

IA para Detecção de Aproximações entre Satélites e Detritos: revisão de escopo

***AI for Detecting Approaches between Satellites and Debris: a
scoping review***

Andréa Zотовици¹

Doutoranda em Engenharia e Tecnologia Espacial

Orcid: <https://orcid.org/0000-0001-9056-7905>

Email: andrea.zotovici@fatec.sp.gov.br

Magda Ap. Silvério Miyashiro²

Doutora em Engenharia e Tecnologia Espacial

Orcid: <https://orcid.org/0009-0007-0322-6143>

E-mail: magda.miyashiro@online.uscs.edu.br

Maurício G. V. Ferreira³

Doutor em Computação Aplicada

Orcid: <https://orcid.org/0000-0002-6229-9453>

E-mail: mauricio.ferreira@inpe.br

Francisco das Chagas Carvalho⁴

Doutor em Engenharia e Tecnologia Espacial

Orcid: <https://orcid.org/0000-0003-0113-9445>

E-mail: francisco.chagas@inpe.br

Resumo

Esta revisão de escopo tem como objetivo identificar e caracterizar as técnicas de Inteligência Artificial (IA) empregadas na identificação de aproximações entre satélites e detritos espaciais, visando à prevenção de colisões em órbita. O estudo foi conduzido segundo a metodologia do *Joanna Briggs Institute* (JBI) e

¹ Instituto Nacional de Pesquisas Espaciais (INPE) / Faculdade de Tecnologia Luigi Papaiz. São José dos Campos / Diadema, SP, Brasil.

² Instituto Nacional de Pesquisas Espaciais (INPE) / Universidade de São Caetano do Sul (USCS). São José dos Campos / São Caetano do Sul, SP, Brasil.

³ Instituto Nacional de Pesquisas Espaciais (INPE). São José dos Campos, SP, Brasil.

⁴ Instituto Nacional de Pesquisas Espaciais (INPE). São José dos Campos, SP, Brasil.

reportado conforme a extensão PRISMA-ScR. A busca foi realizada nas bases *Scopus* e *Web of Science*, com critérios de elegibilidade definidos e seleção por pares. Os resultados evidenciam o uso crescente de algoritmos de IA, como aprendizado de máquina e redes neurais, aplicados à análise de dados orbitais (TLEs e CDMs) para prever riscos de colisão com maior precisão. A originalidade da revisão está em sua ênfase nas técnicas de predição, oferecendo uma visão consolidada das abordagens existentes e das lacunas de pesquisa no campo da segurança orbital.

Palavras-chave: centros de operações de satélites, detecção de colisões, inteligência artificial, precisão, satélites ativos.

Abstract

This scoping review aims to identify and characterize Artificial Intelligence (AI) techniques employed in detecting close approaches between satellites and space debris, with the objective of preventing in-orbit collisions. The study was conducted following the Joanna Briggs Institute (JBI) methodology and reported in accordance with the PRISMA-ScR extension. The search strategy was applied to the Scopus and Web of Science databases, using predefined eligibility criteria and a dual-reviewer selection process. The findings highlight the growing adoption of AI algorithms—such as machine learning and neural network—applied to orbital data analysis (TLEs and CDMs) to improve collision risk prediction accuracy. The originality of this review lies in its focus on predictive techniques, offering a consolidated overview of existing approaches and identifying research gaps in the field of orbital safety.

Keywords: active satellites, artificial intelligence, collision detection, precision, satellite operations centers.

1. Introdução

Os detritos espaciais representam uma ameaça crescente à exploração espacial (Yap, Heiberg & Truffer, 2023), uma vez que podem colidir com satélites ativos em alta velocidade, criando milhares de novos fragmentos e agravando o cenário conhecido como “Síndrome de Kessler” (Thompson, 2015; Barry, 2022). A Figura 1 é uma imagem, gerada pelo *Geminis*⁵, que foi adicionada a um artigo do Portal R7 que aborda a ameaça do lixo espacial e dos satélites à camada de ozônio e à segurança orbital.

Figura 1 – Lixo Espacial



Fonte: Fala Ciência (2025).

