

## 15º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2024

### CONSTRUÇÃO DE BANCO DE DADOS PARA IDENTIFICAR NUVENS MAGNÉTICAS

M. OLIVEIRA BOTELHO<sup>1</sup>, M.W. OLIVEIRA<sup>2</sup>

<sup>1</sup> Graduanda em Licenciatura em Matemática, Bolsista PIBIFSP, IFSP, Campus São José dos Campos, milene.botelho@ifsp.edu.br.

<sup>2</sup> Doutor em Ciências da Computação e Matemática Computacional pela Universidade de São Paulo, Brasil(2016)  
Professor do Instituto Federal de Ciências e Tecnologia de SP, oliveiramw@ifsp.edu.br

Área de conhecimento (Tabela CNPq): 1.01.04.01-1 Física Matemática

**RESUMO:** As Ejeções de Massa Coronal (CMEs) são eventos solares que liberam grandes volumes de plasma magnetizado. Quando essas ejeções se propagam pelo meio interplanetário, são conhecidas como Ejeções de Massa Coronal Interplanetárias (ICMEs). A modelagem do campo magnético dessas estruturas, especialmente das nuvens magnéticas (MCs) com possíveis configurações cilíndricas, representa um dos principais desafios na investigação das ICMEs. Este estudo realiza uma revisão da literatura sobre modelagem geométrica das MCs. Além disso, a pesquisa visa desenvolver um banco de dados de imagens para aprimorar a criação de modelos automáticos, baseados em Redes Neurais e outras metodologias de aprendizado de máquina. Devido ao volume e à complexidade dos dados, a classificação manual das MCs é demorada e trabalhosa para pesquisadores. Desse modo, esse estudo propõe um banco de dados que busca otimizar a eficiência das análises na área.

**PALAVRAS-CHAVE:** Heliofísica. Nuvens magnéticas. Aprendizado de máquina. Modelagem geométrica.

### CONSTRUCTION OF A DATABASE TO IDENTIFY MAGNETIC CLOUDS

**ABSTRACT:** Coronal Mass Ejections (CMEs) are solar events that release large volumes of magnetized plasma. When these ejections propagate through the interplanetary medium, they are known as Interplanetary Coronal Mass Ejections (ICMEs). Modeling the magnetic field of these structures, especially magnetic clouds (MCs) with potential cylindrical configurations, represents one of the main challenges in ICME research. This study conducts a literature review on the geometric modeling of MCs. Furthermore, the research aims to develop an image database to enhance the creation of automatic models based on Neural Networks and other machine learning methodologies. Due to the volume and complexity of the data, the manual classification of MCs is time-consuming and laborious for researchers. Therefore, this study proposes a database that seeks to optimize the efficiency of analyses in the field.

**KEYWORDS:** Heliophysics. Magnetic clouds. Machine learning. Geometric modeling.

### INTRODUÇÃO

A dinâmica do Sistema Solar é influenciada pela atividade magnética, com destaque para as Ejeções de Massa Coronal Interplanetárias (ICMEs). Essas ejeções, oriundas de explosões solares, transportam grandes quantidades de massa e fluxos magnéticos intensos, que ao interagirem com a magnetosfera terrestre, provocam processos de reconexão magnética (dos Santos et al., 2020). Quando as ICMEs apresentam peculiaridades específicas como: (i) valores de beta do plasma inferiores a um, (ii) campo magnético médio mais intenso que o vento solar circundante, (iii) baixa temperatura dos íons e (iv) rotação angular significativa do vetor do campo magnético (Burlaga, 1988, citado por Rosa Oliveira et al., 2021), formam as chamadas Nuvens Magnéticas (MCs). A monitoração dessas

características é importante para prever impactos potenciais na tecnologia terrestre, como satélites, redes de comunicação e missões espaciais.

A modelagem geométrica das MCs e o uso de técnicas de aprendizado de máquina são ferramentas eficientes para aprofundar a compreensão desses fenômenos e melhorar as previsões. A modelagem geométrica fornece uma representação detalhada da estrutura interna das MCs, enquanto o aprendizado de máquina facilita a análise de grandes volumes de dados. A integração dessas abordagens automatiza a classificação dos eventos e identifica padrões através do aprendizado de máquinas (ML). Este trabalho é resultado de uma iniciação científica em andamento e, a seguir, apresenta-se uma revisão dos modelos utilizados para a caracterização das MCs, a metodologia de aprendizado de máquina empregada, estratégias para a construção do banco de imagens e as conclusões alcançadas até o momento.

