com resultados considerados muito críticos e que merecem atenção. Os critérios utilizados para destaque de vermelho dos indicadores e consideração do mesmo como crítico foram:

- *Lead time* (dias): acima do terceiro quartil dos resultados de todos os SKUs;
- Criticidade/impacto da falta: itens classificados como “Z”;
- Frequência de utilização (12 meses): acima de 8 meses;
- Consumo (12 meses): acima do terceiro quartil dos resultados de todos os SKUs.



Figura 13 – Parte 1: Dashboard para gestão de estoques

Fonte: O autor

A Figura 14 ilustra a parte 2 do *dashboard*. Nela é exibido o histórico de consumo do SKU selecionado nos últimos 12 meses. Além disso, o gráfico exibe o limite superior e inferior no qual o resultado é considerado um *outlier*, a partir do critério utilizado para identificação de *outliers* apresentado no Apêndice 3. O objetivo dessa informação é de demonstrar o comportamento recente de consumo do item e avaliações de possíveis comportamentos fora do comum.



Figura 14 – Parte 2: Dashboard para gestão de estoques

Fonte: O autor

A terceira e última parte do *dashboard*, ilustrado na Figura 15, exibe a previsão de demanda dos próximos 6 meses do SKU selecionado a partir do método GA-ANN proposto nesta dissertação, através dos métodos de suavização exponencial e SVM, empregados com objetivo de comparação e a partir do planejamento de consumo apresentado pela área de PCM da empresa. Além disso, as medidas de performance MAPE e RMSE de cada método de previsão são apresentadas de maneira a servirem de insumo para o tomador de decisão selecionar o método de previsão mais adequado para o SKU. O melhor resultado de MAPE e RMSE entre os métodos empregados é apresentado de verde e os demais resultados apresentados em vermelho. No Apêndice 8 o *dashboard* completo é exibido, a partir do filtro do SKU N174020005.



Figura 15 – Parte 3: Dashboard para gestão de estoques

Fonte: O autor

5.5

Análise dos resultados e considerações finais

A partir dos resultados do estudo de caso apresentados nas seções anteriores pode-se analisar os benefícios que a aplicação dos métodos combinados pode gerar no processo de gestão de estoques. A classificação dos SKUs por sua criticidade permite o direcionamento de esforços para aqueles itens que tem maior impacto nos processos da empresa. Em um universo com mais de 16 mil SKUs em estoque, sendo que, destes, mais de 7 mil apenas para manutenção de locomotivas, é de vital importância a aplicação de um método robusto e efetivo de ranqueamento. A partir da análise dos pesos de cada um dos critérios algumas importantes conclusões podem ser avaliadas. Primeiramente, um fator relevante trata-se de que o critério criticidade/impacto da falta é o de maior relevância para análise de criticidade dos SKUs, muito superior aos demais critérios analisados, com 52% do peso total. Isso fez com que os itens de maior criticidade fossem aqueles classificados como Z. Esses são os itens que, caso falem no estoque, mais impactam no processo da empresa, podendo gerar atrasos de manutenção das locomotivas que, conseqüentemente, pode gerar falta desses ativos para circulação, o que pode ocasionar perda de volume de transporte e não atendimento à demanda dos clientes. As potenciais

consequências que os itens classificados como Z podem gerar justificam o porquê desse critério ter sido avaliado como o de maior peso. A frequência de utilização foi o critério de segundo maior peso, fato que é justificável dado que itens com maior utilização entre os meses são aqueles que, caso faltem no estoque, irão acarretar no não atendimento à alguma demanda. O *lead time* veio logo atrás com o terceiro maior peso e muito próximo do anterior, o que se justifica pelo fato de um tempo de entrega longo gerar um maior risco de não atendimento no prazo, sendo, portanto, necessário acompanhamento mais próximo e compra antecipada. Por fim, o critério seguinte foi o de consumo em unidades monetárias dos últimos 12 meses, que foi um fato muito relevante, dado que esse é o critério do ABC, mais tradicional método de classificação de SKUs utilizado, reforçando a importância de se utilizarem outros critérios, com pesos diferentes, para avaliação de criticidade dos SKUs.

Após a seleção dos itens mais relevantes iniciou-se a etapa seguinte do trabalho, que consistiu na aplicação de um método de previsão de demanda a partir de ferramentas de ML. A aplicação demonstrou que o método combinado escolhido GA-ANN é aplicável para o processo de previsão de demanda por séries temporais dos SKUs selecionados, com resultado médio superior aos demais métodos de comparação testados e o resultado da empresa. Conforme já citado na subseção 5.3.2, o MAPE médio dos 5 SKUs selecionados é de 32,16% para a previsão realizada pela empresa e foi encontrado um desempenho de 14,44% no modelo GA-ANN proposto nessa dissertação. Esses resultados encontrados tem grandes implicações econômicas e de qualidade no negócio da empresa. A melhor capacidade de previsão permite planejar com mais eficiência suas compras e estoques, reduz o risco de demandas não atendidas e permite a empresa trabalhar com um estoque de segurança inferior mantendo um nível de serviço adequado. Por sua vez, essa necessidade de menor estoque para compensar a variabilidade da demanda tem impactos financeiros diretos em seu custo de oportunidade e risco de obsolescência. O custo de estocagem é um fator crítico acompanhado pela empresa, sendo um dos fatores que mais oneram suas finanças e impactam seu desempenho econômico. Portanto, ferramentas que permitem a redução de seus estoques tem potencial de alavancar consideravelmente seus resultados. Além disso, apesar de aplicado a apenas 5 SKUs como forma de testar a metodologia, o método foi desenvolvido de maneira a ser possível sua generalização para outros itens que a empresa julgar importantes e necessários de serem previstos com maior acurácia. A utilização do método GA para otimização de alguns parâmetros da rede permite que isso seja feito para cada SKU poupando testes exaustivos de diferentes configurações desses parâmetros, permitindo que a empresa consiga replicar com facilidade o modelo.

Por fim, a consolidação de todo o trabalho em um *dashboard* gerencial aplicado em uma ferramenta de BI permite primeiramente consolidar em um único local e de maneira visual a partir de KPIs o desempenho dos seus principais SKUs. Além disso, o intuito da ferramenta é tornar o processo cada vez mais automatizado, permitindo visualizações rápidas e confiáveis do cenário atual que servirão como insumo para a tomada de decisões estratégicas.

É importante destacar a relevância prática e literária da combinação das diversas ferramentas e metodologias aplicadas no presente trabalho e as vantagens que essa combinação pode gerar. A principal característica de cada método foi combinada de maneira que se complementassem e sanassem os *gaps* existentes nos demais. O AHP contribuiu com a sua principal característica de refletir nos pesos dos critérios os conhecimentos e experiências das pessoas que mais entendem do processo e foi complementada pelo *fuzzy*, que trabalhou a subjetividade e incerteza dos seus julgamentos e pelo *Vikor*, que complementou o método a partir do ranqueamento dos itens. Todo esse primeiro processo serviu

para priorizar os itens mais críticos e relevantes para a aplicação da etapa seguinte, de previsão de demanda através de ANN. Sem que os SKUs fossem priorizados os esforços e aplicação dessa robusta e importante ferramenta de previsão poderia ter menor impacto para a empresa. Por sua vez, uma das principais dificuldades da ANN é com relação a escolha de seus parâmetros, que podem variar de acordo com o tipo de dado trabalhado, fato que foi sanado pela aplicação da ferramenta de otimização GA. Para finalizar e resumir os resultados das etapas anteriores de maneira automatizada e sistêmica destaca-se a importância da ferramenta de BI.

A escolha das metodologias aplicadas e de seus parâmetros foram baseadas na literatura, a partir da SLR e do *scoping review*. O AHP foi o principal método aplicado nos trabalhos da SLR, porém nenhum trabalho empregou o FAHP Vikor. Já a ANN, também se tratou da principal metodologia de previsão de demanda aplicada no *scoping review*, porém nenhum trabalho otimizou seus parâmetros através de GA. Por fim, não foi encontrado nenhum trabalho na literatura que combinasse todos essas metodologias, FAHP Vikor, GA-ANN e ferramenta de BI na gestão de estoques, o que atrelado aos resultados positivos que foram obtidos, trata-se da principal contribuição literária desta dissertação.

6

Conclusão e oportunidades de pesquisas futuras

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. O primeiro objetivo da dissertação foi de identificar os principais conceitos e aplicações referentes ao MCDM e ML na tomada de decisão na gestão de estoques, revelando suas aplicações e finalidades. Isso foi realizado primeiramente a partir de uma SLR, que englobou 35 artigos, sendo 28 relacionados à pesquisa (1), de aplicação do MCDM na classificação de SKUs e 7 relativos à pesquisa (2), referente à utilização de métodos de ML na gestão de estoques. O estudo revelou importantes achados principalmente para a pesquisa (1), como o método mais utilizado, sendo esse o AHP, e os principais critérios que a literatura aplica na classificação de estoques. Devido ao baixo número de artigos encontrados na pesquisa (2) da SLR, a análise literária foi complementada com um *scoping review*, que teve como foco uma aplicação específica do ML, que é a previsão de demanda. O estudo, que abordou 31 artigos, permitiu identificar quais os principais métodos de ML aplicados na previsão de demanda e concluindo-se que ANN trata-se de uma das principais técnicas. Além disso, permitiu identificar as configurações da rede neural mais utilizadas e com melhores resultados.

O segundo objetivo foi de desenvolver um modelo que combinasse o MCDM para ranqueamento dos SKUs e um modelo de ML para previsão de demanda. Para ranqueamento dos SKUs o modelo escolhido foi o combinado FAHP Vikor. A seleção do AHP ocorreu devido à sua ampla utilização no processo de gestão de estoques, sendo o principal método identificado na SLR, e também devido à suas características como de utilização de critérios qualitativos e possibilidade de refletir as experiências dos tomadores de decisão. O *fuzzy* foi utilizado com o objetivo de melhorar o modelo e sanar algumas deficiências do AHP, como a subjetividade das avaliações. Por fim, a aplicação do método Vikor ocorreu com o objetivo de ranquear as alternativas a partir dos pesos definidos com o FAHP, de acordo com a proximidade de cada uma com a solução ideal. A partir da definição dos SKUs mais críticos, o modelo de ML é aplicado para previsão de demanda dos mesmos. Para isso foi escolhido o método combinado GA-ANN. O ANN foi principal método utilizado nos estudos do *scoping review*, com boa performance principalmente para previsão de demandas de dados não lineares. Já o GA foi empregado para otimizar alguns parâmetros da ANN e sanar um de seus *gaps*.

O terceiro objetivo da dissertação 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 método MCDM combinado FAHP Vikor e do método de ML GA-ANN pode trazer importantes melhorias no processo de gestão de estoques. O MCDM permitiu garantir o destino de esforços e recursos nos itens que tem mais importância para a 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. Isso endereça um dos principais problemas atuais da empresa que é a baixa aderência entre o planejado e o

realizado de materiais, auxiliando no processo de planejamento de compras. Por fim, o ultimo objetivo alcançado foi a organização dos resultados da aplicação dos métodos em um *dashboard* gerencial, aplicado na ferramenta de BI Qlik Sense. O mesmo irá aprimorar consideravelmente a agilidade e qualidade da tomada de decisão na empresa relacionada à gestão de estoques.

