

**MINISTÉRIO DA DEFESA
EXÉRCITO BRASILEIRO
DEPARTAMENTO DE CIÊNCIA E TECNOLOGIA
INSTITUTO MILITAR DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE DEFESA**

JOSÉ VICTOR DE PINA CORRIÇA

**MADRID: CLUSTERIZAÇÃO HIERÁRQUICA INTEGRADA À MODELAGEM
MULTICRITÉRIO PARA TOMADA DE DECISÃO COM APOIO À
IDENTIFICAÇÃO DE CRITÉRIOS RELEVANTES NO
CENÁRIO DE APLICAÇÃO**

**RIO DE JANEIRO
2025**

JOSÉ VICTOR DE PINA CORRIÇA

MADRID: CLUSTERIZAÇÃO HIERÁRQUICA INTEGRADA À MODELAGEM
MULTICRITÉRIO PARA TOMADA DE DECISÃO COM APOIO À
IDENTIFICAÇÃO DE CRITÉRIOS RELEVANTES NO
CENÁRIO DE APLICAÇÃO

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Defesa do Instituto Militar de Engenharia, como requisito parcial para a obtenção do título de Mestre em Ciências em Engenharia de Defesa.

Orientadores: Paulo César Pellanda, Dr. ENSAE
Ronaldo Ribeiro Goldschmidt, D.Sc.
Marcos dos Santos, D.Sc.

Rio de Janeiro
2025

©2025

INSTITUTO MILITAR DE ENGENHARIA

Praça General Tibúrcio, 80 – Praia Vermelha

Rio de Janeiro – RJ CEP: 22290-270

Este exemplar é de propriedade do Instituto Militar de Engenharia, que poderá incluí-lo em base de dados, armazenar em computador, microfilmар ou adotar qualquer forma de arquivamento.

É permitida a menção, reprodução parcial ou integral e a transmissão entre bibliotecas deste trabalho, sem modificação de seu texto, em qualquer meio que esteja ou venha a ser fixado, para pesquisa acadêmica, comentários e citações, desde que sem finalidade comercial e que seja feita a referência bibliográfica completa.

Os conceitos expressos neste trabalho são de responsabilidade do autor e dos orientadores.

Corriça, José Victor de Pina.

MADRID: Clusterização Hierárquica Integrada à Modelagem Multicritério para Tomada de Decisão com Apoio à Identificação de Critérios Relevantes no Cenário de Aplicação / José Victor de Pina Corriça. – Rio de Janeiro, 2025.

83 f.

Orientadores: Paulo César Pellanda, Ronaldo Ribeiro Goldschmidt e Marcos dos Santos.

Dissertação (mestrado) – Instituto Militar de Engenharia, Engenharia de Defesa, 2025.

1. apoio à decisão; modelagem multicritério; produtos de defesa; clusterização hierárquica; aprendizado de máquina. i. Pellanda, Paulo César (orient.) ii. Goldschmidt, Ronaldo Ribeiro (orient.) iii. Santos, Marcos dos (orient.) iv. Título


JOSÉ VICTOR DE PINA CORRIÇA

**MADRID: Clusterização Hierárquica Integrada à
Modelagem Multicritério para Tomada de Decisão com
Apoio à Identificação de Critérios Relevantes no
Cenário de Aplicação**


Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Defesa do Instituto Militar de Engenharia, como requisito parcial para a obtenção do título de Mestre em Ciências em Engenharia de Defesa.

Orientadores: Paulo César Pellanda, Ronaldo Ribeiro Goldschmidt e Marcos dos Santos.

Aprovada em 27 de fevereiro de 2025, pela seguinte banca examinadora:




Prof. **Paulo César Pellanda** - Dr. ENSAE do IME - Presidente




Prof. **Ronaldo Ribeiro Goldschmidt** - D.Sc. do IME



Prof. **Marcos dos Santos** - D.Sc. do IME



Prof. **Julio Cesar Duarte** - D.Sc. do IME



Prof. **Daniel Augusto de Moura Pereira** - D.Sc. do UFCG

Rio de Janeiro
2025

Dedico este trabalho a todos que, direta ou indiretamente, contribuíram para minha trajetória acadêmica, oferecendo apoio, incentivo e sabedoria ao longo do caminho. Em especial, à minha família, amigos e orientadores, que foram pilares fundamentais nessa conquista.

AGRADECIMENTOS

Primeiramente, expresso minha profunda gratidão a Deus e a Meishu-Sama por me abençoarem com saúde, força e determinação, permitindo-me trilhar minha jornada acadêmica com dedicação e disciplina. Aos meus queridos pais, Camilo e Vera, os quais estiveram ao meu lado durante todos os momentos da minha vida me dando força e suporte incondicional para que eu pudesse prosseguir na busca pelos meus objetivos. Ao meu orientador Professor Dr. Paulo César Pellanda, registro minha mais profunda gratidão pelo inestimável suporte prestado ao longo deste período, cuja orientação precisa e direcionamento assertivo foram fundamentais e indispensáveis para a conclusão deste estudo. Ao meu orientador Professor Dr. Ronaldo Ribeiro Goldschmidt, agradeço profundamente pela orientação de excelência, cujas contribuições foram cruciais para a condução e o aperfeiçoamento desta pesquisa. Ao meu orientador Professor Dr. Marcos dos Santos, registro minha sincera gratidão pelo inestimável apoio ao longo de todo o processo de desenvolvimento deste trabalho. Aos meus orientadores técnicos da Marinha do Brasil CMG(RM1) Richard Harold Geraldo Asch e CC(EN) Yuri Marchetti Tavares, pela orientação e apoio fundamentais ao desenvolvimento desta pesquisa, meus sinceros agradecimentos. Aos estimados Professores do Programa de Pós-graduação em Engenharia de Defesa, cujos preciosos ensinamentos transmitidos ampliaram de forma inestimável meu conhecimento, contribuindo significativamente para o meu desenvolvimento intelectual e pessoal. Aos membros da banca examinadora, Professor Dr. Julio Cesar Duarte e Professor Dr. Daniel Augusto de Moura Pereira, registro minha sincera gratidão pela generosidade em aceitar participar deste processo avaliativo. Ao Exército Brasileiro e aos docentes e discentes do Instituto Militar de Engenharia, deixo aqui meu profundo e sincero sentimento de gratidão pela experiência acadêmica vivenciada ao longo desses dois anos de mestrado.

“O segredo do sucesso reside na força de vontade e no empenho para alcançá-lo”.
(Mokiti Okada)

RESUMO

O trabalho propõe o desenvolvimento do método Multicriteria Analysis Directed by Ranking and Integrated Data-clustering (MADRID), um método inovador que integra a Clusterização, uma técnica de Aprendizado de Máquina não supervisionado, com a Análise Multicritério à Decisão (AMD), com foco na otimização de processo de aquisição de novos meios da Marinha do Brasil, com o propósito de fortalecer as suas capacidades operacionais de forma a permitir atender o definido no Plano Estratégico da Marinha (PEM-2040), na Política e Estratégia Nacional de Defesa e no Livro Branco de Defesa Nacional, de garantir a soberania nacional, a proteção das águas jurisdicionais e o cumprimento de suas missões estratégicas. O método proposto aplica a técnica de clusterização pelo método hierárquico aglomerativo single linkage, empregando o método híbrido DIBR-MABAC para ordenação dos cluster pelos valores dos centróides, realiza o ranqueamento das alternativas dentro de cada cluster e efetua o ranqueamento final do método composto pelas alternativas contidas na matriz de decisão final, a qual contém todas as alternativas do cluster mais bem ranqueado conjuntamente com as alternativas mais bem avaliadas dos demais cluster. O estudo de caso avaliou um grupo de seis veículos aéreos não tripulados (VANT) à luz de sete critérios. Para realizar a análise de sensibilidade, neste estudo optou-se pela comparação entre os ranqueamentos gerados por meio da variação dos pesos dos critérios e, para isso, foram criados dois cenários onde foram variados os pesos. O método MADRID ranqueou os VANTs e apresentou uma alta correlação com os resultados gerados pelos dois cenários em questão, comprovando sua robustez e aplicabilidade. Além disso, foi desenvolvida uma ferramenta computacional a qual aplica o método MADRID, possibilitando uma interface intuitiva e simples com o usuário para emprego prático do método. Na apresentação da plataforma computacional, o software foi aplicado em uma matriz de decisão com dados hipotéticos de aeronaves e apresentou uma correlação de 0,96 com o método COCOSO e de 0,97 com o método TOPSIS, destacando-o como uma ferramenta prática e precisa no apoio à decisão. Por fim, o método MADRID se configura como uma contribuição relevante para a avaliação de produtos de defesa e a tomada de decisões, apresentando potencial para ser aplicado em diversas áreas do conhecimento.

Palavras-chave: apoio à decisão; modelagem multicritério; produtos de defesa; clusterização hierárquica; aprendizado de máquina.

ABSTRACT

The study proposes the development of the Multicriteria Analysis Directed by Ranking and Integrated Data-clustering (MADRID) method, an innovative approach that integrates Clustering, an unsupervised Machine Learning technique, with Multicriteria Decision Making (MCDM), focusing on optimizing the acquisition process of new assets for the Brazilian Navy to strengthen its operational capabilities to meet the guidelines established in the "Plano Estratégico da Marinha (PEM-2040)", the National Defense Policy and Strategy, and the National Defense White Paper, ensuring national sovereignty, the protection of jurisdictional waters, and the fulfilment of strategic missions. The proposed method applies clustering using the hierarchical agglomerative single linkage method, employing the hybrid DIBR-MABAC method to rank clusters based on the values of their centroids, ranking the alternatives within each cluster, and performing the final ranking of the method, which consists of the alternatives contained in the final decision matrix. This matrix includes all the alternatives from the highest-ranked cluster and the best-evaluated alternatives from the other clusters. The case study assessed a group of six unmanned aerial vehicles (UAVs) based on seven criteria. To conduct the sensitivity analysis, this study chose to compare rankings generated by varying the criteria weights. For this purpose, two scenarios were created where the weights were modified. The MADRID method ranked the UAVs and correlated highly with the results obtained from both scenarios, demonstrating its robustness and applicability. A computational tool was also developed to implement the MADRID method, providing an intuitive and user-friendly interface for practical application. During the presentation of the computational platform, the software was applied to a decision matrix with hypothetical aircraft data, achieving a correlation of 0.96 with the COCOSO method and 0.97 with the TOPSIS method, highlighting MADRID as a practical and precise tool in decision support. Finally, the MADRID method is a relevant contribution to evaluating defense products and decision-making processes, with potential applications across various fields of knowledge.

Keywords: decision making; Multicriteria modeling; defense products; hierarchical clustering; machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Publicações por ano.	19
Figura 2 – Esquema de aglomeração em análise de agrupamentos.	30
Figura 3 – Ilustração dos elementos envolvidos no cálculo de $s(i)$, onde o objeto i pertence ao cluster A	32
Figura 4 – Agrupamento com linhas representando as distâncias do i -ésimo ponto aos demais elementos da amostra.	33
Figura 5 – Fases do processo de seleção.	37
Figura 6 – Posição das alternativas em relação a área aproximada da fronteira. . .	48
Figura 7 – Primeiro diagrama do método MADRID.	52
Figura 8 – Diagrama do método MADRID.	53
Figura 9 – Funcionalidades da plataforma.	56
Figura 10 – Entrada de dados.	58
Figura 11 – Seleção da ordem de significância dos critérios.	58
Figura 12 – Definição da interrelação entre os critérios.	59
Figura 13 – Resultado dos pesos dos critérios.	59
Figura 14 – Gráfico de dendrograma.	60
Figura 15 – Gráfico de silhueta.	61
Figura 16 – Matriz dos centróides.	61
Figura 17 – Análise dos clusters.	62
Figura 18 – Matriz de decisão final.	63
Figura 19 – Ranqueamento final do método MADRID.	63
Figura 20 – Gráfico de silhueta.	68

LISTA DE TABELAS

Tabela 1 – Artigos mais relevantes.	18
Tabela 2 – Resumo dos métodos que empregaram Clusterização e AMD.	40
Tabela 3 – Matriz de decisão.	55
Tabela 4 – Ranqueamento gerado pelos métodos.	64
Tabela 5 – Relacionamento e escala.	67
Tabela 6 – Dados das alternativas.	67
Tabela 7 – Ordem de significância entre os critérios adjacentes.	68
Tabela 8 – Peso dos critérios.	68
Tabela 9 – Matriz de centróides dos clusters.	68
Tabela 10 – Ordenação dos clusters pelos valores dos centróides.	69
Tabela 11 – Ordenação das alternativas de cada cluster.	69
Tabela 12 – Ordenação global do método MADRID.	70
Tabela 13 – Ordenação dos clusters e pesos gerados no cenário 1.	70
Tabela 14 – Ordenação dos clusters e pesos gerados no cenário 2.	71

LISTA DE ABREVIATURAS E SIGLAS

AHP	Analytic Hierarchy Process
AM	Aprendizado de Máquina
AMD	Apoio Multicritério à Decisão
ANP	Analytic Network Process
ARAS	Additive Ratio Assessment
BID	Base Industrial de Defesa
BWM	Best-Worst Method
COPRAS	Complex Proportional Assessment
CRITIC	Criteria Importance Through Intercriteria Correlation
DEMATEL	Decision Making Trial and Evaluation Laboratory
DIBR	Defining Interrelationships Between Ranked Criteria
ELECTRE	ELimination Et Choix Traduisant la REalité
FAHP	Fuzzy Analytical Hierarchy Process
FCM	Fuzzy C-Means
FMCDM	Fuzzy Multi-Criteria Decision Making
MABAC	Multi-Attribute Border Approximation area Comparison
MADRID	Multicriteria Analysis Directed by Ranking and Integrated Data Clustering
MAIRCA	Multi-Attribute Ideal-Real Comparative Analysis
MB	Marinha do Brasil
PEM	Plano Estratégico da Marinha
PO	Pesquisa Operacional
PROMETHEE	Preference Ranking Organization Method for Enrichment Evaluations

MDHC	Multicriteria Divisive Hierarchical Clustering
RSL	Revisão Sistemática da Literatura
SMAA	Stochastic Multicriteria Acceptability Analysis
SWARA	Step-Wise Weight Assessment Ratio Analysis
TODIM	Tomada de Decisão Iterativa Multicritério
TOPSIS	Technique for Order Preference by Similarity to Ideal Solution

SUMÁRIO

1	INTRODUÇÃO	15
1.1	MOTIVAÇÃO	17
1.2	CARACTERIZAÇÃO DO PROBLEMA	19
1.3	OBJETIVOS	20
1.3.1	OBJETIVOS ESPECÍFICOS	20
1.4	JUSTIFICATIVA	20
1.5	CONTRIBUIÇÃO ESPERADA	24
1.6	ESTRUTURA DO TRABALHO	25
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	APOIO MULTICRITÉRIO À DECISÃO (AMD)	26
2.2	A CLUSTERIZAÇÃO	28
2.2.0.1	O MÉTODO DA SILHUETA	31
2.3	A CLUSTERIZAÇÃO E OS MÉTODOS AMD	33
3	TRABALHOS RELACIONADOS	36
4	O MÉTODO MADRID	42
4.1	CLUSTERIZAÇÃO HIERÁRQUICA <i>SINGLE-LINKAGE</i>	44
4.2	DIBR (<i>DEFINING INTERRELATIONSHIPS BETWEEN RANKED CRITERIA</i>)	46
4.3	MABAC (<i>MULTI-ATTRIBUTIVE BORDER APPROXIMATION AREA COMPARISON</i>)	47
4.4	MÉTODO HÍBRIDO DIBR-MABAC	50
4.5	ESTRUTURA DO MÉTODO MADRID	51
4.6	PLATAFORMA COMPUTACIONAL	55
4.6.1	APLICAÇÃO PRÁTICA DO MÉTODO MADRID	55
4.6.2	FERRAMENTA COMPUTACIONAL MADRID	56
4.6.3	ANÁLISE DE SENSIBILIDADE	63
5	ESTUDO DE CASO	66
5.1	SOLUÇÃO DO PROBLEMA	66
5.2	CÁLCULO DOS PESOS DOS CRITÉRIOS	67
5.3	APLICAÇÃO DA TÉCNICA DE CLUSTERIZAÇÃO HIERÁRQUICA <i>SINGLE LINKAGE</i>	68
5.4	ORDENAÇÃO GLOBAL E CLASSIFICAÇÃO DAS ALTERNATIVAS	69
5.5	ANÁLISE DOS RESULTADOS	70

6	CONCLUSÃO	73
6.1	PROPOSTA PARA TRABALHOS FUTUROS	74
	REFERÊNCIAS	76
	APÊNDICE A – CONTRIBUIÇÕES PARA A PESQUISA	83

1 INTRODUÇÃO

O Programa de Pós-graduação em Engenharia de Defesa do IME visa, a partir de uma formação fortemente assentada na pesquisa básica de qualidade, com inserção internacional e caráter inter e multidisciplinar, preencher essa demanda nacional de pessoal altamente qualificado e especializado nas áreas de ciências e engenharias, contribuindo para esse novo papel reservado ao Brasil no cenário geopolítico mundial. No entanto, em contraste com a realidade internacional descrita, na esfera nacional, a indústria de defesa diminuiu consideravelmente o seu tamanho e importância ao longo dos anos oitenta e noventa (ADESA; PELLANDAA; BORGES JUNIOR, 2010).

Adicionalmente, a necessidade de vigilância e defesa do nosso território de dimensões continentais, em especial da cobiçada região amazônica, leva a uma crescente conscientização da importância da área científico-tecnológica para a soberania e segurança nacionais. Do mesmo modo, pode-se citar a necessidade de defesa e soberania na área denominada Amazônia Azul, que engloba a zona economicamente exclusiva, onde estão localizadas as reservas de petróleo da camada do pré-sal (ADESA; PELLANDAA; BORGES JUNIOR, 2010).

O Aprendizado de Máquina (AM) é, em sua essência, a extração de conhecimento a partir de bases de dados. Por envolver áreas como a Estatística, a Inteligência Artificial e a Ciência da Computação, é popularmente visto como uma subárea que tange tópicos como a análise preditiva e o aprendizado estatístico (BAKSHI; BAKSHI, 2018) e que compreende métodos computacionais para a aquisição de novos conhecimentos, novas habilidades e novas maneiras de organizar o conhecimento existente (TYUGU, 2011). Além disso, sistemas de aprendizado de máquina são usados para identificar objetos em imagens, transcrever fala em texto, combinar notícias, postagens ou produtos com os interesses dos usuários e selecionar resultados de pesquisa relevantes (LECUN; BENGIO; HINTON, 2015).

A clusterização, uma técnica do aprendizado de máquina não supervisionado, é muito comum para análise estatística de dados, usada em muitos campos, incluindo aprendizado de máquina, mineração de dados, reconhecimento de padrões, análise de imagens e bioinformática. Esta técnica consiste no processo de agrupar objetos semelhantes em diferentes grupos, ou mais precisamente, o particionamento de um conjunto de dados em subconjuntos, de modo que os dados em cada subconjunto sejam agrupados de acordo com alguma medida de distância definida (MADHULATHA, 2012).

De acordo com Fávero e Belfiore (2017), os métodos de clusterização são classificados em hierárquicos e não hierárquicos. Os hierárquicos se caracterizam por favorecer uma

estrutura hierárquica (passo a passo) para a formação dos agrupamentos e podem ser aglomerativos, quando começam com cada observação isolada e unem grupos com base em semelhanças ou distâncias até formar um único agrupamento, ou divisivos, que partem de um único grupo e o dividem sucessivamente. Entre os métodos aglomerativos destacam-se o encadeamento único (single linkage), completo (complete linkage) e médio (average linkage). Já os métodos não hierárquicos, como o k-means, definem previamente o número de clusters e alocam as observações aos seus centros de aglomeração, buscando maximizar a homogeneidade interna. Quando não há estimativa inicial sobre o número de clusters, recomenda-se aplicar um método hierárquico antes de usar um método não hierárquico, pois os primeiros permitem explorar diferentes possibilidades de agrupamento ao longo de seus estágios.

