

Intelligent Techniques for Resource Allocation using Multi-Agent Systems and Multi-Criteria Methods: A Systematic Literature Review

Luiz Gustavo de Souza Lopes¹, Pedro Machado Araújo¹, Diana F. Adamatti^{1,2}

¹Programa de Pós-Graduação em Modelagem Computacional (PPGMC)
Universidade Federal do Rio Grande (FURG)
Campus Polo Carreiros - Rio Grande, RS – Brasil ,

²Universidade Federal do Rio Grande do Sul (UFRGS)
Campus Serra – Caxias do Sul, RS – Brasil

lglopes1789@gmail.com, pedro.machado.rs@hotmail.com, dianaada@gmail.com

Abstract. *Resource allocation is a challenge present in several domains, requiring decision-support mechanisms capable of operating in complex and dynamic environments. This paper presents a Systematic Literature Review conducted according to the PRISMA2020 guidelines, aiming to analyze the application of Multi-Agent Systems (MAS) and Multi-Criteria Decision Making (MCDM) methods to resource allocation problems. A total of 18 relevant studies were selected, revealing the predominance of MAS-based approaches, often combined with multicriteria methods and Artificial Intelligence techniques. The reviewed studies report benefits related to adaptability, decentralized decision-making, and resource utilization efficiency, although challenges concerning scalability and real-world implementation remain. The findings indicate that the integration of MAS and MCDM represents a promising approach for addressing complex resource allocation problems.*

Resumo. *A alocação de recursos é um desafio presente em diversos domínios, exigindo mecanismos capazes de apoiar a tomada de decisão em ambientes complexos e dinâmicos. Neste contexto, este trabalho apresenta uma Revisão Sistemática da Literatura conduzida conforme as diretrizes PRISMA2020, com o objetivo de analisar a aplicação de Sistemas Multiagentes (MAS) e Métodos de Tomada de Decisão Multicritério (MCDM) em problemas de alocação de recursos. Foram selecionados 18 estudos relevantes, cujos resultados evidenciam a predominância de abordagens baseadas em MAS, frequentemente combinadas com métodos multicritério e técnicas de Inteligência Artificial. Os estudos reportam benefícios relacionados à adaptabilidade, descentralização e eficiência na utilização dos recursos, embora desafios de escalabilidade e aplicação em ambientes reais ainda permaneçam. Os resultados indicam que a integração entre MAS e MCDM constitui uma abordagem promissora para problemas complexos de alocação de recursos.*

1. Introdução

A alocação eficiente de recursos é um problema recorrente em diversos domínios, sendo amplamente abordado na literatura científica e em aplicações práticas. Esse desafio

manifesta-se em diferentes contextos, como na gestão de aeroportos, onde há elevada demanda pelo controle e coordenação de recursos incluindo aeronaves, bagagens e fluxo de passageiros (Mamdouh et al. 2020), na otimização de vagas em estacionamento, especialmente em grandes centros urbanos com alta densidade populacional e elevada demanda por vagas (Lin et al. 2017), e na organização de infraestrutura computacional, como em ambientes de computação em nuvem, caracterizados por grande volume de dados e alta variabilidade de carga (Abid et al. 2020). Em todos esses cenários, a necessidade de distribuir recursos de forma eficiente, adaptativa e escalável torna-se um fator crítico para o desempenho dos sistemas.

Não existe uma solução universalmente ótima para problemas de alocação de recursos, especialmente em ambientes escaláveis, dinâmicos e distribuídos. Conforme discutido em estudos de revisão da literatura, a alocação de recursos consiste no processo de distribuição de cargas de trabalho entre múltiplos recursos, com o objetivo de otimizar critérios de desempenho específicos, sendo aplicada em diversos domínios, como computação em nuvem, redes definidas por software (SDN), redes celulares e sistemas 5G (Hamaali and Zeebaree 2021). Esses trabalhos evidenciam que diferentes técnicas e algoritmos são necessários dependendo do contexto, incluindo abordagens como algoritmos baseados em computação em nuvem, métodos de otimização distribuída, como o *Alternating Direction Method of Multipliers* (ADMM), e estratégias baseadas em justiça e balanceamento de carga.

