



人工智能在空间天气建模中的应用综述

张灵倩, 李晖, 魏新华, 罗冰显, 王继业, 张月霞, 刘文超, 王爵, 王铁砚, 宋伟, 郑睿, 于静, 杨雅捷, 王铮, 王赤

引用本文:

张灵倩, 李晖, 魏新华, 等. 人工智能在空间天气建模中的应用综述[J]. 地球物理学报, 2026, 69(7): 2735–2764.

Zhang L Q, Li H, Wei X H, et al. A review of artificial intelligence applications in space weather modeling[J]. *Chinese Journal of Geophysics*, 2026, **69**(7): 2735–2764.

<https://doi.org/10.6038/cjg2025T0472>

相关论文

基于人工智能和VLF信号传播的昼夜过渡区电子密度反演

彭怀云, 王茂琰, 张世田, 徐彤, 刘兵, 李海龙, 吴健
地球物理学报 2026, **69**(4): 1438–1446 doi: [10.6038/cjg2025T0162](https://doi.org/10.6038/cjg2025T0162)

川滇地区地震活动性的聚类分析与人工智能预报

刘天雅, 张怀, 袁正, 谭传奇, 黄松芳, 黄非, 石耀霖
地球物理学报 2026, **69**(1): 244–264 doi: [10.6038/cjg2025S0608](https://doi.org/10.6038/cjg2025S0608)

基于电成像测井资料的裂缝智能拾取方法与应用研究

罗世鸿, 伍东, 陈永权, 林旺, 杨果, 章成广, 蔡明, 张远君
地球物理学报 2025, **68**(11): 4482–4497 doi: [10.6038/cjg2025S0482](https://doi.org/10.6038/cjg2025S0482)

智能导向钻井一体化软件系统平台研发

付长民, 王啸天, 底青云
地球物理学报 2023, **66**(1): 139–152 doi: [10.6038/cjg2022Q0416](https://doi.org/10.6038/cjg2022Q0416)

大闭环伺服控制随钻智能导向钻井方法

吴思源, 李守定, 陈冬, 李晓, 杜爱民, 张莹
地球物理学报 2021, **64**(11): 4215–4227 doi: [10.6038/cjg202100449](https://doi.org/10.6038/cjg202100449)

百米级气象数值模拟研究进展与展望

马小娇, 陈敏, 黄向宇, 苗世光, 李玉焕
地球物理学报 2023, **66**(5): 1911–1930 doi: [10.6038/cjg2022Q0216](https://doi.org/10.6038/cjg2022Q0216)



关注微信公众号, 获得更多资讯信息

张灵倩, 李晖, 魏新华等. 2026. 人工智能在空间天气建模中的应用综述. 地球物理学报, 69(7): 2735-2764, doi: 10.6038/cjg2025T0472.

Zhang L Q, Li H, Wei X H, et al. 2026. A review of artificial intelligence applications in space weather modeling. *Chinese J. Geophys.* (in Chinese), 69(7): 2735-2764, doi: 10.6038/cjg2025T0472.



人工智能在空间天气建模中的应用综述

张灵倩¹, 李晖¹, 魏新华¹, 罗冰显¹, 王继业², 张月霞³, 刘文超⁴, 王爵⁴,
王铁砚⁵, 宋伟², 郑睿², 于静², 杨雅捷^{1,2}, 王铮¹, 王赤^{1*}

- 1 中国科学院国家空间科学中心(太阳活动与空间天气全国重点实验室), 北京 100080
- 2 中央民族大学信息工程学院, 北京 100081
- 3 北京信息科技大学信息与通信工程学院, 北京 102206
- 4 北京理工大学(天基智能信息处理全国重点实验室), 北京 100081
- 5 云南大学地球科学学院地球物理系, 昆明 650091

摘要 近年来, 人工智能技术在空间天气与空间探测领域的深度融合, 正加速推动空间科学从“物理-数值模拟”范式向“物理引导的数据智能建模”范式转型. 本文全面整合空间科学各子领域研究进展, 系统回顾了 AI 在太阳物理、日冕动力学、日地耦合、地磁扰动、磁暴与亚暴、电离层响应、磁重联与湍流演化及行星空间环境等典型过程中的建模与预测应用. 重点梳理了卷积神经网络、深度学习、Transformer、物理信息神经网络(PINNs)等主流算法在多尺度复杂过程中的建模性能, 揭示其在事件识别、时序预测、物理结构重构、因果推演等方面的优势与挑战. 本文进一步剖析了空间天气 AI 模型普遍存在的可解释性不足、数据不平衡、模型泛化性差等问题, 并强调“AI-ready”标准化数据库建设的基础性作用. 以 NASA SDO 项目、SPASE 元数据模型、以及中国子午工程(CMP)为例, 探讨了多源、多尺度观测数据与物理模拟协同体系对 AI 模型训练与验证的关键支撑作用. 倡议依托子午工程为战略支点, 建设“以空间任务为牵引, 以探测数据为基石, 以 AI 技术为引擎”的中国空间智能基础设施.

关键词 空间天气; 太阳活动; 磁层活动; 人工智能; 机器学习

中图分类号 P35

收稿日期 2025-08-03, 2025-10-29 收修定稿

DOI: 10.6038/cjg2025T0472

CSTR: 32084.14.cjg2025T0472

A review of artificial intelligence applications in space weather modeling

ZHANG LingQian¹, LI Hui¹, WEI XinHua¹, LUO BingXian¹, WANG JiYe², ZHANG YueXia³,
LIU WenChao⁴, WANG Jue⁴, WANG TieYan⁵, SONG Wei², ZHENG Rui², YU Jing²,
YANG YaJie^{1,2}, WANG Zheng¹, WANG Chi^{1*}

- 1 State Key Laboratory of Space Weather, National Space Science Center, Chinese Academy of Sciences, Beijing 100080, China
- 2 Information Engineering College, MinZu University of China, Beijing 100081, China
- 3 School of Information and Communication Engineering, Beijing Information Science and Technology University, Beijing 102206, China
- 4 National Key Laboratory of Science and Technology on Space-Born Intelligent Information Processing, Beijing Institute of Technology, Beijing 100081, China
- 5 Department of Geophysics, School of Earth Sciences, Yunnan University, Kunming 650091, China

基金项目 太阳活动与空间天气全国重点实验室专项基金项目, 国家自然科学基金项目(42374198, 42188101), 民用航天“十四五”空间科学预研项目(D010301, D010202), 中国科学院国际伙伴计划(183311KYSB20200017), 及子午工程数据治理能力提升与数智驱动的电波环境应用项目联合资助.

第一作者简介 张灵倩, 女, 1972 年生, 副研究员, 硕士生导师, 主要从事空间天气及人工智能交叉研究. E-mail: lqzhang@nssc.ac.cn

*** 通讯作者** 王赤, 男, 1967 年生, 院士, 博士生导师, 主要从事太阳活动、空间物理和空间天气建模相关研究. E-mail: cw@spaceweather.ac.cn

Abstract In recent years, the deep integration of Artificial Intelligence (AI) technologies into space weather and space exploration is accelerating a paradigm shift in space science, from the traditional “physics–numerical simulation” model toward a new “physics-guided data-intelligent modeling” framework. This paper comprehensively synthesizes research progress across various subfields of space science and systematically reviews AI-driven modeling and prediction applications in key processes such as solar physics, coronal dynamics, solar–terrestrial coupling, geomagnetic disturbances, magnetic storms and substorms, ionospheric responses, magnetic reconnection and turbulence evolution, and planetary space environments. Special attention is given to the modeling capabilities of mainstream AI algorithms, including Convolutional Neural Networks (CNNs), deep learning, Transformers, and Physics-Informed Neural Networks (PINNs), in capturing multi-scale, complex physical phenomena. Their strengths and limitations in event identification, time-series forecasting, physical structure reconstruction, and causal inference are discussed in detail. The paper further analyzes common challenges in current space weather AI models, including poor interpretability, imbalanced datasets, and limited generalization capability, and emphasizes the foundational importance of building standardized “AI-ready” databases. Using examples such as NASA’s SDO mission, the SPASE metadata model, and China’s Meridian Project (CMP), the paper explores how multi-source, multi-scale observational data and physical simulation frameworks provide critical support for AI model training and validation. It advocates leveraging the Meridian Project as a strategic platform to build an intelligent infrastructure for China’s space science of “mission-driven, data-grounded, and AI-powered”.

Keywords Space weather; Solar activity; Magnetosphere activity; Artificial Intelligence; Machine Learning

0 引言

空间天气 (Space Weather) 是指由于太阳活动引发的扰动在日地空间传播, 并作用于地球磁层、电离层及热层等近地空间环境的一系列物理过程的总称 (Akasofu, 1980). 主要扰动源包括超声速太阳风、行星际磁场 (Interplanetary Magnetic Field, IMF) 变化、高能粒子注入及伴随的电磁辐射等, 这些扰动多由太阳黑子 (Albregtsen and Maltby, 1978)、太阳耀斑 (Dessler, 1967)、日冕物质抛射 (Coronal Mass Ejection, CME) (Cargill and Harra, 2007) 以及太阳高能粒子事件 (Bougeret and Pick, 2007) 等太阳活动引发. 这些扰动诱发了一系列空间响应, 包括地磁暴、磁层亚暴、电离层极光增强和辐射带扰动等 (Dungey, 1961; Akasofu, 1981; Baker et al., 1994). 太阳风的尺度与强度对空间天气的演化具有决定性作用. 例如, 在中尺度 (约 1~2 小时) 上的持续 IMF 南向太阳风会驱动亚暴, 表现为磁层 (磁尾重联和磁场偶极化)、电离层 (极区极光点亮)、极区 Pi2 信号增强, 及地面 (地磁 AE 指数增长) 等不同等离子体区域的活动 (Baker et al., 1996). 而强 CME 驱动的地磁暴可持续数小时至数天, 造成全球磁层重构与地面感应电流增强, 可能引发卫星电子设备故障、通

信导航中断, 甚至对地面电网构成威胁 (Wik et al., 2009; Matamba and Habarulema, 2018; Buzulukova and Tsurutani, 2022). 随着社会对航天、通信与导航基础设施的日益依赖, 空间天气的监测、建模与预警能力显得尤为关键 (Camporeale, 2020).

空间天气过程呈现出高度非线性、多尺度耦合及间歇性等复杂特征. 传统的空间天气研究主要依赖三大核心手段, 分别是理论建模、观测手段以及数值模拟. 这三者构成了现代空间物理学研究的基础框架, 支撑着我们对日地系统中各种复杂物理过程的理解与分析. 首先, 理论建模作为空间天气研究的起点, 依托经典的电磁场理论、等离子体物理和磁流体动力学 (Magnetohydrodynamics, MHD), 构建出一套描述太阳风与地球磁层、电离层相互作用的数理方程体系. 这类模型涵盖了等离子体运动、磁场演化、能量传输等多个物理量的耦合演化过程, 是理解磁重联、激波传播、环电流形成等关键现象的重要工具 (Baker et al., 1994). 早期理论如 Dungey 磁层对流模型 (Dungey, 1961) 和 Akasofu 能量装-卸载模型 (Akasofu, 1981) 为磁层动力学研究奠定了基础. 其次, 地面与天基观测提供了对空间天气系统直接和间接的实测数据支撑. 典型的空間探测任务包括太阳风监测卫星 (Advanced Composition Explorer,

ACE)、地磁场观测卫星 (Geostationary Operational Environmental Satellite, GOES) 以及磁层多点测量任务 (Magnetospheric Multiscale Mission, MMS) 等. 这些任务通过搭载磁强计、离子与电子分析器、等离子体探测器等多种高精度传感器, 获取太阳风速度、密度、磁场方向、高能粒子流等关键参数, 为研究磁层响应机制与事件驱动过程提供了数据基础. 此外, 地面磁力计网络、极光观测站、雷达系统 (如 SuperDARN) 和 GPS 接收器等, 也构成了地面观测的重要组成部分, 实现了对地磁扰动、电离层总电子含量 (Total Electron Content, TEC) 变化等现象的连续监测. 第三, 数值模拟是连接理论与观测的关键桥梁, 特别是在无法进行实地实验的空间环境中, 其重要性日益突出. 全球 MHD 模拟是最常用的一类方法, 它通过求解耦合的 MHD 方程来重构从太阳风注入到磁层、电离层响应的全链条过程. 代表性的全球模型包括 SWMF (Space Weather Modeling Framework)、OpenGGCM、LFM (Lyon-Fedder-Mobarry) 模型等. 此外, 粒子轨道追踪 (Particle Tracing)、混合模拟 (Hybrid Simulations) 和 PIC (Particle-in-Cell) 等方法也被用于刻画微观粒子加速与波粒相互作用等细节机制.

近年来, 人工智能 (Artificial Intelligence, AI) 技术的迅猛发展为空间物理注入了新的活力, 尤其是在大数据背景下, 机器学习 (Machine Learning, ML) 展现出对日地空间环境这一高度非线性系统建模的强大潜力 (Baker, 2020; Azari et al., 2020; Liemohn et al., 2021; Asensio et al., 2023). 机器学习通过统计规律学习输入与输出之间复杂的映射关系, 避免了对显式物理先验的依赖, 特别适用于以观测数据为驱动的建模任务. 典型的学习范式包括监督学习、无监督学习、半监督学习与强化学习 (Pankratius et al., 2016). 相较于传统方法, ML 具备以下三大显著优势: (1) 适应非线性、多耦合系统建模; (2) 能够从海量历史数据中自动挖掘潜在模式; (3) 支持多源异构数据的融合建模. 这些特性使其成为空间天气建模的重要工具, 为提升模型精度与泛化能力提供了有力支撑 (Breiman et al., 1984; Coveney et al., 2016; Lugaz et al., 2021; Poduval et al., 2023a, b).

神经网络是当前机器学习领域的核心技术之一. 从建模机制角度看, 神经网络大致可分为两大类: 数据驱动神经网络 (Data-Driven Neural Network, DDNN) 与物理信息神经网络 (Physics-Informed Neural

Network, PINN) (Cai et al., 2021; Poduval et al., 2023a, b; Nair et al., 2023; Anirudh et al., 2023). 前者强调从数据中直接学习特征, 主要依赖于高质量观测数据训练模型, 广泛应用于预测、分类等任务中. 近年来, 基于人工神经网络 (Artificial Neural Network, ANN)、卷积神经网络 (Convolutional Neural Network, CNN)、循环神经网络 (Recurrent Neural Network, RNN) 等技术的 DDNN 方法已在空间天气多个子领域取得突破性成果, 逐渐成为空间物理研究的重要支撑工具 (McGranaghan et al., 2017; Camporeale, 2019). 相较之下, PINN 将控制方程、边界条件等已知物理规律显式嵌入网络结构与损失函数中, 在优化过程中同时最小化数据误差与物理残差, 进而提升模型的物理一致性与可解释性 (Bard and Dorelli, 2021). 该方法在科学计算、工程仿真等数据稀缺或难以获取的领域表现出更强的泛化能力与鲁棒性 (Abiodun et al., 2018).

当前空间天气研究中仍以数据驱动的机器学习技术为主. 然而, 空间天气数据本身具备极高的复杂性, 这为 ML 建模带来了诸多挑战. 首先, 数据类型多样, 涵盖时间序列 (如磁场变化、太阳风速度)、图像 (如太阳 X 射线图、极光图像)、光谱 (或粒子能谱) 及雷达回波 (如 SuperDARN) 等多模态信息. 其次, 空间等离子体系统包含多种离子成分, 携带电场、磁场与电流等复杂参量, 形成高度耦合、高维度的磁流体环境. 第三, 空间天气过程具有强烈的非平稳性与间歇性, 广泛伴随湍流主导的激波、间断面、相干结构等多尺度动力过程. 第四, 数据来源高度异构, 跨越天基与地基平台, 融合不同轨道、不同观测装置和地理分布的传感器系统. 这些特征一方面为 ML 方法提供了丰富的应用场景, 尤其在特征提取、模式识别与数据驱动建模方面展现出独特优势; 但另一方面, 也对算法的泛化能力、鲁棒性与物理一致性提出更高要求.

表 1 系统性地总结了从太阳活动源区到地磁响应等多个区域中关键的物理过程及典型机器学习任务, 清晰展示了 AI/ML 方法在空间天气链式响应机制中的嵌入方式与实际贡献. 当前, AI 技术已在多个环节中展现出强大能力, 涵盖特征提取、异常检测、数据生成建模、数值模拟加速、因果推理及空间探测任务等方面 (Karniadakis et al., 2021; Bouriat et al., 2022; Dumitru and Munteanu, 2023).