Dentre as principais contribuições desta dissertação, pode-se citar que a combinação dos diferentes métodos na gestão de estoques, formando um importante modelo de tomada de decisão. 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.

Dentre as limitações de pesquisa, pode-se primeiramente citar o critério de seleção dos artigos para a SLR e o *scoping review*, que selecionou apenas artigos de periódicos que se enquadravam na lista AJG/ABS de 2018, sendo o *scoping review* considerando apenas aqueles periódicos com 2, 3 ou 4 estrelas. Apesar deste ser um importante critério para avaliação de qualidade dos dados, a seleção de apenas artigos revisados por pares pode gerar um viés, favorecendo a permanência de apenas estudos com resultados positivos. Outra importante limitação de pesquisa trata-se da quantidade de SKUs selecionados para aplicação da previsão de demanda através do GA-ANN e para a elaboração do *dashboard*, que abrangeu um piloto com 5 itens, selecionados a partir daqueles mais críticos obtidos pelo FAHP Vikor. Seria inviável a seleção de uma amostra grande de itens dado as etapas seguintes necessárias para aplicação dos métodos. Além disso, o objetivo do trabalho foi de realizar um piloto com os itens selecionados, que deverá ser replicado pela própria empresa nos demais itens em que julgar necessário.

Algumas oportunidades de pesquisas futuras podem ser direcionadas. Primeiramente, relativo à etapa teórica da pesquisa, recomenda-se novas revisões de literatura, tanto SLR quanto *scoping review*, a partir da remoção de alguns critérios de exclusão, como o enquadramento dos periódicos na lista AJG/ABS, aumentando, desta forma, a amostra de estudos para análise. Relativo à etapa de estudo de caso, para o método MCDM aplicado recomenda-se a realização de análise de sensibilidade dos resultados, avaliando o efeito da mudança dos pesos no ranking final dos itens. Para a aplicação do GA-ANN, recomenda-se replicar o modelo para mais SKUs da empresa, dessa forma comprovando se o método irá manter uma boa performance. É recomendável também testar outros modelos de previsão clássicos e de ML além dos aplicados, de maneira a confirmar o GA-ANN como melhor método de previsão de demanda para os SKUs selecionados. Além disso, recomenda-se para trabalhos futuros inserir como *input* dos modelos ANN outros dados da empresa que podem ter influência na previsão de demanda mensal. Com relação à aplicação do GA, é recomendável testar a otimização de outros parâmetros da rede, como o número de nós de *input*, o número de camadas ocultas e de nós nessas camadas, dessa forma podendo melhorar ainda mais a performance do modelo. Por fim, relativo ao *dashboard* gerencial elaborado no sistema Qlik Sense, recomenda-se integrar o mesmo com os sistemas da empresa, de maneira a obter automaticamente os resultados sem necessidade de intervenção manual. A empresa está passando por um processo de transformação digital e essa integração representará um grande passo para sua evolução tecnológica.

Glossário

123 - método de classificação de SKUs a partir da dificuldade de aquisição dos itens, sendo 1 itens de aquisição complexa, 2 itens de difícil aquisição e 3 itens de fácil obtenção

ABC - método de classificação de estoques baseado no consumo anual do item em unidades monetárias, sendo A muito importante, B moderadamente importante e C menos importante

Backpropagation - algoritmo de aprendizado supervisionado que calcula o erro de saída da rede e propaga para as camadas anteriores de maneira a recalculando os pesos de cada conexão com o objetivo de reduzir este erro

Backward search - consiste em avaliar a literatura citada pelos artigos selecionados na revisão

Forward search - trata-se da revisão dos artigos que citaram aqueles que foram encontrados pelas palavras-chave

Hidden layer - camada oculta de uma rede neural

Input layer - camada de entrada de uma rede neural

Learning rate - taxa que determina a magnitude das mudanças dos pesos da rede durante o treinamento

Matriz bi-critério - primeira técnica envolvendo MCDM para classificação de SKUs, envolvendo dois critérios

Modelos MCDM de otimização - método aplica modelos de otimização linear ponderada para determinar o peso ótimo dos critérios com relação ao resultado de cada alternativa

Momentum - taxa que faz com que um peso siga uma direção aproximadamente igual ao peso anterior durante o treinamento, com isso reduzindo oscilações

Outlier - dados que se desviam muito do resto das observações

Output layer - camada de saída de uma rede neural

PQR - método de classificação de SKUs a partir da frequência de utilização dos itens, sendo P itens de muita movimentação, Q itens de frequência de utilização intermediária e R itens de baixa frequência de utilização

Scoping review - metodologia de pesquisa que mapeia os dados relevantes da literatura existente de um tema de interesse, resume e divulga os resultados encontrados e identifica *gaps* existentes

Training cycles - número de iterações que são realizadas pelo modelo de ANN durante seu treinamento para atualização dos seus pesos

XYZ - método de classificação de SKUs a partir de sua criticidade/impacto da falta, sendo X itens de baixa criticidade, Y de criticidade média e Z de alta criticidade

Referências bibliográficas

ABBASIMEHR, H.; SHABANI, M.; YOUSEFI, M. An optimized model using LSTM network for demand forecasting. **Computers and Industrial Engineering**, v. 143, 2020.

ABDEL-AAL, R. E. Univariate modeling and forecasting of monthly energy demand time series using abductive and neural networks. **Computers and Industrial Engineering**, v. 54, n. 4, p. 903–917, 2008.

ABOLGHASEMI, M.; BEH, E.; TARR, G.; GERLACH, R. Demand forecasting in supply chain: The impact of demand volatility in the presence of promotion. **Computers and Industrial Engineering**, v. 142, 2020.

ABUBAKAR, A. M.; NAMIN, B. H.; HARAZNEH, I.; ARASLI, H.; TUNÇ, T. Does gender moderates the relationship between favoritism/nepotism, supervisor incivility, cynicism and workplace withdrawal: A neural network and SEM approach. **Tourism Management Perspectives**, v. 23, p. 129–139, 2017.

ANTOSZ, K.; RATNAYAKE, R.M.C. Spare parts' criticality assessment and prioritization for enhancing manufacturing systems' availability and reliability. **Journal of Manufacturing Systems**, v.50, p.212–225, 2019.

ARKSEY, H.; O'MALLEY, L. Scoping studies: Towards a methodological framework. **International Journal of Social Research Methodology: Theory and Practice**, v. 8, n. 1, p. 19–32, 2005.

ARUNRAJ, N. S.; AHRENS, D. A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. **International Journal of Production Economics**, v. 170, p. 321–335, 2015.

AU, K. F.; CHOI, T. M.; YU, Y. Fashion retail forecasting by evolutionary neural networks. **International Journal of Production Economics**, v. 114, n. 2, p. 615–630, 2008.

AYU NARISWARI, N.P.; BAMFORD, D.; DEHE, B. Testing an AHP model for aircraft spare parts. **Production Planning and Control**, v.30, n.4, p.329–344, 2019.

BABAI, M.Z.; LADHARI, T.; LAJILI, I. On the inventory performance of multi-criteria classification methods: empirical investigation. **International Journal of Production Research**, v.53, n.1, p.279–290, 2015.

BABILONI, E.; GUIJARRO, E. Fill rate: from its definition to its calculation for the continuous (s, Q) inventory system with discrete demands and lost sales. **Central European Journal of Operations Research**, v.28, n.1, p.35–43, 2018.

BACCHETTI, A.; PLEBANI, F.; SACCANI, N.; SYNTETOS, A. Empirically-driven hierarchical classification of stock keeping units. **International Journal of Production Economics**, v.143, n.2, p.263–274, 2013.

BAKLACIOGLU, T.; TURAN, O.; AYDIN, H. Metaheuristic approach for an artificial neural network: Exergetic sustainability and environmental effect of a business aircraft. **Transportation Research Part D: Transport and Environment**, v. 63, p. 445–465, 2018.

BAKLACIOGLU, T.; TURAN, O.; AYDIN, H. Metaheuristics Optimized Machine Learning Modelling of Environmental Exergo-Emissions for an Aero-Engine. **International Journal of Turbo and Jet Engines**, p. 1–16, 2019.

BANA E COSTA, C.A.; VANSNICK, J.C. MACBETH - An interactive path towards the construction of cardinal value functions. **International Transactions in Operational Research**, v.1, n.4, p.489–500, 1994.

BENARDOS, P. G.; VOSNIAKOS, G. C. Optimizing feedforward artificial neural network architecture. **Engineering Applications of Artificial Intelligence**, v. 20, n. 3, p. 365–382, 2007.

BHATTACHARYA, A.; SARKAR, B.; MUKHERJEE, S.K. Distance-based consensus method for ABC analysis. **International Journal of Production Research**, v.45, n.15, p.3405–3420, 2007.

BORADE, A.B.; SWEENEY, E. Decision support system for vendor managed inventory supply chain: A case study. **International Journal of Production Research**, v.53, n.16, p.4789–4818, 2015.

BOUTSELIS, P.; MCNAUGHT, K. Using Bayesian Networks to forecast spares demand from equipment failures in a changing service logistics context. **International Journal of Production Economics**, v. 209, p. 325–333, 2019.

BRAGLIA, M.; GRASSI, A.; MONTANARI, R. Multi-attribute classification method for spare parts inventory management. **Journal of Quality in Maintenance Engineering**, v.10, n.1, p.55–65, 2004.

BRANS, J.P. **L'ingenierie de la decision, l'laboration d'instruments d'aide la decision. Colloque sur l'Aide la Decision.** Faculte des Sciences de l'Administration, Universite Laval, 1982.

BRANS, J.P.; MARESCHAL, B. Promethee V: Mcdm Problems With Segmentation Constraints. **INFOR: Information Systems and Operational Research**, v.30, n.2, p.85–96, 1992.

BRANS, J.P.; MARESCHAL, B. The promethee VI PROCEDURE: How to differentiate hard from soft multicriteria problems. **Journal of Decision Systems**, v.4, n.3, p.213–223, 1995.

BRANS, J.P.; MARESCHAL, B.; VINCKE, P. PROMETHEE: a new family of out-ranking methods in multicriteria analysis. **Operational Research, IFORS 84** . Amsterdam, 1984.

BRANS, J.P.; VINCKE, P. A Preference Ranking Organisation Method: (The PROMETHEE Method for Multiple Criteria Decision-Making). **Management Science**, v.31, n.6, p.647–656, 1985.

BRANS, J.P.; VINCKE, P.; MARESCHAL, B. How to select and how to rank projects: The Promethee method. **European Journal of Operational Research**, v.24, n.2, p.228–238, 1986.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

BUCKLEY, J. J. Fuzzy hierarchical analysis. **Fuzzy Sets and Systems**, v. 17, n. 3, p. 233–247, 1985.