O Quadro 1 apresenta a quantidade de objetos em órbita que podem ser os satélites ativos e os resíduos que provenientes de satélites inativos, estágios de foguetes e outros equipamentos. Além das colisões acidentais, destacam-se como fontes de geração o término de missões, os testes de armas antissatélite e a degradação causada por fatores naturais (Colvin, Karcz & Wusk, 2023).

Quadro 1 – Quantidade Aproximada de Objetos Espaciais.

Tipo de Objetos	Quantidade Aproximada
Cargas úteis ativas	12.500
Objetos de Analista	17.100
Detritos	19.300
Total	48.900

Fonte: Space-Track (s.d.).

⁵ Gemini - Software de inteligência artificial geradora de imagem. Disponível em: <https://gemini.google.com/>

Embora existam pesquisas voltadas à mitigação e remoção de detritos (Migaud, 2020; Hoeher, 2023; Viavattene *et al.*, 2022), a principal estratégia é a prevenção de colisões através da identificação de aproximações críticas e manobra do satélite para evitar a colisão. Para isso, são utilizados dados como os *Conjunction Data Messages* (CDM), que preveem a probabilidade de colisão, contêm os dados orbitais e o *Time of Closest Approach* (TCA), podendo chegar com a antecedência de até sete dias (Merz *et al.*, 2017). No entanto, muitas vezes esses dados são recebidos com menos antecedência, o que corresponde ao momento em que o risco aumenta, e ainda é necessário verificar a sua exatidão recorrendo a um software específico para o cálculo da probabilidade de colisão.

É possível utilizar os *Two-Line Elements* (TLEs) dos detritos juntamente com a órbita do satélite em tempo real, atualizados diariamente para identificar o TCA. Porém é necessário contar com o apoio de um conjunto de softwares que deverão propagar a órbita do satélite e dos detritos, a fim de gerar a matriz de covariância e calcular a probabilidade. A propagação da órbita é realizada através da biblioteca *Simplified General Perturbations* (SGP4).

O processo de prevenção de colisão requer um elevado número de ações por parte dos operadores, na ausência de um sistema computacional que execute todas as etapas. Conforme Schaus *et al.*, (2022), é de grande importância aumentar a automação nos referidos processos, de modo a reduzir o esforço dos operadores e a melhorar a eficiência da tomada de decisões.

Nesse contexto, as técnicas de Inteligência Artificial (IA) têm demonstrado um potencial significativo na análise de grandes volumes de dados orbitais, possibilitando a previsão de trajetórias e a identificação de riscos de aproximação. Deste modo, considerando que as revisões de escopo são indicadas para identificar áreas emergentes, a presente revisão visa caracterizar as abordagens baseadas em IA aplicadas à prevenção de colisões entre satélites e detritos, com enfoque nas técnicas empregadas, no seu desempenho e na sua contribuição para aumentar a precisão da predição de colisão entre satélite e detritos.

O objetivo geral deste artigo é identificar as técnicas de IA empregadas na identificação de aproximação crítica entre satélites e detritos espaciais, para o processo de prevenção de colisão.

Para que os objetivos definidos sejam atingidos, é necessário definir os objetivos específicos. Neste caso, os objetivos específicos são:

- Identificar os algoritmos de IA utilizados na prevenção de colisão entre satélites e detritos espaciais.
- Caracterizar as abordagens baseadas em IA voltadas para a prevenção de colisões.

Este estudo aborda uma revisão de escopo, conduzida com o propósito de identificar e sintetizar evidências sobre a aplicação de técnicas de IA na identificação de aproximações críticas entre satélites e detritos espaciais. A opção por este tipo de revisão é justificada pela natureza exploratória do tema, cuja literatura é ampla e em expansão, o que requer uma abordagem ampla e sistemática de mapeamento do conhecimento existente.

