# Algoritmos Evolutivos Aplicados à Tomada De Decisão Em Grupo

**Lucas Daniel Del Rosso Calache**
Departamento de Engenharia de Produção, EESC, Universidade de São Paulo - USP
Avenida Trabalhador são-carlense, 400, CEP 13566-590 - São Carlos – SP
lucascalache@gmail.com

**Victor Claudio Bento Camargo**
Departamento de Engenharia de Produção, Universidade Federal de São Carlos - UFSCar
Rod. Washington Luís, km 235, CEP 13565-905 - São Carlos - SP.
victor.camargo@dep.ufscar.br

**Lauro Osiro**
Departamento de Engenharia de Produção, Universidade Federal do Triangulo Mineiro - UFTM
Av. Randolfo Borges Júnior, 1400, CEP 38064-200, Uberaba - MG
lauro.osiro@uftm.edu.br

**Luiz Cesar Ribeiro Carpinetti**
Departamento de Engenharia de Produção, EESC, Universidade de São Paulo - USP
Avenida Trabalhador são-carlense, 400, CEP 13566-590 - São Carlos – SP
carpinet@sc.usp.br

**RESUMO**

Para lidar com a complexidade de problemas de tomada de decisão em grupo, algoritmos evolutivos vêm sendo aplicados na literatura. Os algoritmos genéticos (GA) e de otimização por enxame de partículas (PSO) se destacam por serem os algoritmos evolutivos mais utilizados nesses problemas. Dessa forma, o presente estudo realiza uma revisão sistemática da literatura com o objetivo de apresentar o estado da arte sobre as aplicações dos algoritmos GA e PSO nos problemas de tomada de decisão em grupo. Os resultados obtidos com a estratificação dos artigos selecionados mostram um crescimento do número de publicações dessas aplicações nos últimos anos; relevância do uso de conjuntos *fuzzy* e de propostas de busca de consenso entre os tomadores de decisão. Desta forma, esses resultados permitiram a identificação de oportunidades de estudos futuros.

**PALAVRAS CHAVE. Algoritmos evolutivos. Decisão em grupo. Revisão sistemática.**

**Metaheurísticas. Apoio à Decisão Multicritério.**

**ABSTRACT**

To deal with the complexity of group decision making problems, evolutionary algorithms have been applied in the literature. Genetic algorithms (GA) and particle swarm optimization (PSO) stand out as the most used evolutionary algorithms in these problems. In this way, this study performs a systematic literature review with the purpose to present the state of the art on the applications of GA and PSO algorithms in group decision making problems. The results obtained through the stratification of the selected articles show a growth in the number of published papers on these theme in recent years; relevance of the use of fuzzy sets and proposals for consensus research process among the decision makers. In this way, the findings allowed the identification of opportunities for future studies.

**KEYWORDS. Evolutionary algorithms. Group decision. Systematic review.**

**Metaheuristics. Multicriteria Decision Support.**

## 1. Introdução

A tomada de decisão é uma das principais funções dos gestores de qualquer organização que convivem com um ambiente cada vez mais complexo e competitivo [Nooraie, 2012]. Devido à crescente complexidade dos problemas de tomada de decisão no mundo real, a tomada de decisão em grupo tem sido aplicada de forma eficaz e eficiente para a resolução de problemas da atualidade [Ren et al 2021]. Uma decisão de grupo é definida como um problema de decisão compartilhado por duas ou mais partes interessadas que devem fazer uma escolha pela qual todas as partes terão alguma responsabilidade [Kilgour et al. 2010]. Dessa forma, a tomada de decisão em grupo é uma atividade que consolida e agrega as diferentes opiniões de um grupo de tomadores de decisão a fim de encontrar a melhor solução para um problema [Zhang et al. 2019].

Para lidar com o processo de tomada de decisão em grupo várias abordagens vêm sendo propostas e aplicadas em diferentes problemas. Essas abordagens aplicam técnicas de forma isoladas ou combinadas para considerar a opinião de especialistas sobre o desempenho de alternativas em relação à critérios com diferentes níveis de importância. Dessa forma, várias variáveis e parâmetros devem ser considerados nesse tipo de problema, o que pode trazer grande complexidade para sua resolução [de Almeida et al. 2012].

A complexidade desses tipos de problemas pode ser tratada por meio da aplicação de algoritmos evolutivos que apresentam uma alta eficiência com menor sensibilidade em relação ao tamanho do problema em comparação com as técnicas tradicionais, diminuindo assim o tempo de resolução dos problemas [Alvarez et al. 2015]. Em algoritmos evolutivos, os conjuntos de valores gerados são ajustados de acordo com um procedimento evolutivo iterativo, o que dispensa a consideração de uma relação explicita entre funções objetivo e restrições. Além disso, estes métodos também podem ser facilmente implementados em problemas de otimização discretos, contínuos e mistos com pequenas adaptações, o que favorece sua ampla aplicação em diversos problemas de engenharia [Andrab et al. 2017].

Dentre os algoritmos evolutivos existentes, o algoritmo genético (Genetic Algorithm - GA) e o algoritmo de otimização por enxame de partículas (Particle swarm optimization - PSO) se destacam na literatura. O PSO é tido como um dos algoritmos heurísticos mais simples em termos de complexidade de equações. Já o GA é um algoritmo de otimização baseado na genética da evolução natural e de busca global, evitando soluções localmente ideais [Ouarda e Bouamar, 2014]. Dessa forma, esses dois tipos de algoritmos evolutivos se tornaram os mais aplicados em diversos contextos [Abdelkader et al. 2019; Katoch et al. 2020; Wu et al. 2018], inclusive em problemas de tomada de decisão em grupo. Entretanto, nenhum estudo observado até o momento apresenta uma revisão da literatura sobre esse tema.

Dessa forma, o presente estudo tem como objetivo apresentar o estado da arte sobre a aplicação de GA e PSO em problemas que envolvem a tomada de decisão em grupo por meio de uma revisão sistemática da literatura. Após a introdução, o presente artigo está estruturado com a Seção 2 apresentando os algoritmos evolutivos com detalhamento do GA e do PSO. A metodologia aplicada na revisão sistemática é apresentada pela Seção 3. Os resultados obtidos nesse levantamento são apresentados e discutidos na Seção 4. Finalmente, a Seção 5 apresenta a conclusão do estudo e as oportunidades de estudos futuros.