CHEN, J.X. Multiple criteria ABC inventory classification using two virtual items. **International Journal of Production Research**, v.50, n.6, p.1702–1713, 2012.

CHEN, Y.; LI, K.W.; KILGOURC, D.M.; HIPEL, K.W. A case-based distance model for multiple criteria ABC analysis. **Computers and Operations Research**, v.35, n.3, p.776–796, 2008.

CHIOU, C. Y.; CHEN, H. C.; YU, C. T.; YEH, C.Y. Consideration Factors of Reverse Logistics Implementation -A Case Study of Taiwan's Electronics Industry. **Procedia - Social and Behavioral Sciences**, v. 40, p. 375–381, 2012.

CHONG, A. Y. L., BOYING, L.; NGAI, E. W. T.; CH'NG, E.; LEE, F. Predicting online product sales via online reviews, sentiments, and promotion strategies. **International Journal of Operations & Production Management**, v. 36, n. 4, p. 358–383, 2016.

CHONG, A. Y. L.; CH'NG, E.; LIU, M. J.; LI, B. Predicting consumer product demands via Big Data: the roles of online promotional marketing and online reviews. **International Journal of Production Research**, v. 55, n. 17, p. 5142–5156, 2017.

CHU, C.W.; LIANG, G.S.; LIAO, C.T. Controlling inventory by combining ABC analysis and fuzzy classification. **Computers and Industrial Engineering**, v.55, n.4, p.841–851, 2008.

CO, H. C.; BOOSARAWONGSE, R. Forecasting Thailand's rice export: Statistical techniques vs. artificial neural networks. **Computers and Industrial Engineering**, v. 53, n. 4, p. 610–627, 2007.

CROOM, S. Topic issues and methodological concerns for operations management research. **Eden Doctoral Seminar on Research Methodology in Operations Management**. Bruxelas, 2005.

CUI, R.; GALLINO, S.; MORENO, A.; ZHANG, D.J. The Operational Value of Social Media Information. **Production and Operations Management**, v. 27, n. 10, p. 1749–1769, 2018.

DA VEIGA, C. P.; DA VEIGA, C. R. P.; PUCHALSKI, W.; COELHO, L. S.; TORTATO, U. Demand forecasting based on natural computing approaches applied to the foodstuff retail segment. **Journal of Retailing and Consumer Services**, v. 31, p. 174–181, 2016.

DOGANIS, P.; AGGEOLOGIANNAKI, E.; SARIMVEIS, H. A combined model predictive control and time series forecasting framework for production-inventory systems. **International Journal of Production Research**, v. 46, n. 24, p. 6841–6853, 2008.

DOMBI, J.; JÓNÁS, T.; TÓTH, Z. E. Modeling and long-term forecasting demand in spare parts logistics businesses. **International Journal of Production Economics**, v. 201, p. 1–17, 2018.

DOUMPOS, M.; ZOPOUNIDIS, C. A multicriteria classification approach based on pairwise comparisons. **European Journal of Operational Research**, v.158, n.2, p.378–389, 2004.

DRIVAS, K.; KREMMYDAS, D. The Matthew effect of a journal's ranking. **Research Policy**, v.49, n.4, 2020.

EDWARDS, W. How to Use Multiattribute Utility Measurement for Social Decisionmaking. **IEEE Transactions on Systems, Man and Cybernetics**, v.7, n.5, p.326–340, 1977.

FERREIRA, K. J.; LEE, B. H. A.; SIMCHI-LEVI, D. Analytics for an online retailer: Demand forecasting and price optimization. **Manufacturing and Service Operations Management**, v. 18, n. 1, p. 69–88, 2016.

FISHBURN, P. C. **Utility theory for decision making**. 1. ed. New York: John Willey & Sons, 1970. 234p.

FLORES, B.E.; WHYBARK, D.C. Implementing multiple criteria ABC analysis. **Journal of Operations Management**, v.7, n.1–2, p.79–85, 1987.

FLORES, B.E.; WHYBARK, D.C. Multiple Criteria ABC Analysis. **Journal of Operations Management**, v.6, n.3, p.38–46, 1986.

FORZA, C. Survey research in operations management: a process-based perspective. **International Journal of Operations & Production Management**, v.22, n.2, p.152–194, 2002.

FU, W.; CHIEN, C. F. UNISON data-driven intermittent demand forecast framework to empower supply chain resilience and an empirical study in electronics distribution. **Computers and Industrial Engineering**, v. 135, p. 940–949, 2019.

GAJPAL, P.P.; GANESH, L.S.; RAJENDRAN, C. Criticality analysis of spare parts using the analytic hierarchy process. **International Journal of Production Economics**, v.35, n.1–3, p.293–297, 1994.

GAO, X.; LEE, G. M. Moment-based rental prediction for bicycle-sharing transportation systems using a hybrid genetic algorithm and machine learning. **Computers and Industrial Engineering**, v. 128, p. 60–69, 2019.

GARDNER, M. W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14–15, p. 2627–2636, 1998.

GEORG, J. **Business intelligence para gestão de vendas do setor de e-commerce utilizando Qlik Sense**. 2017. 63 f. Trabalho de conclusão de curso (Graduação) – Faculdade de Sistemas de Informação, Universidade Regional de Blumenau, Blumenau, 2017.

GIANNOCCARO, I.; PONTRANDOLFO, P. Inventory management in supply chains: A reinforcement learning approach. **International Journal of Production Economics**, v.78, n.2, p.153–161, 2002.

GOGUS, O.; BOUCHER, T. O. Strong transitivity, rationality and weak monotonicity in fuzzy pairwise comparisons. **Fuzzy Sets and Systems**, v. 94, n. 1, p. 133–144, 1998.

GONZÁLEZ-ROMERA, E.; JARAMILLO-MORÁN, M. Á.; CARMONA-FERNÁNDEZ, D. Forecasting of the electric energy demand trend and monthly fluctuation with neural networks. **Computers and Industrial Engineering**, v. 52, n. 3, p. 336–343, 2007.

GUO, F.; DIAO, J.; ZHAO, Q.; WANG, D.; SUN, Q. A double-level combination approach for demand forecasting of repairable airplane spare parts based on turnover data. **Computers and Industrial Engineering**, v. 110, p. 92–108, 2017.

GUTIERREZ, R. S.; SOLIS, A. O.; MUKHOPADHYAY, S. Lumpy demand forecasting using neural networks. **International Journal of Production Economics**, v. 111, n. 2, p. 409–420, 2008.

GÜVEN, İ.; ŞİMŞİR, F. Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods. **Computers and Industrial Engineering**, v. 147, 2020.

HADI-VENCHEH, A. An improvement to multiple criteria ABC inventory classification. **European Journal of Operational Research**, v.201, n.3, p.962–965, 2010.

HATEFI, S.M.; TORABI, S.A.; BAGHERI, P. Multi-criteria ABC inventory classification with mixed quantitative and qualitative criteria. **International Journal of Production Research**, v.52, n.3, p.776–786, 2014.

HECKERLING, P. S.; GERBER, B. S.; TAPE, T. G.; WIGTON, R. S. Use of genetic algorithms for neural networks to predict community-acquired pneumonia. **Artificial Intelligence in Medicine**, v. 30, n. 1, p. 71–84, 2004.

HILLIER, F.S.; LIEBERMAN, G.J. **Introduction to Operations Research**. 7 ed.: McGraw-Hill, 2001.1214p.

HOU, F.; LI, B.; CHONG, A. Y.; YANNOPOULOU, N.; LIU, M. J. Understanding and predicting what influence online product sales? A neural network approach. **Production Planning and Control**, v. 28, n. 11–12, p. 964–975, 2017.

HUBER, J.; STUCKENSCHMIDT, H. Intraday shelf replenishment decision support for perishable goods. **International Journal of Production Economics**, v. 231, 2021.

HWANG, C.L.; YOON, K. **Multiple Attribute Decision Making: Methods and Applications**. New York: Springer-Verlag, 1981. 284p.

IQBAL, Q.; MALZAHN, D. Evaluating discriminating power of single-criteria and multi-criteria models towards inventory classification. **Computers and Industrial Engineering**, v.104, p.219–223, 2017.

ISHIZAKA, A.; LOLLI, F.; BALUGANI, E.; CAVALLIERI, R.; GAMBERINI, R. DEASort: Assigning items with data envelopment analysis in ABC classes. **International Journal of Production Economics**, v.199, p.7–15, 2018.

JAIPURIA, S.; MAHAPATRA, S. S. A study on behaviour of bullwhip effect in (R, S) inventory control system considering DWT-MGGP demand forecasting model. **Journal of Modelling in Management**, v. 14, n. 2, p. 385–407, 2019.

KABIR, G.; HASIN, M.A.A. Multi-criteria inventory classification through integration of fuzzy analytic hierarchy process and artificial neural network. **International Journal of Industrial and Systems Engineering**, v.14, n.1, p.74–103, 2013.

KAHRAMAN, C. **Fuzzy Multi-Criteria Decision Making: Theory and Applications with Recent Developments**. V.16. Springer Science+Business Media, 2008. 590 p.

KARTAL, H.; OZTEKIN, A.; GUNASEKARAN, A.; CEBI, F. An integrated decision analytic framework of machine learning with multi-criteria decision making for multi-attribute inventory classification. **Computers and Industrial Engineering**, v.101, p.599–613, 2016.

KEENEY, R. L.; RAIFFA, H. **Decisions with Multiple Objectives: preferences and value tradeoffs**. New York: John Willey & Sons, 1976. 569 p.

KHEIRKHAH, A.; AZADEH, A.; SABERI, M.; AZARON, A.; SHAKOURI, H. Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis. **Computers and Industrial Engineering**, v. 64, n. 1, p. 425–441, 2013.

KILIC, H. S.; ZAIM, S.; DELEN, D. Development of a hybrid methodology for ERP system selection: The case of Turkish Airlines. **Decision Support Systems**, v. 66, p. 82–92, 2014.

KOURENTZES, N. Intermittent demand forecasts with neural networks. **International Journal of Production Economics**, v. 143, n. 1, p. 198–206, 2013.

KÜCK, M.; FREITAG, M. Forecasting of customer demands for production

planning by local k-nearest neighbor models. **International Journal of Production Economics**, v. 231, 2021.

LANCIONI, R.A. New Developments in Supply Chain Management for the Millennium. **Industrial Marketing Management**, v.29, n.1, p.1–6, 2000.

LAPA, J.; BERNARDINO, J.; FIGUEIREDO, A. A comparative analysis of open source business intelligence platforms. **International Conference on Information Systems and Design of Communication**. Lisbon, 2014.

LEE, C.K.M.; NA, C.M.; KIT, N.C. IoT-based asset management system for healthcare-related industries. **International Journal of Engineering Business Management**, v.7, n.19, 2015.

LEE, C. Y.; CHIANG, M. C. Aggregate demand forecast with small data and robust capacity decision in TFT-LCD manufacturing. **Computers and Industrial Engineering**, v. 99, p. 415–422, 2016.