2. Procedimentos Metodológicos

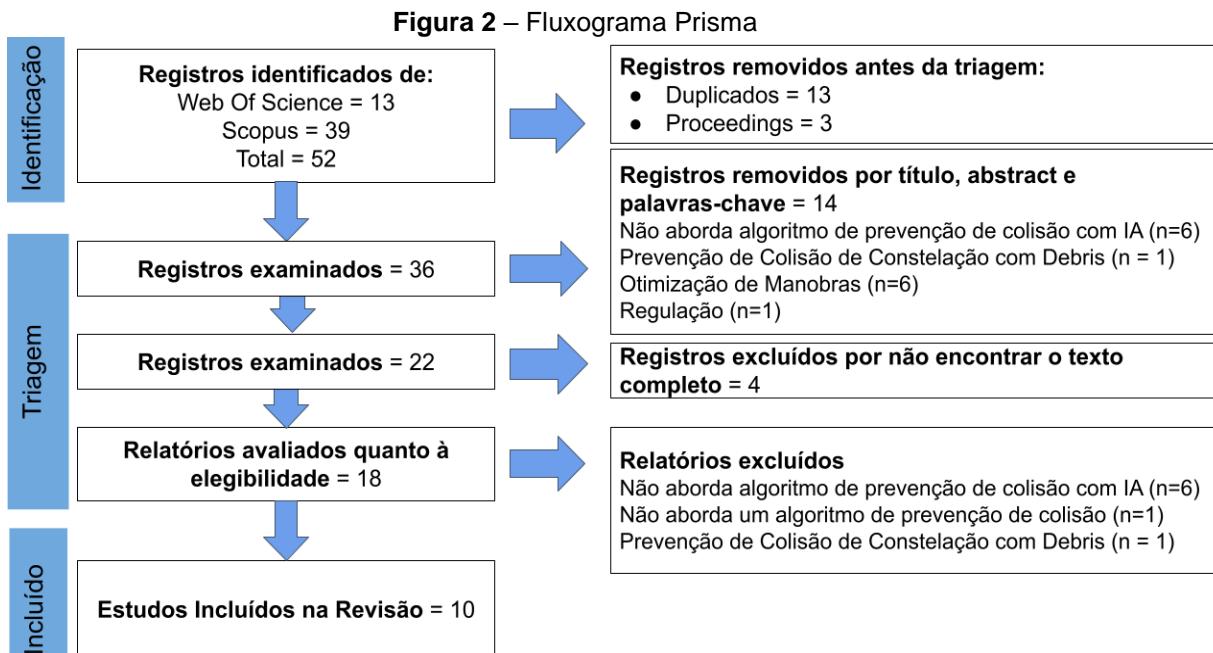
2.1. Objeto de estudo

O presente estudo tem como objeto de análise artigos científicos que abordam o uso de técnicas de IA aplicadas à identificação de aproximações entre satélites e detritos espaciais, com foco na prevenção de colisões em órbita. A revisão visa identificar as abordagens existentes, os algoritmos utilizados e o desempenho das soluções propostas para apoiar os centros de operações espaciais na antecipação de riscos orbitais.

2.2. Delineamento da pesquisa

A presente revisão de escopo é de natureza qualitativa e descritiva, tendo sido conduzida segundo a metodologia proposta pelo Joanna Briggs Institute (JBI) para a realização de revisões de escopo (Tricco *et al.*, 2018; Peters *et al.*, 2024). A opção por este delineamento é justificada pela necessidade de compreender o estado da arte na Prevenção de Colisões entre Satélites e

Detritos Espaciais, recorrendo à IA. O relato do processo de revisão (Miyashiro *et al.*, 2025) foi estruturado em conformidade com as diretrizes da extensão PRISMA para Revisões de Escopo (PRISMA-ScR), conforme apresentado na Figura 2. Desta forma, foram garantidos o rigor metodológico e a transparência propostos, em conformidade com o protocolo estabelecido na plataforma *Open Science Framework*⁶.



Fonte: Elaborado pelos autores (2025).

2.3. Detalhamento dos procedimentos

O procedimento de revisão de escopo foi iniciado com a elaboração prévia do protocolo metodológico, o qual compreendeu as seguintes etapas:

- Definição dos termos População, Conceito e Contexto (PCC);
- Formulação da questão de pesquisa;
- Definição da chave de busca;
- Definição dos critérios de inclusão e exclusão;
- Seleção dos estudos;
- Extração de dados;

⁶ Center for Open Science. (2025). Open Science Framework. Center for Open Science. <https://osf.io/>

- Análise dos dados.

A questão de pesquisa foi formulada com base no acrônimo PCC, sendo a mesma apresentada da seguinte forma:

- População: satélites ativos em ambiente orbital;
- Conceito: técnicas de IA aplicadas à identificação de colisões com detritos espaciais;
- Contexto: operações orbitais em ambiente espacial.