本文旨在系统回顾人工智能特别是机器学习

表 1 太阳-地球空间天气系统中各区域的主要物理过程及其典型机器学习任务

Table 1 Primary physical processes and representative machine learning tasks across the various regions in the Sun-Earth space weather system		
区域	主要物理过程	ML典型任务
太阳活动源区	日冕物质抛射(CME)、耀斑爆发、日冕加热	活动识别、爆发预测、分类建模
太阳风传播区	太阳风结构演化、激波传播	风种分类、扰动识别、回归预测
磁鞘区	湍流、激波、磁场重联	湍流识别、磁重联检测、非高斯建模
内磁层	粒子加速与损失、电流系统变化	高能粒子预报、谱重建、数据补全
外磁层	磁场偶极化、磁尾重联、高速流	磁尾分区、亚暴预测、联检测、边界检测、
电离层	电离扰动、TEC变化、极光现象	TEC预测、极光识别、磁场湍动
热层	EUV加热、热膨胀、大气密度变化、轨道拖曳	密度建模、轨道预报、热层响应分类、扰动识别
中层大气	重力波传播与破碎、潮汐、极夜喷流(PMSE)、SSW事件起源	波动识别、温度建模、扰动分类、波源估计
地磁响应	地磁扰动、感应电流	亚暴、磁暴指数预测、极端事件识别、地磁暴模型

技术在空间物理领域中的研究进展,涵盖其在预测建模、分类识别、图像分析、磁重联检测等关键任务中的前沿应用,并进一步探讨其在构建下一代智能预警系统与推进科学建模能力方面的潜力.全文结构安排如下:引言阐明空间天气背景、核心挑战及 AI/ML 研究框架;随后概述主流学习范式与算法体系.应用层面沿日-地空间链条展开:源区聚焦耀斑、黑子及冕洞建模预报;传播区关注扰动识别与到达时间预估;磁层部分涵盖外磁层(向阳面及等离子体片)与内磁层(辐射带、环电流、等离子体层)的结构建模与粒子预报;电离层主要涵盖多纬度活动与极光分类;地磁活动梳理指数建模及磁暴亚暴预报.此外,探讨 AI 在磁重联/湍流信号识别和物理建模中的应用,并简述行星空间环境研究探索.

最后总结趋势,展望未来方向.

1 机器学习方法概述

机器学习 (ML) 是一类利用统计推断与计算算法,从数据中自动学习模式、提取规律,并执行预测与分类任务的技术集合.在无需显式建模物理机制的前提下,ML 借助数学模型刻画输入与输出之间复杂的非线性映射关系,因此尤为适用于高维、多源、强耦合的复杂系统.正因如此,ML 在空间天气建模中展现出显著优势.我们在表 2 展示了主流 AI 模型在空间天气建模中的性能与适用性对比.下文将分别介绍不同类别的机器学习方法.

表 2 主流 AI 模型在空间天气建模中的性能与适用性对比

Table 2 Performance and applicability comparison of mainstream AI models for space weather modeling							
模型类型	建模能力	可解释性	计算成本	数据依赖性	空间天气典型应用	优势	局限性
SVM	中	高	低	中	CME分类、耀斑预测	精度高,适合小样本	难扩展至大规模或多分类任务
RF	中	中高	中	中	SEPs事件分类、极光识别	鲁棒性强,抗噪能力好	模型复杂,训练耗时
LSTM	高	低	高	高	地磁指数预测、SEPs时间序列	擅长处理时间序列数据	易过拟合,训练慢
CNN	高	低	中高	高	太阳图像识别、冕洞提取	图像建模能力强	不适于长期序列预测
GNN	高	低	高	高	空间拓扑建模、区域传播路径	建模多区域连接性强	网络结构复杂,训练不稳定
PINN	中	极高	高	中	日冕磁场反演、太阳风传播建模	强物理约束能力,适用于数据稀缺问题	建模复杂,训练成本高
Transformer	极高	低	极高	极高	CME传播预测、磁场结构预测	长时间依赖建模能力强,泛化能力好	模型庞大,计算资源占用高
K-means/SOM	低	高	低	中	太阳风分类、事件结构探索	易于解释,训练速度快	难处理复杂的非线性系统

1.1 传统机器学习方法

在传统机器学习范式中,常规模型通常在中小样本场景和对模型可解释性要求较高的任务中表现出色.这类方法结构较为简洁,计算效率高,调试与

可视化便捷,适合于早期探索、特征工程及原型建模.典型方法包括:

1) 决策树 (Decision Tree) (Breiman et al., 1984), 通过层级划分特征空间构建树状结构,具备良好可

解释性, 适用于多类别任务;

2) 支持向量机 (Support Vector Machine, SVM) (Suthaharan, 2016), 构造最大间隔超平面, 适用于高维小样本分类问题;

3) 随机森林 (Random Forest, RF) (Ho, 1995), 通过集成多棵决策树增强模型的鲁棒性与泛化能力;

4) K 近邻 (K-Nearest Neighbor, KNN) (Denoeux, 1995), 基于“近者相似”原则进行无参数预测;

5) K 均值聚类 (K-means) (Arthur and Vassilvitskii, 2007), 作为无监督方法广泛用于聚类与结构划分;

6) 回归分析 (Maulud and Abdulazeez, 2020), 包括线性回归、岭回归、Lasso 等, 用于数值变量间的函数建模。

在空间天气研究中, 以上模型已被广泛用于太阳风类型识别 (Li et al., 2013)、太阳活动预报 (Huang et al., 2024)、磁层区域划分 (da Silva et al., 2022)、扰动事件聚类与识别 (Wang et al., 2025a, b) 等任务。

1.2 深度神经网络

深度神经网络 (Deep Neural Network, DNN) 作为现代机器学习的核心架构, 通过多层神经元模拟人脑连接机制, 具备卓越的非线性建模能力与特征表达能力。基础模型如多层感知器 (Multilayer Perceptron, MLP) 适合中小维度的非线性建模, 已广泛应用于太阳黑子识别、耀斑活动分析与极光图像分类等任务 (Knudsen et al., 2021)。在时间序列建模方面, 循环神经网络 (RNN) 及其变体长短期记忆网络 (Long Short-Term Memory, LSTM) 通过引入门控机制 (输入门、遗忘门、输出门) 有效缓解梯度消失问题, 适用于建模太阳风速度、地磁指数、极光活动等动态信号 (Sherstinsky, 2020)。

DNN 方法在空间天气多个子领域均取得实质性进展, 包括图像识别与分类 (如太阳耀斑、极光图像等)、地磁指数预测 (如 Dst 、 Kp 等)、时间序列建模 (如磁暴演化)、异常检测 (如高能粒子异常增强)、数据补全与插值 (如太阳风数据缺失重建) 等。相关应用覆盖面广、性能优越, 已逐步成为空间物理建模的重要技术支柱。

1.3 卷积神经网络

卷积神经网络 (CNN) 是深度学习 (Deep Learning, DL) 领域中最具代表性和广泛应用的方法之一, 特别适用于图像识别、语音处理以及自然语言理解等结构化数据任务。CNN 的设计灵感来源于动物视觉皮层中神经元的局部连接机制, 其核心原理在于通过局部感受野 (local receptive field)、参数共享 (weight

sharing) 与层级特征抽象 (hierarchical feature learning), 有效捕捉输入数据中的空间结构与时间动态特征。CNN 模型通常由一系列基础组件构成: 包括用于提取局部空间特征的卷积层, 引入非线性表达能力的激活函数 (如 ReLU), 实现下采样的池化层, 以及提升训练稳定性和泛化能力的批量归一化 (BatchNorm) 与 Dropout 等正则化机制; 网络末端则通常包含全连接层, 用于最终的分类或回归输出。CNN 依赖大规模训练数据与反向传播算法, 通过端到端的学习过程逐层优化参数, 实现高效且自动化的特征提取与表达建模。在现代卷积神经网络中, 残差网络 (ResNet) (He et al., 2016) 适用于构建更深层次模型, 实现复杂图像模式识别、重建与拓扑结构反演; U-Net (Ronneberger et al., 2015) 结构也在图像语义分割与物理图像重建中表现出色。

在空间科学领域, CNN 已逐渐成为建模高度非线性和多尺度耦合系统的重要工具, 尤其在太阳活动识别 (Israni et al., 2025)、太阳风参数建模 (Raju S and Das S, 2021)、地磁暴预测 (Liu et al., 2024) 以及空间天气智能预警系统等方面展现出巨大潜力。空间天气过程具有高度复杂性, 涉及图像、磁图、粒子流、等离子体等多源异构数据, 而 CNN 在处理此类高维观测数据中蕴含的空间模式与潜在关联方面表现优越。具体应用方面, CNN 已被广泛用于从太阳极紫外图像 (EUV)、白光图像和磁图中自动识别太阳黑子群、日冕洞以及耀斑活动区, 实现对太阳活动区的智能分类与爆发概率预测 (Yang et al., 2025)。例如, Tiwari 等 (2020) 提出的 SEARCH 模型可高效分割极区日冕洞, 而 Yang 等 (2025) 则利用 EUV 图像训练 CNN 预测耀斑活动, 显著提升了太阳事件的预报能力。

1.4 物理信息神经网络

随着物理驱动模型与数据驱动方法的不断融合, 物理信息神经网络 (PINNs) 成为近年来颇受关注的前沿方法。PINNs 通过将已知物理先验知识 (如磁流体力学 MHD 方程、边界条件与守恒律) 嵌入神经网络的损失函数中, 实现数据拟合精度与物理一致性的统一优化 (Karniadakis et al., 2021)。这种方法特别适用于数据稀缺、边界条件不全或物理可解释性要求较高的场景。代表性应用包括: 太阳风传播建模 (Temmer et al., 2023), 借助 PINNs 重建大尺度速度场, 同时保持与 MHD 方程结构的一致性 (Cai et al., 2021); 日冕磁场反演任务, 通过结合光球磁图与边界条件重构三维日冕磁拓扑, 为理解太阳爆发

机制提供了全新路径 (Wu et al., 2018; Jarolim et al., 2023); 在磁重联与等离子体湍流建模中, PINNs 展现出在高度非线性动力学问题中的强解释性与稳健性能 (Rosofsky and Huerta, 2023). PINNs 的发展代表着从传统“数据驱动建模”向“数据-物理融合建模”范式的转变, 为构建高精度空间天气模拟与下一代智能预警系统提供了重要方法支撑.

2 太阳活动源区 (Solar Activity Region)

太阳活动源区是太阳爆发性事件 (如太阳耀斑与日冕物质抛射, CME) 的主要发生区域, 其磁场结构与演化特征直接影响爆发性事件的触发机制及其对空间天气环境的影响. 近年来, 机器学习方法被广泛应用于太阳活动源区的识别、分类与爆发预报研究. 这类方法能够从海量的太阳观测数据中挖掘潜在模式, 有效提升对太阳活动的定量评估与预测能力, 特别在短时临近预报、爆发强度评估及概率性预测等方面展现出显著优势. 通过构建以太阳向量磁场、紫外成像、活动区演化参数等为输入的智能模型, 机器学习技术正逐步成为提高太阳活动预报时效性与准确性的关键手段.

2.1 耀斑, CME, 黑子, 冕洞

多种传统机器学习方法已被成功应用于太阳活动源区的预测任务. 其中, 支持向量机 (SVM)、级联卷积神经网络 (Cascade CNN, CCNN) 以及长短期记忆网络 (LSTM) 在太阳耀斑、黑子及日冕物质抛射的预报中表现突出. Qahwaji 等 (2008)、Colak 和 Qahwaji (2009) 分别利用 SVM 与 CCNN 对 SOHO/LASCO 和 NGDC 提供的太阳观测数据进行建模, 实现了对太阳耀斑和 CME 的预测. Liu 等 (2017) 使用随机森林 (RF) 算法预测特定活动区在 24 小时内是否会发生某一类耀斑, 并根据最大 GOES 等级将耀斑划分为 B、C、M、X 四类; 模型基于 SHARP 参数构建了训练样本集. Cinto 等 (2020) 进一步引入梯度提升决策树 (GBDT) 与时间窗机制, 通过特征选择提升了预测精度. 集成学习方法 (如 RF、GBDT) 通过集成多个决策树, 有效缓解了单一模型的过拟合问题.

随着深度学习的飞速发展, 越来越多基于神经网络的方法被用于太阳耀斑强度、时序与概率建模. Huang 等 (2018) 基于 SOHO/MDI 和 SDO/HMI 的光球磁图, 首次构建 CNN 模型实现了耀斑先兆特征

的自动提取. Liu 等 (2019) 将 LSTM 网络引入耀斑分级预测, 建立活动区未来 24 小时耀斑概率预测模型. Jiao 等 (2020) 进一步拓展为时间序列建模, 提高了对连续演化信息的捕捉能力. He 等 (2022) 提出结合 LSTM 与极限梯度提升 (eXtreme Gradient Boosting, XGBoost) 的短时预报模型, 选取 SHARP 参数中六个关键特征量, 成功预测未来 48 小时内是否将发生 $\geq M$ 级耀斑. Kumar A 和 Kumar V (2024) 利用双向门控循环单元 (Bidirectional Gated Recurrent Unit, BiGRU) 发展出混合 CNN-BiGRU 网络用于太阳黑子演化建模, 结合局部特征提取 (CNN) 与时序建模 (BiGRU), 提升了 SSN (太阳黑子数) 的基础预测能力. 同年 Kumar 又提出 Vipin-深度分解重组滚动窗口模型 (vD2R2w), 集成时间序列分解、深度网络与滚动预测机制, 在多个数据集上持续优于传统模型.

在新型 ML 方法与复杂结构建模方面, 基于 Transformer 架构的模型也逐渐应用于太阳活动预测中. Wang 等 (2020) 利用无监督核主成分分析 (Kernel Principal Component Analysis, KPCA) 方法从太阳活动区磁极性反转线 (PIL) 梯度掩码图像和 24 小时的差分图像中直接提取特征, 结果表明提取的特征因子在预测强耀斑爆发方面有效, 超越了传统的磁特征 R 值与其差分. Abdullallah 等 (2023) 提出的 SolarFlareNet 框架结合了卷积神经网络 (CNN)、LSTM 与 Transformer 网络, 能够进行多级概率预测. 该模型通过建模太阳活动源区磁参数的时间序列, 显著提升了预测精度, 尤其在处理复杂时空特征方面展现出优越性能. Zhang 等 (2025) 提出 DeepHalo 模型 (一种 Transformer 模型), 用于预测活动区 (AR) 在未来 24 小时内是否会产生晕状日冕物质抛射 (CME). 该模型是首个用于晕状 CME 预测的 transformer 模型. 模型输入为 SDO/HMI 的 SHARP 矢量磁参数 (18 个特征), 基于 2010 年 11 月至 2023 年 8 月的 1283 个 CME 事件 (含 117 个全晕、209 个部分晕、957 个非晕 CME) 构建数据集, 通过线性插值填补缺失值和合成少数类过采样技术 (Synthetic Minority Over-sampling Technique, SMOTE) 过采样处理不平衡数据.

随着太阳活动研究对模型的预测精度、物理一致性与解释能力要求的提升, 融合物理约束与深度学习的建模方法成为当前研究热点. 在早期融合模型研究中, Camporeale 等 (2017) 采用高斯过程 (GP) 对太阳风数据进行分类与回归建模, 结合贝叶斯推理对不确定性进行评估. Wheatland (2023) 将 PINNs 应用于实时太阳日冕建模, 实现了对耀斑与 CME

活动的快速响应预测, 提升了空间天气预警的时效性与精度 (Wheatland, 2023). Johnson R 等 (2024) 则构建了一个融合经验模型与 PINNs 的混合框架, 用于太阳风和 CME 的结构建模, 验证了该方法在不同太阳活动周期中的稳定性和跨周期泛化能力. Shen 等 (2024) 在其研究中将 PINNs 与深度计算机视觉模型结合, 处理太阳黑子与耀斑的多源图像数据, 展示了在大规模遥感观测数据处理中的高适应性. Illarionov (2025) 综述了 PINNs 在太阳黑子群结构建模中的表现, 指出该方法在避免过拟合、处理复杂边界条件与提升解释性方面具有显著优势. Zheng 等 (2023) 对多种预测模型 (LSTM、SVM、DL 与 PINNs) 进行了系统性比较, 指出不同算法在不同任务情境下性能差异明显.