Diante desse cenário, diferentes abordagens têm sido propostas para mitigar os problemas de alocação de recursos. Conforme apresentado por (Mani 2025), diversas técnicas têm sido exploradas na literatura, incluindo algoritmos de agendamento baseados em heurísticas, meta-heurísticas, métodos de otimização e abordagens baseadas em aprendizado de máquina, além de soluções híbridas. Trabalhos clássicos na área de escalonamento e alocação, como os baseados em *bin packing*, *job scheduling* e otimização combinatória, demonstram avanços significativos. No entanto, tais abordagens ainda enfrentam limitações quando aplicadas a ambientes altamente dinâmicos e descentralizados, principalmente devido à necessidade de informações previamente conhecidas sobre o estado do sistema, ao elevado custo computacional associado à reotimização diante de mudanças e à dificuldade de produzir decisões em tempo adequado quando o número de recursos, tarefas e restrições aumenta.

Com o avanço do poder computacional e o crescimento da complexidade dos sistemas, novas abordagens têm ganhado destaque, especialmente aquelas baseadas em inteligência artificial. Nesse contexto, os Sistemas Multiagentes (*Multi-Agent Systems* – MAS) surgem como uma alternativa promissora (Maldonado Andrade et al. 2024). Esses sistemas são compostos por múltiplos agentes autônomos que interagem entre si e com o ambiente, sendo capazes de tomar decisões descentralizadas, adaptar-se a mudanças e cooperar para alcançar objetivos globais (Gokulan and Srinivasan 2010). O uso de MAS tem sido explorado em áreas como logística (Dominguez and Cannella 2020), redes inteligentes (Izmirliglu et al. 2024), sistemas distribuídos e gestão de recursos (Doostmohammadian et al. 2025), demonstrando grande potencial em cenários dinâmicos e complexos.

Além disso, observa-se o crescimento recente de abordagens que combinam MAS com métodos de tomada de decisão multicritério, algoritmos de otimização e aprendi-

zado por reforço, ampliando as possibilidades de aplicação em ambientes dinâmicos e distribuídos (Hady et al. 2025a). Entretanto, ainda não existe um consenso sobre quais estratégias apresentam melhores resultados em diferentes cenários de alocação de recursos.

Dessa forma, este trabalho apresenta uma Revisão Sistemática da Literatura conduzida conforme as diretrizes PRISMA2020 (Page et al. 2021), com o objetivo de mapear o estado da arte sobre técnicas empregadas em problemas de alocação de recursos. A revisão busca identificar os principais domínios de aplicação, abordagens utilizadas, incluindo MAS, Métodos de Tomada de Decisão Multicritério (MCDM - *Multi-criteria decision-making*), bem como analisar os benefícios reportados, as limitações observadas e as lacunas de pesquisa identificadas na literatura recente.

2. Metodologia

Esta Revisão Sistemática da Literatura (RSL) foi conduzida com base nas diretrizes do PRISMA2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) (Page et al. 2021), com o objetivo de **identificar, selecionar e analisar estudos relacionados à aplicação MAS e MCDM em problemas de alocação de recursos**.

A definição do protocolo de pesquisa foi realizada considerando as questões de pesquisa apresentadas anteriormente, bem como a necessidade de mapear o estado da arte sobre as abordagens utilizadas na literatura para apoiar processos de alocação de recursos em ambientes complexos e dinâmicos.

2.1. Fontes de Dados

A busca bibliográfica foi realizada em bases de dados e periódicos reconhecidos pela relevância de suas publicações nas áreas de otimização, pesquisa operacional, inteligência artificial e sistemas multiagentes. Para a seleção dos estudos, foram consultadas a plataforma arXiv¹, bem como os periódicos European Journal of Operational Research (EJOR)², IEEE Access³, Computers & Operations Research (C&OR)⁴ e Decision Support Systems (DSS)⁵, escolhidos por sua relevância e abrangência na publicação de pesquisas relacionadas aos temas investigados.

A seleção dessas fontes foi motivada pela recorrência de publicações relacionadas aos temas de MAS, Tomada de Decisão Multicritério e Alocação de Recursos.

2.2. Critérios de Inclusão

Para compor o conjunto inicial de estudos, foram adotados os seguintes critérios de inclusão:

1. artigos completos publicados em língua inglesa;
2. estudos publicados entre janeiro de 2015 e abril de 2026;
3. publicações com acesso ao texto completo;
4. trabalhos relacionados aos temas de MAS, Métodos Multicritério ou Alocação de Recursos.