LEE, Y. H.; JUNG, J. W.; EUM, S. C.; PARK, S. M.; NAM, H. K. Production quantity allocation for order fulfilment in the supply chain: A neural network based approach. **Production Planning and Control**, v. 17, n. 4, p. 378–389, 2006.

LOLLI, F.; GAMBERINI, R.; REGATTIERI, A.; BALUGANI, E.; GATOS, T.; GUCCI, S. Single-hidden layer neural networks for forecasting intermittent demand. **International Journal of Production Economics**, v. 183, p. 116–128, 2017.

LOLLI, F.; ISHIZAKA, A.; GAMBERINI, R. New AHP-based approaches for multi-criteria inventory classification. **International Journal of Production Economics**, v.156, p.62–74, 2014.

MAGON, R.B.; THOMÉ, A.M.T.; FERRER, A.L.C.; SCAVARDA, L.F. Sustainability and performance in operations management research. **Journal of Cleaner Production**, v.190, p.104–117, 2018.

MAJDI, A.; BEIKI, M. Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. **International Journal of Rock Mechanics and Mining Sciences**, v. 47, n. 2, p. 246–253, 2010.

MAYRING, P. Qualitative content analysis. **A companion to qualitative research**, v.1, p.159-176, 2004.

MELNYK, S. A.; LUMMUS, R. R.; VOKURKA, R.J.; BURNS, L. J.; SANDOR, J. Mapping the future of supply chain management: A delphi study. **International Journal of Production Research**, v.47, n.16, p.4629–4653, 2009.

MIGUEL, C. **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. 2. ed. Rio de Janeiro: Elsevier, 2012. 280p.

MIN, H. Artificial intelligence in supply chain management: theory and applications. **International Journal of Logistics Research and Applications**, v.13, n.1, p.13–39, 2010.

MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D.G. Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. **BMJ**, v.339, n.7716, p.332–336, 2009.

MOLENAERS, A; BAETS, H.; PINTELON, L.; WAEYENBERGH, G. Criticality classification of spare parts: A case study. **International Journal of Production Economics**, v.140, n.2, p.570–578, 2012.

NG, W. L. A simple classifier for multiple criteria ABC analysis. **European Journal of Operational Research**, v.177, n.1, p.344–353, 2007.

- OPRICOVIC, S. **Multicriteria Optimization of Civil Engineering Systems**. 1998. 302 p. PhD Thesis, Faculty of Civil Engineering, Belgrade, 1998.
- OPRICOVIC, S.; TZENG, G. H. Compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS. **European Journal of Operational Research**, v. 156, n. 2, p. 445–455, 2004.
- PAN, Y.; PAVUR, R.; POHLEN, T. Revisiting the Effects of Forecasting Method Selection and Information Sharing under Volatile Demand in SCM Applications. **IEEE Transactions on Engineering Management**, v. 63, n. 4, p. 377–389, 2016.
- PARK, J.; BAE, H.; BAE, J. Cross-evaluation-based weighted linear optimization for multi-criteria ABC inventory classification. **Computers and Industrial Engineering**, v.76, n.1, p.40–48, 2014.
- PARTOVI, F.Y.; ANANDARAJAN, M. Classifying inventory using an artificial neural network approach. **Computers and Industrial Engineering**, v.41, n.4, p.389–404, 2002.
- PARTOVI, F.Y.; BURTON, J. Using the Analytic Hierarchy Process for ABC Analysis. **International Journal of Operations & Production Management**, v.13, n.9, p.29–44, 1993.
- PLACIDO DOS SANTOS, F. S.; OLIVEIRA, F. An enhanced L-Shaped method for optimizing periodic-review inventory control problems modeled via two-stage stochastic programming. **European Journal of Operational Research**, v. 275, n. 2, p. 677–693, 2019.
- PRESTWICH, S.D.; TARIM, S.A.; ROSSI, R.; HNIC, B. A neuroevolutionary approach to stochastic inventory control in multi-echelon systems. **International Journal of Production Research**, v.50, n.8, p.2150–2160, 2012.
- PRIORE, P.; PONTE, B.; ROSILLO, R.; DE LA FUENTE, D. Applying machine learning to the dynamic selection of replenishment policies in fast-changing supply chain environments. **International Journal of Production Research**, v.57, n.11, p.3663–3677, 2019.
- PUCHALSKY, W.; RIBEIRO, G. T.; VEIGA, C. P.; FREIRE, R. Z.; COELHO, L. S. Agribusiness time series forecasting using Wavelet neural networks and metaheuristic optimization: An analysis of the soybean sack price and perishable products demand. **International Journal of Production Economics**, v. 203, p. 174–189, 2018.
- PUNIA, S.; NIKOLOPOULOS, K.; SINGH, S.P.; MADAAN, J.K.; LITSIOU, K. Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail. **International Journal of Production Research**, 2020.
- RAMANATHAN, R. ABC inventory classification with multiple-criteria using weighted linear optimization. **Computers and Operations Research**, v.33, n.3, p.695–700, 2006.
- REZAEI, J.; DOWLATSHAHI, S. A rule-based multi-criteria approach to inventory classification. **International Journal of Production Research**, v.48, n.23, p.7107–7126, 2010.
- REZAEI, K.; RAMIYANI, S. S.; NAZARI-SHIRKOUHI, S.; BADIZADEH, A. Evaluating performance of Iranian cement firms using an integrated fuzzy AHP-VIKOR method. **Applied Mathematical Modelling**, v. 38, n. 21–22, p. 5033–5046, 2014.

RODA, I.; MACCHI, M.; FUMAGALLI, L. A review of multi-criteria classification of spare parts: From literature analysis to industrial evidences. **Journal of Manufacturing Technology Management**, v.25, n.4, p.528–549, 2014.

RODRIGUEZ, D.S.S.; COSTA, H.G.; DO CARMO, L.F.R.R.S. Métodos de auxílio multicritério à decisão aplicados a problemas de PCP: Mapeamento da produção em periódicos publicados no Brasil. **Gestão e Produção**, v.20, n.1, p.134–146, 2013.

ROY, B; BERTIER, P. **La méthode ELECTRE II: Une methode de classement en presence de critteres multiples**. Paris: SEMA(Metra-International), 1971. 25p.

ROY, B.; BOUYSSOU, D. **Aide multicritère à la décision: méthodes et cas**. Paris: Econômica, 1993. 695p.

ROY, B. Classement et choix en presence de points de vue multiples (La methode ELECTRE). **Revue Francaise D Informatique de Recherche Operationnelle**, v.2, n.8, p. 57–75, 1968.

ROY, B. ELECTRE III: Un algorithme de classements fondé sur une représentation floue des préférences en présence de critères multiples. **Cahiers du Centre d'Etudes de Recherche Opérationnelle**, v.20, n.1, p. 3–24, 1978.

ROY, B.; HUGONNARD, J. C. Ranking of suburban line extension projects on the Paris metro system by a multicriteria method. **Transportation Research Part A: General**, v.16, n.4, p.301–312, 1982.

ROY, B. **Multicriteria Methodology for Decision Aiding**. V.12. Springer Science+Business Media Dordrech, 1996. 293p.

RUSSEL, S.; NORVIG, P.; **Artificial Inteligence: A Modern Approach**. Prentice-Hall, Second Edition, 2003.

SAATY, T.L. **The Analytic Hierarchy Process**. New York: McGraw-Hill, 1980. 287p.

SARMAH, S.P.; MOHARANA, U.C. Multi-criteria classification of spare parts inventories - A web based approach. **Journal of Quality in Maintenance Engineering**, v.21, n.4, p.456–477, 2015.

SHAMSADDINI, R.; VESAL, S.M.; NAWASER, K. A new model for inventory items classification through integration of ABC-Fuzzy and fuzzy analytic hierarchy process. **International Journal of Industrial and Systems Engineering**, v.19, n.2, p.239–261, 2015.

SITORUS, F.; CILLIERS, J.J.; BRITO-PARADA, P.R. Multi-criteria decision making for the choice problem in mining and mineral processing: Applications and trends. **Expert Systems with Applications**, v.121, p.393–417, 2019.

SOUSA, R. Case research in operations management. **EDEN Doctoral Seminar on Research Methodology in Operations Management**. Bruxelas, 2005.

SOYLU, B.; AKYOL, B. Multi-criteria inventory classification with reference items. **Computers and Industrial Engineering**, v. 69, n.1, p.12–20, 2014.

SUSTROVA, T. An artificial neural network model for a wholesale company's order-cycle management. **International Journal of Engineering Business Management**, v.8, p.1–6, 2016.

THOMÉ, A.M.T.; SCAVARDA, L.F.; SCAVARDA, A.J. Conducting systematic literature review in operations management. **Production Planning and Control**, v.27, n.5, p.408–420, 2016.

TORABI, S.A.; HATEFI, S.M.; SALECK PAY, B. ABC inventory classification in the presence of both quantitative and qualitative criteria. **Computers and Industrial Engineering**, v.63, n.2, p.530–537, 2012.

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a methodology for developing evidence-informed management knowledge by means of systematic review. **British journal of management**, v.14, n.3, p.207–222, 2003.

VAN KAMPEN, T.J.; AKKERMAN, R.; VAN DONK, D.P. SKU classification: A literature review and conceptual framework. **International Journal of Operations and Production Management**, v.32, n.7, p.850–876, 2012.

VIDAL, G.H.P.; DO CARMO, L.F.R.R.S.; CAIADO, R.G.G. **Métodos de apoio multicritério à decisão e modelos de machine learning na gestão de estoques: fundamentos e aplicabilidade**. ENEGEP – Encontro Nacional de Engenharia de Produção. Foz do Iguaçu, 2020.

VILLEGAS, M. A.; PEDREGAL, D. J.; TRAPERO, J. R. A support vector machine for model selection in demand forecasting applications. **Computers and Industrial Engineering**, v. 121, p. 1–7, 2018.

WANG, B. SONG, J.; REN, J.; LI, K.; DUAN, H.; WANG, X. Selecting sustainable energy conversion technologies for agricultural residues: A fuzzy AHP-VIKOR based prioritization from life cycle perspective. **Resources, Conservation and Recycling**, v. 142, p. 78–87, 2019.

WINICZENKO, R; GÓRNICKI, K; KALETA, A; JANASZEK-MÁNKOWSKA, M. Optimisation of ANN topology for predicting the rehydrated apple cubes colour change using RSM and GA. **Neural Computing and Applications**, v. 30, n. 6, p. 1795–1809, 2018.

WONG, W. K.; GUO, Z. X. A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. **International Journal of Production Economics**, v. 128, n. 2, p. 614–624, 2010.

YANG, L.; LI, H.; CAMPBELL, J.F.; SWEENEY, D.C. Integrated multi-period dynamic inventory classification and control. **International Journal of Production Economics**, v.189, p.86–96, 2017.

YU, W. **ELECTRE TRI – Aspects méthodologiques et manuel d’Utilisation**. Document du LAMSADE. Université de Paris–Dauphine. Paris, 1992.

