

SAPEVO-PC: Integrando Apoio à Decisão Multicritério e Aprendizado de Máquina para Avaliar Navios de Guerra

Igor Pinheiro de Araújo de Araújo Costa^{1,2*}, Raphael Gonzaga Duarte³, Gabriel Capela², Victor Benicio Ardilha da Silva Alves¹, Guilherme da Silva¹, Carlos Francisco Simões Gomes², Marcos dos Santos^{2,4}

¹ Centro de Análises de Sistemas Navais (CASNAV)

² Universidade Federal Fluminense (UFF)

³ Universidade de São Paulo (USP)

⁴ Instituto Militar de Engenharia (IME)

*E-mail: costa_igor@id.uff.br

RESUMO

Este estudo apresenta o método *SAPEVO-PC*, uma evolução da família *SAPEVO* que integra um método de apoio à decisão multicritério e o aprendizado de máquina para apoiar a seleção de navios da Marinha, um processo crítico na garantia da soberania nacional. O *SAPEVO-PC* permite a inclusão de preferências qualitativas juntamente com dados quantitativos, incorporando conceitos da análise de componentes principais, aprimorando a precisão e a simplicidade na tomada de decisões. Um estudo de caso envolvendo 32 navios de guerra e dez critérios quantitativos demonstrou a aplicação prática do método. As classificações resultantes equilibraram preferências subjetivas com medidas objetivas de desempenho, mostrando consistência entre vários tomadores de decisão. Este estudo destaca o potencial do *SAPEVO-PC* para melhorar a eficiência da tomada de decisões em ambientes complexos, como o militar, através de análises robustas e confiáveis.

PALAVRAS CHAVE. SAPEVO-PC, Aprendizado de Máquina, Análise Multicritério.

Tópicos [1º] 26. SE- PO em Defesa e Poder Marítimo (SE-PODMAR); [2º] 6.D&SP – PO em Defesa e Segurança Pública.

ABSTRACT

Abstract: This study presents the SAPEVO-PC method, an evolution of the SAPEVO family that integrates a multicriteria decision support method and machine learning to support the selection of Navy ships, a critical process in ensuring national sovereignty. SAPEVO-PC allows the inclusion of qualitative preferences alongside quantitative data, incorporating concepts from principal component analysis, improving accuracy and simplicity in decision-making. A case study involving 32 warships and ten quantitative criteria demonstrated the practical application of the method. The resulting classifications balanced subjective preferences with objective performance measures, showing consistency across multiple decision makers. This study highlights the potential of SAPEVO-PC to improve decision-making efficiency in complex environments, such as the military, through robust and reliable analyses

KEYWORDS. SAPEVO-PC, machine learning, multi-criteria analysis.

Paper topics [1st] 26. SE- OR in Defense and Maritime Power; [2nd] 6.D&SP – OR in Defense and Public Security.

1. Introdução

A investigação e o desenvolvimento militar no mundo moderno não são apenas dois dos principais fatores na construção do poder militar de um Estado, no fortalecimento da sua independência estratégica e na garantia de vantagens tecnológicas, mas também representam fatores essenciais no progresso científico, tecnológico e econômico do Estado [Gilkova 2022]. A relação entre a corrida armamentista e a estabilidade estratégica tem sido significativa para os estados aumentarem o poder militar e os consequentes efeitos sobre suas rivalidades com outros estados [Ali e Sidhu 2023]. Gilkova [2022] afirmou que os países líderes no que diz respeito aos gastos em pesquisa e desenvolvimento militar não só dominam a criação e o desenvolvimento de armas e equipamentos militares, mas também são atualmente os países mais desenvolvidos do mundo no campo da robótica, informação e outros tipos de tecnologia civil.

Neste contexto, a seleção de um navio de guerra é crucial para qualquer nação com interesses marítimos significativos, pois esta escolha reflete diretamente as capacidades de defesa do país, a projeção de poder e a segurança nacional [Costa et al. 2020]. Além disso, este processo tem implicações além do escopo puramente militar, influenciando as relações diplomáticas e geopolíticas de um país [Santos et al. 2021]. A decisão pode sinalizar um compromisso com a manutenção da paz e estabilidade regionais ou refletir a capacidade de uma nação de dissuadir ameaças potenciais.

Dentro das forças armadas, uma técnica de Pesquisa Operacional rotineira empregada é a metodologia de tomada de decisão multicritério (MCDM, do inglês *Multi-Criteria Decision Making*), empregada para se referir a uma coleção de metodologias que visam incorporar múltiplos critérios para auxiliar as partes interessadas e grupos na exploração de decisões significativas, Greco et al. [2016] afirmaram que os elementos fundamentais do MCDM consistem em um conjunto de alternativas, um mínimo de dois critérios e o envolvimento de pelo menos um tomador de decisão (DM, do inglês *Decision-Maker*). Costa et al. [2022] realizaram uma extensa revisão da literatura sobre MCDM no campo militar, e destacaram vários estudos recentes, como a escolha de um navio de assistência hospitalar militar para apoiar o combate à pandemia da COVID-19 [Costa et al. 2020], a hierarquização das estratégias de policiamento [Basílio et al. 2021; Basílio e Pereira 2020], a seleção de drones a serem adquiridos para uso em guerra naval [Moreira et al. 2021] e segurança pública [Moreira et al. 2022], e a classificação de aeronaves [Costa et al. 2020; Maêda et al. 2021], bases militares [De Almeida et al. 2021] e pessoal [Costa et al. 2022a].