Dentre essas técnicas de clusterização, destaca-se o método hierárquico aglomerativo, no qual são formados agrupamentos cada vez maiores a cada estágio de aglomeração pela junção de novas observações ou grupos, em função de determinado critério (método de encadeamento) e com base na medida de distância escolhida (FÁVERO; BELFIORE, 2017). O método hierárquico aglomerativo single linkage privilegia as menores distâncias para que sejam formados novos agrupamentos a cada estágio de aglomeração pela incorporação de observações ou grupos (FÁVERO; BELFIORE, 2017).

Para Belfiore e Fávero (2013), a Pesquisa Operacional (PO) é composta da utilização de métodos de origem científica, como modelos estatísticos por exemplo, matemáticos e algoritmos computacionais, como ferramentas para auxiliar no processo decisório de um determinado cenário. Ela é amplamente aplicada em situações que requerem a alocação de recursos variados, principalmente em condições de escassez. Dentro do vasto campo da PO, o Apoio Multicritério à Decisão (AMD) possui relevância ímpar, proporcionando um embasamento técnico e científico, apoiando o decisor na escolha pela alternativa que supra as necessidades e anseios de forma mais eficiente (DE ARAÚJO COSTA et al., 2020). Neste contexto, o Apoio Multicritério à Decisão é usado para descrever um conjunto de abordagens formais que buscam levar em conta, de forma explícita, vários critérios para ajudar as partes interessadas e grupos a explorarem decisões importantes (BELTON; STEWART, 2002). Apesar da diversidade de abordagens, métodos e técnicas multicritério, os componentes básicos do AMD são um conjunto finito ou infinito de ações (alternativas, soluções, cursos de ação etc.), pelo menos dois critérios e pelo menos um Decisor (DM – Decision Maker). Diante desses elementos básicos, o AMD é uma atividade que auxilia na tomada de decisões, principalmente no que se refere à escolha, classificação ou ordenação das ações (GRECO; FIGUEIRA; EHRGOTT, 2016a).

Além disso, a tomada de decisões é um processo vital para a academia e sociedade, desde economia e negócios até ciência, engenharia e setores governamentais. A complexidade das decisões muitas vezes envolve a consideração de múltiplos critérios, cada um com

seu peso e importância relativa. Nesse contexto, os métodos AMD desempenham um papel crucial na avaliação de alternativas e na escolha da melhor solução (BELTON; STEWART, 2002). Como exemplos de trabalhos que empregam técnicas de clusterização em problemáticas de AMD com o propósito de aprimorar a tomada de decisão, pode-se citar: Dahooi et al. (2019) lançaram o método FCM-ARAS, utilizando a técnica de clusterização não hierárquica Fuzzy C-Means (FCM) em conjunto com o método multicritério ARAS para a avaliação do desempenho financeiro das empresas; e Swindiarto et al. (2018) lançaram o método FCM-TOPSIS, realizando o agrupamento pela técnica FCM conjuntamente com o método Technique for Order Preference by Similarity to Ideal Solution (TOPSIS) para avaliação de desempenho com múltiplos critérios.

Em vista do exposto, esta Dissertação propõe o desenvolvimento de um novo método de suporte à decisão o qual apresenta uma nova forma de combinação das técnicas de Clusterização e AMD, buscando uma melhor otimização da organização das informações e apresentação dos resultados para tomada de decisão. A combinação dessas metodologias oferece uma solução interdisciplinar eficaz para enfrentar os desafios na área de defesa, aprimorando o processo de tomada de decisão e, conseqüentemente, contribuindo de forma significativa para o fortalecimento da Base Industrial de Defesa (BID) através da aquisição otimizada de novos produtos de defesa.

1.1 MOTIVAÇÃO

Quando uma nação precisa adquirir novos equipamentos militares, como aeronaves de treinamento, armamentos ou tanques de guerra, muitos fatores devem ser levados em conta. Isso requer a análise de fatores conflitantes e, neste contexto, o AMD pode ser de grande relevância no apoio à tomada de decisões (SÁNCHEZ-LOZANO; RODRÍGUEZ, 2020). Nesse contexto, a motivação para o desenvolvimento desta dissertação está enraizada na crescente necessidade da Marinha do Brasil em aprimorar seus processos decisórios, especialmente em um contexto global e nacional de defesa que se torna cada vez mais complexo e desafiador. O AMD auxilia os tomadores de decisão na análise de ações ou alternativas potenciais em situação de múltiplos fatores e critérios conflitantes (qualitativos e quantitativos), através da utilização de regras de decisão na agregação desses critérios com o fim de avaliar ou classificar as alternativas (FIGUEIRA; GRECO; EHRGOTT, 2005). O modelo de tomada de decisão inclui os seguintes componentes: critérios, pesos e notas (classificação) que são atribuídos para cada alternativa, em cada critério (CARDOSO et al., 2009). Os métodos AMD permitem a consideração simultânea de múltiplos critérios, enquanto as técnicas de clusterização agrupam elementos com características semelhantes, facilitando a identificação de padrões em grandes volumes de dados. A combinação dessas duas abordagens cria uma metodologia poderosa e eficaz para a tomada de decisões em cenários complexos. Ademais, a partir da pesquisa na base Scopus realizada em maio de

2024, é apresentada uma análise bibliométrica. Na tabela 1, pode-se observar os artigos científicos mais relevantes que integram técnicas de clusterização com métodos AMD.


Tabela 1 – Artigos mais relevantes.

Artigos	Citações
WANG, Y., 2008, <i>Expert Systems with Applications</i>	175
MARDANI, 2016, <i>Energy</i>	68
KESKIN, G. A., 2015, <i>International Journal of Production Research</i>	67
GUDEMIR, 2015, <i>Industrial Management and Data Systems</i>	64
CHEN, N., 2019, <i>International Journal of Disaster Risk Reduction</i>	63
MAGHSSOODI, A., 2018, <i>Computers & Industrial Engineering</i>	63
HILLERMAN, T., 2017, <i>Journal of Computational Science</i>	57
MADHIRAJI, H. A., 2019, <i>Economic Res. Ekonomska Istraživanja</i>	57
LIU, P., 2021, <i>Reliability Engineering and System Safety</i>	56
DAHOOJ, J. H., 2019, <i>Economic Res. Ekonomska Istraživanja</i>	55
ISHIZAKA, A., 2021, <i>Omega</i>	38
CHEN, L., 2018, <i>Int. Journal of Machine Learning and Cybernetics</i>	37
HAMZELOEI, F., 2016, <i>Procedia Computer Science</i>	32
LÓPEZ-ORTEGA, O., 2011, <i>Expert Systems with Applications</i>	21
AZADNIA, A. H., 2011, <i>IEEE</i>	20

Fonte: Próprio autor.

O gráfico ilustrado na figura 1 foi gerado a partir da busca na base de dados Scopus. Os dados mostram uma trajetória ascendente na produção acadêmica ao longo do período analisado de 2004 a 2024. Esta tendência de alta sugere um interesse crescente na área e um potencial robusto para investigações futuras. O notável aumento da produção, especialmente nos anos mais recentes, reflete a crescente importância e demanda por pesquisas que integrem métodos de Apoio Multicritério à Decisão e técnicas de clusterização, configurando um campo de estudo em constante evolução e aprofundamento. Vale destacar que, em 2023, foram publicados 151 artigos nessa área de pesquisa na base Scopus.

Figura 1 – Publicações por ano.



1.2 CARACTERIZAÇÃO DO PROBLEMA

Os recursos orçamentários destinados à Defesa devem garantir a estabilidade orçamentária de investimentos voltados à aquisição de Produtos de Defesa – PRODE, estimulando os programas de desenvolvimento de tecnologias na busca pela atuação da defasagem tecnológica das Forças Armadas e, assim, fortalecendo a Base Industrial de Defesa – BID (DEFESA, 2012). Frente ao exposto, o ponto focal que motiva essa Dissertação consiste no imperativo de a Marinha do Brasil ampliar e aperfeiçoar seus processos decisórios por meio da integração de novas tecnologias com a finalidade de melhorar e refinar a metodologia que envolve a tomada de decisão, especialmente em um contexto de defesa cada vez mais desafiador, onde decisões erradas ou tardias podem comprometer a segurança e a defesa do país. Assim, o aperfeiçoamento do processo decisório otimiza a seleção de novos produtos de defesa para a MB, contribuindo diretamente para o fortalecimento e desenvolvimento da Base Industrial de Defesa. Esse avanço não apenas garante aquisições mais alinhadas às necessidades estratégicas e operacionais da força, como também promove a inovação tecnológica no setor de defesa, consolidando-o como um elemento crucial para a soberania e segurança do país. Além disso, o aperfeiçoamento do processo decisório também se traduz em benefícios econômicos para a força, permitindo uma alocação mais eficiente dos recursos disponíveis. Por meio de uma metodologia aprimorada, a Marinha do Brasil pode otimizar seus investimentos, reduzindo desperdícios e priorizando aquisições que tragam o melhor custo-benefício.

Os métodos AMD que integram técnicas de clusterização têm se destacado de forma significativa no campo da Pesquisa Operacional, proporcionando soluções eficazes para problemas de elevada complexidade. No entanto, a revisão sistemática da literatura

revelou algumas lacunas importantes. Primeiramente, observa-se que devido à falta de uma abordagem que possibilite uma análise descritiva detalhada dos clusters como a matriz dos centróides, por exemplo, não há uma identificação clara de padrões e relações entre os dados. Além disso, a ausência de uma metodologia que reduza a dimensão do problema por meio de clusterização e direcione a tomada de decisão com base no emprego pretendido do meio a ser adquirido.

Portanto, o aprimoramento do processo de tomada de decisão proposto por meio do desenvolvimento deste novo método AMD proporcionará não só a otimização na seleção de produtos de defesa para a Marinha do Brasil, como também poderá servir como uma ferramenta aplicável a processos de seleção em diversos outros campos da ciência, contribuindo para a melhoria e refinamento das decisões em diferentes áreas do conhecimento. Diante do contexto apresentado, surgem as duas questões de pesquisa:

QP1: Por que priorizar a técnica de clusterização hierárquica single-linkage na integração com métodos de apoio multicritério à decisão ao invés das demais técnicas de clusterização?

QP2: Como o uso de técnicas de clusterização hierárquica single-linkage pode melhorar a tomada de decisão?

1.3 OBJETIVOS

O objetivo desta pesquisa é desenvolver uma metodologia que combine técnicas de clusterização hierárquica aglomerativa single linkage com métodos AMD para aperfeiçoar o processo de tomada de decisão da Marinha do Brasil no processo de aquisição de novos produtos de defesa.

1.3.1 OBJETIVOS ESPECÍFICOS

Os objetivos específicos da dissertação incluem: implementação de uma ferramenta computacional que execute o método MADRID; promover maior eficiência operacional, contribuindo para o fortalecimento da Base Industrial de Defesa; tornar a decisão mais simples e subjetiva; apoio à tomada de decisão na seleção de uma aeronave remotamente pilotada para a Marinha do Brasil, conforme previsto no PEM-2040; comprovar a eficácia do método MADRID e publicação de artigos científicos com aplicação do método.

1.4 JUSTIFICATIVA

Este capítulo tem o propósito de apresentar a justificativa para a pesquisa de Mestrado em Engenharia de Defesa. Para isso, avaliou-se alguns documentos os quais abordam o cenário de demandas nacionais como a Política e Estratégia Nacional de Defesa, o Livro Branco de Defesa Nacional e o Plano Estratégico da Marinha (PEM-

2040), assim como informações extraídas da revisão da literatura da pesquisa em questão, destacando a interdisciplinaridade, o impacto na sociedade e o alinhamento ao Programa de Pós-graduação em Engenharia de Defesa para o projeto.

O Programa de Construção do Núcleo do Poder Naval é de caráter estratégico e inclui subprogramas e projetos relacionados à obtenção de meios, por aquisição ou construção, visando aumentar a capacidade operacional da Marinha para o cumprir suas missões. Uma das características deste Programa é seu potencial para o desenvolvimento dos setores afetos à Ciência, Tecnologia e Inovação (CT&I), mediante a transferência de tecnologia e a nacionalização de sistemas de defesa, bem como seu potencial para alavancar o desenvolvimento da indústria nacional e segmentos correlatos (DEFESA, 2020).

Ademais, o porte da economia nacional poderá permitir melhores condições de cooperação com nações mais avançadas no campo tecnológico, ou mesmo o aproveitamento de projetos de desenvolvimento nacional de interesse da área de Defesa, de modo a mitigar as eventuais insuficiências e obsolescências de equipamentos das Forças Armadas e a falta de regularidade nas aquisições de PRODE. Tais desdobramentos, entre outros benefícios, incrementariam a geração de empregos qualificados na BID, a absorção de tecnologias avançadas e a geração de oportunidades de exportação (DEFESA, 2012).

Em decorrência da análise dos ambientes internacional e nacional e suas projeções, bem como da Concepção Política, são estabelecidos os Objetivos Nacionais de Defesa (OND), os quais devem ser interpretados como as condições a serem alcançadas e mantidas permanentemente pela nação brasileira no âmbito de Defesa (DEFESA, 2012).

São Objetivos Nacionais de Defesa (DEFESA, 2012):

I. Garantir a soberania, o patrimônio nacional e a integridade territorial: Trata-se de assegurar a condição inalienável de fazer valer os interesses nacionais e de exercer a última instância da autoridade do Estado, sobre o conjunto das instituições, bens nacionais, direitos e obrigações, bem como a estabilidade da ordem jurídica, o acesso e a mobilidade em todo o Território Nacional;

II. Assegurar a capacidade de Defesa para o cumprimento das missões constitucionais das Forças Armadas: Refere-se a proporcionar às Forças Armadas as capacidades necessárias para realizar a vigilância, o controle e a defesa do território, das águas jurisdicionais e dos espaços aéreo e exterior brasileiros e prover a segurança das linhas de comunicação marítimas de interesse, por meio da dotação do setor de defesa de recursos orçamentários condizentes com a estatura político-estratégica do Brasil, com a devida regularidade e continuidade, e com o suporte das infraestruturas críticas, tais como transporte, energia e comunicação, entre outro; e

III. Promover a autonomia tecnológica e produtiva na área de defesa: Significa manter e estimular a pesquisa e buscar o desenvolvimento de tecnologias autóctones,

sobretudo as mais críticas na área de Defesa, bem como o intercâmbio com outras nações detentoras de conhecimentos de interesse do País. Refere-se, adicionalmente, à qualificação do capital humano, assim como ao desenvolvimento da BID e de produtos de emprego dual (civil e militar), além da geração de empregos e renda.

De acordo com o Plano Estratégico da Marinha – PEM 2040 (2021), qualquer interação marítima apresenta o potencial de gerar algum grau de diplomacia naval, com benefícios para o País, convergentes com a obtenção de uma maior inserção no cenário internacional. Como consequência, o Poder Naval precisa ser preparado para tal consecução. Para que a diplomacia naval possa produzir efeitos concretos para o País, é necessária uma força naval corretamente dimensionada para o combate. Um dos muitos efeitos desejados da diplomacia naval é a dissuasão, situação que somente é possível com meios navais, aeronavais e de fuzileiros navais em quantidade e qualidade adequados.

A Estratégia Naval 6.2, definida pelo PEM 2040 (2021), apresenta a Construção do Núcleo do Poder Naval, cujo objetivo é substituir meios navais, aeronavais e de fuzileiros navais que ultrapassaram ou estão próximos de ultrapassar sua vida útil, através das seguintes Forças Navais:

I. Força Naval 3, com o objetivo de obter Navios de superfície para compor o Poder Naval (PROSUPER): Obter Navio com capacidade de Controle de áreas marítimas (NCAM) capaz de operar com aeronaves de asa fixa, rotativa e/ou remotamente pilotadas, Navios Escolta, Navio de Apoio Logístico Móvel, Navios Anfíbios, Navio Escola, Navios de Contramedidas de Minagem, Avisos de Instrução para a Escola Naval e Colégio Naval;

II. Força Naval 4, com o objetivo de obter Navios-Patrolha para compor o Poder Naval (PRONAPA): Obter os Navios-Patrolha a serem empregados na proteção da Amazônia Azul;

III. Força Naval 6, com o objetivo de obter aeronaves para compor o Poder Naval (PROAERO): Obter aeronaves de asa fixa, rotativa e/ou remotamente pilotadas para missões de combate e de apoio; simulador de voo tático para helicópteros; helicópteros antissubmarino e de esclarecimento e ataque; helicópteros de emprego geral de médio porte; helicópteros de instrução (HI); e helicópteros de emprego geral de pequeno porte (HUP); e

IV. Força Naval 7, com o objetivo de garantir o poder de combate necessário para o emprego do Poder Naval por meio da aquisição de material para atendimento da Dotação do Corpo de Fuzileiros Navais (PROADSUMUS): Ampliar e modernizar os equipamentos do CFN, de modo a assegurar as capacidades operativas esperadas pela MB.

Nesse contexto, surge a necessidade de desenvolver ferramentas que atendam e resolvam essas demandas da MB, com a finalidade de servir como um apoio à tomada de decisão da Alta Administração Naval no tocante à aquisição de produtos de defesa. Para isso, será desenvolvido uma nova metodologia a partir da aplicação de Métodos de Apoio

Multicritério à Decisão em conjunto com a técnica de Clusterização, que é uma área do Aprendizado de Máquina não supervisionado, trazendo, dessa forma, a interdisciplinaridade para a pesquisa em questão.

Os métodos AMD auxiliam os tomadores de decisão na análise de ações ou alternativas potenciais em situação de múltiplos fatores e critérios conflitantes (qualitativos e quantitativos), através da utilização de regras de decisão na agregação desses critérios com o fim de avaliar ou classificar as alternativas, no processo para a tomada da decisão, a Engenharia de Produção se torna um mecanismo fundamental no assessoramento dos gestores. Dentro desta grande área da Engenharia, a Pesquisa Operacional é o campo abrangente e multidisciplinar que emprega modelos matemáticos e analíticos para a solução de problemas complexos do cotidiano (TEIXEIRA, 2019).

A pesquisa em questão traz uma abordagem inovadora para enfrentar desafios complexos na área de defesa, combinando métodos avançados de análise de dados e tomada de decisão. Ao integrar técnicas de Clustering com Métodos de Apoio Multicritério à Decisão, a pesquisa em questão estabelece uma metodologia robusta e eficaz para melhorar a eficiência e eficácia nas decisões estratégicas da Marinha do Brasil. Essa inovação tem o potencial de otimizar a alocação de recursos, aprimorar a gestão de aquisições, e fortalecer as capacidades operacionais e estratégicas da defesa nacional.

Esta pesquisa também apresenta impactos econômico, social, ambiental e cultural, conforme pode-se observar nos tópicos a seguir:

I. Impacto Social: A pesquisa contribuirá para o aprimoramento da gestão pública na área de defesa através da otimização da alocação de recursos. Além disso, a aplicação desta nova metodologia servirá como uma ferramenta para atender às demandas da MB, como a aquisição de Navios e Aeronaves que prestam apoio às operações de buscar e salvamento e Patrulha Naval, trazendo um impacto social para o País;

II. Impacto Tecnológico: A pesquisa desenvolvida contribuirá terá um impacto tecnológico relevante, pois será apresentada uma metodologia inovadora que engloba tanto a Pesquisa Operacional quanto o Aprendizado de Máquina em uma abordagem inovadora;

III. Impacto Econômico: A eficiência na gestão de recursos e na tomada de decisões estratégicas, como a aquisição de equipamentos de defesa, pode levar a uma maior eficiência econômica. Isto irá impactar tanto a Marinha do Brasil quanto empresas privadas envolvidas na indústria de defesa.

