

## ESTUDO ESTRATÉGICO PARA SELEÇÃO DE ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL: UMA ABORDAGEM À LUZ DO MÉTODO MULTICRITÉRIO MELCHIOR

Igor Pinheiro de Araujo Costa (UFF) costa\_igor@id.uff.br  
Sérgio Mitihiro do Nascimento Almeida (UFF) sergiomaeda@gmail.com.br  
Arthur Pinheiro de Araujo Costa (UFF)  
Carlos Francisco Simões Gomes (UFF) cfsg1@bol.com.br  
Marcos dos Santos (IME) marcosdossantos\_doutorado\_uff@yahoo.com.br

### Resumo

Este artigo tem o objetivo de selecionar um algoritmo para a tarefa de classificação em Machine Learning (ML). Como arcabouço metodológico, utilizou-se o método de Apoio Multicritério à Decisão (AMD) Méthode d'ELimination et de CHOix Incluant les relations d'ORDre (MELCHIOR). O experimento realizado considerou como relevantes os seguintes critérios: Precisão, sensibilidade e tempo de processamento dos algoritmos. Os dados utilizados são referentes à intenção de compra na internet e o objetivo é prever se o cliente irá finalizar ou não uma determinada compra. Nesta pesquisa, os decisores relataram dificuldade em avaliar e estabelecer os pesos dos critérios. Por esse motivo, optou-se pelo método MELCHIOR como técnica para apoiar o processo decisório, pois esta ferramenta proporciona a avaliação das alternativas sem necessidade de elicitar os pesos dos critérios. Como resultado, o algoritmo Gradient Boosting Decision Tree foi selecionado como o mais indicado para a tarefa de classificação em ML.

**Palavras-Chaves:** Análise Multicritério, Machine Learning, MELCHIOR.

### 1. Introdução

O crescimento da cultura “direcionada por dados” abre espaço para métodos de apoio à tomada de decisão e técnicas de *Machine Learning* (ML). Cresce a demanda por métodos e modelos que gerem informação de qualidade para fins acadêmicos e profissionais. O ML, conforme pontuam Raschka e Mirjalili (2017), cresceu como um subcampo da Inteligência Artificial (IA), desenvolvendo um papel importante na pesquisa e no dia a dia.

A classificação, uma tarefa comum de ML, tem como objetivo a previsão de valores categóricos binomiais ou multinomiais. Alguns exemplos são as previsões de compra de produto e cancelamento de serviço, bem como a detecção de fraude e risco de inadimplência.

A seleção de algoritmos em ML pode ser entendida como um problema de múltiplas alternativas e critérios. Portanto, o propósito neste artigo é explorar essa possível interação entre análise multicritério e IA. Nesse contexto, os métodos de Apoio Multicritério à Decisão (AMD) têm como objetivo ajudar no entendimento do processo decisório e na escolha das alternativas diante de múltiplos critérios (GOMES; GOMES, 2019; OLIVEIRA *et al.*, 2021).

Segundo Santos *et al.* (2015), os métodos multicritério consideram julgamentos de valor e não apenas questões técnicas, para avaliar alternativas para resolver problemas reais, apresentando um alto grau de multidisciplinaridade. Esses métodos têm sido utilizados para apoiar o processo de tomada de decisão em diversos problemas complexos recentes, conforme apresentado em (COSTA *et al.*, 2020, 2021; MOREIRA *et al.*, 2020; SANTOS; COSTA; GOMES, 2021; TENÓRIO *et al.*, 2020).