## 2. Algoritmos Evolutivos

Algoritmos evolutivos são algoritmos desenvolvidos com inspirações biológicas que fornecem soluções não otimizadas, mas de boa qualidade para problemas cuja resolução pode ser muito lenta ou impraticável por métodos exatos [Pétrowski e Ben-Hamida 2017]. Segundo Yu e Gen (2010), algoritmos evolutivos são algoritmos que realizam tarefas de otimização ou aprendizagem com a capacidade de evoluir e possuem três principais características:

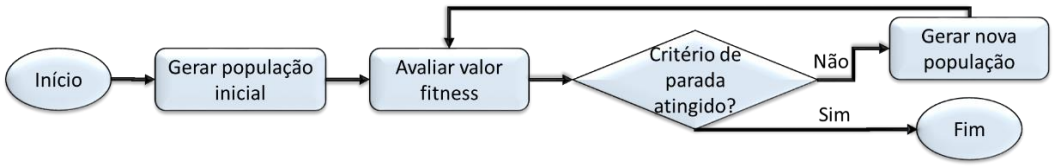
i) Baseado em população: o algoritmo mantém um grupo de soluções, chamada de população, que busca boas soluções ou aprender o problema de forma paralela. A população é tida como um princípio básico do processo de evolução.

ii) Orientado para a aptidão: cada solução em uma população é chamada de indivíduo. Cada indivíduo tem sua representação dada pelo gene, também chamada de código, e a avaliação de desempenho conhecida como valor fitness. Os algoritmos preferem os indivíduos mais aptos com melhores valores fitness, o que é tido como um fundamento do processo de otimização e convergência.

iii) Orientado por variações: os indivíduos serão submetidos a um número de operações de variações para imitar mudanças com inspirações biológicas, que são fundamentais para explorar o espaço de soluções.

A Figura 1 apresenta o processo genérico adotado pelos algoritmos evolutivos. Após a inicialização, a população é avaliada e os critérios de parada são verificados. Se nenhum dos critérios de parada é cumprido, uma nova população é gerada novamente e o processo é repetido até que um ou mais dos critérios de parada sejam atendidos. Um critério de parada pode ser estático ou dinâmico. O critério de parada estático permite que um algoritmo funcione para um determinado número de iterações. Já um exemplo de critério de parada dinâmico é repetir o processo até que as k melhores soluções estejam dentro de algum percentual de melhores soluções encontradas [Kachitvichyanukul 2012].

**Figura 1. Processo genérico de um algoritmo evolutivo.**




## 2.1. Algoritmo genético (*Genetic Algorithm* - GA)

Proposto inicialmente por John Holland (1975), o desenvolvimento de algoritmos genéticos faz parte da área de aprendizado de máquinas da computação evolutiva [Koza 1992]. GA se inspira no fenômeno da evolução natural e imita a ideia darwiniana de sobrevivência do indivíduo mais apto [Meena e Minz 2019]. Dessa forma, o algoritmo genético é um algoritmo de busca probabilística baseado na mecânica da seleção natural e na genética [Kumar et al. 2010]. Os princípios básicos para a elaboração de um algoritmo genético são apresentados a seguir [Meena e Minz 2019; Kumar et al. 2010]:

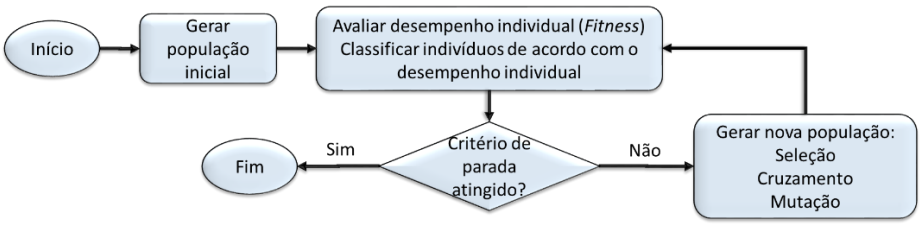
Inicialização da população: o algoritmo genético é inicializado com um conjunto de soluções chamado população. Cada solução é representada por um cromossomo e o tamanho da população é preservado ao longo de cada geração;

Cálculo da aptidão: em cada geração o desempenho ou aptidão de cada cromossomo é avaliado de acordo com uma função de avaliação, ou seja, os cromossomos que irão compor a geração seguinte são selecionados probabilisticamente com base no desempenho. Um operador de seleção escolhe os cromossomos de uma população à qual é aplicado um operador genético (mutação ou cruzamento).

Seleção: várias abordagens podem ser utilizadas para definir os cromossomos "pais" que integrarão o processo de cruzamento. Após a seleção dos “cromossomos pais”, o operador do cruzamento é aplicado para procurar melhores descendentes. Alguns dos cromossomos selecionados "cruzam" e produzem descendentes que visam preservar e combinar as melhores características dos pais para desenvolver novas e melhores soluções. O operador de cruzamento procura também explorar o espaço de solução em diferentes direções para obter populações diferentes.

Mutação: ao produzir os descendentes, o processo de mutação aleatória também ocorre. O operador de mutação é aplicado para obter uma melhor exploração do espaço de solução, tentando evitar, tanto quanto possível, picos e vales de soluções locais.

**Figura 2. Processo genérico para um algoritmo genético.**




## 2.2. Otimização por enxame de partículas (*Particle Swarm Optmization* - PSO)

Proposto inicialmente por Kennedy e Eberhart (1995), o PSO é uma ferramenta de otimização estocástica que se baseia no comportamento social dos bandos de aves e dos cardumes de peixes, em que membros de um grupo tendem a seguir a liderança do melhor do grupo [Choudhary et al. 2020]. Em PSO, uma solução é representada como uma partícula, e a população de soluções pode ser traduzida como enxame de partículas. Cada partícula tem duas propriedades principais: a posição e a velocidade. As partículas se movem para uma nova posição de acordo com a velocidade. Para cada nova posição alcançada, a melhor posição de cada partícula e a melhor posição do grupo de soluções são atualizados. A velocidade de cada partícula é ajustada de acordo com suas experiências no algoritmo. O processo é repetido até que seja atingido um critério de parada [Kachitvichyanukul 2012].