2.2 太阳高能粒子和太阳能辐射水平

太阳高能粒子 (Solar Energetic Particles, SEPs) 事件和太阳能辐射水平的变化对空间天气的监测与预警具有重要意义, 尤其在影响航天器运行、高空飞行安全以及地面电力系统方面起着关键作用. 目前, 已经有许多研究聚焦于利用机器学习与深度学习技术对 SEPs 事件进行建模与预测, 以提高对太阳磁暴和空间天气事件的响应速度. 例如, Kasapis 等 (2022) 提出了一种基于 SMARP (Space-Weather MDI Active Region Patches) 数据的自动化 SEPs 事件预测方法, 结合了支持向量机与回归模型. 这一方法通过将耀斑峰值强度等辅助参数引入, 成功将预测准确率从 72% 提升至 92%, 并且能够提前 55.3 min 进行预警, 极大地提升了预警系统的实用性与操作性. Stumpo 等 (2021) 进一步对现有的实时太阳质子事件警报模型 (ESPERTA) 进行了机器学习改进, 引入稀有事件校正与 SMOTE 数据平衡算法, 通过优化数据分布来增强模型的预测能力. 研究结果表明, 该模型在保留类分布一致性的前提下, 探测概率 (POD) 达到 0.83, 虚警率 (FAR) 降至 0.39, 进一步提高了模型的精度与稳定性. 在深度学习方法中, Abdullah 等 (2022) 提出了一种基于双向长短期记忆网络 (biLSTM) 的 SEPs 事件预测方法, 利用 SDO/HMI 的 SHARP 矢量磁场参数, 并结合 2010—2021 年间的 GOES 耀斑与 DONKI 数据, 建立了一个用于 SEPs 事件预测的数据集. 通过与随机森林 (RF) 和多层感知机 (MLP) 模型的对比, 表明 biLSTM 模型在准确率、F1 值及概率预测等多项评估指标上均优于其他传统机器学习方法, 展示了深度序列建模在太阳活动领域中的显著优势. 此外,

Moreland 等 (2024) 推出的 MEMPSEP-III 数据集, 整合了多源数据, 包括 GOES、ACE、SDO 和 SOHO 等卫星数据, 涵盖了第 23 与第 24 太阳活动周期部分期间的 252 个阳性事件和 17542 个阴性样本, 为 SEPs 事件预测提供了丰富的训练资源和更高的预测精度. Whitman 等 (2023) 对 36 种当前科学社区开发的 SEPs 模型进行了总结. 模型类型包括经验模型、物理基模型、机器学习模型及多模块预测系统. 经验模型基于观测数据的关联关系, 能快速生成预测; 物理基模型依据粒子加速和传输等物理过程建模, 虽计算密集但可模拟事件的时空分布; 机器学习模型利用人工智能技术从数据中识别规律; 多模块预测系统则结合多种模型形成链式预测流程.

在太阳能辐射预测方面, Lai 等 (2021) 提出了一种结合深度时间序列聚类 (Deep Time-series Clustering, DTC) 与特征注意力深度预测 (Feature Attention based Deep Forecasting, FADF) 的混合深度学习模型, 用于提前一小时预测全球水平面太阳辐照度 (Global Horizontal Irradiance, GHI). 该模型在处理太阳辐射的非平稳性和局部突变问题上, 显示出显著优势. 通过在 Itupiranga (巴西) 和 Ocala (美国) 两个数据集上的验证, 该模型相比传统的智能持久性模型, 分别降低了 11.88% 和 12.65% 的均方根误差 (RMSE), 提升了太阳辐射预测的准确性. Daniell 和 Mehta (2023) 则提出了一种集成神经网络方法, 将多层感知机 (MLP) 与长短期记忆网络 (LSTM) 结合, 针对太阳射电流量 $F_{10.7}$ 进行短期预测. 通过滑动窗口和超参数调优, 该方法在相对均方误差 (rRMSE) 等指标上, 相较于传统的线性回归模型提升了 48% 至 59%, 为短期太阳辐射预测提供了更加精确的解决方案. Yan S N 等 (2025) 采用 iTransformer 模型对 $F_{10.7}$ 的趋势与扰动成分进行联合建模与预测, 并融合两者结果获取最终预报值. 同时, 还引入了软 X 射线耀斑指数、活动区磁类型和 X 射线背景通量等参量来作为模型输入, 增强模型对太阳活动特征的感知能力. 与 SWPC、BGS 和 CLS 等国际业务预报机构的预报结果相比, 该方法在短期和中期预报中显著提升了准确性与稳定性, 并在不同太阳活动阶段展现出更强的适应性, 为 $F_{10.7}$ 指数的高质量预报提供了新的解决方案. Kumari 和 Toshniwal (2021) 对深度学习模型在太阳辐照度建模中的应用进行了全面综述, 重点分析了 LSTM、深度信念网络 (DBN)、卷积神经网络 (CNN) 等架构在应对太阳

辐射的间歇性、季节性和非线性动态方面的优势. 研究表明, 深度学习模型在这些方面明显优于传统统计模型和浅层机器学习方法, 能够自适应地捕捉太阳辐射中的复杂模式和长期趋势. 该综述还强调, 模型的性能不仅受到架构设计的影响, 还与输入特征选择、天气类型分类以及时间尺度配置等因素密切相关.

3 行星际太阳风

根据其与地球磁层的相互作用位置, 行星际太阳风可简要划分为两类: 弓激波上游的远地太阳风 (upstream solar wind) 与弓激波下游的近地太阳风 (downstream solar wind). 其中, 远地太阳风作为空间天气扰动的先导驱动源, 其传播路径、演化机制及关键物理参数 (如速度、密度、磁场方向等) 对于预警系统的时效性和准确性具有决定性影响. 以下将围绕“远地太阳风的传播建模”、“扰动类型分类识别”以及“AI 驱动的预警预测”三个方面, 介绍相关研究进展.

3.1 传播路径和传播时间

当前针对 CME 与太阳风在日地空间传播过程的研究, 已发展出多种人工智能建模体系. 根据核心算法路径的不同, 这些模型大致可归纳为五类: ① 统计学习与传统机器学习模型, ② 卷积神经网络 (CNN) 类模型, ③ Transformer 序列建模类模型, ④ 多模态集成与混合模型, ⑤ 物理引导的 AI 融合模型. 各类别模型在复杂扰动结构识别、时间序列预测与传播路径建模方面展现出不同技术优势与适用边界.

Camporeale 等 (2017) 基于高斯过程回归 (GPR) 模型对 OMNI 数据进行四类太阳风自动分类, 分类准确率均超过 90%; Oliveira 等 (2024) 利用回归方法结合 SC23–SC25 的黑子数与激波事件数据预测 SC25 的激波频率为 275 ± 10 次, 高于 SC24 但低于 SC23, 显示出统计方法在长期趋势预测中的稳定性与实用性. Collin 等 (2025) 开发了一种基于多项式回归的模型, 利用太阳极紫外 (EUV) 图像中提取的日冕洞面积、位置以及 27 天前的太阳风速等特征, 预测 4 天后到达地球的太阳风速 (SWS), 尤其关注高速太阳风 (HSS). 模型通过 Lasso 特征选择和分布变换 (解决 HSS 峰值速度低估问题), 在 2010—2019 年数据上实现均方根误差 (RMSE) $68.1 \text{ km} \cdot \text{s}^{-1}$, HSS

峰值速度 RMSE $76.8 \text{ km} \cdot \text{s}^{-1}$, 且在第 25 太阳周 (2020—2023) 的业务预测中表现可靠 (RMSE $80.3 \text{ km} \cdot \text{s}^{-1}$). 该模型优于神经网络和磁流体动力学 (MHD) 模拟等复杂方法, 仅通过少量物理特征即可解释大部分太阳风变化. Ahn 等 (2025) 对比了代表性经验模型与深度学习 (DL) 模型在 1 AU 处太阳风速预测中的性能, 重点评估高速太阳风 (HSS) 的预测效果. 研究覆盖 2012—2020 年每年 10—12 月, 通过统计和事件两种验证方法, 分析不同太阳活动相位下模型的表现, 发现 DL 模型在准确性和稳定性上更具优势. Shi Y R 等 (2021, 2022) 开发了将逻辑回归权重应用于推荐算法的模型来预测 CME 是否会到达地球, 对每个 CME 使用推荐算法选出最相似的历史事件, 用于 CME 对地有效性预测和比较分析. Oliveira 等 (2024) 基于 SC23–SC25 周期的太阳黑子数与激波事件统计数据, 建立回归模型预测 SC25 的行星际激波频率为 275 ± 10 次, 明显高于 SC24 (187 ± 8 次), 但仍低于 SC23 (343 ± 12 次), 表明 SC25 或呈现中等强度的太阳活动趋势. 该类统计方法在长期演化趋势分析中仍具有良好的物理解释力与稳定性. Amaya 等 (2020) 基于自组织映射 (Self-Organizing Map, SOM) 与主成分分析 (Principal Component Analysis, PCA)/自动编码器对 ACE 卫星 14 年数据进行聚类, 成功区分冕洞风与瞬态结构; Roberts 等 (2020) 在 K-means 基础上引入交叉螺旋度等非局部变量, 挖掘出传统分类框架难以捕捉的潜在结构. Narock 等 (2024) 构建的概率神经网络 (PNN) 模型进一步引入香农熵以量化分类不确定性, 实现 96% 的分类准确率, 在增强模型可信度的同时保障了可解释性.

Nguyen 等 (2019) 提出基于 CNN 结合滑动窗口与峰值检测的 ICME 自动识别算法, 在 WIND 数据集上实现了约 84% 的召回率和精度, 显示出强大的非线性特征提取能力. Raju H 和 Das S (2021) 进一步将 CNN 应用于 SDO/AIA 193Å 图像进行太阳风速度回归估算, 而 Lin R P 等 (2024) 结合主成分分析与图像分割算法, 基于 CNN 精准提取 CME 的速度、角宽与中心位置等参数. Upendran 等 (2020) 提出 WindNet 模型, 融合 CNN 与 LSTM 网络对 SDO 极紫外图像进行训练, 预测 L1 点太阳风速度, 显著优于自回归与朴素基准模型. Liu 等 (2023) 将 Transformer 机制引入太阳风传播建模, 提升了对长时间依赖结构的建模精度. 而 Alielden 等 (2023) 提出的 LSTM-CNN 集成模型 LCNN, 结合 STEREO-A/B 数据预测 IR

(Interface Region, 界面区) 传播时间, 在 20 ~ 160 min 预测窗口内达到 93% 的敏感性, 为事件级别预警提供支持. Legnaro 等 (2025) 使用卷积神经网络 CNNs 和视觉 Transformer ViTs, 基于 Mount Wilson 分类方案对太阳活动区图像进行分类, 旨在评估不同架构的性能. 使用 SOLAR-STORM1 数据集 (2010—2017 年, 含 15641 个样本, 分为 alpha、beta、beta-X 三类), 并结合数据增强和迁移学习训练模型. 结果显示: 结合磁图和连续谱图像可提升性能 (ResNet18 准确率 0.903); 仅用磁图时, DeiT 模型表现最佳 (准确率 0.901); 仅用连续谱图像时性能较低 (最高准确率 0.877).

对于多模态集成与混合模型, Li Y C 等 (2024) 构建两种基于冠状图像的预测模型, 其中 Model B 结合 11 项物理参数, 相较纯 CNN 模型 (Model A) 在传播时间预测中误差降低约 33%, MAE (Mean Absolute Error, 平均绝对误差) 为 5.12 小时. 证实结合成像观测与物理参数训练的机器学习模型能显著提升 CME 到达时间预测精度. Guastavino 等 (2023) 则提出融合物理拖拽模型与神经网络的双阶段架构, 在 1 ~ 6 小时预测窗口内显著优于传统数据驱动方法, 展示了物理机制引导在 AI 建模中的潜力. Yang 等 (2018) 提出混合智能源面模型 (HISS), 结合人工神经网络与太阳磁场参数, 在 1 AU 太阳风速度预测中取得了 0.74 的相关系数与 $68 \text{ km}\cdot\text{s}^{-1}$ 的误差. Lin R 等 (2024) 将 PFSS 外推生成的磁场图作为 CNN 输入, 实现对 3 ~ 6 天后太阳风速度的预测, RMSE 为 $80.8 \pm 4.8 \text{ km}\cdot\text{s}^{-1}$, 展示了日冕磁结构在深度模型中的核心作用. Barros 等 (2024) 引入 RNN 对 MULTI-VP 模型初始条件进行优化, 即便不重新训练主模型, 也显著增强了模拟结果的稳定性与精度.

3.2 太阳风分类

在行星际太阳风研究中, 不同类型太阳风的准确分类对于理解其起源机制、演化动态以及对地球空间天气的影响具有重要意义. 目前, AI 驱动的太阳风分类方法大致可分为以下两类技术路径: (1) 统计学习方法和 (2) 神经网络分类方法.

统计学习方法以 Camporeale 等 (2017) 提出的高斯过程回归 (GPR) 方法为代表. 该模型使用 OMNI 数据中的历史标注样本, 基于太阳风速度 (V_{sw})、质子温度标准差 (σT) 等七个关键参数, 实现了对 ejecta、日冕洞风、流带风和扇区反转风四类太阳风的精准分类. 分类准确率均超过 90%, 并进一步利用 Bayesian 概率输出计算不同类型之间的转移概

率, 拓展了太阳风演化链建模与概率预报系统的研究框架. 该方法在小样本条件下展现出良好的泛化能力与不确定性表达能力. Li 等 (2020) 提出一种基于机器学习的太阳风分类方法, 将 1 AU 处的太阳风分为日冕洞起源高速太阳风、太阳赤道附近起源的低速太阳风、扇区反转区太阳风和日冕物质抛射四类. 通过对 13 个太阳风参数的 8191 种组合进行穷举, 确定八维参数方案 (B_t 、 N_p 、 T_p 、 V_p 、 N_{ap} 、 T_{exp}/T_p 、 S_p 、 M_p) 表现最佳, 其中 KNN 分类器的总体准确率最高, 达 92.8%. Amaya 等 (2020) 结合自组织映射 (SOM)、主成分分析 (PCA) 和自动编码器 (对 ACE 卫星近 14 年的太阳风数据进行了聚类建模), 提出 DSOM 分类框架, 能够识别出冕洞风与瞬态扰动结构, 并实现了太阳风演化过程的连续性可视化. Roberts 等 (2020) 利用 K-means 算法引入交叉螺旋度、剩余能量等非局部物理量, 在 ACE 数据上成功划分出 ICME 与非冕洞风等类型, 展示了从物理变量出发的分类潜力. Narock 等 (2024) 提出的概率神经网络 (PNN) 以阿尔芬速度、温度比、等离子体熵等多维物理参数为输入, 实现对太阳风的五类划分 (冕洞风、流带风、扇区反转、磁障碍和鞘层). 模型通过引入香农熵对分类不确定性进行度量, 在保持 96% 分类准确率的同时显著增强了模型的可信度与可解释性, 特别在极端扰动和过渡结构识别中表现优异.

3.3 太阳风预测模型

太阳风预测在空间天气预报中处于核心位置. 太阳风参数预测是空间天气预报体系中的核心组成部分, 对于实现地磁扰动、电离层紊乱等空间灾害的提前识别具有重要意义. 传统方法多依赖于物理模型 (如 ENLIL、WSA-ENLIL 等). 当前研究主要沿以下三条路径展开: (1) 图像驱动的卷积神经网络预测模型; (2) 多参数回归与数据重建模型; (3) 物理-AI 融合模型.