A explosão de dados na era atual, impulsionada por tecnologias como 5G e a Internet das Coisas, ressalta a necessidade de ferramentas ágeis para analisar grandes quantidades de informações e apoiar processos complexos de tomada de decisão [Helmick et al. 2021]. Nesse sentido, é cada vez mais imperativo que pesquisadores desenvolvam e apliquem metodologias que facilitem a análise de vastos conjuntos de dados. Neste cenário, a Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*), que é uma técnica de aprendizado de máquina (ML, do inglês *Machine Learning*) não supervisionada, ganha muita importância pois permite a análise de observações descritas por variáveis interdependentes quantitativas para extrair informações significativas, representando-as como um conjunto menor de novas variáveis [Abdi e Williams 2010].

Ainda neste contexto, diversos autores têm apontado que o número de avaliações pareadas representa um desafio significativo em métodos multicritério. Greco et al. [2016] reconhecem que comparar diretamente critérios e alternativas em um grande conjunto pode ser custoso e suscetível a inconsistências.

Como contribuição para mitigar este problema, este artigo propõe a utilização do método multicritério denominado *Simple Aggregation of Preferences Expressed by Ordinal Vectors—Principal Components* (SAPEVO-PC), que integra conceitos de análise multicritério e técnicas avançadas de ML [Costa et al. 2024]. O método proposto reduz o número de avaliações pareadas para obter os pesos dos critérios, utilizando conceitos de PCA para avaliar o desempenho das alternativas. Com o método SAPEVO-PC é possível lidar com grandes volumes de dados de forma eficiente e fornecer um suporte robusto e confiável à decisão. O método permite a análise de dados qualitativos (obtenção de pesos de critérios) com menor esforço cognitivo e de dados quantitativos (análise do desempenho das alternativas), aproveitando as vantagens de cada abordagem.

Diante do exposto, este artigo propõe uma metodologia para avaliação de navios de guerra baseada em conceitos relacionados a MCDM e ML. Foram analisados dados das esferas militar, econômica e estratégica de 32 navios de marinhas de diferentes países, utilizando 10 critérios quantitativos. O método SAPEVO-PC se destaca por permitir a ponderação de critérios com base na opinião de especialistas, exigindo poucas comparações; e identifica correlações entre variáveis, o que ajuda a entender como atributos dos navios de guerra se relacionam. Além disso, promove redução de dados, criando fatores mais fáceis de interpretar, e gera indicadores de desempenho que permitem uma avaliação precisa das capacidades dos navios.

Combinando técnicas de MCDM e Machine Learning, a metodologia proposta oferece uma abordagem inovadora e replicável, sendo útil não somente para a seleção de navios, mas também para a academia, defesa e engenharia naval.

2. Referencial teórico

Em problemas de decisão, há um aumento notável nas avaliações pareadas que envolvem um número elevado de critérios e alternativas. Esse aumento pode resultar em considerável sobrecarga cognitiva para os tomadores de decisão, tornando o processo decisório mais desafiador e sujeito a inconsistências de julgamento. Nesse sentido, uma inovação importante do *SAPEVO-PC* é a redução significativa das comparações pareadas necessárias durante o processo de avaliação, que se torna mais eficiente, reduzindo a carga cognitiva dos tomadores de decisão e aumentando a confiabilidade geral dos resultados [Costa et al. 2024]. Essa eficiência é alcançada sem comprometer a abrangência e a precisão das avaliações.

2.2 Método SAPEVO-PC

Este tópico descreve os conceitos e etapas para a aplicação do método SAPEVO-PC [Costa et al. 2024]. O método possui duas fases distintas: predominantemente qualitativa e quantitativa. A primeira fase consiste na obtenção dos pesos dos critérios, na qual as opiniões qualitativas de múltiplos tomadores de decisão são consideradas para determinar a importância relativa de cada critério. Essa fase garante que as opiniões e preferências de especialistas sejam efetivamente integradas à tomada de decisão. A segunda fase envolve a avaliação do desempenho de alternativas usando algoritmos de *ML*, especificamente PCA. Essa fase quantitativa fornece *insights* baseados em dados para criar indicadores de desempenho, proporcionando uma avaliação robusta e objetiva de cada alternativa. Ao combinar essas duas fases, o SAPEVO-PC oferece uma abordagem abrangente e equilibrada para a tomada de decisão multicritério, integrando a contribuição qualitativa de especialistas com o rigor analítico quantitativo.

Conforme Costa et al. [2024]. Na fase qualitativa, deve-se definir os critérios denominados Elemento Ideal Positivo (EIP) e Elemento Ideal Negativo (EIN) para determinar os pesos dos critérios. Ressalta-se que o EIP é o critério considerado mais importante, enquanto o EIN é o menos importante, na perspectiva do decisor.

As avaliações pareadas são realizadas apenas comparando o EIP com cada um dos outros critérios e, da mesma forma, comparando o EIN entre si. O método SAPEVO-PC baseia-se em uma escala ordinal de sete pontos, conforme mostrado na Tabela 1. Essa escala varia de 1 (Igualdade) a 7 (Absolutamente melhor/pior), permitindo que o decisor estabeleça preferências qualitativamente, de acordo com suas avaliações subjetivas.

Tabela 1. Escala conceitual do método SAPEVO-PC.