Um tutorial para aplicação do PSO é apresentado em Marini e Walczak (2015). A posição de uma partícula pode ser descrita por meio de um vetor $x_i = \{x_{i1}, x_{i2}, x_{i3}, x_{iD}\}$, em que $D$ representa o número de parâmetros a serem otimizados. Já a população de $N$ candidatos que constitui o enxame é representado por $X = \{X_1, X_2, X_3, \dots, X_N\}$. Para cada nova iteração $t + 1$ do algoritmo na busca da melhoria da solução de um problema, as partículas definem a trajetória no espaço dos parâmetros por meio da Eq. 1.

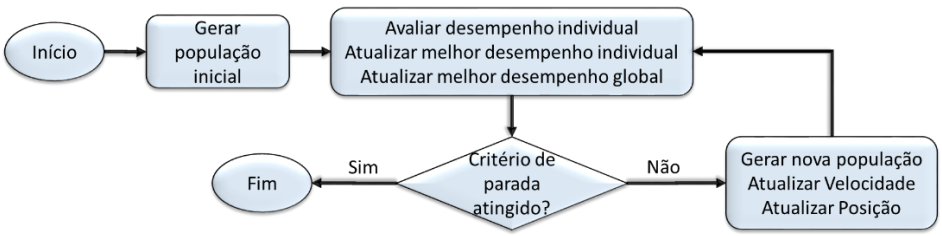
$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (1)$$

No qual $v_i$ representa o vetor de velocidade dos componentes da partícula $i$, que direcionam a trajetória das partículas no espaço de soluções conforme representado pela Eq. 2.

$$v_i(t+1) = v_i(t) + c_1\big(p_i - x_i(t)\big)R_1 + c_2\big(g - x_i(t)\big)R_2 \quad (2)$$

Em que $p_i$ é a coordenada da melhor solução obtida pela partícula $i$ até o momento; $g$ é a melhor solução global obtida por todo o enxame até o momento; $c_1$ e $c_2$ são constantes de aceleração respectivamente chamados de coeficiente cognitivo e coeficiente social com $0 \leq c_1, c_2 \leq 4$, e definem a magnitude do passo adotado por uma partícula na direção de sua melhor solução pessoal e melhor solução global. Para que os componentes sociais e cognitivos possuam uma influência de caráter estocástico sobre a regra de atualização da velocidade na Eq. 2, duas matrizes diagonais de números aleatórios $R_1$ e $R_2$ são geradas a partir de uma distribuição uniforme [0, 1]. Dessa forma, as trajetórias traçadas pelas partículas são de natureza semi-randômica, pois derivam da contribuição da atração sistemática para as melhores soluções individuais e globais e considera o peso estocástico desses dois termos de acelerações. O procedimento geral básico seguido pelo PSO é representado pela Figura 3.

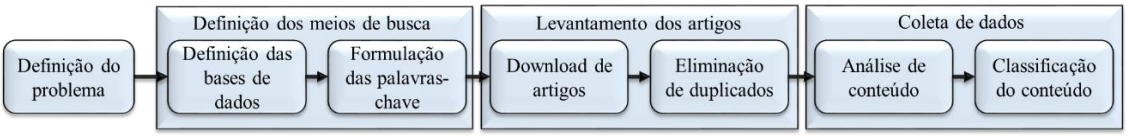
**Figura 3. Processo genérico para um algoritmo PSO.**



## 3. Metodologia Aplicada na Revisão Sistemática

Para apresentar o estado da arte sobre a aplicação dos algoritmos evolutivos GA e PSO em problemas de tomada de decisão em grupo, uma revisão sistemática foi conduzida. As revisões sistemáticas diferem das análises narrativas e exploratórias, adotando um processo replicável, científico e transparente [Tranfield et al. 2003]. Os passos seguidos no presente estudo são ilustrados pela Figura 4, seguem o procedimento apresentado em Calache et al. (2020) e são descritos a seguir:

**Figura 4. Passos seguidos na revisão sistemática.**




- Definição do problema: no presente estudo, deseja-se analisar as aplicações de algoritmos evolutivos nos problemas de decisão em grupo. Para isso, os principais algoritmos evolutivos aplicados ao tema foram considerados com o objetivo de entender o estado da arte e verificar possibilidades de avanços no tema;
- Definição dos meios de busca: As bases de dados utilizadas para o levantamento foram Web of Science (apps.webofknowledge.com) e SCOPUS (www.scopus.com), devido aos seus vastos acervos relacionados à gestão de operações. O conjunto de palavras {(*"Genetic Algorithm" AND "Group Decision") OR* (*"Particle Swarm Optimization" AND "Group Decision"*)} foi aplicado, retornando um total de 104 artigos na base Web of Science e 107 artigos na SCOPUS até o final de março de 2021.
- Levantamento dos artigos: Todos os artigos de periódicos, congressos e livros retornados da pesquisa até o final de março de 2021 foram avaliados. Inicialmente as duplicidades foram eliminadas, e em seguida, o conteúdo dos artigos foram analisados para garantir a seleção dos artigos que realmente estão no escopo de pesquisa. A estratégia de busca foi ler inicialmente o resumo e palavras chaves, e em caso de dúvidas, as seções seguintes eram lidas para análise do seu escopo. Caso o artigo não aplicasse o GA ou PSO em um problema considerando um grupo de tomadores de decisão, o artigo era excluído da análise. No total 97 artigos foram selecionados para a fase seguinte.
- Coleta de dados: Os 97 artigos selecionados foram lidos e classificados de acordo com o ano de publicação, país de origem da universidade do primeiro autor, periódico, número de citações, tema de aplicação, busca por consenso ou não, representação da informação, técnica combinada, se aborda um problema multicritério ou não, número de tomadores de decisão considerados e número de critérios avaliados.