Desta forma, a questão de pesquisa foi obtida estabelecida: Como técnicas de Inteligência Artificial têm sido utilizadas para identificar colisões entre satélites e detritos espaciais?

A etapa seguinte define a estratégia de busca apresentada no Quadro 2. Esta estratégia foi elaborada com termos controlados e não controlados, combinando os descritores presentes em estudos da área, e aplicada nas bases de dados *Scopus* e *Web of Science*. A seleção dessas bases foi determinada pela sua cobertura, credibilidade e uso consolidado em revisões sistemáticas, abrangendo as principais editoras científicas, tais como a ACM, a Elsevier, a Springer, a IEEE, a Taylor & Francis e a Wiley, que são reconhecidas como referência nas Engenharias (Phillips *et al.*, 2024). Na presente etapa, foi definida a aplicação do filtro de idiomas, tendo sido selecionados os idiomas: inglês, português e espanhol.

Quadro 2 – Chave de Busca.

Chave de Busca genérica	
Web of Science e Scopus	Search Query
#1	satellite
#2	("collision avoidance" OR "conjunction analysis")
#3	"space debris"
#4	("genetic algorithm" OR "cognitive computing" OR "evolutionary computation" OR "artificial intelligence" OR "machine learning" OR "deep learning" OR "fuzzy logic" OR "intelligent")
#1 AND #2 AND #3 AND #4	Web of Science = 13 Scopus = 39 Total = 52

Fonte: Elaborado pelos autores (2025).

Em seguida, foi realizada a definição dos critérios de elegibilidade, apresentados no Quadro 3, que serviram de orientação à triagem dos estudos, visando a definição dos artigos que serão incluídos ou excluídos.

Quadro 3 – Critérios de Elegibilidade.

Critérios de Elegibilidade	
Inclusão	Exclusão
Estudos que apresentem técnicas de IA aplicadas na identificação de aproximação entre satélites e detritos usando Inteligência Artificial	<ol style="list-style-type: none"> 1. Aborda Regulação 2. Não aborda algoritmo de prevenção de colisão com IA 3. Não aborda um algoritmo de prevenção de colisão 4. Otimização de Manobras 5. Prevenção de Colisão de Constelação com Debris 6. Apenas dados de Proceedings. 7. Estudos que tratem de manobras de satélites. 8. Texto do artigo não é de acesso aberto ou não foi encontrado

Fonte: Elaborado pelos autores (2025).

O processo de seleção compreende a consulta nas bases de dados seguida pela triagem dos registros obtidos. As consultas ocorreram no período compreendido entre 18 de julho de 2022 e 12 de junho de 2025, com a repetição do processo semestralmente seguindo o mesmo protocolo elaborado no início da revisão de escopo.

O processo de triagem foi realizado em duas fases: (1) leitura de títulos, resumos e palavras-chave; (2) leitura e análise do texto completo. A seleção foi realizada por dois revisores independentes, sendo que eventuais discordâncias foram resolvidas com auxílio de um terceiro revisor.

Os critérios de elegibilidade estabelecidos no protocolo foram aplicados às duas fases da triagem. O gerenciamento da revisão foi realizado com o suporte da plataforma Parsifal (Fabbri *et al.*, 2016).

2.4. Extração e Análise de dados

A extração de dados visou identificar, em cada estudo incluído, informações específicas. A organização das respostas sobre as técnicas de IA utilizadas para identificar a aproximação crítica entre satélites e detritos espaciais, a fonte de dados utilizada para treinar o modelo, o desempenho do modelo e os dados que deveriam ser preditos foi efetuada através do registro em tabelas.

A análise dos dados foi realizada através de uma abordagem descritiva e apresentada na seção de Resultados e Discussões, com o propósito de responder à questão de pesquisa. A análise foi efetuada com base nas tabelas elaboradas durante a extração e foi complementada por um resumo descritivo, conforme recomendado por Peters *et al.* (2024).

3. Resultados e Discussões

Após a aplicação dos critérios de elegibilidade, alguns dos 52 estudos inicialmente identificados nas bases *Scopus* e *Web of Science*, foram excluídos por não satisfazerem os requisitos definidos. O Quadro 4 apresenta os estudos excluídos, acompanhados das respectivas justificativas, conforme previsto no protocolo da revisão.