## REVISÃO BIBLIOGRÁFICA

A modelagem geométrica das Nuvens Magnéticas (MCs) é uma área de estudo em desenvolvimento contínuo. Goldstein (1983) propõe que as MCs assumem a forma de um tubo de fluxo magnético, onde as correntes elétricas são paralelas ou antiparalelas às linhas do campo magnético, configurando-as como um corpo cilíndrico com plasma magnetizado e linhas de campo torcidas (Goldstein, 1983; Bothmer e Schwenn, 1998, citado por Oliveira, 2020; Priest e Forbes, 1990, citado por Oliveira, 2020). Com base nesta configuração, modelos analíticos são desenvolvidos para reconstruir e analisar as características topológicas das MCs, permitindo a adaptação dos modelos a dados reais de eventos.

As MCs são frequentemente detectadas por satélites no vento solar e suas configurações são analisadas para identificar assinaturas em suas linhas de fluxo magnético, possibilitando a interpretação de informações como rotação, direção e intensidade, entre outras configurações complexas. Para determinar a rotação do eixo cilíndrico, alguns autores utilizam o método da mínima variância (MVA). Esta técnica envolve uma mudança de base no espaço dos dados por meio de autovalores e autovetores, e pode ser ajustada pelo modelo de equilíbrio livre de força, com soluções baseadas em funções de Bessel (Rosa Oliveira et al., 2021).

O formato cilíndrico das MCs possui peculiaridades que são discutidas na literatura. Explora-se as principais abordagens geométricas utilizadas para modelar essas estruturas, com foco nos modelos geométricos cilíndrico-elíptico (EC) e cilíndrico-circular (CC) (Nieves-Chinchilla et al., 2016, 2018). A revisão inclui uma análise dos trabalhos de Oliveira (2021), Santos (2019) e Nieves-Chinchilla (2016), que fundamentam a metodologia para construção do banco de dados e garantem uma compreensão dos modelos geométricos existentes e sua aplicação no aprendizado de máquinas.

A conversão dos dados observacionais *in situ*, geralmente em formato 1D, como os fornecidos pelo satélite Advanced Composition Explorer (ACE), para um modelo 3D é um problema ainda em investigação. A reconstrução geométrica do evento utiliza uma técnica que infere a trajetória da espaçonave, traduzindo o sistema de coordenadas da espaçonave para o sistema de coordenadas cartesianas locais. Os componentes do campo magnético são descritos utilizando longitude ( $\phi$ ) e latitude ( $\theta$ ), que representam a inclinação do eixo das MCs no sistema de coordenadas GSE (Goldstein, 1983; Rosa Oliveira et al., 2021).




FIGURA 1. Modelo geométrico circular-cilíndrico (CC).  
 Fonte: Adaptado de Nieves-Chinchilla (2016).

A identificação de nuvens magnéticas (MCs) em Ejeções de Massa Coronal Interplanetárias (ICMEs) vem se beneficiando do aprendizado de máquina. Estudos recentes exploram redes neurais profundas para aumentar a precisão e a eficiência na análise de grandes volumes de dados. Santos e cols. (2020), por exemplo, obteve uma Rede Neural Convolutiva Profunda (DCNN) para identificar assinaturas de tubo de fluxo em dados *in situ*, treinando o modelo com dados sintéticos e reais e avaliando-o com eventos observados pelo satélite Wind (1995-2015).

A disponibilidade crescente de séries temporais em heliofísica, como a precisão do campo magnético interplanetário (FMI), vem impulsionando o uso de técnicas de big data no clima espacial (Camporeale, 2018; Ramos et al., 2023). Embora o número de eventos MCs coletados seja limitado, a classificação direta de dados de satélite ainda é inovadora. O estudo de Santos et al. (2020) representa um avanço nessa área, e esta iniciação científica adota abordagem semelhante.