No âmbito internacional, esta pesquisa tem grande relevância por contribuir para o fortalecimento da posição estratégica do Brasil no cenário global de defesa no apoio ao processo de aquisição de novos produtos de defesa. Dessa maneira, contribui de forma significativa para aprimorar a eficiência operacional da Marinha do Brasil.

A aplicação desta ferramenta no apoio à tomada de decisão da Alta Administração

Naval é de grande relevância no cenário nacional, pois a pesquisa contribui diretamente para o alcance dos Objetivos Nacionais de Defesa, ao fortalecer a autonomia tecnológica e produtiva do país. Assim, promove-se a garantia da soberania e a proteção do patrimônio nacional, elementos essenciais para a segurança e o desenvolvimento estratégico do Brasil.

Regionalmente, a pesquisa tem um impacto significativo na segurança e desenvolvimento das áreas costeiras e fronteiriças do Brasil. A melhoria na capacidade operacional da Marinha do Brasil, que é um dos resultados esperados desta pesquisa, garante uma melhor vigilância e proteção das águas jurisdicionais brasileiras, especialmente em áreas estratégicas como a Amazônia Azul. Isso não só reforça a segurança nacional, mas também promove o desenvolvimento econômico e social nas regiões litorâneas e ribeirinhas, especialmente em áreas que dependem da segurança marítima para suas atividades econômicas.

1.5 CONTRIBUIÇÃO ESPERADA

A metodologia do método MADRID apresenta uma solução inovadora no apoio para o contexto da tomada de decisão em contextos complexos de defesa. A implementação computacional dessa metodologia visa criar uma ferramenta prática e eficaz, a qual possibilitará o aprimoramento na tomada de decisão na MB.

A aplicação do método MADRID permitirá uma avaliação precisa e objetiva das alternativas. Essa abordagem contribui diretamente para o PEM-2040 ao proporcionar um processo de decisão alinhado com os objetivos operacionais da MB. O desenvolvimento de uma nova ferramenta voltada para o aprimoramento no processo de tomada de decisão permite maior aderência às necessidades estratégicas da Marinha, contribuindo para a soberania nacional e o fortalecimento da BID por meio da seleção aprimorada de novos produtos de defesa.

Além do impacto direto na defesa, o método MADRID oferece contribuições significativas para a Engenharia de Produção e a Pesquisa Operacional, promovendo uma metodologia interdisciplinar que pode ser aplicada a diferentes setores, incluindo tecnologia e indústrias de grande escala. Sua plataforma computacional viabiliza o uso do método em avaliações complexas e sustentáveis, assegurando o uso ético e eficiente em variados cenários de tomada de decisão.

Por fim, espera-se que o MADRID fortaleça o processo de decisão de produtos de defesa do Brasil e amplie os horizontes da ciência e tecnologia em áreas estratégicas e operacionais. A plataforma se consolidará como uma ferramenta essencial para a MB e para a comunidade acadêmica, impulsionando publicações e inovações no campo da decisão multicritério e expandindo suas aplicações para ambientes militares e civis.

1.6 ESTRUTURA DO TRABALHO

Esta dissertação está estruturada em seis capítulos, sendo este próprio a introdução, onde se apresentou a motivação, caracterização do problema, assim como os objetivos e a justificativa do trabalho. No capítulo dois é realizada a fundamentação teórica, onde é abordado o método de apoio multicritério à decisão, a técnica de clusterização e a integração entre os mesmos. Já no capítulo três é enfatizada a revisão sistemática da literatura deste trabalho. No capítulo quatro apresenta a metodologia do método MADRID, assim como o desenvolvimento e aplicação prática da ferramenta computacional desenvolvida. Em seguida é apresentado um estudo de caso no capítulo cinco, aplicando o método MADRID para seleção de uma aeronave remotamente pilotada para a Marinha do Brasil e, por fim, o capítulo seis com a conclusão deste trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os conceitos fundamentais desta dissertação, introduzindo as bases teóricas essenciais para a compreensão do tema e da solução proposta.

2.1 APOIO MULTICRITÉRIO À DECISÃO (AMD)

Os métodos multicritério têm sido desenvolvidos para apoiar e conduzir os decisores na avaliação e escolha das alternativas solução em diferentes espaços. O espaço das variáveis de decisão, em particular, consiste no conjunto de decisões factíveis e não factíveis para dado problema. Nas decisões em grupo, as preferências individuais podem ser combinadas de modo a resultar em uma decisão do grupo. As variáveis de decisão são as ações detalhadas, que devem ser decididas e comunicadas. A decisão do grupo é, assim, consequência de um intercâmbio de decisões entre os membros do grupo do qual emana a negociação das propostas aceitáveis. Se o compromisso é obtido, elas são automaticamente acordadas (GOMES; GOMES, 2019).

Um ponto importante da decisão é a objetividade: os participantes podem divergir na avaliação de uma decisão, mas a decisão grupal é objetiva e final, como decisão. Pesos podem então ser usados para agregar os valores das funções-objetivos em um único valor, determinando a utilidade da decisão alternativa. De modo geral, problemas de decisão podem ser discretos, quando se trata de um número finito de alternativas, ou contínuos, quando tal número pode ser pensado como infinitamente grande (GOMES; GOMES, 2019).

Os métodos AMD são muito úteis para apoiar o processo decisório, pois consideram julgamentos de valor, e não apenas questões técnicas para avaliar alternativas em problemas reais, apresentando alta multidisciplinaridade (SANTOS *et. al.*, 2015). No processo para a tomada da decisão correta, a Engenharia de Produção se torna um mecanismo fundamental no assessoramento dos gestores (DOS SANTOS; DA COSTA MARTHA; DOS REIS, 2019). A Pesquisa Operacional (PO), como uma das disciplinas inerente à Engenharia de Produção, é uma área que cuida da otimização dos processos organizacionais e de métodos de resolução de problemas e apoio à decisão, entre outros. A PO procura aperfeiçoar as operações existentes e/ou ajudar no processo de tomada de decisão, visando não só fornecer subsídios racionais para a tomada de decisão, bem como proporcionar ferramentas quantitativas ao processo de tomada de decisões. Em suma, a PO é um método científico de tomada de decisões (GOMES; GOMES, 2019).

Nesse contexto, técnicas têm sido desenvolvidas para uma análise multicritério para apoiar e conduzir os decisores na avaliação e escolha das alternativas-solução, em diferentes espaços. O espaço das variáveis de decisão, em particular, consiste no conjunto de decisões factíveis e não factíveis para dado problema (GOMES; GOMES, 2019). Dentre estas técnicas temos os métodos de Apoio Multicritério à Decisão (AMD).

O método AMD é usado para descrever um conjunto de abordagens formais que buscam levar em conta, de forma explícita, vários critérios para ajudar as partes interessadas e grupos a explorarem decisões importantes (BELTON; STEWART, 2002). Esses métodos aplicam-se sempre que se deseje selecionar, ordenar, classificar ou descrever alternativas presentes em um processo decisório na presença de múltiplos critérios – quantitativos e qualitativos (RANGEL; GOMES, 2010). Apesar da diversidade de abordagens, métodos e técnicas multicritério, os componentes básicos do AMD são um conjunto finito ou infinito de ações (alternativas, soluções, cursos de ação etc.), pelo menos dois critérios e pelo menos um Decisor (DM – Decision Maker). Diante desses elementos básicos, o AMD é uma atividade que auxilia na tomada de decisões, principalmente no que se refere à escolha, classificação ou ordenação das ações (GRECO; FIGUEIRA; EHRGOTT, 2016b).

Segundo Van Hoan e Ha (2021), a aplicação dos métodos de AMD nas Forças Armadas é importante porque a tomada de decisão precisa é fator decisivo para o sucesso e pode reduzir os gastos e aumentar a capacidade de defesa. De acordo com os autores, esses métodos são projetos científicos sistemáticos para ajudar os tomadores de decisão a tomar decisões precisas. Entre os diversos métodos AMD descritos na literatura, alguns se destacam, como, por exemplo: Analytic Hierarchy Process (AHP), Technique for Order Preferences by Similarity to Ideal Solution (TOPSIS), ELimination Et Choix Traduisant la REalité (ELECTRE), Preference Ranking Organization Method for Enrichment Evaluation (PROMETHEE), Multicriteria Decision Aiding Hybrid Algorithm (THOR) e o Multi-Attributive Border Approximation area Comparison (MABAC).

Os métodos AMD classificam-se de diferentes maneiras. A classificação de maior relevância é a que subdivide os métodos de agregação por meio de critério único de síntese/compensatório (Escola Americana) e métodos de sobreclassificação/não compensatórios (Escola Francesa), também denominada Escola Europeia (RANGEL; GOMES, 2010). Os métodos AHP - Analytic. Hierarchy Process, MAUT - Multiple Attribute Utility Theory, MACBETH - Measuring Attractiveness by a Categorical Based Evaluation Technique, TODIM - Tomada de Decisão Interativa Multicritério e TOPSIS - Technique for Order of Preference by Similarity to Ideal Solution seguem a filosofia da Escola Americana (compensatória). Já os métodos da Família ELECTRE - Elimination and Choice Translating Reality for Enrichment Evaluation e PROMETHEE - Preference Ranking Method for Enrichment Evaluation seguem a Escola Europeia (não compensatória). Rangel e Gomes (2010) afirmam, no entanto, que os métodos MACBETH e TODIM possuem elementos

técnicos de ambas as escolas. O THOR é classificado como híbrido.

O Apoio Multicritério à Decisão configura-se como um domínio metodológico essencial no campo da Pesquisa Operacional e da Engenharia de Produção, cuja principal finalidade é fornecer subsídios analíticos para decisões complexas envolvendo múltiplos critérios, frequentemente conflitantes e heterogêneos. Em contextos organizacionais e estratégicos, como gestão pública, planejamento logístico e defesa nacional, as decisões raramente dependem de um único atributo; ao contrário, exigem a consideração simultânea de fatores econômicos, ambientais, sociais e técnicos. Nesse sentido, o AMD propicia uma estrutura formal para incorporar as preferências dos decisores e sistematizar o processo decisório, tornando-o mais transparente, racional e alinhado aos objetivos estratégicos estabelecidos.

Portanto, os métodos AMD surgem como ferramentas essenciais para auxiliar os tomadores de decisão em contextos complexos e multifacetados, como a aquisição de equipamentos militares e a otimização de processos organizacionais. No setor de defesa, onde as decisões envolvem altos investimentos e impactos estratégicos, o uso de um método de apoio à tomada de decisão eficaz se mostra particularmente relevante para mitigar riscos e otimizar recursos. A utilização desses métodos é imensamente facilitada por softwares especializados.

2.2 A CLUSTERIZAÇÃO

A análise de agrupamentos constitui um conjunto de técnicas exploratórias extremamente úteis e que podem ser aplicadas quando se deseja verificar a presença de comportamentos semelhantes entre observações (como indivíduos, empresas, municípios, países, entre outros) em relação a determinadas variáveis, visando à formação de grupos, ou clusters, nos quais predomine a homogeneidade interna. Assim, esse conjunto de técnicas, também denominado análise de conglomerados ou análise de clusters, tem como objetivo principal a alocação de observações em um número relativamente reduzido de agrupamentos que sejam internamente homogêneos e externamente heterogêneos, representando o comportamento conjunto das observações com base nas variáveis analisadas. Em outras palavras, as observações de cada grupo devem ser relativamente similares entre si, quanto às variáveis consideradas na análise, e significativamente distintas das observações pertencentes a outros grupos (FÁVERO; BELFIORE, 2017).

O pesquisador pode escolher realizar uma análise de agrupamentos com o intuito de ordenar e alocar as observações em grupos e, assim, estudar a quantidade ideal de clusters formados; ou, alternativamente, pode, desde o início, definir a quantidade de grupos que pretende formar, com base em um critério específico, e observar o comportamento do ordenamento e da alocação das observações nessa quantidade previamente estabelecida de

grupos. Independentemente da natureza do objetivo, a análise de agrupamentos mantém-se exploratória (FÁVERO; BELFIORE, 2017).

Os métodos de aglomeração podem ser classificados, essencialmente, em dois tipos, conhecidos como hierárquicos e não hierárquicos. Enquanto os primeiros se caracterizam por favorecer uma estrutura hierárquica (passo a passo) para a formação dos agrupamentos, os métodos não hierárquicos empregam algoritmos com o objetivo de maximizar a homogeneidade dentro de cada agrupamento, sem envolver um processo hierárquico para essa finalidade (FÁVERO; BELFIORE, 2017).


Os esquemas de aglomeração hierárquicos podem ser aglomerativos ou divisivos, conforme o modo como se inicia o processo. Se todas as observações forem inicialmente consideradas separadas e, com base em suas distâncias (ou semelhanças), formarem-se grupos até que se atinja um estágio final com apenas um agrupamento, então esse processo é denominado aglomerativo. Entre os esquemas hierárquicos aglomerativos, são mais frequentemente utilizados os que aplicam o método de encadeamento do tipo único (nearest neighbor ou single linkage), completo (furthest neighbor ou complete linkage) ou médio (between groups ou average linkage) (FÁVERO; BELFIORE, 2017).

Já os esquemas de aglomeração não hierárquicos, entre os quais o mais popular é o procedimento k-means, ou k-médias, referem-se a processos em que são definidos centros de aglomeração a partir dos quais são alocadas as observações pela proximidade a eles. Ao contrário dos esquemas hierárquicos, em que o pesquisador pode estudar as diversas possibilidades de alocação das observações e até definir uma quantidade interessante de clusters com base em cada um dos estágios de agrupamento, um esquema de aglomeração não hierárquico requer a estipulação, a priori, da quantidade de clusters a partir da qual serão definidos os centros de aglomeração e alocadas as observações. É por essa razão que se recomenda a elaboração de um esquema de aglomeração hierárquico preliminarmente à de um esquema não hierárquico, quando não há uma estimativa razoável da quantidade de clusters que podem ser formados a partir das observações do banco de dados e com base nas variáveis em estudo (FÁVERO; BELFIORE, 2017).

O método hierárquico aglomerativo Single Linkage privilegia as menores distâncias para que sejam formados novos agrupamentos a cada estágio de aglomeração pela incorporação de observações ou grupos (FÁVERO; BELFIORE, 2017). Johnson e Wichern (2002) propõem uma sequência lógica de passos para que se facilite o entendimento da análise de agrupamentos, elaborada por meio de determinado método hierárquico aglomerativo:

I. Sendo “**n**” a quantidade de observações de um banco de dados, devemos dar início ao esquema de aglomeração com exatamente “**n**” grupos individuais (estágio 0), de modo que teremos inicialmente uma matriz de distâncias (ou de semelhanças) D_0 composta pelas distâncias entre cada par de observações.

Figura 2 – Esquema de aglomeração em análise de agrupamentos.



Fonte: (FÁVERO; BELFIORE, 2017).

II. No primeiro estágio, devemos escolher a menor distância entre todas as que compõem a matriz D_0 , ou seja, aquela que une as duas observações mais similares. Nesse exato momento, deixamos de ter “ n ” grupos individuais para termos $(n - 1)$ grupos, sendo um deles formado por duas observações.

III. No estágio de aglomeração seguinte, devemos repetir o estágio anterior, porém agora levando em consideração a distância entre cada par de observações e entre o primeiro grupo já formado e cada uma das demais observações, com base em um dos métodos de encadeamento adotado. Em outras palavras, teremos, após o primeiro estágio de aglomeração, uma matriz D_1 , com dimensões $(n - 1) \times (n - 1)$, em que uma das linhas será representada pelo primeiro par agrupado de observações. No segundo estágio, conseqüentemente, um novo grupo será formado pelo agrupamento de duas novas observações ou pela junção de determinada observação ao primeiro grupo já formado anteriormente, no primeiro estágio.

IV. O processo anterior deve ser repetido $(n - 1)$ vezes, até que reste apenas um único grupo formado por todas as observações. Em outras palavras, no estágio $(n - 2)$ teremos uma matriz D_{n-2} que conterá apenas a distância entre os dois últimos grupos remanescentes, antes da fusão final. V. Por fim, a partir dos estágios de aglomeração e das distâncias entre os agrupamentos formados, é possível construir um gráfico em formato de árvore, que resume o processo de aglomeração e explicita a alocação de cada observação em cada agrupamento. Esse gráfico é conhecido como dendrograma.

A etapa para a elaboração de uma análise de agrupamentos consiste em definir a

medida de distância (dissimilaridade) ou de semelhança (similaridade) que servirá de base para que cada observação seja alocada em determinado grupo. As medidas de distância são frequentemente utilizadas quando as variáveis do banco de dados forem essencialmente métricas, visto que, quanto maiores as diferenças entre os valores das variáveis de duas determinadas observações, menor a similaridade entre elas ou, em outras palavras, maior a dissimilaridade (FÁVERO; BELFIORE, 2017).

Para a implementação do método MADRID foi utilizada a medida de dissimilaridade como base para cada observação a distância euclidiana. Dessa forma, a expressão 1 apresenta a definição geral da distância euclidiana entre duas observações quaisquer p e q :

$$d_{pq} = \sqrt{\sum_{j=1}^k (x_{pj} - x_{qj})^2} \quad (1)$$

2.2.0.1 O MÉTODO DA SILHUETA

O método das silhuetas foi proposto por Rousseeuw (1987) para uso em métodos de obtenção de agrupamentos por partição. A ideia é auxiliar o pesquisador a escolher o número ótimo de grupos e, ao mesmo tempo, permitir que se construa uma representação gráfica do agrupamento encontrado (SOUZA, 2007).

Para construir silhuetas, precisamos apenas de duas coisas: a partição que obtivemos (aplicando alguma técnica de clusterização) e o conjunto de todas as proximidades entre os objetos. Para cada objeto “ i ”, introduziremos um determinado valor “ $s(i)$ ”, e então esses números serão combinados em um gráfico (ROUSSEEUW, 1987).

Primeiramente, vamos definir os valores “ $s(i)$ ” no caso de dissimilaridades. Considere qualquer objeto “ i ” no conjunto de dados e denote por A o cluster ao qual ele foi atribuído (ROUSSEEUW, 1987). Quando o cluster A contém outros objetos além de “ i ”, podemos calcular:

I. $a(i)$ = dissimilaridade média de i em relação a todos os outros objetos de A ;

Na figura 5, esta é a média do comprimento de todas as linhas dentro de A . Agora, consideremos qualquer cluster C que seja diferente de A e calculemos (ROUSSEEUW, 1987):

II. $d(i,C)$ = dissimilaridade média de i em relação a todos os objetos de C ; e


Na figura 5, esta é a média do comprimento de todas as linhas que vão de i até C . Após calcular $d(i,C)$ para todos os clusters $C \neq A$, selecionamos o menor desses valores e o denotamos por (ROUSSEEUW, 1987):

III. $b(i) = \text{Mínimo } d(i, C)$.

$$C \neq A$$

Pode-se interpretar $b(i)$ como a distância entre i e o grupo vizinho mais próximo a ele em termos do critério de dissimilaridade utilizado.

Figura 3 – Ilustração dos elementos envolvidos no cálculo de $s(i)$, onde o objeto i pertence ao cluster A.



Fonte: (ROUSSEEUW, 1987).

O número $s(i)$ é obtido combinando $a(i)$ e $b(i)$ da seguinte forma (ROUSSEEUW, 1987):

$$s(i) = \begin{cases} 1 - \frac{a(i)}{b(i)}, & \text{se } a(i) < b(i); \\ 0, & \text{se } a(i) = b(i); \\ \frac{b(i)}{a(i)} - 1, & \text{se } a(i) > b(i). \end{cases} \quad (2)$$


É até mesmo possível expressar isso em uma única fórmula (ROUSSEEUW, 1987):

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (3)$$

A figura 6 ilustra um exemplo das distâncias consideradas no cálculo de $s(i)$ num agrupamento hipotético com quatro grupos C1, C2, C3 e C4. Com referência ao i -ésimo ponto, as linhas pontilhadas representam as distâncias consideradas para encontrar $a(i)$, e as contínuas para $b(i)$ (SOUZA, 2007).