Quadro 4 – Estudos excluídos.

Estudos Excluídos	
Motivo	Estudos
Aborda Regulação	1
Não aborda algoritmo de prevenção de colisão com IA	12
Não aborda um algoritmo de prevenção de colisão	1
Otimização de Manobras	6
Prevenção de Colisão de Constelação com Debris	2
Proceedings	3
Texto do artigo não é de acesso aberto ou não foi encontrado	4

Fonte: Elaborado pelos autores (2025).

O Quadro 5 apresenta os estudos incluídos na revisão, contemplando as principais técnicas de IA aplicadas à identificação de aproximações críticas entre satélites e detritos espaciais. A análise considerou as características dos dados utilizados no treinamento dos modelos de aprendizagem de máquina, bem como o desempenho reportado para cada abordagem.

Quadro 5 – Estudos selecionados.

Estudos Selecionados		
Estudo	Técnica de IA	Entrada
(Catulo et al., 2023)	Modelos Ocultos de Markov	CDM
(Choi et al., 2024)	Inteligência Artificial Espaço-Tempo Rede Neural Profunda	TLE
(Etherajan, 2023)	Floresta Aleatória	CDM
(Guimarães et al., 2023)	Modelo de Difusão	CDM
(Huang & Shu, 2024)	Transformador de Autoatenção	Órbita em tempo real, TLE, SGP4
(Kabir et al., 2020)	Rede Neural de Regressão	CDM
(Mashiku, Frueh, Memarsadeghi, Gizzi, & Burton, 2019)	Rede Neural Profunda, K-means, SVM, Fuzzy Inference System	Dados do programa CARA da NASA
(Schaus et al., 2022)	Regressão Linear, Regressão em Crista, Redes Neurais Feedforward	CDM
(Uriot et al., 2022)	Equipe 1: Cascata de limiares e análise estatística Equipe 2: Manhattan, LSTM	CDM
Ramaneti, Krishna, Ahmed e Rajesh (2021)	Aprendizagem de Máquina e Algoritmo e Probabilístico	TLE e SPG-4

Fonte: Elaborado pelos autores (2025).

Após a avaliação dos dez estudos selecionados, foi observado que as estratégias mais utilizadas para identificar aproximações críticas são as que recorrem a arquivos com CDM, utilizados em seis estudos, seguidos do uso de TLE em três estudos. Um artigo apresenta dados de um sistema do próprio programa de pesquisa da NASA denominado CARA, onde:

- CDM – É um arquivo que fornece parâmetros críticos para decisões rápidas de manobra enviado para o centro de operações apenas quando há risco de maior aproximação entre um satélite e detritos espaciais com antecedência que pode ser de uma semana a poucos dias do TCA, dependendo de o aumento da probabilidade de colisão ser menor que 1×10^{-4} ;
- CARA – É um sistema da NASA utilizado para avaliar riscos de colisão e planejar manobras de mitigação que recebe como entrada arquivos de CDM e modelos orbitais para análise;

- Órbita em Tempo Real – São informações atualizadas em tempo real sobre a posição orbital de um satélite, possui alta precisão no acompanhamento em tempo real;
- TLE – Descreve parâmetros orbitais de um objeto seguindo um formato padronizado;
- SGP4 – É um modelo matemático para previsão de posição orbital que recebe os dados do TLE de um satélite e de um detrito.

Os resultados obtidos mostram que o CDM é amplamente utilizado para a geração de modelos de IA destinados à predição do risco de colisão, apesar de o seu recebimento ocorrer com pouco tempo de antecedência para o TCA. Uma alternativa para o centro de operações consiste na utilização de um software comercial ou desenvolvido na própria instituição, com vista a usar dados do TLE dos detritos e dados da órbita do satélite em tempo real aplicados ao SGP4 para a propagação da órbita para um TCA. No entanto, esta alternativa é considerada inviável para alguns, devido ao esforço dos operadores e ao custo associado à aquisição ou desenvolvimento do software.

Alguns artigos afirmam que os modelos de aprendizagem de máquina podem gerar previsões mais precisas (Mashiku *et al.*, 2019; Kabir *et al.*, 2020; Ramaneti *et al.*, 2021; Etherajan, 2023; Guimarães *et al.*, 2023; Huang & Shu, 2024).