No que tange à aplicação de métodos de AMD em problemáticas relacionadas ao ML, a literatura apresenta diversas modelagens híbridas de ML e AMD, como na análise da tomada de decisão humana por meio de preferências de aprendizado (GUO *et al.*, 2021); em um procedimento de apuração de casos de COVID-19 (GUHATHAKURATA *et al.*, 2021); proposição de um novo modelo de verificação de autoria para contas de mídia social comprometidas por um ser humano (ALTERKAVI; ERBAY, 2021); auxílio à decisão na tomada de decisão financeira, em avaliação de modelos de previsão de casos de emergência (MOUSAVI; LIN, 2020); classificação do desempenho de fornecedores usando algoritmo de ML de *Random Forest* (WILSON *et al.*, 2020); metodologia de *benchmarking* para seleção do modelo ideal de diagnóstico COVID-19 (MOHAMMED *et al.*, 2020); suscetibilidade a incêndios florestais e mapeamento de risco usando vulnerabilidade social/ infraestrutura e variáveis ambientais (GHORBANZADEH *et al.*, 2019); seleção ideal de algoritmo de agrupamento para aplicativos de perfil de carga (PANAPAKIDIS; CHRISTOFORIDIS, 2018); e estrutura analítica de decisão integrada para classificação de estoque com vários atributos (KARTAL *et al.*, 2016).

Song e Peng (2019) realizaram experimento com base em análise multicritério na seleção de algoritmos classificadores para previsões de risco financeiro. Kou *et al.* (2012) analisaram as diferenças entre ordenações de classificadores produzidas por métodos multicritério. Ali, Lee e

Chung (2017) propuseram uma metodologia multicritério para ordenar classificadores baseada na seleção de critérios e atribuição de pesos.

O objetivo deste artigo é selecionar um algoritmo para a tarefa de classificação em ML, mediante aplicação do método de AMD *Méthode d'ELimination et de CHOix Incluant les relations d'ORDre* (MELCHIOR).

Nesta pesquisa, foi relatada pelos decisores uma dificuldade em avaliar e estabelecer os pesos dos critérios. Nesses casos, o método MELCHIOR apresenta boa aderência, uma vez que proporciona a avaliação das alternativas sem necessidade de elicitar os pesos dos critérios, além de não considerar interação entre eles. Por isso, neste artigo optou-se pela aplicação desse método de sobreclassificação como ferramenta para apoio à tomada de decisão.

Este trabalho está dividido em 5 seções além desta introdução. A seção 2 aborda o entendimento da situação problemática, com a definição dos critérios e alternativas que compõem o estudo de caso proposto. A seção 3 apresenta o referencial teórico do método MELCHIOR, enquanto a seção 4 aborda a metodologia usada no artigo. A seção 5 apresenta a aplicação do método MELCHIOR para apoiar o processo de tomada de decisão no estudo de caso proposto. Finalmente, a seção 6 conclui este estudo.

## **2. Estruturação do problema**

Para auxiliar o entendimento do problema, neste artigo foi aplicado um método de estruturação de problemas (PSM – *Problem Structuring Methods*) consagrado na literatura – a *Soft Systems Methodology* (SSM) (CHECKLAND, 1981). Os PSM constituem uma das etapas do processo de tomada de decisão que tem como objetivo organizar assuntos, questões e/ou dilemas para os quais se buscam proposições de decisões, inicialmente; e não resolvê-los, a priori (BANDEIRA *et al.*, 2018). Os PSM são amplamente aceitos no âmbito da Pesquisa Operacional (PO) e no movimento de sistemas para o entendimento e estruturação de problemas complexos (ROSENHEAD; MINGERS, 2001).

Segundo Mingers e Rosenhead (2004), os PSM são procedimentos de abordagem para situações que apresentem múltiplos atores, diferentes perspectivas, interesses conflitantes, intangíveis significativos e incertezas complexas.


Dentre os métodos mais comumente utilizados e consolidados na literatura, a SSM tem sido explorada em uma variedade de campos de pesquisa, bem como serve a interesses práticos igualmente diversos (ROSE, 1997).

De acordo com Checkland (1981), a SSM apresenta sete estágios de aplicação, dos quais dois foram abordados neste artigo para a estruturação do problema: 1 - explorar uma situação problemática não estruturada; e 2 - expressá-la.

No primeiro estágio, foi utilizada a técnica de *brainstorming* pelos autores, para demonstrar as percepções do grupo sobre todas as informações possíveis, sem interferências ou julgamentos para definir o problema. No segundo estágio, foi construída uma figura rica (Figura 1), a qual possui grande valor como ponto de partida na análise exploratória do problema (CHECKLAND, 2000).