Para os casos em que i constitui-se por si só num grupo de elemento único, tornando-se impossível calcular $a(i)$, Rousseeuw (1987) recomenda assumir-se $s(i)=0$.

Figura 4 – Agrupamento com linhas representando as distâncias do i -ésimo ponto aos demais elementos da amostra.



Fonte: (SOUZA, 2007).

Observando-se as equações 2 e 3, é direto concluir que $s(i)$ varia no intervalo $[-1;1]$, além de ser adimensional. Um valor de $s(i)$ mais próximo de -1 é um indício de que o i -ésimo elemento foi provavelmente mal classificado, pois neste caso $b(i) \ll a(i)$, ou seja, i , em média, está mais distante dos elementos do seu próprio grupo do que aquele usado no cálculo de $b(i)$. Por outro lado, se $s(i)$ é mais próximo de 1 , pode-se supor que sua classificação foi adequada, pois $b(i) \gg a(i)$. Um valor de $s(i)$ próximo ao zero ocorre quando $a(i)$ e $b(i)$ são semelhantes, indicando que o i -ésimo indivíduo está num ponto intermediário entre os dois grupos (SOUZA, 2007).

O coeficiente de silhueta médio (CSM) é um índice de qualidade para todo o agrupamento, dado pela média de $s(i)$ (SOUZA, 2007):

$$CSM = \frac{\sum_{i=1}^n s(i)}{n} \quad (4)$$

2.3 A CLUSTERIZAÇÃO E OS MÉTODOS AMD

A Tomada de Decisão Multicritério permite que os tomadores de decisão escolham ou ranqueiem alternativas com base em uma avaliação frente a múltiplos critérios. O Apoio Multicritério à Decisão é uma ferramenta valiosa em pesquisa operacional e ciência de gestão, com diversos métodos desenvolvidos ao longo dos anos e aplicados a problemas de decisão em várias áreas (GOVINDAN; JEPSEN, 2016).

Conforme comentado anteriormente, a clusterização refere-se a um conjunto de técnicas não supervisionadas que agrupam alternativas de calibre semelhante em um mesmo objeto. Existem duas famílias principais de algoritmos de clusterização, descritas a

seguir (ISHIZAKA; LOKMAN; TASIOU, 2021):

Clusterização hierárquica: uma família de métodos que busca construir uma hierarquia de clusters (MURTAGH; CONTRERAS, 2017).

Clusterização não hierárquica: uma família de métodos em que as alternativas são atribuídas a clusters depois que o tomador de decisão decide previamente o número de clusters a serem formados (SAXENA et al., 2017).

Nesse contexto, os métodos AMD e Análise de Cluster podem ser usados para resolver problemas em diferentes áreas, servindo como ferramentas para análise e tomada de decisão. A combinação dessas técnicas pode tornar as análises mais robustas e possibilitar decisões mais assertivas para os tomadores de decisão. A combinação com técnicas de clustering também possibilita agrupar dados considerados homogêneos, de modo que dados com diferenças de tamanho visíveis não sejam comparados, por exemplo, como a mesma Unidade de Tomada de Decisão (DMU – Decision Making Unit) (DE OLIVEIRA et al., 2023).

Além disso, a Análise de Cluster é uma técnica muito importante e pode ser utilizada para diferentes aplicações. Quando aplicada juntamente com métodos AMD, essa análise pode fornecer agrupamentos que ajudam a explicar melhor os dados e auxiliam os gestores na tomada de decisões. Esses agrupamentos são realizados levando em consideração os critérios, ou seja, os dados podem ser agrupados de acordo com um critério específico que o tomador de decisão considera mais importante (DE OLIVEIRA et al., 2023).

No trabalho desenvolvido por Ishizaka (2021), a clusterização hierárquica é priorizada como uma solução para lidar com a incerteza do número de clusters. Essa abordagem é particularmente útil quando a estrutura exata dos grupos, como o número de clusters, é desconhecida, pois possibilita que o analista descubra a organização natural dos dados. Assim, a clusterização hierárquica facilita a criação de agrupamentos progressivos, ajustando-os de acordo com as relações internas entre as alternativas de decisão. De acordo com Joe Anand et al. (2023) a abordagem híbrida de tomada de decisão, que combina técnicas de aprendizado de máquina com métodos AMD, certamente aliviará as dificuldades no manuseio de dados. Os métodos AMD são geralmente aplicáveis a um número considerável de unidades de tomada de decisão, e sua aplicação em grandes conjuntos de dados exige um trabalho preliminar significativo. No entanto, este modelo híbrido realiza o processo inicial de triagem de dados, o que, por sua vez, melhora a integridade dos resultados.

Além disso, o método AMD pode ser explorado com diferentes tipos de representações. Como uma extensão dessa abordagem, diferentes métodos AMD podem ser implementados para realizar comparações mais abrangentes. Assim, é certo que tais métodos integrados reduzirão os desafios de tomada de decisão enfrentados pelos órgãos governantes (ANAND et al., 2023).

Dessa forma, quando integrada a métodos AMD, a clusterização hierárquica oferece uma estrutura complementar para a análise. Com isso, a clusterização hierárquica single linkage não apenas organiza os dados de forma eficiente, mas também amplia a robustez das análises multicritério, garantindo que os critérios sejam avaliados em um contexto apropriado.

3 TRABALHOS RELACIONADOS

Abramo e D'Angelo Abramo e D'Angelo (2011) aportam que uma boa revisão da literatura deve possuir precisão, explicada pelo grau de proximidade das medidas dos indicadores de desempenho ao seu verdadeiro valor; robustez, capacidade do sistema de fornecer uma classificação que não é sensível à parte do produto de pesquisa avaliada; validade, competência do sistema em medir o que se propõe; funcionalidade, capacidade do sistema de medição no sentido de atender todas as funções para as quais é utilizado; além do tempo necessário para realizar a medição e os custos diretos e indiretos da revisão da literatura.


Essa revisão sistemática da literatura foi conduzida conforme as diretrizes estabelecidas por Kitchenham (2004). Esta revisão focou exclusivamente em literatura publicada em periódicos acadêmicos, conferências e simpósios, restringindo-se a trabalhos redigidos em inglês. A estratégia de busca empregada para a identificação de publicações relevantes foi cuidadosamente desenvolvida para garantir uma abordagem sistemática e abrangente no mapeamento do estado atual do conhecimento neste campo específico de estudo.

A metodologia empregada para a construção da string de busca foi meticulosamente delineada, baseando-se na seleção de palavras-chave estritamente alinhadas ao tema central da pesquisa no período de tempo entre os anos de 2004 a 2024. Esta seleção criteriosa de termos-chave visou assegurar uma abrangência e precisão ótimas na recuperação de publicações pertinentes às temáticas de análise de decisão multicritério e técnicas de clusterização, conforme delineado no escopo do estudo. A escolha das palavras-chave foi conduzida de modo a refletir de forma fidedigna o núcleo temático da investigação, contribuindo assim para a eficácia e a eficiência do processo de busca nas bases Scopus, Web of Science e IEEE seguindo a metodologia proposta por Carrera-Rivera et al. (2022):

("Clustering") AND ("multi-criteria"OR "MCDM"OR "MCDA"OR "multicriteria"OR "multi-criteria decision analysis"OR "multi-criteria decision making"OR "multicriteria decision making"OR "multicriteria decision analysis")

A figura 7 apresenta as fases do processo de seleção da pesquisa em questão, conforme o método proposto por Croft et al. (2022). Os artigos identificados passaram por um rigoroso processo de análise, que começou com a avaliação dos títulos, resumos e palavras-chave. Em seguida, foi realizada exclusão de duplicidades entre as três bases de dados. Após essa etapa, procedeu-se à leitura integral dos textos e à análise criteriosa de sua qualidade, culminando na seleção final de 25 artigos.

Figura 5 – Fases do processo de seleção.



Fonte: Próprio autor.

Dentre os diversos métodos existentes aplicando técnicas de clusterização com métodos AMD, destacam-se alguns como:

- Li et al. (2023) realizaram um estudo utilizando o TOPSIS e a técnica de clusterização não hierárquica k-means para classificar e delimitar microbacias ecológicas e limpas.
- Wang (2008) utiliza a técnica de clusterização não hierárquica para agrupar índices financeiros, identificando indicadores representativos de cada cluster. Esses indicadores são então utilizados como critérios no método Fuzzy Multi-Criteria Decision-Making (FMCDM) para avaliar o desempenho financeiro de companhias aéreas.

- Chen et al. (2019) apresentam uma metodologia utilizando os métodos AHP e TOPSIS e a técnica de clusterização não hierárquica para avaliar o risco de desastres regionais na China.

- Güçdemir e Selim (2015) apresentaram a integração do método Fuzzy AHP com técnica de clusterização não hierárquica para segmentação de clientes.

- Ishizaka et al. (2021), com o objetivo de avaliar o desempenho de bancos dos Estados Unidos, desenvolveram um algoritmo de clusterização hierárquica, o SMAA-MDHC, que agrupa alternativas em grupos homogêneos com preferências similares. Diferentemente dos estudos existentes nesta linha, um método de agrupamento em conjunto é incorporado ao framework SMAA-PROMETHEE para obter soluções de agrupamento mais robustas e estáveis.

- Guhathakurata et al. (2021) analisaram os fatores que determinam a distribuição desigual de mortes por COVID-19 entre diferentes países. Utilizando o método AHP, foi calculado um índice de risco para cada fator e a clusterização hierárquica foi aplicada para visualizar a relação entre o número de mortes e o índice de suscetibilidade dos países, destacando como esses fatores influenciam a mortalidade de forma diferente entre as nações analisadas.

- Em seu artigo, Trojan et al. (2023) realizaram uma análise comparativa usando o método multicritério ELECTRE TRI e algoritmos de clusterização para obter um procedimento auxiliar para definir limiares iniciais para o método ELECTRE TRI.

- Joe Anand et al. (2023) (2023) propuseram um método híbrido de tomada de decisão para seleção de fornecedores logísticos na indústria elétrica, combinando o algoritmo de clustering Fuzzy C-Means (FCM) e o método de decisão multi-critério MAIRCA (Multi-Attributive Ideal-Real Comparative Analysis).

- Güler et al. (2023) realizaram sua pesquisa com objetivo de orientar os tomadores de decisão na avaliação prática do risco de terremotos, integrando técnica de clustering e os métodos ELECTRI I e SWARA.

- Akay et al. (2023) realizaram um estudo que investiga o risco de sedimentos em áreas florestais na Turquia. O uso combinado do método WASPAS e a técnica de clustering fuzzy proporciona uma abordagem abrangente e eficaz para a avaliação do risco de sedimentos.

- Nilashi et al. (2024) utilizaram o método DEMATEL, clustering e lógica fuzzy para a avaliação da cadeia de suprimentos de veículos elétricos.

- Ding et al. (2024), em seu trabalho, avalia o desempenho de segurança viária na região do Sudeste Asiático utilizando o modelo CRITIC-TOPSIS-Kmeans. O modelo proposto é usado para ranquear e agrupar o desempenho de segurança viária dos países.

- Wu et al. (2024) apresentam uma estrutura integrada para a seleção de locais de estações de troca de baterias para veículos elétricos, combinando o algoritmo de clusterização K-means e o método TODIM.

- Azadnia et al. (2011a) apresentam o modelo de integração do algoritmo de clusterização Fuzzy C-Means e do método TOPSIS para avaliação do valor vitalício do cliente. - Keskin (2015) utilizou a integração do algoritmo fuzzy DEMATEL e fuzzy C-Means para avaliação e seleção de fornecedores.

- Maghsoodi et al. (2018) apresentam uma abordagem inovadora chamada CLUS-MCDA, que combina a análise de cluster k-means com o método MULTIMOORA, para melhorar a análise de decisão multicritério com dados de big data.

- Hillerman et al. (2017) apresentaram uma nova abordagem utilizando a técnica de clusterização não hierárquica K-means com o método multicritério Analytic Hierarchy Process (AHP) para avaliar alegações suspeitas de assistência médica.

- Chen et al. (2018) propuseram um novo algoritmo de clusterização ordenada, chamado K-means ordenado, que considera o grau de preferência entre alternativas usando o fluxo líquido relativo do PROMETHEE para resolver um problema de clusterização ordenada relacionado aos índices de desenvolvimento humano.

- Liu e Li (2021) propuseram um novo método aprimorado de análise de modos de falha e efeitos para tomada de decisão em grupo multicritério na avaliação de riscos da logística verde utilizando a técnica de clusterização k-means e o método PROMETHEE II.

- López Ortega e Rosales (2011) propuseram um método de apoio à decisão combinando a técnica de clusterização fuzzy e o método AHP.

- De Smet (2013) abordou o problema da clusterização ordenada multicritério, ou seja, a detecção de categorias ordenadas em um contexto multicritério. Para isso, propôs uma extensão do PROMETHEE II chamada P2CLUST. O algoritmo é inspirado tanto pelo procedimento k-means quanto pela ideia subjacente do método FLOWSORT.

- Swindiarto et al. (2018) lançaram o método FCM-TOPSIS por meio do agrupamento da técnica FCM conjuntamente com o método TOPSIS.

- Dahooi et al. (2019) lançaram o método FCM-ARAS, utilizando a técnica de clusterização não hierárquica Fuzzy C-Means (FCM) em conjunto com o método multicritério ARAS para a avaliação do desempenho financeiro de empresas.

- Mahdiraji et al. (2019) desenvolveram um estudo com o objetivo de sugerir uma estratégia de banco digital para a indústria bancária iraniana utilizando a técnica de clusterização k-means e o método BWM-COPRAS.

- O método desenvolvido por Azadnia et al. (2011b) utiliza o algoritmo Fuzzy C-Means (FCM), o Processo Analítico Hierárquico Fuzzy (FAHP) e o ELECTRE para resolver o problema de seleção de fornecedores.

Tabela 2 – Resumo dos métodos que empregaram Clusterização e AMD.

Nº	Autor(es)	Técnica de Clusterização	Método AMD
1	Li et al. (2023)	K-means	TOPSIS
2	Wang (2008)	Grey Relation Analysis	FMCDM
3	Chen et al. (2019)	Self-Organizing Maps	AHP e TOPSIS
4	Güçdemir e Selim (2015)	Ward's method / Single-Linkage / Complete Linkage / K-means	Fuzzy AHP
5	Ishizaka et al. (2021)	Hierarchical Clustering	SMAA-MDHC
6	Guhathakurata et al. (2021)	Hierarchical Clustering	AHP
7	Trojan et al. (2023)	Particle Swarm Optimization; Algoritmo Genético e Evolução Diferencial	ELECTRE-TRI
8	Joe Ananda et al. (2023)	Fuzzy C-Means	MAIRCA
9	Güler et al. (2023)	Two-Step Cluster Analysis	ELECTRE e SWARA
10	Akay et al. (2023)	Fuzzy C-Means	WASPAS
11	Nilashi et al. (2024)	K-means	DEMATEL
12	Ding et al. (2024)	K-means	CRITIC-TOPSIS
13	Wu et al. (2024)	K-means	TODIM
14	Azdnia et al. (2011a)	Fuzzy C-Means	TOPSIS
15	Keskin (2015)	Fuzzy C-Means	Fuzzy DEMATEL
16	Maghsoodi et al. (2018)	K-means	MULTIMOORA
17	Hillerman et al. (2017)	K-means	AHP
18	Chen et al. (2017)	K-means	PROMETHEE
19	Liu e Li (2021)	K-means	PROMETHEE-II
20	López Ortega e Rosales (2011)	Fuzzy C-Means	Fuzzy AHP
21	De Smet (2013)	K-means	FLOWSORT
22	Swindiarito et al. (2018)	Fuzzy C-Means	TOPSIS
23	Dahoui et al. (2019)	Fuzzy C-Means	ARAS
24	Mahdiraji et al. (2019)	K-means	BWM-COPRAS
25	Azdnia et al. (2011b)	Fuzzy C-Means	FAHP e ELECTRE

Fonte: Próprio autor.

Como evidenciado pela Revisão Sistemática da Literatura (RSL), o uso combinado dessas abordagens tem se mostrado uma estratégia promissora, permitindo não apenas a identificação de agrupamentos homogêneos, mas também a aplicação de métodos multicritério mais robustos e ajustados às necessidades específicas dos tomadores de decisão por meio de uma análise mais profunda. A partir da análise das 25 publicações selecionadas, destaca-se que tanto as técnicas hierárquicas quanto as não hierárquicas de clusterização têm sido amplamente empregadas.

Os 25 estudos analisados demonstraram que a escolha entre clusterização hierárquica e não hierárquica depende de alguns fatores. A clusterização hierárquica, por exemplo, tem sido priorizada em contextos de incerteza sobre o número de agrupamentos, como no trabalho de Ishizaka et al. (2021). Por outro lado, a clusterização não hierárquica tem sido amplamente aplicada em situações em que o número de clusters é previamente definido, como apresentado nos estudos de Li et al. (2023) e Chen et al. (2018), os quais empregaram a técnica de clusterização não hierárquica k-means. Dessa forma, a RSL destaca a relevância da integração entre técnicas de clusterização e métodos AMD como uma abordagem promissora, evidenciando o potencial dessa integração para o aprimoramento dos processos decisórios.

O método MADRID distingue-se dos demais por integrar de maneira inovadora a clusterização hierárquica com a modelagem multicritério, destacando-se pelo apoio à identificação de critérios relevantes no contexto analisado. Diferente de métodos tradicionais, que se limitam a agrupar alternativas ou gerar um ranking global, o MADRID promove uma

análise em múltiplos níveis: inicialmente organiza alternativas em clusters homogêneos e, em seguida, aplica o DIBR-MABAC para ranquear tanto os grupos quanto as alternativas dentro deles. Essa abordagem permite identificar os critérios com maior impacto na formação dos agrupamentos e na classificação final, auxiliando o decisor na definição dos atributos mais importantes para o problema.

4 O MÉTODO MADRID

Em seu estudo, Corriça et al. (2024) propuseram uma nova metodologia utilizando o método Multicriteria Analysis Directed by Ranking and Integrated Data-clustering (MADRID), o qual integra Aprendizado de Máquina e Apoio Multicritério à Decisão (AMD), aplicando a técnica de clusterização pelo método hierárquico aglomerativo single linkage com os métodos MABAC (Multi-Attributive Border Approximation area Comparison) e DIBR (Defining Interrelationships Between Ranked Criteria), visando atender às necessidades operacionais da Força, assim como os demais problemas atinentes às outras áreas da Ciência.

O método MADRID partiu da suposição sobre a integração de técnicas de aprendizado de máquina não supervisionado, como a clusterização, com métodos AMD, permitiria uma análise de dados avançada e detalhada, possibilitando uma melhor compreensão das características técnicas de um conjunto de alternativas.

Essa integração é particularmente poderosa ao aplicar a clusterização para formar grupos de alternativas com base em semelhanças nos critérios avaliados, seguido pela extração e análise de dados por meio da matriz dos centróides que representam as médias das características dos clusters, permitindo observar padrões específicos em cada grupo e orientar a tomada de decisão de forma contextualizada e direcionada.

Por exemplo, ao analisar aeronaves remotamente pilotadas, a matriz dos centróides pode destacar quais clusters possuem características mais adequadas para diferentes tipos de emprego, como vigilância e reconhecimento ou apoio e combate. Em missões de vigilância e reconhecimento, critérios como velocidade e autonomia tendem a ser prioritários. Nesse caso, a análise dos centróides permite identificar o cluster com valores mais elevados nesses critérios e, dentro desse cluster, aplicar um método de AMD para ranquear as alternativas e selecionar a mais adequada para essa finalidade. Por outro lado, para missões de apoio e combate, características como payload e velocidade podem ser mais importantes, levando a uma análise direcionada ao cluster com centróides que atendam melhor a esses requisitos.