Lin R 等 (2024) 提出融合 PFSS (势场源面) 外推与卷积神经网络 (CNN) 的预测框架, 利用 GONG 观测的光球磁图生成 90×180 分辨率的磁场图作为模型输入, 实现对 3 ~ 6 天后 L1 点太阳风速度的预测. 在准连续测试中, 模型取得了 0.53 ± 0.07 的相关系数、 $80.8 \pm 4.8 \text{ km}\cdot\text{s}^{-1}$ 的均方根误差 (RMSE) 和 0.39 的高速流事件威胁评分 (TSS), 充分展现了 CNN 在日冕结构感知与图像特征建模方面的潜力. Hecht 等 (2023) 提出基于多层神经网络的多变量太阳风参数预测模型, 覆盖了质子速度、密度、温度、磁场强

度、氧离子电荷态比等多个关键指标。该模型不仅适用于缺测数据的修复与补全,还具备事件特征估计与科学推理功能,为提升空间数据完整性与物理可用性提供了有力工具。与此同时, Bouriat 等 (2022) 对 ACE 卫星 1998—2021 年的 SWEPAM 与 MAG 数据进行了标准化与特征工程处理,构建出具备代表性和可推广性的数据集,为神经网络与集成学习方法提供了稳健的数据支撑。Yang 和 Shen (2019, 2021) 介绍了一种新的 AI 结合的三维 MHD 行星际太阳风模型。该模型利用多种观测数据和 ANN 技术获取自洽边界条件,其中磁场来自磁图和势场源表面外推,电子密度来自偏振亮度 (pB) 观测,速度通过 ANN 结合磁图和 pB 观测推导,温度则通过自洽方法从磁场和电子密度得出。该模型能合理再现源表面参数的全球分布,与 OMNI 和 Ulysses 观测数据一致性较好。

Johnson 等 (2022) 首次提出结合经验模型与物理模型的物理信息神经网络方法,基于欧姆定律构建约束损失函数,对 NASA OMNI 数据集进行多元时间序列分析,通过训练长短期记忆网络 (LSTM)、卷积神经网络 (CNN) 等五种深度学习模型,验证了该方法相较现有深度学习模型的优越性,为太阳风预测提供了新的有效途径。Guastavino 等 (2023) 进一步提出双阶段混合建模策略:首先使用物理拖拽模型估算 CME 的阻力系数,再利用神经网络对传播误差进行反向优化,有效提升了行程时间预测的准确性。Barros 等 (2024) 尝试将 RNN 引入 MULTI-VP 模型的初始条件优化过程中,即便不对主模型重新训练,仅通过对初始场的调节,也显著提升了模拟精度与数值稳定性。

3.4 近地太阳风:弓激波和磁鞘

近地太阳风区的研究主要聚焦于弓激波及其下游的磁鞘区 (Magnetosheath)。作为太阳风与地球磁层相互作用的首要界面,这些区域在等离子体压缩、无碰撞激波形成及能量输运等动力学过程中扮演关键角色。对其精确识别与建模对于提升空间天气预报的时效性与准确性具有重要意义。当前,近地太阳风-磁鞘区研究正从静态分类逐步向高时空分辨率、物理一致性与跨平台可泛化的动态智能建模转变。Breuillard 等 (2020) 构建了一种基于全卷积神经网络 (Fully Convolutional Network, FCN) 的分类模型,对 MMS (2016—2019 年) 任务中十类等离子体区域进行自动标注,包括太阳风、弓激波、磁鞘、

离子前震等,模型在标注数据集上达到了 89% 的识别准确率,并成功迁移至 Cluster 任务数据,验证了其跨任务的泛化能力。Lalti 等 (2022) 进一步建立了目前最大规模的弓激波穿越事件数据库 (2797 个案例),并提出自动化提取 θ_{Bn} 与 Alfvén 马赫数 (MA) 等关键物理指标的方法,揭示了准平行激波在粒子加速方面的效率更高,且事件分布呈现由日下点向尾翼递减的空间结构。Olshevsky 等 (2021) 采用 CNN 模型对 MMS 双离子谱仪 (DIS) 三维能谱图进行分析,实现对太阳风、磁鞘、磁层等区域的高精度分类,整体准确率超过 98%,特别擅长识别激波过渡态与边界模糊区域。Toy-Edens 等 (2024) 则提出一种基于高斯混合模型 (Gaussian Mixture Model, GMM) 的无监督学习方法,结合自动特征生成与后处理,对 8 年 MMS 数据进行无标注聚类,最终将其划分为太阳风、前震、磁鞘和磁层四类,分类准确率达 97.8%,并实现了过渡事件时间标注。

Koller 等 (2024) 通过对日冕洞起源的高速太阳风事件分析发现,该类型太阳风在准垂直激波条件下更易在磁鞘中诱发离子能量通量增强,显著区别于其他源区太阳风 (如 CME 或流带风) 的响应模式。Dimmock 和 Nykyri (2013) 利用 THEMIS 五年观测数据构建了磁鞘区速度、密度与磁场强度的统计分布图谱,并指出在准垂直激波条件下磁鞘区域存在明显的不对称性,该结果得到了全球 MHD 模型 BATS-R-US 的验证,进一步夯实了激波-磁鞘动力学耦合的理论基础。为提高磁鞘扰动的预测能力,Karlsson 等 (2021) 结合 Cluster 航天器多点观测,开发了基于离子通量、磁场扰动与各向异性指标的边界识别算法,有效减少了上游误差对磁鞘识别结果的影响,提升了预测模型的稳健性。在喷流识别方面,Raptis 等 (2020) 构建了初始喷流数据库,并训练基于 MMS 数据的神经网络模型实现喷流类型的分类 ($\theta_{Bn} < 45^\circ$ 为准平行, $\theta_{Bn} > 45^\circ$ 为准垂直),分类准确率达 93%,即使在 IMF 数据缺失情形下依然保持较强鲁棒性。O'Brien 等 (2024) 开发的 PRIME-SH (Probabilistic Regression of Inputs to the Magnetosheath Environment) 模型则基于 Wind 航天器 L1 点观测,训练循环神经网络 (RNN) 对 MMS 探测的磁鞘等离子体状态进行概率回归,能够有效重构激波跃变、磁场弯曲、流体停滞点及耗尽层等现象,模型在连续秩概率评分 (CRPS) 指标上达到了 0.227σ ,显著优于传统经验模型。

4 外磁层 (Outer Magnetosphere)

4.1 向阳面磁层与磁层顶

向阳面磁层是地球与太阳风相互作用的第一前沿, 其结构演化对磁层能量注入与空间天气扰动具有决定性意义。早期研究即尝试将人工神经网络 (ANN) 引入磁层结构建模。Dmitriev 和 Suvorova (2000) 基于 NeuroShell2 平台构建 ANN 模型, 利用太阳风和 IMF 参数预测三维磁层顶位置, 不仅提升了动态不对称性的刻画能力, 还揭示了磁层顶在不同 IMF 主导机制 (如动压平衡、磁重联控制、响应饱和) 下的位置演化规律, 奠定了磁层 AI 建模的初步框架。Wang 等 (2025a) 进一步基于 MMS 卫星数据, 结合小波变换与决策树分类器, 构建太阳风-磁层交界区的多类别等离子体分区模型, 实现了对太阳风、弓激波、磁鞘、磁层顶及内磁层等区域的自动化划分, 显著提升了空间区域建模的精度与分辨率。

随着深度学习的发展, 循环神经网络及其长短期记忆结构被广泛用于磁层区域的动态识别与分类。Yeakel 等 (2022) 在 Cassini 数据上比较多种分类器性能, 结果显示 LSTM 在磁层顶穿越识别中的准确率最高 (82.1%), 能够有效捕捉多变量时间序列中的演化模式。此外, 该模型在识别日侧弓激波穿越事件中的识别率达到 91.2%, 验证了其在边界动态检测中的优越性。Innocenti 等 (2021) 利用自组织映射 (Self-Organizing Map, SOM) 对全球 MHD 模拟数据的局部等离子体参数进行降维聚类, 成功识别出太阳风、磁鞘和磁层边界等区域, 展示了无监督学习在无需先验标注条件下的区域识别能力。Edmond 等 (2024) 结合主成分分析 (PCA)、SOM 与层次聚类, 对 THEMIS 与 MMS 的实测数据进行系统分析, 构建超 8000 个穿越事件的分类数据库, 并能识别出热流异常与爆发性流结构, 整体模型准确率达 99.4%, 是当前磁层自动分类的先进成果之一。Nguyen 等 (2019, 2022) 将梯度提升树 (Gradient Boosting Machine, GBM) 应用于多颗航天器的原位数据, 实现对磁层与太阳风区域的高效自动识别, 分类精度与训练效率均优于传统支持向量机 (SVM) 和随机森林 (RF) 模型, 并成功构建了超过 3 万个穿越事件的标注数据集。Li S 等 (2023) 在磁层顶建模中引入 Shapley 加法解释模型 (SHapley Additive exPlanations, SHAP) 解释框架, 量化太阳风动压与 IMF 分量对磁层驻留距离

(MSD) 预测的影响, 揭示 IMF B_z 与磁场总强度之间的非线性协同作用可在特定条件下诱发 MSD 凹陷区, 显著提升了模型的物理解释性与透明度。

为突破传统方法在磁层顶边缘检测中的视场限制, Wang J Q 等 (2024) 针对 SMILE 任务中磁层顶 (magnetopause) 的检测需求, 提出 OESA-UNet 模型, 该模型结合自适应预处理、注意力机制 (SE 模块和 CBAM 模块) 及 U 型网络结构, 用于从有限视场 (FOV 为 $16^\circ \times 27^\circ$) 的软 X 射线图像中检测磁层顶位置。通过对 17064 张模拟 MHD 图像的训练与测试, 模型显著优于传统边缘检测方法和其他语义分割模型 (如 UNet、DeeplabV3+), 可有效支持切线拟合方法 (TFA) 进行三维磁层顶反演, 为研究日侧磁层与太阳风相互作用提供关键技术支持。

4.2 夜侧磁层: 磁尾等离子体片

地球夜侧外磁层中的磁尾等离子体片因其在能量积累、重联释放及环电流演化过程中的核心地位, 近年来成为 AI 建模研究的重要焦点。其研究主要围绕结构识别、动态预测与驱动机制等核心问题, 利用聚类与降维方法对磁尾等离子体片的空间结构进行细化建模成为研究的突破口。Bakrania 等 (2020) 将自动编码器 (AE)、主成分分析 (PCA)、均值漂移与凝聚聚类算法结合, 成功将传统的三分类等离子体模式细分为八类子结构, 并通过模型独立性验证证明该分类体系具有较强的可推广性与稳定性。此外, Wang 等 (2025b) 利用 MMS 数据和滤波决策树混合分类器, 构建磁尾区域的等离子体多类分区模型, 实现了对越尾电流片 (cross-tail current sheet, CTCS)、中心等离子体片 (central plasma sheet, CPS)、等离子体片边界层 (plasma sheet boundary layer, PSBL) 和尾瓣 (lobe) 等区域的自动区分, 标志着高分辨空间区域建模能力的提升。

在动态过程追踪方面, Constantinescu 和 Marghitu (2020) 将前馈神经网络 (FNN) 与滑动窗口技术相结合, 识别爆发性体流 (BBFs) 与能量转换区域 (ECRs), 引入对数采样策略以处理不平衡数据分布, 显著提升了训练稳定性与事件检出能力。Stephens 和 Sitnov (2021) 构建虚拟航天器数据库, 结合最近邻挖掘 (kNN) 算法, 在模拟中捕捉电流片变薄与偶极化等近尾现象, 并将其与内磁层动力学 (如压力增强与电流圈重建) 融合, 实现物理机制跨尺度集成建模。

时间序列预测方面, Priyadarshi 等 (2021) 引入 LSTM 构建基于 RCM 模型输出的平行统计预测框

架,有效预测未来几十分钟的等离子体片参数(如熵、磁通与电场分量),表现出与物理模型一致的趋势. Swiger 等 (2020) 进一步将 IMF 条件、太阳风速度/密度与磁地方时等动态驱动因子引入神经网络框架中,在对 1~200 keV 电子通量进行 4 小时窗口预测中将误差降低至 0.38,验证了短期动态建模中数据-物理混合策略的有效性.

参数建模方面, Yue 等 (2015) 利用支持向量回归 (SVR) 技术,构建赤道面二维等离子体片压力模型,预测亚暴增长期的环电流压力分布.模型以太阳风动压、太阳黑子数等为输入,准确捕捉不同径向与地方时区域压力响应的异质性机制,误差低至 5%,具备较高工程适用性.在磁尾流场建模中, Cao 等 (2023) 结合随机森林 (RF) 与梯度提升树 (GBDT) 对 ARTEMIS 与 Cluster 多点数据进行特征重要性分析,发现 IMF B_y 分量、Dst 指数及边界位移对 V_y 与 V_z 分量影响最显著.该模型在磁尾速度预测中相关系数达 0.75,显著优于传统线性模型,并揭示 IMF 与磁尾流相互作用的主控路径,是当前解释能力较强的驱动因子回归研究代表.

除数据驱动预测外,一些研究尝试将物理模型中的先验约束嵌入 AI 结构.如 Swiger 等 (2020) 模型中不仅输入太阳风参数,还加入物理边界条件(如磁地方时)与历时特征,实现对高能粒子流的更稳定拟合.该类模型可通过调节损失函数、特征交互层等手段,引入磁重联、电流片薄化等机制性信息,是提升 AI 模型物理一致性的新方向.

5 内磁层 (Inner Magnetosphere)

5.1 辐射带

地球辐射带作为内磁层中最活跃、最复杂的带电粒子储能区域,其电子通量的快速增强或骤减对空间天气预警具有关键影响.近年来, AI 技术在辐射带建模中的广泛应用,推动了通量预测、事件归因、区域映射等方面的重大进展.辐射带 AI 建模的最初尝试多采用前馈神经网络与经验模型. Koons 和 Gorney (1991) 构建三层感知器网络,以 K_p 指数与行星际磁扰动为输入,有效预测 GEO 轨道 >3 MeV 电子通量. Stringer 等 (1996) 进一步引入磁地方时 (MLT),增强对小时级尺度的短时预测精度. Turner 和 Li (2008) 则结合通量自身的滞后特性,建立统计回归模型,提升对 1.1~1.5 MeV 能段中等能

量电子预测性能,为后续建模提供先验依据.随着高时空分辨率数据的积累,研究者采用长短期记忆网络 (LSTM)、变分自编码器 (VAE) 等序列模型对电子通量时间演化进行预测. Sun 等 (2023) 和 Wei 等 (2018) 提出基于 LSTM 的多日预测框架,在多个能段(特别是高能 >2 MeV)均表现出高相关性与低 RMSE. Zhang 等 (2022) 采用经验模态分解 (EMD) 结合 LSTM,提升了极端增强事件下的稳定性与预测精度;而 Chu 等 (2021) 提出的 ORIENT-R 模型则在不依赖边界条件的前提下,通过太阳风参数实现相关系数 $R \approx 0.95$ 的高预测相关性. Ma 等 (2023, 2024) 首次系统引入沙普利可加解释 (SHapley Additive exPlanations, SHAP) 和 SHAP 增强叠加纪元分析 (SHAP-Enhanced Superposed Epoch Analysis, SHESEA) 框架,对 AI 模型进行机制解析,发现动态压力是导致通量骤降的最主要因素,而亚暴强度与持续时间则决定通量增强路径. Chu 等 (2023) 则将哨声波振幅作为目标变量,基于不平衡回归模型揭示其分布与亚暴注入漂移路径呈高度一致性,说明波粒相互作用对高能电子的控制路径存在非局部调控规律.

除时间预测外,研究者也尝试借助 AI 对不同轨道区域的通量特征进行空间映射与模式识别. Drozdov 等 (2023) 结合 LEO 卫星数据与机器学习构建 LEO→GEO 的映射模型,提升了中高轨 (MEO-GEO) 区域预测的空间广度. Hua 等 (2024) 提出分类模型识别电子骤降事件,精度达 90%; Killey 等 (2023) 基于无监督聚类分析出六类典型电子俯仰角分布类型,为理解空间粒子各向异性结构提供了新途径.

考虑物理机制的建模策略是当前 AI 建模的发展重点. Yu 等 (2014) 将 RAM-SCB 物理模型输出与神经网络进行耦合,增强对太阳风驱动下辐射带演化的理解. Xiang 等 (2021) 优化径向扩散方程参数,将机器学习算法嵌入系数求解过程,提升对内层电离层粒子迁移的建模能力. Chen W X 等 (2024) 结合 Fokker-Planck 方程与神经网络重建边界条件 (LBC) 下的散射分布,有效模拟波粒交互引发的粒子流失过程, Staples 等 (2024) 则通过数据同化技术提升长期预测稳定性.

为提升对不同 L 区域、极端事件(如 SEPs 或骤降)的泛化能力, de Lima 等 (2020) 在 PreMevE 2.0 中引入深度网络优化 >4.5 L 区域的预测准确度, Smirnov 等 (2020) 开发 MERLIN 模型,利用 GPS 星

座数据实现多能段 ($<1\text{ MeV}$ 至 $>5\text{ MeV}$) 通量预测, 展现出广覆盖与高精度性能. Qian 等 (2020) 结合 EMD 与卡尔曼滤波, 解决电子通量时间序列的非平稳性问题, 提高异常事件的响应稳定性. Shin 等 (2016) 从空间结构角度探讨模型在不同能量层面与轨道位置上的适用边界, 为广域适应性建模奠定基础.

5.2 等离子体层

地球等离子体层位于内磁层区域, 主要由冷等离子体组成, 是磁层-电离层-热层能量和物质耦合的关键区域. 该层结构在调控波粒相互作用、高能粒子的俘获与损失、内辐射带边界的重构及电磁波传播路径方面起着决定性作用. 等离子体层密度的时空演化过程直接影响空间天气系统的响应机制.

前馈神经网络 (Feedforward Neural Network, FNN) 是最早应用于等离子体层建模的 AI 结构之一, 主要用于冷等离子体密度的静态估算. Bortnik 等 (2016) 利用 THEMIS 卫星 2008—2014 年期间的观测数据, 并以 5 小时尺度的 SYM- H 指数为主要输入, 构建双层 FNN 模型, 成功重建了 $L=2\sim 6$ 区域的冷等离子体密度分布. 模型在羽流结构识别方面表现突出 (相关系数 $R > 0.93$, RMSE ≈ 1.7), 验证了神经网络在高度非线性空间结构拟合中的优势. Chu 等 (2017) 进一步将地磁扰动指数 (如 AL 、 $F_{10.7}$) 及空间位置特征引入模型中, 构建包含历史依赖机制的 FNN 网络, 首次实现了对磁暴期间羽流形成、等离子体侵蚀与恢复过程的连续模拟, 为动态过程建模提供了原型范式. 除密度建模外, AI 方法也被应用于等离子体层波动过程的模拟与特征分析. Tang 等 (2023) 使用 LightGBM 梯度增强树模型预测 plasmaspheric hiss 波的振幅演化, 并通过特征重要性排序方法系统评估各输入变量贡献. 在引入冷等离子体密度作为辅助变量后, 模型相关系数由 0.788 提升至 0.973, 显著增强了对磁暴期波动增强的捕捉能力. 此类研究强调了 AI 技术在特征选择、波动建模与物理解释方面的协同潜力.

