



Jaqueline Alves do Nascimento

**Desenvolvimento de metodologia de apoio à decisão
para manutenção inteligente combinando abordagens
multicritério e *machine learning*: Estudo de Caso em
empresa de manufatura**

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. Rodrigo Goyannes Gusmão Caiado
Coorientador: Prof. Luiz Felipe Roris Rodriguez Scavarda do Carmo

Rio de Janeiro,
fevereiro de 2024



Jaqueline Alves do Nascimento

**Desenvolvimento de metodologia de apoio à decisão para
manutenção inteligente combinando abordagens
multicritério e *machine learning*: Estudo de Caso em
empresa de manufatura**

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. Rodrigo Goyannes Gusmão Caiado

Orientador

Departamento de Engenharia Industrial – PUC-RIO

Prof. Luiz Felipe Roris Rodriguez Scavarda do Carmo

Coorientador

Departamento de Engenharia Industrial – PUC-RIO

Gilson Brito Alves Lima

UFF

Thais Spiegel

UERJ

Renan Silva Santos

PUC-Rio

Rio de Janeiro, 22 fevereiro de 2024

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

Jaqueline Alves do Nascimento

Graduada em Tecnologia em Processamento de Dados pela Faculdades Integradas Simonsen (1999). cursou MBA em Engenharia de manutenção na UFRJ (2012). Pós-graduada em Ciências de Dados pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) (2021). Concursada como Analista de Gestão – TI na Casa da Moeda do Brasil.

Ficha Catalográfica

Nascimento, Jaqueline Alves do

Desenvolvimento de metodologia de apoio à decisão para manutenção inteligente combinando abordagens multicritério e machine learning : estudo de caso em empresa de manufatura / Jaqueline Alves do Nascimento ; orientador: Rodrigo Goyannes Gusmão Caiado ; coorientador: Luiz Felipe Roris Rodriguez Scavarda do Carmo. – 2024.

120 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2024.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. MCDM. 3. Manutenção 4.0. 4. Machine learning. 5. Estudo de caso. I. Caiado, Rodrigo Goyannes Gusmão. II. Carmo, Luiz Felipe Roris Rodriguez Scavarda do. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD:658.5

Dedico este trabalho as
minhas filhas Sabrina e Milena.

Agradecimentos

É com imensa satisfação e profunda gratidão que me dirijo a todos neste momento tão significativo. A conclusão desta jornada de pesquisa e a defesa desta dissertação de mestrado representa um capítulo fundamental em minha vida pessoal, profissional e a retomada da minha vida como professora.

Primeiramente, gostaria de expressar minha sincera gratidão aos membros da banca examinadora, além da PUC-Rio pela bolsa de isenção de mensalidades do mestrado.

Ao meu orientador Rodrigo Caiado, agradeço profundamente pela orientação, paciência incansável, apoio constante ao longo de todo o processo de pesquisa e pelo repasse dos conhecimentos de dezenas de métodos decisórios.

Agradeço em especial ao coorientador Felipe Scavarda, por sua paciência e afincamento em fornecer diversas críticas construtivas e durante cada período do mestrado. Assim como ao professor Renan Silva pelas aulas ministradas na engenharia civil e pela participação nas bancas de qualificação e de defesa do mestrado.

À Deus, minha família e amigos próximos, expresso a gratidão pelo apoio incondicional, compreensão e encorajamento ao longo desta jornada. Sem a paciência de meu marido, das minhas filhas, além dos cafezinhos tragos pela minha mãe, isso não seria possível. Este sucesso é de todos nós.

Aos demais professores do DEI que me proporcionaram diversos ensinamentos. Às colegas de mestrado Esther, Bruna Santiago e Bruna Kaiser. Nossa amizade vivenciada durante esta jornada será lembrada com carinho.

Agradeço ao Sergio Bruno, Edson Frederichs, Sérgio Perini e Leonardo Abdias por prontamente aceitarem meu pedido de ausências, nos dias necessários para o cumprimento dessa jornada. E, por último, expresso minha sincera gratidão a todos os mantenedores que colaboraram na pesquisa, bem como aos demais membros da manutenção e produção, aos quais dedico meu profundo apreço.

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

Resumo

Nascimento, Jaqueline Alves; Caiado, Rodrigo Goyannes Gusmão (orientador). Scavarda, Luiz Felipe Roris Rodriguez do Carmo (coorientador). **Desenvolvimento de metodologia de apoio à decisão para manutenção inteligente combinando abordagens multicritério e machine learning: estudo de caso em empresa de manufatura**. Rio de Janeiro, 2024. 120p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

A Indústria 4.0 (I4.0) e a transformação digital estão revolucionando a manutenção nas indústrias, impulsionando-a rumo a uma abordagem mais inteligente e proativa, conhecida como manutenção inteligente (smart maintenance – SM). Recentemente vive-se a transição para a Manutenção 4.0, em que decisões baseadas em dados e análises avançadas trazidas com a SM permitem aumentar a eficiência, reduzir os custos operacionais e têm um grande impacto no desempenho operacional. Com a crescente digitalização dos processos e a disponibilidade de novas tecnologias, as decisões estão se tornando mais inteligentes, o que requer ter um processo de tomada de decisão estruturado. No entanto, tomar decisões gerenciais pode ser complexo devido a múltiplos critérios e pontos de vista envolvidos. Por exemplo, podem existir trade-offs e prioridades competitivas diferentes entre equipes funcionais como de manutenção, de produção e financeira. Nessa perspectiva, é crucial ter uma metodologia que combine esses aspectos conflitantes e, na era da Manutenção 4.0, a consideração de múltiplos critérios e pontos de vista, justifica a necessidade de um framework de apoio à decisão que combine técnicas de apoio multicritério à decisão (multi-criteria decision making - MCDM) e Machine Learning (ML). A partir da revisão de escopo observou-se a ausência de metodologias (e frameworks) de apoio à decisão combinando essas abordagens em estudos empíricos e em países emergentes. Diante disso, a presente pesquisa propõe aplicar um framework de apoio à decisão para SM em empresa de manufatura brasileira. Como método empírico foi realizado um estudo de caso, utilizando dados reais de manutenção, observação participante e entrevistas, além de análise documental. Uma abordagem multicritério híbrida é proposta por meio dos métodos AHP, MOORA, MULTIMORA e de Borda com dados qualitativos e quantitativos, para resolver um problema de ranking de impressoras para fazer parte do início das manutenções preditivas. A implementação computacional compõe a metodologia ocorreu em Python. Ao final foi possível observar que a combinação de MCDM e ML pode ser uma abordagem eficaz para aprimorar a tomada de decisão na manutenção, considerando a complexidade dos dados envolvidos.

Palavras-chave

MCDM, Manutenção 4.0; Machine Learning; Estudo de caso.

Abstract

Nascimento, Jaqueline Alves; Caiado, Rodrigo Goyannes Gusmão (advisor); Scavarda, Luiz Felipe Roris Rodriguez do Carmo (coadvisor). **Development of a decision support methodology for intelligent maintenance combining multicriteria and machine learning approaches: Case study in a manufacturing company.** Rio de Janeiro, 2024. 120p. Dissertação de Mestrado – Departamento de Engenharia Industrial Católica do Rio de Janeiro.

Industry 4.0 (I4.0) and digital transformation are revolutionizing maintenance in industries, pushing it towards a more intelligent and proactive approach, known as smart maintenance (SM). Recently, the transition to Maintenance 4.0 has been experienced, where maintenance decisions based on data and advanced analytics brought about by SM make it possible to increase efficiency, reduce operating costs and have a major impact on operational performance. With the increasing digitalization of processes and the availability of new technologies, decisions are becoming smarter, which requires having a structured, data-driven decision-making process for efficient decisions. However, making management decisions can be complex due to the multiple criteria and points of view involved. For example, there can be trade-offs and different competing priorities between functional areas such as maintenance, production and finance. From this perspective, it is crucial to have a methodology that combines these conflicting aspects, and in the Maintenance 4.0 era, the consideration of multiple criteria and points of view justifies the need for a decision support framework that combines multi-criteria decision making (MCDM) and Machine Learning (ML) techniques. A scoping review showed that there is a lack of decision support methodologies (and frameworks) combining these approaches in empirical studies and in emerging countries. In view of this, this research aims to propose and apply a decision support framework for MS in a Brazilian manufacturing company. A case study is used as the empirical method, using real maintenance data, participant observation and interviews, as well as document analysis. A hybrid multi-criteria approach is proposed using AHP, MOORA, MULTIMORA and Borda methods with qualitative and quantitative data, to solve a problem of ranking printers to be part of the start of predictive maintenance. The computational implementation of the approaches that make up the methodology took place in Python. At the end of the research, it was possible to observe that the combination of MCDM and ML can be an effective approach to improve decision-making in asset maintenance, considering multiple criteria and the complexity of the data involved.

Keywords

MCDM, Maintenance 4.0; Machine Learning; case study.

Sumário

1	Introdução	16
1.1	Contextualização do tema	16
1.2	Justificativa e motivação	17
1.3	Lacunas e questões de pesquisa	18
1.4	Objetivo geral e específicos	20
1.5	Originalidade e contribuições da pesquisa	20
1.6	Metodologia	21
1.7	Estrutura da Dissertação	22
2	Fundamentação teórica	24
2.1	Gestão de ativos, gerenciamento e pilares da manutenção	24
2.2	Métodos de MCDM	26
2.2.1.	Compensatórios e não compensatórios	27
2.2.2.	Alocação de pesos com decisão em grupo	28
2.2.3.	Ranking com agregação aditiva	30
2.2.4.	Método ordinal	32
2.3	Técnicas de ML para gestão da manutenção	33
2.4.	Modelos de previsão - clássicos e técnicas de ML	35
3	Metodologia de pesquisa	38
3.1	Revisão de escopo	38
3.2	Estudo de caso	43
3.2.1.	Grupo focais	46
3.2.2.	Entrevistas	48
3.2.3.	Análise de dados, com abordagens quantitativas e qualitativas entre MCDM e ML	49
3.2.4.	Aplicação dos métodos no Framework	50
4	Resultados Teóricos	52
4.1	Análise bibliométrica	52
4.2	Análise descritiva	57
4.3	Análise de conteúdo	58

5 Resultados empíricos	61
5.1 Estudo de caso em empresa de manufatura	61
5.2 Proposição e aplicação do Framework de apoio a decisão	62
5.2.1. Processo decisório	64
5.3 Métodos de previsão	69
5.4 Aplicação do método de alocação de pesos	75
5.5 Aplicação dos métodos com agregação aditiva	77
5.6 Aplicação do Método ordinal	80
5.7 Análise de sensibilidade dos resultados	81
5.8 Avaliação do framework por especialistas	84
6 Discussões	85
7 Conclusões e sugestões para trabalhos futuros	90
Referências Bibliográficas	93
Apêndice 1- Protocolo de estudo de caso	106
Apêndice 2 - Média geométrica do AHP – AIP	107
Apêndice 3 - Resultados das avaliações pelo tomador de decisão dos decisores	108
Apêndice 4 – Diagrama com o produto da pesquisa de dissertação	120

Lista de Figuras

Figura 1 – Arquitetura MLP com duas camadas	35
Figura 2 – PRISMA fluxograma	42
Figura 3 – Estudo de caso	43
Figura 4 – Número de documentos publicados ao longo dos anos	52
Figura 5 – Documentos por tipo de publicação	53
Figura 6 – Publicações associadas aos documentos da amostra de estudo	53
Figura 7 – Trabalhos em destaque com maior quantidade de publicações	54
Figura 8 – Principais termos pesquisados - escalada por ano	55
Figura 9 – Rede de co-ocorrência de palavras-chave ao longo dos anos	55
Figura 10 – Sobreposição de palavras-chave via VOSviewer	56
Figura 11 – Framework proposto	63
Figura 12 – Técnicas empregadas na dissertação	64
Figura 13 – Estrutura Hierárquica do Problema de Decisão	67
Figura 14 – Gráficos RNA	71
Figura 15 – Análise e visualização do banco de dados	72
Figura 16 – Análise e visualização dos dados históricos ARIMA	74
Figura 17 – Guias de organização das planilhas	75
Figura 18 – Protocolo do AHP-AIP	76
Figura 19 – Fluxo do AHP-AIP no framework	77
Figura 20 – Ranking final do AHP-AIP	77
Figura 21 – Fluxo do AHP-MOORA no framework	78
Figura 22 – Soma e a raiz da soma para MOORA	78
Figura 23 – Ranking MOORA	79
Figura 24 – Fluxo do MOORA com a matriz de Tchebycheff	79
Figura 25 – Valores mínimos e máximos MOORA	79
Figura 26 – Ranking MOORA Método Tchebycheff.	80
Figura 27 – Ranking MULTIMOORA	80

Figura 28 – Ranking final Framework	81
Figura 29 – Modelo adotado para análise de sensibilidade	82
Figura 30 – Análise de sensibilidade Cenário 1	82
Figura 31 – Análise de sensibilidade Cenário 2	82
Figura 32 – Análise de sensibilidade Cenário 3	83
Figura 33 – Gráfico do ranqueamento final impressoras para preditiva	86
Figura 34 – Resultados dos métodos	87
Figura 35 – Árvore de decisão da pesquisa	120

Lista de Tabelas

Tabela 1 – Índice Randômico	30
Tabela 2 – Descrição da estratégia PICO	39
Tabela 3 – Revisão de escopo	40
Tabela 4 – Pesquisa na base Scopus	41
Tabela 5 – Pesquisa na base Web of Science	41
Tabela 6 – Grupos focais	47
Tabela 7 – Entrevistas	49
Tabela 8 – Métodos descritos nos documentos analisados	58
Tabela 9 – Critérios iniciais para entrada dos dados	65
Tabela 10 – Escala de comparação par a par para o método AHP	67
Tabela 11 – Teste inicial de estacionariedade	72
Tabela 12 – Valores finais de estacionariedade	73
Tabela 13 – Resultado dos parâmetros de avaliação ARIMA	73
Tabela 14 – Resultado por impressora	75
Tabela 15 – Descrição das tabelas de avaliação no Excel	75
Tabela 16 – Protocolo de estudo de caso	106
Tabela 17 – Média geométrica	107
Tabela 18 – Comparações dos pesos dos critérios - gerente	108
Tabela 19 – Comparações de alternativa para o critério “falha” gerente	108
Tabela 20 – Comparações de alternativa para o critério “segurança” Gerente	109
Tabela 21 – Comparações de alternativa para o critério “OEE” gerente	109
Tabela 22 – Comparações de alternativa para o critério “Custo” gerente	109
Tabela 23 – Comparações de alternativa para o critério “preventiva” gerente	110
Tabela 24 – Comparações de alternativa para o critério “treinamento”gerente	110
Tabela 25 – Comparações dos pesos dos critérios - supervisor	111
Tabela 26– Comparações de alternativa x critério “falha” supervisor	111
Tabela 27– Comparações de alternativa x critério “segurança” supervisor	111
Tabela 28 – Comparações de alternativa x critério “OEE” supervisor	112
Tabela 29 – Comparações de alternativa x critério “Custo” supervisor	112
Tabela 30 – Comparações de alternativa x critério “preventiva” supervisor	112
Tabela 31 – Comparações de alternativa x critério “treinamento” supervisor	112
Tabela 32 – Comparações de alternativa x critério “falha” técnico 1	114
Tabela 33 – Comparações de alternativa x critério “falha” técnico 1	114

Tabela 34 – Comparações de alternativa x critério “segurança” técnico 1	114
Tabela 35 – Comparações de alternativa x critério “OEE” técnico 1	115
Tabela 36 – Comparações de alternativa x critério “Custo” técnico 1	115
Tabela 37 – Comparações de alternativa x critério “preventiva” técnico 1	115
Tabela 38 – Comparações de alternativa x critério “treinamento” técnico 1	116
Tabela 39 – Comparações dos pesos dos critérios - técnico 02	117
Tabela 40 – Comparações de alternativa x critério “falha” técnico 2	117
Tabela 41 – Comparações de alternativa x critério “segurança” técnico 2	117
Tabela 42 – Comparações de alternativa x critério “OEE” técnico 2	118
Tabela 43 – Comparações de alternativa x critério “Custo” técnico 2	118
Tabela 44 – Comparações de alternativa x critério “preventiva” técnico 2	118
Tabela 45 – Comparações de alternativa x critério “treinamento” técnico 2	119

Lista de abreviaturas e siglas

ACF – Teste da Função de Auto-Correlação

AHP – *Analytic Hierarchy Process*, em português, Processo de Hierarquia Analítica

AIC – *Akaike Information Criterion*, em português, Critério de Informação de Akaike

AIP – *Aggregating Individual Priorities*, em português, Agregando Prioridades Individuais

AML – *Azure Machine Learning*, em português, em português, Aprendizado de Máquina Azure

ANP – *Analytic Network Process*, em português, Processo de Rede Analítica

ARIMA – *Autoregressive Integrated Moving Average*, em português, Modelo Auto-regressivo Integrado de Médias Móveis

BDT – *Boolean Decision Tree*, em português, Árvore de Decisão Booleana

BIC – *Bayesian Information Criterion*, em português Critério de Informação Bayesiano

BORDA – *Borda Count*, em português, Método de Borda

COPRAS – *Complex Proportional Assessment*, em português, Avaliação Proporcional Complexa

DEMATEL – *Decision-Making Trial and Evaluation Laboratory*, em português, Laboratório de Ensaio e Avaliação Para Tomada de Decisões

ELECTRE – *Elimination and Choice Expressing Reality*, em português, Eliminação e Escolha Expressando a Realidade

EVAMIX – *Evaluation Mixed Model*, em português, Modelo Misto de Avaliação I4.0 – Indústria 4.0

IA – Inteligência Artificial

IC – Índice de Consistência

ISO 45001 – Norma de sistemas de gestão de saúde e segurança ocupacional

ISO 55000 – Norma de requisitos para a gestão de ativos

MAPE – *Mean Absolute Percentage Error*, em português, Erro Percentual Médio Absoluto

MAE – *Mean Absolute Error*, em português, Erro Médio Absoluto

MCDM – *Multi-Criteria Decision Making*, em português, Tomada de Decisão Multicritério

ML – *Machine Learning*, em português, aprendizado de máquina

MLP – *Multilayer Perceptron*, em português, Perceptron Multicamadas

MOORA – *Multi-Objective Optimization Ratio Analysis*, em português, Análise da Taxa de Otimização Multiobjetivo

MULTIMOORA – *Multi-Objective Optimization on the basis of Ratio Analysis Multiplicative Form*, em português, Otimização Multi-Objetivo com base no Formulário Multiplicativo de Análise de Razão

MSE – *Mean Squared Error*, em português, Erro Quadrático Médio

NPCM - Núcleo de Programação e Controle da Manutenção

OEE – *Overall Equipment Effectiveness*, em português, Eficácia Geral do Equipamento

PRISMA – *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*, em português, Principais Itens para Relatar Revisões Sistemáticas e Meta-Análises

PROMETHEE – *Preference Ranking Organization Method for Enrichment Evaluation*, em português, Método de Organização de Classificação de Preferência para Avaliação de Enriquecimento

RMSE – *Root Mean Squared Error*, em português, Raiz Quadrática Média dos Erros

RNA – Redes Neurais Artificiais

SM – *Smart Maintenance*, em português, Manutenção Inteligente

SVM – *Support Vector Machine*, em português, Máquina de Vetor de Suporte

SMART – *Simple Multi-Attribute Rating Technique*, em português, Técnica simples de Classificação Multiatributos

TOPSIS– *Technique for Order of Preference by Similarity to Ideal Solution*, em português, Técnica para Ordem de Preferência por Similaridade com a Solução Ideal

VIKOR – *VlseKriterijusko Kompromisno*, em português, Classificação de Compromisso

1

Introdução

Neste capítulo aborda-se inicialmente a contextualização do tema da dissertação. Em seguida, apresenta-se a justificativa que motivou a pesquisa, apresentam-se lacunas de pesquisa, objetivos gerais e específicos, suas contribuições, originalidade e metodologia adotada, e, finalmente, a estrutura organizacional da dissertação.

1.1 Contextualização do tema

Uma gestão adequada e sustentável dos processos de manutenção pode reduzir e controlar impactos de custos de produção, desempenho dos ativos, disponibilidade dos equipamentos e a qualidade do produto (Franciosi *et al.*, 2020). Sendo assim, as empresas devem otimizar a função de manutenção para atingir altos níveis de disponibilidade e confiabilidade com custo reduzidos, combinando estratégias diversas (Naranjo *et al.*, 2022).

Em virtude disso os modelos de manutenção são amplamente aplicados nas indústrias para promover uma melhor e mais barata conservação de ativos, confiabilidade, qualidade e segurança no processo operacional (De Jesus Santos *et al.*, 2022). Neste sentido, espera-se que a área de manutenção seja vista como uma função chave na manufatura, e constitua uma área central de investigação, para melhor utilização de ativos e recursos, conservação e extensão da vida útil de um equipamento (Holgado *et al.*, 2020).

Igualmente, na era da I4.0, a Manutenção 4.0, impulsionada por tecnologias digitais, oferece oportunidades significativas para estratégias de manutenção eficazes. Jasiulewicz-Kaczmarek e Gola (2019) destacam que ela maximiza a vida útil dos equipamentos, evita paradas não planejadas, aumenta a segurança e economiza custos. Bousdekis *et al.* (2019) sugerem que as tecnologias da Manutenção 4.0 aprimoram a tomada de decisão na manutenção, porém mais pesquisas são necessárias (Hlihel *et al.*, 2022).

Dentro do contexto da Manutenção 4.0 surge a Manutenção Inteligente (Smart Maintenance – SM), definida por Bokrantz *et al.* (2020a) como um projeto para

gerenciar a manutenção em ambientes digitais. Embora semelhantes, Manutenção Inteligente combina IoT, aprendizado de máquina e análise de dados para otimizar a manutenção, enquanto a manutenção 4.0 busca uma gestão mais inteligente e eficiente, transitando de práticas tradicionais para métodos baseados em dados (De Faria e Quelhas, 2021).

Logo, a dissertação foi motivada pela crescente importância da Manutenção 4.0 e da necessidade de tomar decisões inteligentes e baseadas em dados, visando aumentar a eficiência e reduzir custos operacionais. No entanto, a complexidade das decisões gerenciais de ativos é ampliada pela presença de múltiplos critérios e perspectivas divergentes entre equipes funcionais, como as de manutenção, produção e financeira. Assim, foi pesquisado se a combinação de apoio multicritério à decisão (em inglês *multi-criteria decision making* – MCDM) e técnicas de *Machine Learning* – ML pode ser uma abordagem eficaz para aprimorar a tomada de decisão na manutenção de ativos, considerando a complexidade dos dados e a diversidade de critérios e alternativas.

1.2 Justificativa e motivação

No contexto dos métodos de apoio a decisão, a utilização de métodos multicritério, apoiados por ferramentas informatizadas, pode aprimorar os processos, proporcionando resultados prospectivos (Ondrus *et al.*, 2015). No caso de problemas de decisão mais complexos, que envolvam altos valores materiais, as empresas estão diante de um desafio estratégico, onde a identificação da alternativa mais conveniente pode ser dificultada (Dodun *et al.*, 2021). Deste modo, a fim de tomar uma decisão, é essencial compreender o problema em questão, bem como a necessidade e o objetivo da decisão, os critérios e subcritérios envolvidos, os grupos afetados e as partes interessadas e ainda considerar as alternativas de ação que devem ser tomadas (Saaty, 2008).

Dentre os principais estudos que utilizam o MCDM, pela perspectiva da digitalização da manutenção e operações, podem-se citar: Tohanean *et al.*, (2018) que afirmam que a digitalização melhora o desempenho organizacional; Pech e Vrchota (2022) ao proporem um modelo conceitual para alavancar a I4.0 e a digitalização para apoiar a personalização do produto. Ademais, Machado *et al.* (2019) avaliaram a prontidão digital das empresas e identificaram desafios e facilitadores para a digitalização. De Sousa Pereira e Moraes (2020) estabeleceram prioridades de gestão usando MCDM para auxiliar na tomada de decisões de manutenção em sistema de águas. Entretanto, as tarefas de

personalização, sistemas de água e digitalização, são complexas devido à presença de múltiplos fatores interdependentes e incertezas associadas aos dados e às condições dos equipamentos (De Sousa Pereira e Morais, 2020).

No que diz respeito à manutenção industrial e aos Sistemas de Gerenciamento de Ativos, além de métodos de MCDM que podem ser vinculados ao Sistema Informatizado para fornecer uma capacidade de suporte à decisão, as técnicas de ML também têm sido utilizadas em diferentes contextos, para previsão da condição do componente e no planejamento de manutenção (Gorski *et al.*, 2022). Entretanto, o surgimento de tecnologias de manufatura inteligentes nas últimas décadas criou desafios sem precedentes nos sistemas de manutenção (Errandonea, *et al.*, 2020).

Entre os principais desafios dos sistemas inteligentes ligados à manufatura têm-se: problemas de segurança na fabricação, integração de sistemas, falta de retorno do investimento em novas tecnologias e questões financeiras (Phuyal, Bista e Bista, 2020). Logo, apesar dos avanços nas tecnologias de manutenção inteligente, a aplicação prática dessas abordagens em empresas de manufatura enfrenta desafios significativos como privacidade e segurança de dados, custos iniciais, complexidade técnica e integração de sistemas.

Consequentemente, segundo Sánchez (2011), há uma necessidade de desenvolver uma metodologia específica que integre abordagens multicritério e de previsão de cenários futuros, a fim de fornecer suporte à tomada de decisão de manutenção inteligente em um contexto industrial real. Assim, reforçando a alegação, Arantes *et al.* (2021) salientou a importância de as empresas buscarem inovação e alcançarem resultados financeiros sustentáveis. Isso indica a imperatividade de adotar metodologias que integrem abordagens multicritério e de previsão no âmbito empresarial.

1.3 Lacunas e questões de pesquisa

Ao longo de suas jornadas profissionais, os trabalhadores investem uma parcela significativa de tempo aprimorando suas habilidades decisórias, porém, avaliar a eficácia de uma determinada decisão, no entanto, é bastante complicado, por envolver vários fatores, como assimilação de dados, comunicação, colaboração e acompanhamento (Drummond, 1996). Desse ponto de vista, o ML pode ser usado para inferir dicas que podem ajudar os trabalhadores a aprenderem a tomar melhores decisões (Bastani *et al.*, 2021). E, embora na academia alguns estudos aplicam os conceitos da SM, como Bokrantz *et al.*

(2020a), ainda há escassez de frameworks para a gestão da manutenção, combinando processamento de dados, ML, diagnóstico de falhas, prognóstico e raciocínio de decisão (Cachada *et al.*, 2018).

Além disso, a Manutenção 4.0, considerada um subconjunto da Indústria 4.0, apresenta-se como um sistema inteligente de autoaprendizagem que prevê falhas, faz diagnósticos e estabelece ações de manutenção (Jasiulewicz-Kaczmarek e Gola, 2019; Martinetti *et al.*, 2020). Nesse sentido, nesta nova era da manutenção, a integração de métodos de MCDM e de técnicas de ML tem ganhado destaque na literatura como Khanorkar e Kane (2023) e Aissani, Mechrouf e Filali (2021). Khanorkar e Kane (2023) usaram técnicas de tomada de decisão multicritério e técnicas de aprendizado de máquina para classificar inventários. Já Aissani *et al.* (2021), efetuaram experimentos com previsão empregando Redes Neurais Artificiais (RNAs) e Máquina de Vetor de Suporte (em inglês, *Support Vector Machine* - SVM) para aprimorar processos de decisórios para a manutenção de ativos.

Khanorkar e Kane (2023) relataram que o ML tem a vantagem de poder lidar com grandes volumes de dados de forma eficiente e serem combinados com abordagens de MCDM para problemas de classificação. Aissani *et al.* (2021) discutiram a necessidade de implementar a manutenção 4.0 em sistemas complexos, construindo sistemas confiáveis. Entretanto, ainda há pouca literatura com foco na proposição de ferramentas de apoio à decisão de manutenção para manufatura digitalizada (Gopalakrishnan *et al.*, 2022).

Em vista disso, a fim de guiar a dissertação e fornecer evidências importantes para explorar novos fenômenos, a proposta apresenta a investigação de duas questões de pesquisa:

QP1. No contexto da Manutenção 4.0, como a literatura explora a combinação entre MCDM e ML para apoiar a tomada de decisão para manutenção de ativos?

QP2. Como as abordagens de MCDM e de ML podem ser combinadas e aplicadas para o desenvolvimento de um framework de apoio a decisão para SM na manufatura?

A QP1 é necessária para permitir que através da revisão de literatura, sejam identificados os principais desafios, lacunas e oportunidades relacionados ao tema de manutenção inteligente na indústria de manufatura. Essa identificação permeará o desenvolvimento do capítulo de resultados teóricos e a implantação do framework registrado no capítulo de resultados empíricos.

1.4 Objetivo geral e específicos

O objetivo geral desta dissertação é propor e aplicar um framework de apoio à decisão para SM em uma empresa de manufatura brasileira. Para alcançar esse objetivo foram definidos os seguintes objetivos específicos:

- 1) Identificar na literatura as combinações de abordagens MCDM e ML para apoiar a tomada de decisão para manutenção de ativos;
- 2) Construir um framework para SM, combinando MCDM e ML.
- 3) Aplicar o framework em uma empresa de manufatura brasileira, por meio de um estudo de caso.

O primeiro objetivo envolverá uma revisão de escopo para identificar as principais abordagens de MCDM e ML que podem ser aplicados para manutenção dentro da I4.0. Em seguida, a proposta de um Framework Gerencial para Manutenção Inteligente é delineada com o intuito de aprimorar os processos de manufatura, promovendo seleção de impressoras industriais, incluindo a coleta de dados, aplicação de algoritmos e de modelos MCDM. A implementação do framework ocorrerá em fases distintas. Inicialmente, será desenvolvida a estrutura do modelo, integrando cuidadosamente a definição dos modelos. Em seguida, o framework será aplicado com os métodos escolhidos, passará por ajustes, testes controlados. Posteriormente na fase de resultados passará por avaliação e revisão por especialistas. Será aplicado em uma fase piloto na empresa de manufatura, permitindo uma implementação gradual, avaliação contínua e ajustes conforme necessário. O processo culminará no estudo de caso.

Os objetivos envolverão um estudo de caso com observação participante, formação de grupo focais e entrevistas, assim como análise de documentos (normas ISO 55000 e ISO 45001) com abordagens quantitativas e qualitativas entre MCDM e ML, a fim de refinar e aplicar a metodologia proposta em um caso real da manufatura, com monitoramento constante e refinamento contínuo, garantindo sua eficácia e alinhamento às necessidades específicas da empresa.

1.5 Originalidade e contribuições da pesquisa

A pesquisa destaca a originalidade e contribuições significativas ao combinar métodos tradicionais de tomada de decisão com técnicas avançadas de aprendizado de máquina (Lima Junior *et al.*, 2013; Pereira e Longaray, 2021).

A dissertação teve como finalidade propor uma nova ferramenta de apoio à decisão em grupo integrando múltiplos métodos (AHP - Analytic Hierarchy Process , MOORA -Multi-Objective Optimization Ratio Analysis com a métrica de Tchebtcheff, MULTIMOORA Multi-Objective Decision e Borda Count para construir um framework onde os gestores possam ranquear ativos em uma indústria de manufatura. Essa abordagem visa construir um framework no qual os gestores possam ranquear ativos na indústria de manufatura.

A contribuição teórica reside na combinação de técnicas quali-quantitativas, fornecendo uma estrutura conceitual para a tomada de decisões em contextos complexos. A investigação conjunta considera a capacidade preditiva do ML e a capacidade de avaliação multicritério do MCDM, explorando os pontos fortes e fracos de ambas as abordagens no departamento de manutenção. Além disso, propõe diretrizes teóricas para garantir transparência e responsabilidade na tomada de decisões.

Em termos práticos, aqueles interessados em aplicar o modelo proposto poderão identificar variáveis relacionadas à manutenção e manufatura, adaptando-as às suas necessidades específicas. Eles poderão observar as estratégias de manutenção ao aplicar MCDM, considerando simultaneamente critérios econômicos e de segurança. A implementação do modelo não requer softwares ou procedimentos complexos e pagos, pois basta acessar o código desenvolvido para identificar padrões de manutenção e classificar as alternativas.

Neste cenário, a tomada de decisão envolveu critérios e alternativas para priorização (Zonta *et al.*, 2020), além de ser incremental e original ao associar ao MCDM o ML e aplicar na engenharia de manutenção. Essas contribuições visam colaborar com uma base teórica sólida para a aplicação prática da metodologia de apoio à decisão proposta em empresas de manufatura.

1.6 Metodologia

A pesquisa utiliza uma abordagem de métodos mistos, combinando múltiplos métodos qualitativos e quantitativos, assim como Ortiz e Greene (2007). Para escolher os métodos a serem empregadas no estudo de caso, recorreu-se a literatura para descobrir as que melhor poderiam se adequar ao conjunto de decisores, critérios e alternativas.