A figura rica é uma simples ferramenta de SSM, extremamente útil para abrir a discussão em torno das percepções individuais em direção a uma visão ampla sobre as diferentes questões que afetam a situação. São criadas de forma livre e não estruturada para capturar a interpretação dos participantes de uma situação real (CHECKLAND, 1981; ROSE, 1997).

Figura 1 - Figura Rica - Critérios para seleção de algoritmo



Fonte: Autores (2021)

O objetivo do estudo de caso é escolher um algoritmo classificador para prever se o indivíduo na internet irá finalizar a compra (classe positiva) ou não (classe negativa). A figura rica retrata a tentativa de equilíbrio entre os critérios na escolha do algoritmo. No que se refere aos critérios quantitativos. Enquanto as métricas de avaliação refletem a eficácia do algoritmo, o tempo de processamento é uma medida da performance.

- As métricas de avaliação precisão e sensibilidade possuem como base a matriz de confusão (Tabela 1). A precisão mede a assertividade ao prever a classe positiva e sua fórmula é  $VP/(VP+FP)$ . Já a sensibilidade mede capacidade de alcançar e classificar os positivos, sua fórmula é  $VP/(VP+FN)$ .

Tabela 1 - Matriz de confusão

	Positivo	Negativo
Positivo Previsto	Verdadeiro Positivo (VP)	Falso Positivo (FP)
Negativo Previsto	Falso Negativo (FN)	Verdadeiro Positivo (VP)

Fonte: Autores (2021)

- Para o tempo de processamento foi considerado o tempo médio de 3 execuções. Além disso, foram considerados como alternativas os seguintes algoritmos:
- *K-nearest neighbor* (KNN), o qual tem como objetivo encontrar os K vizinhos mais próximos de uma nova amostra e realizar a previsão com base neles;
- *Support Vector Machine* (SVM), que trabalha para encontrar o hiperplano que melhor separa a base de treinamento, maximizando a distância entre o hiperplano e os pontos mais próximos a ele, de forma a evitar classificações erradas de novas amostras;
- *Random Forest* (RF): um conjunto de árvores de decisão construído em amostras dos dados; e
- *Gradient Boosting Decision Tree* (GBM): o qual realiza um treinamento sequencial, desenvolvendo novos modelos a partir de erros de modelos anteriores.

### 3. O método MELCHIOR

Para o estabelecimento das relações de preferência, o método MELCHIOR, proposto por Leclercq (1984), estabelece três situações fundamentais de comparação entre as alternativas:

- a) Preferência Fraca (q): Existem razões claras e positivas que não implicam uma preferência estrita em favor de uma (bem definida) das duas ações, mas essas razões são

insuficientes para que seja assumida uma preferência estrita em favor de outra, ou a indiferença entre elas (GOMES; GOMES, 2019);

- b) Preferência estrita (p): Existem razões claras e positivas que justificam uma preferência significativa em favor de uma (bem definida) das duas ações;
- c) Veto (v): Limite definido para cada critério que fixa um valor para a diferença  $g_j(b) - g_j(a)$  (diferença em relação ao critério  $j$  e discordante da afirmativa  $aSb$ ), a partir do qual não será aceita a proposição  $aSb$  (GOMES; GOMES, 2019).

No método MELCHIOR, a informação básica é uma família  $F$  de pseudocritérios, ou seja, critérios  $g_j$  com limiar de indiferença  $q_j$  e um limiar de preferência  $p_j$  ( $p_j > q_j \geq 0$ ) de tal forma que,  $\forall j \in J$  e  $\forall a, b \in A$  (MARTEL; MATARAZZO, 2016):

- $a$  é estritamente preferível a  $b$  ( $aP_jb$ ) em relação a  $g_j$  se  $g_j(a) > g_j(b + p_j[g_j(b)]$ ;
- $a$  é fracamente preferível a  $b$  ( $aQ_jb$ ) em relação a  $g_j$  se  $g_j(b) + p_j[g_j(b)] \geq g_j(a) > g_j(b) + q_j[g_j(b)]$ ;
- $a$  e  $b$  são indiferentes ( $aI_jb$ ) se não há preferência estrita ou fraca entre eles.