Grau	Descrição
1	O EIP e o outro critério são igualmente importantes
2	O EIP é ligeiramente mais importante que o outro critério
3	O EIP tem importância moderada quando comparado com os outros critérios
4	O EIP tem importância considerável quando comparado com os outros critérios
5	O EIP tem grande importância quando comparado com os outros critérios
6	O EIP tem uma importância muito grande quando comparado com os outros critérios
7	O EIP tem importância absoluta quando comparado com os outros critérios

Fonte: Os autores.

Para realizar as comparações pareadas dos critérios sobre o EIN, serão atribuídos valores simétricos aos indicados na Tabela 1, considerando que este parâmetro é o pior entre todos os critérios em análise (todas as notas atribuídas ao EIN sobre os demais serão negativas).

Observa-se uma redução significativa no número de avaliações de paridade no SAPEVO-PC em comparação com outros métodos da família SAPEVO. A equação (1) representa o número de avaliações pareadas (K) necessárias para obter os pesos dos critérios e avaliar as alternativas em critérios qualitativos usando o método SAPEVO-PC, onde n é o número de critérios ou alternativas que estão sendo avaliados

$$K = 2n - 3 \quad (1)$$

2.2.1 Fase 1: Avaliação Qualitativa para Obtenção dos Pesos dos Critérios

Etapa 1. Definir um conjunto de critérios de decisão. Nesta etapa, os critérios $C = \{C_1; C_2; \dots; C_n\}$ serão avaliados no processo de tomada de decisão.

Etapa 2. Identificar os critérios considerados melhores (mais desejáveis, mais importantes) e os piores (menos desejáveis, menos importantes). Nesta etapa, o tomador de decisão determina qual critério é melhor ou pior, sem comparações pareadas.

Etapa 3. Avaliar a preferência do melhor critério geral em relação aos demais critérios (A^+) utilizando a escala de 7 pontos apresentada na Tabela 1. O resultado da avaliação da precedência do melhor critério (EIP) sobre os demais é apresentado por meio do vetor representado na equação (2):

$$A^+ = \{a_{P1}, a_{P2}, \dots, a_{Pn}\} \quad (2)$$

onde P_j representa a preferência do melhor critério EIP sobre um determinado critério j , e n representa o número do critério. Observa-se que o elemento $a_{PP}=1$ porque representa a comparação do elemento EIP consigo mesmo.

Passo 4. Estabelecer a preferência de todos os critérios sobre o EIN (A^-) usando os valores simétricos (multiplicados por -1) na Tabela 1. O resultado das avaliações de precedência dos outros critérios sobre o EIN forma o vetor representado na equação (3):

$$A^- = \{a_{N1}, a_{N2}, \dots, a_{Nn}\} \quad (3)$$

onde N_j indica a preferência do critério j sobre o pior critério EIN. O elemento $a_{NN}=1$ corresponde à comparação do EIN consigo mesmo.

Passo 5. Calcular o elemento A^* , representado pela soma global de A^- e A^+ para cada critério, conforme a equação (4):

$$A^* = \{(a_{N1} + a_{P1}), (a_{N2} + a_{P2}), \dots, (a_{Nn} + a_{Pn})\} \quad (4)$$

Este termo representa o nível geral de precedência para cada um dos critérios.

Etapa 6. Calcular o valor de precedência normalizado de A_N para cada critério de acordo com o vetor representado na equação (5):

$$A_N = \left\{ \left(\frac{a_1^* - \max a_j^*}{\min a_j^* - \max a_j^*} \right), \left(\frac{a_2^* - \max a_j^*}{\min a_j^* - \max a_j^*} \right), \dots, \left(\frac{a_n^* - \max a_j^*}{\min a_j^* - \max a_j^*} \right) \right\} \quad (5)$$

onde a_j^* indica a soma dos elementos N_j e P_j . Cabe ressaltar que os valores normalizados obtidos variam de 0 a 1, onde o peso do EIN é igual a 0 e o EIP recebe peso máximo de 1. Entretanto, assim como nos modelos SAPEVO clássicos, essa normalização pode resultar em critérios com pesos iguais a 0, o que conceitualmente não faz sentido, pois tal critério não seria considerado na análise.

Gomes et al. [2020] sugeriram atribuir o peso de 1% do menor valor subsequente para contornar essa limitação. No entanto, esses valores permanecem muito próximos de 0 na prática. Neste artigo, atribui-se o peso de 20% do menor valor subsequente ao critério com menor

importância, conforme Costa et al. [2024]. Os resultados representam pontuações cardinais dos critérios e alternativas aos critérios qualitativos, esclarecendo as relações de preferência para cada variável em cada contexto de avaliação.

Passo 7. Calcular os valores dos pesos dos critérios, W_S , representados em escala percentual, conforme o vetor apresentado pela equação (6):

$$W_S = \left\{ \left(\frac{A_{N_1}}{\sum_{j=1}^N A_{N_j}} \right), \left(\frac{A_{N_2}}{\sum_{j=1}^N A_{N_j}} \right), \dots, \left(\frac{A_{N_n}}{\sum_{j=1}^N A_{N_j}} \right) \right\} \quad (6)$$

As etapas 1 a 7 são executadas para cada DM envolvido na tomada de decisão.

Passo 8. Calcular o Valor de Decisão do Grupo, W_G , representado em escala percentual, conforme equação (7):

$$W_G = \left\{ \left(\frac{\sum_{j=1}^D W_{S_1}}{D} \right), \left(\frac{\sum_{j=1}^D W_{S_2}}{D} \right), \dots, \left(\frac{\sum_{j=1}^D W_{S_n}}{D} \right) \right\} \quad (7)$$

W_G é o vetor de valores de decisão do grupo para os critérios; D é o número total de tomadores de decisão; W_S é o peso do i -ésimo critério que o d -ésimo tomador de decisão atribui.