Na pesquisa, inicialmente realizou-se uma revisão de escopo através da literatura acadêmica como ferramenta útil no crescente arsenal de abordagem de síntese de evidências (Munn *et al.*, 2018), com objetivo de obter conhecimentos,

devido ao alto custo de implantação de manutenções e incertezas. O diagrama PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analysis) será empregado para ajudar a elucidar às questões de pesquisa QP1 e QP2, proporcionando uma estrutura rigorosa para identificar, selecionar e analisar estudos relevantes sobre um determinado tópico, garantindo transparência e replicabilidade do processo. O PRISMA é uma coleção de diretrizes para a composição e estruturação de revisões sistemáticas e meta análises (Gawde *et al.*, 2023).

Na sequência foi realizado um estudo de caso em uma empresa de manufatura, com o objetivo de analisar seu processo de gestão de manutenção e propor um método para seleção de ativos para iniciar o processo de manutenção preditiva.

A metodologia adotada nesta pesquisa, ao integrar MCDM, métodos de previsão clássica e técnicas de ML, proporciona uma compreensão aprofundada dos processos decisórios na gestão de manutenção. A análise de documentos, especialmente das normas ISO 55000 e ISO 45001, confere um respaldo normativo, alinhando as práticas propostas a padrões internacionais de qualidade e segurança. Complementarmente, a análise de dados históricos de manutenções identifica padrões e tendências, enquanto a abordagem multifacetada, combinando métodos qualitativos como entrevistas com profissionais experientes e métodos quantitativos, fortalece a robustez da pesquisa, validando os resultados e enriquecendo a discussão com perspectivas práticas. Essa metodologia apoia o avanço e discussão sobre a área, além de oferecer soluções práticas e estratégias de tomada de decisão aplicáveis ao cenário real de gestão de manutenção com o estudo de caso.

No contexto da manutenção inteligente, a pesquisa destaca o potencial promissor para aumentar a eficiência do processo de manutenção (Von Enzberg *et al.*, 2020). Documentando a abordagem de métodos mistos essa metodologia é decisiva em situações que demandam interpretação humana, identificando padrões complexos nos dados e otimizando escolhas com base em múltiplos critérios e alternativas.

1.7 Estrutura da Dissertação

A presente dissertação está organizada em sete capítulos, sendo este o introdutório. No segundo capítulo, é apresentada a Fundamentação Teórica onde são definidos os conceitos centrais do trabalho, tais como gerenciamento da manutenção e gestão de ativos, os pilares da manutenção, análise dos métodos MCDM, além de técnicas de ML para gestão da manutenção e modelos de

previsão. No capítulo 3 apresenta-se a Metodologia de Pesquisa com revisão de escopo e estudo de caso incluindo os grupos focais, entrevistas, análise de dados abrangendo as quantitativas e qualitativas entre MCDM e ML subsequentemente a metodologia para aplicação dos métodos do framework. O capítulo 4 apresenta os resultados teóricos obtidos com a revisão de escopo, endereçando a questão de pesquisa 1 (QP1), incluindo as análises bibliométrica, descritiva e de conteúdo. Já o capítulo 5 oferece os resultados empíricos obtidos com o estudo de caso na empresa de manufatura, endereçando a questão de pesquisa 2 (QP2). O capítulo 6 foca nas discussões dos resultados. Por fim no capítulo 7 há conclusões, limitações da pesquisa e sugestões para trabalhos futuros.

2 Fundamentação teórica

Este capítulo apresenta na primeira seção uma introdução que contextualiza a importância do gerenciamento da manutenção e gestão de ativos, além dos conceitos sobre os pilares da manutenção. A próxima seção aborda o papel dos Métodos de MCDM, contemplando os métodos compensatórios e não compensatórios, métodos de alocação de pesos com decisão em grupos, métodos com agregação aditiva e método ordinal. Em seguida, a seção 2.3 exibe as técnicas de ML para gestão da manutenção, findando com os modelos de previsão clássicos e técnicas de ML na seção 2.4.

Neste capítulo foi utilizado um conjunto de 431 documentos, encontrados durante a busca nas bases *Scopus* e *Web of Science* no mês de março de 2023.

2.1 Gestão de ativos, gerenciamento e pilares da manutenção

Segundo a “EN 13306:2017 - Maintenance terminology”, Norma Europeia, a manutenção engloba ações técnicas, administrativas e gerenciais ao longo do ciclo de vida de um objeto, visando sua preservação ou restauração para cumprir sua função. Já a gestão de ativos preocupa os gestores devido à complexidade das operações e aos recursos cada vez mais limitados (Salzano *et al.*, 2023).

Por conseguinte, o gerenciamento da manutenção de ativos exige cada vez mais dos gestores decisões ágeis e confiáveis e para isso diversas metodologias têm sido aprimoradas ao longo do tempo visando dar suporte à essa tomada de decisão. De tal modo que a digitalização dos serviços de manutenção é a chave para o enorme impacto econômico de qualquer setor de manufatura, juntamente com um impacto positivo significativo no meio ambiente, sociedade e na tecnologia (Karki *et al.*, 2022).

Como resultado, questões sobre gestão de ativos são populares entre pesquisadores e as formas de fazer manutenção mudam por setor, podendo ir de inspeções simples a sistemas inteligentes que preveem a vida útil e realizam manutenção automatizada (Urbani *et al.*, 2020).

Como ilustração, os primeiros documentos mencionando gestão de ativos no conjunto de dados coletados iniciam-se no final da década de 1960 (Da Silva

e De Souza, 2021). Dadas as explicações, gerenciar ativos e planejar sua manutenção sob severas restrições econômicas, sociais, políticas e de segurança é a melhor maneira de garantir a confiabilidade necessária (Mirhosseini e Keynia, 2021).

Desta maneira, os gestores da manutenção industrial enfrentam desafios ao tentar estabelecer ou concordar com transformações impulsionadas pelo avanço das tecnologias digitais (Bokrantz *et al.*, 2020b). Apesar da recente transformação da indústria manufatureira com a digitalização e a chegada da Internet das Coisas (Urbani *et al.*, 2020), a cooperação interdisciplinar entre produção e planejamento de manutenção permanece uma área prioritária na I4.0 (Silvestri *et al.*, 2020). Nesse contexto, alguns conceitos essenciais para os mantenedores são discutidos no dia a dia, conforme destacado a seguir:

Para as indústrias, a manutenção segue como um processo operacional vital para o desempenho de fábricas de qualquer tamanho e formato e, perpassar pela manutenção entra na dimensão da manutenção inteligente onde o conceito reflete uma corrente de pesquisa emergente (Bokrantz e Skoogh, 2023). Nesse sentido, na literatura as estratégias de gestão da manutenção mais frequentemente estudadas são: corretiva, preventiva, preditiva e prescritiva (Zonta *et al.*, 2020).

A Manutenção corretiva é uma intervenção necessária causada por uma falha aleatória que torna o equipamento indisponível e geralmente ações corretivas são mais caras e acarretariam baixa qualidade do serviço (Do Carmo Mendonca *et al.*, 2018; Urbani *et al.*, 2020; Consilvio *et al.*, 2019).

Contudo, a manutenção preventiva é implementada para evitar falhas prematuras e esse tipo de atuação perpassa por um problema - agendamento de manutenção – pois este inclui determinar quando parar as fabricas para realizar manutenção preventiva de forma a manter a confiabilidade do sistema e reduzir os custos (Mirhosseini e Keynia, 2021).

Em contrapartida, a relevância da manutenção preditiva ganha destaque no âmbito da I4.0 (Dalzochio *et al.*, 2020). A capacidade de implementar essa abordagem surge como um fator essencial para otimizar o tempo de inatividade das máquinas, reduzir custos e a qualidade da produção (Zonta *et al.*, 2020).

Com isso, atualmente, é imperativo que a manutenção inteligente olhe para os desafios do planejamento de produção com uma perspectiva orientada para a aplicação, a fim de minimizar as perturbações nos cronogramas de produção devido a eventos inesperados de falha, o que também pode afetar a qualidade dos produtos e pode exigir remanufatura cara (Padovano *et al.*, 2021).

Como dito, a Manutenção Inteligente, uma transição para novas tecnologias (Bokrantz *et al.*, 2020a), é um conceito multidimensional, abrangendo tomada de decisão baseada em dados, recursos humanos, integração interna e externa (Bokrantz *et al.*, 2020b).

Na fundamentação teoria, para complementar os pilares de manutenção, a série ISO 55000 é o primeiro padrão internacional oficial na disciplina de gerenciamento de ativos que alcançou consenso global (Da Silva e De Souza, 2021). Alsyouf *et al.* (2018) afirmam que as organizações que adotam a certificação ISO 55000 poderão obter melhor atuação a partir da gestão eficaz de seus bens. As normas ISO 5500X se propõem a atender a necessidade de gestão da vida útil dos ativos físicos garantindo o nível de competitividade, de acordo com os objetivos estratégicos empresarial (Pais *et al.*, 2020).

Finalmente, para trazer luz ao requisito de segurança, surge a norma ISO 45001, estabelecida pelo Comitê de Projeto ISSO/PC 283 em outubro de 2013, aborda requisitos de saúde, segurança ocupacional e define parâmetros para sistemas de gestão, proporcionando um quadro abrangente para organizações aprimorarem práticas relacionadas à saúde e segurança no trabalho (Morgado, Silva e Fonseca, 2019). A norma analisa o local de trabalho, incluindo processos tecnológicos, operações e equipamentos, especificando requisitos de segurança, e está em constante evolução (Bejinariu *et al.*, 2023).

2.2 Métodos de MCDM

Em tomadas de decisões complexas, o uso de métodos de apoio multicritério à decisão (MCDM) é a forma mais científica de garantir uma decisão fundamentada entre várias alternativas (Abdulgader *et al.*, 2018). A aplicação de um método de MCDM é um processo que contempla algumas fases: (i) formulação de um problema, (ii) definição de objetivos, (iii) seleção de critérios, (iv) definição de alternativas, (v) definição de pesos, (vi) pontuações para os critérios e (vii) escolha de métodos adequados (Gebre *et al.*, 2021).

Portanto, na tomada de decisão, torna-se importante ter um método que siga procedimentos padronizados (Salzano *et al.*, 2023), podendo ser classificados como métodos de múltiplos atributos e de múltiplos objetivos (Zavadskas *et al.*, 2019). Diversos métodos como AHP, ANP (*Analytic Network Process*), *Simple Additive Weighting*, TOPSIS (*Technique for Order of Preference by Similarity to Ideal Solution*), VIKOR (*Vlsekriterijusko Kompromisno*), COPRAS (*Complex Proportional Assessment*), PROMETHEE (*Preference Ranking*

Organization Method for Enrichment Evaluation), DEMATEL (*Decision-Making Trial and Evaluation Laboratory*), ELECTRE (*Elimination and Choice Expressing Reality*), MOORA, SMART (*Simple Multi-Attribute Rating Technique*), EVAMIX (*Evaluation Mixed Model*), etc., foram propostos para lidar com problemas MCDM nos últimos anos (*Mousavi-Nasab e Sotoudeh-Anvari, 2017*).

Existe ainda os métodos de ferramentas analíticas ordinais de apoio à tomada de decisão, que são o método Borda e Copeland (*Guimarães et al., 2020*). Ambos são projetados para ordenar alternativas com base em preferências ou avaliações de critérios, sem atribuir valores numéricos absolutos. Esses métodos são comumente empregados em situações em que é necessário estabelecer uma ordem de prioridade entre várias opções, levando em consideração múltiplos critérios (*Valladares et al., 2008*).

Deste modo, ao integrar a manutenção com o MCDM, destaca-se que a manutenção 4.0 tem o potencial de modificar as compensações das estratégias mais antigas, conforme indicado por *Jasiulewicz-Kaczmarek e Gola (2019)*. Exemplificando, *Do Carmo Mendonca et al. (2018)* propõem o uso de métodos MCDM para priorizar prensas de pneus. Adicionalmente, *Ramachandran et al. (2019)* sugerem um sistema de apoio à decisão para a gestão da manutenção de redes rodoviárias, incorporando uma abordagem multi-objetivo. Além disso, na implementação os MCDMs facilitam a representação e compreensão dos pontos-chave, oferecendo suporte na interpretação dos dados de empresas de manufatura e o uso de frameworks se mostram uma ferramenta prática (*Guillén et al., 2016*).

2.2.1. Compensatórios e não compensatórios

Pode-se dizer que existem atualmente duas grandes escolas de estudo de métodos multicritérios: a Escola Americana com os métodos compensatórios e a Escola Francesa exibindo os não compensatórios. A Escola Americana busca uma compensação entre diferentes critérios, aceitando a troca de valores entre critérios, permitindo que uma alternativa compense deficiências em um critério com vantagens em outro. Já na Escola Francesa, os métodos atuam com a característica de não aceitação da compensação entre critérios; cada critério é avaliado de forma independente, valorizando a relação de preferência entre alternativas sem permitir a compensação (*Gomes e Costa, 2013; Gomes, 2009*).

Assim, nos métodos compensatórios uma carência em um atributo pode ser compensado por uma boa avaliação em outro atributo, já os não

compensatórios se houvesse um recurso específico do nosso desejo, e se uma alternativa não tivesse esse recurso, então estaria fora de questão, não importa quais outros recursos ela tivesse - esses outros recursos não compensariam isso. Um exemplo disso é exibido em alguns concursos públicos onde os candidatos que não alcançarem nota alta na prova de redação já serão eliminados. Assim, nos métodos não compensatórios não há compensações entre os critérios, ou seja, suas características e benefícios são individuais e específicos (Avery, 2011). Os métodos AHP, SAW e MAUT fazem parte dos compensatórios e os ELECTRE, PROMETHEE não-compensatórios. Existe ainda métodos como o MULTIMOORA que combina ambos os métodos.

Nesse contexto, a Escola Americana tem um conjunto de métodos voltados à utilização da Teoria da Utilidade Multiatributo, já a escola francesa, por sua vez, estabelece relações de classificação para auxiliar os decisores na seleção entre alternativas por meio de uma abordagem em pares (Da Silveira Esteves *et al.*, 2022). Não só as técnicas, mas também as ações que serão utilizadas durante o processo de tomada de decisão são distintas. A escola Americana tende a ser mais quantitativa e orientada para a otimização, enquanto a Escola Francesa valoriza mais o julgamento humano e lida com incertezas (Rangel, Gomes e Moreira, 2009).

Ao escolher um método multicritério, é crucial considerar o contexto específico do problema de decisão e determinar se a avaliação é do tipo compensatório ou não. A seleção inadequada do método pode resultar em resultados que não refletem adequadamente a complexidade do problema. Dessa forma, um desempenho inferior em um critério pode ser compensado por um desempenho superior em outro, permitindo uma análise mais abrangente e equilibrada dos diferentes aspectos envolvidos na tomada de decisão (Inmetro, 2022).

2.2.2. Alocação de pesos com decisão em grupo

No MCDM, uma teoria de medição por meio de comparações de pares se baseia nos julgamentos de especialistas para derivar prioridades, sendo uma abordagem amplamente utilizada para obter preferências ou pesos de importância em relação aos critérios e alternativas para uma variedade de campos de pesquisa (Pun *et al.*, 2017; Tscheikner-Gratl *et al.*, 2017).

Dentre os métodos, o AHP utiliza comparações de pares e julgamentos de especialistas para derivar prioridades, sendo amplamente utilizado em diversos

campos de pesquisa para obter preferências ou pesos de importância em relação a critérios e alternativas (Pun *et al.*, 2017; Tscheikner-Gratl *et al.*, 2017). A literatura comprovou sua confiabilidade, apresentando vantagens como a capacidade de incorporar critérios qualitativos e quantitativos e índices de consistência que garantem a qualidade das decisões (Abdullah *et al.*, 2023; Tscheikner-Gratl *et al.*, 2017). Além disso, o AHP é de fácil compreensão, mesmo para aqueles não familiarizados com métodos de apoio à decisão multicritério (Tscheikner-Gratl *et al.*, 2017), no entanto, apresenta algumas desvantagens, como a dificuldade em utilizar valores precisos para representar julgamentos linguísticos (Pun *et al.*, 2017) e a possível perda de informação devido a efeitos de compensação entre critérios, afetando a qualidade e precisão das informações disponíveis (Macharis *et al.*, 2004).

No AHP utiliza-se de matriz de prioridade, para capturar as preferências e importâncias e de vetor de prioridades (w) derivado dessa matriz.

Fórmula: (1)

$$Aw = \lambda_{max}W$$

É relevante destacar que a consistência das comparações feitas pelos tomadores de decisão, sendo este fundamental para garantir a validade dos resultados com a realização do Índice de Consistência (IC).

Fórmula: (2)

$$IC = \frac{\lambda_{max} - n}{n - 1}$$

Em que λ_{max} é o valor máximo da matriz de decisão e n é o número de alternativas que estão sendo comparadas. IC deve ser inferior a 0,01 para que as comparações pareadas sejam consideradas consistentes, ilustrado na fórmula (1).

No método é necessário calcular a Razão de Consistência (RC).

Fórmula: (3)

$$RC = \frac{IC}{IR}$$

Em que IR é o Índice Randômico calculado conforme Tabela 1.

Dimensão da matriz (n)	3	4	5	6	7	8	9	10
IR	0,58	0,9	1,12	1,24	1,32	1,41	1,45	1,49

Tabela 1 – Índice Randômico.
Fonte: Adaptado de Saaty (1987)

Como complemento existe ainda a abordagem AHP-AIP que determina os pesos e classifica as alternativas com média aritmética sendo adequado quando o grupo de tomadores de decisão é heterogêneo (Do Nascimento *et al.*, 2023).

2.2.3. Ranking com agregação aditiva

O ranking com agregação aditiva usa a soma ponderada dos critérios para cada alternativa e para combinar pontuações gerando ranqueamentos precisos. O método MULTIMOORA permite a construção de três rankings, cada um derivado da aplicação de técnicas diferentes. O primeiro, MOORA, está associado a sistema de taxas, o segundo à distância da avaliação das alternativas em relação a um ponto de referência, e, por fim, a função de utilidade multiplicativa. A ordenação hierárquica final é determinada por relações de dominância ordinal cuidadosamente elaboradas (Olimpio, 2020).

O MOORA é uma abordagem que considera objetivos benéficos e não benéficos para selecionar ou ordenar. Uma das principais vantagens é que ele requer menos tempo de computação, devido à utilização de matemática simples (Rane *et al.*, 2021). Além disso, o MOORA é considerado matematicamente compreensível e adequado para avaliação de sistemas de manutenção, fornecendo uma avaliação objetiva e razoável (Pérez-Domínguez *et al.*, 2018). Neste âmbito, Joel Villa-Silva *et al.* (2019) destacaram a aplicabilidade do método. Este procedimento tem como objetivo calcular o quadrado de cada elemento no conjunto de dados e, em seguida, dividir esses valores pela soma dos quadrados dos dados para obter denominadores. Depois, os índices resultantes são normalizados entre zero e um para ranqueamento (Brauers e Zavadskas, 2006).

Utiliza-se das fórmulas 4, 5, 6 e 7 para execução dos métodos MULTIMOORA, iniciando com a montagem da matriz de decisão (a), normalização dos valores (b) e o cálculo da matriz de decisão normalizada e moderada (c) (Lima (2021)).

Fórmula:

$$D = \begin{bmatrix} x_{1,1} & x_{1,1} & \dots & x_{1,1} & x_{1,1} \\ x_{2,1} & x_{1,1} & \dots & x_{1,1} & x_{1,1} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{1,1} & x_{1,1} & \dots & x_{1,1} & x_{1,1} \\ x_{1,1} & x_{1,1} & \dots & x_{1,1} & x_{1,1} \end{bmatrix}$$

(a)

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}$$

(b)

$$v_{ij} = w_j * r_{ij}$$

(c)

Fonte: Lima (2021)

Para determinar o cálculo do primeiro modelo de ranqueamento, baseado no sistema de relação Y_i de uma alternativa (Lima (2021)) é efetuada a fórmula 5.

Fórmula: (5)

$$Y_i = \sum_{j=1}^k x_{ij}^* - \sum_{j=k+1}^N x_{ij}^*$$

Fonte: Lima (2021)

Sendo: $j = 1 \dots k$: representando o conjunto dos atributos de benefício e $j = (k + 1) \dots N$: representa o conjunto dos atributos de custo (Lima (2021)).

Para resolução do segundo modelo, que tem por base a utilização de um ponto de referência *Chebyshev* o cálculo foi descrito na fórmula 6, onde r_j para um determinado atributo representa o melhor valor.

Fórmula: (6)

$$Y_i^* = \min_j (\max_i |r_j - x_{ij}^*|)$$

Fonte: Lima (2021)

Para o terceiro e último modelo as fórmulas foram descritas na sequência. Sendo A_i o resultado dos critérios a serem maximizados. B_i o resultado dos critérios a serem minimizados e U_i a utilidade total de uma alternativa, registrada na fórmula 7.

Fórmula: (7)

$$A_i = \prod_{j=1}^k r_{ij}^{w_j} \quad B_i = \prod_{j=k+1}^N r_{ij}^{w_j} \quad U_i = \frac{A_i}{B_i}$$

(a) (b) (c)

Fonte: Lima (2021)

Outro método é a chamada métrica Tchebycheff (Brauers e Zavadskas (2006)). O método identifica primeiro o valor de avaliação da pior alternativa em cada índice como ponto de referência (Wang *et al.*, 2024). Os pontos de referência podem ser determinados pela fórmula 8:

Fórmula: (8)

$$\min_{(j)} \left\{ \max_{(i)} |r_i - N^{x_{ij}}| \right\}$$

$i = 1, 2, \dots, n$ são os critérios, $j = 1, 2, \dots, m$ são as alternativas, $r_i = i^{th}$ coordenação do ponto de referência do objetivo máximo; cada coordenada de ponto de referência é selecionada como a coordenada correspondente mais alta

das alternativas, $N^{x_{ij}}$ = o objetivo normalizado i da alternativa j (Do Nascimento *et al.*, 2023). Em seguida, é medida a distância entre cada alternativa e o ponto de referência.

2.2.4. Método ordinal

Um dos métodos mais antigos de MCDM é o método de Borda. O método é uma abordagem ordinal que surgiu da observação de que, em eleições, uma alternativa vencedora em uma pluralidade de votos pode ser derrotada por outra alternativa na votação por maioria de pares (Okamoto e Sakai, 2019). Sua grande vantagem é a simplicidade, onde os pontos atribuídos pelos decisores a cada alternativa são somados, e a alternativa com a menor pontuação é a escolhida (Cruz *et al.*, 2012). No entanto, uma desvantagem do método é que ele não permite uma comparação direta entre as opções, o que pode limitar sua aplicabilidade em certos cenários de tomada de decisão.

O método pode combinar os resultados dos ranqueamentos obtidos a partir de vários métodos de avaliação para obter um ranqueamento final da alternativa (Wang *et al.*, 2024). Liu *et al.* (2021), utilizaram o método MULTIMOORA em conjunto com a regra de BORDA para seleção sustentável de fornecedores e Wang *et al.* (2024) aplicaram Borda ao problema de governança ecológica combinado com o Borda para obter os resultados da avaliação.

Neste método, a fórmula utilizada para calcular a pontuação de cada alternativa é exibida na fórmula 9.

Fórmula: (9)

Pontuação da Alternativa i = Σ (Pontos atribuídos pelo decisor à alternativa i para cada critério)

Em que:

Pontuação da Alternativa i é a pontuação total atribuída à alternativa i . Pontos atribuídos pelo decisor à alternativa i para cada critério são os pontos que o decisor dá à alternativa i em relação a cada critério específico (Do Nascimento *et al.*, 2023). Os pontos são somados para cada alternativa, considerando as avaliações feitas pelos decisores para cada critério. No Borda, o ranqueamento ocorre pela alternativa de menor pontuação para a de maior pontuação (Guimarães *et al.*, 2020).

2.3 Técnicas de ML para gestão da manutenção

A incorporação de técnicas de ML na gestão de manutenção, como discutido na tese de doutorado de Pereira (2022), reflete o avanço no campo da inteligência artificial (IA) e destaca a aplicabilidade prática dessas técnicas para melhorar a eficiência e eficácia na manutenção de sistemas complexos.

Nesse sentido, alguns artigos sugerem que o ML pode ser benéfico para o gerenciamento de manutenção. Milad *et al.* (2020) descobriram que os sistemas *Azure Machine Learning* (AML) eram eficazes na previsão da manutenção do pavimento. Carvalho *et al.* (2019) revisaram a literatura destacando métodos de aprendizado de máquina aplicados à manutenção preditiva, utilizando dados do mundo real fornecidos por uma empresa portuguesa. Já Ferreira *et al.* (2022) usaram ML para prever avarias nos equipamentos.

No geral, Milad *et al.* (2020); Carvalho *et al.* (2019); Ferreira *et al.* (2022) sugerem que o ML pode ajudar nas estratégias de manutenção, melhorando o desempenho e prolongando a vida útil do equipamento.

Nessa perspectiva, segundo Carvalho (2019), o ML fornece abordagens preditivas poderosas para aplicativos de manutenção preditiva. No entanto, o desempenho dessas aplicações depende da escolha adequada da técnica de ML (Carvalho *et al.*, 2019) podendo ser usado para interceptar falhas corretamente (Milad *et al.*, 2020). Além disso, o desenvolvimento do algoritmo de ML abrange a seleção de dados históricos, dados de pré-processamento, seleção, treinamento e validação de modelo, além da manutenção (Çinar *et al.*, 2020).

Um exemplo disso é que o Machine Learning (ML) dentro da Inteligência Artificial (IA) surgiu como uma ferramenta poderosa para o desenvolvimento de algoritmos preditivos inteligentes em diversas aplicações (Carvalho *et al.*, 2019). Além disso, as fábricas inteligentes demandam mudanças na manufatura e na gestão dos operadores (Silvestri *et al.*, 2020). Sob esse olhar, apesar da ampla gama de algoritmos de ML disponíveis, geralmente, eles podem ser categorizados em três grupos principais: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado por Reforço (Pereira, 2022).

Nota-se, em última análise, que um algoritmo ML pode ser usado em vários estágios para realizar tarefas de ranqueamento ou previsão. De modo geral, muitos modelos com diferentes estruturas e recursos são utilizados para o problema de previsão de séries temporais, como os ARIMA (*Autoregressive integrated moving average*) e RNAs (Dalzochio *et al.*, 2020; Bas, Egrioglu e Cansu, 2024).

O modelo ARIMA também citado como metodologia *Box-Jenkins* (Box *et al.*, 2015) é uma abordagem que permite solução estocásticas ou probabilísticas para análise de séries temporais, permitindo a identificação e ajustes de modelos auto-regressivos integrados à média móvel, realizando as previsões futuras. No modelo ARIMA, o valor futuro de uma variável é uma combinação linear de valores passados e erros passados (Adebisi *et al.*, 2014).

A aplicação ocorre em ciclos em quatro fases distintas. A primeira fase, denominada Identificação, consiste em determinar qual entre as diversas versões dos modelos de *Box-Jenkins* melhor descreve o comportamento da série temporal em análise (Silva *et al.*, 2021). Em seguida, a etapa de Estimação envolve a estimativa dos parâmetros e do componente auto-regressivo, bem como de médias móveis, juntamente com a variância (Harvey, 1990).

A terceira etapa, conhecida como verificação ou diagnóstico, tem como objetivo avaliar a adequação do modelo estimado para descrever o comportamento dos dados. Caso o modelo não seja considerado apropriado, o ciclo é repetido, retornando à fase de Identificação. É possível identificar diversos modelos, os quais são então estimados e por fim, a última etapa da metodologia é a previsão, na qual, uma vez obtido um modelo satisfatório, o foco principal é realizar previsões (Chodakowska *et al.*, 2021).

Pode-se ainda realizar o teste de raízes unitárias de *Dickey-Fuller* Aumentado (ADF), aplicado para análise de estacionariedade, e o teste da Função de Auto-Correlação (ACF), utilizado para analisar os resíduos do modelo (De Souza, 2008).

Em outro exemplo, as RNAs são métodos baseados em dados com estruturas complicadas causadas por camadas ocultas, seus modelos mudam de acordo com a estrutura dos dados, alterando o número de camadas ou unidades ocultas podendo garantir conformidade alta com os dados (Bas, Egrioglu e Cansu, 2024).

A Figura 1 mostra um exemplo de RNAs. As RNAs consistem em uma camada de entrada, uma ou mais ocultas e uma de saída (Zhu *et al.*, 2017).

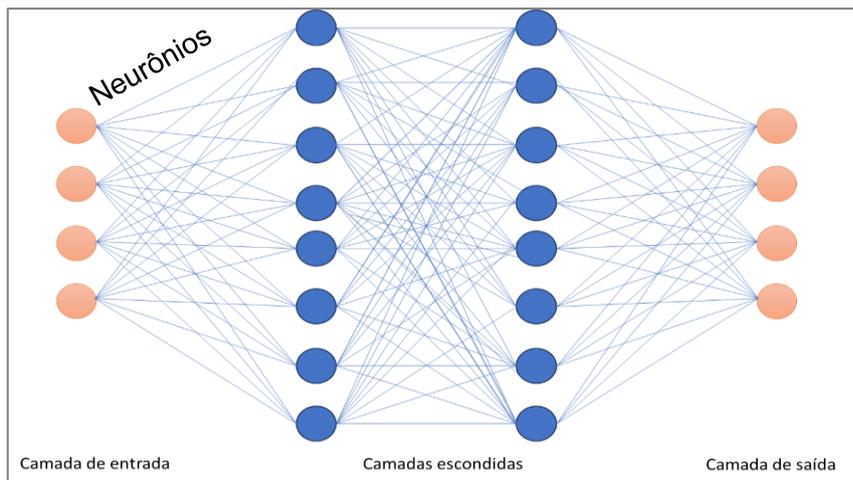


Figura 01 - Arquitetura MLP com duas camadas

Fonte: Autoria própria

Uma RNA digitalmente, tenta emular a estrutura neural do cérebro, que consiste em vários milhares de células neurônio, que está interligado em uma grande rede. Isso é feito por meio de neurônios artificiais, manipulando a entrada e a saída, conectando-se a outros neurônios, criando uma grande rede. Hoje existem vários usos diferentes para RNAs, que vão desde a pesquisa acadêmica em áreas como a medicina até fins comerciais e previsão esportiva (Aziz, 2020).

Segundo Fabianowski *et al.*, (2021), as RNAs foram extensivamente aplicadas com sucesso na engenharia civil para questões de tomada de decisão com base em dados históricos e parâmetros declarados. Verificou-se com base nos cálculos que com a RNA é necessário um tempo muito menor para fazê-los em comparação com os métodos alternativos.

O interesse em RNAs advém de propriedades atraentes, como processamento simultâneo de informações e efetiva aproximação de não linearidades. A vantagem indiscutível é a dispensa do conhecimento de modelos matemáticos (Fabianowski *et al.*, 2021). A maior dificuldade na aplicação de RNA está ligada à necessidade de realizar processamento de aprendizado, que requer uma grande quantidade de dados e com alta diversidade (Fabianowski *et al.*, 2021). O RNA é modelo de aprendizado de máquina e ARIMA é um método estatístico clássico (Rundo *et al.*, 2019).

2.4. Modelos de previsão - clássicos e técnicas de ML

Modelos de previsão desempenham um papel crucial em uma variedade de campos, desde meios de transporte com a previsão de tráfego, finanças observando as taxas de juros, passando pelas engenharias, metrologia e saúde. Eles podem ser classificados em categorias principais como modelos clássicos e técnicas de ML. Os modelos clássicos e ML são utilizados para prever os dados de uma série temporal, sendo que estudos atuais geralmente utilizam algoritmos clássicos de ML para estabelecer um modelo de predição (Meeks *et al.*, 2022).

No estudo de Meeks *et al.* (2022) os autores fizeram pesquisa para selecionar sensores de taxa de corrosão e consideraram ambas as formas de analisar dados de séries temporais. Do grupo de série temporal clássica eles envolveram os algoritmos Autoregressivos, Média Móvel Autoregressiva (ARMA) e ARIMA. Para modelos de ML, analisaram SVM, *Gradient Boosting Regression* e K-regressão do vizinho mais próximo.

Já uma série temporal é uma sequência de pontos de dados em pontos igualmente espaçados no tempo. Elas tipicamente exibem características como não estacionariedade, autocorrelação e sazonalidade (Schaffer *et al.*, 2021). Analisar séries temporais implica abordar a não estacionariedade, explorar a autocorrelação para identificar dependências temporais e avaliar modelos para construir previsões precisas e informativas.

Algumas métricas são usadas para avaliação dos modelos de previsão como MSE (*Mean Squared Error*), RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*) e MAPE (*Mean Absolute Percentage Error*) (Pramono *et al.*, 2019).

- MSE: O MSE é a média dos quadrados dos erros entre as previsões e os valores reais da série temporal. Ele penaliza mais fortemente erros maiores, pois eleva esses erros ao quadrado. Quanto menor o valor do MSE, melhor será o ajuste do modelo às previsões. O MSE é útil para medir a precisão geral do modelo.