为了捕捉等离子体层非平稳演化中的时序特征, Huang 等 (2022) 提出基于循环神经网络 (RNN) 的编码器-解码器架构, 将地磁扰动指数的时间序列嵌入隐空间, 再结合卫星轨道参数预测冷等离子体密度演化. 该模型成功重建了羽流在晨昏方向的非对称演变过程, 展现出小时至日尺度密度变化建模中的高稳定性和拟合精度, 拓宽了磁暴响应与粒子输运过程的分析路径.

在面向全球范围建模的需求下, Zhelavskaya 等

(2017) 提出 Plasma density INference Engine (PINE) 模型, 采用 Kp 、 AE 、SYM- H 等多种扰动指数的 96 小时历史数据作为输入, 通过全连接神经网络预测 $L=2\sim 6$ 范围内的电子密度. 模型结果在 Van Allen Probes 与 IMAGE/EUV 成像数据上均表现出良好一致性. 在此基础上, Zhelavskaya 等 (2021) 进一步将 PINE 输出与物理模型耦合, 开展数据同化实验, 有效提升了模型在极端扰动条件下的稳定性, 为 AI 模型与第一性原理模型的融合提供了可行路径.

为满足工程应用对速度与计算资源的实际需求, 研究者开发了若干轻量化、可部署的 AI 模型. Bianco 等 (2023) 提出的 PINE-RT 模型仅以 Kp 指数与 L1 点太阳风参数为输入, 显著压缩输入维度, 提升了推理速度. 该模型虽在精度上略有牺牲, 但具备分钟级预测能力, 适用于航天器充电风险监控、空间天气快速响应等实时场景, 展现出极高的工程部署潜力.

5.3 环电流

环电流是内磁层中围绕赤道面形成的高能粒子电流系统, 主要由能量在 10 keV 至数百 keV 的 H^+ 、 He^+ 、 O^+ 等离子及电子组成, 控制着地磁扰动的空间幅度与结构分布. 其动力学响应受到太阳风压缩、电场对流、波粒散射及磁层-电离层耦合等多重过程驱动. 前馈神经网络作为 ANN 的主要分支, 是最早被应用于环电流建模的 AI 方法, 主要用于静态通量估算与非线性拟合. Li J X 等 (2023) 利用 Van Allen RBSPICE 高时空分辨率质子数据, 构建了环电流质子人工神经网络模型 (RCPANN). 模型以地磁扰动指数 (SYM- H 、ASY- H 、 Kp) 与 L1 点太阳风参数为输入, 预测多个能量通道的质子通量演化. 结果显示模型在磁暴主相期间重建通量增强与空间重构方面具有极高精度, 并揭示出磁地方时方向上的非对称性与恢复期粒子耗散行为. 这一研究标志着基于 ANN 的通量拟合模型已能提供逼近物理过程的预测能力, 尤其适用于捕捉扰动主相下的粒子急剧演化.

Yan Y 等 (2025) 构建了多输出卷积神经网络模型, 以 IMF 参数、太阳风速度/密度与多地磁指数的 3 天历史序列为输入, 同时预测 H^+ 、 He^+ 、 O^+ 、电子在多个能量段的等离子体压力分布. 模型在静止期与磁暴期均表现出高拟合精度 (Pearson 相关系数 $0.93\sim 0.95$), 揭示磁暴期间离子组分的系统性重构现象: H^+ 虽整体占主导, 其主相期间贡献下降, 而 O^+ 在强扰动环境下表现出主导的动力响应. 此外, He^+ 与电子通量的周期性局地增强暗示非局地热输运与质量分离机制在扰动响应中的关键角色, 强调模型需

引入质量区分项以提升物理一致性. DNN 结构适用于模拟复杂耗散机制及其空间-能量分布特征. [Chen 等 \(2023\)](#) 提出的 EPFN (Energetic Particle Flux Network) 模型以太阳风输入、地磁指数与历史电子分布为特征, 重建了全球尺度上的高能电子沉降通量 (EEP). 模型准确捕捉 EEP 在磁暴主相急剧增强与恢复相快速衰减中的异构分布特性, 揭示了环电流能量向极区高层大气沉降的过程, 强调其在电离层加热与极区化学过程中的关键作用. 该方法填补了从环电流系统到下层大气能量链条建模的空白.

6 电离层 (Ionosphere)

6.1 电离层建模

电离层电子密度结构 (如 TEC、 f_oF_2 、 h_mF_2) 是联结太阳活动与地球空间响应的关键耦合层, 在不同纬度区域展现出显著的物理机制差异与非线性演化特征. 传统机器学习方法在高纬区域建模中依然保持良好泛化性能. [Sun 等 \(2011\)](#) 基于 SVM 构建赤道电离异常 (EIA) 区域磁暴期 TEC 变化预测模型, 表现稳定. [McGranaghan 等 \(2018\)](#) 以 SVM 建模极区 GNSS 信号相位闪烁, 提高电离层扰动期信号完整性. [Asaly 等 \(2022\)](#) 则将 SVM 用于地震前兆识别, 成功检测 $M_w > 6$ 地震前 TEC 异常, 真负率 (也称特异度, Specificity) 达 85.7%. 集成学习方法在中低纬度也取得良好效果. [Zewdie 等 \(2021\)](#) 将随机森林 (RF) 与 LSTM 融合, 建模哥伦比亚 TEC 演化, 分析 $F_{10.7}$ 与 $Ly\alpha$ 通量的驱动作用. [Shi 等 \(2023\)](#) 利用 CEEMDAN + ISOA 解耦后与 LSTM 集成建模 h_mF_2 , RMSE 下降约 30%. [Tang 等 \(2023\)](#) 结合 LightGBM 与排列重要性方法, 预测等离子体层嘶声波振幅, 对地磁扰动事件的敏感响应能力显著提升.

循环神经网络及其变体 LSTM 因具备建模非线性、非平稳时间序列的能力, 在电离层建模中得到广泛应用. [Liu 等 \(2020\)](#) 提出融合球谐系数 (SH)、Dst 指数与 EUV 通量的 LSTM 模型, 在低纬区域准确重建 EIA 结构及磁暴增强密度 (SED) 演变. [Shi S 等 \(2022\)](#) 以中国 GNSS 网络为基础, 构建双向 LSTM (BiLSTM) 模型, 显著优于 IRI-2016 与传统 ANN 在 1~2 小时 TEC 预测中的表现. [Ren 等 \(2024\)](#) 设计了融合 SHC 与 VTEC 信息的 Ion-LSTM 模型, 结合地磁日循环特征 (HDs/HDc), 在东亚区域 1~2 日预测精度显著提升. 高纬与极区方向亦有重

要进展. [Kim 等 \(2020, 2021\)](#) 将 LSTM 模型嵌入物理模型 SAMI2 框架, 分别用于 N_mF_2 与 f_oF_2 预测, 在磁暴期相较 IRI-2016 精度提升超过 30%. 此外, [McGranaghan 等 \(2021\)](#) 提出 PrecipNet 网络, 实现极区粒子沉降通量的精细时序建模, 为空间能量输入量化提供新工具. [Chen 等 \(2022\)](#) 提出一种多步辅助预测模型 (MSAP), 基于 LSTM 并结合太阳黑子数、 $F_{10.7}$ 、 A_p 和 Dst 等外部地磁与太阳活动指数, 实现对 TEC 未来 6 天的预测, 其平均绝对偏差 (MAD) 和均方根误差 (RMSE) 分别为 2.485 和 3.511 TECU, 且在磁暴期间表现出良好的稳定性与低误差, 有效缓解了预测时间增长导致的误差累积问题.

[Wang Z 等 \(2023\)](#) 结合 ResNet 与 EfficientNet 架构, 成功识别海南区域 Spread-F 事件图像, 分类准确率远超传统阈值法. [Tian 等 \(2024\)](#) 开发 SELF-ANN 网络, 实现全球 Es 层电离层闪烁强度图重建, Spearman 相关系数达 0.589, 验证其对太阳活动的敏感响应. [Li W B 等 \(2023, 2024\)](#) 进一步基于 CNN-ResNet 模型, 以 IMF B_y 为主变量输入, 精准预测扰动期热层质量密度 (TMD) 响应. [Xu 等 \(2024\)](#) 采用 CNN-BiLSTM-TPA 架构预测低纬 f_oF_2 , 整体表现优于 IRI-2020. [Licata 等 \(2022\)](#) 对比 HASDM-ML 与 CHAMP-ML 模型在磁暴后热层冷却建模中的能力, 成功捕捉 1~3 天内最大 40% 密度下降趋势. [Gao 等 \(2025\)](#) 提出了一种基于深度学习的 ISNet 模型, 用于提前 1 小时预测低纬度地区电离层闪烁指数 S4. ISNet 模型采用多种深度学习技术与动态建模框架, 实现了外部变量可扩展性, 可为其他空间天气事件中复杂动态系统的建模提供参考. [Li W B 等 \(2023\)](#) 利用 ResNet 深度学习框架构建热层质量密度 (TMD) 模型, 基于 CHAMP 卫星 2002—2010 年观测数据训练, 并通过 GRACE-A 数据、HASDM 和 NRLMSISE-00 模型验证, 发现 ResNet 模型较传统 MLP 能更好提取观测数据中的多尺度特征并保留泛化能力, 且通过控制变量实验证实该模型可有效区分赤道质量密度异常和地磁风暴等不同物理过程对应的空间环境指数影响. [Li L C 等 \(2024\)](#) 构建注意力引导的 ED-AttConvLSTM 网络, 显著增强电离层昼夜周期性与扰动响应的建模能力, 尽管在 5 天以上长时序预测中仍面临精度下降挑战. [Jeong 等 \(2024\)](#) 提出基于 ConvLSTM 的朝鲜半岛区域 TEC 预测模型, 该模型直接预测二维 TEC 分布图, 通过卷积操作同时捕捉 TEC 的时序演化规律与空间关联特征, 有效解决了传统逐点 LSTM 预测中格点间

预测值不连续、空间拼接痕迹明显的问题, 显著提升了预测 TEC 图的空间一致性和整体可靠性. Shih 等 (2024) 提出无需地理先验知识的 Transformer 架构, 首次实现全球 48 小时 TEC 预测, RMSE 控制在 1.8 TECU 以内, 显著超越现有 LSTM 模型.

为应对极区快速响应建模需求, Kataoka 等 (2024) 提出 SMRAI2 回声状态网络, 实现百万倍速计算, 用于实时极光系统电导、电流与电势模拟. Gowtam 等 (2024) 构建极区 FAC 网络及电导子模块, 构成 ML-AIM 模型, 实现在热层-等离子体-极光系统的能量闭环建模. Gao 等 (2025) 提出了一种基于动态时空分解框架的电离层闪烁预测方法, 将闪烁幅度 S4 指数分解为背景场和扰动场建模, 并引入动态图生成器来构建观测数据的动态关系网络, 使用一个编码器来聚合先验信息, 以及通过一个延迟感知模块来建模闪烁与太阳辐射、地磁扰动等外部影响之间的时延效应, 可以提前 1 小时较为准确地预报低纬地区电离层闪烁指数的分布.

6.2 极光活动

极光是高纬电离层最直观且动态的电动力学现象, 是太阳风-磁层-电离层 (SW-MLT-IT) 耦合机制的重要可视化表现. 其细节结构与时空分布不仅揭示高纬能量沉降的非均匀性, 还直接关联亚暴起始、电场重构及极区电导率变化等关键过程. 近年来, 得益于全天空成像 (All-Sky Imager, ASI) 系统的广泛部署及多源观测网络的发展, 人工智能 (AI) 技术, 尤其是深度学习 (DL) 与图像识别方法, 正推动极光研究迈向高精度、自动化与物理解释相结合的新阶段. 以下将按主要 AI 建模路径, 对极光图像识别与建模的研究进展进行分类综述.

卷积神经网络以其卓越的图像识别能力, 被广泛用于极光图像的自动分类任务. Clausen 和 Nickisch (2018) 在 THEMIS 全天空图像数据集上构建六类分类器, 实现 82% 的总体准确率, 在极光/非极光二分类任务中的真阳性率高达 96%. Zhong 等 (2020) 采用 AlexNet、VGG、ResNet 等主流模型对中国黄河站图像进行分类, 显著减少对手工特征提取的依赖. Kvammen 等 (2020) 进一步测试七类极光结构识别模型, 验证 ResNet-50 在精度 (92%) 与稳定性方面均优于其他网络, 为极光图像识别奠定标准化技术路径.

针对极光图像标注数据匮乏的问题, 自监督学习为建模提供了创新解决方案. Johnson J W 等 (2024) 基于 SimCLR 框架, 在 2008—2022 年 THEMIS

数据集上训练无监督嵌入网络, 无需人工标签即可提取极光图像的深层特征表示. 结合太阳风参数、IMF 矢量与地磁台站数据, 成功实现六类极光状态的分类与其地磁响应的耦合分析, 为极光类型识别与太阳风驱动机制之间的因果建模提供了新路径.

极光图像的精细结构识别成为近期研究热点. Niu 等 (2019) 提出基于 FPN-C4 架构与两阶段推理机制的改进型 Mask R-CNN 实例分割模型, 在标注测试集上取得 86.8% 的 mAP (mean Average Precision, 平均精度均值), 成功从 18417 张图像中提取出 29938 条极光弧, 进而量化极光弧宽度的统计分布. Yang 等 (2024) 通过南极中山站多视场尺度分析, 发现极光弧宽度服从对数正态分布, 且受限于成像视角与仪器分辨率, 提出了结构建模的物理精度边界.

为满足极光扰动的快速识别与实时预警需求, 多项研究构建了轻量级图像分类系统. Nanjo 等 (2022) 基于 ResNet-50 构建“Tromsø AI”自动识别系统, 处理挪威特罗姆瑟十年全天图像, F1 分数达 93%, 揭示极光的年际周期性、月变化规律与 UT 时间分布特征. Sado 等 (2022, 2023) 开发“TAME”模型, 结合迁移学习与 SVM 分类器, 在六类与二类极光分类任务中分别达到 73% 与 91% 的识别精度, 并在预测未来 15 min 内亚暴 onset 时刻方面展现出良好的实用前景.