No método MELCHIOR nenhum peso é atribuído aos critérios. Uma relação binária  $M$  em  $F$  é definida de tal forma que  $g_i M g_j$  significa que "o critério  $g_i$  é tão importante quanto o critério  $g_j$ " [Martel e Matarazzo, 2016].

A fim de se obter a relação abrangente de superação  $aSb$ , Leclercq (1984) propôs uma forma particular de análise, na qual os critérios a favor e contra a relação de sobreclassificação são avaliados para verificar a concordância e se não existe situação de discordância. Ou seja, nenhum critério  $g_j$  de  $F$  existe tal que  $g_j(b) > g_j(a) + v_j$ , onde  $v_j$  é um limiar de veto para o critério  $g_j$  (ausência de discordância).

Neste método, um critério  $g_j \in F$  é dito ser a favor da relação de superação  $aSb$  se uma das seguintes as situações forem verificadas:

- $aP_jb$  (preferência marginal estrita de  $a$  em relação a  $b$ ) (1ª condição);
- $aP_jb$  ou  $aQ_jb$  (preferência marginal estrita ou fraca de  $a$  em relação a  $b$ ) (2ª condição);
- $g_j(a) > g_j(b)$  (3ª condição).

Um critério  $g_j \in F$  é dito ser contra a relação de superação  $aSb$  se uma das seguintes situações são verificadas:

- $bP_j a$  (preferência marginal estrita de  $b$  sobre  $a$ ) (1ª condição);
- $bP_j a$  ou  $bQ_j a$  (preferência marginal estrita ou fraca de  $b$  sobre  $a$ ) (2ª condição);
- $g_j(b) > g_j(a)$  (3ª condição).

A análise de concordância da relação de superação  $aSb$ , para  $a, b \in A$ , é feita verificando se a família de critérios  $G$  a favor dessa relação "mascara" a família dos critérios  $H$  que são contra a relação  $aSb$ . Estes subconjuntos de critérios são comparados apenas usando a relação binária  $M$  em  $F$ . Diz-se que um subconjunto  $G$  de critérios "mascara" um subconjunto  $H$  de critérios ( $G, H \subset F, F \cap G = \emptyset$ ) se, para cada critério  $g_i$  de  $H$ , existe um critério  $g_j$  de  $G$  tal que:

- $g_j M g_i$  (1ª condição); ou
- $g_j M g_i$  ou não ( $g_i M g_j$ ) (2ª condição).

Onde ao mesmo critério  $g_j$  de  $G$  é permitido mascarar no máximo um critério de  $H$ .

Leclercq (1984) explica que, ao escolher duas combinações adequadas das condições acima, sendo a primeira mais rigorosa que a segunda, e verificando a concordância e ausência de discordância, uma relação forte ou fraca de superação pode ser respectivamente construída (Tabela 2).

Tabela 2 - Estabelecimento das relações de sobreclassificação

Relação	Condições
$aP_j^+ b$	Se $g_j(a) > g_j(b) + p_j$
$aQ_j^+ b$	Se $g_j(a) > g_j(b) + p_j$ e $g_j(a) > g_j(b) + q_j$
$aI_j^+ b$	Se $g_j(a) > g_j(b) + q_j$ e $g_j(a) > g_j(b)$
$aE_j b$	Se $g_j(a) = g_j(b)$
$aP_j^- b$	Se $bP_j^+ a$
$aQ_j^- b$	Se $bQ_j^+ a$
$aI_j^- b$	Se $bI_j^+ a$

Fonte: Adaptado de Leclercq (1984)

Para o estabelecimento das relações de sobreclassificação forte e fraca entre as alternativas, Leclercq (1984) define:

- a) Sobreclassificação forte ( $S_F$ ): Para que uma alternativa  $a$  apresente uma relação de superação forte sobre  $b$ , necessariamente:
  - Não haja critérios para os quais  $b$  é estritamente preferível a ' $a$ ';
  - O critério  $i$  para o qual  $b$  é fracamente preferível a ' $a$ ' deve ser mascarado por critérios mais importantes para os quais  $A$  goza de estrita preferência.