- RMSE: O RMSE é a raiz quadrada do MSE e representa o erro médio entre as previsões e os valores reais em unidades originais da série temporal. É uma métrica amplamente utilizada e fácil de interpretar, pois está na mesma escala que os dados originais. Quanto menor o valor do RMSE, melhor será a precisão do modelo.

- MAE: é a média dos valores absolutos dos erros entre as previsões e os valores reais da série temporal. O MAE é útil quando desejamos uma métrica que seja robusta a outliers.

- MAPE: é a média dos valores absolutos das porcentagens de erros entre as previsões e os valores reais. Essa métrica expressa os erros em termos de

porcentagem dos valores reais, tornando-a interpretável quando queremos medir o erro relativo em relação ao tamanho dos valores reais.

3

Metodologia de pesquisa

Neste capítulo, é abordado inicialmente o delineamento metodológico por meio da revisão do escopo de métodos multicritérios e de modelos de ML para manutenção de ativos para amparar o estudo de caso. São empregados vários métodos de pesquisa para coleta de dados, tais como: revisão da literatura, observação direta, grupo focal e entrevistas; e abordagem de métodos mistos, combinando métodos qualitativos e quantitativos para análise de dados, além das explicações do procedimento de aplicação dos métodos no framework, fornecendo insights valiosos para pesquisadores e profissionais que buscam abordagens integradas e eficazes para lidar com a complexidade (Mudashiru *et al.*, 2021). A dissertação segue Mingers (2003), que argumenta que o uso de diferentes métodos de pesquisa produzirá resultados mais ricos e confiáveis. A aplicação de abordagens que mesclam diversas técnicas de decisão se destaca ao enfrentar desafios complexos, com uso de métodos mistos, possibilitando a contemplação de uma variedade de alternativas e critérios, resultando em análises mais sólidas e abrangentes. Dessa forma, essa estratégia integrativa não apenas fortalece a qualidade das análises, mas também enriquece a compreensão dos fatores envolvidos em contextos decisórios complexos (Tan *et al.*, 2021). Alinhado com os objetivos desta dissertação, a aplicação de métodos MCDM na manutenção industrial é justificada pela complexidade inerente às decisões nesse contexto.

3.1 Revisão de escopo

A revisão de escopo tornou-se uma abordagem cada vez mais popular para sintetizar evidências de pesquisa. Esta revisão objetiva “identificar lacunas, esclarecer conceitos ou para investigar a conduta e método da pesquisa” (Munn *et al.*, 2018). A presente dissertação adota as etapas de Arksey e O’Malley (2005) para conduzir uma revisão de escopo se apresentando em 5 etapas, as quais são:

Etapa 1: encontrar a questão da pesquisa;

Etapa 2: descobrir os estudos relevantes;

Etapa 3: efetuar a seleção pelas pesquisas;

Etapa 4: mapear os dados;

Etapa 5: sintetizar e expor os resultados.

Do ponto de vista prático, de forma exploratória, a revisão de escopo vai ajudar a identificar e sintetizar evidências científicas sobre ML e MCDM e manutenção na perspectiva da I4.0.

A revisão de escopo foi iniciada com a identificação das questões de pesquisas, entrando na Etapa 1. A elaboração da estratégia de busca foi baseada nos componentes da questão norteadora estruturada do acrônimo PICO. PICO representa um acrônimo para População, Intervenção, Comparação e Resultado (Richardson *et al.*, 1995). A Tabela 2 apresenta os quatro componentes do uso da estratégia PICO que foi empregada para pesquisa.

Componentes analisados	Respostas
P - População	Manutenção de ativos
I - Intervenção	MCDM + ML
C - Comparação	Perspectiva da I4.0
O - Resultados	Tomada de decisões

Tabela 2 – Descrição da estratégia PICO

Assim, a primeira pergunta norteadora desta pesquisa foi:

QP1 - No contexto da Manutenção 4.0, como a literatura explora a combinação entre MCDM e ML para apoiar a tomada de decisão para manutenção de ativos?

Para a etapa de seleção dos estudos, foram definidas duas bases de dados eletrônicas e internacionais. As bases de dados Scopus, da *Elsevier*, (scopus.com) e *Web of Science* (webofscience.com) foram escolhidas em função de sua complementariedade e do grande acervo associado ao domínio de gerência de operações (Magon *et al.*, 2018). Além da Scopus ser confiável e neutra, curada por especialistas reconhecidos em diversas áreas e a Elsevier, por sua vez, é uma renomada editora científica que oferece uma extensa coleção de periódicos revisados por pares. Ambas fortalecem a validade e abrangência da pesquisa, contribuindo para uma fundamentação sólida.

As buscas foram realizadas em 31 de março de 2023 e utilizou-se o diagrama PRISMA para ilustrar o processo de identificação, rastreamento e elegibilidade (Moher *et al.*, 2010). O alvo da busca e seleção de documentos foi para permear a elaboração da pesquisa (Thomé *et al.*, 2016).

A expressão de busca empregada foi definida para abordar apenas as palavras-chave que estivessem relacionadas com os conceitos do problema. Na Tabela 3 é exibida as descrições das buscas durante a revisão de escopo, de forma documentar fornecendo uma referência útil para revisão posterior.

Descrição das buscas	
Base de busca	<i>Scopus e Web of Science</i> em março de 2023.
Operadores booleanos	“AND” e “OR”
Classificações	“TITLE-ABS-KEY”
Palavras-chaves	MCDM, MCDA, MULTI-CRITERIA DECISION MAKING, MULTIPLE CRITERIA DECISION MAKING, MULTI-CRITERIA, MULTICRITERIA DECISION, MULTI-CRITERIA DECISION, MULTI-ATTRIBUTE DECISION, MULTIATTRIBUTE DECISION, AHP, ELECTRE , PROMETHEE , TOPSIS , VIKOR, ARAS, MOORA, MULTIMORA, WASPAS, DEMATEL, MACHINE LEARNING, ARTIFICIAL NEURAL , INDUCTIVE LEARNING, ARTIFICIAL NEURAL, CONVOLUTIONAL NEURAL NETWORKS, CASE-BASED REASONING, SUPPORT VECTOR MACHINE, REINFORCEMENT LEARNING, DEEP LEARNING, ARTIFICIAL INTELLIGENCE, DECISION TREES, LOGISTIC REGRESSION, ENSEMBLE METHODS, UNSUPERVISED LEARNING, SUPERVISED LEARNING, DATA MINING, DATA ANALYTICS
Critério de inclusão	Os artigos devem atender a pelo menos um termo relacionado ao tema da pesquisa; os artigos devem ser publicados ou em processo de publicação em periódicos.
Critério de exclusão	Para permitir a replicação do estudo, foi estabelecido os seguintes critérios de exclusão: Não estavam relacionados à manutenção ou ao contexto da I4.0; Escritos em outra língua que não seja a inglesa; Artigos duplicados; e/ou com indisponibilidade de texto completo.
Ano publicação	Sem restrições
Pesquisa	31 de março de 2023

Tabela 3: Revisão de escopo

Os critérios foram condensados nas Tabelas 4 e 5 exibindo os operadores, palavras-chaves e anos de publicações.

Base de dados <i>Scopus</i>
(TITLE-ABS-KEY (mcdm OR mcda OR "multi-criteria decision making" OR "multiple criteria decision making" OR multi-criteria OR "multicriteria decision" OR "multi-criteria decision" OR "multi-attribute decision" OR "multiattribute decision" OR ahp OR electre OR promethee OR topsis OR vikor OR aras OR moora OR multimora OR waspas OR dematel) AND TITLE-ABS-KEY ("machine learning" OR "Artificial Neural" OR "inductive learning" OR "artificial neural networks" OR "Convolutional Neural Networks" OR "case-based reasoning" OR "support vector machines" OR "reinforcement learning" OR "deep learning" OR "artificial intelligence" OR "decision trees" OR "random forests" OR "logistic regression" OR "ensemble methods" OR "unsupervised learning" OR "supervised learning" OR "data mining" OR "data analytics" OR

<p>"data science" OR "knowledge discovery in databases" OR "KDD" OR "genetic algorithm") AND TITLE-ABS-KEY (mainten* OR "industr* 4.0" OR "digital* manufact*" OR "manufact* 4.0"))</p>

Tabela 4 – Pesquisa na base *Scopus*.

Base de dados <i>Web of Science</i>
<p>(TS= (mcdm OR mcda OR "multi-criteria decision making" OR "multiple criteria decision making" OR multi-criteria OR "multicriteria decision" OR "multi-criteria decision" OR "multi-attribute decision" OR "multiattribute decision" OR ahp OR electre OR promethee OR topsis OR vikor OR aras OR moora OR multimooraa OR waspas OR dematel)) AND TS= ("machine learning" OR "Artificial Neural" OR "inductive learning" OR "artificial neural networks" OR "Convolutional Neural Networks" OR "case-based reasoning" OR "support vector machines" OR "reinforcement learning" OR "deep learning" OR "artificial intelligence" OR "decision trees" OR "random forests" OR "logistic regression" OR "ensemble methods" OR "unsupervised learning" OR "supervised learning" OR "data mining" OR "data analytics" OR "data science" OR "knowledge discovery in databases" OR "KDD" OR "genetic algorithm") AND TS= (mainten* OR "industr* 4.0" OR "digital* manufact*" OR "manufact* 4.0"))</p>

Tabela 5 – Pesquisa na base *Web of Science*.

A Etapa 2 consiste em descobrir os estudos relevantes. A estratégia de busca produziu 431 documentos sendo possível observar que a maior quantidade retornada foi na base *Scopus* com 329 e a menor foi *WoS* com 102.

Cumprindo a Etapa 3 de “Seleção pelas pesquisas”, foi efetuado o primeiro critério de exclusão fazendo a retirada dos documentos repetidos utilizando os pacotes *Bibliometrix* e do Software *RStudio Cloud*, restando 370 documentos, para continuidade do protocolo de seleção e leitura de títulos e resumos. Assim, 61 documentos foram excluídos por serem duplicados, restando 370 artigos para rastreamento. Em seguida 353 artigos foram excluídos devido à sua relação vaga com o tema, com base apenas no título e resumo, além de documentos inacessíveis. Para a etapa 4 “Mapeamento dos dados” foi necessário fazer a leitura completa dos 60 documentos selecionados, com base nos títulos e seus resumos visando excluir os que não estavam relacionados à pergunta de pesquisa ou sem contexto com I4.0 e/ou manutenção, formando a base documental restando 13 artigos. A revisão identificou ainda 1 documento adicional usando o processo de *snowballing*.

A técnica de *snowballing*, também conhecida como "bola de neve" em português, envolve a busca de referências bibliográficas a partir de fontes já identificadas, visando identificar demais publicações relevantes (Wohlin, 2014). Ao final 14 documentos restaram para a revisão de escopo.

A identificação das bases de dados e registros para questão de pesquisa Q1, foi apresentado no fluxograma PRISMA na Figura 2.

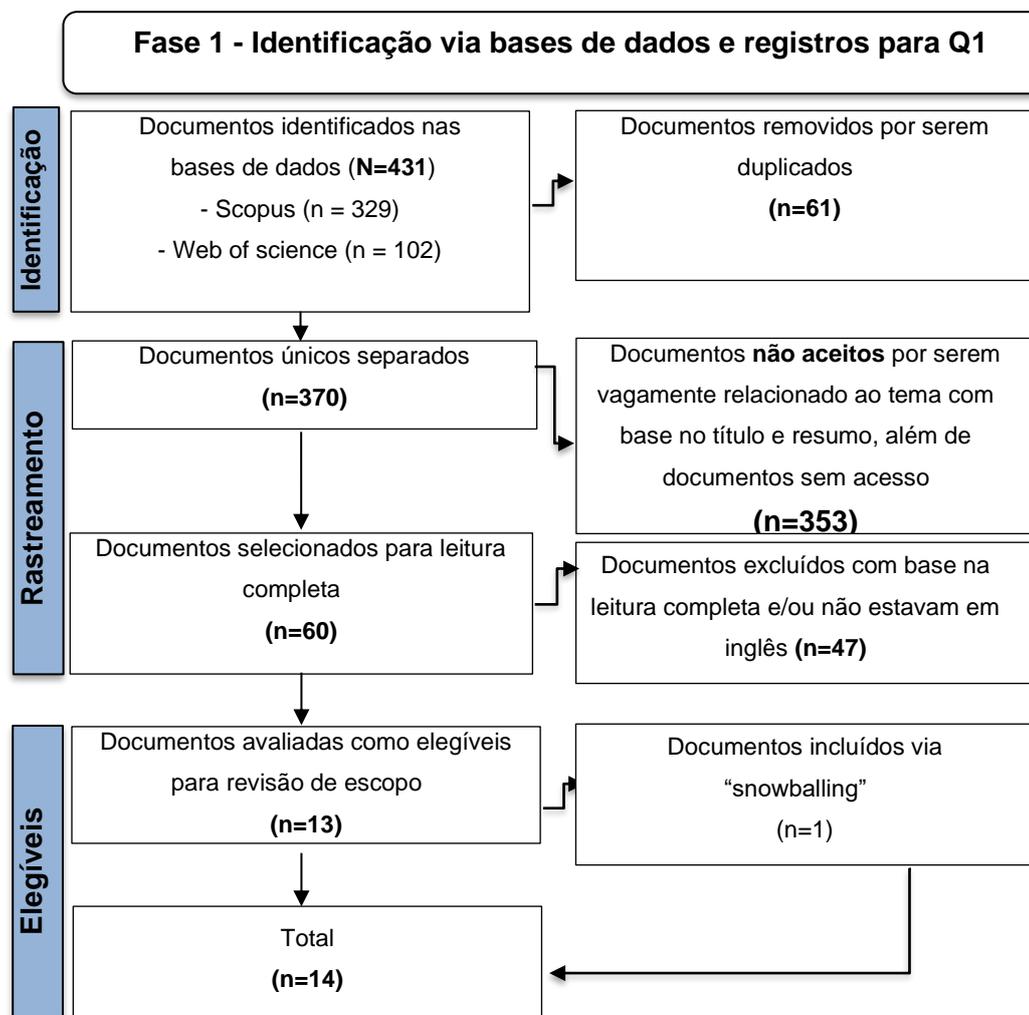


Figura 2 – PRISMA fluxograma
Fonte: Autoria própria

Após finalizar a seleção pela pesquisa, a Etapa 05 “sintetizar e expor os resultados”, foi desenvolvida, de forma a analisar os documentos gerando uma bibliometria. Assim, foi utilizado o Microsoft Excel, *VOSviewer*, *Bibliometrix*, pacote *R-tool* (Bashiri, Geranmayeh e Sherafati, 2012). Analisando os resultados obtidos foi possível obter dados para o capítulo 4 de Resultados Teóricos com as análises bibliométricas, descritivas e de conteúdo. A Análise Bibliométrica para quantificar e avaliar as produções acadêmicas incluindo número de citações, autores mais citados e periódicos de destaque para avaliar a relevância, a Análise Descritiva

para examinar a distribuição de temas e a Análise de Conteúdo para identificar padrões (Moura *et al.*, 2020; Miolo, Sausen e Cappellari (2018).

3.2 Estudo de caso

O objetivo do estudo de caso é obter uma compreensão aprofundada do objeto de estudo e explorar questões de pesquisa (Hollweck, 2015). O estudo foi realizado, abordando questões teóricas e práticas, a exemplo de Tscheikner-gratl *et al.* (2017) ao pesquisarem sobre 5 métodos (MCDM) disponíveis (ELECTRE, AHP, WSM, TOPSIS e PROMETHEE). Outra pesquisa que ajudou essa dissertação foi o estudo de Consilvio *et al.* (2019), em que os autores pesquisaram programação e manutenção preditiva considerando a criticidade dos ativos.

A condução da investigação do estudo de caso seguiu o roteiro adaptado de Yin (2015). A sequência do estudo de caso consiste em 4 macro etapas com 7 sub etapas no total, podendo ser vista na Figura 3 desenvolvida no site drawio.net.



Figura 3 – Estudo de caso
Fonte: Autoria Própria

Essas quatro macros etapas representam uma estrutura abrangente para a condução de estudos de caso.

Macro etapa 1:

Para iniciar a Subetapa 1 de planejamento, foi necessário a escolha de um estudo de caso único ou múltiplo. Dessa maneira foi definido que a pesquisa será um Estudo de Caso Único, envolvendo uma unidade de análise, por ser um caso

representativo e decisivo (Yin, 2015). Assim será possível aprofundar a investigação para tomada de decisão, com o uso de metodologia inovadora. Na primeira etapa delimitou-se ainda a escolha da empresa, ficando definida uma empresa de manufatura de grande porte e importância nacional por ser única em termos de unidades fabricadas, cultura organizacional, estrutura e localização.

Robert K. Yin sugere diversas estruturas para estudos de caso, como Analítica linear, Comparativa, Cronológica, Construção de teoria, "suspense" ou Não sequencial, proporcionando ao pesquisador a flexibilidade necessária na escolha da abordagem mais apropriada para comunicar os resultados. No estudo de caso na empresa pesquisada, foi aplicado a estrutura composicional comparativa, referindo-se a um formato onde o material do estudo de caso é repetido duas ou mais vezes, sendo útil para diferentes perspectivas (Yin, 2015).

Na Subetapa 2, como desenvolvimento do protocolo, a estrutura do estudo de caso foi realizada em conformidade com as abordagens listadas no Apêndice 1- Protocolo de estudo de caso, uma vez que o protocolo é um meio eficaz de tratar o problema geral de confiabilidade dos estudos de caso (Yin, 2015). Onde o tipo de coleta de dados foi definido como exploratório para gerar insights e no final testar hipóteses (Yin, 2015), com a análise das comparações par a par de cada decisor. Levantamento das teorias, com o capítulo 2 de fundamentação teórica. Escolha da variação do estudo com a escolha da unidade de análise sendo a empresa de manufatura do Rio de Janeiro. Definição das questões de estudo, usando a estratégia PICO que foi descrita na revisão de escopo. Definição do grupo focal para fase de preparação de estudo. Levantamento de fontes de evidências com o desenvolvimento do framework e da própria dissertação. Validade do estudo com a avaliação do framework e exibição da análise de sensibilidade aos especialistas. Confiabilidade ao empregar o protocolo evitando que houvesse esquecimento de quaisquer itens. Preparação do relatório e de conteúdo com todos os registros na dissertação.

Além disso, a seleção do caso, realizada na Sub etapa 3 de seleção dos casos, o tema de metodologia para seleção e ranqueamento de impressora de grande porte para serem submetidas a manutenção preditiva, permite gerar teorias ou insights iniciais sobre padrões e percepção dos decisores, podendo ser apontada pela representatividade do tema para a empresa e a academia, permanecendo como Desenvolvimento de metodologia de apoio à decisão para Manutenção inteligente combinando abordagens multicritério e machine learning.

Como elaboração de um plano geral, ficou definido o emprego dos métodos MCDM e Modelos de previsão - clássicos e técnicas de ML.

Macro etapa 2:

A Subetapa "4" destaca a importância da Preparação para Coleta de Evidência de Dados, organizando recursos para entrevistas, triagem de decisores em grupos focais, observações e análise de banco de dados histórico, com a colaboração do investigador. Yin (2015) enfatiza a necessidade de um pesquisador treinado para garantir a qualidade do estudo, minimizando vies e conduzindo a pesquisa de maneira ética, dada a interação contínua com os participantes, para um estudo de caso de qualidade. A preparação cuidadosa dos dados para compartilhamento é ressaltada como uma etapa crucial nesta fase do estudo de caso (Yin, 2015). Assim durante a pesquisa foram identificadas as metodologias e métodos a serem investigados, restando a escolha dos 5 modelos MCDM, definição dos critérios e alternativas relevantes, definição do ARIMA e de RNA. Foram também definido o grupo focal com a participação do pesquisador.

Macro etapa 3:

A Subetapa "5" foca na Coleta de Dados. Yin (2015) destaca sobre o momento de coleta, pois a necessidade de prestar atenção nos tempos de entrevistas, fontes essenciais de informação, que podem variar em duração. Além disso, a coleta se estende a várias fontes, como análise de documentos, registros eletrônicos, artefatos físicos, entre outras fontes.

Assim, no estudo de caso, como coleta de dados, para alimentar os modelos de previsão as informações concentraram-se nas bases de dados temporais de manutenções de cada impressora, para servir como apoio ao primeiro critério definido para ser julgado pelos decisores, com finalidade de impactar na tomada de decisão. Na coleta foram incluídos ainda, a preparação adequada dos conjuntos de treinamento e testes necessários aos modelos de predição.

Finalizando a subetapa 5, ocorreu a realização das entrevistas – com observação participante, aplicando o formulário incluído nos Apêndices 2 e 3, a fim de quantificar e qualificar as variáveis de decisão, integrando múltiplos métodos com revisão teórica de escopo e resultados empíricos, como entrevistas, questionários e observações no Framework, permitindo a triangulação dos dados, aumentando a validade e a confiabilidade dos resultados.

Já a subetapa "6" concentra-se na Análise dos Dados, cabendo ao pesquisador examinar as saídas empíricas em busca de padrões significativos, empregando teorias para uma análise robusta (Yin, 2015). Assim, para os modelos ARIMA e RNA, a análise dos dados foi centrada na avaliação do desempenho preditivo com ajuste dos parâmetros do modelo com base na série

temporal, identificando as tendências e padrões sazonais, avaliando a precisão das previsões por meio de métricas de desempenho.

A escolha dos especialistas foi desmembrada na seção 3.2.1. denominada Grupo Focais.

Como análise de conteúdo, para envolver a sistematização e interpretação de informações textuais (Yin, 2015), ocorreu também a verificação da consistência dos valores das matrizes durante o uso do AHP, além da avaliação sistemática com a análise de sensibilidade dos resultados de todos os MCDMs empregados e avaliação do framework por especialistas.

Já nas abordagens MCDM a análise envolveu a construção de matrizes de comparação para os critérios estabelecidos, permitindo a obtenção de pesos relativos e a hierarquização desses critérios no método AHP. Nos métodos da família MOORA, por sua vez, foi necessário a normalização dos dados, a determinação de pesos relativos e a aplicação de fórmulas específicas para avaliação, descritas no capítulo de resultados empíricos. Já no método Borda a análise ocorreu na contagem individual as alternativas.

Macro etapa 4:

A última Subetapa "7" é denominada "Relato dos Resultados", sendo vital para apresentar os achados de forma clara e coerente, seja por meio de narrativas expressando as descobertas em termos acadêmicos ou práticos, além da necessidade de evitar o erro em não identificar um público específico (Yin, 2015).

Logo, finalizando o roteiro, foram destacadas as conclusões derivadas do Framework proposto, evidenciando como as preferências influenciaram o ranqueamento final, com gráficos e tabelas para facilitar a compreensão dos resultados, tornando o relato acessível a qualquer público.

3.2.1. Grupo focais

Os grupos focais são uma forma estendida de entrevista em grupo com discussão aprofundada, de forma estruturada e organizada, com a ajuda de um facilitador explorando tópicos pesquisados (Gundumogula e Gundumogula, 2020).

A estrutura do grupo focal deve englobar não apenas o pesquisador, mas também os participantes, o contexto e a formulação das perguntas de acordo com os propósitos do grupo de discussão. Além disso, o tamanho do grupo focal pode ser ajustado de acordo com os objetivos da pesquisa e deve ser selecionado com cuidado, escolhendo pessoas adequadas (Muijeen e Kongvattananon, 2020).

Os participantes do grupo devem ser indivíduos selecionados, pela experiência ou conhecimentos sobre o assunto específico e que possam contribuir com informações sobre o tema pretendido (Gundumogula e Gundumogula, 2020).

Desta forma, foi elaborado o primeiro encontro com decisores do grupo. O superintendente do departamento foi convidado a participar. Nessa reunião o tema da pesquisa foi discutido e a definição do quantitativo de pessoas envolvidas.

Por esse motivo, para orientar a pesquisa, foram selecionados indivíduos com diferentes níveis hierárquicos e de conhecimento, incluindo um gerente, um supervisor e dois técnicos para atuarem como decisores e uma pesquisadora na figura da analista da mesma empresa de manufatura, que neste caso é a própria autora da dissertação e gerente do NPCM - Núcleo de Programação e Controle da Manutenção.

Todos os especialistas ouvidos e a analista possuem um mínimo de 10 anos de atuação na empresa, exibido na Tabela 6.

Entrevistado	Qualificação	Duração da reunião (h)	Objetivo
Gerente	Engenheiro eletrônico 16 anos de empresa	01:45	Definir a pesquisa, impressoras e critérios
Supervisor	Engenheiro eletrônico 12 anos de empresa		
Técnico 1	Engenheiro eletrônico 12 anos de empresa		
Técnico 2	Engenheiro eletrônico 36 anos de empresa		
Analista	Analista de TI – Gestão 22 anos de empresa		

Tabela 6: Grupo focais

A quantidade de participantes do grupo foi escolhida nesse quantitativo pois em MCDM, muitas vezes empregam amostras não probabilísticas por conveniência, uma vez que a amostra seleciona participantes com base na disponibilidade, facilitando a formação rápida do grupo (Freitag, 2018).

Para dar continuidade a pesquisa, a coleta de informação foi iniciada com três etapas: definição do problema; identificação de critérios e identificação de alternativas (Saaty, 2004). Como primeira saída dessa reunião inicial de grupo focal, foi possível definir o processo decisório com as alternativas e consensuar os critérios com suas funções de priorização relatando se são critérios que a gestão deseja maximizar ou minimizar, formando a estruturação do modelo, uma vez que um dos momentos mais importante com relação a decisão multicritério é a escolha dos critérios a serem ponderados e avaliados (Goes, 2017).

Foram discutidos sobre a totalidade de impressoras que passariam pelo estudo, já que o número de impressoras da fábrica analisada era extenso. Assim, foi acordado a limitação da quantidade e que estas seriam apenas as impressoras que geram mais horas com manutenção corretivas. Como alternativas, a pesquisa resultou em quatro (04) tipos de impressoras, três *offset*, uma serigráfica e quatro calcográficas, além de seis (06) critérios.

Como instrumento de pesquisa os temas pesquisados rodearam a análise das 13 categorias de indicadores de desempenho que medem os efeitos da Manutenção inteligente (Lundgren *et al.*, 2021), entre elas desempenho, custos, segurança, eficiência energética, entre outros.

O item eficiência energética foi descartado, pois somente os prédios individualmente possuem a medição de consumo de energia. Os ativos físicos, até a data da pesquisa não possuíam pontos de medição de energia para revelar a eficiência energética da manutenção por equipamento.

Ao todo foram feitos 2 (duas) rodadas de encontros com o grupo. A análise de resultados foi feita de forma manual usando a técnica de Análise de Conteúdo ao definir o objeto do estudo, efetuar a pré-análise com organização de materiais coletados e leitura exploratória sobre o tema. Na sequência foi efetuada a categorização das alternativas e critérios, interpretação e a apresentação das descobertas (Mozzato, 2011).

O resultado foi validado e exibido na seção dos resultados empíricos. Durante todo o tempo que durou a pesquisa, a autora dessa dissertação que tem 23 anos de empresa, atuou como moderadora guiando as discussões, assegurando que todos os participantes tivessem a oportunidade de expressar suas opiniões e argumentos de maneira equitativa, além de efetuar a gestão de conflitos (Azeredo, 2016), permitindo que as decisões fossem tomadas de maneira informada e colaborativa.

3.2.2. Entrevistas

As entrevistas são uma ferramenta valiosa para obter informações detalhadas e ricas sobre o fenômeno estudado, permitindo que o pesquisador explore perspectivas, experiências e opiniões dos participantes envolvidos no caso. Com o uso delas, é possível obter informações precisas e confiáveis para alcançar conhecimento sobre os assuntos sob investigação (Yin, 2015).

Ainda, segundo Yin (2015) as entrevistas desempenham um papel crucial como fonte vital de informação no processo de condução do Estudo de Caso.

Quatro meses após a reunião de formação do grupo de trabalho, ocorreu a entrevista com os quatro decisores definidos durante a reunião de montagem do grupo focal. A duração foi registrada na Tabela 7.

Entrevistado	Duração da entrevista(h)	Objetivo
Gerente	01:02:00	Preenchimento da matriz de comparação cada critério
Supervisor	00:35:00	
Técnico 1	00:55:00	
Técnico 2	01:20:21	

Tabela 7: Entrevistas

Desta forma, a partir das respostas obtidas na aplicação das matrizes de avaliações de priorizações dos decisores, foi demandado que os tomadores de decisão avaliassem os elementos em comparações aos pares dentro de cada nível, designando pesos relativos a essas comparações, manifestando suas preferências (Heymann *et al.*, 2023). Utilizando o software da Microsoft Excel, cada decisor foi entrevistado de forma individual em quatro dias na mesma semana. As informações estão disponíveis no Apêndice 2 e 3 e foram guardadas para serem lidas no framework em Python durante o estudo de caso. A razão para usar a planilha do Excel para coletar dados é dupla: os gerentes e técnicos já estavam familiarizados com os pacotes do Office e os custos de aquisição de licenças são baixos (Salzano *et al.*, 2023).

3.2.3. Análise de dados, com abordagens quantitativas e qualitativas entre MCDM e ML

À medida que a tecnologia da informação se consolida e o cenário de análise de dados se amplia, observa-se uma redução no interesse por abordagens de MCDM dependentes de julgamentos intuitivos. No entanto, é indiscutível que as técnicas de MCDM continuam desempenhando um papel crucial no embasamento da tomada de decisões orientada por dados (Yalcin *et al.*, 2022).

Conforme Yin (2015) a análise de dados em estudos de caso, envolve organização, interpretação e apresentação dos dados e Sahoo e Goswami (2023) indicam que a fusão de técnicas de IA e ML pode aprimorar abordagens de MCDM. Recomenda-se ainda utilização de métodos objetivos ou a combinação de abordagens subjetivas e objetivas para analisar abrangentemente o processo de avaliação do peso dos critérios (Mudashiru *et al.*, 2021).

Essas integrações de análise de dados, MCDM e IA oferecem vastas oportunidades para investigações em estudos futuros. Assim, o propósito é otimizar os métodos existentes e conceber novas abordagens, buscando alcançar resultados mais eficientes (Mudashiru *et al.*, 2021). Nesse contexto, as disciplinas foram unidas neste estudo de caso para aprimorar os modelos decisórios na empresa de manufatura, uma vez que, a exploração do potencial de algoritmos de IA e ML, como RNA, algoritmos genéticos e aprendizado por reforço, no contexto do MCDM, pode conduzir ao desenvolvimento de sistemas de apoio à decisão mais eficazes e precisos (Sahoo e Goswami, 2023).

Após a definição dos grupos focais e entrevistas, a pesquisa desenvolveu o modelo de previsão clássico ARIMA e a técnica de ML - RNA. Isso visou capacitar os decisores, com o apoio da moderadora da pesquisa, a realizar análises do grande volume de dados coletados relacionados ao histórico de manutenções das alternativas de impressoras. Esse processo resultou em uma análise descritiva e preditiva. A análise preditiva é a próxima etapa no aprendizado da análise descritiva e responde ao que pode acontecer (Yalcin *et al.*, 2022).

3.2.4. Aplicação dos métodos no Framework

No estudo de caso, o desenvolvimento do framework transcorreu por 3 etapas distintas, uma vez que as informações aprendidas durante a fundamentação teórica ofereceram uma estrutura robusta para o desenvolvimento, implementação e avaliação do framework.

Foi necessária estrutura lógica para vincular de maneira coesa os dados empíricos às questões de pesquisa iniciais e, por último, às suas conclusões, pois a sequência proporciona uma orientação clara, conectando todos os elementos do processo de pesquisa, desde a coleta de dados até a interpretação final (Yin, 2015), estruturando em três fases cruciais: Definição, Aplicação e Resultados.

Na fase inicial de Definição, o framework estabeleceu claramente seu escopo, objetivos e fundamentos teóricos, identificando necessidades e metas a serem abordadas. Para Yin (2015) esta definição deve limitar o escopo da pesquisa. Diante desta configuração, na etapa de Aplicação, o framework foi implementado em Python, traduzindo diretrizes teóricas em elementos práticos, sendo submetido a testes de consistência para garantir eficácia em cenários reais.

A pesquisa seguiu a observação direta, uma técnica prevalente em estudos de caso devido à sua implementação no ambiente real. Essa escolha visa proporcionar uma coleta de dados enriquecedora e contextual, conforme

ênfâtizado por Yin (2015), que destaca a observaão direta como uma ferramenta vital para capturar insights que refletem a complexidade do mundo real.

Na fase de Resultados, a atenão voltou-se para a avaliaão e anlise dos impactos do framework, utilizando a avaliaão com os especialistas.