Os artigos que recorrem à IA para predição de:

- aproximação crítica (Choi *et al.*, 2024) ;
- incerteza da posição (Guimarães *et al.*, 2023; Schaus *et al.*, 2022);
- órbita (Huang e Shu, 2024; Ramaneti *et al.*, 2021);
- probabilidade de colisão (Choi *et al.*, 2024, Catulo *et al.*, 2023; Uriot *et al.*, 2022; Schaus *et al.*, 2022; Ramaneti *et al.*, 2021; Kabir *et al.*, 2020);
- risco de colisão (Etherajan, 2023);
- tempo de aproximação (Choi *et al.*, 2024).

Os trabalhos de Catulo *et al.* (2023), Schaus *et al.* (2022), Uriot *et al.* (2022) e Ramaneti *et al.* (2021) destacam a relevância da automação por motivos como:

- reduzir o esforço dos operadores;
- garantir a segurança de missões espaciais mesmo com o aumento das atividades espaciais e quantidade de detritos;
- garantir a eficiência na tomada de decisão.

4. Conclusões

A revisão realizada permitiu compreender como diferentes técnicas de IA têm sido usadas para melhorar a detecção e a prevenção de colisões orbitais, demonstrando os progressos alcançados, bem como as limitações e as oportunidades para investigações futuras.

As técnicas de IA baseiam-se predominantemente em métodos aprendizagem de máquina, que utilizam arquivos de CDM e TLE como dados de entrada. Quando são utilizados dados do arquivo TLE, é necessário recorrer a algoritmos de propagação (SGP4), que propagam a órbita do satélite e dos detritos, a fim de gerar a matriz de covariância e calcular a probabilidade. Os dados do arquivo CDM são recebidos com poucos dias de antecedência em relação ao TCA e já contêm tudo o que é necessário para estimar a probabilidade, mas têm de ser verificados.

Embora cada base de dados possa ter condições que limitem a previsão, os estudos apontam os modelos de aprendizagem de máquina, como as redes neurais e a regressão polinomial, como modelos que podem gerar previsões mais precisas do risco de colisão. A revisão do âmbito do estudo auxiliou na identificação dos dados preditos nos trabalhos relacionados com a prevenção de colisões, com vista à identificação das aproximações mais críticas, que incluem a probabilidade de colisão, o risco de colisão, a incerteza da posição, a órbita e o tempo de aproximação.

Os artigos indicam que a aplicação da IA melhora significativamente a segurança dos satélites e das missões espaciais, permitindo um maior tempo para o planejamento de manobras. Os resultados da revisão indicam que a aplicação da IA no processo de prevenção de colisões é importante para garantir

a eficiência da tomada de decisão e a segurança das missões espaciais, mesmo com o aumento dos detritos.

Como o histórico de dados orbitais de satélites ativos e de detritos é necessário para treinar o modelo, o armazenamento dos dados ao longo dos anos pode contribuir para que o modelo seja novamente gerado com melhor desempenho. No entanto, o processo de preparação de dados, treinamento e teste do modelo de aprendizagem de máquina pode demandar bastante tempo, desse modo ferramentas de automatização podem ser aplicadas para tornar a atualização mais ágil. Isso demanda trabalhos futuros que apoiem a decisão sobre a ferramenta mais adequada e a sua integração no processo atual dos centros de operação.