Nenhum estudo de Santos et al. (2020), foram usadas imagens de hodogramas editadas, sem eixos ou marcadores. Hodogramas são gráficos 2D dos componentes do campo magnético durante eventos, combinados dois a dois. Para dados reais, utilizam-se as coordenadas do FMI. Imagens sintéticas foram geradas ajustando parâmetros do modelo cilíndrico-circular (Nieves-Chinchilla et al., 2016) e adicionando ruídos gaussianos.




FIGURA 2. Hodogramas das componentes do campo magnéticos de ICME observada em 13 de abril de 2006.

Fonte: Adaptado da Figura 5 em Santos et. al 2020.

Adicionalmente, Rosa Oliveira et al. (2021) utiliza hodogramas de dados reais e sintéticos para resolver a ambiguidade na orientação das MCs causada pelo método da mínima variância (MVA). Os hodogramas obtidos das componentes transformadas pelo MVA representam os planos de máxima, mínima e média variância dos dados obtidos *in situ*. Em contraste, Rosa Oliveira et al. (2021) utiliza dados sintéticos baseados no modelo livre de força e combinado à rotação um ângulo  $w$ .

## METODOLOGIA

O aprendizado de máquina, um campo da Inteligência Artificial, permite que os sistemas aprendam e sejam projetados a partir de dados, dependendo da necessidade de intervenção humana (Faceli, 2011). Este trabalho propõe construir um banco de dados para aplicar modelos de aprendizado de máquina no estudo das Ejeções de Massa Coronal Interplanetárias (ICMEs), automatizar e melhorar a classificação de eventos de nuvens magnéticas (MCs).

A criação do banco de dados segue a abordagem de dos Santos et al. (2020), que utiliza imagens de hodogramas baseados em dados simulados e reais. O diferencial deste estudo é a técnica de Rosa Oliveira et al. (2021), que aprimora hodogramas com o método da mínima variância (MVA) para dados reais e gera hodogramas sintéticos com um modelo livre de forças e giros.

Para os hodogramas reais, o MVA é aplicado a dados *in situ* do satélite Advanced Composition Explorer (ACE). Esse método determina a orientação do campo magnético ao maximizar a variância em uma direção e minimizá-la em outras, facilitando a identificação de estruturas magnéticas complexas. As imagens dos hodogramas reais são geradas sem eixos, focando nos componentes magnéticos.

Os três hodogramas são plotados em 2D com os componentes do campo magnético ao longo do eixo da nuvem magnética  $B_A$ ,  $B_T$  e  $B_R$  (Oliveira, 2020), calculados pelas funções de Bessel (1) e (2) com relação  $B_A \times B_T$ ,  $B_R \times B_A$  e  $B_R \times B_T$ , que representam os componentes do campo magnético.

$$J_0(x) = \sum_{m=0}^{\infty} \frac{(-1)^m}{m! m!} \left(\frac{x}{2}\right)^{2m} \quad (1)$$

$$J_1(x) = \sum_{m=0}^{\infty} \frac{(-1)^m}{m! (m+1)!} \left(\frac{x}{2}\right)^{2m+1} \quad (2)$$

$$B_A = B_0 J_0(\alpha R), \quad B_T = B_0 H J_1(\alpha R), \quad e \quad B_R = 0 \quad (3)$$

Para a geração dos hodogramas reais e sintéticos, são utilizados os dados do satélite ACE e a tabela de Cane e Richardson (2008), que fornece uma lista de eventos observados no vento solar. A partir dessa tabela, são detalhados outros parâmetros característicos dos eventos, utilizando o programa Automatic Magnetic Cloud Data Analysis (AMCDA), conforme descrito nos apêndices de Rosa Oliveira et al. (2021). A Figura 3 apresenta um exemplo com 6 hodogramas sendo 3 pares de planos de máxima e mínima variância (nas colunas) da figura e correspondendo a dados obtidos *in situ* transformados pelo MVA (ao centro) e dois cenários de dados sintéticos (à esquerda e à direita).