Como parte da abordagem na fase de Definião, empregou-se os modelos de previso ARIMA e RNA, alm do mtodo de alocao de pesos com deciso em grupo AHP-AIP; mtodos de ranking com agregao aditiva utilizando o mtodo MULTIMOORA; e finalizando com o mtodo ordinal Borda, proposto por Jean Charles de Borda no sculo XVIII. Para complementar a pesquisa, implementou-se anlise de sensibilidade para testar a confiabilidade dos resultados. (Wieckowski e Saabun, 2023). Essas estratgias aprimoraram a fundamentao te3rica e a aplicao prtica do framework e foram compiladas no Apndice 4, sendo reunidas as informaoes sobre a estrutura de deciso metodol3gica em forma de uma rvore de deciso. Essa representao visual e sequencial delinea um percurso a ser seguido durante um processo decis3rio, detalhando as etapas necessrias para atingir o prop3sito desejado (Gomes, 2014).

4 Resultados Teóricos

Este capítulo apresenta os resultados teóricos obtidos por meio da revisão bibliográfica e análise de estudos existentes sobre o tema MCDM e sua aplicação. O capítulo está organizado em três seções: Na primeira seção é exibida a Análise Bibliométrica para identificar tendências, padrões e lacunas. A Análise Descritiva é descrita na seção 4.2 para apresentar as características dos dados pesquisados e Análise de Conteúdo na seção 4.3 para atingir uma compreensão abrangente e aprofundada do estado da arte da pesquisa dentro do o MCDM.

4.1 Análise bibliométrica

Para destacar a tendência sobre a combinação dos temas MCDM e ML ao longo dos anos, todos os 370 documentos únicos encontrados na revisão de escopo, apontados na seção de Revisão de Escopo desta dissertação, foram exibidos ao longo do tempo. Logo, pode ser visto na Figura 4, a combinação dos termos crescendo ao longo dos anos. No exercício corrente de 2023, já foram 30 documentos publicados até a data da busca (31 de março de 2023).

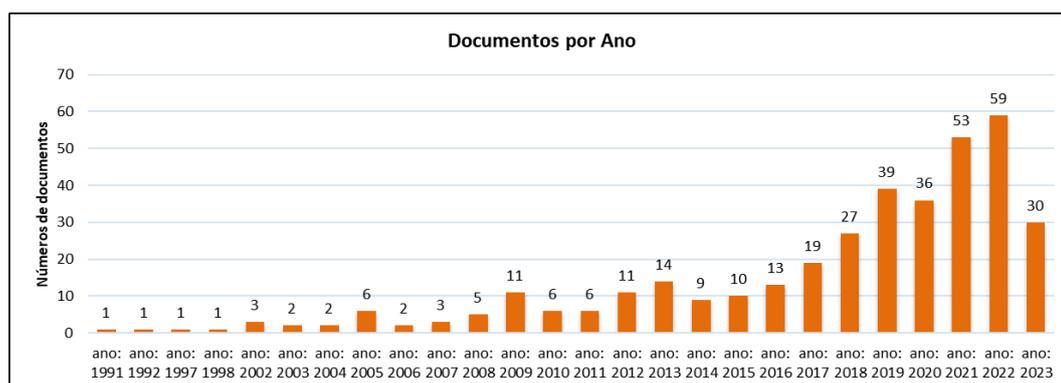


Figura 4: Número de documentos publicados ao longo dos anos

Fonte: Autoria própria

No gráfico ainda é possível observar que os 5 últimos anos de publicações correspondem a 59% da totalidade de documentos, reforçando assim a relevância atual e crescente do tema.

Entre os documentos levantados, foi realizada análise explorando a porcentagem de documentos por tipo de publicação em destaque, representada

na Figura 5. O gráfico expõe que 49% são de periódicos, 43% são documentos de conferências e 8% representam capítulos de livros, revisão e demais documentos como itens em fase de correção e/ou artigos de anais de eventos.

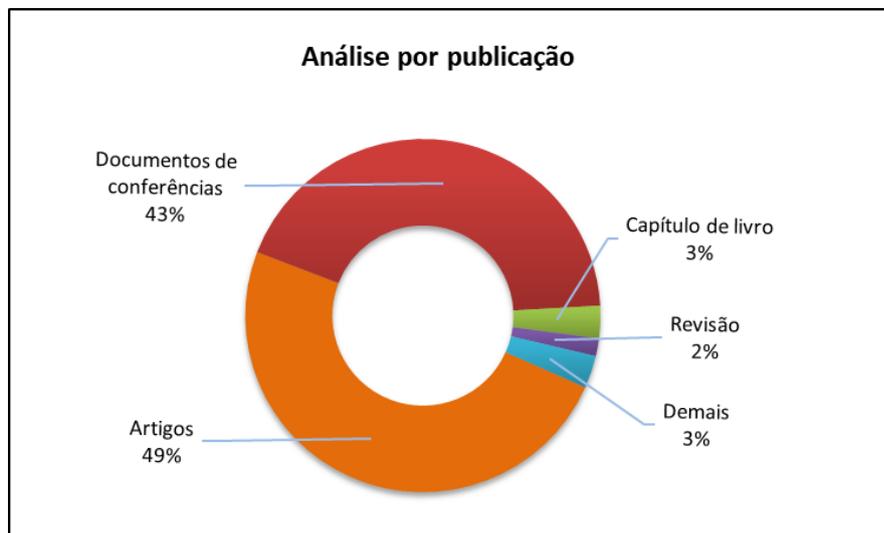


Figura 5: Documentos por tipo de publicação

Fonte: Autoria própria

A Figura 6 destaca as publicações, exibindo os 10 periódicos mais frequentes. O “*Advances In Intelligent Systems And Computing*” é o periódico que apresenta mais publicações, contabilizando 9 publicações e *Journal of Cleaner Production*, com 6 documentos.

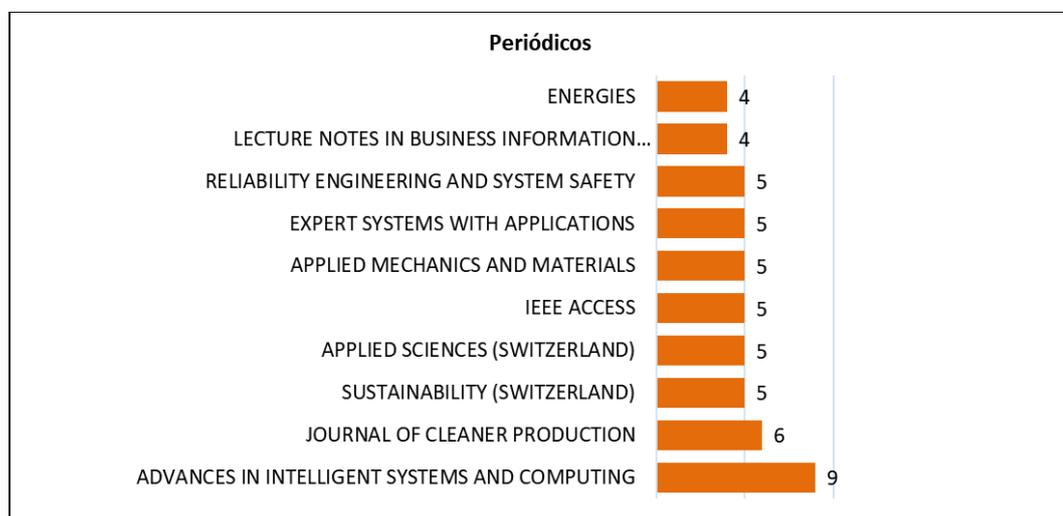


Figura 6: Publicações associadas aos documentos da amostra de estudo

Fonte: Autoria própria

Logo, o entendimento acerca do desempenho das publicações assume um papel de extrema relevância, pois orienta as principais fontes de publicações e a bibliometria é uma análise estatística e uma ferramenta quantitativa para estudar essas publicações existentes (Liu e Duffy, 2023).

O gráfico da Figura 7 concentra os 10 trabalhos com mais citações apresentadas na base Scopus no dia 31/03/2023, mensurando assim, o alcance do tema. Destacando-se Rajput e Singh (2019) liderando com 274 citações, seguidos por Mourtzis e Vlachou (2018) com 149, e Aminyavari *et al.* (2014) com 140, enriquecendo significativamente o panorama acadêmico da temática.

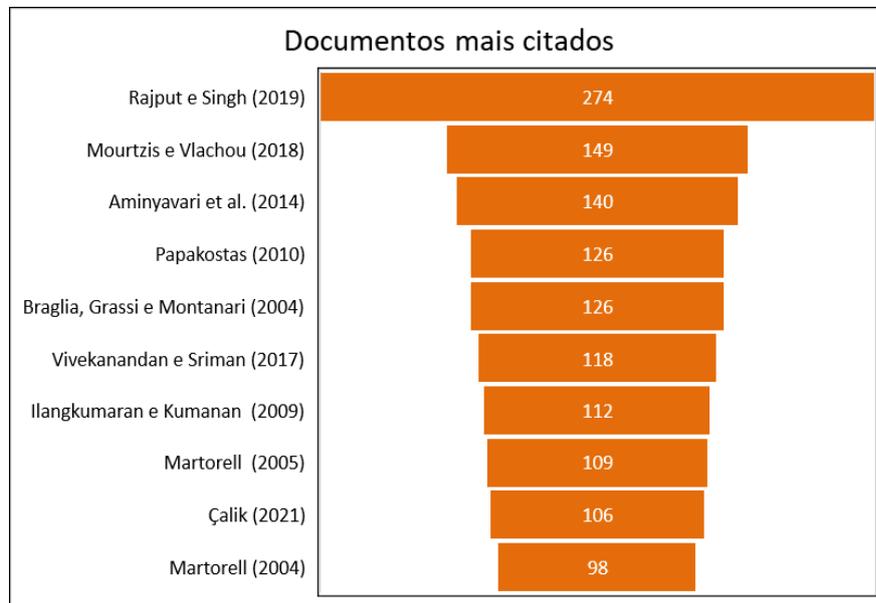
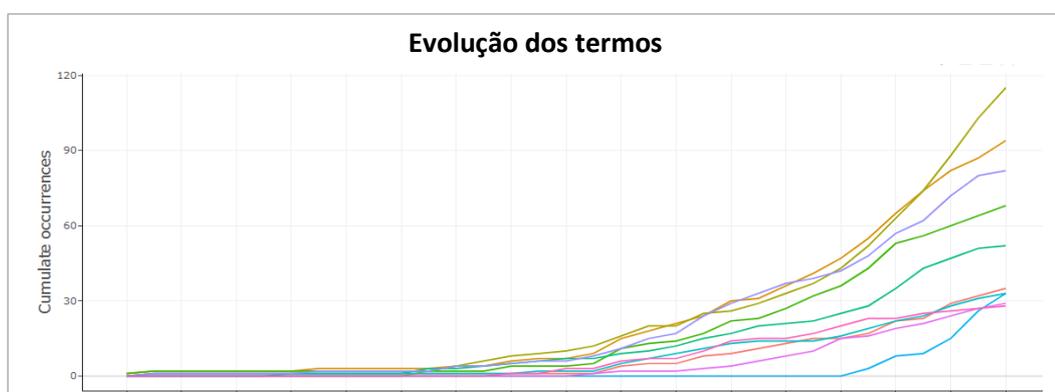


Figura 7: Trabalhos em destaque com maior quantidade de publicações

Fonte: Autoria própria

O gráfico da figura 8 foi desenvolvido com o uso do software *VOSviewer* para ler a base gerada no *RStudio*. No gráfico é possível ver a escalada crescente ao longo dos anos, após o software analisar por palavra-chave.

Os termos *Artificial Intelligence*, *decision making*, *decision suporte system*, *geral algorithms*, *Hierarchical systems*, *industry 4.0*, *maintenance*, *multiobjective optimization* e *optimization*, surgem dos termos da língua inglesa, sendo em português IA, tomada de decisão, sistema de suporte à decisão, algoritmos gerais, sistemas hierárquicos, I4.0, manutenção, otimização multiobjectivo e otimização, respectivamente.



estudos. Foi possível evidenciar a escassez de pesquisas que abordam a integração entre os métodos de MCDM e o ML em estudos de caso.

4.2 Análise descritiva

Na presente dissertação, buscou-se explorar e analisar diretamente as contribuições e perspectivas específicas dos autores em relação ao tema em questão, visando servir de checagem de lacunas e posteriormente de base para aplicação.

Portanto, a Tabela 8 resume algumas características dos modelos de decisão propostos pelos 14 documentos selecionados na seção de revisão de escopo. Estão exibidos os autores, incluindo os métodos e o modelo de ML empregado, uma vez que para resolver a tarefa de previsão, a tecnologia de aprendizado de máquina está sendo cada vez mais frequente, e a literatura fornece evidências da eficácia dos modelos de previsão baseados em ML (Leukel *et al.*, 2021).

	Métodos utilizados	ML utilizados	Referência	Aplicação
1	TOPSIS	SVM, Naive Bayes e Decision Tree	Gorski <i>et al.</i> (2022)	O TOPSIS faz ranqueamento inicial, e se as pontuações do ranqueamento das alternativas forem próximas, utiliza-se o ML para uma classificação mais precisa.
2	Fuzzy-AHP	RNA	Sharma e Rai (2021)	Seleção de metodologia de análise de confiabilidade humana adequada para manutenção de sistemas reparáveis.
3	TOPSIS	Gradient Boosting, Lasso, Ridge, Random Forest, Elastic Net, Neural Network e Multiple Linear regression	Mahpour e El-Dirab (2022)	Uso dos ML para encontrar políticas de manutenção ótimas em uma rede rodoviária
4	AHP	Algoritmo genético	Ismail <i>et al.</i> (2023)	Combinaram os métodos para programação de manutenção de geradores de usinas hidrelétricas.
5	<i>Dominant Analytic Hierarchy Process</i>	RNAs (Multilayer perceptron - MLP)	Fabianowski, <i>et al.</i> (2021)	A precisão do modelo RNA foi verificada comparando os resultados fornecidos com os resultados obtidos usando o modelo agregado AHP para avaliação da condição de pontes
6	AHP	Algoritmo genético	Zhou <i>et al.</i> (2020)	Analisaram estruturas de energia eólica offshore

	Métodos utilizados	ML utilizados	Referência	Aplicação
7	AHP	K-means e Decision Trees and Rede neural	Ouah (2019)	Avaliação do risco de defeito de dutos
8	Poisson não homogêneo	<i>Boolean Decision Tree</i> (BDT)	Dhanisetty <i>et al.</i> (2018)	Combinaram os métodos para efetuarem processos operacionais de manutenção aplicada a um caso de dano de flap externo de Boeing 777
9	Ferramenta Simulink do Matlab	Algoritmo genético	Sachdeva <i>et al.</i> (2018)	Apresentam um framework para otimização do cronograma de manutenção preventiva de componentes.
10	VIKOR e AHP	Algoritmo genético RNA	De Paula Vital (2022)	Estrutura de suporte à decisão para gerenciamento de estoque.
11	AHP	Reinforcement learning	He <i>et al.</i> (2021)	Sistema de suporte multicritério baseado em aprendizado de reforço profundo para otimizar o processo químico têxtil.
12	VIKOR	Rede neural multicamada perceptron	Bashiri <i>et al.</i> (2012).	Pesquisaram problema de otimização multi-resposta usando rede neural artificial e PCR-VIKOR.
13	AHP	Rede neural artificial	Fabianowski, <i>et al.</i> (2021)	Desenvolvimento de RNA para avaliação da condição de pontes com base no método híbrido de tomada de decisão.
14	TOPSIS	Rede neural artificial	Martyn e Kadziński (2023)	Empregou aprendizagem de preferência profunda para análise de decisão de múltiplos critérios.

Tabela 8 – Métodos descritos nos documentos analisados

Na tabela 8 é possível destacar que dois documentos, (15%) dos estudos combinaram duas ou mais técnicas nos modelos de decisão. Dentre essas, o método AHP aparece em ambas e em mais cinco outras publicações, totalizando 62% dos documentos que aplicaram MCDM e ML. Com base nos modelos de ML, quatro documentos combinaram dois ou mais modelos de ML, totalizando 31%. As RNAs foram os modelos mais recorrentes em oito das publicações. Desta forma, algumas características dos estudos que servem para orientar o estudo de caso foram encontrados, como: AHP sendo amplamente empregado, o direcionamento para seleções em indústrias, bem como o uso do método MOORA e a transformação digital norteando os estudos.

4.3 Análise de conteúdo

Analisando os conteúdos, no contexto da I4.0, a automação de processos e a manutenção preditiva desempenham um papel eficaz (Gorski *et al.*, 2022).

Também foi descoberto que, para direções de pesquisas futuras é necessário propor algoritmos de aprendizagem de preferência neural para outras abordagens MCDM intuitivas (Martyn e Kadziński, 2023).

Nesse contexto, o MCDM forneceu muitos métodos para estabelecer uma abordagem sistemática para a tomada de decisões de manutenção (Martyn e Kadziński, 2023). Assim, focando em ML e MCDM, nos 14 documentos selecionados é esclarecido que o ML não é a única ferramenta de classificação e que métodos com menores custos computacionais podem ser utilizados, como é o caso do MCDM (Gorski *et al.*, 2022). Além disso, as RNA são consideradas um potencial ferramental de apoio ao processo de tomada de decisão (Fabianowski *et al.*, 2021). Sobre seu uso, o elemento básico da rede é o neurônio, a partir do qual é construída uma estrutura perceptron multicamadas, formando um conjunto de camadas totalmente interconectadas. Cada neurônio da n -ésima camada é conectado a cada neurônio da $n + 1$ permitindo a transmissão de dados pela rede, da camada de entrada para a de saída através das camadas ocultas (Fabianowski *et al.*, 2021).

Sobre os modelos de predição, a seleção de características é um dos principais desafios de ML, pois foi observado que a ausência ou presença de certas características pode causar baixo desempenho em algoritmos de ML (Gorski *et al.*, 2022). Esse processo pode ser classificado como supervisionado, não supervisionado ou por reforço. O aprendizado supervisionado usa dados de entrada e a saída esperada são de dados rotulados. O sistema faz previsões iterativas e aprende conforme se ajusta automaticamente à saída esperada. Portanto, neste método, o usuário indica o que deve ser aprendido a priori pelo sistema (De Paula Vidal *et al.*, 2022).

Já Mahpour e El-Diraby (2022) esclarecem que algoritmos genéticos se referem a métodos de otimização baseados em processos inspirados na evolução genética. Esses algoritmos são utilizados para resolver problemas complexos.

Outro método de predição que pode ser empregado combinado com MCDM é o *Reinforcement Learning* que é uma estrutura bem compreendida e matematicamente fundamentada sendo amplamente aplicada para lidar com questões práticas de otimização e tomada de decisão (He *et al.*, 2021).

Outro modelo de aprendizado de máquina que pode ser utilizado é o SVM. Os SVMs mapeiam os dados no espaço, onde tentam encontrar de forma iterativa um hiperplano de separação com margem máxima e é originalmente desenvolvido para classificação supervisionada (De Paula Vidal *et al.*, 2022).

Gorski *et al.* (2022) pontuaram que os modelos de ML têm alto custo de operação enquanto o MCDM, tem um baixo custo computacional em comparação com o ML.

Sobre MCDM, Bouchaala e Nouredine (2019) comparou os métodos PROMETHEE e TOPSIS para priorizar equipamentos críticos em um complexo de gás. Assim (Bouchaala e Nouredine (2019) e Seiti *et al.* (2019) demonstram a utilidade dos métodos MCDM no gerenciamento de manutenção para priorizar as atividades de manutenção e selecionar as estratégias de manutenção mais econômicas.

Para a combinação dos métodos de ML foram encontrados os 14 documentos listados na Tabela 08 desta dissertação. Porém, nesta perspectiva, não foram encontrados nenhum documento focado na combinação de MCDM combinando ML para decisão na manutenção industrial.

Após analisar os estudos, é possível dizer que métodos de aprendizado de máquina são úteis para manutenção preditiva, ou seja, no gerenciamento de operações de máquinas com base em dados coletados por sensores (Gorski *et al.*, 2022). Nos estudos lidos, foram encontradas diversas oportunidades de pesquisas relacionadas a esse tema, dado que o ML, devido às suas propriedades de aprendizado, podem reconhecer padrões nos dados e prever, com alguma precisão, seus resultados futuros, além do MCDM ser um dos procedimentos de otimização de múltiplas respostas podendo ser uma combinação das ferramentas com conceitos estatísticos (Bashiri *et al.*, 2012; De Paula Vidal *et al.*, 2022).

5 Resultados empíricos

No quinto capítulo desta dissertação são apresentados a proposição da aplicação e seus resultados empíricos, apresentando a investigação que se inicia na seção 5.1 com a caracterização da operação e da empresa do estudo de caso em que foi pesquisado e aplicado o Framework de Apoio à Decisão. A seção 5.2 detalha a estrutura do framework proposto destacando as melhorias tangíveis e insights resultantes da implementação do framework pelo grupo focal e o processo decisório na 5.2.1. Na sequência, nas seções 5.3 a 5.7, são apresentados os resultados detalhados de métodos específicos utilizados durante a pesquisa. Isso inclui métodos de previsão (5.3), métodos de alocação de pesos em decisões grupais (5.4), o ranking com agregação aditiva (5.5), o método ordinal (5.6) e a análise de sensibilidade dos resultados é apresentada na seção (5.7). Conclui-se o capítulo com uma avaliação crítica do framework por especialistas na seção (5.8), fornecendo uma perspectiva valiosa sobre a validade e refinamento do modelo proposto.

5.1 Estudo de caso em empresa de manufatura

O estudo de caso ocorreu no Departamento de Manutenção industrial de uma empresa de manufatura. O Departamento é peça fundamental para garantir o pleno funcionamento das instalações e a integridade dos equipamentos utilizados nos processos produtivos da empresa pesquisada, assegurando a infraestrutura, em conformidade com os padrões de qualidade e segurança estabelecidos no Brasil, além de realizar a manutenção preventiva e corretiva de máquinas e equipamentos do complexo industrial que possui em torno de 500 mil m² de área total e de 121 mil m² de área construída. No ano de 2022, o departamento contou com mais de um milhão de reais para gestão da manutenção de todo o parque, de acordo com as informações públicas distribuídas no Relatório de Gestão Anual da empresa.

No caso do Departamento em questão, existe um setor específico com a finalidade de manter os equipamentos industriais e conta com aproximadamente 75 empregados para coordenar e executar as questões relativas à manutenção

mecânica, elétrica e eletrônica dos tipos preventivas e corretivas, os preservando de forma a garantir as capacidades e qualidades de cada equipamento, incluindo o apoio a área de NPCM – planejamento e controle da manutenção.

Alguns desafios econômicos incluem aspectos como otimizar os custos de parada incluindo o equilíbrio entre custos de manutenção preventiva e corretiva, planejamento de recursos incluindo peças de reposição a planejamento de horas extras, além da organização dos riscos financeiros ao sugerirem a substituição de equipamentos antigos.

A empresa, que por razões de confidencialidade não será mencionada explicitamente, desempenha um papel crucial no contexto econômico brasileiro, reconhecida por sua contribuição significativa para o sistema financeiro nacional, desempenha um papel fundamental na produção de meios circulantes, exercendo autenticidade e rastreamento de produtos, controle fiscal, identificação de cidadãos, medalhas e moedas comemorativas, meios postais, documentos de premiação, entre outros documentos.

Sobre os métodos MCDMs os tomadores de decisão careciam de familiaridade com o conceito, dependendo exclusivamente de reuniões conduzidas por meio de discussões informais e registros em atas de reuniões das tomadas de suas decisões.

Seus clientes incluem a Empresa de Correios e Telégrafos - Correios, Tribunal Superior Eleitoral, Secretaria da Receita Federal, Agência Nacional de Telecomunicações, Agência Nacional de Aviação Civil, Conselho Federal de Medicina, Universidade de São Paulo, entre outros.

Cumprir notar que ao longo dos anos, a empresa tem passado por modernizações e adaptações para atender às demandas de certificações ISO: ISO 9001 (Gestão da Qualidade), ISO 14001 (Gestão Ambiental), ISO 45001 (Gestão de Saúde e Segurança do Trabalho) e ISO 15.540 (Segurança Gráfica) e Certificado de Aprovação do Corpo de Bombeiros para funcionamento da empresa.

5.2 Proposição e aplicação do Framework de apoio a decisão

O objeto deste estudo de caso, consiste em uma nova abordagem para combinar os rankings de múltiplos métodos e predição de falhas para auxiliar na seleção de ativos, no que diz respeito à priorização de impressoras de grande porte, devido ao alto custo de implantação de manutenções.

A partir das características do Departamento de Manutenção, o Framework foi proposto em três etapas (Definição, Aplicação e Resultados). A etapa 01 dominou a definição dos objetivos, métodos, modelos e ML, além da escolha dos decisores, critérios e alternativas. Na segunda etapa, foram aplicados o modelo de predição e RNA, e métodos MCDM, incidindo ajustes e ranking final por último, na etapa 03, ocorreu a avaliação dos resultados. Em vista disso, a dissertação integra o descritivo das etapas, conforme Figura 11.

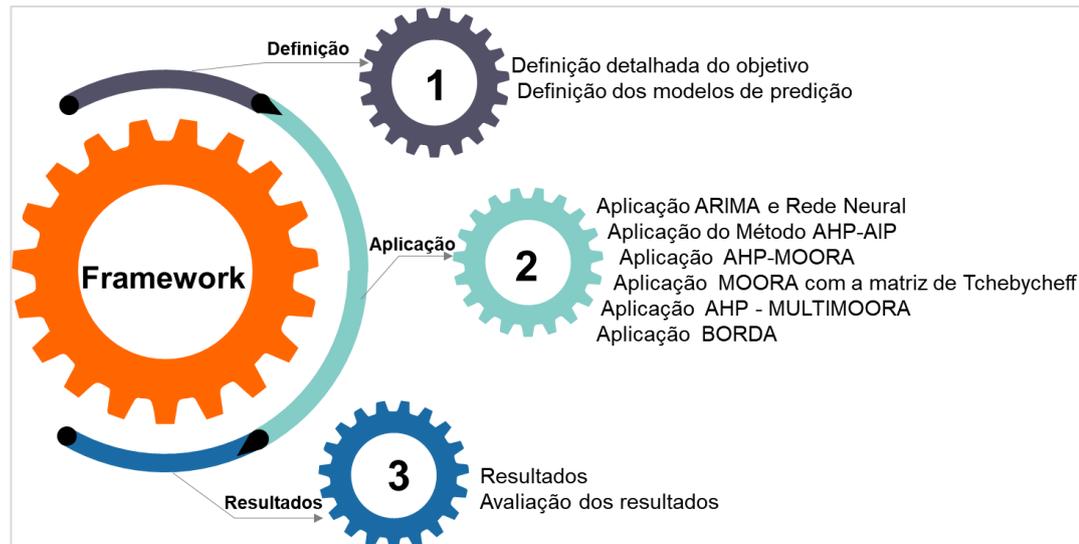


Figura 11: Framework proposto

Fonte: Autoria própria

Devido ao diferencial, descrito por Goes (2017) o estudo de caso empregado nessa dissertação, inicia seus métodos utilizando o método compensatório AHP-AIP (*Aggregating Individual Priorities*). E, dada as características citadas por Liu *et al.*, (2021), a abordagem seguirá com o uso do MOORA, incluindo seus subconjuntos de métodos compensatórios e não compensatórios com abordagem do Ponto de Referência baseada na métrica Tchebycheff Min–Max, como modelo não compensatório e a forma Multiplicativa completa proporcionando a oportunidade de compensar o fraco desempenho de uma alternativa num critério pelos desempenhos noutros critérios (Hafezalkotob, 2019). O framework será finalizado com o método Borda para ordenação final como pode ser observado na Figura 12.



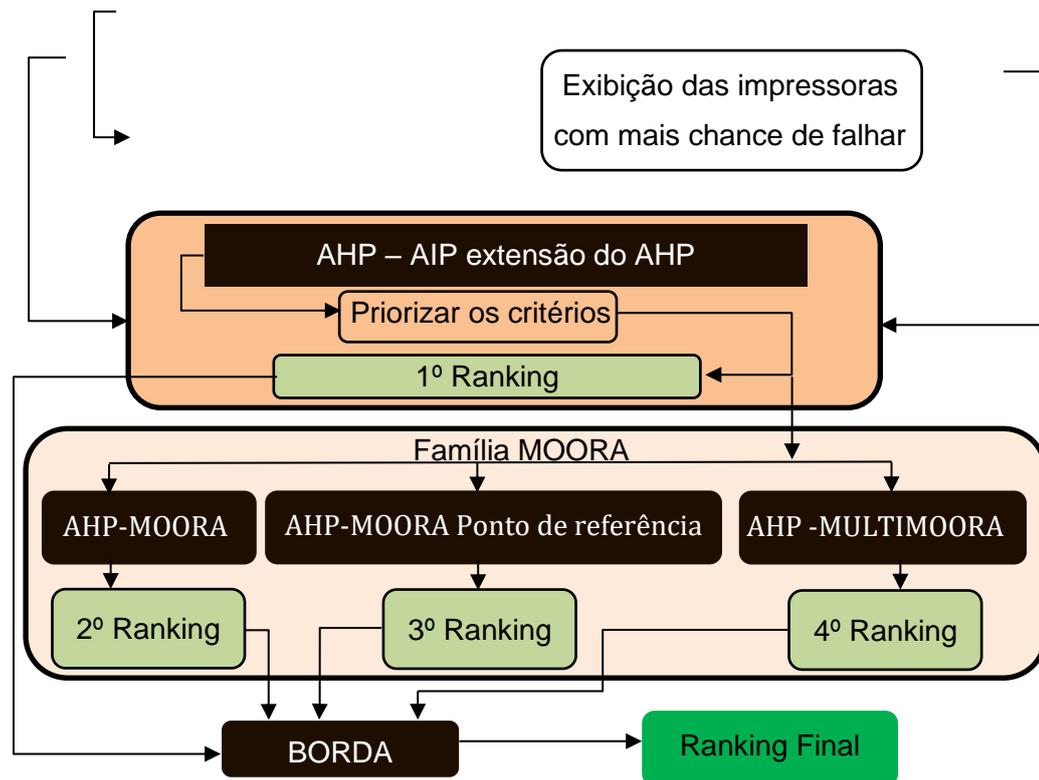


Figura 12: Técnicas empregadas na dissertação

Fonte: Autoria própria

5.2.1. Processo decisório

O trabalho proposto começa com o estabelecimento de critérios e escalas para avaliação. O grupo focal, durante a reunião que durou 01:45min e de forma presencial na sala do gerente de manutenção, chegou ao consenso que os critérios deveriam ser mensurados e definidos de acordo com a planta fabril, observando as normas vigentes e apoiados na literatura. Por esse motivo, as normas ISO 55000 e ISO 45001 fizeram parte da escolha dos critérios.

O grupo apontou também que seria importante para a pesquisa observar os dados de manutenções corretivas das impressoras escolhidas para o estudo. Por esse motivo, os dados foram disponíveis para treinar a rede neural e a predição Arima, e como dado de saída as informações foram empregadas para apoiar aos decisores no momento da entrevista, para escolha dos pesos de entrada do primeiro critério do método AHP e suas análises par a par.

Foram obtidos seis critérios que impactam a escolha das impressoras (Falha, Segurança, Custo, Preventiva e Treinamento e *Overall Equipment Effectiveness* - OEE) conforme apresentados na Tabela 9. O critério inicial foi conduzido pela observação de falhas estudado na série ISO 55000, devido a sua

importância para a manutenção (Da Silva, 2020) em seguida, os demais critérios foram escolhidos. A coluna Tipo representa valores como "Custo" para critérios que representam custos a serem minimizados e "Benefício" para critérios que representam benefícios a serem maximizados, visando a distinção entre critérios com impactos positivos ou negativos no processo de tomada de decisão.

Critério	Descrição	Categoria	Tipo	Origem
Diagnóstico de falha	Refere-se a observação do estado anormal do equipamento. Observando a chance desse ativo falhar no próximo semestre. Está ligado ao desejo de minimizar o tempo gasto de manutenção corretivas	Desempenho de manutenção	Benefício	ISO 55000
Aspectos de segurança	Referem-se as impressoras que possuem mais risco de acidentes. Está ligado ao desejo de maximizar a segurança do profissional.	Performance de segurança	Benefício	ISO 45001:2018 Gestão de Segurança.
OEE	Esse critério concentra-se na eficiência do equipamento ao longo do tempo, alinhado aos objetivos estratégicos da empresa. Está ligado ao objetivo de maximizar a eficiência.	Desempenho de manutenção	Benefício	(Lundgren <i>et al.</i> , 2021).
Custos	Refere-se a observação do impacto financeiro aos custos para efetuar a manutenção corretiva, preventiva ou efetuar um <i>Health Check</i> . Está ligado ao objetivo de minimizar os custos com manutenção	Desempenho financeiro	Custo	
Preventiva	Refere-se ao prolongamento da vida útil das impressoras. Está ligado ao objetivo de maximizar a obrigação das paradas planejadas.	Desempenho de manutenção	Benefício	ISO 55000
Treinamento	Refere-se ao reconhecimento da importância do desenvolvimento e capacitação dos recursos humanos. Está ligado ao objetivo de maximizar investimentos em capacitação para perder a dependência da manutenção junto aos fabricantes.	Investimento complementar	Custo	(Lundgren <i>et al.</i> , 2021).