Nesta etapa, calcula-se a média das avaliações dos tomadores de decisão para derivar o valor da decisão em grupo. Isso envolve calcular a média dos pesos individuais atribuídos por cada tomador de decisão a cada critério. O valor da decisão em grupo fornece uma avaliação coletiva que incorpora as perspectivas de todos os tomadores de decisão, garantindo uma avaliação equilibrada e representativa.

2.2.2. Fase 2: Avaliação Quantitativa Integrando MCDM e ML

A segunda fase do método SAPEVO-PC emprega os princípios da PCA integrada ao algoritmo proposto. Antes de abordar a PCA, é necessário compreender a análise fatorial, voltada à identificação de relações entre variáveis correlacionadas e à criação de novas variáveis (fatores) que representem essas relações [Fávero e Belfiore 2024; Budaev 2010; Fávero e Belfiore 2019].

A análise fatorial busca reduzir a dimensionalidade dos dados, agrupando variáveis correlacionadas em fatores comuns. Dentre as técnicas disponíveis, a PCA é a mais comum por gerar fatores ortogonais (não correlacionados) a partir de combinações lineares das variáveis originais [Fávero e Belfiore 2024]. Historicamente, Pearson [1896] introduziu o conceito de correlação, Spearman [1904] contribuiu com a metodologia de análise das relações entre as variáveis, finalmente Hotelling [1933] formalizou a PCA como um processo de maximização da variância dos dados originais.

Inicialmente, para extrair fatores das k variáveis, é necessário definir a matriz de correlações ρ com os valores da correlação linear de Pearson entre cada par de variáveis, conforme ilustrado na matriz (8).

$$\rho = \begin{pmatrix} 1 & \rho_{12} & \dots & \rho_{1k} \\ \rho_{21} & 1 & \dots & \rho_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{k1} & \rho_{k2} & \dots & 1 \end{pmatrix} \quad (8)$$

O coeficiente de Pearson ρ varia entre -1 e 1 , indicando desde forte correlação negativa até forte correlação positiva [Egghe e Leydesdorff 2009; Smith 2015]. A análise fatorial é viável quando os valores da matriz de correlação são altos e estatisticamente significativos. Valores abaixo de $0,30$ em grande número indicam que a técnica pode ser inadequada [Hair et al. 2009]. Para avaliar essa adequação, utilizam-se dois testes: o índice Kaiser–Meyer–Olkin (KMO) e o teste de esfericidade de Bartlett.

O índice KMO varia de 0 a 1 , fornecendo a proporção de variância comum a todas as variáveis da amostra, possivelmente atribuída a um fator comum [Shrestha 2021]. De acordo com Fávero e Belfiore [2024], valores mais próximos de 1 indicam que as variáveis compartilham uma

porcentagem muito alta de variância com altas correlações de Pearson. Por outro lado, valores próximos de 0 resultam de baixos índices de correlação de Pearson, o que pode indicar que a análise fatorial não será adequada.

Por sua vez, o teste de esfericidade proposto por Bartlett [1954] compara a matriz de correlação de Pearson com uma matriz identidade I de igual dimensão, a fim de verificar se as correlações de Pearson entre os pares de variáveis são estatisticamente diferentes de 0, o que significa que os fatores podem ser extraídos com base nas variáveis originais.

Após verificar a adequação global da análise fatorial, deve-se começar por definir os fatores por componentes principais, através da determinação dos autovalores, autovetores e escores fatoriais [Fávero e Belfiore 2019].

Um fator representa a combinação linear de variáveis originais, são obtidos multiplicando-se cada escore fatorial pela variável original correspondente. Os escores fatoriais representam os parâmetros de um modelo linear que relacionam um dado fator às variáveis originais [Fávero e Belfiore 2024], eles são obtidos através do cálculo dos autovetores da matriz ρ de correlações.

Conforme Costa et al. [2024] A integração dos pesos dos critérios W , obtidos na fase 1, com os valores da PCA ocorre no cálculo das pontuações fatoriais. Os pesos dos critérios originais W_s são combinados com os valores derivados da PCA neste processo. Especificamente, cada peso dos critérios originais resultante da fase 1 é multiplicado pelo valor correspondente, garantindo que opiniões qualitativas de especialistas e valores estritamente quantitativos baseados em dados sejam incorporados à avaliação final.

Essa integração permite uma avaliação mais abrangente e precisa das alternativas, aproveitando os pontos fortes de ambos os métodos. Considerando dados qualitativos e quantitativos, a equação fatorial pode ser representada pela Equação (9):

$$F_{ki} = \frac{v_{1k}}{\sqrt{\lambda_k^2}} \cdot ZX_{1i} \cdot W_{s_1} + \frac{v_{2k}}{\sqrt{\lambda_k^2}} \cdot ZX_{2i} \cdot W_{s_2} + \dots + \frac{v_{kk}}{\sqrt{\lambda_k^2}} \cdot ZX_{ki} \cdot W_{s_k} \quad (9)$$

onde W_s representa o peso de cada critério obtido na fase 1; k representa o número de critérios originais em análise.

Neste trabalho, utilizou-se a análise fatorial por PCA, na qual o primeiro fator F_1 , formado pelo maior percentual de variância compartilhado pelas variáveis originais, também é denominado fator principal [Fávero e Belfiore 2024].