ZAVADSKAS, E. K.; TURSKIS, Z.; ANTUCHEVICIENE, J.; ZAKAREVICIUS, A. Optimization of weighted aggregated sum product assessment. **Electronics and Electrical Engineering**, v.122, n.6, p.3–6, 2012.

ZHOU, P.; FAN, L. A note on multi-criteria ABC inventory classification using weighted linear optimization. **European Journal of Operational Research**, v.182, n.3, p.1488–1491, 2007.

APÊNDICE 1 – Formulário de coleta de dados

FAHP - Fuzzy Analytic Hierarchy Process

Objetivo: Determinar o peso de importância dos critérios, para classificação dos SKUs

Insira os dados apenas nos campos verdes livres

Instruções:

Por favor, compare a importância entre os critérios estabelecidos e preencha a tabela: qual elemento de cada par é mais importante, **A ou B**, e quanto ele é mais importante, a partir da escala de importância abaixo.

Intensidade	Explicação
Mesma importância	Ambos os elementos contribuem igualmente para o objetivo
Intermediária: Mesma importância - Moderada	Classificação intermediária entre o de mesma importância e de importância moderada
Importância moderada	Experiência e juízo favorecem levemente uma atividade com relação à outra
Intermediária: Moderada - Forte	Classificação intermediária entre o de importância moderada e forte
Importância forte	Experiência e juízo favorecem fortemente uma atividade com relação à outra
Intermediária: Forte - Muito Forte	Classificação intermediária entre o de importância forte e muito forte
Importância muito forte	Uma atividade é muito fortemente favorecida, sendo sua dominância evidenciada na prática
Intermediária: Muito Forte - Extrema	Classificação intermediária entre o de importância muito forte e extrema
Importância extrema	A evidência favorecendo uma das atividades é a maior possível, com o mais alto grau de segurança

Crítérios:

Lead Time de entrega dos fornecedores - Tempo médio de entrega de um item

Criticidade/impacto da falta - Impacto causado pela falta do item para a empresa

Custo total de demanda - Histórico de utilização do item em unidades monetárias (custo unitário x demanda anual)

Frequência de Utilização - Frequência em que um item é retirado do estoque

Avaliação:

Nome:

Data:

Critério		Mais importante?	Escala de importância
A	B	A, B ou Igual	
Lead Time de entrega dos fornecedores	Criticidade/impacto da falta	<input type="text"/>	<input type="text"/>
	Custo total de demanda	<input type="text"/>	<input type="text"/>
	Frequência de Utilização	<input type="text"/>	<input type="text"/>
Criticidade/impacto da falta	Custo total de demanda	<input type="text"/>	<input type="text"/>
	Frequência de Utilização	<input type="text"/>	<input type="text"/>
Custo total de demanda	Frequência de Utilização	<input type="text"/>	<input type="text"/>

APÊNDICE 2 – *Fuzzy* AHP Vikor

a) Método *Fuzzy* AHP

I. Determinação dos critérios e estabelecimento de uma estrutura hierárquica

A primeira etapa do AHP consiste em determinar os critérios utilizados e elaboração da estrutura hierárquica do problema. O nível 1 da estrutura hierárquica apresenta o objetivo da aplicação do AHP. No nível 2 são estruturados os critérios e subcritérios, quando estes existirem. Por fim, no último nível são representadas as alternativas que desejam ser ranqueadas (REZAIIE et al., 2014).

II. Coleta dos julgamentos de especialistas em matrizes de comparação paritárias *fuzzy*

A segunda etapa do método trata-se da coleta dos julgamentos dos especialistas. Esta é uma etapa fundamental do AHP, onde a partir de uma matriz de comparação paritária (MCP), todos os critérios são comparados dois a dois pelo tomador de decisão, seguindo uma escala de importância. O número de julgamentos de cada tomador de decisão para n critérios é $n(n-1)/2$ (SAATY, 1987). A avaliação é realizada em variáveis linguísticas, que são associados a *triangular fuzzy numbers* (TFNs). A Tabela 17 representa cada variável linguística com seus respectivos TFNs positivos e negativos, proposta por Chiou et al. (2012).

Variáveis linguísticas	TFN Positivo	TFN Negativo
Mesma importância	(1,1,1)	(1,1,1)
Intermediária: Mesma importância - Moderada	(1,2,3)	(1/3,1/2,1)
Importância moderada	(2,3,4)	(1/4,1/3,1/2)
Intermediária: Moderada – Forte	(3,4,5)	(1/5,1/4,1/3)
Importância forte	(4,5,6)	(1/6,1/5,1/4)
Intermediária: Forte - Muito Forte	(5,6,7)	(1/7,1/6,1/5)
Importância muito forte	(6,7,8)	(1/8,1/7,1/6)
Intermediária: Muito Forte - Extrema	(7,8,9)	(1/9,1/8,1/7)
Importância extrema	(9,9,9)	(1/9,1/9,1/9)

Tabela 17 – *Triangular fuzzy numbers*
Fonte: Chiou et al. (2012)

A partir da associação definida na Tabela 17, essa classificação é convertida em TFNs para cada julgamento, gerando 3 MCPs. Cada MCP em números *fuzzy*, para cada tomador de decisão k e par de critérios i e j , é ilustrada nas eq. (1) e (2).

$$A^k = [\tilde{a}_{i,j}^k] \quad (1)$$

$$A^k = \begin{bmatrix} \tilde{a}_{1,1}^k & \tilde{a}_{1,2}^k & \tilde{a}_{1,3}^k & \tilde{a}_{1,4}^k \\ \tilde{a}_{2,1}^k & \tilde{a}_{2,2}^k & \tilde{a}_{2,3}^k & \tilde{a}_{2,4}^k \\ \tilde{a}_{3,1}^k & \tilde{a}_{3,2}^k & \tilde{a}_{3,3}^k & \tilde{a}_{3,4}^k \\ \tilde{a}_{4,1}^k & \tilde{a}_{4,2}^k & \tilde{a}_{4,3}^k & \tilde{a}_{4,4}^k \end{bmatrix} \quad (2)$$

A próxima etapa consiste em agregar as 3 avaliações em uma única MCP, através do método de média geométrica proposto por Buckley (1985), ilustrado na eq. (3).

$$\tilde{a}_{i,j} = (\tilde{a}_{i,j}^1 \times \tilde{a}_{i,j}^2 \times \tilde{a}_{i,j}^3)^{1/3} \quad (3)$$

III. Cálculo da taxa de consistência (CR)

Nesta etapa é avaliada a consistência dos julgamentos de comparação entre os critérios realizado pelos tomadores de decisão. Para o cálculo da consistência do FAHP foi utilizado o método proposto por Gogus e Boucher (1998), que consiste em calcular dois CRs, sendo um com os valores médios de cada TFN (componente m) e outro com a média geométrica dos valores menores e maiores (componentes l e u).

O primeiro passo do método consiste em formar duas novas MCPs, a partir da matriz agregada formada no método anterior, sendo que uma delas chamaremos de A^m , formada pelos valores médios de da matriz agregada, representada pela eq. (4) e a segunda chamaremos de A^g e será formada pela média geométrica dos valores menores e maiores, conforme eq. (5).

$$A^m = [a_{i,j,m}] \quad (4)$$

$$A^g = [(a_{i,j,u} \times a_{i,j,l})^{1/2}] \quad (5)$$

O processo seguinte segue o método de Saaty para números *crisp* ou nítidos, onde para cada uma das matrizes calculam-se os vetores de peso ou autovetores w^m e w^g , conforme eq. (6) e eq. (7).

$$w^m = [w_i^m] \text{ onde } w_i^m = 1/n \times \sum_{j=1}^n \frac{a_{i,j,m}}{\sum_{i=1}^n a_{i,j,m}} \quad (6)$$

$$w^g = [w_i^g] \text{ onde } w_i^g = 1/n \times \sum_{j=1}^n \frac{(a_{i,j,u} \times a_{i,j,l})^{1/2}}{\sum_{i=1}^n (a_{i,j,u} \times a_{i,j,l})^{1/2}} \quad (7)$$

A partir dos vetores de peso, calcula-se o autovalor médio de cada uma das matrizes, conforme eq. (8) e eq. (9).

$$\lambda_{med}^m = 1/n \times \sum_{i=1}^n \sum_{j=1}^n a_{i,j,m} \times (w_j^m / w_i^m) \quad (8)$$

$$\lambda_{med}^g = 1/n \times \sum_{i=1}^n \sum_{j=1}^n (a_{i,j,u} \times a_{i,j,l})^{1/2} \times (w_j^g / w_i^g) \quad (9)$$

Seguindo o procedimento, o próximo passo é calcular o *consistency indices* (CI) ou índice de consistência, a partir da eq. (10) e eq. (11).

$$CI^m = \frac{(\lambda_{med}^m - n)}{(n-1)} \quad (10)$$

$$CI^g = \frac{(\lambda_{med}^g - n)}{(n-1)} \quad (11)$$

A etapa final para calcular a *consistency ratio* (CR) ou taxa de consistência consiste em dividir o CI pelo *radom index* (RI) ou índice randômico. O RI é um índice definido por Saaty que varia de acordo com o número de critérios. Porém, para o cálculo do CR para números *fuzzy* a partir dos valores médios e da média geométrica dos menores e maiores valores, Gogus e Boucher (1998) desenvolveu uma tabela de RI em função do tamanho da matriz, isto é, do número de critérios utilizados. Na Tabela 18 é ilustrado o RI para cada respectivo tamanho de matriz. Dividindo o CI pelo RI encontramos o valor de CR.

Tamanho do matriz	RI^m	RI^g
1	0	0
2	0	0
3	0,4890	0,1796
4	0,7937	0,2627
5	1,0720	0,3597
6	1,1996	0,3818
7	1,2874	0,4090
8	1,3410	0,4164
9	1,3793	0,4348
10	1,4095	0,4455
11	1,4181	0,4536
12	1,4462	0,4776
13	1,4555	0,4691
14	1,4913	0,4804
15	1,4986	0,4880

Tabela 18 - *Random índices* (RI)

Fonte: Gogus e Boucher, 1998

IV. Cálculo dos pesos *fuzzy*

Os pesos *fuzzy* consistem no peso de cada um dos critérios no formato TFN, ou seja, denotado por (l,m,u). Para o cálculo é utilizado o método da média geométrica de Buckley (1985), representado pelas eq. (12) e (13), onde \tilde{w}_i representa o peso *fuzzy* do critério i .

$$\tilde{r}_i = (\tilde{a}_{i,1} \times \tilde{a}_{i,2} \times \tilde{a}_{i,3} \times \tilde{a}_{i,4})^{1/4} \quad (12)$$

$$\tilde{w}_i = \tilde{r}_i \times (\tilde{r}_1 + \tilde{r}_2 + \tilde{r}_3 + \tilde{r}_4)^{-1} \quad (13)$$

V. Defuzzificação da MCP e cálculo dos pesos *crisp*

A última etapa do método consiste em transformar os números *fuzzy*, em formato TFN, em números *crisp*. Para isso foi utilizado o método *Centre of Area*

(COA). A eq. (14) calcula os pesos *crisp* pelo método COA e a eq. (15) calcula os pesos normalizados de cada critério (KILIC; ZAIM; DELEN, 2014).

$$M_i = \frac{lw_i + mw_i + uw_i}{3} \quad (14)$$

$$\tilde{N}_i = \frac{M_i}{\sum_{i=1}^n M_i} \quad (15)$$

b) Método Vikor

Neste tópico serão abordadas as etapas do método, que utilizando-se dos pesos de cada critério que foram obtidos do método FAHP irá ranquear as alternativas em ordem de importância e criticidade.