Tabela 9: Critérios iniciais para entrada dos dados.

Dentre as opções de seleção, as alternativas selecionadas foram as impressoras industriais de grande porte, Impressora Offset 01, Impressora Offset 02, Impressora Offset 03, Impressora serigráfica 01, Impressora calcográfica 01, Impressora calcográfica 02, Impressora calcográfica 03 e Impressora calcográfica 04, totalizando assim, 08 alternativas de impressoras. Cabe ressaltar que em média esses equipamentos apresentam 5 metros de comprimento, 3 metros de altura e 2 metros de largura.

Sintetizando as impressoras, as offset são equipamentos que utilizam processo indireto. A tinta não é aplicada diretamente à superfície de impressão, mas é transferida primeiro para um cilindro intermediário (rolo de borracha) e, a partir daí, para o substrato (normalmente papel). Esse método envolve a criação

de uma imagem espelhada em relação à matriz de impressão. Amplamente empregado na indústria de impressão, especialmente para grandes tiragens como revistas, catálogos e materiais publicitários, o processo offset é reconhecido por sua capacidade de proporcionar alta qualidade, reprodução precisa de detalhes e cores vibrantes, tornando-se uma escolha comum para produção em larga escala (Editora, 2018).

Outra técnica de impressão é a calcografia, sendo definida como a arte da impressão em relevo, utilizando-se de rolos e placas de metal entre outros componentes. Por derradeiro, a última impressora estudada emprega a impressão serigráfica, onde a tinta passa pelas áreas permeáveis e imprime sobre o substrato desejado, podendo ser dos mais diversos tipos de superfície, tais como papel, madeira, metal, tecido, alvenaria, plástico, vidro (Jiménez *et al.*, 2017; Aminger e De Menezes, 2021).

De acordo com o site cromaiberica.com, acessado em 03/05/2023, a impressora serigráfica, tem seu funcionamento de forma totalmente automática por meio de um servomotor, assim como sua carga e descarga de produto. Esta característica a torna muito adequada para instalação em linhas de produção. Para serigrafia com tinta UV, o sistema aplica um tratamento UV LED para pré-secagem antes de aplicar uma nova cor de forma totalmente automática. Também existe a opção de usar tintas *hot melt*, que são tintas termofusíveis sendo sólida em temperatura ambiente, mas que derrete quando aquecida, tornando-se líquida e facilmente aplicável. As impressões possuem elevado padrão de qualidade, podendo incluir elementos de segurança.

Já as impressoras calcográficas tem como base dois rolos para prensar e transportar uma placa metálica sobre a qual é colocada uma placa gravada com tinta. Quando o mecanismo de acionamento é ativado, a pressão exercida pelos rolos, também chamada de pressão de contato, permite que a imagem gravada seja transferida para o papel, obtendo-se assim a imagem final (Jiménez *et al.*, 2017).

A fim de continuar o processo decisório, a Figura 13 mostra a estruturação hierárquica do problema de decisão propostas por Saaty (1987) após a seleção dos critérios e alternativas que deverão ser avaliados para implementar o framework e depois da construção da hierarquia do modelo.

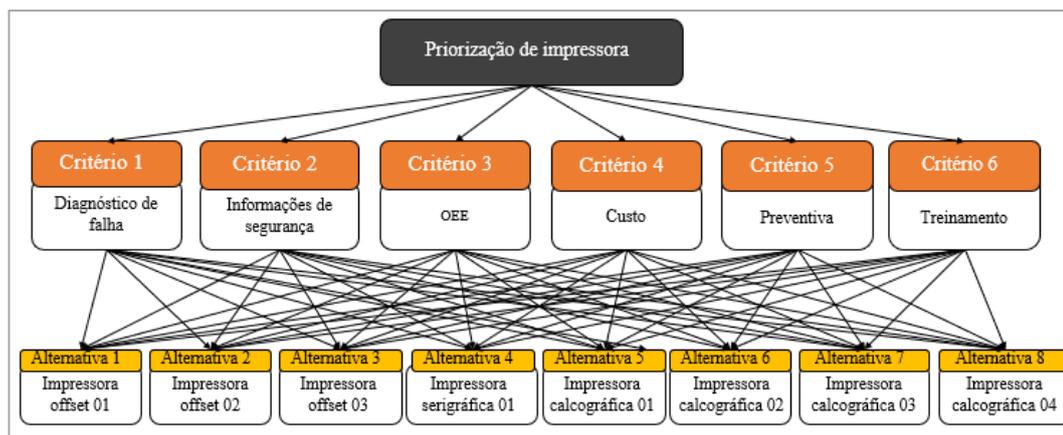


Figura 13 - Estrutura Hierárquica do Problema de Decisão
Fonte: Adaptado de Saaty (1991).

Na pesquisa, foi utilizada a Escala Numérica de Saaty, conforme Tabela 10, para fazer comparações pairadas entre os elementos da hierarquia, quantificando as preferências dos decisores visando ajudar a realizar análises matemáticas que levam a uma hierarquia de prioridades consistente e confiável.

Escala numérica	Intensidade	Descrição
1	Mesma importância	Os dois critérios contribuem igualmente para o objetivo.
3	Importância moderada	A experiência e o julgamento favorecem levemente um critério em relação ao outro.
5	Mais importante	A experiência e o julgamento favorecem fortemente um critério em relação ao outro.
7	Muito importante	Um critério é muito fortemente favorecido em relação ao outro
9	Extremamente mais importante	A evidência favorece um critério em relação ao outro com o mais alto grau de certeza.
2,4,6,8	Valores intermediários	Valores intermediários entre dois julgamentos, utilizados quando o decisor sentir dificuldade ao escolher entre dois graus de importância

Tabela 10 – Escala de comparação par a par para o método AHP

Para calcular a razão de consistência foi utilizado o Índice Randômico (RI) do AHP em função do tamanho da matriz, proposta por Saaty (1987).

Os métodos MCDM escolhidos para aplicação na empresa de manufatura foram os AHP-AIP, AHP-MOORA, MOORA com a matriz de Tchebycheff, AHP - MULTIMOORA e BORDA (Do Nascimento *et al.*, 2023), além dos modelos para predição ARIMA e ML RNA.

A escolha dos métodos AHP e família MOORA se justifica pelo fato de serem métodos do tipo compensatório, permitindo a consideração de múltiplos critérios de forma ponderada e a tomada de decisão mesmo quando há *trade-offs* entre diferentes alternativas, o que é essencial para a complexidade envolvida na

seleção de estratégias de manutenção na Indústria 4.0 e dadas as alternativas e critérios definidos.

Cabe registro que durante o desenvolvimento e aplicação dos métodos não ocorreram contatos com o grupo focal. O desenvolvimento foi sob responsabilidade

Nos métodos de MCDMs, o Método AHP-AIP foi empregado para iniciar o framework com a entrevista dos decisores, determinando os critérios e alternativas, além de priorizar os pesos e ordenar as alternativas com média geométrica com objetivo de obter o ranking 01 das alternativas. Na sequência foi utilizado os métodos AHP-MOORA para descoberta do segundo ranking. No AHP-MOORA com ponto de referência (matriz de Tchebycheff) cada alternativa foi avaliada com base em sua distância em relação aos pontos ideais (melhor desempenho possível). A matriz de Tchebycheff foi então usada para calcular a eficiência de cada alternativa em relação a esses pontos extremos e encontrar a solução que maximiza essa eficiência geral, ou seja, a solução mais próxima do ponto ideal em todos os critérios simultaneamente, findando o Ranking 03 das alternativas. Como quarto método, o AHP-MULTIMOORA foi usado para o último ranking. O método Borda finalizou a pesquisa classificando em ordem os rankings anteriores, suscitando no ranking final, conforme pode ser observado na Figura 12, já apresentada.

Para fazer a descoberta de quais impressoras teriam mais chances de falhar, visando auxiliar os decisores no momento de pontuar os critérios no modelo inicial AHP, nesta pesquisa foi utilizada a rede neural LSTM *Long Short-Term Memory*, que é um tipo especializado de rede neural recorrente usada para previsão em sequências de dados, como séries temporais, além do ARIMA.

Para gerar o framework, o método foi desenvolvido em Python por ser uma linguagem de programação amplamente utilizada e reconhecida por sua versatilidade. Todos os métodos foram desenvolvidos sem o uso de bibliotecas prontas, já que na literatura foi possível encontrar de forma clara a síntese matemática dos métodos, facilitando assim, no futuro que o método com os cinco modelos, torne-se disponível para uso em outras necessidades de decisão, além da reprodutibilidade e transparência da pesquisa científica.

Cabe ressaltar, que todo método foi desenvolvido no Google Colab de forma gratuita e que as bibliotecas prontas utilizadas para base foram as *NumPy*, *Pandas*, *SciPy* e *Scikit-learn*, que oferecem ferramentas poderosas para manipulação de dados, cálculos matemáticos e implementação de algoritmos de tomada de decisão, permitindo economizar tempo na implementação.

Durante a montagem do processo decisório, também ficou definido que o superintendente não seria ouvido durante o ciclo de entrevistas, retornando na pesquisa somente, na etapa de avaliação, descrito na seção 5.8 de Avaliação do Modelo por Especialistas. A decisão foi tomada, uma vez que durante o período das entrevistas, o superintendente estaria usufruindo de seu período de férias.

5.3 Métodos de previsão

Os métodos de previsão ARIMA e Rede Neurais, descritos no seção 2.4 foram os métodos de escolha para observação da série de dados.

Para iniciar a aplicação, as etapas criadas foram:

- Seleção dos dados: Foi possível analisar dados entre os anos de 2018 e 2022, efetuando assim 5 anos de histórico de manutenções corretivas.
- Mineração dos dados: O processo de descoberta de conhecimento em banco de dados, em inglês *Knowledge Discovery in Database* – KDD é a mais tradicional metodologia, para detectar dados e informações armazenadas nas bases de dados, transformando-as em conhecimento, sendo empregado em 5 etapas (Fayyad, 1996). Assim, a etapa 01 de preparação a seleção dos dados foi feita eliminando os atributos irrelevantes ao domínio da pesquisa, desta forma foi utilizada o código `drop("drop(columns=["NUSMA"])` para eliminar a coluna com o número das manutenções corretivas. Na etapa 02 de Pré-processamento, foi feita a limpeza dos dados com a retirada de dados duplicados com o código `df.drop_duplicates(inplace=True)`. A etapa 03 de Transformação dos Dados, foi utilizada para deixar os dados no formato apropriado para a predição, onde os dados foram convertidos em *datetime* com o código `df['Data'] = df['Data'].apply(lambda x: transform_day(x,periodo))`
`df['Data'] = df['Data'].astype("datetime64")`. A etapa 04 de Mineração dos dados foi feita com a análise exploratória das previsões do modelo ARIMA e LSTM, assim como a etapa 05 de identificação dos resultados.

O modelo proposto foi iniciado empregando o modelo de RNAs com algoritmo LSTM para previsão de falha das 8 impressoras.

- Construção do modelo LSTM: Desenvolvido em Python, com uso de pacote pandas e numpy e biblioteca Keras para construção das camadas.

Foi necessário deixar a série estacionária. Além de ser necessário deixar a escala dos dados da série para o intervalo de 0 a 1, para garantir que todos estejam na mesma escala.

- Treinamento do modelo: As montagens das funções foram configuradas para realizar a leitura e pré-processamento dos dados de *input*. Foi utilizado o parâmetro *n_lookback* em RNAs é utilizado para definir o número de etapas anteriores (*lags*) da sequência de dados que serão usadas como entrada para prever o próximo valor. O parâmetro *n_forecast* em RNA foi usado para definir o número de etapas futuras que o modelo irá prever a partir dos dados de entrada.
- Validação e ajuste de hiperparâmetros: Foi utilizado 3 camadas com 50, 50 e 30 unidades com o uso do modelo Keras, que é uma biblioteca popular de aprendizado profundo.
- Teste do modelo: Foi utilizada a função de perda Loss. Loss é uma medida que quantifica o quão bem o modelo está realizando sua tarefa. Na pesquisa, a função de perda utilizada é 'mean_squared_error', que é o erro médio quadrado. Essa função é comumente usada em problemas de regressão, onde o objetivo é prever valores numéricos. O erro médio quadrado mede a média dos quadrados das diferenças entre as previsões do modelo e os valores reais dos dados.
- Para otimização foi utilizado o otimizador optimizer que é um algoritmo que ajusta os pesos e os vieses da rede neural durante o treinamento para minimizar a função de perda. No código, o otimizador escolhido é 'adam'. O otimizador Adam é um método de otimização popular e eficiente que adapta a taxa de aprendizado com base nas estatísticas dos gradientes calculados durante o treinamento. Muitas vezes é usado para manter a estabilidade do sistema (Salem *et. al.*, 2022).
- O número de épocas de treinamento foi estipulado em 200 e tamanho do lote foi configurado para 32. O tamanho do lote refere-se ao número de amostras de treinamento usadas em uma atualização dos pesos do modelo. O modelo foi testado em computador CORE i7. A duração de processamento foi de 03 minutos. Previsão: Foram gerados 8 gráficos, conforme exibidos na Figura 14.

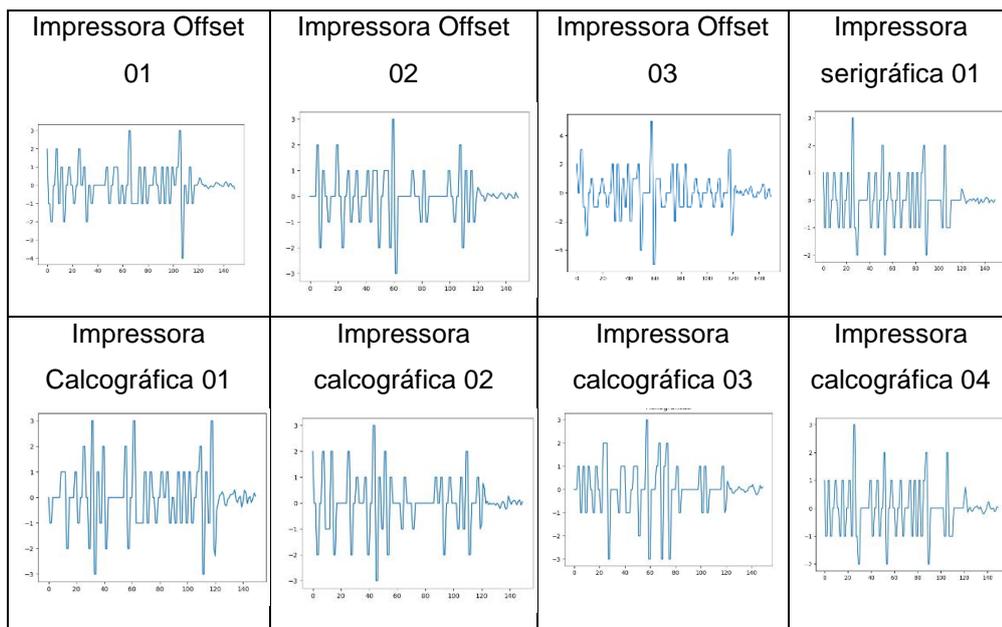


Figura 14: Gráficos RNA

Fonte: Autoria própria

Do mesmo modo, foram feitas 8 rodadas do modelo ARIMA, para previsão das falhas das oito impressoras. As etapas criadas foram:

- Coleta dos dados: os mesmos dados da RNA.
- Construção do modelo ARIMA: Desenvolvido em Python. Uso das bibliotecas *pandas*, *numpy* e *matplotlib*. Uso da biblioteca *statsmodels* para estimar, testar e utilizar uma variedade de modelos estatísticos, incluindo modelos de regressão, modelos de séries temporais. Foi necessário o uso da função para ADF avaliar a estacionariedade das séries temporais. A estacionariedade é uma propriedade fundamental para aplicar o modelo ARIMA, pois o modelo assume que a série temporal é estacionária ou pode ser transformada em estacionária.
- As métricas MSE, RMSE, MAE e MAPE foram utilizadas na avaliação de modelos, pois fornecem uma maneira de quantificar a precisão das previsões em relação aos valores reais da série temporal.
- Análise e visualização dos dados: A Figura 15 mostra a quantidade de falhas por impressoras (a) e gráfico de distribuição facetadas falhas acumuladas (b).

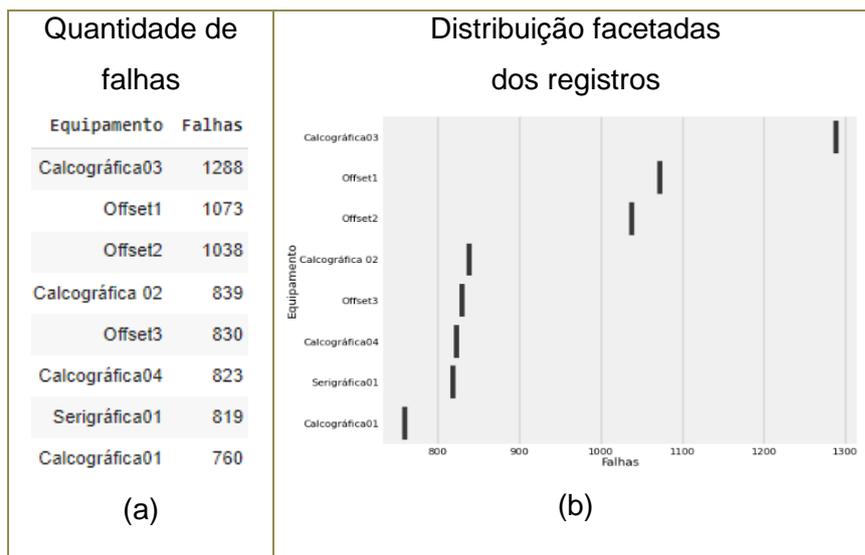


Figura 15: Análise e visualização do banco de dados

Fonte: Autoria própria

Para cada impressora foram feitos o teste de hipótese de para verificação da estacionariedade. Como teste estatístico, se o resultado limite da análise ($p\text{-Value} < 0.05$) o sistema confirma que é uma série estacionaria, ou seja, tem média constante ao longo do tempo e não existe tendências de alta ou de baixa, conforme Tabela 11.

Impressora	p-valor	Interpretação do p-valor
Offset 01	0.097149	Não é estacionária.
Offset 02	2.819657	Não é estacionária.
Offset 03	0.000015	É estacionária.
Serigráfica 01	0.000246	É estacionária.
Calcográfica 01	0.000118	É estacionária.
Calcográfica 02	0.000001	É estacionária.
Calcográfica 03	0.174770	Não é estacionária
Calcográfica 04	0.000914	É estacionária.

Tabela 11: Teste inicial de estacionariedade

As impressoras Offset 01, 02 e Calcográfica 03 precisaram ser estacionárias. Em virtude do resultado, foi efetuado o ajuste nas séries. Logo, após a transformação todas as séries das impressoras passaram a ser estacionárias, conforme Tabela 12.

Impressora	p-valor	Interpretação do p-valor
Offset 01	0.000003	É estacionária.
Offset 02	0.033237	É estacionária.
Offset 03	0.000015	É estacionária.
Serigráfica 01	0.000246	É estacionária.
Calcográfica 01	0.000118	É estacionária.
Calcográfica 02	0.000001	É estacionária.
Calcográfica 03	0.034770	É estacionária.
Calcográfica 04	0.000914	É estacionária.

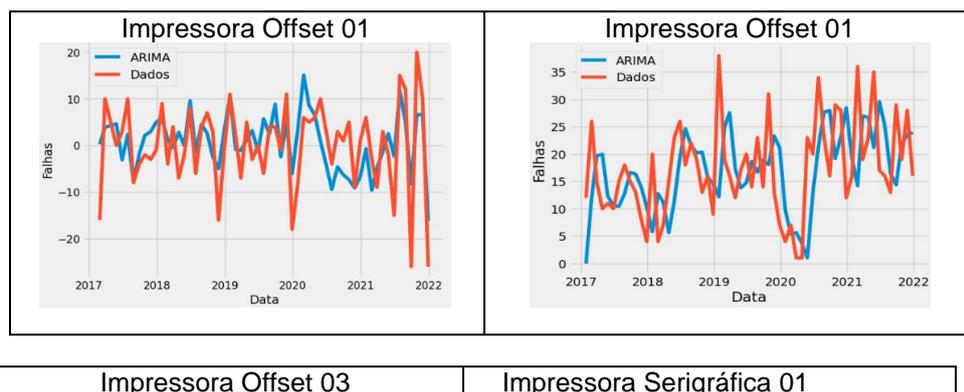
Tabela 12: Valores finais de estacionariedade

Avaliação do ajuste dos parâmetros de avaliação usando a função `auto_arima`, fornecida pela biblioteca `pmdarima` que automatiza o processo de ajuste de um modelo ARIMA, conforme descrito na Tabela 13. Essa função automatiza a seleção dos melhores hiperparâmetros do modelo, utilizando métodos como busca exaustiva, busca por grade e critérios de seleção de modelos (como AIC - *Akaike Information Criterion* ou BIC - *Bayesian Information Criterion*) para encontrar o modelo ARIMA mais adequado.

Impressora	Critérios (p, d q)	Treino do modelo MSE	Treino modelo RMSE	Treino modelo MAE	Treino modelo MAPE
Offset 01	(1,0,2)	230.030	15.166	12.479	0.917
Offset 02	(1,1,0)	89.677	9.469	7.761	0.6304
Offset 03	(1,0,0)	136.8998	11.7004	10.45893	3.49938
Serigráfica 01	(1,1,0)	104.31953	10.21369	8.00963	0.645453
Calcográfica 01	(0,0,1)	47.64082	6.90223	5.44918	0.49140
Calcográfica 02	(1,0,0)	44.19996	6.64830	5.17634	0.47660
Calcográfica 03	(3,0,1)	216.9545	14.72937	11.15133	0.82317
Calcográfica 04	(1,1,0)	73.003	8.544	7.386	0.668

Tabela 13 – Resultado dos parâmetros de avaliação ARIMA

Avaliação do modelo: O modelo foi ajustado para 0.95 de intervalo de confiança. Para cada impressora foram gerados gráficos, conforme imagens da Figura 16.



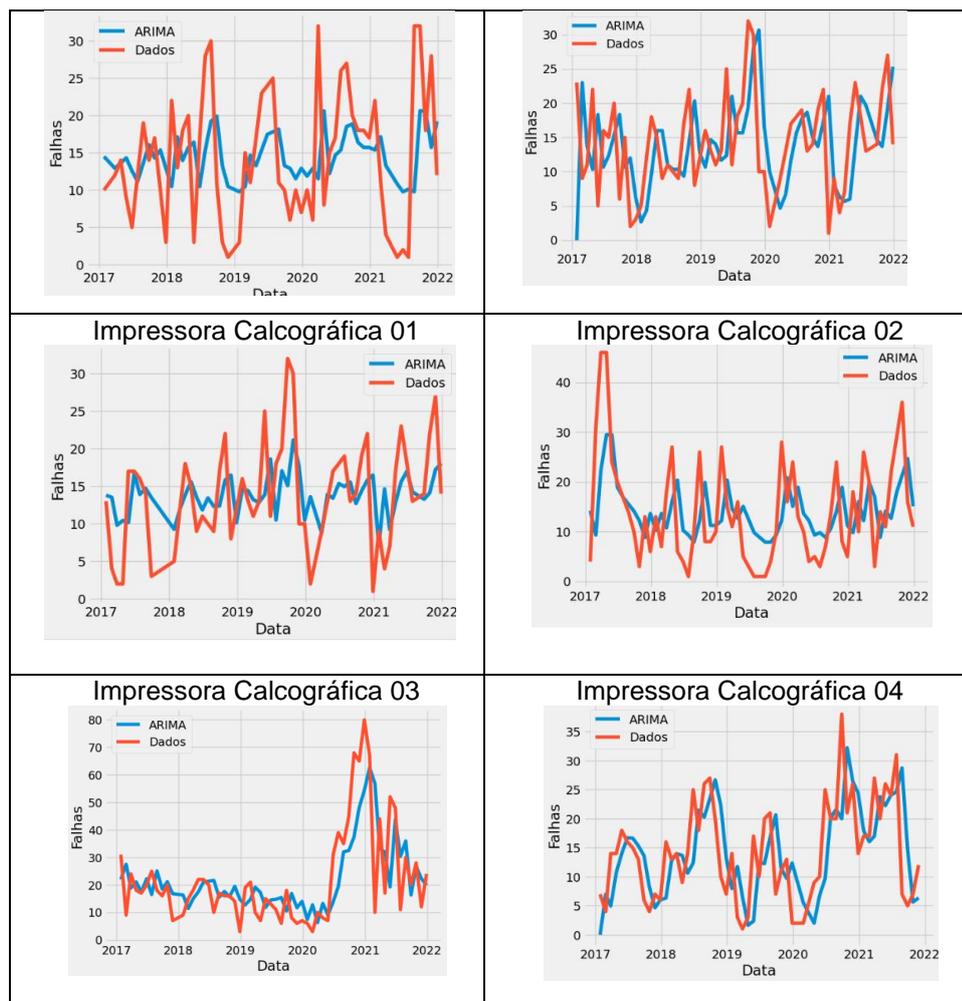


Figura 16: Análise e visualização dos dados históricos ARIMA

Fonte: Autoria própria

Verifica-se que a série de dados é substituída pelas previsões, visando prever a próxima observação o dado real da série deve ser utilizado. A última previsão realizada foi no horizonte de curto prazo, na grandeza de 1 mês. Na Tabela 14 estão exibidos os resultados por impressora.

Impressora	Previsão ARIMA	Em relação à média mensal	Resultado
Offset 01	11.704	-35%	O número de falhas do mês 1 está abaixo da média
Off set 02	16.579	-4%	O número de falhas do mês 1 está abaixo da média
Offset 03	12.207	-12	O número de falhas do mês 1 está abaixo da média
Serigráfica 01	14.130	4%	O número de falhas do mês 1 está acima da média
Calcográfica 01	12.054	-5%	O número de falhas do mês 1 está abaixo da média
Impressora	Previsão ARIMA	Em relação à média mensal	Resultado

Calcográfica 02	11.681	-16	O número de falhas do mês 1 está abaixo da média
Calcográfica 03	26.057	21%	O número de falhas do mês 1 está acima da média.
Calcográfica 04	14.331	4%	O número de falhas do mês 1 está acima da média

Tabela 14: Resultado por impressora

O resultado mostrou que a impressora Serigráfica 1, Calcográfica 03 e 04 ficariam acima da média, demandando desta forma muito tempo da manutenção, podendo ocasionar altas paradas de operação para os produtos produzidos em cada uma das impressoras citadas. Assim o resultado registrado na tabela 14 foi exibida aos decisores para orientar na tomada de decisão.

5.4 Aplicação do método de alocação de pesos

Inicialmente para registrar as comparações pareadas, um formulário de pesquisa usando a ferramenta *Google Form* foi enviado, porém dos 4 decisores somente 2 responderam no prazo. Assim o método de registro das comparações foi alterado para planilha do Microsoft Excel, e então todos os decisores responderam individualmente e dentro do prazo. Ao todo foram geradas 4 planilhas para serem lidas no Python com as comparações, conforme Tabela 15.

Dados dos decisores	Nome da planilha
Gerente	Dados_decisoresGerente.xls
Supervisor	Dados_decisoresSupervisor.xls
Técnico 01	Dados_decisoresTecnico01.xls
Técnico 02	Dados_decisoresTecnico02.xls

Tabela 15: Descrição das tabelas de avaliação no Excel.

Em cada tabela estão contidas 6 guias. A primeira contendo as avaliações da Matriz de Comparação em Pares dos Critérios “Par_critérios”. As demais continham Matriz de Priorização das Alternativas para os critérios “Cr01_Falha”, “Cr02_Segurança”, “Cr03_OEE”, “Cr04_Custo”, “Cr05_preventiva” e “Cr06_treinamento” respectivamente, conforme Figura 17.

<u>Par_critérios</u>	Cr01_Falhas	Cr02_Seguranca	Cr03_OEE	Cr04_Custo	Cr05_Preventiva	Cr06_Treinamento
----------------------	-------------	----------------	----------	------------	-----------------	------------------

Figura 17: Guias de organização das planilhas

Fonte: Autoria própria

Desta forma, as etapas do AHP utilizadas foram descritas na Figura 18, desenvolvida na ferramenta drawio.net.

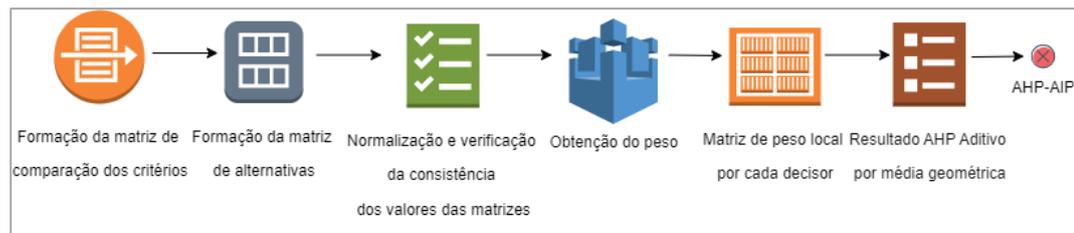


Figura 18: Protocolo do AHP-AIP

Fonte: Autoria própria

Após o entendimento do AHP, foi possível iniciar e gerar a Matriz de comparação dos critérios e alternativas.

Para ajudar nas decisões par a par das alternativas, os decisores receberam os resultados oriundos do histórico de falhas das impressoras.

O primeiro decisor a participar foi o gerente, tendo assim uma participação decisiva com a percepção de gestão. A matriz de comparação é gerada $n \times n$, onde todos os critérios são comparados com os outros, comparando o critério da coluna com cada critério das linhas. Na sequência, todos os demais decisores concluíram o preenchimento de suas matrizes.

Em ato contínuo, foi gerando o método AHP no Python, conforme Figura 19.

De posse das planilhas, com a opinião de todos os decisores, no Python ocorreram a configuração inicial com as importações dos pacotes e criação das funções. Quatro rodadas foram feitas para leitura das planilhas, após a configuração inicial, sendo possível a formação dos pesos dos critérios e ranking final de cada um decisor. Os dados dos pesos de cada decisor foi descrito no Apêndice 3 desta dissertação. Esses dados serão lidos em momento posterior no MULTIMOORA.

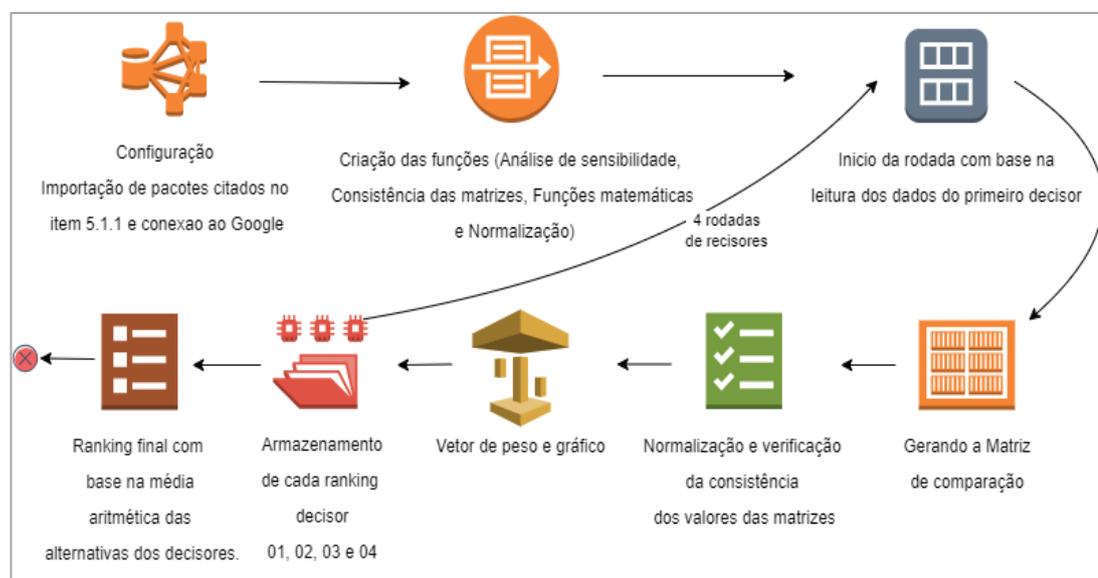


Figura 19: Fluxo do AHP-AIP no framework

Fonte: Autoria própria

Ao final o framework mostrou o ranking final do AHP-AIP com base na média aritmética, como pode ser observado no último item da figura 20.