- b) Sobreclassificação fraca ( $S_f$ ): Para que uma alternativa a apresente uma relação de superação fraca sobre b, é necessário que os critérios i para os quais b tem a vantagem devem ser mascarados por critérios j pelo menos tão importantes em favor de a.

Finalmente, ressalta-se que, ao aplicar o método MELCHIOR, nenhuma possibilidade de interação entre critérios é levada em consideração, uma vez que as relações de sobreclassificação são construídas analisando, um a um, os critérios a favor e contra a relação aSb (MARTEL; MATARAZZO, 2016).

#### 4. Metodologia

A proposta é utilizar o método MELCHIOR para selecionar um classificador com o objetivo de prever se o indivíduo irá efetuar ou não uma compra online. Os dados contêm informações sobre data, comportamento de acesso e características do indivíduo.

A base de dados utilizada faz parte do repositório do UCI *Machine Learning* e possui 12330 observações, 18 atributos e aproximadamente 16% dos dados são referentes a consumidores que finalizaram a compra. Portanto, é uma base desbalanceada.

De início foram inseridos os conjuntos de alternativas e critérios para a estruturação do problema: KNN, SVM, RF e GBM como alternativas, bem como precisão, sensibilidade, tempo de processamento e interpretabilidade como critérios. A tabela 3 mostra os desempenhos das alternativas à luz dos critérios estabelecidos.

Tabela 3 - Dados das alternativas à luz dos critérios

Alternativas	Precisão	Sensibilidade	Tempo em segundos
KNN	39,6	19,8	4,5
SVM	71,5	34,6	7,5
RF	67,2	62,6	5,2
GBM	66,3	61	4,7

Fonte: Autores (2021)

#### 5. Aplicação do método MELCHIOR

A tabela 4 mostra os desempenhos das alternativas à luz dos critérios estabelecidos, bem como os limiares de preferência estrita, fraca e veto, estabelecidos em conjunto com especialistas da área de ML. Ressalta-se que Precisão e Sensibilidade são critérios de maximização, ao passo que o tempo de processamento, de minimização.



Tabela 4 - Matriz de performance

Alternativas	Precisão (Max.)	Sensibilidade (Max.)	Tempo em segundos (Min.)
KNN	39,6	19,8	4,5
SVM	71,5	34,6	7,5
RF	67,2	62,6	5,2
GBM	66,3	61	4,7
q	10	13	0,5
p	20	20	1
v	40	50	4

Fonte: Autores (2021)

Após definição das alternativas, critérios, limiares de preferência e veto, pode-se aplicar o método MELCHIOR. A tabela 5 ilustra as relações de sobreclassificação, baseado em Leclercq (1984):

Tabela 5 - Estabelecimento das relações de sobreclassificação


Avaliação paritária	Precisão	Sensibilidade	Tempo	Relação de sobreclassificação
KNN/SVM	P <sup>-</sup>	Q <sup>-</sup>	P <sup>+</sup>	SVM S <sub>f</sub> KNN
KNN/RF	P <sup>-</sup>	P <sup>-</sup>	Q <sup>+</sup>	RF S <sub>F</sub> KNN
KNN/GBM	P <sup>-</sup>	P <sup>-</sup>	I	GBM S <sub>F</sub> KNN
SVM/RF	I	P <sup>-</sup>	P <sup>-</sup>	RF S <sub>F</sub> SVM
SVM/GBM	I	P <sup>-</sup>	P <sup>-</sup>	GBM S <sub>F</sub> SVM
RF/GBM	I	I	Q <sup>-</sup>	GBM S <sub>f</sub> RF

Fonte: Autores (2021)

Onde S<sub>F</sub> representa sobreclassificação forte e S<sub>f</sub> ilustra uma relação de superação fraca entre as alternativas.

Assim, com as relações de sobreclassificação entre as alternativas devidamente estabelecidas, é possível gerar um grafo de superação (Figura 2).