## 4. Resultados e discussões

O desenvolvimento dos algoritmos evolutivos teve início na década de 60 [Yu e Gen 2010], porém, as aplicações em problemas de decisão de grupo iniciaram somente a partir da década de 90 [Aiken 1997]. Desde então, o número de estudos relacionados ao tema apresenta um crescimento ao longo dos anos, conforme demonstrado pelo gráfico na Figura 5. Esse crescimento reflete a ampla flexibilidade de aplicação dos algoritmos GA e PSO na resolução de diferentes tipos de problemas.

Apesar do crescimento no número de publicações e grande difusão dos algoritmos, existe uma concentração dos estudos sobre o tema em poucos países. A Figura 6 apresenta um gráfico com o número de artigos publicados de acordo com a nacionalidade da universidade do primeiro autor. Até o período considerado nessa revisão, apenas 17 países apresentaram estudos publicados sobre o tema, com uma grande colaboração da China com 50,5% do total dos estudos, seguida pelo Estados Unidos com 9,3% de participação no levantamento. A identificação desses países pode ser útil para a prospecção de parcerias para colaborações internacionais.

**Figura 5. Número de artigos publicados em cada período de anos.**

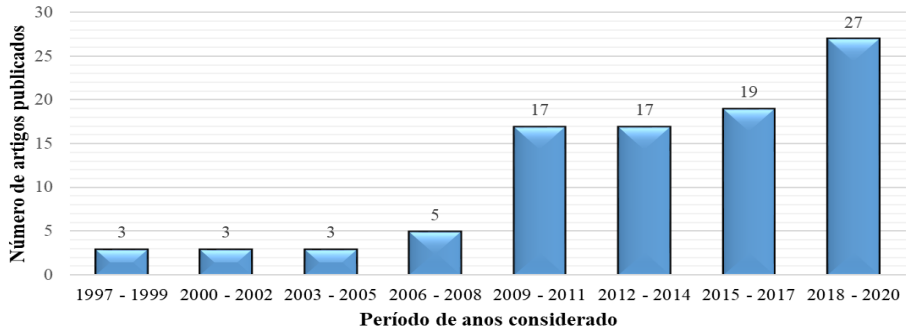
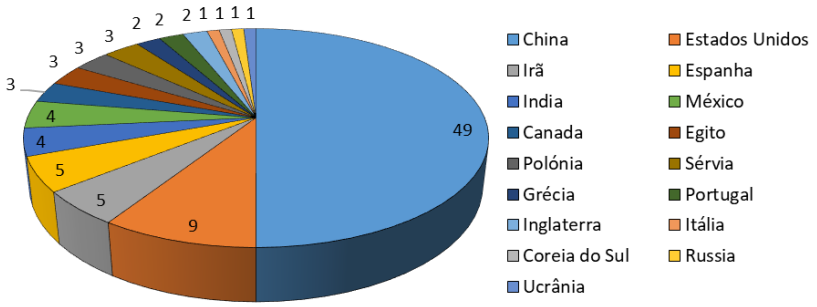
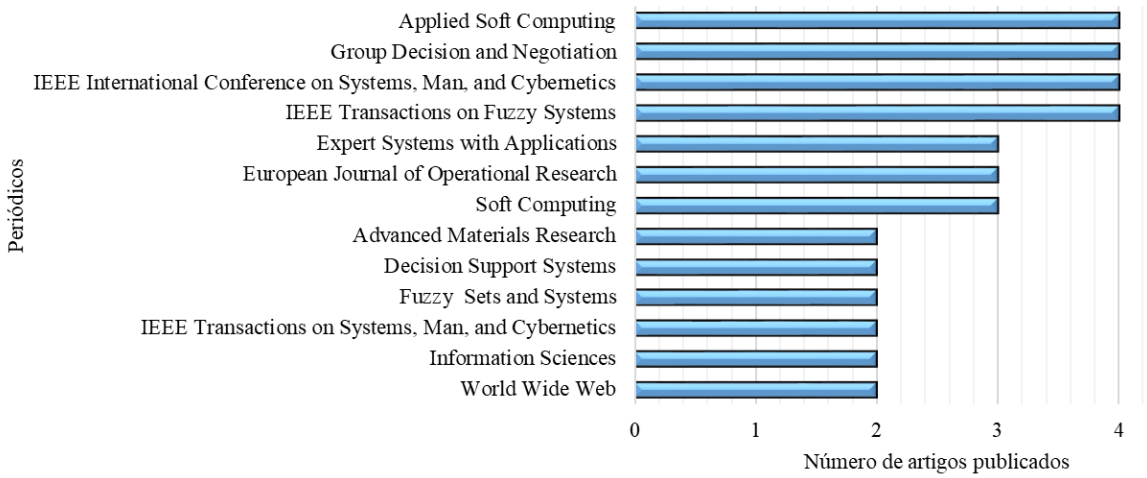



**Figura 6. Participação dos países na publicação de artigos.**




Devido à flexibilidade de aplicação desses algoritmos evolutivos, 55 periódicos e 17 congressos diferentes apresentam artigos encontrados nesse levantamento. É possível verificar uma concentração de artigos em periódicos focados no desenvolvimento e aplicação de modelos de tomada de decisão, principalmente envolvendo técnicas *Soft Computing* e representações de informação *fuzzy*. Entretanto, apenas 13 periódicos (18%) apresentam mais de um artigo relacionado ao tema em discussão, conforme ilustrado no gráfico da Figura 7. Esse levantamento pode contribuir para os autores identificarem os periódicos mais complacentes com o tema abordado, e assim direcionarem suas submissões de artigos.

**Figura 7. Número de artigos publicados por periódicos.**



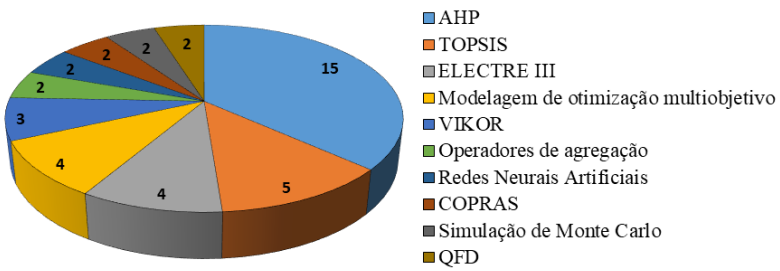

Embora vários problemas são apresentados e tratados pelos estudos, apenas 9 tipos de problemas são apresentados por mais de um estudo. Esses principais problemas abordados são apresentados e descritos pela Tabela 1.