¹<https://arxiv.org>

²<https://www.sciencedirect.com/journal/european-journal-of-operational-research>

³<https://ieeaccess.ieee.org>

⁴<https://www.sciencedirect.com/journal/computers-and-operations-research>

⁵<https://www.sciencedirect.com/journal/decision-support-systems>

2.3. Estratégia de Busca

Com o objetivo de identificar trabalhos relacionados ao uso de agentes na organização de salas e recursos por meio de métodos de tomada de decisão multicritério (MCDM), a estratégia de busca foi dividida em três áreas de interesse. Essa divisão foi adotada devido à quantidade limitada de trabalhos que abordam diretamente a combinação entre sistemas multiagentes, MCDM e alocação de salas. Assim, as áreas foram definidas pelas seguintes chaves de busca:

- **Chave 1 — Sistemas Multiagentes (MAS):**
TITLE-ABS-KEY ("multi-agent systems"OR
"agent-based systems")
- **Chave 2 — Tomada de Decisão Multicritério (MCDM):**
TITLE-ABS-KEY ("multi-criteria decision
making"OR "scoring system")
- **Chave 3 — Alocação de Recursos:**
TITLE-ABS-KEY ("resource allocation"OR
"room allocation"OR "space allocation"OR
"timetabling")

As buscas foram realizadas separadamente, resultando em 3.770 registros para a Chave 1, 1.540 para a Chave 2 e 624 para a Chave 3. Posteriormente, os registros foram analisados buscando trabalhos que apresentassem relação com pelo menos duas das três áreas, permitindo ampliar o escopo da revisão sem perder a proximidade com o problema investigado.

A partir dessas estratégias, foram realizadas buscas individuais nas bases selecionadas, resultando nos quantitativos apresentados na Tabela 1.

Tabela 1. Resultados das buscas por base de dados

Busca	arXiv	EJOR	IEEE Access	C&OR	DSS	Total
A	1.498	30	2.220	14	8	3.770
B	217	33	1.282	9	8	1.549
C	62	92	473	57	2	624
Total Base	1.777	155	3.975	80	18	4.228

Após a execução das estratégias de busca, os registros obtidos foram consolidados para análise conjunta. A Tabela 2 apresenta a interseção entre as estratégias A, B e C, em cada base de dados considerada. Essa etapa permitiu identificar trabalhos relacionados tanto aos MAS quanto aos Métodos de Tomada de Decisão Multicritério aplicados à alocação de recursos, ficando um total de **107** estudos.

Tabela 2. Resultados das combinações entre as chaves de busca.

Combinação	arXiv	EJOR	IEEE Access	C&OR	DSS	Total
A-B	20	1	35	1	0	57
B-C	5	1	9	0	1	16
A-C	3	2	25	3	0	33
A-B-C	0	0	1	0	0	1
Total	28	4	70	4	1	107

A partir da consolidação dos resultados, foi realizado o processo de seleção dos estudos seguindo as recomendações do PRISMA2020. Inicialmente, foram identificados 4.228 registros por meio das três estratégias de busca, seguindo pela etapa de junção de busca ficando com 107 artigos que aparece em duas busca. Após a remoção de duplicatas e aplicação dos critérios de elegibilidade, permaneceram **76 estudos** para análise.

Na etapa de triagem, foi realizada a leitura dos títulos e resumos dos trabalhos selecionados, sendo excluídos os estudos que não apresentavam aderência ao escopo da pesquisa. Ao final do processo, **18 artigos** foram considerados elegíveis e incluídos na revisão sistemática. O fluxo completo de seleção dos estudos pode ser observado na Figura 1.

Os 18 artigos selecionados constituem a base para as análises apresentadas nas seções seguintes e são apresentados na Tabela 3.

A Tabela 3 apresenta a classificação temática dos 18 estudos selecionados para compor esta revisão sistemática. Embora diversos trabalhos tenham sido recuperados por mais de uma estratégia de busca, a categorização foi realizada com base no foco principal identificado após a leitura completa dos títulos.




Figura 1. Fluxo de seleção dos estudos conforme as diretrizes PRISMA 2020.

Fonte: Próprio Autor.

Dessa forma, a presença de um artigo em múltiplas estratégias de busca não implica necessariamente que ele aborde todos os temas de maneira equivalente. Em diversos casos, determinados conceitos aparecem apenas como elementos de apoio ou contextualização, sem constituírem o objetivo central da pesquisa. Por essa razão, alguns estudos foram classificados em apenas uma categoria, mesmo tendo sido identificados por consultas relacionadas a MAS, MCDM e Alocação de Recursos.