7 地磁活动 (Geomagnetic Activity)

7.1 dB_H/dt 预测模型

地磁场作为地球空间天气系统中对太阳风扰动响应最迅速、最直接的部分, 尤其在地磁暴期间, 其水平分量的剧烈变化 (如 dB_H/dt) 可在地表诱发强烈的感应电流 (Geomagnetically Induced Currents, GIC), 对输电、电信、导航与管道系统等关键基础设施构成重大威胁. 近年来多种深度学习模型在预测中展现优越性能. Pinto 等 (2022) 系统评估了前馈神经网络、CNN 与 LSTM 模型在北美六个地磁台站的扰动预测表现, 发现 LSTM 在磁暴期响应中表现出更高灵敏度和更低误差波动. Siddique 和 Mahmud (2022) 进一步提出融合贝叶斯 CNN、贝叶斯 LSTM 与贝叶斯前馈网络的集成深度学习结构, 并引入置信区间估计, 显著提升了模型的稳健性与实际可用性. 在 2011 年与 2015 年强磁暴事件中, 模型不仅保持了较高预测准确率, 还为电网级风险评估提供了

可量化的不确定性输出。

由于地磁观测数据常包含大量瞬态突变与非物理噪声信号,影响模型训练与事件识别的准确性。McCuen 等 (2023) 构建基于 SVM 的地磁扰动识别系统,使用 dB/dr 峰值特征提取短时扰动区段,并通过 SVM 分类其为自然扰动(如极光环电流引发)或人为伪信号(如设备噪声、电网扰动等),为地磁数据预处理、极端事件排查与实时质量控制提供了可行方案。Malanushenko 等 (2020) 基于 Gibson 和 Low 磁通绳模型合成超 3.6 万个 CME 事件样本,构建 CNN 扰动预测系统。以磁场矢量分量 (B_x , B_y , B_z) 作为输入时,最大南向磁场成分 $\max(-B_z)$ 的预测准确率达 97%; 使用极化斯托克斯参数 (L/I , A_z , V/I) 输入亦可达 95%。其中,圆偏振量 V/I 的强相关性表明多通道偏振观测对 CME 建模具有重要潜力。

7.2 地磁亚暴与 AE 指数预测

地磁亚暴作为磁层能量储存与非对称释放的典型过程,其爆发常伴随着极光弧结构迅速增强、电离层电流系统剧烈扰动以及中高纬地区地磁扰动的显著升高。AE 指数(及其组成成分 AU 与 AL) 长期以来被广泛用于描述极区电流强度与亚暴发展阶段,是衡量高纬空间天气扰动的重要参数。传统预测方法主要依赖经验统计与线性回归模型,但在捕捉强非线性演化、实现短时精准预测及触发事件识别等方面存在明显不足。近年来,人工智能技术,特别是深度神经网络、卷积模型、稀疏贝叶斯学习与记忆增强结构,在 AE 指数建模与亚暴事件分类中展现出显著优势。

在 AE 指数短时建模的早期探索中,Amata 等 (2009) 提出基于人工神经网络 (ANN) 的 AE 指数预测框架,模型以 L1 点的太阳风参数与 IMF 磁场矢量为输入,构建具有时间反馈结构的前馈网络,用于 5 min 与 60 min 尺度的 AE 值预测。在 $AE > 400$ nT 的强扰动条件下,其 60 min 预测性能显著优于传统经验模型,而 5 min 尺度的性能提升较为有限,反映出 AE 指数对太阳风输入存在一定的“短时预测盲区”。后续研究中,Ferreira 和 Borges (2021) 通过引入季节、地方时等辅助变量,显著提升了 ANN 模型的拟合能力,相关系数高达 0.91,研究发现 IMF 矢量分量(特别是 B_z) 相较于太阳风速度对 AE 指数变化具有更强的预测贡献,而太阳活动周期参数则影响较小。这一结果强调了高维磁场信息在电流指数建模中的关键作用。Yang 和 Shen (2022) 开发了一种基于非线性自回归外生输入 (Nonlinear Autoregressive

Network with Exogenous Inputs, NARX) 神经网络的模型,用于提前一天预测周期性的地磁扰动幅度(以 A_p 指数衡量)。模型输入为从太阳观测中获得的源表面特征(包括膨胀因子、最小角距离、磁场强度、磁纬度和电子密度等),并结合历史 A_p 指数反馈。对 CR2181 至 CR2190 期间的预测结果显示,该模型的精度高于 27 天持续法,尤其在预测 A_p 指数大于 10 和 15 的地磁扰动日时,具有更高的探测概率和更低的虚警率。

针对亚暴触发机制复杂、难以单一时间序列建模的问题,自组织映射 (SOM) 与卷积网络结构被引入进行事件级分类与概率建模。Barkhatov 等 (2020) 基于 SOM 神经网络,利用 1998—2012 年 33 个磁云事件的 AL 扰动数据,识别出三类典型亚暴响应模式,并通过 IMF B_z 持续负向时间等积分特征完成事件聚类,准确率达 70%。Maimaiti 等 (2019) 则首次将 ResNet 结构用于亚暴概率预测,模型以过去 2 小时的太阳风参数作为输入,输出未来 1 小时的亚暴发生概率。尽管模型召回率达 77%,但主成分分析揭示太阳风输入间存在高度冗余,提示亚暴触发机制还涉及磁尾能量积累与再联结等隐藏变量,亟待物理引导的 AI 建模框架进一步挖掘。Andriyas 和 Andriyas (2017) 采用多变量相关向量机 (MVRVM),构建基于稀疏表示的地磁指数预测模型,仅用 14.6% 的训练样本即成功预测 Dst 、 AL 与 PC 等指数,在主磁暴期间的预测效率分别达 82.4%、84.4% 和 76.0%。该方法在小样本学习与模型泛化方面展现出独特优势。Nakano 和 Kataoka (2022) 则利用回声状态网络 (Echo State Network, ESN) 构建 AU/AL 指数的非线性预测模型,揭示在 IMF B_z 接近零但太阳风速度较高时,太阳风质子密度对 AU/AL 存在非线性放大调制效应,从数据驱动角度提供了极光电急流激发机制的新解释。

从早期的前馈神经网络与简单时序建模,到近年来基于事件驱动的深层卷积模型、稀疏贝叶斯结构与概率神经网络,AI 方法正在重塑 AE 指数预测与地磁亚暴识别的理论体系与建模范式。当前趋势正由传统序列回归转向高维输入融合、概率预测与物理机制嵌入,强调非线性结构的表达能力与事件触发的精准识别。

7.3 Dst 指数与磁暴预报

Dst 指数作为表征地磁环电流扰动强度的关键参数,长期用于量化磁暴的强度、演化过程及空间天气影响。然而,受限于太阳风-地磁系统间的强非

线性耦合关系及扰动响应中的复杂时滞特性, 传统物理驱动模型在短时预报、实时响应和不确定性表达等方面存在明显局限. 近年来, 随着 AI 技术的迅速发展, 越来越多的研究将其应用于地磁指数 (Dst 、 $SYM-H$ 、 Kp) 等的短期与中长期预测, 展现出优越的性能和应用潜力.

前馈神经网络 (FNN) 作为 AI 技术在地磁建模中最早被应用的模型之一, 具有结构简单、训练快速的优势. Wu 和 Lundstedt (1997) 首次基于 Elman 型递归网络对 Dst 指数进行预测, 验证了太阳风速度 (V)、密度 (n) 及 IMF 南向分量 (B_z) 在驱动地磁扰动中的重要作用. Lazzús 等 (2017) 进一步将粒子群优化 (PSO) 引入人工神经网络 (ANN) 中, 仅基于历史 Dst 序列便可实现 3 小时内的高精度预测. 尽管该类模型不具备时间记忆功能, 但在轻量部署、数据规模受限的情境下仍具有实际应用价值.

针对地磁扰动的时序特性, 循环神经网络 (RNN) 及其演化结构 (LSTM、GRU、Bi-LSTM) 成为近年研究热点. Gruet 等 (2018) 提出结合高斯过程的 GPNN 模型, 用于 Dst 指数 1~6 小时的概率预测, 其中 1 小时相关系数高达 0.966. Hu 等 (2023) 则结合 GRU 与多保真度增强策略, 实现 6 小时窗口内 $RMSE = 13.54$ nT 的精度水平. Bi-LSTM 结构进一步捕捉扰动的双向时间特征, Abdualлах 等 (2024) 结合图神经网络提出 SYMHnet 模型, 实现分钟级分辨率下 $SYM-H$ 的短时精准预测.

集成学习因其鲁棒性与泛化能力, 在地磁建模中被广泛采用. Ren 等 (2023) 提出 DLMEM 模型, 融合随机森林 (RF)、XGBoost 与注意力机制 GRU, 在 170 次磁暴事件的恢复期 TEC 预测中, 优于 Ion-LSTM 模型, $RMSE$ 降低逾 40%. Wang J J 等 (2023) 基于 XGBoost 预测 Kp 指数, 在暴时期间 $F1$ 分数达 0.82, 优于 SWPC 的 3 天预测. Wang T Y 等 (2024) 利用积分梯度算法分析 AI 模型的决策逻辑, 提升了地磁 AI 预报模型的可解释性. Wang T Y 等 (2025) 以日冕大尺度结构参数作为预报因子驱动神经网络模型, 使模型的磁暴事件预报能力显著优于国际前沿的 Kp 指数 AI 预报模型.

高斯过程回归 (GPR) 与贝叶斯神经网络为地磁扰动预测提供了不确定性表达与可信区间评估的能力. Chandorkar 等 (2017) 提出 GP-AR/ARX 模型, 输出 Dst 指数的动态置信区间, 适用于磁暴等级分类. Smith 等 (2020) 对比多种模型后指出, 以 IMF B_z 和

磁场强度为输入的贝叶斯模型在 SC/SSC 突发事件预测中 ROC (Receiver Operating Characteristic, 受试者工作特征) 得分超 0.8, 具备较强的稳健性与可解释性, 适合用于轨道调整、电网防护等高风险场景.

CNN 模型因其强大空间特征提取能力, 被用于遥感图像驱动的地磁扰动建模. Hu 等 (2022) 使用 SoHO 卫星 MDI、EIT、LASCO 图像预测 Dst 骤降事件, 实现 1~3 天的提前预警. Getmanov 等 (2024) 结合 ResNet34 网络与 Muon 望远镜数据识别 $Dst < -45$ nT 的极端事件, 准确率超过 82%. 该类方法为磁暴前兆识别、多模态预测与图像信息融合提供了新范式. 图神经网络 (Graph Neural Network, GNN) 为建模地磁扰动的全球空间结构提供新手段. Upendran 等 (2022) 提出无网格深度模型 DAGGER, 结合 GRU 与球谐函数预测全球 dB/dt 的 1 min 分辨率扰动, 最远可提前 30 min 响应. Abdualлах 等 (2024) 在 GNN-BiLSTM 框架下构建 $SYM-H$ 预测模型, 实现对突发扰动的空间感知建模. GNN 方法适用于建模磁场拓扑结构、极区电流闭合路径与全球扰动传播链.

面对极端磁暴数据稀缺、不平衡性严重的挑战, AI 模型开始引入特殊机制增强预测性能. Chu 等 (2025) 提出 IRANNA 模型, 引入不平衡学习策略, 显著提升 SuperMAG SML 强事件的预测准确率. Wang R Y 等 (2024) 使用 Encoder-Decoder 结构结合蒙特卡洛 Dropout 机制, 为 Dst 序列构建可信置信区间. Conde 等 (2023) 通过 LSTM 与 block bootstrapping 结合, 量化 $SYM-H$ 2 小时内预测的不确定性, 验证其在短时尺度内的稳健性. 为实现地磁扰动的多指标协同建模, 研究者构建了多任务学习框架, 联合建模 Dst 、 $SYM-H$ 与 Kp 等地磁指数. Tan 等 (2018) 与 Wang J J 等 (2023) 分别使用 LSTM 与 XGBoost 模型预测 Kp , 磁暴期间性能显著优于传统模型. Siciliano 等 (2020) 比较 CNN 与 LSTM 对 $SYM-H$ 建模的差异, 验证历史信息对提升预测效果的重要性. Collado-Villaverde 等 (2024) 提出通用评价指标分箱误差 (BFE) 衡量模型对强磁暴的适应能力, 为统一评估体系奠定基础.

8 磁重联和湍流

磁重联 (Magnetic Reconnection) 与湍流 (Turbulence) 是太阳风-磁层相互作用中最关键的非线性动力学过程, 广泛存在于地球磁尾、日冕爆发、太阳风与行

星际空间等多种等离子体环境中. 尽管已有大量理论和模拟研究揭示了磁重联的拓扑演化及湍流的谱分布与能量级联特性, 但受限于高维数据复杂性与空间观测稀疏性, 其精确建模、结构识别与机制归因仍面临挑战. 随着机器学习与深度学习技术的发展, 研究者逐步借助数据驱动方法分析大规模粒子模拟、磁力仪测量及遥感观测, 显著提升了磁重联与湍流事件的自动检测效率, 并推动小尺度结构还原与潜变量重建的新路径探索.

事件检测与分类是 AI 方法最早应用于磁重联与湍流研究的领域之一. [Hu 等 \(2020\)](#) 基于二维 Vlasov-Maxwell 混合模拟构建超过 2000 例手动标注图像, 采用卷积神经网络 (CNN) 训练识别 32×32 像素事件片段, 准确率达 70%, 真阳性率达 82%, 优于传统决策树模型, 验证了 DL 在结构识别中的优势. 在无监督学习方面, [Sisti 等 \(2021\)](#) 采用 K-means 与 DBSCAN 对模拟电流片结构进行聚类, 通过纵横比 $AR=18$ 的阈值优化分类性能, 实现对磁重联区与背景区的自动划分. [Waters 等 \(2024\)](#) 基于 2.5 维 PIC 模拟与 K-means 聚类, 进一步划分出流入区、扩展区与分离区等结构单元, 揭示引导磁场强度对离子能量释放的调控作用. [Dupuis 等 \(2020\)](#) 引入高斯混合模型 (GMM) 结合贝叶斯信息准则 (BIC), 识别非高斯分布粒子速度结构, 精度优于传统各向异性参数 Q , 尤其在双哈里斯片结构的粒子非热特征捕捉方面表现出色. 这些研究表明, 监督与无监督学习技术均能有效提升磁重联与湍流事件的自动识别与区域分类能力, 具备在大规模模拟与多航天器观测任务中广泛应用的潜力.

其次, ML 方法在磁重联拓扑结构重建方面已带来突破性进展. [Sitnov 等 \(2021\)](#) 基于 K 最近邻 (KNN) 方法, 挖掘磁尾 MHD 模拟数据, 成功定位 $30R_E$ (R_E 为地球半径, $1R_E=6371$ km) 的稳定重联区与 $20R_E$ 的瞬态重联区, 相关粒子轨道模拟验证了其动力学稳定性. [Stephens 等 \(2023\)](#) 结合 26 年多航天器数据与模式识别方法, 重建了磁尾典型拓扑结构 (如 X 线、O 线与磁零点), 并与 MMS 卫星离子扩散区观测实现小于 $2R_E$ 的空间匹配, 验证了准绝热离子轨道机制的物理合理性. [Köhne 等 \(2023\)](#) 利用自组织映射 (SOM) 方法对 PIC 模拟数据进行解析, 成功划分出等离子体团的边界区、合并区、内核区等关键区域, 体现无监督算法在高维全动力学数据中的应用优势.

随着模拟复杂度与变量维度激增, 传统 AI

模型面临泛化能力与可解释性瓶颈. 融合物理约束的神经网络成为当前热点. [Mathews 等 \(2021\)](#) 基于 Braginskii 双流理论构建物理信息神经网络 (PINNs), 利用二维电子压强张量输入, 重建电场与电势场, 在多噪声环境下性能优于 Boltzmann 近似. [Rosofsky 和 Huerta \(2023\)](#) 结合张量傅里叶网络与物理信息神经算子 (PINO), 在不可压磁流体 (MHD) 雷诺数 $Re=250$ 模拟中重建湍流流线结构, 保留能量守恒特性.

在太阳风与磁层局地环境中, 小尺度结构 (如小型磁通量绳 SMFRs、等离子体团等) 是磁重联与湍流能量耗散的重要载体. [Farooki 等 \(2024\)](#) 基于 Wind 卫星时间序列, 使用随机森林算法分类太阳风为 MCs、SMFRs 与非磁绳区域, SMFR 识别结果 AUC (Area Under the Curve, 曲线下面积) 高达 86%, 提示其可能源于背景磁结构演化. [Bergstedt 和 Ji \(2024\)](#) 利用解析 MHD 构造人工等离子体团数据, 结合浅层 CNN 训练结构识别模型, 尽管检出率达 70%, 但背景扰动下假阳性偏高, 说明当前模型在复杂观测环境中的鲁棒性仍有待提升.

这些研究拓展了 AI 在局域磁结构探测、极小尺度事件分类及模拟数据还原等方面的技术边界. 人工智能技术正深刻变革磁重联与湍流等离子体动力学的研究范式. 从事件识别、结构重建到变量反演与机制推断, AI 不断拓展空间等离子体建模的尺度与维度. 同时, 融合守恒物理、图结构拓扑与不平衡学习策略成为提升模型可解释性与稳健性的核心方向.

9 行星空间

行星磁层作为行星空间环境中最为复杂且高度动态的区域, 其结构与行为受到太阳风输入、内部等离子体源、磁场配置及电离层耦合等多重因素共同调控. 随着深空探测任务的不断深入, 如 Juno (木星)、Cassini (土星)、MESSENGER (水星) 等探测器提供了覆盖多个行星系统的长期高分辨率磁场与等离子体观测数据. 与地球磁层类似, 这些外行星系统同样具备典型的物理边界与结构特征, 包括磁层顶 (MP)、弓激波 (BS)、等离子体片、磁尾以及磁重联等重要动力学区域. 受限于行星环境的多样性、观测数据稀疏性及扰动尺度的显著差异, 传统依赖物理阈值与专家经验的边界识别与建模方法在效率、精度及跨行星适应性方面逐渐暴露出局限性.

在此背景下, AI 技术正日益成为行星空间环境研究的重要补充工具. 下面我们将从行星磁层边界识别、磁重联建模与结构分类、以及物理融合建模三个角度系统梳理相关 AI 研究进展, 并探讨其未来发展趋势.