5. Referências Bibliográficas

- Barry, K., 2022. Space Debris Mitigation and Remediation: Historical Best Practices and Lessons Learned for Innovative Preserving and Utilizing Clean-Orbit Access. *New Space*, 10(4), pp. 246–26, <https://doi.org/10.1089/space.2021.0022>.
- Catulo, J. S., Soares, C., & Guimarães, M. (2023). Predicting the probability of collision of a satellite with space debris: A Bayesian machine learning approach. *arXiv preprint arXiv:2311.10633*. <https://doi.org/10.48550/arXiv.2311.10633>.
- Choi, S. S., Ryu, P. J., Sim, K., Seong, J., Song, J. W., Mah, M., & Kim, D. D. (2024). AstroLibrary: A library for real-time conjunction assessment and optimal collision avoidance. *Journal of Space Safety Engineering*, 11(3), 462–468. <https://doi.org/10.1016/j.jsse.2024.07.003>.
- Colvin, T., Karcz, M., and Wusk, G., 2023. Cost Benefit Analysis of Space Debris Remediation: Evaluating Early- and Late-Stage Orbits of Mega-constellations. *Acta Astronautica*, 205, pp. 131061. <https://ntrs.nasa.gov/citations/20230002817> Document ID 2023000281.
- Etherajan, S. (2023). Learned prediction for space debris collision risk and avoidance. In 2023 *7th International Conference on Electronics, Communication and Aerospace Technology (ICECA)* (pp. 1871–1875). IEEE. <https://doi.org/10.1109/ICECA58529.2023.10395345>.
- Fabbri, D., Santos, R. C. do, & Silva, F. Q. B. da. (2015). Parsifal: A web tool for supporting systematic literature reviews. In *Proceedings of the 19th International Conference on Evaluation and Assessment in Software Engineering (EASE)* (pp. 1–6). ACM. <https://doi.org/10.1145/2745802.2745822>.
- Fala Ciência. (2025, 26 de outubro). Lixo espacial cresce e coloca Terra em risco ao danificar camada de ozônio: O aumento de satélites e lixo espacial representa riscos crescentes à órbita terrestre. R7. <https://noticias.r7.com/fala-ciencia/lixo-espacial-cresce-e-coloca-terra-em-risco-ao-danificar-camada-de-ozonio-26102025/>. Recuperado em: 27/10/2025.
- Guimarães, M., Soares, C., & Manfletti, C. (2023). Predicting the position uncertainty at the time of closest approach with diffusion models. *arXiv preprint arXiv:2311.05417*. <https://doi.org/10.48550/arXiv.2311.05417>.

- Huang, G., & Shu, T. (2024). A global-local probsparse self-attention transformer for LEO satellite orbit prediction. In *2024 International Conference on Machine Learning and Applications (ICMLA)* (pp. 91–98). IEEE.
<https://doi.org/10.1109/ICMLA61862.2024.00019>.
- Hoher, T., 2023, Preventing Kessler: EU Policy Recommendations for the Mitigation of Space Debris. *AREA*, p. 55.
https://www.europeanhorizonsamsterdam.org/_files/ugd/79a695_cbb136751e7b4a3c81c6bc47b5e68887.pdf#page=56.
- Kabir, M. R., Faysal, T. I., Hossain, M. S., Shorno, J. N., & Siddique, S. (2020). A satellite collision avoidance system based on General Regression Neural Network. In *Proceedings of 2020 IEEE/ACM International Conference on Big Data Computing, Applications and Technologies (BDCAT)* (pp. 154–160). IEEE.
<https://doi.org/10.1109/BDCAT50828.2020.00004>.
- Miyashiro, M. S., Zотовици, А., Ferreira, M. G. V. & Carvalho, F. C. C. (2025). Artificial Intelligence Applications in Identifying Close Approaches Between Satellites and Space Debris, Avoiding Collision in Orbit: A Scoping Review [Protocolo de revisão de escopo]. OSF. <https://doi.org/10.17605/OSF.IO/7QU4E>.
- Mashiku, A., Frueh, C., Memarsadeghi, N., Gizzi, E., & Burton, A. (2019). Predicting satellite close approaches using statistical parameters in the context of artificial intelligence. In *Proceedings of AAS/AIAA Astrodynamics Specialist Conference*, Paper No. AAS 19-703. Document ID: 20190029048.
- Merz, K., Bastida Virgili, B., Braun, V., Flohrer, T., Funke, Q., Krag, H., ... & Siminski, J. (2017, April). Current collision avoidance service by ESA's Space Debris Office. In *7th European Conference on Space Debris* (p. 219).
<https://conference.sdo.esoc.esa.int/proceedings/sdc7/paper/1017>
- Migaud, M. R., 2020, Protecting earth's orbital environment: policy tools for combating space debris, *Space Policy*, 52, p. 101361. <https://doi.org/10.1016/j.spacepol.2020.101361>.
- Peters, M. D. J., Godfrey, C., McInerney, P., Munn, Z., Tricco, A. C., & Khalil, H. (2024). Scoping reviews. In E. Aromataris, C. Lockwood, K. Porritt, B. Pilla, & Z. Jordan (Eds.), *JBI manual for evidence synthesis*. JBI. <https://doi.org/10.46658/JBIMES-24-09>.