Essa classificação teve como objetivo evidenciar a principal contribuição de cada trabalho para o escopo desta revisão, permitindo uma análise mais precisa da distribuição dos estudos entre os temas investigados e das interseções existentes entre eles.

Tabela 3. Trabalhos analisados na RSL, organizados segundo o foco de estudo

	MAS	Resource Allocation	MCDM
(Alarbi et al. 2023)	X	X	X
(Li et al. 2019)	X	X	X
(Liu and Mohamed 2008)	X	X	-
(Shyalika et al. 2020)	X	X	-
(Yang 2023)	X	X	-
(Hady et al. 2025b)	X	X	-
(Bezoui et al. 2023)	X	-	X
(Dorri et al. 2018)	X	-	-
(Dahan 2021)	X	-	-
(Singh 2025)	X	-	-
(Cardoso and Ferrando 2021)	X	-	-
(Rocha et al. 2023)	X	-	-
(Molina-Pariente et al. 2015)	-	X	X
(Rasoanaivo and Zaraté 2022)	-	X	X
(Artigues et al. 2026)	-	X	-
(Gómez Sánchez et al. 2023)	-	X	-
(Aijun et al. 2019)	-	-	X
(Al-Shaery et al. 2022)	-	-	X

Fonte: Próprio Autor.

3. Resultados da Revisão Sistemática

Com o objetivo de compreender a atuação dos Sistemas Multiagentes (MAS) no contexto da tomada de decisão e alocação de recursos, foram analisados os estudos selecionados, buscando identificar os principais objetivos, estratégias e campos de aplicação dessas abordagens. De modo geral, os resultados evidenciam o potencial dos MAS para lidar com problemas complexos e dinâmicos, destacando-se a descentralização das decisões, a capacidade de adaptação às mudanças do ambiente e a utilização mais eficiente dos recursos disponíveis.

Observou-se que os MAS são aplicados em diferentes domínios, incluindo logística, computação em nuvem, cidades inteligentes, saúde e manufatura. Os estudos de (Singh 2025), (Cardoso and Ferrando 2021), (Rocha et al. 2023) e (Dorri et al. 2018) destacam que a utilização de múltiplos agentes permite dividir problemas complexos em

processos de decisão distribuídos, contribuindo para maior robustez, escalabilidade e flexibilidade dos sistemas.

Outro aspecto recorrente identificado na literatura é a necessidade de mecanismos eficientes para seleção e priorização de recursos. Nesse contexto, diversos trabalhos empregam MCDM, como AHP, WSM, PROMETHEE, TOPSIS e Best-Worst Method (BWM), visando considerar simultaneamente múltiplos critérios durante o processo decisório. Os estudos analisados indicam que esses métodos contribuem para aumentar a qualidade das decisões e tornar o processo mais transparente e justificável.

A revisão também evidenciou que problemas de alocação de recursos frequentemente apresentam elevada complexidade computacional. Trabalhos como os de (Li et al. 2019), (Artigues et al. 2026) e (Gómez Sánchez et al. 2023) classificam diversos cenários de alocação como NP-difíceis, tornando inviável a obtenção de soluções ótimas para instâncias de grande porte. Como consequência, observa-se ampla utilização de heurísticas, meta-heurísticas e algoritmos aproximados para obtenção de soluções satisfatórias em tempo computacional viável.

Em relação aos resultados obtidos, diversos estudos reportam melhorias significativas de desempenho. Entre os benefícios observados destacam-se a redução de custos operacionais, melhoria da utilização dos recursos, aumento da eficiência dos processos de alocação e maior capacidade de adaptação a ambientes dinâmicos. Os trabalhos de (Alarbi et al. 2023), (Molina-Pariente et al. 2015), (Liu and Mohamed 2008) e (Yang 2023) apresentam evidências de ganhos expressivos em indicadores operacionais após a aplicação das abordagens propostas.

Por outro lado, algumas limitações foram identificadas de forma recorrente. Entre elas destacam-se os desafios relacionados à escalabilidade dos sistemas multiagentes, ao aumento da comunicação entre agentes em ambientes de grande porte e à dificuldade de modelar adequadamente preferências humanas e critérios subjetivos. Além disso, a literatura aponta que ainda existe uma lacuna entre as soluções propostas academicamente e sua adoção em ambientes reais.