**Tabela 1. Principais problemas abordados pelos estudos.**

| Tipos de problemas abordados | Artigos publicados |
|---|---|
| **Seleção de Fornecedores:** processo de avaliação e seleção de fornecedores, que são atividades relacionadas com a função de Compras, estabelecendo a relação de suprimento de materiais e serviços para a empresa. | Abdel-Baset et al (2019); Cabrerizo et al. (2013); Hajipour et al. (2020); Hao et al. (2020); Inti e Tandon (2017); Liu et al. (2007); Xu et al. (2010). |
| **Seleção de investimentos:** envolve a avaliação e seleção de carteiras de investimento ou priorização de investimentos. | Cabrerizo et al. (2013); Tan et al. (2018); Xu e Cai (2012); Zainashev (2010); Zhou et al. (2020). |
| **Seleção de projetos:** avaliação e seleção dos projetos disponíveis para a seleção do portfólio que trará maior benefício para a organização. | Álvarez et al. (2020); Liang et al. (2013); Piroozmand e Boroushaki (2016); Renzi e Leali (2016); Yang e Jiang (2009). |
| **Fornecimento de água:** envolve o gerenciamento do processamento e fornecimento de água para a população. | Álvarez et al. (2020b); Li et al. (2010); Li et al. (2011); Ghodsi et al. (2016). |
| **Seleção de pessoas:** avaliação e seleção de recursos humanos para determinada atividade ou função. | Lin e Hsu (2010); Liu et al. (2019); Wu et al. (2018). |
| **Planos de emergência:** avaliação e seleção de soluções e planos de contingência para respostas em situações emergências. | Li et al. (2014); Liu et al. (2020); Zhang et al. (2017). |
| **Desenvolvimento de produtos:** avaliação de design e características técnicas no desenvolvimento de produtos. | Liang et al. (2015); Liu et al. (2010); Renzi e Leali (2016). |
| **Localização de facilidades:** avaliação e seleção de pontos para a instalação de facilidades. | Simić et al. (2017); Tadić et al. (2019). |
| **Desenvolvimento de navios:** avaliação e seleção de características técnicas para navios. | Hou et al. (2011); Ölçer et al. (2006). |

Na maioria dos estudos encontrados (53%), os algoritmos evolutivos GA e PSO são combinados com outras técnicas de tomada de decisão, principalmente com o objetivo de propor um modelo de decisão multicritério. O gráfico na Figura 8 apresenta as técnicas que foram encontradas em mais de um artigo, com ênfase para as técnicas multicritério AHP (*Analytic Hierarchy Process*) aplicada em 15% dos estudos seguido pelo *Technique for Order of Preference by Similarity to Ideal Solution* - TOPSIS (5%). Nesse contexto, destacamos o artigo de Abdelkader et al. (2019) que combina ambos os algoritmos evolutivos com cinco diferentes técnicas multicritérios. Já o artigo com o maior número de citações combina o GA com o ELECTRE III [Leyva-Lopez e Fernandez-Gonzalez 2003]. Por outro lado, o artigo que apresenta o maior índice de citação, que leva em conta a razão entre o número de citações e o tempo de disponibilidade do artigo, apresenta a combinação do GA com as técnicas multicritério ANP e VIKOR para lidar com um problema de seleção de fornecedores sustentáveis [Abdel-Baset 2019].

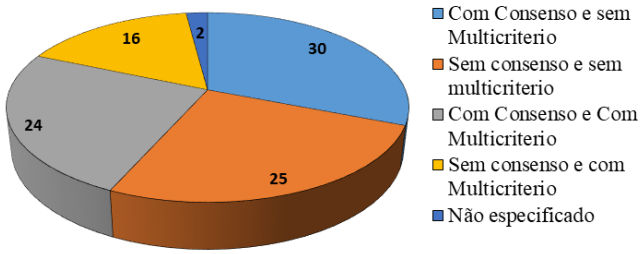
**Figura 8 - Técnicas aplicadas em conjunto com os algoritmos evolutivos.**




Um ponto interessante a ser observado nos estudos é a maior aplicação dos algoritmos em problemas que buscam o consenso dos tomadores de decisão, conforme representado no gráfico da Figura 9. Dessa forma, os modelos propostos buscam minimizar a divergência entre os tomadores de decisão envolvidos no processo de decisão, evitando assim, futuras contestações sobre o resultado obtido [Alvarez et al. 2020; Mohamadi et al. 2019]. Entretanto, poucos estudos

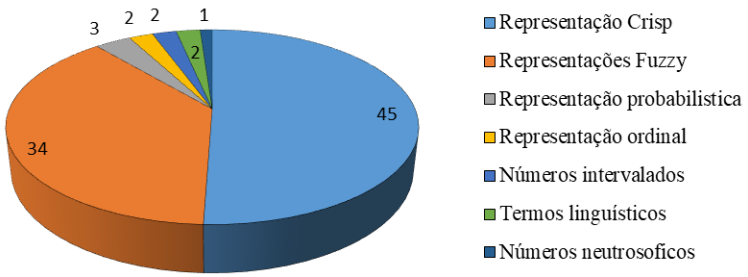
combinam abordagens de consenso com técnicas multicritério, evidenciando novas oportunidades de aplicações de técnicas tais como *ELECTRE TRI* e *TOPSIS Class* utilizadas na categorização de alternativas. Além disso, não foram observados estudos que apliquem métodos de estruturação de problemas, tais como *Value Focused Thinking* (VFT) e *Strategic options development and analysis* (SODA), que podem contribuir para uma melhor compreensão do problema avaliado.