Após o estabelecimento dos fatores, é possível definir as cargas fatoriais, representadas pelas correlações de Pearson entre as variáveis originais e cada fator gerado [Garrido et al. 2013].

Em resumo, um conjunto de dados contendo alternativas e critérios é inicialmente utilizado. Em seguida, os critérios qualitativos são avaliados por múltiplos tomadores de decisão. Os resultados dessas avaliações são integrados aos escores fatoriais, permitindo a extração de fatores por meio de análises estatísticas como o Teste KMO e o Teste de Esfericidade de Bartlett para garantir a adequação dos dados. Por fim, é realizada uma avaliação de desempenho das alternativas, considerando os fatores calculados pela integração das avaliações qualitativas e quantitativas.

3. Metodologia

Conforme a classificação proposta por [Creswell e Creswell 2017], esta pesquisa pode ser quantitativa, combinando estudos de caso e modelagem matemática [Bertrand e Fransoo 2002]. O conjunto de dados sobre navios de guerra analisado neste estudo é altamente relevante, pois foi meticulosamente compilado a partir de fontes confiáveis que fornecem dados detalhados e precisos sobre navios militares, como [Janes 2024; Global Security 2024], garantindo a precisão e a relevância das informações. Essas fontes foram selecionadas por sua credibilidade e pela abrangência dos dados oferecidos.

A Tabela 2 apresenta os critérios analisados em nosso estudo, bem como uma descrição de cada um deles.

Tabela 2. Critérios utilizados na análise.


CRITÉRIO	Deslocamento (ton)	Velocidade (nós)	Capacidade de carga (ton)	Armamento (quantidade)	Custo (USD)
SIGLA	DSP	SPD	CAP	BRAÇO	CST
MONOTONICIDADE	Max	Max	Max	Max	Min
CRITÉRIO	Alcance (milhas náuticas)	Equipe (tamanho da tripulação)	Ano de comissionamento	Alcance de mísseis (milhas náuticas)	Alcance do radar (milhas náuticas)
SIGLA	RNG	CRE	YOC	MSL	RAD
MONOTONICIDADE	Max	Min	Max	Max	Max

Fonte: Os autores.

Esses 10 critérios para avaliação de navios de guerra foram cuidadosamente considerados para abranger uma ampla gama de capacidades e características operacionais, permitindo uma análise robusta e diversificada. A metodologia proposta visa proporcionar uma visão abrangente e flexível, visto que cada Marinha pode ter objetivos diferentes ao empregar um navio, como operações contra desastres naturais, assistência social, patrulhamento, combate à pirataria ou outras tarefas táticas, operacionais e estratégicas.

A Figura 1 ilustra a metodologia proposta neste artigo para avaliação de navios de guerra.

Figura 1. Fluxograma da metodologia proposta.



Fonte: Os autores.

A Fase 1 começa com um conjunto de dados de navios de guerra de marinhas de todo o mundo, seguido pela avaliação de critérios qualitativos pelos cinco diferentes especialistas, culminando no consenso do grupo. A Fase 2 envolve a adaptação dos conceitos de PCA, a realização de testes de validação, a integração de dados qualitativos e quantitativos, a avaliação de desempenho dos navios, a classificação dos navios e a realização de uma análise de sensibilidade, considerando as opiniões individuais, levando à decisão final.

4. Resultados e Discussão

Esta seção detalhará os resultados de acordo com a metodologia proposta, que segue as etapas do *SAPEVO-PC* apresentadas anteriormente. Inicialmente, tem-se a fase qualitativa da análise.

4.1. Obtenção de Pesos de Critérios Utilizando a Escala Qualitativa

O estudo utilizou o método *SAPEVO-PC* para obter os pesos dos critérios utilizados na tomada de decisão militar, com base em entrevistas com especialistas. Inicialmente, foram definidos o Elemento Ideal Positivo e o Negativo, considerados como “Armamento” e “Custo”, respectivamente. O primeiro decisor (DM 1), consultor de táticas operacionais, destacou o “Armamento” como o critério mais importante (peso=16,71%), indicando uma preferência pela eficácia operacional em detrimento da economia; o DM 2 (Logística e Cadeia de Suprimentos), priorizou capacidade de carga (16,91%); o DM 3 (Inteligência e Segurança), destacou alcance do radar (16,29%), valorizando vigilância; o DM 4 (Tecnologia e Inovações), atribuiu maior peso ao armamento (17,11%), demonstrando preferência por sistemas modernos; o DM 5 (Planejamento Estratégico e Políticas), priorizou custo (16,71%), focando na gestão orçamentária.

Somando os pesos individuais, chega-se ao peso obtido pelo grupo. Em geral, as armas apresentam o maior peso médio (13,71%), indicando um reconhecimento coletivo da importância do poder de fogo e das capacidades de defesa em cenários operacionais. Isso é seguido de perto pelo ano de comissionamento (11,29%) e alcance (11,32%), sugerindo um valor compartilhado atribuído à modernidade e ao alcance operacional.