Essa integração possibilita não somente identificar o cluster mais alinhado a cada tipo de emprego, mas também, dentro de cada cluster, utilizar métodos AMD para ranquear as alternativas dentro de cada cluster. Assim, consegue-se obter uma análise sobre qual alternativa seria ideal para um cenário em particular, considerando tanto as características técnicas predominantes no cluster quanto as demandas específicas do emprego em questão.

Além disso, essa integração entre clusterização e AMD não se limita a selecionar a melhor alternativa para um tipo de emprego específico; ela também fornece um entendimento mais profundo da distribuição das alternativas e de como diferentes grupos se

destacam em critérios relevantes. Isso é essencial para cenários de decisão complexos, como a aquisição de produtos de defesa, onde as necessidades podem variar amplamente entre missões. A capacidade de segmentar as alternativas em clusters e analisar seus centróides torna o processo decisório mais robusto, permitindo que cada alternativa seja avaliada dentro de um contexto técnico e operacional bem definido.

Portanto, a análise de dados extraída da clusterização e da matriz dos centróides é um fator preponderante para a integração dos métodos AMD com técnicas de aprendizado de máquina. Essa abordagem proporciona uma visão clara e objetiva das alternativas mais adequadas para diferentes tipos de emprego, garantindo que os recursos sejam alocados de forma eficiente e alinhados aos objetivos estratégicos da Marinha do Brasil.

A partir deste ponto e, através da RSL, a pesquisa em questão apresentou 25 novos métodos os quais integram técnicas de clusterização e métodos AMD. Como abordado no capítulo anterior, a técnica de clusterização se divide entre hierárquica e não-hierárquica. Além disso, a técnica de clusterização hierárquica se divide entre aglomerativa e divisiva, sendo três métodos de encadeamento dentro do método aglomerativo, sendo eles: Single Linkage, Complete Linkage e Average Linkage. A seguir será apresentado o passo a passo de como a pesquisa apontou a técnica de clusterização hierárquica Single-Linkage como a que melhor se integraria na metodologia do método MADRID a fim de cumprir o objetivo do trabalho.

O método utilizado para gerar os pesos dos critérios na metodologia do MADRID é o método DIBR, o qual adota uma abordagem diferenciada para a análise multicritério. Em vez de realizar comparações entre todos os pares de critérios ou alternativas, como no AHP, em que se utiliza a escala de SAATY, o DIBR foca na comparação entre critérios adjacentes. Essa estratégia simplifica o processo de avaliação, já que não exige o preenchimento completo de uma matriz de comparação. Além disso, essa abordagem permite ao método trabalhar com um número muito maior de alternativas e critérios, mantendo a eficiência e evitando problemas de inconsistência, mesmo em cenários com grande volume de dados.

Avaliando os métodos AMD extraídos da RSL, definiu-se o MABAC como a melhor escolha para ser combinado com a técnica de clusterização hierárquica aglomerativa single linkage. O MABAC se diferencia dos demais métodos AMD por avaliar as alternativas com base em suas distâncias em relação à área aproximada da fronteira.

A maioria dos métodos encontrados nessa RSL, como TOPSIS, AHP, PROMETHEE, ELECTRE, WASPAS, e DEMATEL, compartilham semelhanças com o MABAC em sua estrutura. Assim como o MABAC, eles utilizam etapas de normalização, ponderação de critérios e cálculo de valores agregados para cada alternativa. A seguir são apresentados alguns exemplos:

- O TOPSIS e o MABAC trabalham com distâncias, embora o TOPSIS compare as alternativas a soluções ideais positivas e negativas, enquanto o MABAC utiliza a área aproximada da fronteira; e
- Métodos como PROMETHEE e ELECTRE utilizam comparações parciais ou relações de superação, enquanto o MABAC calcula distâncias globais, tornando-se mais simples e intuitivo.

O MABAC se destaca entre os métodos citados por sua robustez, escalabilidade e capacidade de integrar análises locais e globais de maneira eficiente. Ele é ideal para o método MADRID, pois complementa a clusterização hierárquica ao fornecer uma ferramenta multicritério que avalia alternativas dentro de clusters e os clusters entre si de forma precisa e integrada. Ao combinar simplicidade, flexibilidade e eficiência operacional, o MABAC se consolida como uma escolha estratégica para problemas complexos no apoio à tomada de decisão. A seguir serão apresentadas as fórmulas do MADRID e seus conceitos básicos.

4.1 CLUSTERIZAÇÃO HIERÁRQUICA *SINGLE-LINKAGE*

Enquanto os esquemas hierárquicos permitem a identificação do ordenamento e da alocação das observações, oferecendo possibilidades para que o pesquisador estude, avalie e decida sobre a quantidade de agrupamentos formados, nos esquemas não hierárquicos, parte-se de uma quantidade conhecida de clusters e, a partir de então, é elaborada a alocação das observações nesses clusters, com posterior avaliação da representatividade de cada variável para a formação deles. Portanto, o resultado de um método pode servir de input para a realização do outro, tornando a análise cíclica (FÁVERO; BELFIORE, 2017).

A escolha por métodos hierárquicos, em vez de técnicas não hierárquicas como o k-means, foi motivada pela necessidade de evitar que o usuário tivesse que definir previamente o número de clusters. Em métodos não hierárquicos, essa decisão é essencial, mas pode ser problemática, pois a definição de um número inadequado de cluster pode resultar em uma má distribuição das alternativas, comprometendo a qualidade da clusterização e, conseqüentemente, da análise de dados.

A clusterização hierárquica, conforme afirmado por Fávero e Belfiore (2017), oferece maior flexibilidade, permitindo ao usuário explorar diferentes números de agrupamentos antes de fixar uma escolha. Para garantir a qualidade da solução, foi integrado o método da silhueta na ferramenta, que avalia a coesão e a separação dos clusters formados. Essa abordagem permite determinar automaticamente o número ideal de clusters com base nos dados, proporcionando uma clusterização mais precisa e confiável. Com isso, o usuário não

precisa se preocupar com a escolha inicial de um número de cluster, garantindo uma análise robusta e eficiente, sem a complexidade adicional de ajustar manualmente os parâmetros.

O algoritmo de clusterização hierárquica aglomerativa single linkage tem sido amplamente utilizado em várias aplicações e é considerado mais versátil do que muitos outros algoritmos (JAIN; MURTY; FLYNN, 1999). Esta técnica de clusterização funciona bem em conjuntos de dados que contêm clusters não isotrópicos, incluindo clusters bem separados, em formato de cadeia e concêntricos, enquanto um algoritmo particional típico, como o k-means, funciona bem apenas em conjuntos de dados com clusters isotrópicos (NAGY, 1968).

O single linkage forma clusters com base na menor distância entre pontos. Isso permite que ele capture relações locais e progressivas. Como ele respeita as conexões locais, a forma natural do cluster é preservada, e o cálculo do centróide reflete a distribuição real dos pontos.

Embora o complete linkage e o average linkage também possam produzir centróides representativos, sua eficácia depende do formato do cluster. Ou seja, para clusters esféricos ou homogêneos, qualquer um dos três métodos pode ser adequado.

Para clusters não isotrópicos, o single linkage se destaca, pois preserva as relações locais de forma mais eficiente, garantindo que ao calcular o centróide, ele reflita a média dos pontos que realmente pertencem à estrutura do cluster.

Portanto, a técnica de clusterização single linkage é preferível aos demais métodos no MADRID porque identifica clusters com formas complexas e preserva sua estrutura ao calcular os centróides. Esses centróides representam fielmente os dados originais, permitindo que o MADRID execute análises multicritério com eficiência e precisão, mesmo em problemas envolvendo grandes volumes de dados ou padrões não isotrópicos.

A clusterização hierárquica single linkage foi utilizada no método MADRID porque oferece uma capacidade superior de identificar agrupamentos com formas complexas e não isotrópicas, característica fundamental para problemas envolvendo alternativas com grande diversidade técnica e operacional. Diferente de métodos como o k-means, que requerem a definição prévia do número de clusters, o single linkage permite uma exploração mais flexível da estrutura dos dados, possibilitando a descoberta de agrupamentos naturais sem a necessidade de suposições iniciais.

Além disso, a escolha do single linkage se justifica pela sua habilidade em preservar relações locais entre as alternativas. Isso garante que o cálculo dos centróides dos clusters seja representativo das características reais do conjunto de dados, fornecendo uma base sólida para as etapas subsequentes de análise multicritério no método MADRID. Essa preservação da estrutura dos dados é essencial para evitar distorções nos resultados e assegurar que o ranqueamento das alternativas seja contextualizado e alinhado às

necessidades operacionais.

A técnica também se mostrou adequada ao ser combinada com o método da silhueta, utilizado para determinar automaticamente o número ótimo de clusters. Essa integração fortalece a robustez do MADRID, evitando problemas comuns de overfitting ou underfitting na formação de grupos. Com isso, o processo decisório ganha em eficiência e precisão, tornando-se especialmente útil em contextos de big data e em cenários onde a análise de grandes volumes de informações é necessária.

Por fim, a utilização do single linkage no MADRID reflete uma estratégia metodológica alinhada aos princípios de escalabilidade e flexibilidade. Essa abordagem proporciona não apenas uma segmentação mais precisa das alternativas, mas também uma visão estratégica das características técnicas predominantes em cada cluster, permitindo ao tomador de decisão uma avaliação mais aprofundada e direcionada. Assim, o método MADRID consolida-se como uma solução inovadora para problemas complexos de apoio multicritério à decisão.

4.2 DIBR (*DEFINING INTERRELATIONSHIPS BETWEEN RANKED CRITERIA*)

O método DIBR foi criado pelo professor Pamučar e permite que os Decision-Makers (DMs) percebam de uma melhor forma as relações entre os critérios, uma vez que considera as relações entre os critérios adjacentes, eliminando assim o problema de definir relações entre critérios remotos, o que em muitos casos, diminui a consistência dos resultados em modelos que necessitam da subjetividade dos especialistas, como, por exemplo, o que ocorre na primeira etapa do método Analytic Hierarchy Process (AHP) (PAMUCAR et al., 2021). No método AHP, a escala fundamental de Saaty limita a preferências dos especialistas a uma proporção máxima de 9:1, o que dificulta obter resultados consistentes em modelos com muitos critérios, já no método DIBR esse problema é eliminado ao se considerar uma escala com todos os valores reais no intervalo $[0,1]$ (PAMUCAR et al., 2021).

De acordo com Pamucar et al. (2021), o método DIBR é dividido em 3 etapas, sendo elas: classificação dos critérios por significância; comparação entre os critérios e definição de suas interrelações; e cálculo dos coeficientes de pesos dos critérios.

Etapa 1 - Classificação dos critérios por significância: Consideremos n critérios, os DMs definem a classificação dos critérios mediante sua avaliação sobre o grau de significância de cada critério. Como, por exemplo, teremos a seguinte ordem: $C1 > C2 > C3 > \dots > CN$; sendo $C1$ critério de maior significância e CN o critério de menor significância.

Etapa 2 - Comparação entre os critérios e definição de suas interrelações: Os

DMs dividem entre dois critérios adjacentes observados, um intervalo de significância de 100%. Ao comparar o critério C1 com o critério C2, que tenham coeficientes de pesos, respectivamente, 1 e 2 um valor 12 é atribuído, sempre no intervalo $[0,1]$, de modo que:

$$\frac{\rho_1}{\rho_2} = \frac{(1 - \gamma_{12})}{\gamma_{12}} \quad (5)$$

De forma análoga, temos:

$$\frac{\rho_2}{\rho_3} = \frac{(1 - \gamma_{23})}{\gamma_{23}}; \quad (6)$$

$$\frac{\rho_3}{\rho_4} = \frac{(1 - \gamma_{34})}{\gamma_{34}}; \text{ e} \quad (7)$$

...

$$\frac{\rho_{N-1}}{\rho_N} = \frac{(1 - \gamma_{N-1,N})}{\gamma_{N-1,N}} \quad (8)$$

Etapa 3: Cálculo do peso dos critérios: O objetivo desse cálculo (PAMUCAR et al., 2021) é escrever todos os pesos dos critérios em função do peso do critério de maior significância (ρ_1), logo isolando ρ_2 em (2) temos:

$$\rho_2 = \frac{\gamma_{12}}{(1 - \gamma_{12})} \rho_1 \quad (9)$$

Usando (6) em (6), obtemos ρ_3 como uma função de ρ_1 :

$$\rho_3 = \frac{\gamma_{23}}{(1 - \gamma_{23})} \rho_2 = \frac{\gamma_{12}\gamma_{23}}{(1 - \gamma_{12})(1 - \gamma_{23})} \rho_1 \quad (10)$$

Seguindo as substituições, temos:


$$\rho_N = \frac{\gamma_{12}\gamma_{23} \cdots \gamma_{N-1,N}}{(1 - \gamma_{12})(1 - \gamma_{23}) \cdots (1 - \gamma_{N-1,N})} \rho_1 = \frac{\prod_{i=1}^{N-1} \gamma_{i,i+1}}{\prod_{i=1}^{N-1} (1 - \gamma_{i,i+1})} \rho_1 \quad (11)$$

4.3 MABAC (*MULTI-ATTRIBUTIVE BORDER APPROXIMATION AREA COMPARISON*)

A base do método MABAC se reflete na definição da distância da função critério de cada alternativa observada da área aproximada da fronteira (TEŠIĆ et al., 2022). A figura 8 representa a posição das diversas alternativas A_i em relação à área aproximada

da fronteira, para um determinado critério C . Para que uma determinada alternativa A_i seja selecionada como a melhor é preciso que ela tenha a maior quantidade de critérios pertencentes à área aproximada superior (G^+) (PAMUČAR; ČIROVIĆ, 2015).

Figura 6 – Posição das alternativas em relação a área aproximada da fronteira.



Fonte: (PAMUČAR; ČIROVIĆ, 2015).

O método MABAC é dividido em 6 etapas, sendo elas: matriz de decisão inicial; normalização da matriz de decisão; ponderação da matriz normalizada; determinação da área aproximada da fronteira; cálculo da distância da alternativa para a área aproximada da fronteira; e classificação das alternativas (PAMUČAR; ČIROVIĆ, 2015).

Etapa 1 - Matriz de decisão inicial: A matriz de decisão inicial (X) tem o objetivo de relacionar m alternativas aos seus n critérios, de modo que $A_i = (x_{i1}, x_{i2}, \dots, x_{in})$, onde x_{ij} o valor da alternativa A_i para o critério i enésimo, sendo $i = 1, 2, \dots, m$ e $j = 1, 2, \dots, n$.

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix} \quad (12)$$

Etapa 2: Normalização da matriz de decisão: Nessa etapa é preciso verificar para cada critério, se é um critério de custo, ou seja, quanto menor, melhor. Ou se é um critério de ganho, ou seja, quanto maior, melhor.

Para um critério de ganho, é utilizado:

$$N_{ij} = \frac{(X_{ij} - X_i^-)}{(X_i^+ - X_i^-)} \quad (13)$$

E para critérios de custo, é utilizado:

$$N_{ij} = \frac{(X_{ij} - X_i^+)}{(X_i^- - X_i^+)} \quad (14)$$

Onde X_{ij} , X_i^+ e X_i^- são elementos da matriz de decisão inicial (X), onde X_i^+ é o maior dos valores das alternativas para determinado critério e X_i^- o menor dos valores. Resultando assim, na matriz normalizada (N) (PAMUČAR; ČIROVIĆ, 2015):

$$N = \begin{bmatrix} n_{11} & n_{12} & \cdots & n_{1n} \\ n_{21} & n_{22} & \cdots & n_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ n_{m1} & n_{m2} & \cdots & n_{mn} \end{bmatrix} \quad (15)$$

Etapa 3: Ponderação da matriz normalizada: Para essa ponderação, é utilizada os coeficientes de pesos dos n critérios obtidos, no caso do presente estudo, através do método DIBR, representado pela matriz (W), sendo:

$$w = [w_1, w_2, w_3, \dots, w_n] \quad (16)$$

A matriz ponderada (V) é calculada de modo que cada elemento V_{ij} seja calculado da seguinte forma (PAMUČAR; ČIROVIĆ, 2015):

$$V_{ij} = W_i \cdot (n_{ij} + 1) \quad (17)$$

Obtemos então a matriz ponderada (V), sendo:

$$V = \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1n} \\ v_{21} & v_{22} & \cdots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{m1} & v_{m2} & \cdots & v_{mn} \end{bmatrix} = \begin{bmatrix} w_1(n_{11} + 1) & w_2(n_{12} + 1) & \cdots & w_n(n_{1n} + 1) \\ w_1(n_{21} + 1) & w_2(n_{22} + 1) & \cdots & w_n(n_{2n} + 1) \\ \vdots & \vdots & \ddots & \vdots \\ w_1(n_{m1} + 1) & w_2(n_{m2} + 1) & \cdots & w_n(n_{mn} + 1) \end{bmatrix} \quad (18)$$

Etapa 4: Determinação da área aproximada da fronteira: Nessa etapa é determinada a matriz (G), no formato $n \times 1$, que representa a área aproximada da fronteira para cada critério, onde " n " é o número de critérios e cada elemento é o resultado do produtório de cada coluna da matriz V , elevado ao inverso da quantidade de linhas da matriz V , conforme a fórmula abaixo (PAMUČAR; ČIROVIĆ, 2015):

$$g_i = \left(\prod_{j=1}^m v_{ij} \right)^{\frac{1}{m}} \quad (19)$$

Temos então a matriz (G) , onde g_i é a área aproximada para o critério C_i .

Etapa 5: Cálculo da distância da alternativa para a área aproximada da fronteira: A distância das alternativas da área de aproximação da fronteira (q_{ij}) é obtida com a diferença entre os elementos da matriz ponderada (V) e o valor da área de aproximação da borda (G) (PAMUČAR; ĆIROVIĆ, 2015):

$$Q = V - G = \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1n} \\ v_{21} & v_{22} & \cdots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{m1} & v_{m2} & \cdots & v_{mn} \end{bmatrix} - \begin{bmatrix} g_1 & g_2 & \cdots & g_n \\ g_1 & g_2 & \cdots & g_n \\ \vdots & \vdots & \ddots & \vdots \\ g_1 & g_2 & \cdots & g_n \end{bmatrix} \quad (20)$$

A matriz (Q) é então formada, relacionando a distância de todas as m alternativas para cada um dos n critérios.

$$Q = \begin{bmatrix} v_{11} - g_1 & v_{12} - g_2 & \cdots & v_{1n} - g_n \\ v_{21} - g_1 & v_{22} - g_2 & \cdots & v_{2n} - g_n \\ \vdots & \vdots & \ddots & \vdots \\ v_{m1} - g_1 & v_{m2} - g_2 & \cdots & v_{mn} - g_n \end{bmatrix} = \begin{bmatrix} q_{11} & q_{12} & \cdots & q_{1n} \\ q_{21} & q_{22} & \cdots & q_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ q_{m1} & q_{m2} & \cdots & q_{mn} \end{bmatrix} \quad (21)$$

Etapa 6: Classificação das alternativas: Calculando-se a soma da distância das alternativas das áreas aproximadas da fronteira, ou seja, a soma dos elementos da matriz (Q) por linhas, obtêm-se os valores finais das funções critério das alternativas (PAMUČAR; ĆIROVIĆ, 2015):

$$S_i = \sum_{j=1}^n q_{ij}, \quad j = 1, 2, \dots, n \quad i = 1, 2, \dots, m \quad (22)$$

Entre as m alternativas, a que obtiver o maior valor de soma, define-se como a melhor.