Figura 2 - Grafo representando as relações de sobreclassificação entre as alternativas



Fonte: Autores (2021)

A origem das arestas representa a alternativa que sobreclassifica, enquanto o destino, a sobreclassificada. Setas pontilhadas retratam relações de superação fraca ( $S_f$ ), ao passo que as contínuas simbolizam relações de superação fortes ( $S_F$ ).

Analisando o grafo, chega-se à relação de sobreclassificação final, de acordo com Leclercq (1984):

- GBM } RF } SVM } KNN.

Face ao exposto, a alternativa GBM pode ser considerada como a alternativa mais indicada a ser selecionada como algoritmo para a tarefa de classificação em ML. Analisando as razões que justificam essa escolha, observa-se que as alternativas GBM e RF apresenta bons desempenhos em todos os critérios analisados, com relações de indiferença nos critérios precisão e sensibilidade.

Nota-se que o critério que definiu a escolha da alternativa GBM foi o tempo de processamento, definindo a relação de sobreclassificação fraca entre as duas melhores alternativas em favor do algoritmo GBM.

## 6. Conclusão

A tarefa de classificação em ML contribui para a previsão e entendimento de resultados em diversos setores. O método MELCHIOR apoiou, de forma eficaz, a decisão na escolha de um algoritmo classificador. A alternativa escolhida, *Gradient Boosting Decision Tree*, foi

selecionada como o algoritmo mais indicado, tendo seu resultado justificado por um bom desempenho em todos os critérios avaliados, o que fornece credibilidade ao resultado alcançado.

A aplicação do método MELCHIOR ocorreu em um contexto no qual os decisores alegaram grande dificuldade em elicitare os pesos dos critérios, o que justifica a opção por um método de AMD que não apresente interações e que possibilite a análise das alternativas sem atribuição de pesos aos critérios.

Em face ao exposto, ficou claro que a metodologia ora apresentada pode ser utilizada para resolução de problemas dos mais variados tipos, tendo em vista que apresenta um algoritmo simples, flexível, confiável e rápido. Os trabalhos futuros poderiam abordar análises comparativas ou modelagens híbridas do método MELCHIOR com outras ferramentas de AMD, para o apoio à tomada de decisão de alto nível em problemas de nível tático, operacional, estratégico e político.

## Referências

ALI, R.; LEE, S.; CHUNG, T. C. Accurate multi-criteria decision making methodology for recommending machine learning algorithm. **Expert Systems with Applications**, v. 71, p. 257–278, 2017.

ALTERKAVI, S.; ERBAY, H. Novel authorship verification model for social media accounts compromised by a human. **Multimedia Tools and Applications**, 2021.

BANDEIRA, M. C. G. S. P. *et al.* Business model in an agricultural community: Application of Soft Systems Methodology and Strategic Choice Approach. 2018.

CHECKLAND, P. Systems thinking, systems practice: includes a 30-year retrospective. **Journal-Operational Research Society**, v. 51, n. 5, p. 647, 2000.

CHECKLAND, P. B. Systems Theory. **Systems Practice**, 1981.

COSTA, I. P. DE A. *et al.* Choosing a hospital assistance ship to fight the Covid-19 pandemic. **Revista de Saude Publica**, v. 54, 2020.

COSTA, I. P. DE A. *et al.* 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 Latin America Transactions**, v. 19, n. 6, p. 1099–1106, 2021.

GHORBANZADEH, O. *et al.* Forest fire susceptibility and risk mapping using social/infrastructural vulnerability and environmental variables. **Fire**, v. 2, n. 3, p. 1–27, 2019.

GOMES, L.; GOMES, C. F. S. **Princípios e métodos para a tomada de decisão: Enfoque multicritério** São Paulo: Atlas, , 2019.

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**, 2021.