Um fato importante que ocorreu durante a rodada do decisor 02 foi que o teste de consciência, apresentou dados inconsistentes, ou seja, CR maior que 0,10 e, então foi necessário reavaliar o conteúdo da planilha. Foram encontradas três células que estavam sem dados. O decisor foi chamado para completar os dados, e assim, mais uma vez o modelo foi rodado, sendo possível prosseguir com a pesquisa.

mediaaritmética						
	media aritmetica	RankinDecisor_01	RankinDecisor_02	RankinDecisor_03	RankinDecisor_04	
serigráfica_01	0.331397	0.274765	0.368208	0.341572	0.349024	
calcográfica_01	0.164274	0.213594	0.172281	0.137561	0.143864	
Offset_02	0.113189	0.158150	0.080328	0.151075	0.085524	
Offset_03	0.099364	0.097802	0.149817	0.163958	0.040577	
calcográfica_02	0.090673	0.068301	0.066465	0.072086	0.206553	
calcográfica_03	0.078176	0.074770	0.090938	0.080140	0.068544	
Offset_01	0.052628	0.072470	0.033856	0.035829	0.087266	
calcográfica_04	0.026687	0.040148	0.038107	0.017779	0.018648	

Figura 20: Ranking final do AHP-AIP

Fonte: Autoria própria

5.5 Aplicação dos métodos com agregação aditiva

Visando o problema de otimização multicritério de alternativas discretas, propõe-se o método de otimização multiobjetivo (MOORA). O método contém seis passos (Brauers e Zavadskas (2006).

Embasado na matriz de priorização dos critérios e alternativas do AHP, descritas no Apêndice 2 e 3, foi possível gerar o método, conforme Figura 21, apresentada a seguir.

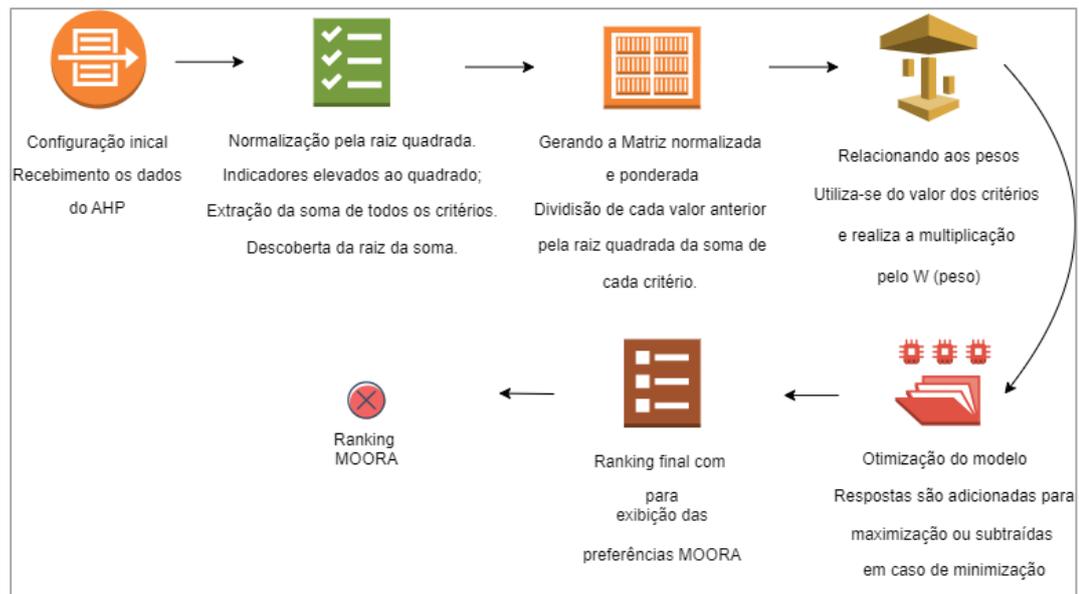


Figura 21: Fluxo do AHP-MOORA no framework.

Fonte: Autoria própria

Para iniciar o MOORA, o Python faz a leitura da média geométrica de todos os decisores oriundos do AHP, formando um único ranqueamento. Nesse momento, as funções de critério podem ser maximizadas ou minimizadas, de acordo com os apontamentos dos decisores durante a montagem do grupo focal.

Critérios de Minimização: Quando um critério é de minimização, significa que quanto menor o valor, melhor será o desempenho da alternativa em relação a esse critério. **Critérios de Maximização:** Quando um critério é de maximização, significa que quanto maior o valor, melhor será o desempenho da alternativa em relação a esse critério. Segundo o fluxo relatado na Figura 22, os dados foram elevados a potência de 2, obtida a soma e a raiz da soma de todos os critérios.

	Cr01_Falhas - MIN	Cr02_Seguranca - MAX	Cr03_OEE - MAX	Cr04_Custo - MIN	Cr05_Preventiva - MAX	Cr06_Treinamento - MAX
calcográfica_01	0.017146	0.019009	0.011862	0.029786	0.018012	0.029667
Offset_02	0.013954	0.010439	0.008799	0.008288	0.017623	0.019760
calcográfica_03	0.005856	0.006458	0.006577	0.006654	0.004943	0.006902
Offset_01	0.138157	0.132322	0.109766	0.140010	0.128812	0.094665
serigráfica_01	0.001546	0.002823	0.000956	0.001819	0.002328	0.002932
calcográfica_02	0.009186	0.010404	0.008211	0.006302	0.004776	0.003965
Offset_03	0.007697	0.005815	0.018535	0.007701	0.007719	0.006966
calcográfica_04	0.000327	0.000318	0.001115	0.000947	0.000837	0.000481
soma	0.193869	0.187586	0.165822	0.201506	0.185050	0.165337
raiz_da_soma	0.039317	0.053129	0.030918	0.042646	0.048251	0.054148

Figura 22: Soma e a raiz da soma para MOORA

Fonte: Autoria própria

Após a realização do peso de cada critério o MOORA foi executado e na Figura 23 é exibido o ranqueamento ordinal das alternativas, mostrando a preferência final do MOORA (Brauers e Zavadskas (2006)).

Ranking MOORA	
Offset_01	4.472046
calcográfica_01	2.008384
Offset_02	1.499078
calcográfica_02	0.973758
calcográfica_03	0.962774
Offset_03	0.884900
serigráfica_01	0.630000
calcográfica_04	0.264837

Figura 23: Ranking MOORA

Fonte: Autoria própria

Para medir a distância entre as alternativas, utiliza-se a métrica Tchebycheff, ajudando assim a classificar e selecionar a melhor alternativa.

De posse da matriz dos dados do MOORA, o método lê esses dados para iniciar o ranking do MOORA – Tchebycheff, observando a referência do critério. Onde caso a descrição indique um critério de Maximização, o código extrai o valor máximo, caso contrário, extrai-se o valor mínimo esclarecido na Figura 24.

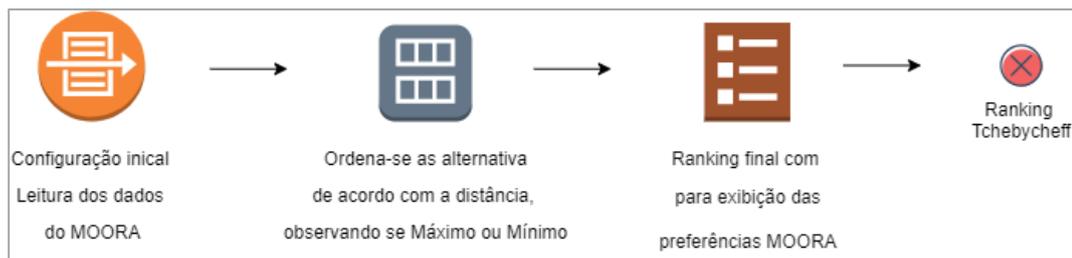


Figura 24: Fluxo do MOORA com a matriz de Tchebycheff

Fonte: Autoria própria

Na Figura 25 é possível observar os valores extraídos de mim e max da leitura de todos os decisores, o framework extraiu os valores 0,018 para Cr01_Falhas - MIN; 0,36 para Cr02_Seguranca - MAX; 0,32 para Cr03_OEE - MAX; 0,02 para Cr04_Custo - MIN; 0,35 para Cr05_Preventiva - MAX e 0,30 Cr06_Treinamento - MAX.

```
[0.0180992513822189,
0.3637608803692959,
0.326991487587202,
0.0295769877462179,
0.359957256205121,
0.307055812649371]
```

Figura 25: Valores mínimos e máximos MOORA

Fonte: Autoria própria

Na sequência, alternativas com valores menores são consideradas melhores. Assim, ordena-se as alternativas de acordo com a menor distância,

sendo possível desenvolver e exibir, conforme Figura 26, o Ranking MOORA usando o Método ponto de referência Tchebycheff.

	Ranking
Offset_01	0.000000
calcográfica_01	0.225889
Offset_02	0.261590
Offset_03	0.287503
calcográfica_03	0.288594
calcográfica_02	0.289792
serigráfica_01	0.310652
calcográfica_04	0.345938

Figura 26: Ranking MOORA Método Tchebycheff
Fonte: Autoria própria

Para gerar o 4º ranking o framework reinicia com a utilização dos mesmos pesos atribuídos aos critérios na etapa de estabelecimento dos pesos dos critérios nos métodos anteriores. Caso o critério seja de minimização o método utiliza a operação de divisão para normalizar os valores em cada critério. A divisão é usada para que valores menores (melhores) recebam uma maior pontuação após a normalização. Porém se for de maximização o método utiliza a operação de multiplicação. A multiplicação é usada para que valores maiores (melhores) recebam uma maior pontuação após a normalização. Multiplicar pelo inverso do valor mínimo encontrado na matriz de decisão faz com que os valores maiores se aproximem da solução ideal. O ranking final calculado com base no MutiMoora está exposto na Figura 27.

	RankingMultiMoora
Offset_01	1.321994e-02
calcográfica_01	2.633563e-04
Offset_02	2.320608e-04
Offset_03	7.610548e-05
calcográfica_02	4.856294e-05
calcográfica_03	3.571423e-05
serigráfica_01	3.956775e-06
calcográfica_04	2.219061e-07

Figura 27: Ranking MULTIMOORA
Fonte: Autoria própria

5.6 Aplicação do Método ordinal

Para finalizar o Framework proposto, o método Borda foi aplicado nos quatro rankings encontrados para orientar técnicos e gestores na determinação do ranking final desta dissertação.

A alternativa final é organizada em ordem decrescente, e foi exibida na Figura 28, finalizando a pesquisa com o ranqueamento do Borda (Pomerol e Barba-Romero, 2000).

	Coeficiente de borda								
	AHP		MOORA		MOORA Tchebycheff		MULTIMOORA		Ordinal BORDA
	Matriz de decisão - ordenação pela maior pontuação (Pomerol e Barba Romero - 2000)								
Impressoras	Apuração	borda	Apuração	borda	Apuração	borda	Apuração	borda	Acum. >
serigráfica_01	0,331397	8	0,630000	2	0,310652	7	3956775	6	23
calcográfica_02	0,090673	4	0,973758	5	0,289792	6	4856294	7	22
Offset_03	0,099364	5	0,884900	3	0,287503	4	7610548	8	20
calcográfica_01	0,164274	7	2008384	7	0,225889	2	2633563	4	20
Offset_02	0,113189	6	1499078	6	0,261590	3	2320608	3	18
calcográfica_03	0,078176	3	0,962774	4	0,288594	5	3571423	5	17
calcográfica_04	0,026687	1	0,264837	1	0,345938	8	2219061	2	12
Offset_01	0,052628	2	4472046	8	0,000000	1	1321994	1	12

Figura 28: Ranking final Framework

Fonte: Autoria própria

Após a definição final do método na empresa de manufatura, o resultado foi apresentado aos especialistas envolvidos e a estes foram solicitados avaliação do modelo e da metodologia, incluindo a utilidade na tomada de decisões (Presley *et al.*, 2016).

5.7 Análise de sensibilidade dos resultados

A análise de sensibilidade foi empregada em 5 passos. Para iniciar a análise, foi identificado os parâmetros de entrada como sendo os pesos dos critérios descobertos durante a rodada do AHP-AIP e explicitado no Apêndice 2, coluna Matriz de Peso. O segundo passo foi a definição dos limites de variação para avaliar a sensibilidade entre 0 e 1. O terceiro passo deu-se em achar a média geométrica dos valores dos 4 decisores, resultando no Média geométrica do AHP – AIP.

Ao quarto passo coube a execução da análise de sensibilidade, para testar variações nas comparações pareadas entre os pesos dos critérios, porém dentro dos limites de variação estipulado, conforme Figura 29.



Figura 29: Modelo adotado para análise de sensibilidade

Fonte: Autoria própria

Os cenários foram feitos com uma modificação direta no peso dos critérios expostos da Tabela 16 – Apêndice 2. Os resultados podem ser vistos na Figura 30.

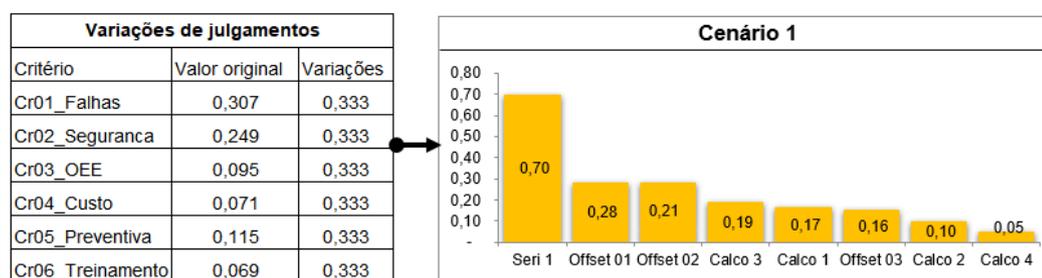


Figura 30: Análise de sensibilidade Cenário 1

Fonte: Autoria própria

No cenário 1, todos os critérios receberam o mesmo peso, na ordem de 0,333, descrito na coluna Variações da Figura 30. O resultado mostrou que se todos os critérios receberem o mesmo peso, a alternativa denominada “Impressora Seri 1” aparecerá em primeiro lugar e a “Impressora Offset 01” em segundo lugar.

No cenário 2, foi efetuada a comparação entre o critério Preventiva e os demais. Assim, ocorreu alteração para considerar o critério Preventiva o mais importante, com a variação de 0,900. Como resposta a impressora Serigráfica 1 permaneceu em primeiro lugar, conforme Figura 31.

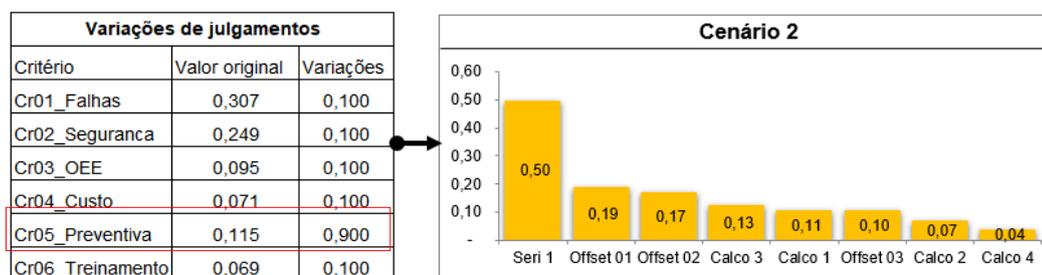


Figura 31: Análise de sensibilidade Cenário 2

Fonte: Autoria própria

O último cenário feito foi a inversão dos valores originais. O valor do critério “Falha” ocupou o lugar do critério “Treinamento” e mais uma vez a impressora “Impressora Serigráfica 1” permaneceu na primeira posição, indicando o 1º sensor para manutenção preditiva instalado, conforme Figura 32. A única mudança ocorreu entre as impressoras Calcográfica 3 e Offset 3 que ocuparam a mesma posição.

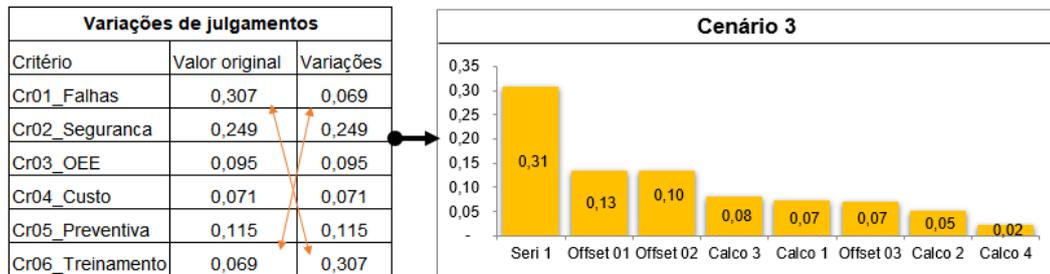


Figura 32: Análise de sensibilidade Cenário 3

Fonte: Autoria própria

Assim, após a análise contendo 3 cenários diferentes, durante a análise de sensibilidade ficou evidente que independentemente das variações de importância nos pesos dos critérios realizados, a impressora Serigráfica se mantém na primeira colocação, demonstrando ser uma opção sólida, proporcionando ao tomador de decisão maior confiança em relação à sua escolha (Loureiro *et al.*, 2018).

5.8 Avaliação do framework por especialistas

Os resultados foram avaliados pelo grupo focal inicial com a presença do Superintendente, da analista participante e demais entrevistados, sendo importante destacar que todas as matrizes criadas ao longo das etapas dos métodos foram aprovadas no teste de consistência, logo todas as análises de pares são tidas como consistentes.

Ao final do processo de implementação do Framework, durante reunião com os envolvidos, os participantes ressaltaram que os dados obtidos inicialmente, através da análise das falhas históricas de cada impressora com a apresentação do ARIMA e RNA, permitiram maior clareza para as decisões emparelhadas nas matrizes, com o intuito de percepção de demandas de manutenções corretivas excessiva ou não, no próximo período. Como registro, todos os participantes comentaram que deram notas altas de prioridades para a impressora Serigráfica 1, mesmo que o histórico de manutenções corretivas não fossem superiores as outras impressoras, uma vez que não existe outra impressora similar na empresa, sendo crítica a situação caso falhe sua operação.

Ademais, os membros do grupo focal destacaram que o fato de não terem conhecimento prévio das respostas dos colegas permitiu uma análise mais objetiva, personalizada e imparcial, abrangendo desde a perspectiva do chão de fábrica pelo técnico, até o nível de supervisor, chegando ao nível gerencial com a colaboração do gerente da manutenção.

Essa abordagem favoreceu uma análise mais abrangente e neutra, garantindo que as decisões fossem pautadas em critérios objetivos e considerando as particularidades de cada um. Neste estudo, destacam-se as estratégias de "Compromisso da alta administração", "Plano estratégico para a I4.0" e "Alinhamento de pessoas, processos e tecnologia" na superação das barreiras da I4.0 (Kumar *et al.*, 2021).

Nos impactos quantitativos, ao analisar os resultados graficamente, verifica-se que a alternativa mais importante é a impressora Serigráfica 1. Utilizando-se do ranking final gerado pelo Método Borda foi definido pelos tomadores de decisão que o ranking encontrado nesta dissertação deverá ser aplicado para os testes iniciais pelas empresas, que estão exibindo seus sistemas de manutenção preditiva aos técnicos responsáveis pela análise da demanda.

Assim, o primeiro sensor para teste, foi colocado na impressora serigráfica, corroborando com a percepção de todos os envolvidos.

6 Discussões

Essa seção descreve a discussão do framework proposto durante a pesquisa acadêmica.

No contexto da pesquisa, a empresa analisada implementou o framework proposto, com a junção do método híbrido na forma do Framework e em um estudo de caso, fundamentando-se nos conceitos derivados da revisão literária, definiu-se o escopo de alternativas, critérios e os métodos. Já na fase empírica, o framework foi concebido, incluindo ARIMA, RNA, AHP, MOORA, MULTIMOORA e Borda, abordando a questão central da dissertação QP1: a combinação entre MCDM e ML na Manutenção 4.0. Os resultados encontrados permitiram validar a eficácia do framework proposto, corroborando com estudos anteriores que destacam a aplicabilidade dos métodos Dhanisetty *et al.* (2018) e Fabianowski *et al.* (2021).

Assim, os resultados obtidos através da reunião com o grupo focal para apresentação do framework e avaliação individual de cada membro corroborou com Yin (2015), ao buscar respostas que forneçam evidências contributivas para a análise dos dados.

No âmbito do MCDM, é comum observar que os resultados obtidos por diferentes métodos resultam em ranqueamentos diversos, assim como os encontrados nesta pesquisa e a dependência exclusiva de um único algoritmo de classificação pode comprometer a robustez do processo, dado que os resultados podem apresentar variações, conforme destacado por Aktas e Demirel (2021). Diante desse desafio, a presente pesquisa adotou uma abordagem mais abrangente ao incorporar tanto os modelos ARIMA quanto as RNAs em conjunto com os cinco métodos tradicionais. Essa abordagem combinada permitiu, ao final, corroborar a assertiva de Aktas e Demirel, evidenciando a importância de uma estratégia diversificada para lidar com a complexidade inerente à tomada de decisões em ambientes multifacetados.

Durante a apresentação dos resultados ao grupo focal, foi consensual que o ranking final estava em acordo com as expectativas, conforme evidenciado na Figura 33. Nessa representação, o eixo y destaca os valores do método Borda, responsável pela classificação. No entanto, observa-se uma discrepância leve em relação a Bobrowski e Łaska (2023), que sugerem que alterações na ordem de

classificação das opções podem ter um impacto significativo nas pontuações finais, podendo resultar em conclusões que não estejam alinhadas com a intuição ou as expectativas do decisor.

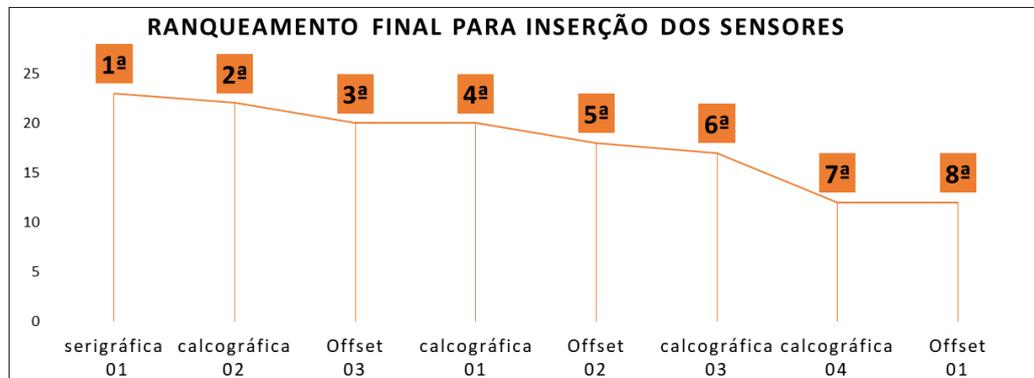


Figura 33 - Gráfico do ranqueamento final impressoras para preditiva.

Fonte: Autoria própria

Assim, os resultados corroboram com o que está na literatura ao evidenciar a eficácia e dinamismo dos métodos de MCDM na tomada de decisões, alinhando-se com pesquisas anteriores como Tscheikner-gratl *et al.* (2017), que ao investigarem cinco métodos multicritério, destacaram a importância dessas abordagens na priorização de projetos, enfatizando o uso no planejamento da reabilitação das redes urbanas de água. Neste contexto, a presente pesquisa, ao utilizar vários métodos e validando empiricamente a aplicação dessas técnicas na área de Manutenção 4.0, difere da maioria dos artigos publicados, já que em sua maioria não empregaram variabilidade de métodos.

Os participantes do grupo focal, reconheceram que os aspectos relacionados aos modelos de predição e MCDM demonstram-se complementares na construção do Framework proposto, destacando que esta pesquisa é relevante, com poucos estudos publicados exibindo a importância na temática pesquisada sobre o uso de Multimétodos incluindo a obtenção de dados de predição manutenções corretivas, respondendo à pergunta QP2: Como as abordagens MCDM e ML podem ser combinadas e aplicadas para o desenvolvimento de um framework de apoio a decisão para SM na manufatura?"

O reconhecimento da natureza complementar dos modelos de previsão e do MCDM na construção do Framework alinha-se com a literatura uma vez que essas conexões servem de guia para estratégias, decisões sobre recursos e intervenções, gerando um ambiente favorável à integração de ML, contendo fatores influentes como 'Integração de Tecnologia', 'Previsão' e 'Gestão de Dados' (Gardas e Narwane, 2023).

O método AHP-AIP teve mais passos do que o AHP padrão, mas permitiu a análise de informações de vários especialistas, enriquecendo a discussão com diversas perspectivas e experiências. Estudos mostraram que os dois métodos diferem não apenas em etapas, mas também em processos e filosofia (Wachowicz e Roszkowska, 2023; Oubahman e Duleba, 2022).

Durante a execução dos métodos, procedeu-se ao cálculo da razão de consistência para cada matriz de comparação pareada, um indicativo de validade interna que se alinha à abordagem proposta por Shameem (2020), reforçando a aceitabilidade da priorização dos critérios adotada. Vale ressaltar que os modelos desenvolvidos neste estudo são passíveis de replicação em pesquisas futuras, mediante a observação dos procedimentos delineados, sendo possível adaptar o tamanho das amostras conforme necessário.

Além disso, a análise de desempenho dos métodos revelou que, diante de variações no ranqueamento final – seja por aumento ou redução –, todos os métodos apresentaram consistência na orientação, corroborando os resultados obtidos por Aktas e Demirel (2021). Esta consistência é evidenciada na Figura 34, reforçando a robustez dos métodos empregados.

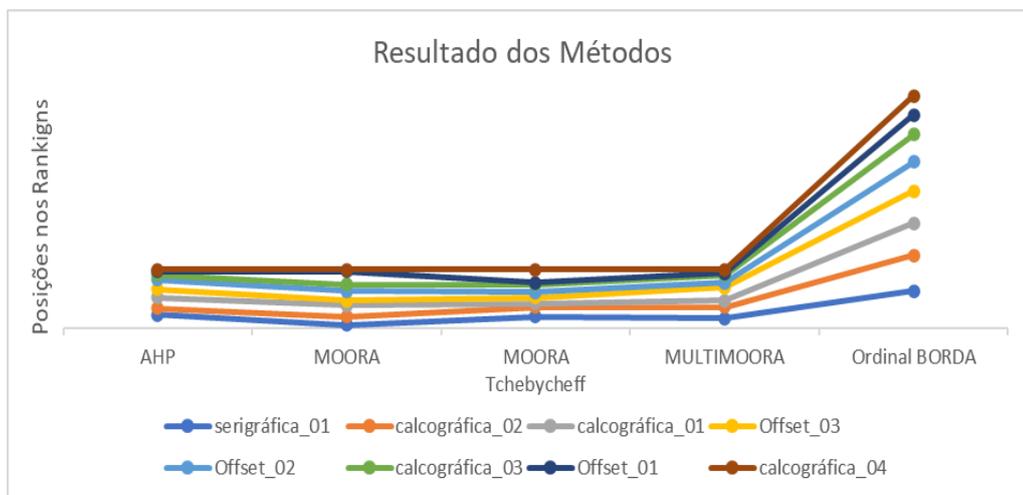


Figura 34: Resultados dos métodos

Fonte: Autoria própria

Ao finalizar a pesquisa e incorporar a análise de sensibilidade, ocorreu um refinamento significativo no framework proposto para o ranqueamento de impressoras. Esse aprimoramento resultou da avaliação da influência da combinação dos pesos iniciais do método AHP-AIP, assegurando o êxito da investigação no estudo de caso.

Foi essencial que a pesquisadora estivesse consciente e reconhecesse tanto os pontos fortes quanto as limitações das abordagens utilizadas, alinhando-se à abordagem metodológica recomendada por Yin (2015).

O refinamento do framework não só fortaleceu a robustez da metodologia, mas enfatizou a necessidade de uma abordagem reflexiva e crítica durante a pesquisa, possibilitando ajustes que aprimoram a validade e confiabilidade dos resultados. Essas considerações não apenas aperfeiçoaram a qualidade das conclusões obtidas, mas também estabeleceram uma base sólida para respaldar o processo de tomada de decisão. A contribuição significativa para uma abordagem mais informada e assertiva, conforme destacado por Wieckowski e Sałabun (2023), confere credibilidade aos resultados, influenciando positivamente as decisões e orientando futuras pesquisas na área em questão, auxiliando na compreensão de como as variações nos pesos influenciam os resultados das decisões Hagag *et al.* (2023).

No que diz respeito a combinação de métodos, a pesquisa corrobora ainda com Campolina (2017), que buscou demonstrar que é possível nas pesquisas entender que otimizar a combinação dos métodos acaba por permitir otimizar a participação de diferentes grupos de interesse, assim como os diferentes tipos de decisores que auxiliaram na pesquisa.

Como limitação do modelo proposto, a luz dos critérios do conjunto dos especialistas careceria de uma nova abordagem, caso fosse necessário a inclusão de um critério novo, permitindo que o decisor tenha autonomia para definir outros parâmetros, além de abarcar a criação da Análise de Sensibilidade dentro do Python, integrando todo o Framework.

Ao trazer para discussão a questão da integração de métodos MCDMs, ressaltava-se, cada vez mais, a especificidade dos métodos. É dessa questão que Da Rocha (2016) partiu para apresentar resultados promissores na tomada de decisões, mesmo a que utilização do método integrado de Borda-AHP não seja comum.

Desse modo, no cenário atual, a utilização de MCDM na manutenção industrial não apenas garante decisões eficazes e eficientes, mas também facilita uma abordagem participativa, integrando diversos pontos de vista e promovendo a colaboração entre as partes interessadas. Essa abordagem mais holística não apenas considera decisão entre objetivos divergentes, mas também possibilita uma adaptação ágil a mudanças nas condições operacionais, assegurando que as decisões de manutenção estejam alinhadas com os objetivos estratégicos da organização.

No que tange à metodologia, em termos de conteúdo, nos estudos anteriores encontrados durante a fundamentação teórica, os autores não discutiram os benefícios e as oportunidades da aplicação do MCDM nos setores

de manutenção industrial. Por fim, este estudo buscou inovação ao direcionar seu foco para a I4.0, embasando-se em um estudo de caso. Isso se deve ao fato de que pesquisas prévias revelaram que 37,4% das empresas não manifestaram interesse em adotar implementações a I4.0, conforme indicado por (Kumar *et al.*, 2021).

Destaca-se ainda como discussão final que a junção do MCDM e ML constitui uma originalidade.

7 Conclusões e sugestões para trabalhos futuros

O cerne desta pesquisa reside na grande necessidade de explorar e integrar abordagens multicritério e métodos de previsão para respaldar a Manutenção Inteligente e a Indústria 4.0 (I4.0) em uma empresa de grande porte no cenário brasileiro. Enquanto inúmeras investigações abordam a I4.0, manutenção industrial e métodos MCDM de forma separada em empresas manufatureiras, destaca-se a escassez de aplicações práticas desses modelos em estudos de caso reais, especialmente quando associados a métodos de previsão.

Para compreender a complexidade dessas abordagens, uma análise da literatura sobre Manutenção Inteligente, conforme definida por Bokrantz *et al.* (2020a), foi enriquecida por uma revisão de escopo e uma breve bibliometria. Esse minucioso exame envolveu 370 documentos e 14 artigos principais, identificando métodos previamente estudados combinados com MCDM e Machine Learning (ML) para respaldar a tomada de decisões na manutenção de ativos.

Com esses subsídios, desenvolveu-se uma abordagem inovadora por meio de um estudo de caso, projetado para compor ranking de instalação de sensores de testes para iniciar a manutenção preditiva em impressoras de grande porte da empresa de manufatura. Uniram-se quatro métodos decisórios em um ranking estratégico para a instalação de sensores de teste, inaugurando uma forma inovadora para tomada de decisão.

Apesar das críticas frequentes ao estudo de caso, como apontadas por Yin (2015), esta dissertação se destaca ao seguir o protocolo proposto por Yin, tornando-se atrativa e orientadora para novos pesquisadores, conectando dados empíricos às questões de pesquisa.

Duas questões de pesquisa nortearam o estudo. A primeira delas, denominada QP1, indagou: "No contexto da Manutenção 4.0, de que forma a literatura explora a integração entre MCDM e ML para auxiliar na tomada de decisão relacionada à manutenção de ativos?". Já a segunda questão, denominada QP2, questionou: "Como as abordagens de MCDM e ML podem ser integradas e aplicadas para elaborar um framework de apoio à decisão para a Manufatura Inteligente?".

Como resposta a QP1 é possível assegurar que no contexto da Manutenção 4.0, a literatura pouco explorou a combinação entre MCDM e ML como uma estratégia promissora para apoiar a tomada de decisão para manutenção de ativos. A combinação empregada nessa pesquisa permitiu uma análise mais abrangente e precisa, considerando múltiplos critérios e utilizando algoritmos de aprendizado de máquina para fornecer insights valiosos e previsões sobre o desempenho dos ativos pesquisados. Sequencialmente, respondendo a QP2 foi possível apontar que as abordagens de MCDM e ML podem ser combinadas e aplicadas para o desenvolvimento de um framework de apoio à decisão para a Manutenção Inteligente na manufatura, pois essa integração permitiu o avanço no campo de MCDM ao combinar pioneiramente métodos como AHP, MOORA, MULTIMORA, com rede neural, ARIMA, e um ranking final agregado usando a contagem de Borda, para ranquear ativos em uma indústria de manufatura no Brasil.