Por fim, observou-se uma tendência crescente de integração entre Sistemas Multiagentes, Métodos de Tomada de Decisão Multicritério e técnicas de Inteligência Artificial, especialmente Aprendizado por Reforço Multiagente (MARL). Essa combinação busca unir a capacidade adaptativa dos agentes com mecanismos mais sofisticados de tomada de decisão, representando uma das principais direções de pesquisa identificadas na literatura recente.

A Tabela 4 apresenta uma síntese dos estudos selecionados e evidencia a diversidade de abordagens utilizadas para apoiar problemas de tomada de decisão e alocação de recursos. Observa-se que os MAS representam a técnica mais recorrente entre os trabalhos analisados, estando presentes de forma direta ou combinada em aproximadamente dois terços dos estudos selecionados. Esse resultado reforça o interesse crescente da comunidade científica por abordagens distribuídas e adaptativas para lidar com ambientes complexos e dinâmicos.

Tabela 4. Síntese dos estudos selecionados

Autor	Técnica	Principal contribuição
(Singh 2025)	MAS	Redução de alucinações e maior robustez
(Cardoso and Ferrando 2021)	Revisão MAS	Lacunas para adoção industrial
(Rocha et al. 2023)	ToM	Melhor modelagem do comportamento humano
(Dorri et al. 2018)	Revisão MAS	Aplicações em múltiplos domínios
(Dahan 2021)	ACO+MAS	Melhor desempenho computacional
(Bezoui et al. 2023)	MOGA-RMP	Soluções mais alinhadas às preferências
(Aijun et al. 2019)	TOPSIS	Ranking estável sob diferentes pesos
(Alarbi et al. 2023)	BWM+MAS	Redução de custos e deslocamentos
(Liu and Mohamed 2008)	MARA	Maximização do bem-estar social
(Shyalika et al. 2020)	DQN	Aprendizado adaptativo
(Yang 2023)	Contract-Net	Escalabilidade até 1000 agentes
(Molina-Pariente et al. 2015)	Meta-heurística	Aumento de cirurgias realizadas
(Rasoanaivo and Zaraté 2022)	AHP/WSM	Apoio multicritério à decisão
(Li et al. 2019)	Busca Local	Bem-estar social acima de 0,9
(Gómez Sánchez et al. 2023)	RCMPSP	Predomínio de heurísticas
(Al-Shaery et al. 2022)	Heurísticas	Eficácia em problemas NP
(Hady et al. 2025b)	MARL	Estratégias cooperativas adaptativas

Em relação aos benefícios reportados, destacam-se ganhos em robustez, adaptabilidade, eficiência operacional e utilização dos recursos disponíveis. Alguns estudos também reportaram reduções de custos, melhoria na qualidade das decisões e aumento do bem-estar social dos agentes envolvidos. Por outro lado, foram identificados desafios recorrentes relacionados à escalabilidade, ao aumento da complexidade computacional e à dificuldade de representar adequadamente preferências humanas em ambientes reais.

De forma geral, os resultados indicam uma convergência entre Sistemas Multiagentes, Métodos de Tomada de Decisão Multicritério e técnicas de Inteligência Artificial, sugerindo uma tendência de integração dessas abordagens para enfrentar problemas cada vez mais complexos de alocação de recursos. A partir desses achados, torna-se relevante discutir como essas técnicas se complementam, quais limitações ainda persistem e quais oportunidades de pesquisa permanecem em aberto.

4. Discussão

Os resultados da revisão indicam que a aplicação de MAS em problemas de alocação de recursos está relacionada principalmente à necessidade de distribuir decisões em ambientes nos quais diferentes entidades possuem objetivos, restrições e níveis de autonomia distintos. Essa característica diferencia os MAS de abordagens estritamente centralizadas, uma vez que o processo decisório pode ser distribuído entre agentes que representam diferentes entidades ou interesses do sistema. Sob essa perspectiva, a recorrência dos MAS

nos estudos analisados não representa apenas uma preferência metodológica, mas está relacionada à própria natureza dos problemas investigados, nos quais decisões precisam ser tomadas de forma dinâmica e considerando informações provenientes de diferentes partes do ambiente.