I. Determinação das soluções positivas ideais e negativas ideais

Segundo Wang et al. (2019), os critérios podem ser divididos em dois grupos, aqueles que quanto maior seus valores, mais crítica é a alternativa e aqueles em que os menores valores indicam as alternativas mais críticas. Para este estudo de caso, todos os 4 critérios considerados são do tipo “quanto maior mais crítico”. Após essa análise, a primeira etapa do método consiste em definir, para cada um dos 4 critérios, qual a solução considerada positiva ideal (f_i^*) e negativa ideal (f_i^-), que serão, respectivamente, os maiores e menores valores medidos em cada critério i no conjunto de alternativas consideradas. A eq. 16 e a eq. 17 demonstram o cálculo de f_i^* e f_i^- .

$$f_i^* = \max_j f_{i,j} \quad (16)$$

$$f_i^- = \min_j f_{i,j} \quad (17)$$

II. Cálculo dos valores de S e R

A segunda etapa do método trata-se do cálculo dos valores de S_j , denominado de grupo de utilidade máxima, e de R_j que é o peso individual mínimo, representados pela eq. (18) e eq. (19) (OPRICOVIC; TZENG, 2004). O S_j trata-se da uma média da diferença normalizada entre o resultado de cada critério e sua solução positiva ideal, ponderado pelo respectivo peso de cada critério w_i , e quanto menor seu resultado indica que em média o resultado de seus critérios está mais próximo do resultado ideal. Já o R_j é bem semelhante ao anterior, porém ele indica a máxima diferença normalizada entre o resultado de cada critério e sua solução positiva ideal, ponderado pelo respectivo peso de cada critério. Ou seja, quanto menor seu resultado indica que o critério com pior desempenho de uma alternativa está próximo de sua solução positiva ideal.

$$S_j = \frac{\sum_{i=1}^n w_i \times (f_i^* - f_{i,j})}{(f_i^* - f_i^-)} \quad (18)$$

$$R_j = \text{Max}_j \left[\frac{w_i \times (f_i^* - f_{i,j})}{(f_i^* - f_i^-)} \right] \quad (19)$$

III. Cálculo do valor de Q

Segundo Opricovic e Tzeng (2004), a terceira etapa do método trata-se do cálculo de Q_j , representado pela eq. 20. A variável Q_j representa a proximidade média de cada alternativa da solução ideal, a partir de uma taxa ponderada pelo distancia média de cada critério da solução positiva ideal (S) e pela distância do critério da alternativa com pior resultado também de sua solução positiva ideal (R).

$$Q_j = \frac{v \times (S_j - S^*)}{(S^- - S^*)} + \frac{(1-v) \times (R_j - R^*)}{(R^- - R^*)} \quad (20)$$

Onde:

$$S^* = \min_j S_j$$

$$S^- = \max_j S_j$$

$$R^* = \min_j R_j$$

$$R^- = \max_j R_j$$

v é o peso da estratégia de utilidade de grupo máxima, considerado como $v = 0,5$.

IV. Ranking das alternativas de acordo com os valores de S, R e Q

A última etapa consiste no ranking das alternativas, a partir dos valores de S, R e Q que foram calculados nas etapas anteriores, formando 3 listas de classificação (OPRICOVIC; TZENG, 2004). Para a classificação final das alternativas deste estudo de caso foram utilizados os valores de Q. O ranking final das alternativas é gerado em ordem crescente do valor de Q, sendo, portanto, a alternativa mais importante e crítica aquela que tem o menor valor de Q.

APÊNDICE 3 – *Artificial neural networks (ANN) com genetic algorithms (GA)*

Esta dissertação aplica um modelo ANN *feed-forward* conhecido como *multi-layer perception* (MLP), em português, perceptron de múltiplas camadas. Segundo Kourntzes (2013), o MLP trata-se do principal modelo de ANN utilizado para previsão de demanda, justificando sua escolha para este estudo de caso. Além disso, este tipo de rede foi a mais citada no *scoping review* apresentado na subseção 4.2.2.

Com relação ao algoritmo de aprendizagem da rede, o modelo aplicado foi o *backpropagation* (BP). Esse algoritmo trata-se de uma técnica de aprendizado supervisionado que calcula o erro de saída da rede, ou seja, a diferença entre o valor real e o valor encontrado pelo modelo, e este erro é propagado para as camadas anteriores da rede de maneira a recalculá-lo os pesos de cada conexão com o objetivo de reduzir este erro, a partir de uma série de iterações (MAJDI; BEIKI, 2010). A escolha do BP foi motivada por sua ampla utilização em modelos de previsão de demanda, sendo o algoritmo mais citado no *scoping review*. Outra importante configuração da rede trata-se da função de ativação, no qual para este modelo foi utilizada a função sigmoide.

Para a aplicação do modelo, o primeiro passo é a realização do pré-processamento dos dados de treino e validação. Para isso foram utilizados alguns métodos de pré-processamento que tem como intuito reduzir a oscilação dos dados e, desta forma, aprimorar o resultado do modelo. O primeiro método trata-se da remoção de *outliers*, que, segundo Wong e Guo (2010), trata-se de dados que se desviam muito do resto das observações. Para a identificação e tratamento dos *outliers* utilizou-se de um modelo adaptado de Wong e Guo (2010), onde um dado é considerado *outlier* caso satisfaça a condição da eq. (21). Os dados classificados como *outlier* foram substituídos pela média dos dois últimos dados anteriores da série.

$$|s_i - \text{média}(S_i)| > n \times \text{desvio.padrão}(S_i) \quad (21)$$

Onde: s_i = consumo no mês i
 S_i = consumo em todos os meses do período
 $n = 2$

Outro método de pré-processamento trata-se da normalização dos dados. Para isso foi utilizado o parâmetro *normalize* do RapidMiner, que transforma os dados para o período -1 a +1 antes de realizar o aprendizado. Conforme observado no *scoping review*, a normalização dos dados é um método de pré-processamento muito comum em modelos de ANN para previsão de demanda.

Após a aplicação do pré-processamento dos modelos, inicia-se a etapa de processamento de treino e validação da ANN. Segundo Zhang, Patuwo e Hu (1998), a maioria dos autores utiliza como divisão treino/validação o 90%/10%, 80%/20% ou 70%/30%, o que pôde ser confirmado a partir dos resultados do *scoping review*. Para este trabalho a proporção treino e validação utilizada foi de 80%/20%. No processo de treino e validação diferentes configurações de redes são avaliadas de maneira a identificar aquela ideal para cada SKU. A Figura 16

ilustra um exemplo de estrutura de rede neural MLP semelhante a aplicada nesta dissertação.

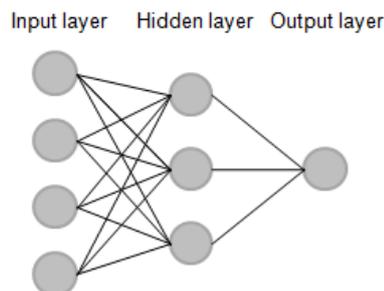


Figura 16– Estrutura MLP
Fonte: O autor

Os nós do *input layer*, ou camada de entrada, trata-se dos dados de entrada do modelo, ou seja, dos valores mensais históricos que são utilizados para prever o período à frente. Para definição dos dados de *input* é realizado um arranjo dos dados chamado de janelamento, com o tamanho da janela sendo quantos dados passados são utilizados para prever o dado a frente. Foram testados, a partir de tentativa e erro, quantidades distintas de nós de entrada que variaram de 6 a 12 nós.

A quantidade de *hidden layers*, em português camadas escondidas, e o número de nós presentes em cada camada são parâmetros que também precisam ser definidos. Para esta dissertação, foram realizados testes com diferentes configurações de camadas escondidas e nós, de maneira a encontrar a estrutura ideal para cada SKU. Os dados testados foram definidos a partir do *scoping review*, sendo que foram testados modelos com 1 e 2 *hidden layers*, dado que uma dessas configurações esteve presente em 95% dos artigos encontrados no *scoping review*. Além disso, foram testados de 1 a 6 nós nas camadas escondidas, situação presente em 61% dos artigos analisados que citaram esse dado. No *output layer* são incluídos a quantidade de nós que representam a saída do modelo. Como o objetivo é prever o período a frente, foi considerado um nó de *output*.

Outros importantes parâmetros a serem avaliados para a definição do modelo ideal de ANN para previsão de demanda de cada SKU são o *training cycles*, o *learning rate* e o *momentum*. O parâmetro *training cycles*, mais conhecido na literatura como *epochs*, traduzido para o português como épocas, trata-se do número de iterações que são realizadas pelo modelo durante seu treinamento para atualização dos seus pesos de maneira a otimizar a função objetivo (PUNIA et al., 2020). O *learning rate* determina a magnitude das mudanças dos pesos da rede durante o treinamento. Já o *momentum* trata-se de uma taxa que faz com que um peso siga uma direção aproximadamente igual ao peso anterior durante o treinamento, com isso reduzindo oscilações (ZHANG; PATUWO; HU, 1998).

Para a definição de quais valores seriam aplicados em cada um destes três parâmetros da rede aplicou-se o modelo de otimização GA, que utiliza-se do princípio de evolução biológica para encontrar soluções ótimas, sendo um importante uso deste método a otimização de parâmetros de ANN, formando, portanto, um modelo GA-ANN que caracteriza o método empregado nesta dissertação. Neste modelo, os parâmetros da ANN são tratados como cromossomos matemáticos e sofrem modificações até que sejam encontrados seus valores ótimos, através de operações de mutação e cruzamento.