4.2. Análise Quantitativa

A análise de correlação entre os valores dos critérios identificou fortes correlações entre deslocamento, capacidade de carga, tripulação, custo e autonomia, o que faz sentido no contexto de navios de guerra — navios maiores tendem a ser mais caros, mais bem equipados e com maior autonomia. A análise fatorial foi validada com estatísticas KMO (0,77) e o teste de esfericidade de Bartlett ($p < 0,05$), confirmando que os dados são apropriados para essa técnica. Os componentes principais (CP) extraídos revelaram que: CP1 representa a dimensão operacional dos navios (tripulação, autonomia, deslocamento, capacidade); CP2 está ligado ao poder militar e ao nível tecnológico (armamento e ano de comissionamento); e CP3 destaca a variável velocidade. Juntos, os três primeiros componentes explicam cerca de 80% da variância dos dados.

A Tabela 3 apresenta os dados e a classificação final dos 32 navios analisados neste estudo, considerando 10 critérios quantitativos e a opinião de cinco especialistas militares com diferentes perfis.

Tabela 3. Classificação dos navios considerando a opinião de cinco especialistas militares com perfis diferentes.

Navios	DSP	SPD	CAP	BRAÇO	CST	RNG	CRE	YOC	MSL	RAD	Classificação
Navio 1	14.564	30	1000	80	-4500	9000	-158	2016	100	300	10
Navio 2	100.000	31.5	9000	90	-8000	12.000	-5500	1975	800	350	1
Navio 3	65.000	25	5000	50	-4100	10.000	-1600	2017	600	320	7
Navio 4	45.400	28	4000	60	-2300	7000	-1600	2013	450	280	12
Navio 5	58.600	29	4500	70	-3200	8000	-2000	1990	700	300	5

Navio 6	28.000	32	4200	80	-5000	11.000	-1500	1988	900	350	2
Navio 7	12.500	34	4100	80	-4500	10.000	-1200	1982	800	320	3
Navio 8	12.000	30	3800	112	-1500	9000	-310	2019	600	340	4
Navio 9	3500	40	1200	50	-600	6000	-75	2008	400	250	26
Navio 10	10.000	30	1300	96	-1400	8300	-300	2007	500	270	9
Navio 11	5520	30	1400	80	-1000	4500	-300	2002	250	260	16
Navio 12	6000	30	2000	68	-800	6000	-200	2012	500	270	17
Navio 13	5690	29	1800	60	-900	4000	-230	2003	400	280	25
Navio 14	7000	30	2000	68	-1000	5000	-230	2017	500	300	15
Navio 15	5800	29	1800	68	-900	4000	-230	2004	400	280	21
Navio 16	7200	30	1800	64	-950	4000	-190	2013	300	310	23
Navio 17	6600	30	1900	70	-700	8000	-300	2011	500	290	14
Navio 18	3200	28	1500	70	-500	7000	-180	2008	400	270	19
Navio 19	5290	26	1600	72	-600	5000	-146	2006	500	290	18
Navio 20	3100	44	1200	60	-700	6000	-80	2010	300	240	22
Navio 21	5400	30	1800	70	-1000	8000	-200	2013	600	280	13
Navio 22	8000	32	2200	48	-1200	7000	-190	2010	450	320	20
Navio 23	6050	29	1600	40	-1200	5000	-200	2002	500	290	28
Navio 24	5800	28	1700	48	-1000	4500	-200	2002	500	290	27
Navio 25	4200	29	1200	30	-800	4000	-180	1990	300	250	31
Navio 26	9500	30	2000	90	-1800	4000	-350	1989	700	310	8
Navio 27	4100	29	1200	40	-600	4000	-180	1977	400	260	29
Navio 28	3600	25	1000	40	-300	5000	-150	1992	300	230	30
Navio 29	21.300	18.8	3000	68	-1800	10.800	-177	2006	700	340	11
Navio 30	12490	32	2500	80	-2000	8000	-485	1983	800	330	6
Navio 31	2600	25	760	30	-370	4500	-110	2020	280	230	32
Navio 32	7350	30	1600	48	-1200	7000	-190	2009	400	320	24

Fonte: Os autores.

A análise de desempenho dos navios revelou que o Navio 2 é consistentemente o melhor avaliado, destacando-se em deslocamento, capacidade de carga, armamento, velocidade e alcance, apesar do alto custo. O Navio 6 ficou em segundo lugar pela sua velocidade e alcance, seguido pelo Navio 7, que equilibra bem velocidade, carga e armamento.

Na outra extremidade, o Navio 31 foi o pior classificado, com desempenho fraco em quase todos os critérios. Os navios 25, 28 e 27 também se mantiveram entre os últimos colocados, com características operacionais limitadas.

A classificação foi validada por especialistas militares, que consideraram o método eficaz e confiável. Apesar de ser mais complexo que métodos tradicionais como AHP e TOPSIS, o SAPEVO-PC oferece maior integração e precisão, sendo especialmente útil em cenários complexos, com diversos dados quantitativos e necessidade de julgamentos especializados.

5. Conclusões

Este artigo explorou a complexidade inerente a problemas relacionados à tomada de decisão em ambientes desafiadores. A metodologia SAPEVO-PC, apresentada como uma evolução na família SAPEVO, demonstrou sua significativa utilidade na avaliação de navios militares, proporcionando uma maneira inovadora de atribuir pesos a critérios da perspectiva do tomador de decisão. A introdução de Elementos Ideais Positivos Ideais e Elementos Ideais Negativos foi crucial para essa abordagem, permitindo a consideração de preferências qualitativas em cenários complexos.