A revisão de escopo empregada permitiu concordar com a assertiva de Kumar, Vrat e Shankar (2021) sobre o crescente interesse em I4.0. Retomando as questões da pesquisa, ficou claro que o método AHP prevaleceu nos estudos observados, mas a ausência de sua combinação específica em Python e com mais de um ou dois métodos foi evidente.

Como aproveitamento no estudo de caso, as entrevistas com decisores experientes e nível hierárquicos diversos, resultaram em uma estrutura de apoio à decisão, reforçando a relevância e utilidade desses métodos.

Um dos objetivos alcançados da dissertação foi ainda, a consolidação do framework desenvolvido em Python, permitindo materializar a leitura dos dados, execução, unificação dos métodos, além de permitir a digitalização industrial.

Do ponto de vista prático, a análise de sensibilidade efetuada, corroborou os resultados dos métodos MCDM. Contudo, as limitações do estudo, como a necessidade de várias rodadas em Python, destacam a importância de futuras pesquisas para abordar outros desafios com outros métodos, onde seja aceitável que na hipótese dos decisores resolverem alterar a quantidade de participantes, alternativas ou critérios, esteja disponível automaticamente uma nova matriz de comparações com mudança da Estrutura Hierárquica do Problema de Decisão.

Embora o estudo tenha alcançado resultados significativos, oportunidades para pesquisas futuras no âmbito de MCDM com ML são evidentes.

A comparação entre MCDM e modelos de previsão destaca-se como uma ferramenta valiosa para análises integradas, oferecendo uma visão abrangente e robusta do problema investigado.

Em conclusão, ao elaborar o modelo proposto e implementar a pesquisa, a decisão final foi iniciar os testes de manutenção preditiva na impressora Serigráfica 01. Este trabalho não apenas contribui para o avanço do conhecimento em MCDM e I4.0, mas também serve como guia para futuras pesquisas na interseção entre métodos multicritério, previsão e manutenção industrial.

Referências Bibliográficas

AVERY, Jill et al. **Consumer behavior: human pursuit of happiness in the world of goods**. Open Mentis, 2011.

ABDULLAH, Ade Gafar et al. Multi-criteria decision making for nuclear power plant selection using fuzzy AHP: Evidence from Indonesia. **Energy and AI**, v. 14, p. 100263, 2023.

ABDULGADER, Fathia Sghayer et al. Development of decision support model for selecting a maintenance plan using a fuzzy MCDM approach: a theoretical framework. **Applied Computational Intelligence and Soft Computing**, v. 2018, 2018.

ADEBIYI, Ayodele Ariyo et al. Comparison of ARIMA and artificial neural networks models for stock price prediction. **Journal of Applied Mathematics**, v. 2014, 2014.

AISSANI, Nassima; Mechrouf, Ibtissem; Filali, Assia. Overview of Maintenance 4.0 and the associated approaches, and a preliminary case study in Algeria. In: 2021 International Conference on Networking and Advanced Systems (ICNAS). **IEEE**, p. 1-6, 2021.

AKTAŞ, Nadine; Demirel, Neslihan. A hybrid framework for evaluating corporate sustainability using multi-criteria decision making. **Environment, Development and Sustainability**, v. 23, n. 10, p. 15591-15618, 2021.

AMINYAVARI, Mehdi et al. Exergetic, economic and environmental (3E) analyses, and multi-objective optimization of a CO₂/NH₃ cascade refrigeration system. **Applied Thermal Engineering**, v. 65, n. 1-2, p. 42-50, 2014.

ALSYOUF, Imad et al. Impact of ISO 55000 on organisational performance: evidence from certified UAE firms. **Total Quality Management & Business Excellence**, v. 32, n. 1-2, p. 134-152, 2021.

AMINGER, Andréa Franco; De-Menezes-Migliari, Mirella. Serigrafia versus impressão digital: uma opção pela estética/Screen printing versus digital printing. 2021.

ARANTES, Pedro Martins Ferreira et al. Abordagem multicritério de apoio à decisão-construtivista para priorização de projetos de uma startup no mercado de software. 2021.

ARKSEY, Hilary; O'Malley, Lisa. Scoping studies: towards a methodological framework. **International Journal of Social Research Methodology**, v. 8, n. 1, p. 19-32, 2005.

Azeredo. Multi-Criteria Decision Analysis: o que é, como funciona, virtudes e limitações da tomada de decisão por múltiplos critérios 2016. Disponível em:

<https://www.htanalyze.com/blog/multi-criteria-decision-analysis-o-que-e-como-funciona-virtudes-e-limitacoes-da-tomada-de-decisao-por-multiplos-criterios/>
Acesso em: 18 nov. 2023.

AZIZ, Mustafa Nizamul. A review on artificial neural networks and its' applicability. **Bangladesh Journal of Multidisciplinary Scientific Research**, v. 2, n. 1, p. 48-51, 2020.

BAS, Eren; Egrioglu, Erol; Cansu, Turan. Robust training of median dendritic artificial neural networks for time series forecasting. **Expert Systems With Applications**, v. 238, p. 122080, 2023.

BASHIRI, Mahdi; Geranmayeh, Amir Farshbaf; Sherafati, Mahtab. Solving multi-response optimization problem using artificial neural network and PCR-VIKOR. In: **2012 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering**. IEEE, 2012. p. 1033-1038.

BASTANI, Hamsa; Bastani, Osbert; Sinchaisri, Wichinpong Park. Learning best practices: Can machine learning improve human decision-making. In: **Academy of Management Proceedings**. Briarcliff Manor, NY 10510: Academy of Management, v.1, p. 14006, 2021.

BEJINARIU, Costica et al. Considerations Regarding the Application of the Occupational Injury and Illness Risk Assessment Method at Workplaces/Workstations, in Relation to the ISO 45001 Standard. **Sustainability**, v. 15, n. 3, p. 2121, 2023.

BERTOLINI, Massimo et al. Machine Learning for industrial applications: A comprehensive literature review. **Expert Systems With Applications**, v. 175, p. 114820, 2021.

BHATIA, Purvee; Diaz-Elsayed, Nancy. Facilitating decision-making for the adoption of smart manufacturing technologies by SMEs via fuzzy TOPSIS. **International Journal of Production Economics**, v. 257, p. 108762, 2023.

BOBROWSKI, Jakub; Łaska, Grażyna. Using spatial elimination and ranking methods in the renewable energy investment parcel search process. **Energy**, v. 285, p. 129517, 2023.

BOUSDEKIS, Alexandros et al. Decision making in predictive maintenance: Literature review and research agenda for industry 4.0. **IFAC-PapersOnLine**, v. 52, n. 13, p. 607-612, 2019.

BOKRANTZ, Jon; Skoogh, Anders. Adoption patterns and performance implications of Smart Maintenance. **International Journal of Production Economics**, v. 256, p. 108746, 2023.

BOKRANTZ, Jon et al. Smart Maintenance: a research agenda for industrial maintenance management. **International Journal Of Production Economics**, v. 224, p. 107547, 2020. (a)

BOKRANTZ, Jon et al. Smart Maintenance: an empirically grounded conceptualization. **International Journal of Production Economics**, v. 223, p. 107534, 2020. (b)

BRAUERS, Willem Karel; Zavadskas, Edmundas Kazimieras. The MOORA method and its application to privatization in a transition economy. **Control and Cybernetics**, v. 35, n. 2, p. 445-469, 2006.

BOX, George et al. **Time Series Analysis: Forecasting and Control**. John Wiley & Sons, 2015.

BOUCHAALA, Mohammed Abdelghani; Nouredine, Rachid; Nouredine, Myriam. 5TH International Conference on Advances In Mechanical Engineering Istanbul 2019, 17-19 DECEMBER 2019.

CACHADA, Ana et al. Maintenance 4.0: Intelligent and predictive maintenance system architecture. In: 2018 IEEE 23rd international conference on emerging technologies and factory automation (ETFA). **IEEE**, p. 139-146, 2018.

CAMPOLINA, Alessandro Gonçalves et al. Análise de decisão multicritério para alocação de recursos e avaliação de tecnologias em saúde: tão longe e tão perto? **Cadernos de Saúde Pública**, v. 33, p. e00045517, 2017.

CARVALHO, Thyago. et al. A systematic literature review of machine learning methods applied to predictive maintenance. **Computers & Industrial Engineering**, v. 137, p. 106024, 2019.

CHODAKOWSKA, Ewa; Nazarko, Joanicjusz; Nazarko, Łukasz. Arima models in electrical load forecasting and their robustness to noise. **Energies**, v. 14, n. 23, p. 7952, 2021

CONSILVIO, Alice et al. Risk-based optimal scheduling of maintenance activities in a railway network. **EURO Journal on Transportation And Logistics**, v. 8, n. 5, p. 435-465, 2019.

ÇINAR, Zeki Murat et al. Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. **Sustainability**, v. 12, n. 19, p. 8211, 2020.

DA ROCHA, Phelipe Medeiros et al. Analysis of the operational performance of brazilian airport terminals: A multicriteria approach with De Borda-AHP integration. **Journal of Air Transport Management**, v. 51, p. 19-26, 2016.

DA SILVEIRA ESTEVES, Fernanda Márcia et al. Seleção de um helicóptero de ataque para apoio às operações anfíbias da Marinha Do Brasil: Uma Análise à Luz do Método THOR 2. 2022.

DA SILVA, Renan Favarao; De Souza, Gilberto Francisco Martha. Mapping the literature on asset management: A bibliometric analysis. **Journal of Scientometric Research**, v. 10, n. 1, p. 27-36, 2021.

DA SILVA, Renan Favarão et al. Defining Maintenance Performance Indicators for asset management based on ISO 55000 and Balanced Scorecard: A hydropower plant case study. In: Proceedings of the 30th European Safety and Reliability Conference and the 15th **Probabilistic Safety Assessment and Management Conference, Venice, Italy**. p. 1-5. 2020.

DALZUCHIO, Jovani et al. Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. **Computers in Industry**, v. 123, p. 103298, 2020.

DE FARIA, Viviane Pereira; Quelhas, Osvaldo Luíz Gonçalves. *Manutenção 4.0: Uma Revisão da Literatura da Base Scopus*, 2021.

DE PAULA VIDAL, Guilherme Henrique et al. MRO Inventory Demand Forecast Using Support Vector Machine—A Case Study. In: **International Joint Conference on Industrial Engineering and Operations Management**. Cham: Springer International Publishing, 2022. p. 221-233.

DE JESUS SANTOS, Augusto César; Cavalcante, Cristiano Alexandre Virgínio; WU, Shaomin. Maintenance policies and models: A bibliometric and literature review of strategies for reuse and remanufacturing. *Reliability Engineering & System Safety*, v. 231, p. 108983, 2022.

DE SOUSA PEREIRA, Leydiana; Morais, Danielle Costa. Multicriteria decision model to establish maintenance priorities for wells in a groundwater system. **Water Resources Management**, v. 34, n. 1, p. 377-392, 2020.

DE SOUZA, Rodrigo Clemente Thom. Previsão de séries temporais utilizando rede neural treinada por filtro de Kalman e evolução diferencial. Pontifícia Universidade Católica do Paraná. 2008.

DHANISSETTY, VS Viswanath; Verhagen, W. J. C.; CURRAN, Richard. Multi-criteria weighted decision making for operational maintenance processes. **Journal of Air Transport Management**, v. 68, p. 152-164, 2018.

DO CARMO MENDONÇA, Tainá et al. Prioritization of maintenance equipment employing multicriteria decision aid. In: **2018 Annual IEEE International Systems Conference (SysCon)**. IEEE, 2018. p. 1-6.

DODUN, O. et al. Selecting an alternative to solve a problem from several available alternatives. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, v.1009. p. 012018, 2021.

DO NASCIMENTO, Jaqueline Alves et al. Asset Prioritization for Predictive Maintenance in the Context of Industry 4.0: A Group Multicriteria Approach. In: **International Joint Conference on Industrial Engineering And Operations Management**. Cham: Springer Nature Switzerland, 2023. p. 595-607.

DRUMMOND, Helga. The politics of risk: trials and tribulations of the Taurus project. **Journal of Information Technology**, v. 11, n. 4, p. 347-357, 1996.

EDITORA, SENAI-SP (Ed.). *Impressão offset-Máquina alimentada a folha*. **SESI SENAI Editora**, 2018.

ERRANDONEA, Itxaro; Beltrán, Sergio; ARRIZABALAGA, Saioa. Digital Twin for maintenance: A literature review. **Computers in Industry**, v. 123, p. 103316, 2020.

FABIANOWSKI, Dariusz; Jakiel, Przemysław; Stemplewski, Sławomir. Development of artificial neural network for condition assessment of bridges based on hybrid decision making method—Feasibility study. **Expert Systems With Applications**, v. 168, p. 114271, 2021.

FRANCIOSI, Chiara et al. Measuring maintenance impacts on sustainability of manufacturing industries: from a systematic literature review to a framework proposal. **Journal of Cleaner Production**, v. 260, p. 121065, 2020.

FAYYAD, Usama; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic. From data mining to knowledge discovery in databases. **AI magazine**, v. 17, n. 3, p. 37-37, 1996.

FREITAG, Raquel Meister Ko. Amostras sociolinguísticas: probabilísticas ou por conveniência? **Revista de estudos da linguagem**, v. 26, n. 2, p. 667-686, 2018.

GARDAS, Revati; Narwane, Swati. An analysis of critical factors for adopting machine learning in manufacturing supply chains. **Decision Analytics Journal**, v.10, p. 100377, 2023.

GAWDE, Shreyas et al. Multi-fault diagnosis of Industrial Rotating Machines using Data-driven approach: A review of two decades of research. **Engineering Applications of Artificial Intelligence**, v. 123, p. 106139, 2023.

GEBRE, Sintayehu Legesse et al. Multi-criteria decision making methods to address rural land allocation problems: A systematic review. **International Soil and Water Conservation Research**, v. 9, n. 4, p. 490-501, 2021.

GORSKI, Ewerton Gusthavo et al. Towards a smart workflow in CMMS/EAM systems: An approach based on ML and MCDM. **Journal of Industrial Information Integration**, v. 26, p. 100278, 2022.

GOPALAKRISHNAN, Maheshwaran; Subramaniyan, Mukund; Skoogh, Anders. Data-driven machine criticality assessment–maintenance decision support for increased productivity. **Production Planning & Control**, v. 33, n. 1, p. 1-19, 2022.

GOES, Vinicius Guimaraes. Aplicação da Matriz de decisão multicritérios e do modelo de facilidades de localização em ambientes competitivos na indústria de pet shops. **Pontifícia Universidade Católica–PUC, Rio de Janeiro, RJ, Brasil**, 2017.

GOMES, Carlos Francisco Simões; Costa, Helder Gomes. Aplicação de métodos multicritério ao problema de escolha de modelos de pagamento eletrônico por cartão de crédito. **Production**, v. 25, p. 54-68, 2013.

GOMES, Kesia Guedes Arraes. Um método multicritério para localização de unidades celulares de intendência da FAB. Tese de Doutorado. **PUC-Rio**. 2009.

GOMES, LFAM; GOMES, CFS. Tomada de Decisão Gerencial–Enfoque Multicritério. 5. a edição-**Editora Atlas**. São Paulo, 2014.

Guimarães, Andressa et al. "Análise das políticas de desenvolvimento econômico adotadas pela coreia do sul e chile à luz dos métodos de BORDA E COPELAND", p. 377-388. **Anais do XIX Simpósio de Pesquisa Operacional & Logística da Marinha**. São Paulo: Blucher, 2020.

GUILLÉN, Antonio. et al. A framework for effective management of condition based maintenance programs in the context of industrial development of E-Maintenance strategies. **Computers in Industry**, v. 82, p. 170-185, 2016.

GUNDUMOGULA, Manju; Gundumogula, M. Importance of focus groups in qualitative research. **International Journal of Humanities and Social Science (IJHSS)**, v. 8, n. 11, p. 299-302, 2020.

HAFEZALKOTOB, Arian et al. An overview of MULTIMOORA for multi-criteria decision-making: Theory, developments, applications, and challenges. **Information Fusion**, v. 51, p. 145-177, 2019.

HAGAG, Asmaa.; Yousef, Laila; Abdelmaguid, Tamer F. Multi-criteria decision-making for machine selection in manufacturing and construction: Recent trends. **Mathematics**, v. 11, n. 3, p. 631, 2023.

HARVEY, Andrew Charles. Arima models. In: Time Series and Statistics. London: Palgrave Macmillan UK, p. 22-24, 1990.

HE, Zhenglei et al. A deep reinforcement learning based multi-criteria decision support system for optimizing textile chemical process. **Computers in Industry**, v. 125, p. 103373, 2021.

HEYMANN, Mozart Caetano; Pereira, Valdecy; Caiado, Rodrigo Goyannes Gusmão. PyMissingAHP: An Evolutionary Algorithm for Filling Missing Values in Incomplete Pairwise Comparisons Matrices with Real or Fuzzy Numbers via Mono and Multiobjective Approaches. **Arabian Journal for Science and Engineering**, p. 1-20, 2023.

HLIHEL, Fadoua Benhamza; Chater, Youness; Boumane, Abderrazak. Maintenance 4.0 Employees' Competencies: Systematic Literature Review. In: 2nd International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET). **IEEE**, . p. 1-14. 2022.

HOLGADO, Maria; Macchi, Marco; Evans, Stephen. Exploring the impacts and contributions of maintenance function for sustainable manufacturing. **International Journal of Production Research**, v. 58, n. 23, p. 7292-7310, 2020.

HOLLWECK, Trista. Case study research design and methods, Robert K. Yin. **The Canadian Journal of Program Evaluation**, v. 30, n. 1, p. 108, 2015.

Inmetro. Guia de Análise Multicritério para Análise de Impacto Regulatório 2022. Disponível em:

<https://www.gov.br/inmetro/pt-br/assuntos/regulamentacao/analise-de-impacto-regulatorio-1/saiba-mais/guia-para-aplicacao-da-analise-multicriterio-em-air-no-inmetro.pdf>

Acesso em: 24 fev. 2024.

ISMAIL, Firas Basim et al. Intelligent Optimization Systems for Maintenance Scheduling of Power Plant Generators. **Information Sciences Letters**, v. 12, n. 3, p. 1319-1332, 2023.

JASIULEWICZ-Kaczmarek, Małgorzata; Gola, Arkadiusz. Maintenance 4.0 technologies for sustainable manufacturing-an overview. **IFAC-PapersOnLine**, v. 52, n. 10, p. 91-96, 2019.

JIMÉNEZ, José Antonio et al. Design of a Sensor System for On-Line Monitoring of Contact Pressure in Chalcographic Printing. **Sensors**, v. 17, n. 9, p. 2029, 2017.

KARKI, Bishal Raj et al. Digital maintenance and the functional blocks for sustainable asset maintenance service—A case study. **Digital Business**, v. 2, n. 2, p. 100025, 2022.

KUMAR, Veepan; Vrat, Prem; Shankar, Ravi. Prioritization of strategies to overcome the barriers in Industry 4.0: a hybrid MCDM approach. **Opsearch**, p. 1-40, 2021.

KHANORKAR, Yash; Kane, Prasad .Selective inventory classification using ABC classification, multi-criteria decision making techniques, and machine learning techniques. **Materials Today: Proceedings**, v. 72, p. 1270-1274, 2023.

KARUPPIAH, Koppiahraj; Sankaranarayanan, Bathrinath; Ali, Syed Mithun. On sustainable predictive maintenance: Exploration of key barriers using an integrated approach. **Sustainable Production and Consumption**, v. 27, p. 1537-1553, 2021.

LEUKEL, Joerg; González, Julian; Riekert, Martin. Adoption of machine learning technology for failure prediction in industrial maintenance: A systematic review. **Journal of Manufacturing Systems**, v. 61, p. 87-96, 2021.

LIU, Peide; Gao, Hui; FUJITA, Hamido. The new extension of the MULTIMOORA method for sustainable supplier selection with intuitionistic linguistic rough numbers. **Applied Soft Computing**, v. 99, p. 106893, 2021.

LIU, Li; Duffy, Vincent. Exploring the Future Development of Artificial Intelligence (AI) Applications in Chatbots: A Bibliometric Analysis. **International Journal of Social Robotics**, v. 15, n. 5, p. 703-716, 2023.

LIMA Junior, Francisco Rodrigues; Osiro, Lauro; Carpinetti, Luiz Cesar Ribeiro. Métodos de decisão multicritério para seleção de fornecedores: um panorama do estado da arte. **Gestão & Produção**, v. 20, p. 781-801, 2013.

LIMA, Mathews Phillipp Santos de. **Avaliação de estratégias de decisão de mobilidade MADM orientados para a qualidade em cenário de redes 5G**. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte. 2021.

LOUREIRO, Rodrigo Resende; Goldman, Fernando Luiz; De Oliveira Neto, Mario Santos. Gestão de portfólio de projetos com auxílio do Método AHP. **Sistemas & Gestão**, v. 13, n. 3, p. 295-310, 2018.

LUNDGREN, Camilla; Bokrantz, Jon; Skoogh, Anders. Performance indicators for measuring the effects of Smart Maintenance. **International Journal of Productivity and Performance Management**, v. 70, n. 6, p. 1291-1316, 2021.

MACHADO, Carla Gonçalves et al. Industry 4.0 readiness in manufacturing companies: challenges and enablers towards increased digitalization. **Procedia Cirp**, v. 81, p. 1113-1118, 2019.

MAGON, Renata Bianchini et al. Sustainability and performance in operations management research. **Journal of Cleaner Production**, v. 190, p. 104-117, 2018.

MAHPOUR, Amirreza; El-Diraby, Tamer. Application of Machine-Learning in Network-Level Road Maintenance Policy-Making: The Case of Iran. **Expert Systems with Applications**, v. 191, p. 116283, 2022.

MARTYN, Krzysztof; Kadziński, Miłosz. Deep preference learning for multiple criteria decision analysis. **European Journal of Operational Research**, v. 305, n. 2, p. 781-805, 2023.

MARTINETTI, Alberto et al. Maintenance 4.0: Where Are We? A Systematic Literature Review. **Applications and Challenges of Maintenance and Safety Engineering in Industry 4.0**, p. 1-30, 2020.

MEI, Yong et al. Probabilistic prediction model of steel to concrete bond failure under high temperature by machine learning. **Engineering Failure Analysis**, v. 142, p. 106786, 2022.

MEEKS, Tiffany et al. Evaluation of Machine Learning Algorithms in Predicting Corrosion Rates on Oil Refinery Piping. In: IIE Annual Conference. Proceedings. **Institute of Industrial and Systems Engineers (IISE)** p. 1-6, 2022.

MINGERS, John. The paucity of multimethod research: a review of the information systems literature. **Information Systems Journal**, v. 13, n. 3, p. 233-249, 2003.

MIĆIĆ, Ljubiša; Mastilo, Zoran. Digital workplace transformation: innovative approach after COVID-19 pandemic. **Economics-Innovative and Economics Research Journal**, v. 10, n. 2, 2022.

MILAD, Abdalrhman et al. Using an azure machine learning approach for flexible pavement maintenance. In: 2020 16th IEEE International Colloquium on Signal Processing & Its Applications (CSPA). **IEEE**. 146-150, 2020.

MIOLO, Marjory Aparecida; Sausen, Jorge Oneide; Cappellari, Gabriela. Um Estudo Bibliométrico em Base de Dados Internacionais. **Salão do Conhecimento**, 2018.

MIRHOSSEINI, Mina; Keynia, Farshid. Asset management and maintenance programming for power distribution systems: A review. **IET Generation, Transmission & Distribution**, v. 15, n. 16, p. 2287-2297, 2021.

MOHER, David et al. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **International Journal Of Surgery**, v. 8, n. 5, p. 336-341, 2010.

MORGADO, Luisa; Silva, Francisco; Fonseca, Luis. Mapping occupational health and safety management systems in Portugal: outlook for ISO 45001: 2018 adoption. **Procedia Manufacturing**, v. 38, p. 755-764, 2019.

MOUSAVI-NASAB, Seyed Hadi; Sotoudeh-Anvarl, Alireza. A comprehensive MCDM-based approach using TOPSIS, COPRAS and DEA as an auxiliary tool for material selection problems. **Materials & Design**, v. 121, p. 237-253, 2017.

MOURA, Luana Kelle Batista et al. Análise bibliométrica das evidências científicas sobre violência contra a pessoa idosa. **Ciência & Saúde Coletiva**, v. 25, p. 2143-2152, 2020.

MOURTZIS, Dimitris et al. Cyber-physical systems and education 4.0—the teaching factory 4.0 concept. **Procedia Manufacturing**, v. 23, p. 129-134, 2018.

MOZZATO, Anelise Rebelato; Grzybovski, Denize. Análise de conteúdo como técnica de análise de dados qualitativos no campo da administração: potencial e desafios. **Revista de Administração Contemporânea**, v. 15, p. 731-747, 2011.

MUDASHIRU, Rofiat Bunmi; Sabtu, Nuridah; ABUSTAN, Ismail. Quantitative and semi-quantitative methods in flood hazard/susceptibility mapping: a review. **Arabian Journal of Geosciences**, v. 14, n. 11, p. 941, 2021

MUIJEEN, Kasorn; Kongvattananon, Puangpaka; SOMPRASERT, Chomchuen. The key success factors in focus group discussions with the elderly for novice researchers **Journal of Health Research**, v. 34, p. 359-371, 2020

MUNN, Zachary et al. Systematic review or scoping review? Guidance for authors when choosing between a systematic or scoping review approach. **BMC Medical Research Methodology**, v. 18, p. 1-7, 2018.

MURUGANANTHAM, Arun.; Gandhi, Meera. Framework for social media analytics based on multi-criteria decision making (MCDM) model. **Multimedia Tools and Applications**, v. 79, p. 3913-3927, 2020.

NARANJO, Jose. et al. A scoping review of pipeline maintenance methodologies based on industry 4.0. **Sustainability**, v. 14, n. 24, p. 16723, 2022.

ONDRUS, Jan; Bui, Tung; Pigneur, Yves. A foresight support system using MCDM methods. **Group Decision and Negotiation**, v. 24, p. 333-358, 2015.

OLIMPIO, Luiz Carlos Magalhães. Modelo híbrido de apoio à decisão multicritério na manutenção preventiva de patrimônios culturais edificados de Sobral. 2020.

ORTIZ, Daniel; Greene, Jennifer. Research design: qualitative, quantitative, and mixed methods approaches. **Qualitative Research Journal**, v. 6, n. 2, p. 205-208, 2007.

OUADAH, Abdelaziz. Pipeline defects risk assessment using machine learning and analytical hierarchy process. In: 2018 International Conference on Applied Smart Systems (ICASS). **IEEE**, p. 1-6, 2018.

OUBAHMAN, Laila; Duleba, Szabolcs. A Comparative Analysis of Homogenous Groups' Preferences by Using AIP and AIJ Group AHP-PROMETHEE Model. **Sustainability**, v. 14, n. 10, p. 5980, 2022.

PADOVANO, Antonio et al. A prescriptive maintenance system for intelligent production planning and control in a smart cyber-physical production line. **Procedia CIRP**, v. 104, p. 1819-1824, 2021.

PAIS, Edmundo. et al. Optimizing the life cycle of physical assets—A review. **WSEAS Trans. Syst. Control**, v. 15, p. 417-430, 2020.

PECH, Martin; Vrchota, Jaroslav. The product customization process in relation to industry 4.0 and digitalization. **Processes**, v. 10, n. 3, p. 539, 2022.

PEREIRA, Márcio Filipe Godinho. Manutenção preventiva na gestão de falhas em redes móveis usando machine learning. Tese de Doutorado. **Instituto Superior de Engenharia de Lisboa**. 2022.

PEREIRA, Letiane Borges; Longaray, André Andrade. O emprego de métodos multicritérios como instrumento de apoio na gestão do serviço de atendimento de ocorrências de urgências e emergências: Uma revisão integrativa. **Brazilian Journal of Development**, v. 7, n. 4, p. 40320-40340, 2021.

PHUYAL, Sudip; Bista, Diwakar; Bista, Rabindra. Challenges, opportunities and future directions of smart manufacturing: a state of art review. **Sustainable Futures**, v. 2, p. 100023, 2020.

POMEROL, Jean-Charles; Barba-Romero, Sergio. Multicriterion Decision In Management: Principles and Practice. **Springer Science & Business Media**, 2000.

PRAMONO, Sholeh Hadi et al. Deep learning-based short-term load forecasting for supporting demand response program in hybrid energy system. **Energies**, v. 12, n. 17, p. 3359, 2019.

PRESLEY, Adrien; Meade, Laura; Sarkis, Joseph. A strategic sourcing evaluation methodology for reshoring decisions. In: Supply Chain Forum: An International Journal. Taylor & Francis, v 17. n. 3, p. 156-169, 2016.

RAJPUT, Shubhangini; Singh, Surya Prakash. Connecting circular economy and industry 4.0. **International Journal of Information Management**, v. 49, p. 98-113, 2019.

RANGEL, Luís Alberto Duncan; Gomes, Luiz Flávio Autran Monteiro; MOREIRA, Rogério Amadel. Decision theory with multiple criteria: an application of ELECTRE IV and TODIM to SEBRAE/RJ. **Pesquisa Operacional**, v. 29, p. 577-590, 2009.

RAMACHANDRAN, Sakthivelan; Rajendran, Chandrasekharan; AMIRTHALINGAM, Veeraragavan. Decision support system for the maintenance management of road network considering multi-criteria. **International Journal of Pavement Research and Technology**, v. 12, p. 325-335, 2019.

RICHARDSON, Scott et al. The well-built clinical question: a key to evidence-based decisions. **ACP Journal Club**, v. 123, n. 3, p. A12-A13, 1995.

RUNDO, Francesco et al. Machine learning for quantitative finance applications: A survey. **Applied Sciences**, v. 9, n. 24, p. 5574, 2019.

SAATY, Roseanna. The analytic hierarchy process—what it is and how it is used. **Mathematical Modelling**, v. 9, n. 3-5, p. 161-176, 1987.

SAATY, Thomas Lorie. Response to Holder's comments on the analytic hierarchy process. **Journal of the Operational Research Society**, v. 42, n. 10, p. 909-914, 1991.

SAATY, Thomas Lorie. Decision making—the analytic hierarchy and network processes (AHP/ANP). **Journal of Systems Science and Systems Engineering**, v. 13, p. 1-35, 2004.

SAATY, Thomas Lorie. Decision making with the analytic hierarchy process. **International Journal of Services Sciences**, v. 1, n. 1, p. 83-98, 2008.

SACHDEVA, Anish; Kumar, Dinesh; Kumar, Pradeep. Planning and optimizing the maintenance of paper production systems in a paper plant. **Computers & Industrial Engineering**, v. 55, n. 4, p. 817-829, 2008.

SCHAFFER, Andrea; Dobbins, Timothy; Pearson, Sallie-Anne. Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. **BMC Medical Research Methodology**, v. 21, n. 1, p. 1-12, 2021.

SAHOO, Sushil Kumar; Goswami, Shankha Shubhra. A comprehensive review of multiple criteria decision-making (MCDM) Methods: advancements, applications, and future directions. **Decision Making Advances**, v. 1, n. 1, p. 25-48, 2023.

SALEM, Hanaa et al. Predictive modelling for solar power-driven hybrid desalination system using artificial neural network regression with Adam optimization. **Desalination**, v. 522, p. 115411, 2022.

SÁNCHEZ, Rodríguez Dey Salvador. Uso de métodos multicriteriais em PCP: aplicação do método AHP em previsão de demanda. 2011

SALZANO, Antonio et al. Existing assets maintenance management: Optimizing maintenance procedures and costs through BIM tools. **Automation in Construction**, v. 149, p. 104788, 2023.

SEITI, Hamidreza et al. Developing a novel risk-based MCDM approach based on D numbers and fuzzy information axiom and its applications in preventive maintenance planning. **Applied Soft Computing**, v. 82, p. 105559, 2019.

SEITI, Ewerton Gusthavo et al. Towards a smart workflow in CMMS/EAM systems: An approach based on ML and MCDM. **Journal of Industrial Information Integration**, v. 26, p. 100278, 2022.

SHARMA, Garima; Rai, Rajiv Nandan. Methodology to select human reliability analysis technique for repairable systems. In: Safety and Reliability Modeling and its Applications. **Elsevier**, p. 261-283, 2021.

SILVA, Aline Beatriz dos Santos et al. Auto-Regressive Integrated Moving Average Model (ARIMA): conceptual and methodological aspects and applicability in infant mortality. **Revista Brasileira de Saúde Materno Infantil**, v. 21, p. 647-656, 2021.

SILVESTRI, Luca et al. Maintenance transformation through Industry 4.0 technologies: A systematic literature review. **Computers in Industry**, v. 123, p. 103335, 2020.

SOTOUDEH-ANVARI, Alireza. The applications of MCDM methods in COVID-19 pandemic: A state of the art review. **Applied Soft Computing**, p. 109238, 2022.

SOTO-ACOSTA, Pedro. COVID-19 pandemic: Shifting digital transformation to a high-speed gear. Information **Systems Management**, v. 37, n. 4, p. 260-266, 2020.