Essa característica está alinhada à concepção de sistemas multiagentes apresentada por (Wooldridge 2009), na qual agentes autônomos interagem em um ambiente para alcançar seus objetivos, podendo cooperar, coordenar ou negociar entre si. No contexto da alocação de recursos, essa estrutura permite representar diferentes participantes do processo decisório e distribuir responsabilidades entre eles. Entretanto, a descentralização também introduz novos desafios, uma vez que o aumento do número de agentes pode ampliar a necessidade de comunicação e coordenação, tornando o processo decisório progressivamente mais complexo.

Nesse contexto, os resultados indicam que o MCDM atua de forma complementar aos MAS. Enquanto os agentes distribuem o processo decisório, os métodos multicritério permitem avaliar e comparar alternativas considerando diferentes critérios, como custo, tempo, disponibilidade, distância e preferências.

A presença de diferentes métodos multicritério nos estudos analisados também evidencia que não existe um único mecanismo de decisão adequado a todos os cenários. A escolha do método está relacionada às características do problema e à forma como os critérios e preferências são representados. Dessa forma, a integração entre MAS e MCDM pode ser interpretada menos como uma simples combinação de técnicas e mais como uma divisão de responsabilidades entre a representação distribuída do problema e a avaliação das alternativas disponíveis.

Outro aspecto relevante diz respeito à incorporação de técnicas de Inteligência Artificial aos sistemas multiagentes. Os resultados apontam uma transição de abordagens nas quais o comportamento dos agentes é predominantemente definido por regras ou estratégias previamente estabelecidas para modelos capazes de aprender a partir das interações com o ambiente. Essa mudança é particularmente relevante em cenários nos quais as condições de alocação não permanecem estáticas, pois permite que as estratégias dos agentes sejam ajustadas conforme novas situações são observadas. Nesse sentido, abordagens baseadas em aprendizado por reforço e MARL ampliam o potencial adaptativo dos MAS, embora também aumentem a complexidade do processo de desenvolvimento, treinamento e avaliação dos agentes.

A combinação desses mecanismos, entretanto, apresenta um desafio importante. A descentralização tende a aumentar a flexibilidade do sistema, enquanto a incorporação de múltiplos critérios e mecanismos de aprendizagem aumenta a quantidade de informações consideradas durante o processo decisório. Consequentemente, existe uma relação entre a capacidade de representação do sistema e a complexidade necessária para coordenar suas decisões. Esse aspecto ajuda a explicar por que questões relacionadas à escalabilidade, comunicação entre agentes e custo computacional permanecem presentes na literatura, mesmo em trabalhos que apresentam ganhos de desempenho.

Além da dimensão computacional, a revisão evidencia uma dificuldade relacionada à representação de aspectos humanos nos processos de alocação. Preferências, prioridades e critérios subjetivos nem sempre podem ser representados adequadamente

por parâmetros fixos. Essa questão torna-se ainda mais relevante em aplicações nas quais diferentes usuários podem apresentar necessidades conflitantes ou nas quais uma decisão considerada eficiente para o sistema não necessariamente corresponde à alternativa mais adequada para cada indivíduo. A utilização de MCDM e mecanismos de aprendizagem pode contribuir para lidar com essa complexidade, mas não elimina o desafio de definir como tais preferências devem ser representadas e ponderadas.

Diante desse cenário, identifica-se uma lacuna relacionada à aplicação conjunta dessas capacidades em problemas de alocação espacial e temporal de recursos hospitalares. Embora a literatura apresente estudos envolvendo MAS, MCDM e técnicas de Inteligência Artificial, essas abordagens são frequentemente investigadas separadamente ou em combinações direcionadas a outros domínios. A alocação de ambientes hospitalares, por sua vez, envolve simultaneamente restrições temporais, disponibilidade de recursos, características dos usuários, prioridades e mudanças constantes na demanda. Dessa forma, esse contexto apresenta características que podem se beneficiar da integração entre agentes autônomos, mecanismos multicritério e estratégias adaptativas.

Assim, os achados da revisão não apenas demonstram a aplicabilidade dos MAS à alocação de recursos, mas também indicam que sua principal oportunidade de evolução está na integração de diferentes mecanismos de decisão. A combinação entre autonomia e coordenação dos agentes, avaliação multicritério e capacidade de aprendizagem pode oferecer uma estrutura mais adequada para problemas nos quais as condições de alocação variam ao longo do tempo e diferentes objetivos precisam ser considerados simultaneamente. Essa perspectiva fundamenta a proposta deste trabalho e direciona a investigação de uma abordagem voltada à alocação espacial e temporal de recursos em ambientes hospitalares.