- GUO, M. *et al.* A hybrid machine learning framework for analyzing human decision-making through learning preferences. **Omega (United Kingdom)**, v. 101, 2021.
- KARTAL, H. *et al.* An integrated decision analytic framework of machine learning with multi-criteria decision making for multi-attribute inventory classification. **Computers and Industrial Engineering**, v. 101, p. 599–613, 2016.
- KOU, G. *et al.* Evaluation of classification algorithms using MCDM and rank correlation. **International Journal of Information Technology & Decision Making**, v. 11, n. 01, p. 197–225, 2012.
- LECLERCQ, J. Propositions d’extension de la notion de dominance en présence de relations d’ordre sur les pseudo-critères: la méthode MELCHIOR. **JORBEL-Belgian Journal of Operations Research, Statistics, and Computer Science**, v. 24, n. 1, p. 32–46, 1984.
- MARTEL, J.-M.; MATARAZZO, B. Other outranking approaches. In: **Multiple Criteria Decision Analysis**. [s.l.] Springer, 2016. p. 221–282.
- MINGERS, J.; ROSENHEAD, J. Problem structuring methods in action. **European journal of operational research**, v. 152, n. 3, p. 530–554, 2004.
- MOHAMMED, M. A. *et al.* Benchmarking Methodology for Selection of Optimal COVID-19 Diagnostic Model Based on Entropy and TOPSIS Methods. **IEEE Access**, v. 8, p. 99115–99131, 2020.
- MOREIRA, M. Â. L. *et al.* **PROMETHEE-SAPEVO-M1 a Hybrid Modeling Proposal: Multicriteria Evaluation of Drones for Use in Naval Warfare**. International Joint conference on Industrial Engineering and Operations Management. **Anais...Military Institute of Engineering (IME)**, Urca, RJ 22290-270, Brazil: Springer, 2020. Disponível em: <[https://www.scopus.com/inward/record.uri?eid=2-s2.0-85097128127&doi=10.1007%2F978-3-030-56920-4\\_31&partnerID=40&md5=7942c4f2d9cfee9521babeefb41e06f4](https://www.scopus.com/inward/record.uri?eid=2-s2.0-85097128127&doi=10.1007%2F978-3-030-56920-4_31&partnerID=40&md5=7942c4f2d9cfee9521babeefb41e06f4)>
- MOUSAVI, M. M.; LIN, J. The application of PROMETHEE multi-criteria decision aid in financial decision making: Case of distress prediction models evaluation. **Expert Systems with Applications**, v. 159, 2020.
- OLIVEIRA, A. S. *et al.* Multiple Criteria Decision Making and Prospective Scenarios Model for Selection of Companies to Be Incubated. **Algorithms**, v. 14, n. 111, 30 mar. 2021.
- PANAPAKIDIS, I. P.; CHRISTOFORIDIS, G. C. Optimal selection of clustering algorithm via Multi- Criteria Decision Analysis (MCDA) for load profiling applications. **Applied Sciences (Switzerland)**, v. 8, n. 2, 2018.
- RASCHKA, S.; MIRJALILI, V. Python Machine Learning: Machine Learning and Deep Learning with Python. **Scikit-Learn, and TensorFlow. Second edition ed**, 2017.
- ROSE, J. Soft systems methodology as a social science research tool. **Systems Research and Behavioral Science: The Official Journal of the International Federation for Systems Research**, v. 14, n. 4, p. 249–258, 1997.
- ROSENHEAD, J.; MINGERS, J. **Rational analysis for a problematic world revisited: Problem structuring methods for complexity, uncertainty and conflict**. [s.l.] Wiley Chichester, 2001.
- SANTOS, M. DOS *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.
- SANTOS, M. DOS; COSTA, I. P. DE A.; GOMES, C. F. S. Sensitivity analysis of multicriteria decision between standard deviation and average in the selection of construction of warships: a new approach to the AHP method. **International Journal of the Analytic Hierarchy Process**, 2021.
- SONG, Y.; PENG, Y. A MCDM-based evaluation approach for imbalanced classification methods in financial risk prediction. **IEEE Access**, v. 7, p. 84897–84906, 2019.

TENÓRIO, F. M. *et al.* Navy Warship Selection and Multicriteria Analysis: The THOR Method Supporting Decision Making. In: **International Joint conference on Industrial Engineering and Operations Management**. [s.l.] Springer, 2020. p. 27–39.

WILSON, V. H. *et al.* Ranking of supplier performance using machine learning algorithm of random forest. **International Journal of Advanced Research in Engineering and Technology**, v. 11, n. 5, p. 298–308, 2020.