**Figura 9 – Distribuição dos artigos de acordo com a abordagem adotada.**




De acordo com as características de cada problema apresentado, diferentes tipos de representações de informação são utilizados pelos estudos. Para lidar com os julgamentos subjetivos dos tomadores de decisão, uma crescente parcela dos estudos utiliza as representações *fuzzy* de informação. Entretanto, a maioria dos estudos utilizam números "*crisp*" para representar os dados analisado, conforme detalhado no gráfico da Figura 10. Dentre os artigos selecionados, nenhum estudo utiliza representações que são capazes de lidar com imprecisões advindas da hesitação dos tomadores de decisão, tais como o *Hesitant Fuzzy*, o *Dual Hesitant Fuzzy* e o *Double Hierarchy Hesitant Fuzzy*. Dessa forma, uma oportunidade de estudo futuro identificada é a utilização dessas novas representações de informações em algoritmos evolutivos, possibilitando aos modelos de tomada de decisão lidarem com mais tipos de fontes de imprecisão advindas da linguagem natural utilizada na coleta de julgamentos.

**Figura 10 - Representações de informação utilizadas pelos artigos.**




Outros pontos levantados pelo presente estudo foi o número de tomadores de decisão e o número de critérios considerados pelos artigos selecionados na revisão. Esses valores interferem diretamente na complexidade computacional dos algoritmos implementados nos modelos de decisão propostos nos estudos. Esses dados são importantes para analisar as principais característica e demandas desses modelos. A grande maioria dos estudos lidam com uma pequena quantidade de tomadores de decisão, conforme pode ser visto no gráfico da Figura 11. Dessa forma 84 % dos estudos consideram 10 ou menos tomadores de decisão, sendo 64% referentes a 6 ou menos. Apenas 7 % dos artigos lidam com um grupo de 20 ou mais tomadores de decisão. Destaca-se o estudo de Chen et al. (2011) que testa 13 tamanhos distintos de grupos de tomadores de decisão, variando entre 3 e 25 participantes.

Conforme apresentado anteriormente, a maioria dos estudos não aplicam técnicas multicritério e acabam lidando com um único critério de tomada de decisão. Dentre os artigos que consideram mais de um critério no modelo de decisão, a maioria utiliza menos de 6 critérios (69 %), conforme apresentado pelo gráfico da Figura 12. Além disso, alguns estudos propõem modelos de

decisão genéricos, sem testar a capacidade de lidar com variados números de critérios analisados. Entretanto, os artigos não lidam com o processo de elicitação dos pesos dos critérios e dos tomadores de decisão ao mesmo tempo. Dentre os artigos analisados, destaca-se o estudo de Lee et al. (2012) que lida com a análise de 24 critérios distintos.

**Figura 11. Número de tomadores de decisão considerados nos estudos.**

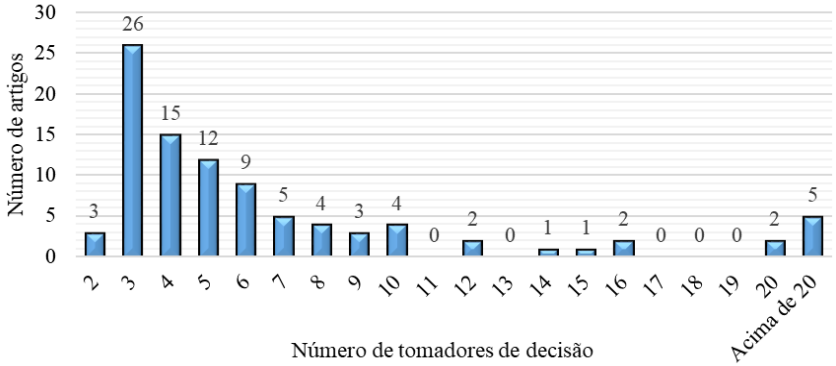
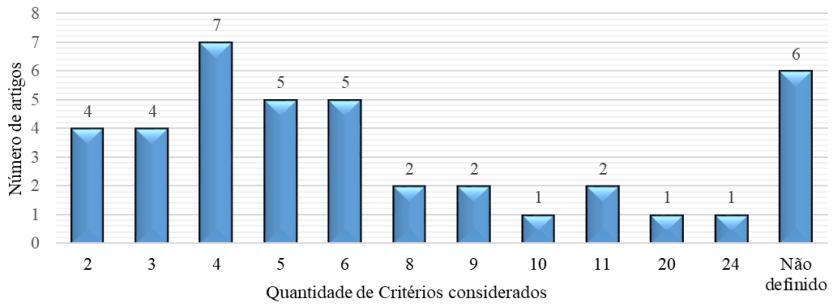



**Figura 12. Número de critérios considerados nos estudos.**




Finalmente, sobre os algoritmos GA e PSO, os principais tipos aplicados são os multiobjetivos MOGA (*multi-objective genetic algorithm*) e MOPSO (*multi-objective particle swarm optimization*) com destaque para o NSGA II (*Non-dominated Sorting Genetic Algorithm*), sendo o algoritmo mais aplicado nos artigos selecionados [Álvarez et al. 2015; Ghodsi et al. 2016; Hajipour et al. 2020; Hao et al. 2020; Kadziński e Tomczyk 2017]. Além disso, identifica-se a oportunidade de combinar outros algoritmos específicos baseados no GA e no PSO para lidar com outros tipos de informação. Por exemplo, o BRKGA (*Biased Random Key Genetic Algorithm*) pode ser combinado com representações *fuzzy* que possuem o intervalo de pertencimento [0,1].

## 5. Conclusões

Este estudo apresenta o estado da arte relacionado a aplicação dos algoritmos evolutivos GA e PSO em problemas de decisão em grupo. Uma revisão sistemática da literatura foi realizada para selecionar os artigos relacionados ao tema. Os artigos selecionados foram avaliados e os dados obtidos foram estratificados para apresentar as informações sobre as aplicações dos algoritmos, e identificar possibilidades de estudos futuros.