磁层边界识别是 AI 在行星空间环境研究中最先取得突破的领域之一. Collier 等 (2020) 利用改进的 K-means 聚类算法, 系统分析了地球与木星磁层顶穿越事件的统计特征. 研究发现, 地球磁层顶呈现单峰分布, 而木星则表现为双峰结构. 该差异被归因于木卫一以约 1 吨/秒的重离子注入速率所构成的强内源等离子体源, 其量级远高于地球电离层输入, 极大增强了木星磁层的多稳定态演化. 此外, 研究还指出木卫一的轨道相位与磁层顶状态之间存在显著统计相关性, 为理解木星磁层的复杂边界行为提供了新视角. 在监督学习方面, Cheng 等 (2022) 基于深度残差网络 (ResNet) 构建了多分类识别框架, 利用 Cassini 任务中获取的磁场与等离子体数据, 实现对土星弓激波 (BS) 与磁层顶 (MP) 穿越事件的自动识别. 该模型在 F1 指标上分别达到 92.1% 和 84.7%, 显著优于传统经验阈值法, 具备强泛化能力, 特别适用于未来如 JUICE 任务的实时边界识别模块. 类似地, Nevskii 等 (2023) 基于 MESSENGER 磁强计数据构建随机森林 (RF) 与支持向量机 (SVM) 模型, 对水星磁层边界进行了精确识别. 结果表明, 87% 的弓激波定位误差小于几十公里, 83% 的磁层顶预测结果与人工标注一致, 为 BepiColombo 任务中的边界识别任务提供了技术支持.

磁重联作为行星磁尾中能量释放与粒子加速的关键过程, 是 AI 建模的另一重要应用方向. Garton 等 (2021) 基于 Cassini 任务数据, 设计前馈神经网络 (FNN) 模型, 以 KRTP 坐标系下的磁场分量为输入, 自动识别土星磁尾中的重联事件. 模型可高效分类典型重联结构, 如等离子体团 (plasmoids)、行进压缩区域 (TCRs) 与偶极化前沿 (dipolarization fronts), 实现对长时序观测数据中事件的快速统计与物理建模. 在更广义的物理建模任务中, Moschou 等 (2023) 首次将物理信息神经网络 (PINNs) 方法引入行星激波反问题中. 该方法利用稀疏流体观测数据作为输入, 结合引力场控制方程, 通过 PINNs 反推出速度场、密度场与压强场. 结果显示, 在多种观测缺失与噪声条件下, PINNs 模型可将密度预测精度提升 2~16 倍, 相关偏差控制在 1% 以内, 展现了

在稀疏、高噪环境下的强鲁棒性与物理一致性.

在技术与范式交汇的关键时期, 人工智能正加速成为驱动科学范式跃迁的核心引擎. 在这一关键战略窗口期, 空间科学与空间探测领域正借助 AI 技术, 快速实现从“经验驱动”向“数据-模型-知识协同驱动”的深层次范式转型. 作为典型的非线性、多尺度、多源耦合复杂系统, 空间天气与空间环境的建模、预测与机制解释长期面临观测能力受限、动力学复杂性高与跨尺度因果链难以解析等挑战. 而 AI 尤其是深度学习、图神经网络、物理信息神经网络、强化学习与生成模型等智能方法的兴起, 正不断突破上述瓶颈, 推动空间科学迈入“智能融合建模”新时代. 在此背景下, 系统性推动 AI 技术赋能空间科学与空间探测, 不仅是科技前沿的重要突破口, 更是服务我国空天安全、深空探测、空间环境监测与预警体系建设的核心战略任务.

9.1 从工具到范式：空间科学研究的智能跃迁

从工具到范式, AI 正在深度赋能空间科学体系. 空间天气研究正在从“物理建模+数值模拟”向“物理引导的数据智能融合建模”加速转型. AI 的嵌入式发展不仅停留于数据分析阶段, 更在预测、反演、系统识别、事件识别、因果建模等核心领域形成“质变”. 空间天气研究正从传统的“物理建模+数值模拟”范式, 向“物理引导+数据驱动+智能建模”快速转型. 以地磁扰动指数 (Dst 、 $SYM-H$ 、 Kp) 为例, 早期方法如 NARX 和 Elman 网络已实现小时级短期预测; 而近年来, LSTM、GRU、Transformer 等深度序列网络与 XGBoost、随机森林 (RF)、贝叶斯优化等技术的融合, 使预测系统实现了从静态回归向时空概率性、结构可解释性与不确定性估计的跃迁.

另一方面, 空间探测智能化迈入任务场景驱动阶段. 面向土星、木星、水星等行星空间的探测任务, AI 方法已深度嵌入航天器边界识别、结构反演、异常预警、磁重联检测等关键流程. 例如 Cheng 等 (2022) 使用 ResNet 网络精确识别卡西尼号磁层结构; Nevskii 等 (2023) 通过机器学习分析 MESSENGER 数据实现水星磁顶自动化识别; Garton 等 (2021) 借助前馈神经网络对土星磁尾磁重联类型进行分类识别, 皆展示了 AI 在“任务级”自主科学认知中的巨大潜力.

9.2 以数据生态为核心：构建 AI-ready 空间科学基础设施

AI 模型的性能上限并不取决于算法结构本身, 而更多依赖于训练数据的质量与结构. 因此, 构建标

准化、结构化、同步化、开放共享的 AI-ready 空间科学数据体系是实现“从单点模型到系统智能”的核心前提。空间 AI 的真正“引擎”不在模型,而在数据生态。以 NASA 的 SDO 项目为例, Galvez 等 (2019) 发布的 6.5 TB 空间 AI 数据集实现了从图像校正、时间对齐到模型基线建立的全流程标准化; SPASE 元数据模型与 HAPI 协议 (Masson et al., 2024) 则为国际日地物理数据共享建立了语义互通的标准。

中国也在积极构建 AI-ready 数据生态体系: 子午工程二期 (China Meridian Project-II, CMP-II) 提出“一链三网四重点”构架, 覆盖从太阳到地球磁层的多尺度耦合过程; 国家空间科学中心的空间环境特殊效应分析平台 (Multiscale Space Environmental Effects Analysis Platform, MSEE)、探月工程和电磁监测网等也为 AI 模型训练提供“东方样本”与关键数据资源。未来构建多模态、全时序、高质量、可追溯的数据生态, 将成为 AI 系统性能突破与可信建模的战略基础设施。

9.3 未来展望: 建设“中国空间智能基础设施”

人工智能在空间科学中的角色正由分析工具向“智能认知合作者”转变。未来的 AI 系统不仅要具备预测和控制能力, 更应实现自适应学习、跨尺度物理推理、科学规律发现与任务协同决策。AI 模型不再局限于“黑箱式”数据拟合, 而是以因果建模、物理约束学习、知识图谱推理等能力为支撑, 自动解析磁重联、极区能量耦合、等离子体输运等关键过程的物理机制。

特别是在异星探测与深空任务中, 构建具备推理与认知能力的“空间智能体”将成为关键支撑路径。在此背景下, 未来中国空间智能基础设施的建设可从以下三个核心方向展开:

(1) 具身智能与星载推理 (Embodied AI and Onboard Inference)

空间科学正逐步迈入“从云端预测向星载推理转变”的新时代。伴随着国产化 AI 芯片、自主操作系统及轻量化模型 (如 MobileNet、TinyML、EdgeTransformer) 在航天平台上的加速部署, 未来的空间天气建模将逐步从地面计算迁移至在轨智能体, 实现对扰动事件的本地实时感知与自主响应。

具身智能体 (Embodied AI Agent) 可将感知、分析与初步决策能力内嵌于遥感卫星与探测器, 实现“在轨识别-在轨判断-在轨响应”的闭环运行模式。这一范式不仅大幅减少了对地面数据回传与计算依赖, 提升系统响应速度与鲁棒性, 更标志着空间科

学研究范式从“离体建模”向“嵌入式智能建模”的根本转型。

(2) 全链式物理图谱构建 (Causal Graphs of Space Weather Systems)

空间天气是一个跨圈层、多尺度、高耦合的复杂系统, 涵盖太阳、日冕、行星际空间、磁层、电离层与热层等多个子系统。当前 AI 模型多集中于单环节建模, 难以捕捉系统级动力学演化的整体逻辑。

为突破“黑箱式预测”局限, 未来亟需基于因果推理 (Causal Inference)、图神经网络 (GNN) 与知识图谱 (Knowledge Graph) 等 AI 方法, 构建覆盖太阳-行星际-磁层-电离层-热层全过程的全链式物理图谱, 实现:

- 多圈层间能量与物质传输路径的系统性表达;
- 多源数据与模型知识的语义融合与因果约束;
- 对复杂扰动事件的可解释建模、可追溯预测与逆向推理。

该图谱不仅可为 AI 模型提供结构先验与因果路径支撑, 也有望推动空间天气从“数据驱动预测”走向“物理驱动发现”的新阶段。

(3) 面向 AI for Science 的弹性系统建模 (Resilient AI Systems for Scientific Discovery)

未来的空间天气建模系统, 除需具备高精度预测能力外, 还应满足复杂空间环境中跨任务、跨区域、跨尺度的自适应建模需求。这就要求 AI 模型具备弹性系统特性, 可以实现: 分布式学习与动态重构能力, 适应不同平台和观测资源差异; 物理知识嵌入与持续学习机制, 保持模型物理一致性与长期稳定性; 迁移泛化与鲁棒进化能力, 应对任务目标变化与数据稀缺场景。

通过引入如物理信息神经网络、联邦学习 (Federated Learning)、模型蒸馏与动态重构机制, AI 模型将实现从“静态工具”向“科学智能体”的转型, 具备自适应演化、因果推理与跨任务泛化能力, 成为空间科学研究中不可或缺的创新引擎。

展望未来, AI 化不仅是技术趋势, 更代表一种科学思维范式的根本跃迁。中国具备以下三大独特优势:

- 1) 拥有全球最系统的空间天气观测网络 (如国际子午圈计划 IMCP);
- 2) 拥有最完整的深空探测任务体系 (探月、探火、探小行星);
- 3) 拥有最活跃的 AI 科研生态与工程能力积累。

因此, 我们有望引领“空间智能”新赛道. 在此, 我们倡议以 CMP 子午工程为战略支点, 联动地面观测、天基遥感与智能探测三大体系, 构建“以空间任

务为牵引, 以探测数据为基石, 以 AI 技术为引擎”的中国空间智能基础设施体系, 为人类深入理解日地系统与太空环境演化提供“中国方案”.

附表 1 统一术语表 (Glossary)

缩写/术语	全称	中文释义	说明与适用范围
ACE	Advanced Composition Explorer	太阳风监测卫星	监测太阳风成分、磁场及高能粒子, 提前预警CME等事件, 支撑空间天气预报
AI	Artificial Intelligence	人工智能	泛指模拟人类智能的算法与系统, 包含机器学习、深度学习等
ANN	Artificial Neural Network	人工神经网络	模拟生物神经元的计算模型, 借多层连接处理非线性数据, 适用于图像识别、语音交互等智能任务 (摘要 1/5).
CCNN	Cascade CNN	级联卷积神经网络	多阶段级联 CNN 结构, 逐层精细化特征, 适用于目标检测、图像超分辨率等多步处理任务
CME	Coronal Mass Ejection	日冕物质抛射	太阳抛射的磁化等离子体云, 引发地磁暴, 适用于空间天气预警及航天器防护
CNN	Convolutional Neural Network	卷积神经网络	主要用于图像/空间结构建模, 强调局部特征与共享权重
DDNN	Data-Driven Neural Networks	数据驱动神经网络	依赖海量数据训练的神经网络, 无需先验物理模型, 适用于气候预测、复杂系统建模
DL	Deep Learning	深度学习	基于多层神经网络的机器学习方法, 适用于非线性与大数据建模
DNN	Deep Neural Network	深度神经网络	一般指MLP类全连接网络, 是DL最基础的形式
DTC	Deep Time-series Clustering	深度时间序列聚类	用 GRU 提特征并联合优化聚类, 适用于 GHI 及类似时序数据的模式识别与聚类.
FADF	Feature Attention based Deep Forecasting	特征注意力深度预测	借特征注意力加权 + GRU, 适用于 DTC 聚类后 GHI 等短期时序预测.
FCN	Fully Convolutional Network	全卷积神经网络	CNN 改进架构, 全卷积层输出同尺寸分割图
GBDT / XGBoost	Gradient Boosting Decision Tree	梯度提升树 / 极限梯度提升	集成学习方法, 提升弱学习器性能
GHI	Global Horizontal Irradiance,	全球水平面太阳辐照度	测量地表单位面积水平面太阳总辐射, 适用于光伏发电效率评估及短期预测(如摘要 1 太阳能模型输入).
GMM	Gaussian Mixture Model	高斯混合模型	多高斯分布加权混合的概率模型, 支持软聚类, 适用于多模态数据聚类、密度估计及图像/语音分析.
GNN	Graph Neural Network	图神经网络	适合建模具有拓扑结构的数据, 如磁层区块间相互作用
GOES	Geostationary Operational Environmental Satellite	地磁场观测卫星	美国静止轨道气象卫星, 监测天气、空间环境 (如太阳 X 射线), 用于灾害预警及空间天气监测
GRU/BiGRU	Gated Recurrent Unit/Bidirectional GRU	门控循环单元/双向GRU	LSTM轻量版本, 更快训练; BiGRU处理序列双向依赖
IMF	Interplanetary Magnetic Field	行星际磁场	太阳风携带的磁场, 控制磁层顶重联, 影响极光/辐射带, 是空间天气模型关键输入
KNN	K-Nearest Neighbor	K近邻算法	基于“距离最近”原则的非参数模型, 用于分类/回归
KPCA	Kernel Principal Component Analysis	核主成分分析	PCA 的非线性扩展, 借核函数映射高维空间提取非线性特征, 适用于太阳耀斑预测等复杂非线性数据降维.
LSTM	Long Short-Term Memory	长短期记忆网络	RNN的改进版本, 解决梯度消失问题, 常用于预测任务
MHD	Magnetohydrodynamics	磁流体动力学	融合流体力学与电磁学, 模拟太阳爆发、磁层演化, 适用于空间等离子体物理建模
ML	Machine Learning	机器学习	AI的重要分支, 依赖样本学习函数关系, 含监督/无监督/强化学习等范式
MLP	Multilayer Perceptron	多层感知器	多层全连接前馈网络, 借非线性激活建模, 适用于分类、回归等非线性任务.
MMS	Magnetospheric Multiscale Mission	磁层多点测量任务	NASA 四星编队探测磁层, 高精度测量磁场/等离子体, 支撑磁重联等空间物理机制研究
MSEE	Multiscale Space Environmental Effects Analysis Platform	空间环境特殊效应分析平台	国家空间科学中心开发的航天数据平台, 聚焦辐射效应/电磁监测等, 为探月工程、AI 模型训练提供空间环境数据支撑.
PCA	Principal Component Analysis	主成分分析	无监督线性降维算法, 用于特征压缩与解释
PINN	Physics-Informed Neural Network	物理信息神经网络	融合物理方程 (如MHD)与神经网络的混合建模架构

续附表 1			
缩写/术语	全称	中文释义	说明与适用范围
RF	Random Forest	随机森林	集成多棵决策树的传统机器学习方法, 具有鲁棒性
RNN	Recurrent Neural Network	循环神经网络	处理时间序列数据, 适合动态演化建模
SEPs	Solar Energetic Particles	太阳高能粒子	太阳爆发(如 CME)加速的高能质子/电子, 威胁航天器安全, 适用于空间天气辐射风险评估
SHAP	SHapley Additive ExPlanations	Shapley加法解释模型	解释黑箱AI模型预测机制的重要工具
SHARP	Space-weather HMI Active Region Patch	空间天气HMI活动区数据块	SDO/HMI卫星提取的活动区矢量磁图及18项衍生物理参数(磁通量、剪切角、电流密度等), 适用于太阳耀斑、CME、SEP等爆发事件的机器学习预测建模与活动区演化分析
SHESEA	SHAP-Enhanced Superposed Epoch Analysis	SHAP 增强叠加纪元分析	结合 SHAP 与叠加纪元分析, 适用于辐射带增强/耗竭事件驱动因素分析.
SMOTE	Synthetic Minority Over-sampling Technique	合成少数类过采样技术	用于解决样本不平衡的机器学习预处理方法
SOM	Self-Organizing Map	自组织映射	一种神经网络式的聚类与降维方法, 常用于可视化结构识别
SVM	Support Vector Machine	支持向量机	强健的传统分类模型, 适合高维小样本问题
Transformer	Transformer	Transformer神经网络	基于注意力机制的新一代序列建模网络, 擅长处理长依赖结构

References

Abduallah Y, Jordanova V K, Liu H, et al. 2022. Predicting solar energetic particles using SDO/HMI vector magnetic data products and a bidirectional LSTM network. *The Astrophysical Journal Supplement Series*, 260(1): 16, doi: [10.3847/1538-4365/ac5f56](#).

Abduallah Y, Wang J T L, Wang H M, et al. 2023. Operational prediction of solar flares using a transformer-based framework. *Scientific Reports*, 13(1): 13665, doi: [10.1038/s41598-023-40884-1](#).