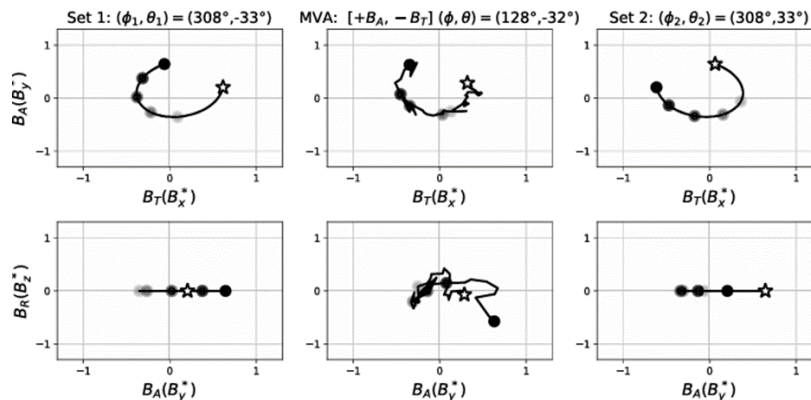


FIGURA 3 .Hodogramas das componentes do campo magnéticos de ICME observado em 28 de fevereiro de 2002 ao centro e hodogramas de dados sintéticos à esquerda e à direita

Fonte: Figura 5 em Rosa Oliveira et al 2021.

Cada imagem do banco de dados é rotulada com base na inclinação do eixo do tubo de fluxo magnético. A inclinação do eixo varia de  $0^\circ$  a  $360^\circ$ , e a classificação distingue entre tubos de fluxo bipolares e unipolares:

**Tubos de Fluxo Bipolares:** Quando o eixo do tubo de fluxo está quase paralelo ao plano da eclíptica ( $|\theta| \leq 45^\circ$ ), a componente  $B_R$  muda de sinal durante a passagem pelo satélite. Este comportamento caracteriza os tipos de nuvens magnéticas SWN, SEN, NES e NWS.

**Tubos de Fluxo Unipolares:** Quando a inclinação do eixo  $B_R$  é alta ( $|\theta| > 45^\circ$ ) em relação ao plano da eclíptica, a componente não muda de sinal, caracterizando os tipos WNE, ESW, ENW e WSE (Oliveira, 2021).

A rotulação é o alvo para a futura aplicação de aprendizado de máquina e classificação dos tipos de nuvens magnéticas. Ou seja, construir este banco de dados consiste de etapa inicial para o treinamento de modelos de aprendizado de máquina que visem a identificação e classificação de nuvens magnéticas com maior precisão e eficiência.

## CONCLUSÃO

Este trabalho aborda a estrutura das Ejeções de Massa Coronal Interplanetárias (ICMEs) e das Nuvens Magnéticas (MCs), com o objetivo de aprimorar as previsões do clima espacial e proteger as tecnologias terrestres e orbitais. A combinação da modelagem geométrica das MCs com técnicas de aprendizado de máquina é uma abordagem que visa entender e prever os impactos desses eventos no clima espacial.

A metodologia adotada, inclui a aplicação do método da mínima variância (MVA) e a construção de hodogramas utilizando modelos geométricos com adição de ruído gaussiano, baseia-se em estudos consolidados, como Rosa Oliveira et al. (2021) e Santos et al. (2020). A integração de dados reais e sintéticos, possibilita uma análise mais robusta das características das MCs.

A pesquisa em aprendizado de máquina aplicada ao estudo das ICMEs ainda está em fase emergente, e trabalhos como o presente são essenciais para avançar na construção de ferramentas que promovam o progresso científico. Este estudo apresenta uma etapa preliminar dentro de um projeto de iniciação científica, com o objetivo de desenvolver um banco de dados que, no futuro, será utilizado para treinar modelos de aprendizado de máquina e redes neurais. A comparação dos resultados analíticos obtidos com os estudos anteriores, como o de Santos et al. (2020), será crucial para validar e aprimorar as metodologias propostas.

A continuidade desta pesquisa visa fornecer recursos para a comunidade científica, contribuindo para o estudo de eventos solares. Ao disponibilizar um banco de dados e metodologias, esperamos apoiar o avanço na compreensão do clima espacial.

## CONTRIBUIÇÕES DOS AUTORES

Milene Botelho é a orientanda de iniciação científica responsável pela execução do trabalho, análise dos dados, e a redação do artigo. Marcos William é professor Dr. orientador, contribuindo com a análise crítica, validação dos resultados e revisão do texto. Todos os autores revisaram e aprovaram a versão final do texto.