A Figura 17 sintetiza o processo de aplicação do GA para otimização dos parâmetros da ANN. Conforme pode ser observado, o primeiro passo do algoritmo

trata-se da criação de uma população inicial de diferentes configurações de redes, sendo que o tamanho dessa população é especificado previamente, onde neste estudo de caso foi especificado uma população de tamanho 100, conforme Baklacioglu, Turan e Aydin (2018) e Majdi e Beiki (2010). A segunda etapa trata-se do cálculo do *fitness function* para cada população que, segundo Majdi e Beiki (2010), trata-se da função objetivo do modelo, que foi definida como o método de medida de performance MAPE. A partir do cálculo da função objetivo, é selecionada a melhor alternativa a partir de um método de seleção previamente definido, que para este trabalho foi selecionado o método *roulette wheel*, do português método da roleta, conforme estudo de Baklacioglu, Turan e Aydin (2018). A etapa seguinte consiste em verificar se o critério de parada do algoritmo foi satisfeito, que foi definido a partir do número máximo de gerações como 100, conforme Baklacioglu, Turan e Aydin (2018). Caso o critério de parada esteja satisfeito, o algoritmo chega ao fim e encontra-se a solução ótima. Caso contrário, passamos para a etapa seguinte, que consiste na mutação das alternativas, no qual o tipo de mutação selecionado foi o *Gaussian* e a realização *crossover* ou cruzamento, no qual a taxa definida foi de 0,9 conforme Baklacioglu, Turan e Aydin (2019). Após isso é gerada nova população, retornando para etapa do cálculo do *fitness function*, seguindo novamente o processo até a satisfação do critério de parada e encontro da melhor solução. A Tabela 19 resume os principais parâmetros utilizados para a aplicação do algoritmo genérico de maneira a otimizar os parâmetros da rede. Já a Tabela 20 ilustra o limite inferior e superior considerando as variáveis otimizadas do modelo, que foram definidos segundo Winiczenko et al. (2018).

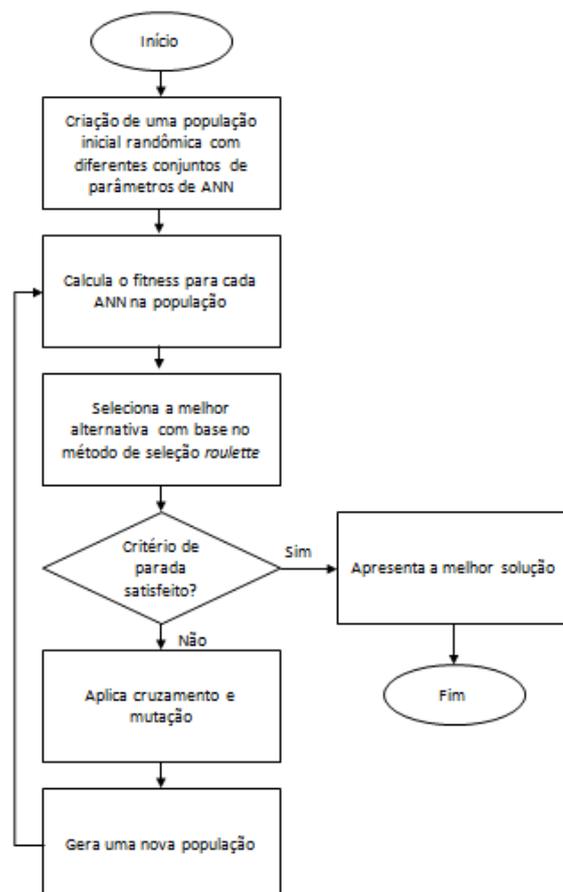


Figura 17 – Processo GA-ANN
 Fonte: Adaptado de Majdi e Beiki, 2010

Parâmetros	Valores
Máximo de gerações	100
Tamanho da população	100
Tipo de mutação	Gaussian
Operador de seleção	Roulette wheel
Taxa de <i>crossover</i>	0,9
<i>Fitness function</i>	MAPE
Variáveis da rede otimizadas	<i>training cycles, learning rate e momentum</i>

Tabela 19 – Parâmetros GA

Fonte: O autor

Variável	Limite inferior	Limite superior
<i>Training cycles</i>	300	5000
<i>Learning rate</i>	0,01	0,4
<i>Momentum</i>	0,1	0,9

Tabela 20 – Limites superior e inferior das variáveis otimizadas

Fonte: O autor

Os principais *outputs* do treino e validação da GA-ANN foram a configuração ideal da rede, a previsão de demanda e as medidas de performance da base de validação, que serão utilizadas para avaliação do desempenho do modelo e análise dos erros envolvidos na previsão. Foram utilizadas duas medidas de performance, que foram o *mean absolute percentage error* (MAPE), do português erro percentual absoluto médio e o *root mean square error* (RMSE), traduzido como raiz quadrada do erro-médio. A escolha destas duas medidas de performance ocorreu devido estarem entre as principais métricas de avaliação de previsões utilizando ANN, sendo que foram as duas que mais foram citadas no *scoping review*. A eq. (22) e a eq (23) demonstram as fórmulas de cálculo do MAPE e do RMSE, respectivamente.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \quad (22)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (23)$$

A próxima etapa consiste testar o modelo otimizado, tendo como *input* uma base de teste que não foi utilizada no processo de aprendizagem de maneira a examinar se esse modelo consegue generalizar o aprendizado para bases nunca vistas. O *output* do teste do modelo consiste na previsão do período considerado e na medida de performance da base de teste, que pode ser comparada com outros modelos de maneira a validar ou não a efetividade do modelo GA-ANN.

APÊNDICE 4 – Avaliação dos critérios em escala linguística

I. Tomador de decisão 1

Critério		Mais importante?	Escala de importância
A	B	A, B ou Igual	
Lead Time de entrega dos fornecedores	Criticidade/impacto da falta	B	Importância muito forte
	Custo total de demanda	B	Importância moderada
	Frequência de Utilização	A	Intermediária: Mesma importância - Moderada
Criticidade/impacto da falta	Custo total de demanda	A	Importância forte
	Frequência de Utilização	A	Importância muito forte
Custo total de demanda	Frequência de Utilização	A	Importância moderada

II. Tomador de decisão 2

Critério		Mais importante?	Escala de importância
A	B	A, B ou Igual	
Lead Time de entrega dos fornecedores	Criticidade/impacto da falta	B	Intermediária: Moderada - Forte
	Custo total de demanda	A	Importância moderada
	Frequência de Utilização	A	Importância moderada
Criticidade/impacto da falta	Custo total de demanda	A	Importância forte
	Frequência de Utilização	A	Importância forte
Custo total de demanda	Frequência de Utilização	B	Importância moderada

III. Tomador de decisão 3

Critério		Mais importante?	Escala de importância
A	B	A, B ou Igual	
Lead Time de entrega dos fornecedores	Criticidade/impacto da falta	Igual	Mesma importância
	Custo total de demanda	A	Importância forte
	Frequencia de Utilização	B	Importância forte
Criticidade/impacto da falta	Custo total de demanda	A	Importância extrema
	Frequencia de Utilização	B	Importância moderada
Custo total de demanda	Frequencia de Utilização	B	Importância extrema

APÊNDICE 5 – MCP com números TFN

I. Tomador de decisão 1

Critério i \ Critério j	<i>Lead Time</i>	Criticidade/ impacto da falta	Custo total de demanda	Frequência de utilização
<i>Lead Time</i>	(1,1,1)	(1/8,1/7,1/6)	(1/4,1/3,1/2)	(1,2,3)
Criticidade/impacto da falta	(6,7,8)	(1,1,1)	(4,5,6)	(6,7,8)
Custo total de demanda	(2,3,4)	(1/6,1/5,1/4)	(1,1,1)	(2,3,4)
Frequência de utilização	(1/3,1/2,1)	(1/8,1/7,1/6)	(1/4,1/3,1/2)	(1,1,1)

II. Tomador de decisão 2

Critério i \ Critério j	<i>Lead Time</i>	Criticidade/ impacto da falta	Custo total de demanda	Frequência de utilização
<i>Lead Time</i>	(1,1,1)	(1/5,1/4,1/3)	(2,3,4)	(2,3,4)
Criticidade/impacto da falta	(3,4,5)	(1,1,1)	(4,5,6)	(4,5,6)
Custo total de demanda	(1/4,1/3,1/2)	(1/6,1/5,1/4)	(1,1,1)	(1/4,1/3,1/2)
Frequência de utilização	(1/4,1/3,1/2)	(1/6,1/5,1/4)	(2,3,4)	(1,1,1)