5. Conclusão

Este trabalho apresentou uma Revisão Sistemática da Literatura com o objetivo de identificar e analisar abordagens relacionadas à utilização de MAS e MCDM em problemas de alocação de recursos. A revisão foi conduzida seguindo as diretrizes PRISMA2020, resultando na seleção e análise de 18 estudos considerados relevantes para o escopo da pesquisa.

Os resultados demonstraram que os Sistemas Multiagentes constituem uma das abordagens mais promissoras para lidar com problemas complexos de alocação de recursos, especialmente em ambientes dinâmicos, distribuídos e sujeitos a constantes mudanças. Além disso, observou-se que a integração com métodos multicritério contribui para melhorar a qualidade das decisões, permitindo considerar simultaneamente múltiplos critérios e restrições durante o processo de alocação.

A revisão também evidenciou a crescente utilização de técnicas de Inteligência Artificial, particularmente Aprendizado por Reforço Multiagente, indicando uma tendência de convergência entre diferentes áreas de pesquisa para o desenvolvimento de sistemas mais autônomos e adaptativos. Entretanto, desafios relacionados à escalabilidade, modelagem de preferências humanas e aplicação em ambientes reais ainda permanecem como temas relevantes para investigações futuras.

Como principal contribuição, esta revisão forneceu uma visão consolidada do estado da arte sobre a utilização de MAS e MCDM em problemas de alocação de recursos,

identificando benefícios, limitações e tendências presentes na literatura recente. Adicionalmente, os resultados permitiram identificar lacunas de pesquisa que justificam o desenvolvimento de novas abordagens voltadas à alocação de recursos espaciais e temporais em ambientes hospitalares.

6. Agradecimentos

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

Referências

- [Abid et al. 2020] Abid, A., Farooq, S., Manzoor, M. F., Farooq, U., and Nawaz, N. (2020). Resource allocation techniques in cloud computing: A review and future directions. *Elektronika ir Elektrotechnika*, 26.
- [Aijun et al. 2019] Aijun, L., Zhang, Y., Lu, H., Tsai, S., Hsu, C.-F., and Lee, C.-H. (2019). An innovative model to choose e-commerce suppliers. *IEEE Access*, PP:1–1.
- [Al-Shaery et al. 2022] Al-Shaery, A. M., Khozium, M. O., Farooqi, N. S., Alshehri, S. S., and Al-Kawa, M. A. M. (2022). Problem solving in crowd management using heuristic approach. *IEEE Access*, 10:25422–25434.
- [Alarbi et al. 2023] Alarbi, M., Jaradat, K., and Lutfiyya, H. (2023). Scope: Smart cooperative parking environment. *IEEE Access*, PP:1–1.
- [Artigues et al. 2026] Artigues, C., Hartmann, S., and Vanhoucke, M. (2026). Fifty years of research on resource-constrained project scheduling explored from different perspectives. *European Journal of Operational Research*, 328(2):367–389.
- [Bezoui et al. 2023] Bezoui, M., Olteanu, A.-L., and Sevaux, M. (2023). Integrating preferences within multiobjective flexible job shop scheduling. *European Journal of Operational Research*, 305(3):1079–1086.
- [Cardoso and Ferrando 2021] Cardoso, R. C. and Ferrando, A. (2021). A review of agent-based programming for multi-agent systems. *Computers*, 10(2).
- [Dahan 2021] Dahan, F. (2021). An effective multi-agent ant colony optimization algorithm for qos-aware cloud service composition. *IEEE Access*, 9:17196–17207.
- [Dominguez and Cannella 2020] Dominguez, R. and Cannella, S. (2020). Insights on multi-agent systems applications for supply chain management. *Sustainability*, 12(5).
- [Doostmohammadian et al. 2025] Doostmohammadian, M., Aghasi, A., Pirani, M., Nekouei, E., Zarrabi, H., Keypour, R., Rikos, A. I., and Johansson, K. H. (2025). Survey of distributed algorithms for resource allocation over multi-agent systems. *Annual Reviews in Control*, 59:100983.
- [Dorri et al. 2018] Dorri, A., Kanhere, S., and Jurdak, R. (2018). Multi-agent systems: A survey. *IEEE Access*, 6:1–1.
- [Gokulan and Srinivasan 2010] Gokulan, B. P. and Srinivasan, D. (2010). An introduction to multi-agent systems. *Studies in Computational Intelligence*, 310:1–27.
- [Gómez Sánchez et al. 2023] Gómez Sánchez, M., Lalla-Ruiz, E., Fernández Gil, A., Castro, C., and Voß, S. (2023). Resource-constrained multi-project scheduling problem: A survey. *European Journal of Operational Research*, 309(3):958–976.
- [Hady et al. 2025a] Hady, M., Hu, S., Pratama, M., Cao, Z., and Kowalczyk, R. (2025a). Multi-agent reinforcement learning for resources allocation optimization: a survey. *Artificial Intelligence Review*, 58.