A aplicação do método SAPEVO-PC, com foco na simplificação do processo de comparação e na redução substancial do número de avaliações por pares, mostrou-se valiosa ao

lidar com a ampla gama de critérios e alternativas envolvidas no estudo de caso proposto, composto por 32 alternativas e 10 critérios. Essa abordagem aborda as limitações inerentes aos métodos multicritério tradicionais, como o alto número de avaliações por pares necessárias, que pode ser dispendioso e propenso a inconsistências.

Além disso, a integração do MCDM com algoritmos de ML possibilitou a redução da dimensionalidade dos dados, transformando dez variáveis originais em três fatores principais sem perder a essência da informação. Essa abordagem combinada simplifica o processo de avaliação e aumenta a precisão e a objetividade dos resultados, permitindo que os tomadores de decisão militares avaliem os diversos critérios envolvidos na seleção de navios com maior confiança e eficiência. Com base nos resultados obtidos, pode-se afirmar que o método SAPEVO-PC possui um vasto potencial que pode ser explorado em diversas outras áreas, além da ciência e engenharia naval.

Em suma, este estudo traz uma contribuição significativa por meio da metodologia desenvolvida, que tem potencial para ser aplicada em diferentes situações, indo além da ênfase exclusiva na classificação resultante. A metodologia representa um avanço significativo na promoção de decisões mais informadas, rápidas e confiáveis, contribuindo para a otimização de recursos e a eficácia das operações em ambientes decisórios.

Referências

- Abdi, H.; Williams, L.J. (2010). Principal Component Analysis. *Wiley Interdiscip. Rev. Comput. Stat.* 2, 433–459. <https://doi.org/10.1002/wics.101>.
- Ali, I.; Sidhu, J.S. (2023). Strategic Dynamics of the Arms Race in South Asia. *J. Asian Afr. Stud.* <https://doi.org/10.1177/00219096231153150>.
- Bartlett, M.S. (1954). A Note on the Multiplying Factors for Various χ^2 Approximations. *J. R. Stat. Soc. Ser. B.* 16, 296–298. <https://doi.org/10.1111/j.2517-6161.1954.tb00174.x>.
- Basilio, M.P.; Pereira, V. (2020). Operational Research Applied in the Field of Public Security. *J. Model. Manag.* 15, 1227–1276. <https://doi.org/10.1108/JM2-02-2019-0034>.
- Basilio, M.P.; Pereira, V.; de Oliveira, M.W.C.; da Costa Neto, A.F. (2021). Ranking Policing Strategies as a Function of Criminal Complaints: Application of the PROMETHEE II Method in the Brazilian Context. *J. Model. Manag.* 16, 1185–1207. <https://doi.org/10.1108/JM2-05-2020-0122>.
- Bertrand, J.W.M.; Fransoo, J.C. (2002). Operations Management Research Methodologies Using Quantitative Modeling. *Int. J. Oper. Prod. Manag.* 22, 241–264.
- Budaev, S.V. (2010). Using Principal Components and Factor Analysis in Animal Behaviour Research: Caveats and Guidelines. *Ethology*, 116, 472–480. <https://doi.org/10.1111/j.1439-0310.2010.01758.x>.
- Costa, I.P.d.A.; Costa, A.P.d.A.; Sanseverino, A.M.; Gomes, C.F.S.; dos Santos, M. (2022). Bibliometric Studies on Multi-Criteria Decision Analysis (MCDA) Methods Applied in Military Problems. *Pesqui. Oper.* 42, e249414. <https://doi.org/10.1590/0101-7438.2022.042.00249414>.
- Costa, I.P.d.A.; Costa, A.P.d.A.; Moreira, M.Â.L.; Castro Junior, M.A.; Pereira, D.A.d.M.; Gomes, C.F.S.; Santos, M. (2024). SAPEVO-PC: Integrating Multi-Criteria Decision-Making and Machine Learning to Evaluate Navy Ship. *Journal of Marine Science and Engineering*, n°8, p. 1444. <https://doi.org/10.3390/jmse12081444>.

Costa, I.P.d.A.; Maêda, S.M.d.N.; Teixeira, L.F.H.d.S.D.B.; Gomes, C.F.S.; dos Santos, M. (2020). Choosing a Hospital Assistance Ship to Fight the COVID-19 Pandemic. *Rev. Saude Publica*, 54, 79. <https://doi.org/10.11606/S1518-8787.2020054002792>.

Costa, I.P.d.A.; Sanseverino, A.M.; Barcelos, M.R.d.S.; Belderrain, M.C.N.; Gomes, C.F.S.; dos Santos, M. (2021). Choosing Flying Hospitals in the Fight against the COVID-19 Pandemic: Structuring and Modeling a Complex Problem Using the VFT and ELECTRE-MOr Methods. *IEEE Lat. Am. Trans.* 19, 1099–1106. <https://doi.org/10.1109/TLA.2021.9451257>.

Costa, I.P.d.A.; Terra, A.V.; Moreira, M.Â.L.; Pereira, M.T.; Fávero, L.P.L.; dos Santos, M.; Gomes, C.F.S. (2022a). A Systematic Approach to the Management of Military Human Resources through the ELECTRE-MOr Multicriteria Method. *Algorithms*, 15, 422. <https://doi.org/10.3390/a15110422>.

Creswell, J.W.; Creswell, J.D. (2017). *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*; Sage Publications: Thousand Oaks, CA, USA; ISBN 1506386717.