Phillips, M., Reed, J. B., Zwicky, D., & Van Epps, A. S. (2024). A scoping review of engineering education systematic reviews. *Journal of Engineering Education*, 113(4), 818-837.

Ramaneti, K. A., Krishna, C., Ahmed, A., & Rajesh, R. (2021). Autonomous space debris collision avoidance system. In *Proceedings of Advances in Automation, Signal Processing, Instrumentation, and Control: Select Proceedings of i-CASIC 2020* (pp. 2489–2501). Springer. http://dx.doi.org/10.1007/978-981-15-8221-9_232.

Schaus, V., Andriof, T., Borrett, C., Burmeister, I., Cabral, F., Carvalho, J., Daugs, M., Hetherton, L., Jung, F., de la Llave, A., Martinavarro, S., McNally, K., Mirgizoudi, M., Natarajan, D. K., Nuske, M., Pathak, D. K., Purton, I., Schiemenz, F., Tenacci, Z., Veith, B., Siminski, J., & Merz, K. (2022). First results of ESA's collision risk estimation and automated mitigation (CREAM) programme. In *Proceedings of the International Astronautical Congress* (Vol. 2022-September). International Astronautical Federation (IAF).

<https://www.dfki.de/en/web/research/projects-and-publications/publication/12989>.

Space-Track.org. (s.d.). Space-Track.org: Promoting space flight safety, protecting the space environment, and supporting the peaceful use of space. <https://www.space-track.org/auth/login>. Recuperado em: 27/10/2025.

Thompson, R., 2015. Space Debris Primer Crosslink. *The Aerospace and Corporation magazine of advances in aerospace technology. Understanding Space Debris*, 16(3), pp. 6–7. <https://aerospace.org/sites/default/files/2019-04/Crosslink%20Fall%202015%20V16N1%20.pdf>.

Tricco, A. C., Lillie, E., Zarin, W., O'Brien, K. K., Colquhoun, H., Levác, D., ... & Higgins, J. P. T. (2018). PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and explanation. *Annals of Internal Medicine*, 169(7), 467-473. <https://doi.org/10.7326/M18-0850>

Uriot, T., Izzo, D., Simões, L. F., Abay, R., Einecke, N., Rebhan, S., MartinezHeras, J., Letizia, F., Siminski, J., & Merz, K. (2022). Spacecraft collision avoidance challenge: Design and results of a machine learning competition. *Astrodynamics*, 1–20. <https://doi.org/10.1007/s42064-021-0101-5>.

Viavattene, G., Devereux, E., Snelling, D., Payne, N., Wokes, S., and Ceriotti, M., 2022, "Design of multiple space debris removal missions using machine learning" *Acta Astronautica*, 193, pp. 277–286. <https://doi.org/10.1016/j.actaastro.2021.12.051>.

Yap, X.-S., Heiberg, J., and Truffer, B., 2023. The emerging global socio-technical regime for tackling space debris: A discourse network analysis. *Acta Astronautica*, 207, pp. 445–454. <http://dx.doi.org/10.1016/j.actaastro.2023.01.016>.

Agradecimentos

Nossos agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pelo apoio Financiamento – Código de Financiamento 001.

Contribuição dos(as) autores(as)

Conforme descrito no protocolo da revisão de escopo (Miyashiro *et al.*, 2025) publicado na OSF.

Autor 1 = Primeiro revisor: Metodologia (Conceito e desenho do estudo/ Busca e seleção/ Coleta de dados/ Análise de dados/ Preparação do manuscrito) e Revisão do manuscrito.

Autor 2 = Segundo revisor: Metodologia (Conceito e desenho do estudo/ Busca e seleção/ Coleta de dados/ Análise de dados/ Preparação do manuscrito) e Revisão do manuscrito.

Autor 3 = Terceiro revisor (Análise de dados) Revisão do manuscrito.

Autor 4 = Especialista (Análise de dados) Revisão do manuscrito.

Declaração de conflito de interesse

Os autores declaram que não há conflito de interesse com o artigo IA para Detecção de Aproximações entre Satélites e Detritos: Revisão de Escopo.