- [Hady et al. 2025b] Hady, M. A., Hu, S., Pratama, M., Cao, J., and Kowalczyk, R. (2025b). Multi-agent reinforcement learning for resources allocation optimization: A survey.
- [Hamaali and Zeebaree 2021] Hamaali, K. and Zeebaree, S. (2021). Resources allocation for distributed systems: A review. 5:76–88.
- [Izmirliloglu et al. 2024] Izmirliloglu, Y., Pham, L., Son, T. C., and Pontelli, E. (2024). A survey of multi-agent systems for smartgrids. *Energies*, 17(15).
- [Li et al. 2019] Li, Y., Jiang, Y., Wu, W., Jiang, J., and Fan, H. (2019). Room allocation with capacity diversity and budget constraints. *IEEE Access*, PP:1–1.
- [Lin et al. 2017] Lin, T., Rivano, H., and Le Mouél, F. (2017). A survey of smart parking solutions. *IEEE Transactions on Intelligent Transportation Systems*, 18(12):3229–3253.
- [Liu and Mohamed 2008] Liu, Y. and Mohamed, Y. (2008). Multi-agent resource allocation (mara) for modeling construction processes. In *2008 Winter Simulation Conference*, pages 2361–2369.
- [Maldonado Andrade et al. 2024] Maldonado Andrade, D., Cruz, E., Abad Torres, J., Cruz, P., and Gamboa, S. (2024). Multi-agent systems: A survey about its components, framework and workflow. *IEEE Access*, PP:1–1.
- [Mamdouh et al. 2020] Mamdouh, M., Ezzat, M., and Hefny, H. (2020). Airport resource allocation using machine learning techniques. *Inteligencia Artificial*, 23:19–32.
- [Mani 2025] Mani, A. B. (2025). Técnicas de alocação e agendamento de recursos em computação em nuvem: Uma revisão abrangente. *International Journal For Multidisciplinary Research*.
- [Molina-Pariente et al. 2015] Molina-Pariente, J. M., Hans, E. W., Framinan, J. M., and Gomez-Cia, T. (2015). New heuristics for planning operating rooms. *Computers Industrial Engineering*, 90:429–443.
- [Page et al. 2021] Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., et al. (2021). The prisma 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372:n71.
- [Rasoanaivo and Zaraté 2022] Rasoanaivo, R. G. and Zaraté, P. (2022). A Decision Support System for student’s room allocation. In Papathanasiou, J., Belioka, M.-P., Dikoglou, P., and Zopounidis, D., editors, *ICDSSST 2022 proceedings : on Decision Support addressing modern Industry, Business and Societal needs ; ISBN: 978-618-5255-18-3*, pages 30–36, Thessaloniki, Greece. EWG-DSS.
- [Rocha et al. 2023] Rocha, M., Silva, H., Morales, A., Sarkadi, S., and Panisson, A. (2023). Applying theory of mind to multi-agent systems: A systematic review.
- [Shyalika et al. 2020] Shyalika, C., Silva, T., and Karunananda, A. (2020). Reinforcement learning in dynamic task scheduling: A review. *SN Computer Science*, 1:306.
- [Singh 2025] Singh, M. (2025). Multi-agent systems: the future of distributed ai platforms for complex task management. *World Journal of Advanced Research and Reviews*, 26(3):048–055.
- [Wooldridge 2009] Wooldridge, M. (2009). *An Introduction to MultiAgent Systems*. John Wiley & Sons, Chichester, 2 edition.
- [Yang 2023] Yang, Y. (2023). Agent-Based Online Scheduling for Multi-Task Resource Allocation in Complex Environments.