De Almeida, I.D.P.; Corriça, J.V.d.P.; Costa, A.P.d.A.; Costa, I.P.d.A.; Maêda, S.M.d.N.; Gomes, C.F.S.; dos Santos, M. (2021). Study of the Location of a Second Fleet for the Brazilian Navy: Structuring and Mathematical Modeling Using SAPEVO-M and VIKOR Methods. In *International Conference of Production Research–Americas*; Communications in Computer and Information Science; Springer International Publishing: Cham, Switzerland; Volume 1408, pp. 113–124. https://doi.org/10.1007/978-3-030-76310-7_9.

Egghe, L.; Leydesdorff, L. (2009). The Relation between Pearson's Correlation Coefficient r and Salton's Cosine Measure. *J. Am. Soc. Inf. Sci. Technol.* 60, 1027–1036.

Fávero, L.P.; Belfiore, P. (2019). *Data Science for Business and Decision Making*; Academic Press Elsevier: Cambridge, MA, USA; ISBN 0128112174.

Fávero, L.P.; Belfiore, P. (2024). *Manual de Análise de Dados: Estatística e Machine Learning Com Excel®, SPSS®, Stata®, R® e Python®*, 2nd ed.; Grupo Gen: Barueri, Brazil; ISBN 9788595159921.

Garrido, L.E.; Abad, F.J.; Ponsoda, V.A. (2013). New Look at Horn's Parallel Analysis with Ordinal Variables. *Psychol. Methods*, 18, 454.

Gilkova, O.N. (2022). Military Research and Development as a Driving Force for the Economy of the Future. In *International Scientific and Practical Conference Operations and Project Management: Strategies and Trends*; Springer International Publishing: Cham, Switzerland; Volume 380, pp. 185–189.

Global Security Rest-of-World Ships Resources. (2025). <https://www.globalsecurity.org/military/world/links-navy.html>. Acesso em 2025-02-25.

Gomes, C.F.S.; dos Santos, M.; Teixeira, L.F.H.d.S.d.B.; Sanseverino, A.M.; Barcelos, M.R.d.S. (2020). SAPEVO-M: A Group Multicriteria Ordinal Ranking Method. *Pesqui. Oper.* 40, e226524. <https://doi.org/10.1590/0101-7438.2020.040.00226524>.

Greco, S.; Figueira, J.; Ehrgott, M. (2016) *Multiple Criteria Decision Analysis: State of Art Surveys*; Springer: Berlin/Heidelberg, Germany; Volume 37.

- Hair, J.F.; Black, W.C.; Babin, B.J.; Anderson, R.E.; Tatham, R.L. (2009). *Análise Multivariada de Dados*; Bookman Editora: ISBN 8577805344.
- Helmick, H.; Nanda, G.; Ettestad, S.; Liceaga, A.; Kokini, J.L. (2021). Applying Text Mining to Identify Relevant Literature in Food Science: Cold Denaturation as a Case Study. *J. Food Sci.* 86, 4851–4864. <https://doi.org/10.1111/1750-3841.15940>.
- Hotelling, H. (2933). Analysis of a Complex of Statistical Variables into Principal Components. *J. Educ. Psychol.* 24, 417–441. <https://doi.org/10.1037/h0071325>.
- Janes. (2024). *Jane's Fighting Ships Yearbook 23/24*; ISBN 978-0-7106-3428-3.
- Maêda, S.M.d.N.; Costa, I.P.d.A.; Castro Junior, M.A.P.; Fávero, L.P.; Costa, A.P.d.A.; Corriça, J.V.d.P.; Gomes, C.F.S.; dos Santos, M. (2021). Multi-Criteria Analysis Applied to Aircraft Selection by Brazilian Navy. *Production*, 31, e20210011. <https://doi.org/10.1590/0103-6513.20210011>.
- Moreira, M.Â.L.; Costa, I.P.d.A.; Pereira, M.T.; dos Santos, M.; Gomes, C.F.S.; Muradas, F.M. (2021). PROMETHEE-SAPEVO-M1 a Hybrid Approach Based on Ordinal and Cardinal Inputs: Multi-Criteria Evaluation of Helicopters to Support Brazilian Navy Operations. *Algorithms*, 14, 140. <https://doi.org/10.3390/a14050140>.
- Moreira, M.Â.; Lellis; Gomes, C.F.S.; dos Santos, M.; Basilio, M.P.; de Araújo Costa, I.P.; de Souza Rocha Junior, C.; José Jardim, R.R.-A. (2022). Evaluation of Drones for Public Security: A Multicriteria Approach by the PROMETHEE-SAPEVO-M1 Systematic. *Procedia Comput. Sci.* 199, 125–133. <https://doi.org/10.1016/j.procs.2022.01.016>.
- Pearson, K. (1896). VII. Mathematical Contributions to the Theory of Evolution.—III. Regression, Heredity, and Panmixia. *Philos. Trans. R. Soc. London. Ser. A Contain. Pap. A Math. Phys. Character*, 187, 253–318.
- Santos, M.; Costa, I.P.d.A.; Gomes, C.F.S. (2021). Sensitivity Analysis of Multicriteria Decision between Standard Deviation and Average in the Selection of Construction of Warships: A New Approach to the AHP Method. *Int. J. Anal. Hierarchy Process*.
- Shrestha, N. (2021). Factor Analysis as a Tool for Survey Analysis. *Am. J. Appl. Math. Stat.* 9, 4–11.
- Smith, R. (2015). A Mutual Information Approach to Calculating Nonlinearity. *Stat.* 4, 291–303.
- Spearman, C. (1904). “General Intelligence” Objectively Determined and Measured. *Am. J. Psychol.* 15, 201–293.