SHAMEEM, Mohammad et al. Analytic hierarchy process based prioritization and taxonomy of success factors for scaling agile methods in global software development. **IET software**, v. 14, n. 4, p. 389-401, 2020.

THOMÉ, Antônio Márcio Tavares; Scavarda, Luiz Felipe; Scavarda, Annibal José. Conducting systematic literature review in operations management. **Production Planning & Control**, v. 27, n. 5, p. 408-420, 2016.

TOHANEAN, Dragos et al. Organizational performance and digitalization in industry 4.0. **Journal of Emerging Trends in Marketing and Management**, v. 1, n. 1, p. 282-288, 2018.

TSCHEIKNER-GRATL, Franz et al. Comparison of multi-criteria decision support methods for integrated rehabilitation prioritization. **Water**, v. 9, n. 2, p. 68, 2017.

TAN, Tan et al. Combining multi-criteria decision making (MCDM) methods with building information modelling (BIM): A review. **Automation in Construction**, v. 121, p. 103451, 2021.

URBANI, Michele et al. Maintenance-management in light of manufacturing 4.0. **Technical, Economic and Societal Effects of Manufacturing 4.0: Automation, Adaption and Manufacturing in Finland and Beyond**, p. 97-111, 2020.

VALLADARES, Gustavo Souza et al. Análise dos componentes principais e métodos multicritério ordinais no estudo de Organossolos e solos afins. **Revista Brasileira de Ciência do Solo**, v. 32, p. 285-296, 2008.

VON ENZBERG, Sebastian et al. Implementation and transfer of predictive analytics for smart maintenance: A case study. **Frontiers in Computer Science**, v. 2, p. 578469, 2020.

WACHOWICZ, Tomasz; Roszkowska, Ewa. How well may the direct linguistic declarations substitute AHP in defining accurate criteria weights? **International Transactions in Operational Research**, 2023.

WANG, Peng et al. Evaluation of ecological governance in the Yellow River basin based on Uninorm combination weight and MULTIMOORA-Borda method. **Expert Systems With Applications**, v. 235, p. 121227, 2024.

WIECKOWSKI, Jakub; Sałabun, Wojciech. Sensitivity analysis approaches in multi-criteria decision analysis: A systematic review. **Applied Soft Computing**, p. 110915, 2023.

WOHLIN, Claes. Guidelines for snowballing in systematic literature studies and a replication in software engineering. In: **Proceedings of the 18th International Conference On Evaluation And Assessment In Software Engineering**, p. 1-10, 2014.

YALCIN, Ahmet Selcuk; Kilic, Huseyin Selcuk; Delen, Dursun. The use of multi-criteria decision-making methods in business analytics: A comprehensive literature review. **Technological Forecasting and Social Change**, v. 174, p. 121193, 2022.

YIN, Robert Kuan. **Estudo de Caso: Planejamento e Métodos**. Bookman Editora, 2015.

ZHOU, Lin et al. Structural health monitoring of offshore wind power structures based on genetic algorithm optimization and uncertain analytic hierarchy process. **Ocean Engineering**, v. 218, p. 108201, 2020.

ZONTA, Tiago et al. Predictive maintenance in the Industry 4.0: A systematic literature review. **Computers & Industrial Engineering**, v. 150, p. 106889, 2020.

ZHU, Feilin et al. Selection of criteria for multi-criteria decision making of reservoir flood control operation. **Journal of Hydroinformatics**, v. 19, n. 4, p. 558-571, 2017.

Apêndice 1- Protocolo de estudo de caso

Elementos	Caracterização	Fase	Conclusão Sim/Não
Tipo de coleta de dados	Buscar esclarecimentos sobre a prática em explanatório, descritivo ou exploratório (Yin, 2015)	Preparação do estudo	Sim
Levantamento das teorias	Bases de dados (Yin, 2015)	Preparação do estudo	Sim
Escolha da Variação do estudo	Foco em uma ou mais unidade de análise; caso único ou múltiplo (Yin, 2015)	Visão geral do estudo de caso	Sim
Unidade de estudo	Qual a unidade a ser analisada? (Yin, 2015)	Preparação do estudo	Sim
Definição das questões de estudo	Como e por que com os objetivos da pesquisa (Yin, 2015)	Preparação do estudo	Sim
Definição do grupo focal	Obtenção de informações (Yin, 2015)	Preparação do estudo	Sim
Levantamento de fontes de evidências	Seja por documentos, registros em arquivos, entrevistas, observação direta ou participante e artefatos físicos (Yin, 2015)	Questões de coleta de dados	Sim
Validade do estudo	Avaliação e construção de explicações (Yin, 2015)	Questões de coleta de dados	Sim
Confiabilidade	Utilização do protocolo, rigor científico e controle de viés (Yin, 2015)	Preparação do estudo	Sim
Preparação do relatório	Uma tarefa essencial é definir o público-alvo podendo ser colegas acadêmicos, organizadores políticos, profissionais em geral, banca de tese ou dissertação, entre outros (Yin, 2015)	Relatórios e análise de dados	Sim
conteúdo	Responder se o estudo alerta para pontos de continuação. Contribuição em relação aos estudos anteriores, sendo documentos que não possuem uma receita única (Yin, 2015)	Relatórios e análise de dados	Sim

Tabela 16: Protocolo de estudo de caso

Apêndice 2 - Média geométrica do AHP – AIP

	Matriz De peso	Offset_01	Offset_02	Offset_03	Flexográfica _01	Calcográfica _01	Calcográfica _02	Calcográfica _03	Calcográfica _04
Cr01_Falhas	0,306978	0,130409	0,117810	0,077430	0,372768	0,095119	0,038805	0,088723	0,018099
Cr02_Seguranca	0,248831	0,137871	0,102170	0,080360	0,363760	0,101999	0,053128	0,076257	0,017822
Cr03_OEE	0,094700	0,108222	0,082528	0,082364	0,316991	0,091096	0,041618	0,141918	0,032925
Cr04_Custo	0,071401	0,172215	0,077901	0,082315	0,373790	0,078780	0,049056	0,087271	0,029576
Cr05_Preventiva	0,114977	0,129543	0,133933	0,071371	0,359957	0,069419	0,049457	0,087772	0,028823
Cr06_Treinamento	0,069083	0,175846	0,125426	0,074276	0,307055	0,063222	0,071937	0,085595	0,022056
Prioridade Final		0,854109	0,639770	0,468117	2,104324	0,499638	0,304003	0,566539	0,149305

Tabela 17: Média geométrica

Apêndice 3 - Resultados das avaliações pelo tomador de decisão dos decisores

Avaliações do decisor 01: Gerente

	Cr01_Falhas	Cr02_Seguranca	Cr03_OEE	Cr04_Custo	Cr05_Preventiva	Cr06_Treinamento
Cr01_Falhas	1,00	5,00	9,00	7,00	0,20	0,33
Cr02_Seguranca	0,20	1,00	7,00	9,00	0,20	0,14
Cr03_OEE	0,11	0,14	1,00	1,00	0,30	3,00
Cr04_Custo	0,14	0,11	1,00	1,00	0,30	0,20
Cr05_Preventiva	5,00	5,00	3,33	3,33	1,00	0,10
Cr06_Treinamento	3,03	7,14	0,33	5,00	10,00	1,00

Tabela 18: Comparações dos pesos dos critérios - gerente

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	0,11	3	5	0,11	3	3	3
Offset_02	9,09	1	7,00	5	0,11	5	3	5
calcográfica_03	0,33	0,14	1	7	0,14	1	3	9
Offset_01	0,20	0,20	0,14	1	0,14	0,11	3	5
serigráfica_01	9,09	9,09	7,14	7,14	1	7	9	7
calcográfica_02	0,33	0,20	1,00	9	0,14	1	5	7
Offset_03	0,33	0,33	0,33	0,33	0,11	0,20	1	7
calcográfica_04	0,33	0,20	0,11	0,20	0,14	0,14	0,14	1

Tabela 19: Comparações de alternativa para o critério "falha" gerente

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	0,33	9,00	9,00	0,14	3,00	3,00	3,00
Offset_02	3,03	1,00	7,00	5,00	0,11	3,00	0,20	9,00
calcográfica_03	0,11	0,14	1,00	9,00	0,11	1,00	0,11	7,00
Offset_01	0,11	0,20	0,11	1,00	0,11	0,11	0,33	5,00
serigráfica_01	7,14	9,09	9,09	9	1,00	7	9	7
calcográfica_02	0,33	0,33	1,00	9,00	0,14	1,00	0,11	9,00
Offset_03	0,33	5,00	9,09	3,03	0,11	9,09	1,00	7,00
calcográfica_04	0,33	0,11	0,14	0,20	0,14	0,11	0,14	1,00

Tabela 20: Comparações de alternativa para o critério “segurança” gerente.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	1	4	5	0,14	7	0,33	3
Offset_02	1,00	1	3	7	0,14	0,11	0,11	9
calcográfica_03	0,25	0,33	1	7	0,14	7	0,11	7
Offset_01	0,20	0,14	0,14	1	0,11	0,11	0,2	5
serigráfica_01	7,14	7,14	7,14	9	1	7	7	7
calcográfica_02	0,14	9,09	0,14	9	0,14	1	0,2	5
Offset_03	3,03	9,09	9,09	5,00	0,14	5,00	1	7
calcográfica_04	0,33	0,11	0,14	0,20	0,14	0,20	0,14	1

Tabela 21: Comparações de alternativa para o critério “OEE” gerente.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	5	5	5	0,11	5	5	0,5
Offset_02	0,20	1	5	7	0,11	7	5	7
calcográfica_03	0,20	0,20	1	7	0,2	5	5	0,2
Offset_01	0,20	0,14	0,14	1	0,11	0,11	5	5
serigráfica_01	9,09	9,09	5,00	9	1	7	9	7
calcográfica_02	0,20	0,14	0,20	9	0,14	1	0,11	0,3
Offset_03	0,20	0,20	0,20	0,20	0,11	9,09	1	9
calcográfica_04	2,00	0,14	5,00	0,20	0,14	3,33	0,11	1

Tabela 22: Comparações de alternativa para o critério “Custo” gerente.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	5	9	5	0,11	5	5	0,2
Offset_02	0,20	1	9	5	0,11	9	1	0,11
calcográfica_03	0,11	0,11	1	5	0,11	1	7	0,2
Offset_01	0,20	0,20	0,20	1	0,11	1,00	5	7
serigráfica_01	9,09	9,09	9,09	9	1	9	9	9
calcográfica_02	0,20	0,11	1,00	1	0,11	1	5	7
Offset_03	0,20	1,00	0,14	0,20	0,11	0,20	1	9
calcográfica_04	5,00	9,09	5,00	0,14	0,11	0,14	0,11	1

Tabela 23: Comparações de alternativa para o critério “preventiva gerente”.

	Offset_01	Offset_02	Offset_03	serigráfica_01	calcográfica_01	calcográfica_02	calcográfica_03	calcográfica_04
Offset_01	1	1	2	5	0,11	5	5	5
Offset_02	1,00	1	7	7	0,14	7	7	9
Offset_03	0,50	0,14	1	5	0,14	1	5	7
serigráfica_01	0,20	0,14	0,20	1	0,14	3,03	0,33	3
calcográfica_01	9,09	7,14	7,14	7	1	7	7	7
calcográfica_02	0,20	0,14	1,00	0,33	0,14	1	0,33	3
calcográfica_03	0,20	0,14	0,20	3,03	0,14	3,03	1	7
calcográfica_04	0,20	0,11	0,14	0,33	0,14	0,33	0,14	1

Tabela 24: Comparações de alternativa para o critério “treinamento gerente”.

Avaliações do decisor 02: Supervisor

	Cr01_Falhas	Cr02_Seguranca	Cr03_OEE	Cr04_Custo	Cr05_Preventiva	Cr06_Treinamento
Cr01_Falhas	1	1	9	5	3	3
Cr02_Seguranca	1,00	1	9	9	3	9
Cr03_OEE	0,11	0,11	1	5	3	3
Cr04_Custo	0,20	0,11	0,20	1	1	5
Cr05_Preventiva	0,33	0,33	0,33	1,00	1	9
Cr06_Treinamento	0,33	0,11	0,33	0,20	0,11	1

Tabela 25: Comparações dos pesos dos critérios - supervisor.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	5,00	9,00	4,00	0,11	9,00	0,11	9,00
Offset_02	0,20	1,00	3,00	5,00	0,11	5,00	0,50	9,00
calcográfica_03	0,11	0,33	1,00	7,00	0,11	5,00	0,33	9,00
Offset_01	0,25	0,20	0,14	1,00	0,11	0,20	0,20	4,00
serigráfica_01	9,09	9,09	9,09	9,00	1,00	9,00	9,00	9,00
calcográfica_02	0,11	0,20	0,20	5,00	0,11	1,00	0,33	5,00
Offset_03	9,00	2,00	3,00	5,00	0,11	3,00	1,00	5,00
calcográfica_04	0,11	0,11	0,11	0,25	0,11	0,20	0,20	1,00

Tabela 26: Comparações de alternativa x critério “falha” supervisor

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	7,00	7,00	7,00	0,14	7,00	0,20	3,00
Offset_02	0,14	1,00	0,14	0,50	0,14	3,00	0,33	7,00
calcográfica_03	0,14	7,14	1,00	9,00	0,33	1,00	0,33	5,00
Offset_01	0,14	2,00	0,11	1,00	0,14	0,20	0,20	5,00
serigráfica_01	7,14	7,14	3,03	7,00	1,00	1,00	7,00	7,00
calcográfica_02	0,14	0,33	1,00	5,00	1,00	1,00	0,20	5,00
Offset_03	5,00	3,00	3,00	5,00	0,14	5,00	1,00	9,00
calcográfica_04	0,33	0,14	0,20	0,20	0,14	0,20	0,11	1,00

Tabela 27: Comparações de alternativa x critério “segurança” supervisor

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	5,00	5,00	9,00	0,14	7,00	0,33	0,30
Offset_02	0,20	1,00	7,00	5,00	0,11	1,00	0,20	0,20
calcográfica_03	0,20	0,14	1,00	7,00	0,14	7,00	0,20	0,20
Offset_01	0,11	0,20	0,14	1,00	0,11	0,11	0,20	0,33
serigráfica_01	7,14	9,09	7,14	9,00	1,00	7,00	7,00	7,00
calcográfica_02	0,14	1,00	0,14	9,00	0,14	1,00	0,11	0,20
Offset_03	3,03	5,00	5,00	5,00	0,14	9,09	1,00	0,14
calcográfica_04	3,33	5,00	5,00	3,03	0,14	5,00	7,14	1,00

Tabela 28: Comparações de alternativa x critério "OEE" supervisor

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	5,00	7,00	5,00	0,11	7,00	0,11	7,00
Offset_02	0,20	1,00	1,00	5,00	0,14	0,17	0,33	0,20
calcográfica_03	0,14	1,00	1,00	5,00	0,11	7,00	0,33	4,00
Offset_01	0,20	0,20	0,20	1,00	0,14	0,20	1,00	5,00
serigráfica_01	9,09	6,94	9,09	7,00	1,00	9,00	9,00	9,00
calcográfica_02	0,14	5,88	0,14	5,00	0,11	1,00	0,33	5,00
Offset_03	9,09	3,03	3,03	1,00	0,11	3,03	1,00	9,00
calcográfica_04	0,14	5,00	0,25	0,20	0,11	0,20	0,11	1,00

Tabela 29: Comparações de alternativa x critério "Custo" supervisor

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	5	5	9	0,14	9	0,33	7
Offset_02	0,20	1	7	9	0,14	9	0,33	7
calcográfica_03	0,20	0,14	1	5	0,11	5	1,00	5
Offset_01	0,11	0,11	0,20	1	0,11	0,20	0,33	5
serigráfica_01	7,14	7,14	9,09	9	1	9	9,00	9
calcográfica_02	0,11	0,11	0,20	5	0,11	1	0,33	4
Offset_03	3,03	3,03	1,00	3,03	0,11	3,03	1	7
calcográfica_04	0,14	0,14	0,20	0,20	0,11	0,25	0,14	1

Tabela 30: Comparações de alternativa x critério "preventiva" supervisor

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	5	7	7	7	7	0,22	7
Offset_02	0,20	1	1	5	0,17	3	5,00	3
calcográfica_03	0,14	1,00	1	3	0,14	3	1,00	7
Offset_01	0,14	0,20	0,33	1	0,14	1,00	5,00	5
serigráfica_01	0,14	5,88	7,14	7	1	7	7,0	9
calcográfica_02	0,14	0,33	0,33	1	0,14	1	3,03	5
Offset_03	0,33	0,20	1,00	0,20	0,14	0,33	1	7
calcográfica_04	0,33	0,33	0,14	0,20	0,11	0,20	0,14	1

Tabela 31: Comparações de alternativa x critério "Treinamento supervisor

Avaliações do decisor 03: Técnico 01

	Cr01_Falhas	Cr02_Seguranca	Cr03_OEE	Cr04_Custo	Cr05_Preventiva	Cr06_Treinamento
Cr01_Falhas	1	5	7	9	3	3
Cr02_Seguranca	0,20	1	9	9	9	7
Cr03_OEE	0,14	0,11	1	1	3	3
Cr04_Custo	0,11	0,11	1,00	1	9	5
Cr05_Preventiva	0,33	0,11	0,33	0,11	1	9
Cr06_Treinamento	0,33	0,14	0,33	0,20	0,11	1

Tabela 32: Comparações dos pesos dos critérios - técnico 1

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	0,33	5,00	7,00	0,14	7,00	0,20	5,00
Offset_02	3,03	1,00	5,00	7,00	0,11	7,00	0,11	7,00
calcográfica_03	0,20	0,20	1,00	7,00	0,14	3,00	0,14	9,00
Offset_01	0,14	0,14	0,14	1,00	0,11	0,11	0,33	5,00
serigráfica_01	7,14	9,09	7,14	9,00	1,00	3,00	3,00	7,00
calcográfica_02	0,14	0,14	0,33	9,00	0,33	1,00	0,14	7,00
Offset_03	5,00	9,09	7,14	3,03	0,33	6,94	1,00	7,00
calcográfica_04	0,20	0,14	0,11	0,20	0,14	0,14	0,14	1,00

Tabela 33: Comparações de alternativa x critério “falha” técnico 1.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	3,00	7,00	5,00	0,11	5,00	5,00	5,00
Offset_02	0,33	1,00	7,00	7,00	0,11	9,00	7,00	9,00
calcográfica_03	0,14	0,14	1,00	5,00	0,20	5,00	5,00	7,00
Offset_01	0,20	0,14	0,20	1,00	0,11	0,11	3,00	5,00
serigráfica_01	9,09	9,09	5,00	9,00	1,00	7,00	7,00	9,00
calcográfica_02	0,20	0,11	0,20	9,00	0,14	1,00	7,00	7,00
Offset_03	0,20	0,14	0,20	0,33	0,14	0,14	1,00	5,00
calcográfica_04	0,20	0,11	0,14	0,20	0,11	0,14	0,20	1,00

Tabela 34: Comparações de alternativa x critério “segurança” técnico 1.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	3,00	7,00	7,00	0,14	7,00	0,14	7,00
Offset_02	0,33	1,00	9,00	7,00	0,11	9,00	0,20	7,00
calcográfica_03	0,14	0,11	1,00	5,00	0,20	5,00	0,20	7,00
Offset_01	0,14	0,14	0,20	1,00	0,14	0,11	0,20	5,00
serigráfica_01	7,14	9,09	5,00	7,00	1,00	7,00	0,20	7,00
calcográfica_02	0,14	0,11	0,20	9,00	0,14	1,00	0,14	7,00
Offset_03	7,14	5,00	5,00	5,00	5,00	7,14	1,00	5,00
calcográfica_04	0,14	0,14	0,14	0,20	0,14	0,14	0,20	1,00

Tabela 35: Comparações de alternativa x critério "OEE" técnico 1.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	7,00	7,00	5,00	0,11	5,00	5,00	5,00
Offset_02	0,14	1,00	5,00	5,00	0,20	7,00	5,00	7,00
calcográfica_03	0,14	0,20	1,00	7,00	0,11	5,00	0,14	5,00
Offset_01	0,20	0,20	0,14	1,00	0,11	0,11	0,20	5,00
serigráfica_01	9,09	5,00	9,09	9,00	1,00	5,00	5,00	7,00
calcográfica_02	0,20	0,14	0,20	9,00	0,20	1,00	0,20	5,00
Offset_03	0,20	0,20	7,00	5,00	0,20	5,00	1,00	9,00
calcográfica_04	0,20	0,14	0,20	0,20	0,14	0,20	0,11	1,00

Tabela 36: Comparações de alternativa x critério "Custo" técnico 1.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	0,14	7,00	7,00	0,20	7,00	0,11	7,00
Offset_02	7,14	1,00	7,00	7,00	0,20	5,00	0,11	9,00
calcográfica_03	0,14	0,14	1,00	5,00	0,11	5,00	0,20	3,00
Offset_01	0,14	0,14	0,20	1,00	0,14	1,00	0,20	7,00
serigráfica_01	5,00	5,00	9,09	7,00	1,00	9,00	7,00	5,00
calcográfica_02	0,14	0,20	0,20	1,00	0,11	1,00	0,11	5,00
Offset_03	9,09	9,09	5,00	5,00	0,14	9,09	1,00	7,00
calcográfica_04	0,14	0,11	0,33	0,14	0,20	0,20	0,14	1,00

Tabela 37: Comparações de alternativa x critério "preventiva" técnico 1.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	0,20	5,00	5,00	0,20	5,00	0,14	5,00
Offset_02	5,00	1,00	7,00	5,00	0,20	9,00	0,11	9,00
calcográfica_03	0,20	0,14	1,00	5,00	0,33	1,00	0,11	7,00
Offset_01	0,20	0,20	0,20	1,00	0,33	1,00	0,20	3,00
serigráfica_01	5,00	5,00	3,03	3,00	1,00	5,00	7,00	7,00
calcográfica_02	0,20	0,11	1,00	1,00	0,20	1,00	0,33	3,00
Offset_03	7,14	9,09	9,09	5,00	0,14	3,03	1,00	9,00
calcográfica_04	0,20	0,11	0,14	0,33	0,14	0,33	0,11	1,00

Tabela 38: Comparações de alternativa x critério “treinamento” técnico 1.

Avaliações do decisor 04: Técnico 02

	Cr01_Falhas	Cr02_Seguranca	Cr03_OEE	Cr04_Custo	Cr05_Preventiva	Cr06_Treinamento
Cr01_Falhas	1	5	9	7	5	3
Cr02_Seguranca	0,20	1	7	9	5	7
Cr03_OEE	0,11	0,14	1	1	3	3
Cr04_Custo	0,14	0,11	1,00	1	7	3
Cr05_Preventiva	0,20	0,20	0,33	0,14	1	7
Cr06_Treinamento	0,33	0,14	0,33	0,33	0,14	1

Tabela 39: Comparações dos pesos dos critérios – técnico 2.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	7	9	7	0,14	0,11	9	7
Offset_02	0,14	1	3	5	0,14	0,20	5	5
calcográfica_03	0,11	0,33	1	5	0,14	0,14	5	3
Offset_01	0,14	0,20	0,20	1	0,14	0,11	9	5
serigráfica_01	7,14	7,14	7,14	7	1	5	7	7
calcográfica_02	9,09	5,00	7,14	9	0,20	1	9	7
Offset_03	0,11	0,20	0,20	0,11	0,14	0,11	1	9
calcográfica_04	0,14	0,20	0,33	0,20	0,14	0,14	0,11	1

Tabela 40: Comparações de alternativa x critério “falha” técnico 2.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1,00	5,00	9,00	0,20	0,11	0,14	7,00	3,00
Offset_02	0,20	1,00	7,00	0,14	0,14	0,14	7,00	9,00
calcográfica_03	0,11	0,14	1,00	0,20	0,14	0,11	9,00	7,00
Offset_01	5,00	7,14	5,00	1,00	0,14	5,00	5,00	5,00
serigráfica_01	9,09	7,14	7,14	7,00	1,00	7,00	7,00	7,00
calcográfica_02	7,14	7,14	9,09	0,20	0,14	1,00	9,00	9,00
Offset_03	0,14	0,14	0,11	0,20	0,14	0,11	1,00	7,00
calcográfica_04	0,33	0,11	0,14	0,20	0,14	0,11	0,14	1,00

Tabela 41: Comparações de alternativa x critério “segurança” técnico 2.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	1	4	5	0,2	0,14	1	3
Offset_02	1,00	1	1	5	0,2	0,33	7	9
calcográfica_03	0,25	1,00	1	7	0,2	0,14	9	7
Offset_01	0,20	0,20	0,14	1	0,14	0,11	5	5
serigráfica_01	5,00	5,00	5,00	7	1	7	7	9
calcográfica_02	7,14	3,03	7,14	9	0,14	1	9	5
Offset_03	1,00	0,14	0,11	0,20	0,14	0,11	1	7
calcográfica_04	0,33	0,11	0,14	0,20	0,11	0,20	0,14	1

Tabela 42: Comparações de alternativa para o critério "OEE" técnico 2.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	7	7	9	0,11	5	7	9
Offset_02	0,14	1	1	5	0,11	0,2	5	7
calcográfica_03	0,14	1,00	1	7	0,14	0,11	9	5
Offset_01	0,11	0,20	0,14	1	0,14	0,11	5	5
serigráfica_01	9,09	9,09	7,14	7	1	7	7	7
calcográfica_02	0,20	5,00	9,09	9	0,14	1	9	6
Offset_03	0,14	0,20	0,11	0,20	0,14	0,11	1	9
calcográfica_04	0,11	0,14	0,20	0,20	0,14	0,17	0,11	1

Tabela 43: Comparações de alternativa x critério "Custo" técnico 2.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	5	5	1	0,2	0,11	9	5
Offset_02	0,20	1	7	5	0,2	0,11	9	5
calcográfica_03	0,20	0,14	1	5	0,2	0,11	5	7
Offset_01	1,00	0,20	0,20	1	0,14	1,00	3	7
serigráfica_01	5,00	5,00	5,00	7	1	7	7	7
calcográfica_02	9,09	9,09	9,09	1	0,14	1	9	7
Offset_03	0,11	0,11	0,20	0,33	0,14	0,11	1	9
calcográfica_04	0,20	0,20	0,14	0,14	0,14	0,14	0,11	1

Tabela 44: Comparações de alternativa x critério "preventiva" técnico 2.

	calcográfica_01	Offset_02	calcográfica_03	Offset_01	serigráfica_01	calcográfica_02	Offset_03	calcográfica_04
calcográfica_01	1	7	9	5	0,2	0,14	9	7
Offset_02	0,14	1	5	5	0,2	0,2	5	3
calcográfica_03	0,11	0,20	1	3	0,2	0,11	9	5
Offset_01	0,20	0,20	0,33	1	0,20	1,00	9	3
serigráfica_01	5,00	5,00	5,00	5	1	5	5	5
calcográfica_02	7,14	5,00	9,09	1	0,20	1	3	5
Offset_03	0,11	0,20	0,11	0,11	0,20	0,33	1	9
calcográfica_04	0,14	0,33	0,20	0,33	0,20	0,20	0,11	1

Tabela 45: Comparações de alternativa x critério “treinamento” técnico 2

Apêndice 4 – Diagrama com o produto da pesquisa de dissertação

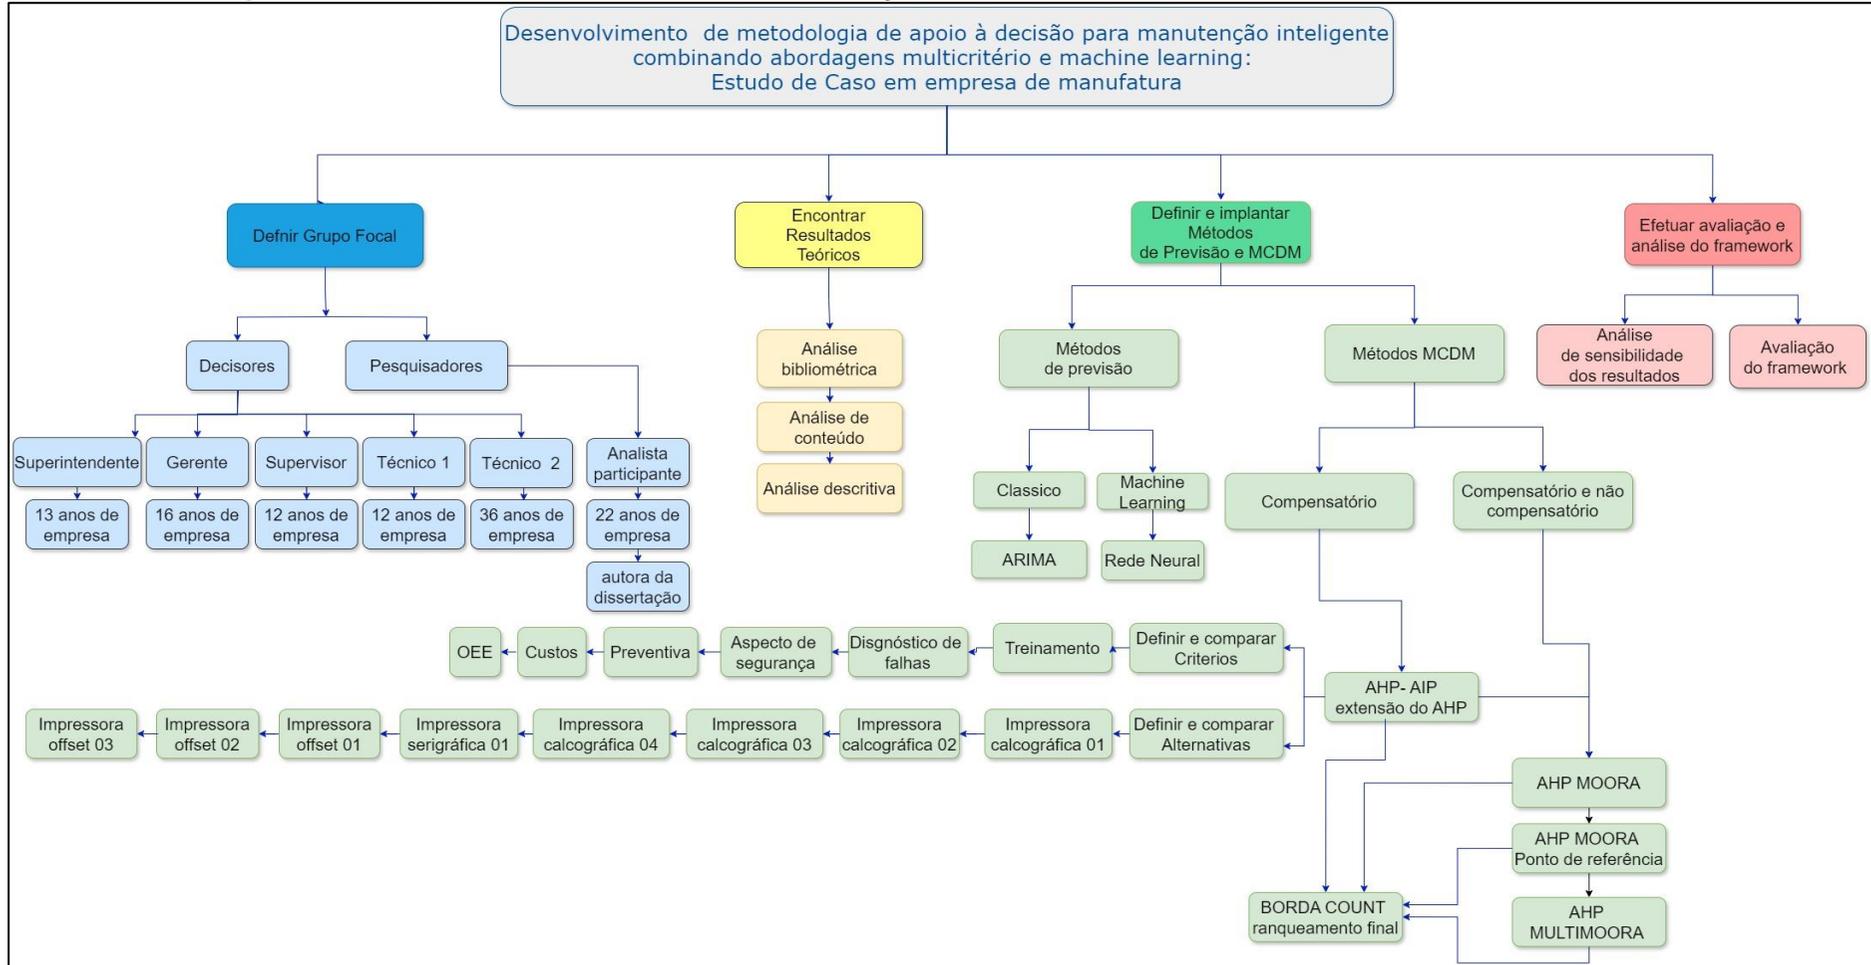


Figura 35 – Árvore de decisão da pesquisa