## AGRADECIMENTOS

MOB agradece ao IFSP-SJC pelo apoio institucional recebido por meio do programa PIBIFSP, principalmente ao professor doutor Marcos William pelo suporte e orientação para o desenvolvimento deste trabalho e da pesquisa em andamento.

## REFERÊNCIAS

BOTHMER, V.; SCHWENN, R. **The structure and origin of magnetic clouds in the solar wind.** *Annales Geophysicae*, v. 16, p. 1-24, 1998.

BURLAGA, L. F. **Magnetic clouds and force-free fields with constant alpha.** *Journal of Geophysical Research*, v. 93, n. A7, p. 7217-7224, 1988. DOI: 10.1029/JA093iA07p07217.

CAMPOREALE, E. **The Challenge of Machine Learning in Space Weather: Nowcasting and Forecasting.** *Space Weather*, v. 17, n. 8, p. 1166-1207, 2019. Feature Article. Free Access. First published: 04 July 2019. DOI: 10.1029/2018SW002061.

FACELI, K.; LORENA, A. C.; GAMA, J. M.; CARVALHO, A. C. P. L. F. **Inteligência artificial: uma abordagem de aprendizado de máquina.** Rio de Janeiro: LTC, 2011.

GOLDSTEIN, H. **On the field configuration in magnetic clouds.** *Solar Wind Five*, NASA Conference Publication, v. 2280, p. 731-733, 1983.

NIEVES-CHINCHILLA, T.; JIAN, L. K.; BALMACEDA, L. et al. **Unraveling the internal magnetic field structure of the Earth-directed interplanetary coronal mass ejections during 1995–2015.** *Solar Physics*, v. 294, n. 89, 2019. DOI: 10.1007/s11207-019-1477-8.

NIEVES-CHINCHILLA, T.; LINTON, M. G.; HIDALGO, M. A.; VOURLIDAS, A. **Elliptic-cylindrical analytical flux rope model for magnetic clouds.** *The Astrophysical Journal*, v. 861, n. 2, 2018. DOI: 10.3847/1538-4357/aac951.

NIEVES-CHINCHILLA, T.; LINTON, M. G.; HIDALGO, M. A.; VOURLIDAS, A.; SAVANI, N. P.; SZABO, A.; FARRUGIA, C.; YU, W. **A circular-cylindrical flux-rope analytical model for magnetic clouds.** *The Astrophysical Journal*, v. 823, n. 1, 2016. DOI: 10.3847/0004-637X/823/1/27.

OLIVEIRA, R. A. R. **Caracterização geométrica de nuvens magnéticas interplanetárias por meio de experimentos computacionais.** Tese (Doutorado) — Instituto de Pesquisa e Desenvolvimento, Universidade do Vale do Paraíba - IP&D-UNIVAP, 2021.

OLIVEIRA, R. A. R.; OLIVEIRA, M. W. S.; OJEDA-GONZÁLEZ, A. et al. **New metric for minimum variance analysis validation in the study of interplanetary magnetic clouds.** *Solar Physics*, v. 295, n. 45, 2020. DOI: 10.1007/s11207-020-01610-6.

OLIVEIRA, R. A. R. et al. **Automatic magnetic cloud data analysis - AMCDA.** Zenodo, set. 2021.

OLIVEIRA, R. A. R. et al. **Resolving the ambiguity of a magnetic cloud's orientation.** *Solar Physics*, 2021.

PRIEST, E. R.; FORBES, T. G. **Magnetic field evolution during prominence eruptions and two-ribbon flares.** *Solar Physics*, v. 126, p. 319-350, 1990.

RAMOS, A. A.; CHEUNG, M. C. M.; CHIFU, I.; GAFEIRA, R. **Machine learning in solar physics.** *Living Reviews in Solar Physics*, v. 20, n. 4, 2023. Review Article. Submitted on 27 Jun. 2023; received on 17 Jan. 2023; accepted on 13 Jun. 2023; published online on 13 Jul. 2023. DOI: 10.1007/s41116-023-00038-x.

SANTOS, L. F. G.; NAROCK, A.; NIEVES-CHINCHILLA, T. et al. **Identifying flux rope signatures using a deep neural network.** *Solar Physics*, v. 295, n. 131, 2020. DOI: 10.1007/s11207-020-01697-x.