4.4 MÉTODO HÍBRIDO DIBR-MABAC

Em seu estudo, Corriça *et al.* (2023) propuseram um método de apoio multicritério à decisão híbrido com o objetivo de propor a seleção de uma nova viatura blindada anfíbia para a Marinha do Brasil, entre cinco alternativas estudadas à luz de cinco critérios. Para realizar a ordenação das alternativas, foi aplicado o método MABAC

(Multi-Attribute Border Approximation area Comparison). O método DIBR-MABAC (Defining Interrelationships Between Ranked Criteria) teve sua aplicação na obtenção dos coeficientes dos pesos dos cinco critérios analisados.

A pesquisa demonstrou a eficiência do método híbrido DIBR-MABAC para solucionar problemas de escolha, evidenciando sua aplicação na seleção da melhor viatura blindada anfíbia, como o Iveco SuperAV, para a Marinha do Brasil. O DIBR se destacou como uma abordagem prática e coerente para determinar os pesos dos critérios, especialmente em casos com grande número de critérios, enquanto o MABAC provou ser uma ferramenta robusta para identificar a escolha ideal. Essa combinação ressalta a importância de métodos AMD no apoio à tomada de decisão para orientar a alocação de recursos em aquisições das Forças Armadas, garantindo soluções racionais e eficazes, mesmo diante de restrições orçamentárias.

4.5 ESTRUTURA DO MÉTODO MADRID


Conforme apresentado por Corriça *et al.* (2024), inicialmente, foi proposto para o método MADRID a seguinte estrutura:

- 1º Passo: Coleta dos dados a serem analisados;
- 2º Passo: Formação de Clusters, utilizando a técnica de clusterização;
- 3º Passo: Classificação dos Clusters por meio do método DIBR-MABAC;
- 4º Passo: Ranqueamento das alternativas do Cluster mais bem avaliado;
- 5º Passo: Escolha da Alternativa mais apropriada.

Contudo, observou-se que, ao selecionar somente as alternativas contidas no cluster mais bem ranqueado pelo método híbrido DIBR-MABAC, as demais alternativas contidas nos demais cluster ficariam fora da matriz de decisão final, causando perda de informação. Dessa forma, foi elaborada uma nova metodologia contendo na matriz de decisão final, não só as alternativas do cluster mais bem ranqueado como também as alternativas mais bem avaliadas dos demais cluster, compondo assim a matriz de decisão final.

Após essa análise, foi realizado uma alteração na estruturação da matriz de decisão final, onde foram incluídas, além das alternativas do cluster mais bem avaliado, as alternativas mais bem avaliadas dos demais clusters.

Figura 7 – Primeiro diagrama do método MADRID.



Fonte: Próprio autor.


Inicialmente, as alternativas são agrupadas usando o método de clusterização hierárquico aglomerativo Single-Linkage, o qual forma clusters, facilitando a identificação de padrões e agrupamentos naturais. Além disso, a clusterização é realizada utilizando o método da silhueta para determinar o número de clusters, garantindo uma segmentação mais precisa e significativa dos dados.

Após realizada a clusterização, os clusters formados são ranqueados por meio dos valores dos centróides através da aplicação do método híbrido DIBR-MABAC. O método DIBR é empregado para determinar os pesos dos critérios de forma objetiva, eliminando a necessidade de definir relações subjetivas entre critérios e o método MABAC é aplicado para ordenação das alternativas. Após isso, as alternativas dentro de cada cluster são ordenadas utilizando-se novamente o método híbrido DIBR-MABAC. Em seguida, estrutura-se a matriz de decisão final composta por todas as alternativas contidas no cluster mais bem ranqueado conjuntamente com a alternativa mais bem classificada dentro de cada um dos demais clusters e, com a aplicação do método híbrido DIBR-MABAC, executa-se o ranqueamento das alternativas da matriz de decisão final, apresentando, assim, um apoio à tomada de decisão da melhor alternativa a ser selecionada.

A figura 10 apresenta o diagrama do método MADRID e, a fim de detalhar melhor este método, apresenta-se a sequência de etapas:

- 1º Passo: Estruturar a matriz de decisão inicial;
- 2º Passo: Aplicar o método Hierárquico Aglomerativo Single Linkage utilizando o método da silhueta e calcular os centróides dos clusters;
- 3º Passo: Ranquear os clusters pelos valores dos centróides por meio do método híbrido DIBR-MABAC;
- 4º Passo: Ranquear as alternativas dentro de cada cluster com o método híbrido DIBR-MABAC;
- 5º Passo: Estruturar a matriz de decisão final composta pelas alternativas contidas no cluster mais bem ranqueado conjuntamente com a alternativa mais bem ranqueada de cada um dos demais cluster;
- 6º Passo: Ranqueamento das alternativas pelo método híbrido DIBR-MABAC a partir da matriz de decisão final; e
- 7º Passo: Seleção da alternativa mais apropriada.

Figura 8 – Diagrama do método MADRID.



Fonte: Próprio autor.

Esta abordagem bipartida, que primeiro clusteriza os dados e depois aplica o método AMD, permite a identificação de padrões naturais e direciona a análise detalhada para os grupos mais relevantes, garantindo uma avaliação mais precisa e eficiente das alternativas. A clusterização não apenas organiza os dados em agrupamentos significativos, mas também

fornece um suporte valioso à tomada de decisão ao considerar o emprego do meio que se pretende adquirir, o que é realizado por meio da análise de dados extraída da matriz de centróides. Essa matriz sintetiza as características médias dos clusters, permitindo alinhar as escolhas às necessidades operacionais e estratégicas de forma mais assertiva. Essa abordagem flexível e adaptável otimiza o uso de recursos e melhora a qualidade das decisões, alinhando-as com os objetivos estratégicos da organização, resultando em escolhas mais informadas e bem fundamentadas.

O método MADRID diferencia-se dos demais por integrar de forma única a clusterização hierárquica à modelagem multicritério, com foco no apoio à identificação de critérios relevantes no contexto analisado. Ao contrário de abordagens convencionais, que se limitam a agrupar alternativas ou gerar um ranking global, o MADRID realiza uma análise em múltiplas etapas: inicialmente, agrupa alternativas em clusters homogêneos e, em seguida, aplica o DIBR-MABAC para ranquear tanto os grupos quanto as alternativas dentro de cada cluster. Essa abordagem possibilita identificar os critérios com maior impacto na formação dos grupos e na classificação final, orientando o decisor sobre os atributos mais relevantes para o problema.

Dessa forma, o método MADRID se apresenta como um método de apoio à decisão quantitativo, ordinal-cardinal não compensatório, o qual analisa dados de forma objetiva. Além disso, o MADRID é um método que realiza ordenação, seleção e classificação das alternativas.

4.6 PLATAFORMA COMPUTACIONAL

Nesta seção, será apresentada a ferramenta computacional MADRID, além da análise de uma matriz de dados hipotéticos composta por aeronaves militares. Ressalta-se que o *dataset* utilizado pode ser baixado diretamente do software.

A ferramenta online MADRID foi desenvolvida para usuários que buscam uma solução prática, eficaz e gratuita para problemas que envolvem suporte à tomada de decisão multicritério. Esta ferramenta possui integração total com o Excel, permitindo a manipulação direta de planilhas dentro da plataforma.

4.6.1 APLICAÇÃO PRÁTICA DO MÉTODO MADRID

A Tabela 3 apresenta a matriz de decisão do exemplo dos dados que serão utilizados para aplicar a ferramenta computacional MADRID. Para isso, selecionou-se 15 aeronaves hipotéticas à luz de seis critérios.

Tabela 3 – Matriz de decisão.

	VEL	ALT	AUT	PYL	PES	CST
Monotonicidade	Lucro	Custo	Custo	Lucro	Lucro	Lucro
Aeronave A	640	8	6	520	310	40
Aeronave B	1500	17	15	1200	400	50
Aeronave C	600	5	8	900	600	33
Aeronave D	300	4	20	330	100	12
Aeronave E	940	12	15	1120	330	22
Aeronave F	520	5	6	350	100	10
Aeronave G	680	10	4	330	65	12
Aeronave H	800	12	20	400	90	20
Aeronave I	540	3	12	300	200	15
Aeronave J	900	8	8	350	167	33
Aeronave K	330	5	18	220	100	10
Aeronave L	890	12	10	400	221	40
Aeronave M	900	9	15	800	102	48
Aeronave N	700	10	8	1000	400	40
Aeronave O	620	8	20	180	200	25

Fonte: Próprio autor.

Para o exemplo em questão, foram definidos seis critérios para avaliação das alternativas, sendo eles os seguintes:


- **Velocidade máxima em nós (VEL):** Refere-se à maior velocidade que a aeronave pode atingir durante o voo.
- **Altitude de voo máxima em km (ALT):** A maior altura a que a aeronave pode operar acima do nível do mar.

- **Autonomia em horas (AUT):** Capacidade da aeronave de permanecer em voo sem necessidade de reabastecimento ou recarga.
- **Payload em kg (PYL):** Capacidade de carga útil que a aeronave pode transportar, incluindo sensores e armamentos.
- **Peso máximo de decolagem em kg (PES):** O peso total que a aeronave pode ter ao decolar, incluindo combustível e carga.
- **Custo (US\$ milhões – CST):** Investimento necessário para adquirir a aeronave.

4.6.2 FERRAMENTA COMPUTACIONAL MADRID

É possível verificar os recursos disponíveis na plataforma, permitindo uma compreensão clara das funcionalidades oferecidas, conforme ilustrado na figura 11.

Figura 9 – Funcionalidades da plataforma.



Fonte: Próprio autor.


A seguir será realizada a explanação sobre cada uma das funcionalidades apresentadas na figura 11:

1. **Instructions (Instruções):** Esta aba fornece instruções sobre como usar o aplicativo MADRID;
2. **Data Input (Entrada de dados):** Esta aba permite a inserção de dados para análise. Primeiramente, deve-se baixar uma tabela de exemplo, carregar seu arquivo de dados em formato .xlsx. Para preencher a linha 'Type', digite '-1' para critérios não-benefícios (quanto maior, pior para a alternativa) e marque '1' para critérios benefícios;
3. **Criteria Weights (Peso dos critérios):** Esta aba exibe os pesos calculados para as variáveis em sua análise;
4. **Dendrogram (Dendrograma):** Esta aba exibe o gráfico de dendrograma;
5. **Clustering Tests (Testes de clusterização):** Esta aba apresenta os resultados da métrica da silhueta. Um valor global elevado da silhueta reflete uma boa separação entre clusters e coesão interna, sendo recomendado para validar a qualidade da clusterização;
6. **Centroids (Centróides):** Esta aba apresenta a classificação dos clusters pelos valores dos seus centróides;
7. **Cluster Analytics (Análise dos clusters):** Esta aba apresenta os resultados da análise de cluster;
8. **Final decision matrix (Matriz de decisão final):** Esta aba apresenta a matriz de decisão final; e
9. **Performance (Desempenho):** Esta aba apresenta o ranqueamento do método MADRID. Observações: Certifique-se de que os dados sejam quantitativos e reais.

Na aba “Data input”, conforme ilustrado na figura 12, é possível realizar o download do arquivo de dados no formato .xlsx, clicando no botão “Download Example File”. Após isso, o usuário insere os dados no arquivo clica no botão “Browse” para procurar o arquivo e realizar o upload do mesmo na plataforma.

Ao preencher a planilha padrão, quando for preencher a linha “Type”, deve-se inserir “1” para critérios monotônicos de lucro (quanto maior o valor, melhor a alternativa) e “-1” para critérios monotônicos de custo (quanto menor o valor, pior a alternativa).


Figura 10 – Entrada de dados.



Fonte: Próprio autor.

Em seguida, na aba “Criteria weights”, conforme ilustrado na figura 13, serão apresentados todos os critérios para serem selecionados em ordem de significância da esquerda para a direita. Após isso, o botão “Confirm this order” possibilita que o usuário possa então inserir a interrelação entre os critérios adjacentes e, ao fim, clicar no botão “Confirm comparisons”, assim como ilustrado na figura 14. Logo após, os valores dos pesos dos critérios são apresentados, como apresentado na figura 15.

Figura 11 – Seleção da ordem de significância dos critérios.



Fonte: Próprio autor.

Figura 12 – Definição da interrelação entre os critérios.

Order confirmed: ('C3', 'C2', 'C4', 'C5', 'C1', 'C6')

Choose how much the criterion C3 is more important than the criterion C2: 50 **60** 100

Choose how much the criterion C2 is more important than the criterion C4: 50 **73** 100

Choose how much the criterion C4 is more important than the criterion C5: 50 **57** 100

Choose how much the criterion C5 is more important than the criterion C1: 50 **65** 100

Choose how much the criterion C1 is more important than the criterion C6: 50 **74** 100

Confirm comparisons

Fonte: Próprio autor.

Figura 13 – Resultado dos pesos dos critérios.

Order confirmed: ('C3', 'C2', 'C4', 'C5', 'C1', 'C6')

Below are the weights calculated using the DIBR method:


C1	C2	C3	C4	C5	C6
0.04482256	0.29833726	0.44750589	0.11034392	0.0832419	0.01574847

Fonte: Próprio autor.

Ao clicar na aba “Dendrogram”, o software apresenta a gráfico de dendrograma, conforme ilustrado na figura 16.

Com base no esquema de aglomeração, pode-se construir um gráfico em formato de árvore, conhecido como dendrograma, cujo intuito é ilustrar o passo a passo dos agrupamentos e facilitar a visualização da alocação de cada observação em cada estágio (FÁVERO; BELFIORE, 2017).

Figura 14 – Gráfico de dendrograma.



Fonte: Próprio autor.

O eixo vertical (Distance) representa as distâncias entre os grupos durante o processo de fusão, enquanto o eixo horizontal lista as alternativas ou observações individuais.


No dendrograma apresentado, nota-se que a Aeronave B se destaca como um outlier, sendo conectada ao restante das alternativas apenas em uma distância bastante elevada, superior a 1600. Em níveis intermediários, surgem grupos que indicam similaridades significativas entre algumas alternativas, conectando-se ao restante do conjunto em distâncias moderadas. Já em distâncias menores, aparecem subgrupos bem definidos.

A aba “clustering test” apresenta os resultados da métrica da silhueta, os quais fornecem uma avaliação da qualidade da clusterização, conforme ilustrado na figura 17. Valores da silhueta próximos de 1 indicam que os objetos estão bem alocados dentro de seus clusters, demonstrando boa coesão interna. Já valores próximos de 0 sugerem que os objetos estão posicionados na fronteira entre dois clusters, podendo indicar ambiguidade na classificação. Por outro lado, valores negativos apontam possíveis alocações inadequadas dos objetos. Um alto valor médio da silhueta global é um indicativo de boa separação entre os clusters e de forte coesão interna, sendo uma ferramenta valiosa para validar a eficácia do agrupamento.

A aba “Centroids” apresenta a matriz dos centróides, composta pelos valores dos critérios dos centróides de cada cluster. Além disso, também fornece o ranqueamento dos cluster pelos valores dos centróides, assim como ilustra a figura 18.

A aba “Cluster Analytics” apresenta o ranqueamento das alternativas dentro de cada cluster, conforme apresentado na figura 19.

Figura 15 – Gráfico de silhueta.



Fonte: Próprio autor.

Figura 16 – Matriz dos centróides.

Matrix formed by the centroids of each cluster:						
Cluster	C1	C2	C3	C4	C5	C6
Cluster 1	668.5714	7.2143	11.3571	335	327.3571	28.3571
Cluster 2	1500	17	15	1200	2400	17

The clusters were classified by their centroids, obtaining the following classification:

Rating	Cluster	Value
1º	Cluster 1	0.3474
2º	Cluster 2	-0.1758

The best cluster is the Cluster number 1 !

Fonte: Próprio autor.

A figura 17 apresenta o coeficiente de silhueta médio calculado para diferentes quantidades de clusters, variando de 2 até 15, que é o número máximo de alternativas nos dados analisados. Conforme ilustrado no gráfico, o maior valor do índice foi obtido para 2 clusters, sugerindo que essa é a melhor configuração para segmentar os dados. Dessa forma, a escolha de 2 clusters se justifica como a mais adequada segundo essa métrica. No desenvolvimento da ferramenta, definiu-se que a clusterização será realizada sempre a partir de 2 clusters pelo menos e calculado o coeficiente de silhueta médio para todos os valores de 2 até o número de alternativas analisadas. Além disso, o software MADRID tem sua aplicação limitada em até 1.000 alternativas.

A figura 18 apresenta a matriz dos centróides de dois clusters formados, com os valores médios calculados para seis critérios C1 a C6. Além disso, os clusters foram classificados com base nos valores de seus centróides, resultando em uma pontuação de 0.3474 para o Cluster 1 e -0.1758 para o Cluster 2. Como o Cluster 1 obteve a maior pontuação, ele foi considerado o melhor cluster no processo de decisão.

Figura 17 – Análise dos clusters.

Cluster number 1 obtained the following classifications:		
Rating	Alternative	Value
1º	Aeronave C	0.2821
2º	Aeronave F	0.2343
3º	Aeronave H	0.2105
4º	Aeronave A	0.1854
5º	Aeronave G	0.1331
6º	Aeronave I	0.116
7º	Aeronave J	0.1124
8º	Aeronave N	0.0957
9º	Aeronave M	-0.0512
10º	Aeronave L	-0.0888
11º	Aeronave K	-0.1331
12º	Aeronave D	-0.147
13º	Aeronave E	-0.2118
14º	Aeronave O	-0.2646
<i>This cluster is the best, all its alternatives will be considered in the final decision matrix.</i>		
Cluster number 2 obtained the following classifications:		
Rating	Alternative	Value
1º	Aeronave B	0
<i>This is not the best cluster, only its best alternative Aeronave B will go into the final decision matrix.</i>		

Fonte: Próprio autor.

A figura 19 apresenta o ranqueamento das alternativas dentro de cada cluster. O Cluster 1, considerado o melhor cluster, contém 14 alternativas, sendo a Aeronave C a melhor avaliada com um valor de 0.2821, seguida pela Aeronave F e Aeronave H. Como esse cluster foi mais bem avaliado, todas as suas alternativas serão incluídas na matriz de decisão final. Já o Cluster 2, por ter obtido um desempenho inferior, terá apenas sua melhor alternativa, a Aeronave B, incluída na matriz final.

Já na aba “Final Decision Matrix” é apresentada a Matriz de decisão final, composta pelas alternativas do cluster mais bem avaliado (cluster 1) conjuntamente com a outra alternativa mais bem avaliada do cluster 2, conforme demonstrado na figura 20.

Por fim, na aba “Performance” é apresentada a ordenação do método MADRID, assim como ilustrado na figura 21, apresentando o ranqueamento final das alternativas obtido pelo método MADRID, com base na matriz de decisão final. As aeronaves foram ordenadas de acordo com seus valores de desempenho.

Figura 18 – Matriz de decisão final.

Alternatives	C1	C2	C3	C4	C5	C6
Aeronave A	640	8	6	520	310	40
Aeronave C	600	5	8	900	600	33
Aeronave D	300	4	20	330	100	46
Aeronave E	940	12	15	50	700	8
Aeronave F	520	5	6	350	100	50
Aeronave G	680	10	4	330	65	12
Aeronave H	800	2	9	80	100	13
Aeronave I	540	3	12	300	250	10
Aeronave J	900	8	8	350	167	30
Aeronave K	330	5	18	200	331	12
Aeronave L	890	12	10	100	220	40
Aeronave M	900	9	15	800	120	48
Aeronave N	700	10	8	200	1320	30
Aeronave O	620	8	20	180	200	25
Aeronave B	1500	17	15	1200	2400	17

Fonte: Próprio autor.

Figura 19 – Ranqueamento final do método MADRID.

Rating	Alternative	Value
1º	Aeronave C	0.2375
2º	Aeronave F	0.2262
3º	Aeronave A	0.1911
4º	Aeronave H	0.1726
5º	Aeronave G	0.1713
6º	Aeronave J	0.1197
7º	Aeronave N	0.0991
8º	Aeronave I	0.0845
9º	Aeronave L	-0.0345
10º	Aeronave M	-0.0477
11º	Aeronave B	-0.0764
12º	Aeronave K	-0.1369
13º	Aeronave D	-0.1571
14º	Aeronave E	-0.1722
15º	Aeronave O	-0.2434

Fonte: Próprio autor.