O levantamento possibilitou observar a importância do tema que apresenta crescimento no número de estudos realizados ao longo dos anos. Esse crescimento pode ser explicado pela flexibilidade de aplicação dos algoritmos em diversos problemas de tomada de decisão. Além disso, os algoritmos são facilmente combinados com diferentes técnicas de tomada de decisão, possibilitando inclusive combinar diferentes técnicas multicritério. Ademais, diferentes representações de informações foram utilizadas pelos estudos, com destaque para o crescimento das aplicações dos diferentes tipos de conjuntos *fuzzy* que buscam lidar com imprecisões advindas de julgamentos subjetivos dos tomadores de decisão.

Outro ponto a ser destacado é a grande participação dos estudos que buscam um modelo de consenso entre os tomadores de decisão, evitando assim futuras contestações sobre o resultado obtido no processo de tomada de decisão. Finalmente, oportunidades de estudos futuros foram apresentadas ao longo do texto, tais como: a combinação dos algoritmos evolutivos com outras técnicas multicritério, tais como as de categorização; a utilização de métodos de estruturação de problemas combinados com os algoritmos; a utilização de representações hesitantes como dado de entrada dos algoritmos; a aplicação do algoritmo como método de consenso para ponderar o peso dos critérios de tomada de decisão e os pesos dos tomadores de decisão.

**Referências**

Abdel-Baset, M., Chang, V., Gamal, A. e Smarandache, F. (2019). An integrated neutrosophic ANP and VIKOR method for achieving sustainable supplier selection: A case study in importing field. Computers in Industry, 106, 94-110.

Abdelkader, E. M., Marzouk, M. e Zayed, T. (2019). An optimization-based methodology for the definition of amplitude thresholds of the ground penetrating radar. Soft Computing, 23(22), 12063-12086.

Aiken, M. (1997). Artificial neural systems as a research paradigm for the study of group decision support systems. Group Decision and Negotiation, 6(4), 373-382.

Alvarez, P. A., Morais, D. C., Leyva López, J. C. e de Almeida, A. T. (2020). An ELECTRE III based consensus-reaching process to improve a collective solution. International Transactions in Operational Research.

Álvarez, P. A., Morais, D. C., Leyva, J. C. e Almeida, A. T. (2015, March). A multi-objective genetic algorithm for inferring inter-criteria parameters for water supply consensus. In International Conference on Evolutionary Multi-Criterion Optimization (pp. 218-233). Springer, Cham.

Andrab, S. G., Hekmat, A. e Yusop, Z. B. (2017). A review: evolutionary computations (GA and PSO) in geotechnical engineering. Computational Water, Energy, and Environmental Engineering, 6(02), 154.

Cabrerizo, F. J., Herrera-Viedma, E. e Pedrycz, W. (2013). A method based on PSO and granular computing of linguistic information to solve group decision making problems defined in heterogeneous contexts. European Journal of Operational Research, 230(3), 624-633.

Calache, L. D. D. R., Osiro, L. e Carpinetti, L. C. R. (2020). Dual Hesitant Fuzzy: Uma Revisão da Literatura. In *Anais do LII SBPO*, João Pessoa. SOBRAPO.

de Almeida, A. T., Morais, D. C., Costa, A. P. C. S., Alencar, L. H. e Daher, S. D. F. D. Decisão Em Grupo E Negociação, Ed. Atlas, São Paulo.

Ghodsi, S. H., Kerachian, R. e Zahmatkesh, Z. (2016). A multi-stakeholder framework for urban runoff quality management: application of social choice and bargaining techniques. Science of The Total Environment, 550, 574-585.

Hajipour, V., Tavana, M., Santos-Arteaga, F. J., Alinezhad, A. e Di Caprio, D. (2020). An efficient controlled elitism non-dominated sorting genetic algorithm for multi-objective supplier selection under fuzziness. Journal of Computational Design and Engineering, 7(4), 469-488.

Hao, J., Li, J., Wu, D. e Sun, X. (2020). Portfolio optimisation of material purchase considering supply risk–A multi-objective programming model. International Journal of Production Economics, 230, 107803.

Hou, Y. H., Huang, S., Hu, Y. L., Meng, X. Y., Wang, W. Q. e Wang, C. (2011). Group decision making of naval ship principal dimensions based on PSO algorithm. In Advanced Materials Research (Vol. 201, pp. 1233-1237). Trans Tech Publications Ltd.

Inti, S. e Tandon, V. (2017). Integration of data envelopment analysis-based preference aggregation method and α particle swarm optimization technique into group decision model. Journal of Computing in Civil Engineering, 31(1), 04016043.

John, H. (1992). Holland. genetic algorithms. *Scientific american*, *267*(1), 44-50.

Kachitvichyanukul, V. (2012). Comparison of three evolutionary algorithms: GA, PSO, and DE. Industrial Engineering and Management Systems, 11(3), 215-223.

Kadziński, M. e Tomczyk, M. K. (2017). Interactive evolutionary multiple objective optimization for group decision incorporating value-based preference disaggregation methods. Group Decision and Negotiation, 26(4), 693-728.

Katoch, S., Chauhan, S. S. e Kumar, V. (2020). A review on genetic algorithm: past, present, and future. Multimedia Tools and Applications, 1-36.

Kilgour, D. M., Chen, Y. e Hipel, K. W. (2010). Multiple criteria approaches to group decision and negotiation. Trends in multiple criteria decision analysis, 317-338.

Koza, J. R. (1992, December). Evolution of subsumption using genetic programming. In *Proceedings of the First European Conference on Artificial Life* (pp. 110-119).

Kumar, M., Husain, M., Upreti, N. e Gupta, D. (2010). Genetic algorithm: Review and application. Available at SSRN 3529843

Leyva-Lopez, J. C. e Fernandez-Gonzalez, E. (2003). A new method for group decision support based on ELECTRE III methodology. European journal of operational research, 148(1), 14-27.

Li, C., Wang, F., Ma, Z., Wei, X. e Wang, H. Computation method of optimal scheme set for water resources scheduling group decision making based on evolution strategy. In 5th International Conference on Computer Sciences and Convergence Information Technology.

Li, C., Wang, F., Wei, X. e Ma, Z. (2011). Solution Method Of Optimal Scheme Set For Water Resources Scheduling Group Decision-Mahing Based On Multi-Agent Computation. Intelligent Automation & Soft Computing, 17(7), 871-883.