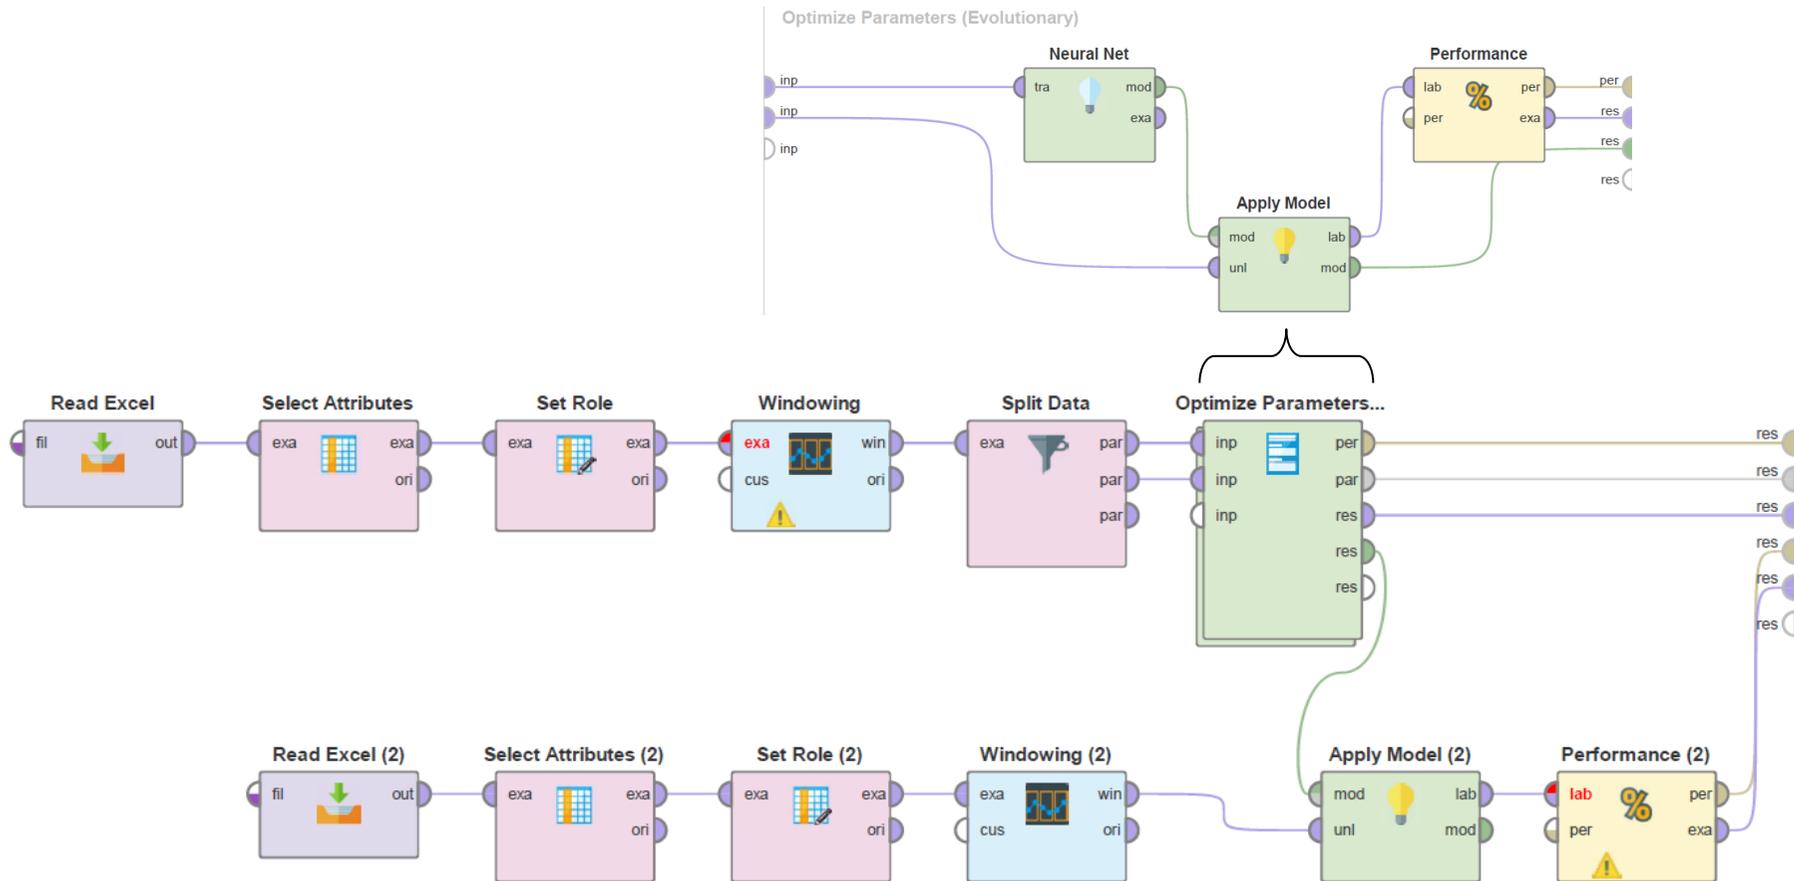
III. Tomador de decisão 3

Critério i \ Critério j	<i>Lead Time</i>	Criticidade/ impacto da falta	Custo total de demanda	Frequência de utilização
<i>Lead Time</i>	(1,1,1)	(1,1,1)	(4,5,6)	(1/6,1/5,1/4)
Criticidade/impacto da falta	(1,1,1)	(1,1,1)	(9,9,9)	(1/4,1/3,1/2)
Custo total de demanda	(1/6,1/5,1/4)	(1/9,1/9,1/9)	(1,1,1)	(1/9,1/9,1/9)
Frequência de utilização	(4,5,6)	(2,3,4)	(9,9,9)	(1,1,1)

IV. Matriz agregada

Critério i \ Critério j	<i>Lead Time</i>	Criticidade/ impacto da falta	Custo total de demanda	Frequência de utilização
<i>Lead Time</i>	(1,1,1)	(0.3, 0.3, 0.4)	(1.3, 1.7,	(0.7, 1.1,
Criticidade/impacto da falta	(2.6, 3, 3.4)	(1,1,1)	(5.2, 6.1,	(1.8, 2.3,
Custo total de demanda	(0.4, 0.6,	(0.1, 0.2, 0.2)	(1,1,1)	(0.4, 0.5,
Frequência de utilização	(0.7, 0.9,	(0.3, 0.4, 0.6)	(1.7, 2.1,	(1,1,1)

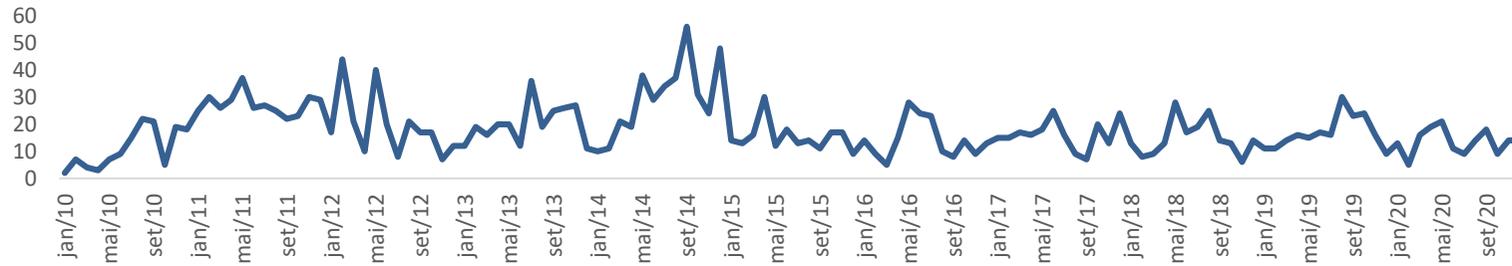
APÊNDICE 6 – Framework Rapidminer: GA-ANN para previsão de demanda



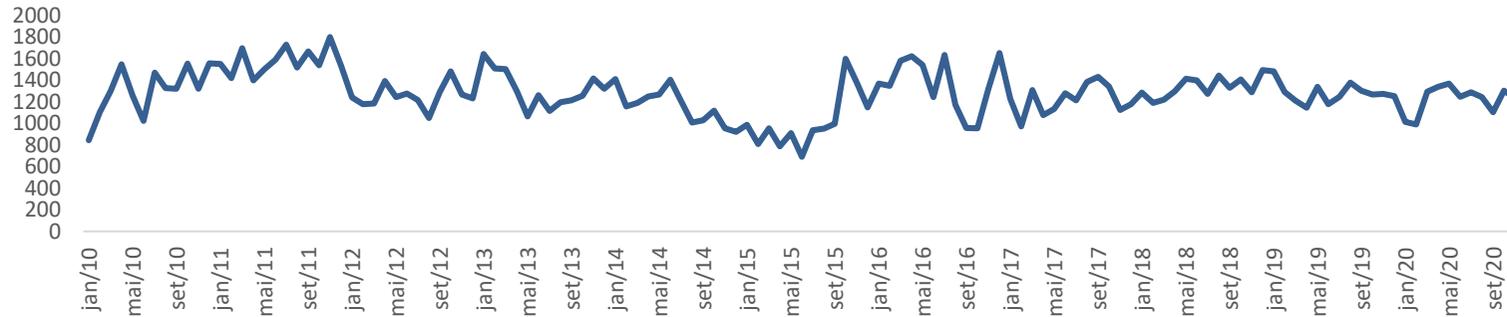
APÊNDICE 7 – Consumo mensal SKUs selecionados

PUC-Rio - Certificação Digital Nº 1913215/CA

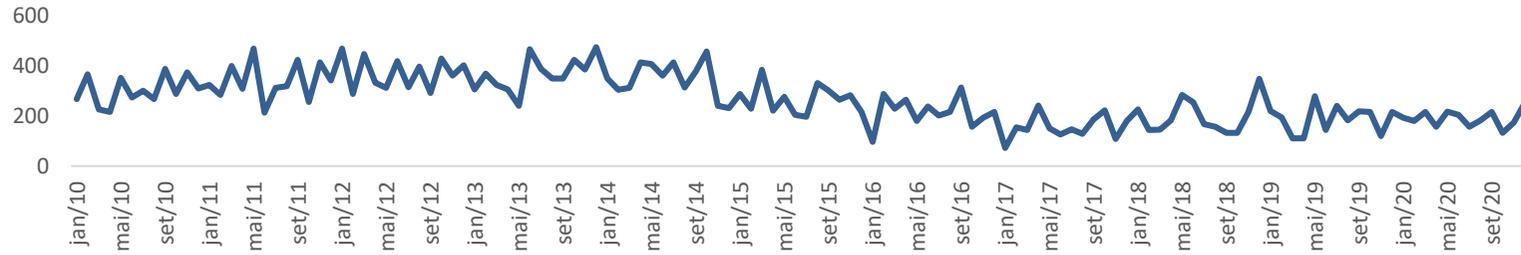
I.SKU N574260284 - Ranking FAHP Vikor: 23º



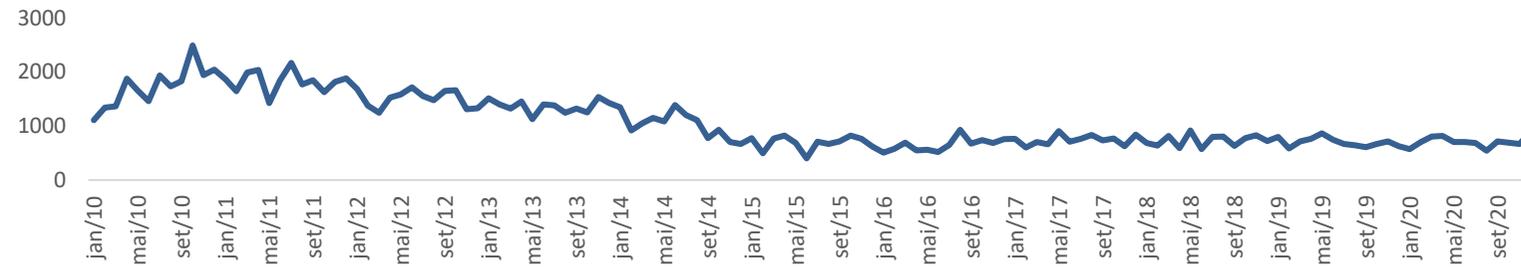
II.SKU N174020005 - Ranking FAHP Vikor: 29º



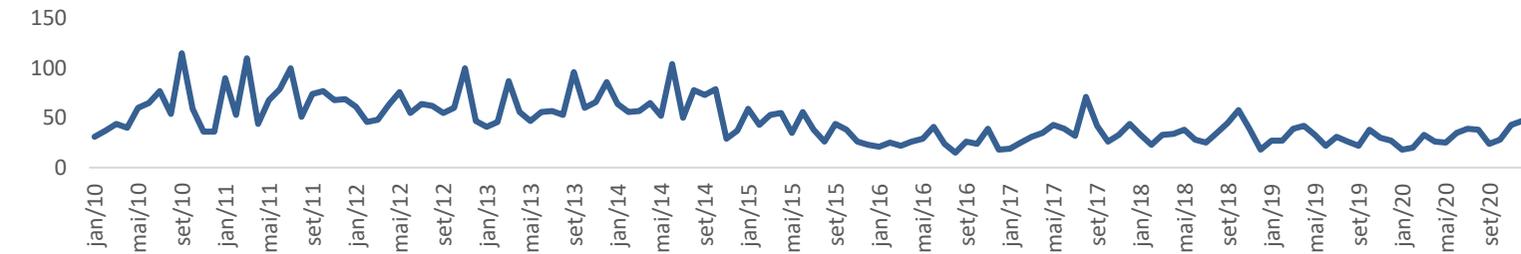
III. SKU N573045004 - Ranking FAHP Vikor: 43°



IV. SKU N512027068 - Ranking FAHP Vikor: 46°



V. SKU N575440022 - Ranking FAHP Vikor: 48°



APÊNDICE 8 – Dashboard gestão de estoques