4.6.3 ANÁLISE DE SENSIBILIDADE

A partir da mesma matriz de decisão inicial utilizada neste exemplo em questão e, utilizando os mesmos valores dos pesos dos critérios gerados pelo método DIBR ilustrado na figura 12, foi realizada a comparação do ranqueamento do método MADRID com outros

dois métodos AMD consagrados na literatura, sendo eles o método COCOSO (YAZDANI et al., 2019) e o método TOPSIS (HWANG et al., 1981).

Tabela 4 – Ranqueamento gerado pelos métodos.

RANKING	MADRID		COCOSO		TOPSIS	
1°	Aeronave C	0,2375	Aeronave C	2,7587	Aeronave F	0,6926
2°	Aeronave F	0,2262	Aeronave F	2,6795	Aeronave C	0,6905
3°	Aeronave A	0,1911	Aeronave A	2,6388	Aeronave A	0,6237
4°	Aeronave H	0,1726	Aeronave H	2,5196	Aeronave H	0,6197
5°	Aeronave K	0,1713	Aeronave K	2,4643	Aeronave K	0,5694
6°	Aeronave J	0,1197	Aeronave J	2,4339	Aeronave G	0,5606
7°	Aeronave G	0,0991	Aeronave G	2,3763	Aeronave J	0,5364
8°	Aeronave I	0,0424	Aeronave I	2,3684	Aeronave I	0,5099
9°	Aeronave L	-0,0345	Aeronave L	2,0568	Aeronave L	0,4913
10°	Aeronave B	-0,0477	Aeronave B	2,0769	Aeronave B	0,4291
11°	Aeronave M	-0,0764	Aeronave M	1,8929	Aeronave M	0,4023
12°	Aeronave N	-0,1369	Aeronave N	1,8263	Aeronave N	0,3864
13°	Aeronave D	-0,1571	Aeronave D	1,5136	Aeronave D	0,3814
14°	Aeronave E	-0,1722	Aeronave E	1,4721	Aeronave E	0,3143
15°	Aeronave O	-0,2434	Aeronave O	1,3576	Aeronave O	0,2987

Fonte: Próprio autor.

A correlação de Spearman (1961), um teste estatístico não paramétrico utilizado para medir a força e a direção da associação entre dois rankings, revelou os seguintes resultados: entre o método MADRID e o método COCOSO, um valor de 0,967 e entre o método MADRID e o método TOPSIS foi de 0,975.

De acordo com a explicação de Mukaka (2012), uma correlação positiva sólida é evidenciada por valores de correlação de Spearman maiores que 0,9, enquanto valores entre 0,7 e 0,9 sugerem uma alta correlação.

Portanto, a análise de sensibilidade realizada com base na correlação de Spearman revelou uma elevada correlação entre o método MADRID e os métodos COCOSO e TOPSIS, ambos amplamente consagrados no campo do Apoio Multicritério à Decisão. Esse resultado evidencia a robustez do MADRID, destacando-o como uma ferramenta prática, precisa e eficaz para apoiar processos de tomada de decisão multicritério.

Ressalta-se que o software MADRID foi escrito na linguagem Python e, durante sua execução, limitou-se o tamanho do dataset em até 1.000 alternativas, inclusive. Quanto ao número de clusters, em um dataset com “n” alternativas, o código calcula o coeficiente de silhueta médio para um número de cluster de 2 até “n”. Ou seja, calcula-se o valor do coeficiente de silhueta médio quando os dados são aglomerados em 2 cluster, 3 cluster, até “n” clusters. Aquele número de cluster que foi identificado com o maior valor de coeficiente de silhueta médio será definido como o número de cluster daquele conjunto de dados a ser

aglomerado.

Assim como no MABAC, a pontuação final das alternativas no método MADRID varia de -1 a 1, pois utiliza a mesma padronização presente na metodologia do MABAC. Esse processo padroniza o desempenho das alternativas, atribuindo valores positivos para aquelas que excedem a referência (área superior) e valores negativos para as que ficam abaixo da referência (área inferior).

5 ESTUDO DE CASO

O uso de Veículos Aéreos Não Transportados (VANTs) militares no campo de batalha tornou-se essencial nas linhas de frente modernas. Essa tecnologia é empregada nos níveis estratégico, operacional e tático em todos os ramos das Forças Armadas. Eles oferecem flexibilidade e adaptabilidade para uma ampla gama de aplicações militares, que ultrapassaram suas responsabilidades originais de reconhecimento. Novos papéis são atribuídos a essa tecnologia, combinando sistemas sofisticados de navegação e comunicação, permitindo que atuem em um amplo espectro de aplicações militares (CRIOLLO; MENA-ARCINIEGA; XING, 2024).

Além disso, a versatilidade desses veículos aéreos permite que elas sejam utilizadas não apenas em missões de combate, mas também no fornecimento de assistência logística, gerenciamento de riscos, operações psicológicas e fotografia avançada, contribuindo para o suporte às operações militares em terra (PATEL; SALOT; PARIKH, 2022).

O Plano Estratégico da Marinha (PEM 2040) (2021) apresenta a construção do Núcleo do Poder Naval, cujo objetivo é substituir meios navais, aeronavais e de fuzileiros navais que já ultrapassaram ou estão próximos de ultrapassar sua vida útil. Entre as iniciativas destacadas, está a Força Naval 6, que visa obter aeronaves para compor o Poder Naval (PROAERO), incluindo a obtenção de aeronaves não tripuladas. Diante disso, faz-se mister a utilização de ferramentas eficientes que apoiem a tomada de decisão da alta administração naval no que tange a aquisição de novos meios para a força.

Nesse contexto, a pesquisa em questão se dedica na seleção das melhores aeronaves não tripuladas para a Marinha do Brasil que atendam ao emprego em missões específicas de apoio e combate, bem como vigilância e reconhecimento. Para gerar a ordenação das alternativas, foi desenvolvido e aplicado o método MADRID, que combina a clusterização hierárquica single linkage, uma técnica de aprendizado de máquina não supervisionado, com os métodos MABAC e DIBR.

5.1 SOLUÇÃO DO PROBLEMA

Para este estudo de caso, foram consultados três decisores/especialistas em veículos aéros não tripulados, os quais avaliaram as alternativas com base nos critérios estabelecidos. Para fins didáticos, os decisores serão identificados como Decisor 1, Decisor 2 e Decisor 3.

Para compor o conjunto de alternativas, foram selecionados seis modelos de VANTs fabricados pela empresa General Atomics: Gray Eagle ER, Gray Eagle STOL, Mojave, Predator C Avenger, Sea Guardian e MQ-9 Reaper. As alternativas foram avaliadas à luz

dos seguintes critérios, estabelecidos pelos próprios decisores (Tabela 5).

Tabela 5 – Relacionamento e escala.

Critério	Definição
Custo (US\$ Mi)	C1 Custo estimado de aquisição da aeronave remotamente pilotada.
Capacidade de carga útil (lb)	C2 Peso máximo de carga que a aeronave pode transportar.
Velocidade máxima de voo (nós)	C3 Velocidade máxima alcançável pela aeronave em voo.
Capacidade de Transporte de Missil Hellfire (unidade)	C4 Quantidade de mísseis Hellfire que a aeronave pode transportar.
Altitude máxima (pés)	C5 Altitude máxima que a aeronave pode atingir.
Autonomia de voo (horas)	C6 Tempo máximo que a aeronave pode permanecer em operação contínua.
Peso máximo de decolagem (lb)	C7 Peso máximo permitido para a aeronave na decolagem.

Fonte: Próprio autor.

O critério custo foi considerado monotônico de custo ou prejuízo, pois busca-se a minimização desse parâmetro.

Foi realizada pesquisa de literatura para obtenção dos dados operativos e custo estimado VANTs. Os dados operativos foram obtidos da página oficial da empresa General Atomics (GRAY EAGLE ER, 2025; GRAY EAGLE STOL, 2025; MOJAVE, 2025; MQ9-REAPER, 2025; PREDATOR C AVENGER, 2025; SEA GUARDIAN, 2025), enquanto os custos estimados foram obtidos em (ARMY UNIVERSITY PRESS, 2018; POPULAR MECHANICS, 2023; REVISTA FORÇA AÉREA, 2022). A Tabela 6 apresenta as alternativas e seus respectivos critérios utilizados na análise.

Tabela 6 – Dados das alternativas.

Aeronaves	C1	C2	C3	C4	C5	C6	C7
Predator C Avenger	20	6500	400	4	50000	20	18200
Gray Eagle ER	20	500	167	4	29000	42	4200
Sea Guardian	133	800	210	8	40000	30	12500
Gray Eagle STOL	20	3400	140	16	25000	25	7000
Mojave	32	3400	140	16	25000	25	7000
MQ-9 Reaper	32	3850	240	4	50000	27	10500

Fonte: Próprio autor.

5.2 CÁLCULO DOS PESOS DOS CRITÉRIOS

Os pesos dos critérios foram obtidos após aplicação do método DIBR, levando em consideração os pontos de vista dos três especialistas da área. A ordem de significância entre os critérios adjacentes foi estabelecida conforme a tabela 7 e os pesos gerados são apresentados na tabela 8:

Tabela 7 – Ordem de significância entre os critérios adjacentes.

C6 > C4 > C3 > C1 > C2 > C7 > C5					
C6 > C4	C4 > C3	C3 > C1	C1 > C2	C2 > C7	C7 > C5
65%	55%	72%	58%	64%	52%

Fonte: Próprio autor.

Tabela 8 – Peso dos critérios.


C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇
0,0711	0,0515	0,1829	0,2235	0,0267	0,4151	0,0289

Fonte: Próprio autor.

5.3 APLICAÇÃO DA TÉCNICA DE CLUSTERIZAÇÃO HIERÁRQUICA SINGLE LINKAGE

O gráfico de silhueta apontou o número de 2 clusters formados como a melhor configuração, indicando que essa divisão apresenta o maior coeficiente de silhueta médio.

Figura 20 – Gráfico de silhueta.



Fonte: Próprio autor.

Tabela 9 – Matriz de centróides dos clusters.

	C1	C2	C3	C4	C5	C6	C7
Cluster 1	24	2433	149	<u>12</u>	26333	<u>30</u>	6066
Cluster 2	61	3716	<u>283</u>	5	<u>46666</u>	25	13733

Fonte: Próprio autor.

Os especialistas estabeleceram os principais critérios para uma aeronave remotamente pilotada cumprir missões específicas, sendo os critérios de autonomia de voo e Capacidade de Transporte de Míssil Hellfire par as missões de apoio e combate e os

critérios de velocidade máxima de voo e altitude máxima para as missões de vigilância e reconhecimento.

Analisando os dados dos centróides, pode-se concluir que o cluster 1 é mais indicado para cumprir missões de apoio e combate por ter obtido valores maiores nos principais critérios para esta missão e o cluster 2 mais indicado para cumprir as missões de vigilância e reconhecimento por também ter obtido valores maiores em ambos os principais critérios desta missão.

5.4 ORDENAÇÃO GLOBAL E CLASSIFICAÇÃO DAS ALTERNATIVAS

A ordenação final obtida pelos valores dos centróides, das alternativas pertencentes aos clusters 1 e 2, assim como a do método MADRID foram calculadas conforme apresentado nas Tabelas 10, 11 e 12, respectivamente.

Tabela 10 – Ordenação dos clusters pelos valores dos centróides.

Posição	Cluster	Pontuação
1°	Cluster 1	0,2956
2°	Cluster 2	-0,1241

Tabela 11 – Ordenação das alternativas de cada cluster.

Cluster 1			Cluster 2		
Posição	VANT	Pontuação	Posição	VANT	Pontuação
1°	Gray Eagle ER	0,3132	1°	Sea Guard.	0,2307
2°	Gray Eagle STOL	-0,0076	2°	MQ-9 Reaper	0,0218
3°	Mojave	-0,0787	3°	Predator C Av	-0,0543

Tabela 12 – Ordenação global do método MADRID.

Posição	VANT	Pontuação
1°	Gray Eagle ER	0,1954
2°	Sea Guardian	0,0720
3°	Gray Eagle STOL	-0,0126
4°	Mojave	-0,0202

5.5 ANÁLISE DOS RESULTADOS

Pode-se concluir que a melhor alternativa a ser escolhida para cumprir a missão de apoio e combate para a MB é a aeronave remotamente pilotada “Gray Eagle ER” por ser a mais bem avaliada do cluster 1 com pontuação de 0,3132, bem distante da segunda posição que foi o “Mojave” com pontuação de -0,0076. Ademais, a melhor alternativa a ser escolhida para cumprir a missão de vigilância e reconhecimento para a MB é a aeronave remotamente pilotada “Predator B” por ser a mais bem avaliada do cluster 2 com uma pontuação de 0,2307, bem afastada da segunda posição a aeronave “MQ-9 Reaper” com pontuação de 0,0218. Ressalta-se que no ranqueamento global do MADRID, a aeronave “Gray Eagle ER” foi a mais bem classificada com pontuação de 0,1954.

Tabela 13 – Ordenação dos clusters e pesos gerados no cenário 1.

Cluster 1			Cluster 2		
Posição	VANT	Pontuação	Posição	VANT	Pontuação
1°	Gray Eagle ER	0,2207	1°	Sea Guard.	0,3248
2°	Gray Eagle STOL	0,0528	2°	MQ-9 Reaper	0,0300
3°	Mojave	-0,0451	3°	Predator C Av	-0,1537

$$C6 > C4 > C1 > C3 > C7 > C2 > C5$$

C6 > C4	C4 > C1	C1 > C3	C3 > C7	C7 > C2	C2 > C5
60%	75%	58%	65%	52%	60%

C1	C2	C3	C4	C5	C6	C7
0,0979	0,0352	0,0708	0,2937	0,0234	0,4405	0,0381

Tabela 14 – Ordenação dos clusters e pesos gerados no cenário 2.

Cluster 1			Cluster 2		
Posição	VANT	Pontuação	Posição	VANT	Pontuação
1°	Gray Eagle ER	0,1170	1°	Sea Guardian	0,2882
2°	Gray Eagle STOL	0,0869	2°	MQ-9 Reaper	0,0426
3°	Mojave	0,0254	3°	Predator C Av	-0,1288

C6 > C4 > C2 > C5 > C1 > C3 > C7					
C6 > C4	C4 > C2	C2 > C5	C5 > C1	C1 > C3	C3 > C7
55%	72%	65%	52%	68%	70%

C1	C2	C3	C4	C5	C6	C7
0,0614	0,1237	0,0289	0,3180	0,0660	0,3887	0,0124

De acordo com Demir et al. (2024), o Coeficiente de Correlação de Spearman é utilizado para medir com precisão a relação entre os ranqueamentos obtidos com pesos variados. Dessa forma, para realizar a análise de sensibilidade, neste estudo optou-se pela comparação entre os ranqueamentos gerados por meio da variação dos pesos dos critérios e, para isso, foram criados dois cenários onde foram variados os pesos conforme apresentados nas tabelas 13 e 14.

As ordenações das alternativas em cada cluster nos dois cenários apresentados nas tabelas 13 e 14 foram idênticas à ordenação das alternativas dos clusters do estudo de caso apresentado na tabela 11. Dessa forma, esse resultado comprova a robustez do método com a pontuação máxima na correlação de spearman, consolidando-o como uma ferramenta eficaz para a análise multicritério.

Em face ao exposto, o objetivo deste artigo foi alcançado, com a escolha dos dois veículos aéreos não tripulados a serem adquiridos pela Marinha do Brasil, sendo o Gray Eagle ER para cumprir missões de apoio e combate, e Sea Guardian, para cumprir missões de vigilância e reconhecimento.

Ressalta-se que o Gray Eagle ER obteve a maior pontuação na ordenação global do método MADRID com uma pontuação bem acima das demais alternativas. Esse resultado não apenas reforça sua superioridade operacional, mas também ressalta a relevância da abordagem adotada pelo MADRID para problemas de alta dimensionalidade. Ao reduzir o problema à matriz de decisão final, o método promoveu uma simplificação substancial, sem comprometer a integridade das informações mais relevantes. Essa redução de dimensão

foi essencial para estruturar o problema de forma lógica e otimizada, permitindo uma análise mais clara e direcionada. Ademais, a aplicação do método da silhueta apontou para a formação do número ótimo de dois clusters, garantindo que as alternativas fossem agrupadas com a melhor configuração possível, maximizando a similaridade interna e a dissimilaridade entre clusters.

A análise de sensibilidade realizada neste estudo comprovou a robustez e a confiabilidade do método MADRID ao avaliar a estabilidade dos ranqueamentos obtidos frente às variações nos pesos dos critérios. Por meio da criação de dois cenários, foi possível observar que as ordenações das alternativas permaneceram consistentes, independentemente das mudanças nas ponderações. Essa resiliência nos resultados, corroborada pela correlação máxima pelo coeficiente de Spearman, evidencia a capacidade de manter sua eficácia e coerência em diferentes contextos decisórios. Essa característica reforça a aplicabilidade do MADRID como uma ferramenta eficaz e confiável para o apoio à tomada de decisão.

Dessa forma, o MADRID se apresenta como um método robusto e eficaz para solucionar os mais diversos problemas referentes ao apoio à tomada de decisão, oferecendo resultados alinhados às necessidades estratégicas da MB. Recomenda-se que o método seja aplicado as demais áreas do conhecimento.

6 CONCLUSÃO

A presente dissertação teve como objetivo desenvolver uma nova metodologia de apoio à tomada de decisão, denominada MADRID, que combina técnicas de clusterização hierárquica aglomerativa single linkage com métodos AMD.

Inicialmente, foram analisados alguns documentos os quais abordam sobre o cenário de demandas do país como a Política e Estratégia Nacional de Defesa, o Livro Branco de Defesa Nacional e o Plano Estratégico da Marinha (PEM-2040). Dentre as diretrizes apresentadas nestes documentos, identificou-se a Estratégia Naval 6.2, definida pelo PEM 2040, a qual apresenta a Construção do Núcleo do Poder Naval, cujo objetivo é substituir meios navais, aeronavais e de fuzileiros navais que ultrapassaram ou estão próximos de ultrapassar sua vida útil, através das Forças Navais, o que evidenciou a necessidade de desenvolver ferramentas específicas para atender às demandas estratégicas da força no tocante à aquisição de produtos de defesa.

Antes do desenvolvimento do método MADRID, foi realizada uma revisão sistemática da literatura com o propósito de identificar métodos que combinassem AMD e técnicas de clusterização, visando explorar potenciais áreas de aprimoramento no processo de tomada de decisão. A pesquisa resultou na seleção de 25 artigos científicos, que serviram como base teórica e referência para o desenvolvimento do método MADRID, oferecendo uma compreensão aprofundada das abordagens existentes e das lacunas a serem exploradas na literatura.

Foi realizado um estudo de caso por meio da aplicação do método MADRID para escolha dos melhores veículos aéreos não tripulados a serem adquiridos pela Marinha do Brasil para cumprir missões de apoio e combate/vigilância e reconhecimento. Nesse estudo, foram analisadas seis alternativas à luz de sete critérios. O resultado apontou a escolha dos dois veículos aéreos não tripulados a serem adquiridos pela Marinha do Brasil, sendo o Gray Eagle ER para cumprir missões de apoio e combate, e Sea Guardian, para cumprir missões de vigilância e reconhecimento. Ressalta-se que o Gray Eagle ER obteve a maior pontuação na ordenação global do método MADRID com uma pontuação bem acima das demais alternativas. Esse resultado não apenas reforça sua superioridade operacional, mas também ressalta a relevância da abordagem adotada pelo MADRID para problemas de alta dimensionalidade. Ao reduzir o problema à matriz de decisão final, o método promoveu uma simplificação substancial, sem comprometer a integridade das informações mais relevantes. Essa redução de dimensão foi essencial para estruturar o problema de forma lógica e otimizada, permitindo uma análise mais clara e direcionada. Ademais, a aplicação do método da silhueta apontou para a formação do número ótimo de dois clusters, garantindo que as alternativas fossem agrupadas com a melhor configuração

possível, maximizando a similaridade interna e a dissimilaridade entre clusters. A análise de sensibilidade realizada neste estudo comprovou a robustez e a confiabilidade do método MADRID ao avaliar a estabilidade dos ranqueamentos obtidos frente às variações nos pesos dos critérios. Por meio da criação de dois cenários, foi possível observar que as ordenações das alternativas permaneceram consistentes, independentemente das mudanças nas ponderações.