Li, N., Sun, M., Bi, Z., Su, Z. e Wang, C. (2014). A new methodology to support group decision-making for IoT-based emergency response systems. Information systems frontiers, 16(5), 953-977.

Liang, D., Liu, D., Pedrycz, W. e Hu, P. (2013). Triangular fuzzy decision-theoretic rough sets. International Journal of Approximate Reasoning, 54(8), 1087-1106.

Liang, D., Pedrycz, W., Liu, D. e Hu, P. (2015). Three-way decisions based on decision-theoretic rough sets under linguistic assessment with the aid of group decision making. Applied Soft Computing, 29, 256-269.

Lin, C. e Hsu, M. L. (2010). Holistic decision system for human resource capability identification. Industrial Management & Data Systems.

Liu, C. H. (2010). A group decision-making method with fuzzy set theory and genetic algorithms in quality function deployment. Quality & Quantity, 44(6), 1175-1189.

Liu, F., Wu, Y., Zhang, J. e Yu, Q. (2019). A PSO-based group decision making model with multiplicative reciprocal matrices under flexibility. Soft Computing, 23(21), 10901-10910.

Liu, F., Zhang, J. e Liu, T. (2020). A PSO-algorithm-based consensus model with the application to large-scale group decision-making. Complex & Intelligent Systems, 6, 287-298.

Liu, Z., Guo, H., Li, D., Tao, H. e Zhang, J. (2007, September). Solving Multi-objective and fuzzy multi-attributive integrated technique for QoS-Aware Web Service Selection. In 2007 International Conference on Wireless Communications, Networking and Mobile Computing (pp. 735-739). IEEE.

Marini, F. e Walczak, B. (2015). Particle swarm optimization (PSO). A tutorial. Chemometrics and Intelligent Laboratory Systems, 149, 153-165.

Meena, R. e Minz, S. (2018). Group Recommender Systems–An Evolutionary Approach Based on Multi-expert System for Consensus. Journal of Intelligent Systems, 1(ahead-of-print).

Mohamadi, A., Ebrahimnejad, S., Soltani, R. e Khalilzadeh, M. (2019). A new two-stage approach for a bi-objective facility layout problem considering input/output points under fuzzy environment. IEEE Access, 7, 134083-134103.

Nooraie, M. (2012). Factors influencing strategic decision-making processes. International Journal of Academic Research in Business and Social Sciences, 2(7), 405.

Ouarda, A. e Bouamar, M. (2014). A comparison of evolutionary algorithms: PSO, DE and GA for fuzzy c-partition. International Journal of Computer Applications, 91(10).

Ölçer, A. I., Tuzcu, C. e Turan, O. (2006). An integrated multi-objective optimisation and fuzzy multi-attributive group decision-making technique for subdivision arrangement of Ro–Ro vessels. Applied Soft Computing, 6(3), 221-243.

Pétrowski, A. e Ben-Hamida, S. (2017). Evolutionary algorithms. ISTE.

Piroozmand, P. e Boroushaki, M. (2016). A computational method for optimal design of the multi-tower heliostat field considering heliostats interactions. Energy, 106, 240-252.

Ren, P., Xu, Z., Wang, X. e Zeng, X. J. (2021). Group decision making with hesitant fuzzy linguistic preference relations based on modified extent measurement. Expert Systems with Applications, 171, 114235.

Renzi, C. e Leali, F. (2016). A multicriteria decision-making application to the conceptual design of mechanical components. Journal of multi-criteria decision analysis, 23(3-4), 87-111.

Simić, D., Ilin, V., Svirčević, V. e Simić, S. (2017). A hybrid clustering and ranking method for best positioned logistics distribution centre in Balkan Peninsula. Logic Journal of the IGPL, 25(6), 991-1005.

Tadić, D., Đorđević, A., Aleksić, A. e Nestić, S. (2019). Selection of recycling centre locations by using the interval type-2 fuzzy sets and two-objective genetic algorithm. Waste Management & Research, 37(1), 26-37.

Tan, X., Gong, Z., Chiclana, F. e Zhang, N. (2018). Consensus modeling with cost chance constraint under uncertainty opinions. Applied Soft Computing, 67, 721-727.

Tranfield, D., Denyer, D. e Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. British journal of management, 14(3), 207-222.

Wu, Z., Ma, N., Zeng, Z. e Xu, J. (2018). Integer programming models to manage consensus for uncertain MCGDM based on PSO algorithms. IEEE Transactions on Fuzzy Systems, 27(5), 888-902.

Xu, Z. e Cai, X. (2012). Minimizing group discordance optimization model for deriving expert weights. Group Decision and Negotiation, 21(6), 863-875.

Xu, Z., Cai, X. e Liu, S. (2010). Nonlinear programming model integrating different preference structures. IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans, 41(1), 169-177.

Yang, L. e Jiang, M. (2009, April). Dynamic group decision making consistence convergence rate analysis based on inertia particle swarm optimization algorithm. In 2009 International Joint Conference on Artificial Intelligence (pp. 492-496). IEEE.

Yu, X. e Gen, M. (2010). Introduction to evolutionary algorithms. Springer Science & Business Media.

Zainashev, T. M. (2010, March). Using a genetic algorithm in the optimal investment portfolio decision-making process. In World Congress on Engineering 2012. July 4-6, 2012. London, UK. (Vol. 2188, pp. 107-111). International Association of Engineers.

Zhang, H., Kou, G. e Peng, Y. (2019). Soft consensus cost models for group decision making and economic interpretations. European Journal of Operational Research, 277(3), 964-980.

Zhang, S., Zhu, J., Liu, X., Chen, Y. e Ma, Z. (2017). Adaptive consensus model with multiplicative linguistic preferences based on fuzzy information granulation. Applied Soft Computing, 60, 30-47.

Zhou, X., Ji, F., Wang, L., Ma, Y. e Fujita, H. (2020). Particle swarm optimization for trust relationship based social network group decision making under a probabilistic linguistic environment. Knowledge-Based Systems, 200, 105999.