O método MADRID destaca-se dos demais métodos revisados na literatura por oferecer uma integração única entre a clusterização hierárquica e a modelagem multicritério, com ênfase no apoio à identificação de critérios relevantes no cenário de aplicação. Diferente de abordagens tradicionais, que muitas vezes apenas agregam alternativas ou fornecem um ranqueamento global, o MADRID possibilita uma análise em múltiplos níveis: primeiro ao agrupar alternativas em clusters homogêneos com base em suas similaridades, e depois ao aplicar o DIBR-MABAC para ranquear tanto os grupos quanto as alternativas internas a cada cluster. Essa estrutura metodológica permite evidenciar quais critérios exercem maior influência sobre o agrupamento e sobre a classificação final, apoiando o decisor na identificação dos atributos mais críticos para o problema em análise.

Por fim, o objetivo desta pesquisa foi alcançado por meio da implementação de uma nova metodologia de suporte à tomada de decisão proporcionando não somente um ranqueamento global da melhor alternativa do conjunto de dados, como também o apoio à tomada de decisão visando a missão em que aquela determinada alternativa será empregada. Os resultados foram testados apresentando uma alta correlação do MADRID com outros métodos já consagrados na literatura. Dessa forma, o MADRID se apresenta como uma ferramenta robusta e eficaz para servir como um apoio à tomada de decisão não somente para aquisição de produtos de defesa, como também para as demais áreas da ciência.

6.1 Proposta para trabalhos futuros

Para trabalhos futuros, sugere-se a integração do método MADRID com os Pontos de Vista Fundamentais (PVF) no ciclo de vida de navios, dentro do escopo da Engenharia de Sistemas, permitindo estruturar decisões desde a concepção até o descarte. A clusterização pode identificar padrões entre embarcações similares, enquanto o ranqueamento multicritério ajusta a priorização de alternativas conforme as necessidades operacionais de cada fase.

Essa abordagem possibilita a adaptação dinâmica dos pesos dos critérios, considerando que, durante o projeto e aquisição, aspectos técnicos e financeiros são mais relevantes, enquanto na operação e manutenção, a confiabilidade e os custos logísticos ganham prioridade. Dessa forma, sua aplicação nesse contexto pode otimizar a tomada de

decisão, reduzir custos e aumentar a eficiência operacional das embarcações ao longo do tempo, consolidando-se como uma solução robusta dentro da Engenharia de Sistemas.

REFERÊNCIAS

- 1 ABRAMO, G.; D'ANGELO, C. A. Evaluating research: from informed peer review to bibliometrics. *Scientometrics*, v. 87, n. 3, p. 499–514, 2011.
- 2 ADESA, R.; PELLANDAA, P. C.; BORGES JUNIOR, I. Engenharia de Defesa: O mais novo programa de pós-graduação do Instituto Militar de Engenharia. *Ciência e Tecnologia*, v. XXVII, p. 94, 2010.
- 3 AKAY, A. O. et al. Spatial assessment of sediment risk with integrated entropy-based WASPAS and fuzzy clustering methods in Turkey: impact of forestry activities and meteorological factors. *Environmental Monitoring and Assessment*, v. 195, n. 10, 2023.
- 4 ANAND, M. C. J. et al. Fuzzy C-Means Clustering with MAIRCA-MCDM Method in Classifying Feasible Logistic Suppliers of Electrical Products. In: *2023 First International Conference on Cyber Physical Systems, Power Electronics and Electric Vehicles (ICPEEV)*. IEEE, 2023.
- 5 AZADNIA, A. H. et al. Integration model of Fuzzy C means clustering algorithm and TOPSIS method for customer lifetime value assessment. In: *IEEE International Conference on Industrial Engineering and Engineering Management*. Department of Manufacturing and Industrial Engineering, Universiti Teknologi Malaysia, Skudai, Malaysia, 2011. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84856534778&doi=10.1109%2FIEEM.2011.6117870>>.
- 6 AZADNIA, A. H. et al. Supplier selection: A hybrid approach using ELECTRE and fuzzy clustering. In: *Communications in Computer and Information Science*. Department of Manufacturing and Industrial Engineering, Universiti Teknologi Malaysia, Skudai, Malaysia, 2011. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-82955184443&doi=10.1007%2F978-3-642-25453-6_56>.
- 7 BAKSHI, K.; BAKSHI, K. Considerations for artificial intelligence and machine learning: Approaches and use cases. In: *2018 IEEE Aerospace Conference*. IEEE, 2018.
- 8 BELFIORE, P.; FÁVERO, L. P. *Pesquisa operacional para cursos de engenharia*. [s.l.]: Elsevier Brasil, 2013. v. 1.
- 9 BELTON, V.; STEWART, T. *Multiple criteria decision analysis: an integrated approach*. [s.l.]: Springer Science Business Media, 2002.
- 10 CARDOSO, R. S. et al. Uso de SAD no apoio à decisão na destinação de resíduos plásticos e gestão de materiais. *Pesquisa Operacional*, v. 29, n. 1, p. 67–95, 2009.

- 11 CARRERA-RIVERA, A. et al. How-to conduct a systematic literature review: A quick guide for computer science research. *MethodsX*, v. 9, p. 101895, 2022.
- 12 CHEN, L. et al. An ordered clustering algorithm based on K-means and the PROMETHEE method. *International Journal of Machine Learning and Cybernetics*, v. 9, n. 6, p. 917–926, 2018.
- 13 CHEN, N. et al. Regional disaster risk assessment of China based on self-organizing map: Clustering, visualization and ranking. *International Journal of Disaster Risk Reduction*, v. 33, p. 196–206, 2019.
- 14 CORRIÇA, J. V. DE P. et al. Seleção de uma aeronave não tripulada para a Marinha do Brasil: uma abordagem por meio da integração do Aprendizado de Máquina com o Apoio Multicritério à Decisão. 2024. Disponível em: <https://proceedings.science/proceedings/100475/_papers/193373>.
- 15 CROFT, R.; XIE, Y.; BABAR, M. A. Data preparation for software vulnerability prediction: A systematic literature review. *IEEE Transactions on Software Engineering*, v. 49, n. 3, p. 1044–1063, 2022.
- 16 DAHOOL, J. H. et al. A new evaluation model for corporate financial performance using integrated CCSD and FCM-ARAS approach. *Economic Research-Ekonomska Istraživanja*, v. 32, n. 1, p. 1088–1113, 2019.
- 17 DAHOOIE, J. H. et al. A new evaluation model for corporate financial performance using integrated CCSD and FCM-ARAS approach. *Economic Research-Ekonomska Istraživanja*, v. 32, n. 1, p. 1088–1113, 2019.
- 18 DE ARAÚJO COSTA, I. P. et al. Desenvolvimento Axiomático e Implementação Computacional do Método Híbrido ELECTRE-MOR: Escolha de Avião-Hospital no Apoio ao Combate à COVID-19. 2020.
- 19 DE OLIVEIRA, M. S. et al. Integrated data envelopment analysis, multi-criteria decision making, and cluster analysis methods: Trends and perspectives. *Decision Analytics Journal*, v. 8, p. 100271, 2023.
- 20 DE PINA CORRIÇA, J. V. et al. Modelagem Matemática Híbrida DIBR-MABAC para ordenação de viaturas blindadas anfíbias para a Marinha do Brasil. 2023.
- 21 DE SMET, Y. P2CLUST: An extension of PROMETHEE II for multicriteria ordered clustering. 2013 IEEE International Conference on Industrial Engineering and Engineering Management. IEEE, 2013.
- 22 DEFESA, B. M. DA. Política Nacional de Defesa: Estratégia Nacional de Defesa. [s.l.] Ministério da Defesa, 2012.

- 23 DEFESA, B. M. DA. Livro Branco de Defesa Nacional. [s.l.: s.n.].
- 24 DEMIR, G.; CHATTERJEE, P.; PAMUCAR, D. Sensitivity analysis in multi-criteria decision making: A state-of-the-art research perspective using bibliometric analysis. *Expert Systems with Applications*, v. 237, p. 121660, 2024.
- 25 DING, S. et al. Assessment of road safety performance based on CRITIC-TOPSIS-Kmeans model. In: Y. X.; K. X. (Eds.). *Proceedings of SPIE - The International Society for Optical Engineering*. Shenzhen College of International Education, Guangdong, Shenzhen
- 26 DOS SANTOS, M.; DA COSTA MARTHA, L.; DOS REIS, M. F. Utilização do algoritmo Branch and Bound na otimização da produção de uma indústria de produtos plásticos. *Revista de Trabalhos Acadêmicos Lusófona*, v. 2, n. 2, p. 217–237, 2019.
- 27 DOS SANTOS, Marcos et al. Simulation of operation of an integrated information for emergency pre-hospital care in Rio de Janeiro municipality. *Procedia Computer Science*, v. 55, p. 931-938, 2015.
- 28 FÁVERO, L. P.; BELFIORE, P. *Manual de análise de dados: estatística e modelagem multivariada com Excel®, SPSS® e Stata®*. [s.l.]: Elsevier Brasil, 2017.
- 29 FIGUEIRA, J.; GRECO, S.; EHRGOTT, M. Multiple criteria decision analysis: state of the art surveys. 2005.
- 30 GOMES, L.; GOMES, C. F. S. Princípios e métodos para a tomada de decisão: Enfoque multicritério. São Paulo: Atlas, 2019.
- 31 GOVINDAN, K.; JEPSEN, M. B. ELECTRE: A comprehensive literature review on methodologies and applications. *European Journal of Operational Research*, v. 250, n. 1, p. 1–29, 2016.
- 32 GRECO, S.; FIGUEIRA, J.; EHRGOTT, M. Multiple criteria decision analysis. [s.l.] Springer, 2016a. v. 37.
- 33 GRECO, S.; FIGUEIRA, J.; EHRGOTT, M. Multiple Criteria Decision Analysis: State of art surveys. [s.l.] Springer, 2016b. v. 37.
- 34 GÜÇDEMİR, H.; SELİM, H. Integrating multi-criteria decision making and clustering for business customer segmentation. *Industrial Management and Data Systems*, v. 115, n. 6, p. 1022–1040, 2015.
- 35 GUHATHAKURATA, S. et al. South Asian Countries are Less Fatal Concerning COVID-19: A Fact-finding Procedure Integrating Machine Learning Multiple Criteria Decision-Making (MCDM) Technique. *Journal of The Institution of Engineers (India): Series B*, v. 102, n. 6, p. 1249–1263, 2021.

- 36 GÜLER, E.; AVCI, S.; ALADAĞ, Z. Earthquake risk prioritization via two-step cluster analysis and SWARA-ELECTRE methods. *Sigma Journal of Engineering and Natural Sciences*, v. 41, n. 2, p. 356–372, 2023.
- 37 HASSANALIAN, M.; ABDELKEFI, A. Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*, v. 91, p. 99–131, 2017.
- 38 HILLERMAN, T. et al. Applying clustering and AHP methods for evaluating suspect healthcare claims. *Journal of Computational Science*, v. 19, p. 97–111, 2017.
- 39 HOAN, P.; HA, Y. ARAS-FUCOM approach for VPAF fighter aircraft selection. *Decision Science Letters*, v. 10, n. 1, p. 53–62, 2021.
- 40 HWANG, C.-L. et al. Methods for multiple attribute decision making. Multiple attribute decision making: methods and applications a state-of-the-art survey, p. 58–191, 1981.
- 41 ISHIZAKA, A.; LOKMAN, B.; TASIOU, M. A Stochastic Multi-criteria divisive hierarchical clustering algorithm. *Omega (United Kingdom)*, v. 103, 2021.
- 42 JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. *ACM Computing Surveys (CSUR)*, v. 31, n. 3, p. 264–323, 1999.
- 43 JOE ANAND, M. C. et al. Fuzzy C-Means Clustering with MAIRCA-MCDM Method in Classifying Feasible Logistic Suppliers of Electrical Products. *Proceedings of the 2023 1st International Conference on Cyber Physical Systems, Power Electronics and Electric Vehicles, ICPEEV 2023*. Mount Carmel College (Autonomous), Department of Mathematics, Karnataka, India: Institute of Electrical and Electronics Engineers Inc., 2023. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85184656953&doi=10.1109%2FICPEEV58650.2023.10391835&partnerID=40&md5=055ea2a031cde7dbfb5f422070a9b4e3>>.
- 44 JOHNSON, R. A.; WICHERN, D. W. *Applied multivariate statistical analysis*. 2002.
- 45 KESKIN, G. A. Using integrated fuzzy DEMATEL and fuzzy C-Means algorithm for supplier evaluation and selection. *International Journal of Production Research*, v. 53, n. 12, p. 3586–3602, 2015.
- 46 KITCHENHAM, B. Procedures for performing systematic reviews. *Keele, UK, Keele University*, v. 33, n. 2004, p. 1–26, 2004.
- 47 LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015.

- 48 LI, X. et al. Zoning technology for the management of ecological and clean small-watersheds via k-means clustering and entropy-weighted TOPSIS: A case study in Beijing. *Journal of Cleaner Production*, v. 397, p. 136449, 2023.
- 49 LIU, P.; LI, Y. An improved failure mode and effect analysis method for multi-criteria group decision-making in green logistics risk assessment. *Reliability Engineering and System Safety*, v. 215, 2021.
- 50 LÓPEZ-ORTEGA, O.; ROSALES, M.-A. An agent-oriented decision support system combining fuzzy clustering and the AHP. *Expert Systems with Applications*, v. 38, n. 7, p. 8275–8284, 2011.
- 51 MADHULATHA, T. S. An overview on clustering methods. *arXiv preprint arXiv:1205.1117*, 2012.
- 52 MAGHSOODI, A. I. et al. CLUS-MCDA: A novel framework based on cluster analysis and multiple criteria decision theory in a supplier selection problem. *Computers Industrial Engineering*, v. 118, p. 409–422, 2018.
- 53 MAHDIRAJI, H. A. et al. Marketing strategies evaluation based on big data analysis: a CLUSTERING-MCDM approach. *Economic Research-Ekonomska Istrazivanja*, v. 32, n. 1, p. 2882–2898, 2019.
- 54 MUKAKA, M. M. A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, v. 24, n. 3, p. 69–71, 2012.
- 55 MURTAGH, F.; CONTRERAS, P. Algorithms for hierarchical clustering: an overview, II. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, v. 7, n. 6, p. e1219, 2017.
- 56 NAGY, G. State of the art in pattern recognition. *Proceedings of the IEEE*, v. 56, n. 5, p. 836–863, 1968.
- 57 NILASHI, M. et al. Using DEMATEL, clustering, and fuzzy logic for supply chain evaluation of electric vehicles: A SCOR model. *AIMS Environmental Science*, v. 11, n. 2, p. 129–156, 2024.
- 58 PAMUCAR, D. et al. Circular economy concepts in urban mobility alternatives using integrated DIBR method and fuzzy Dombi CoCoSo model. *Journal of Cleaner Production*, v. 323, p. 129096, 2021.
- 59 PAMUČAR, D.; ČIROVIĆ, G. The selection of transport and handling resources in logistics centers using Multi-Attributive Border Approximation area Comparison (MABAC). *Expert Systems with Applications*, v. 42, n. 6, p. 3016–3028, 2015.

- 60 RANGEL, Luís Alberto Duncan; GOMES, Luiz Flávio Autran Monteiro. O Apoio Multicritério à Decisão na avaliação de candidatos. *Production*, v. 20, p. 92-101, 2010.
- 61 RODRIGUES, M. S. Plano Estratégico da Marinha PEM 2040. *Revista da EGN*, v. 27, n. 1, p. 13-30, 2021.
- 62 ROSENFELD, J.; DE SMET, Y. An extension of PROMETHEE to hierarchical multicriteria clustering. *International Journal of Multicriteria Decision Making*, v. 8, n. 2, p. 133-150, 2019.
- 63 ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, v. 20, p. 53-65, 1987.
- 64 SÁNCHEZ-LOZANO, J. M.; RODRÍGUEZ, O. N. Application of Fuzzy Reference Ideal Method (FRIM) to the military advanced training aircraft selection. *Applied Soft Computing Journal*, v. 88, 2020.
- 65 SOUZA, E. F. DE. Comparação e escolha de agrupamentos: uma proposta utilizando a entropia. Universidade de São Paulo, 2007.
- 66 SPEARMAN, C. The proof and measurement of association between two things. 1961.
- 67 SWINDIARTO, V. T. P.; SARNO, R.; NOVITASARI, D. C. R. Integration of Fuzzy C-Means Clustering and TOPSIS (FCM-TOPSIS) with Silhouette Analysis for Multi Criteria Parameter Data. *Proceedings - 2018 International Seminar on Application for Technology of Information and Communication: Creative Technology for Human Life, iSemantic 2018*. Department of Information, Technology Management Institut Teknologi, Sepuluh Nopember Surabaya, Indonesia: Institute of Electrical and Electronics Engineers Inc., 2018. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85060026179&doi=10.1109%2FISEMANTIC.2018.8549844&partnerID=40&md5=39cd07f1dbbc68271d4f1a01e463132a>>.
- 68 TEIXEIRA, L. F. H. DE S. de Barros; SANTOS, Marcos dos; GOMES, Carlos Francisco Simões. Proposta e implementação em python do método Simple Aggregation of Preferences Expressed by Ordinal Vectors-Multi Decision Makers: uma ferramenta web simples e intuitiva para Apoio à Decisão. *SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA*, v. 19, 2019.
- 69 TEŠIĆ, D. et al. Modification of the DIBR and MABAC methods by applying rough numbers and its application in making decisions. *Information*, v. 13, n. 8, p. 353, 2022.
- 70 TROJAN, F. et al. Class Thresholds Pre-Definition by Clustering Techniques for Applications of ELECTRE TRI Method. *Energies*, v. 16, n. 4, 2023.

-
- 71 TYUGU, E. Artificial intelligence in cyber defense. 2011 3rd International Conference on Cyber Conflict. IEEE, 2011.
- 72 WANG, Y.-J. Applying FMCDM to evaluate financial performance of domestic airlines in Taiwan. *Expert Systems with Applications*, v. 34, n. 3, p. 1837–1845, 2008.
- 73 WU, Y. et al. Z-number extension of TODIM-CPT method combined with K-means clustering for electric vehicle battery swapping station site selection. *Journal of Energy Storage*, v. 85, 2024.
- 74 YAZDANI, M. et al. A combined compromise solution (CoCoSo) method for multi-criteria decision-making problems. *Management Decision*, v. 57, n. 9, p. 2501–2519, 2019.

APÊNDICE A – CONTRIBUIÇÕES PARA A PESQUISA

- Desenvolvimento de ferramenta computacional online em *shiny* do método MADRID;
- Publicação do artigo "*Modelagem Matemática Híbrida DIBR-MABAC para ordenação de viaturas blindadas anfíbias para a Marinha do Brasil*", no 55º Simpósio Brasileiro de Pesquisa Operacional (SBPO) 2023; e
- Publicação do artigo "*Seleção de uma aeronave não tripulada para a Marinha do Brasil: uma abordagem por meio da integração do Aprendizado de Máquina com o Apoio Multicritério à Decisão*", no 56º Simpósio Brasileiro de Pesquisa Operacional (SBPO) 2024.