Abduallah Y, Alobaid K A, Wang J T L, et al. 2024. Prediction of the SYM-*H* index using a Bayesian deep learning method with uncertainty quantification. *Space Weather*, 22(2): e2023SW003824, doi: [10.1029/2023SW003824](#).

Abiodun O I, Jantan A, Omolara A E, et al. 2018. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11): e00938, doi: [10.1016/j.heliyon.2018.e00938](#).

Ahn S, Son J, Moon Y J, et al. 2025. Comparison of empirical and deep learning models for solar wind speed prediction. *The Astrophysical Journal*, 987(2): 179, doi: [10.3847/1538-4357/ade0b4](#).

Akasofu S I. 1980. The solar wind-magnetosphere energy coupling and magnetospheric disturbances. *Planetary and Space Science*, 28(5): 495-509, doi: [10.1016/0032-0633\(80\)90031-8](#).

Akasofu S I. 1981. Energy coupling between the solar wind and the magnetosphere. *Space Science Reviews*, 28(2): 121-190, doi: [10.1007/BF00218810](#).

Albregtsen F, Maltby P. 1978. New light on sunspot darkness and the solar cycle. *Nature*, 274(5666): 41-42, doi: [10.1038/274041a0](#).

Alielden K, Camporeale E, Korsós M B, et al. 2023. Prediction interval of interface regions: Machine learning nowcasting approach. *Space Weather*, 21(3): e2022SW003326, doi: [10.1029/2022SW003326](#).

Amata E, Consolini G, Palocchia G, et al. 2009. ANN forecast of hourly averaged AE index based on L1 IMF and plasma measurements. *Acta Geophysica*, 57(1): 185-196, doi: [10.2478/s11600-008-0083-1](#).

Amaya J, Dupuis R, Innocenti M E, et al. 2020. Visualizing and interpreting unsupervised solar wind classifications. *Frontiers in Astronomy and Space Sciences*, 7: 553207, doi: [10.3389/fspas.2020.553207](#).

Andriyas T, Andriyas S. 2017. Use of Multivariate Relevance Vector Machines in forecasting multiple geomagnetic indices. *Journal of Atmospheric and Solar-Terrestrial Physics*, 154: 21-32, doi: [10.1016/j.jastp.2016.11.002](#).

Anirudh R, Archibald R, Asif M S, et al. 2023. 2022 review of data-driven plasma science. *IEEE Transactions on Plasma Science*, 51(7): 1750-1838, doi: [10.1109/TPS.2023.3268170](#).

Arthur D, Vassilvitskii S. 2007. *k*-means++: The advantages of careful seeding. //Proceedings of the 18th annual ACM-SIAM symposium on Discrete algorithms. New Orleans: Society for Industrial and Applied Mathematics, 1027-1035.

Asaly S, Gottlieb L A, Inbar N, et al. 2022. Using Support Vector Machine (SVM) with GPS ionospheric TEC estimations to potentially predict earthquake events. *Remote Sensing*, 14(12): 2822, doi: [10.3390/rs14122822](#).

Asensio Ramos A, Cheung M C M, Chifu I, et al. 2023. Machine learning in solar physics. *Living Reviews in Solar Physics*, 20(1): 4, doi: [10.1007/s41116-023-00038-x](#).

Azari A R, Lockhart J W, Liemohn M W, et al. 2020. Incorporating physical knowledge into machine learning for planetary space physics. *Frontiers in Astronomy and Space Sciences*, 7: 36, doi: [10.3389/fspas.2020.00036](#).

Baker D N, Blake J B, Callis L B, et al. 1994. Relativistic electron acceleration and decay time scales in the inner and outer radiation belts: SAMPEX. *Geophysical Research Letters*, 21(6): 409-412, doi: [10.1029/93GL03532](#).

Baker D N, Pulkkinen T I, Angelopoulos V, et al. 1996. Neutral line model of substorms: Past results and present view. *Journal of Geophysical Research: Space Physics*, 101(A6): 12975-13010, doi: [10.1029/95JA03753](#).

Baker D N. 2020. Solar-terrestrial data science: Prior experience and future prospects. *Frontiers in Astronomy and Space Sciences*, 7: 540133, doi:

- 10.3389/fspas.2020.540133.
- Bakrania M R, Rae I J, Walsh A P, et al. 2020. Using dimensionality reduction and clustering techniques to classify space plasma regimes. *Frontiers in Astronomy and Space Sciences*, 7: 593516, doi: 10.3389/fspas.2020.593516.
- Bard C, Dorelli J C. 2021. Neural network reconstruction of plasma space-time. *Frontiers in Astronomy and Space Sciences*, 8: 732275, doi: 10.3389/fspas.2021.732275.
- Barkhatov N A, Vorobjev V G, Revunov S E, et al. 2020. Neural network classification of substorm geomagnetic activity caused by solar wind magnetic clouds. *Journal of Atmospheric and Solar-Terrestrial Physics*, 205: 105301, doi: 10.1016/j.jastp.2020.105301.
- Barros F S, Graça P A, Lima J J G, et al. 2024. Using Recurrent Neural Networks to improve initial conditions for a solar wind forecasting model. *Engineering Applications of Artificial Intelligence*, 133: 108266, doi: 10.1016/j.engappai.2024.108266.
- Bergstedt K, Ji H. 2024. A novel method to train classification models for structure detection in in situ spacecraft data. *Earth and Space Science*, 11(6): e2023EA002965, doi: 10.1029/2023EA002965.
- Bianco S, Haas B, Shprits Y Y. 2023. PINE-RT: An operational real-time plasmasphere model. *Frontiers in Astronomy and Space Sciences*, 10: 1116396, doi: 10.3389/fspas.2023.1116396.
- Bortnik J, Li W, Thorne R M, et al. 2016. A unified approach to inner magnetospheric state prediction. *Journal of Geophysical Research: Space Physics*, 121(3): 2423-2430, doi: 10.1002/2015JA021733.
- Bougeret J L, Pick M. 2007. Solar radio emissions. //Kamide Y, Chian A eds. Handbook of the Solar-Terrestrial Environment. Berlin: Springer, 133-151, doi: 10.1007/978-3-540-46315-3_6.
- Bouriat S, Vandame P, Barthélémy M, et al. 2022. Towards an AI-based understanding of the solar wind: A critical data analysis of ACE data. *Frontiers in Astronomy and Space Sciences*, 9: 980759, doi: 10.3389/fspas.2022.980759.
- Breiman L, Friedman J H, Olshen R A, et al. 1984. Classification and Regression Trees. New York: Chapman and Hall/CRC, doi: 10.1201/9781315139470.
- Breuillard H, Dupuis R, Retino A, et al. 2020. Automatic classification of plasma regions in near-earth space with supervised machine learning: Application to magnetospheric multi scale 2016-2019 observations. *Frontiers in Astronomy and Space Sciences*, 7: 55, doi: 10.3389/fspas.2020.00055.
- Buzulukova N, Tsurutani B. 2022. Space weather: From solar origins to risks and hazards evolving in time. *Frontiers in Astronomy and Space Sciences*, 9: 1017103, doi: 10.3389/fspas.2022.1017103.
- Cai S Z, Mao Z P, Wang Z C, et al. 2021. Physics-informed neural networks (PINNs) for fluid mechanics: A review. *Acta Mechanica Sinica*, 37(12): 1727-1738, doi: 10.1007/s10409-021-01148-1.
- Camporeale E, Carè A, Borovsky J E. 2017. Classification of solar wind with machine learning. *Journal of Geophysical Research: Space Physics*, 122(11): 10910-10920, doi: 10.1002/2017JA024383.
- Camporeale E. 2019. The challenge of machine learning in Space Weather: Nowcasting and forecasting. *Space Weather*, 17(8): 1166-1207, doi: 10.1029/2018SW002061.
- Camporeale E. 2020. ML-Helio: An emerging community at the intersection between heliophysics and machine learning. *Journal of Geophysical Research: Space Physics*, 125(2): e2019JA027502, doi: 10.1029/2019JA027502.
- Cao X, Halekas J S, Haaland S, et al. 2023. Using machine learning to characterize solar wind driving of convection in the terrestrial magnetotail lobes. *Frontiers in Astronomy and Space Sciences*, 10: 1180410, doi: 10.3389/fspas.2023.1180410.
- Cargill P J, Harra L K. 2007. Coronal mass ejection. //Kamide Y, Chian A eds. Handbook of the Solar-Terrestrial Environment. Heidelberg: Springer, 117-132, doi: 10.1007/978-3-540-46315-3_5.
- Chandorkar M, Camporeale E, Wing S. 2017. Probabilistic forecasting of the disturbance storm time index: An autoregressive Gaussian process approach. *Space Weather*, 15(8): 1004-1019, doi: 10.1002/2017SW001627.
- Chen W X, Fu S, Ma X, et al. 2024. Quantifying the spatiotemporal evolution of radiation belt electrons scattered by lower band chorus waves: An integrated model. *Space Weather*, 22(8): e2024SW003876, doi: 10.1029/2024SW003876.
- Chen Z, Liao W T, Li H M, et al. 2022. Prediction of global ionospheric TEC based on deep learning. *Space Weather*, 20(4): e2021SW002854, doi: 10.1029/2021SW002854.
- Chen Z, Tian H, Li H M, et al. 2023. The study on the global evolution of energetic electron precipitation during geomagnetic storm based on deep learning algorithm. *Journal of Geophysical Research: Space Physics*, 128(3): e2022JA030974, doi: 10.1029/2022JA030974.
- Cheng I K, Achilleos N, Smith A. 2022. Automated bow shock and magnetopause boundary detection with Cassini using threshold and deep learning methods. *Frontiers in Astronomy and Space Sciences*, 9: 1016453, doi: 10.3389/fspas.2022.1016453.
- Chu X N, Bortnik J, Li W, et al. 2017. Erosion and refilling of the plasmasphere during a geomagnetic storm modeled by a neural network. *Journal of Geophysical Research: Space Physics*, 122(7): 7118-7129, doi: 10.1002/2017JA023948.
- Chu X N, Ma D L, Bortnik J, et al. 2021. Relativistic electron model in the outer radiation belt using a neural network approach. *Space Weather*, 19(12): e2021SW002808, doi: 10.1029/2021SW002808.
- Chu X N, Bortnik J, Li W, et al. 2023. Distribution and evolution of chorus waves modeled by a neural network: The importance of imbalanced regression. *Space Weather*, 21(10): e2023SW003524, doi: 10.1029/2023SW003524.
- Chu X N, Jia L, McPherron R L, et al. 2025. Imbalanced Regression Artificial Neural Network model for auroral electrojet indices (IRANNA): Can we predict strong events?. *Space Weather*, 23(5): e2024SW004236, doi: 10.1029/2024SW004236.
- Cinto T, Gradwohl A L S, Coelho G P, et al. 2020. Solar flare forecasting using time series and extreme gradient boosting ensembles. *Solar Physics*, 295(7): 93, doi: 10.1007/s11207-020-01661-9.
- Clausen L B N, Nickisch H. 2018. Automatic classification of auroral images from the Oslo auroral themis (OATH) data set using machine learning. *Journal of Geophysical Research: Space Physics*, 123(7): 5640-5647,

- doi: [10.1029/2018ja025274](https://doi.org/10.1029/2018ja025274).
- Colak T, Qahwaji R. 2009. Automated Solar Activity Prediction: A hybrid computer platform using machine learning and solar imaging for automated prediction of solar flares. *Space Weather*, 7(6): S06001, doi: [10.1029/2008SW000401](https://doi.org/10.1029/2008SW000401).
- Collado-Villaverde A, Muñoz P, Cid C. 2024. A framework for evaluating geomagnetic indices forecasting models. *Space Weather*, 22(3): e2024SW003868, doi: [10.1029/2024SW003868](https://doi.org/10.1029/2024SW003868).
- Collier M R, Gruesbeck J R, Connerney J E P, et al. 2020. A *K*-means clustering analysis of the Jovian and terrestrial magnetopauses: A technique to classify global magnetospheric behavior. *Journal of Geophysical Research: Planets*, 125(9): e2019JE006366, doi: [10.1029/2019JE006366](https://doi.org/10.1029/2019JE006366).
- Collin D, Shprits Y, Hofmeister S J, et al. 2025. Forecasting high-speed solar wind streams from solar images. *Space Weather*, 23(1): e2024SW004125, doi: [10.1029/2024SW004125](https://doi.org/10.1029/2024SW004125).
- Conde D, Castillo F L, Escobar C, et al. 2023. Forecasting geomagnetic storm disturbances and their uncertainties using deep learning. *Space Weather*, 21(11): e2023SW003474, doi: [10.1029/2023SW003474](https://doi.org/10.1029/2023SW003474).
- Constantinescu V, Marghitu O. 2020. Neural network based identification of energy conversion regions and bursty bulk flows in cluster data. *Frontiers in Astronomy and Space Sciences*, 7: 51, doi: [10.3389/fspas.2020.00051](https://doi.org/10.3389/fspas.2020.00051).
- Coveney P V, Dougherty E R, Highfield R R. 2016. Big data need big theory too. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2080): 20160153, doi: [10.1098/rsta.2016.0153](https://doi.org/10.1098/rsta.2016.0153).
- da Silva D, Chen L J, Fuselier S, et al. 2022. Automatic identification and new observations of ion energy dispersion events in the cusp ionosphere. *Journal of Geophysical Research: Space Physics*, 127(4): e2021JA029637, doi: [10.1029/2021JA029637](https://doi.org/10.1029/2021JA029637).
- Daniell J D, Mehta P M. 2023. Probabilistic solar proxy forecasting with neural network ensembles. *Space Weather*, 21(9): e2023SW003675, doi: [10.1029/2023SW003675](https://doi.org/10.1029/2023SW003675).
- de Lima R P, Chen Y, Lin Y Z. 2020. Forecasting megaelectron-volt electrons inside Earth's outer radiation belt: PreMeVE 2.0 based on supervised machine learning algorithms. *Space Weather*, 18(2): e2019SW002399, doi: [10.1029/2019SW002399](https://doi.org/10.1029/2019SW002399).
- Denoeux T. 1995. A *k*-nearest neighbor classification rule based on Dempster-Shafer theory. *IEEE Transactions on Systems, Man, and Cybernetics*, 25(5): 804-813, doi: [10.1109/21.376493](https://doi.org/10.1109/21.376493).
- Dessler A J. 1967. Solar wind and interplanetary magnetic field. *Reviews of Geophysics*, 5(1): 1-41, doi: [10.1029/RG005i001p00001](https://doi.org/10.1029/RG005i001p00001).
- Dimmock A P, Nykyri K. 2013. The statistical mapping of magnetosheath plasma properties based on THEMIS measurements in the magnetosheath interplanetary medium reference frame. *Journal of Geophysical Research: Space Physics*, 118(8): 4963-4976, doi: [10.1002/jgra.50465](https://doi.org/10.1002/jgra.50465).
- Dmitriev A V, Suvorova A V. 2000. Three-dimensional artificial neural network model of the dayside magnetopause. *Journal of Geophysical Research: Space Physics*, 105(A8): 18909-18918, doi: [10.1029/2000JA900008](https://doi.org/10.1029/2000JA900008).
- Drozov A Y, Kondrashov D, Strounine K, et al. 2023. Reconstruction of electron radiation belts using data assimilation and machine learning. *Frontiers in Astronomy and Space Sciences*, 10: 1072795, doi: [10.3389/fspas.2023.1072795](https://doi.org/10.3389/fspas.2023.1072795).
- Dumitru D, Munteanu C. 2023. Classifying interplanetary discontinuities using supervised machine learning. *Earth and Space Science*, 10(7): e2023EA002960, doi: [10.1029/2023EA002960](https://doi.org/10.1029/2023EA002960).
- Dungey J W. 1961. Interplanetary magnetic field and the auroral zones. *Physical Review Letters*, 6(2): 47-48.
- Dupuis R, Goldman M V, Newman D L, et al. 2020. Characterizing magnetic reconnection regions using Gaussian mixture models on particle velocity distributions. *The Astrophysical Journal*, 889(1): 22, doi: [10.3847/1538-4357/ab5524](https://doi.org/10.3847/1538-4357/ab5524).
- Edmond J, Raeder J, Ferdousi B, et al. 2024. Clustering of global magnetospheric observations. *Journal of Geophysical Research: Machine Learning and Computation*, 1(4): e2024JH000221, doi: [10.1029/2024JH000221](https://doi.org/10.1029/2024JH000221).
- Farooki H, Abdullah Y, Noh S J, et al. 2024. A machine learning approach to understanding the physical properties of magnetic flux ropes in the solar wind at 1 au. *The Astrophysical Journal*, 961(1): 81, doi: [10.3847/1538-4357/ad0c52](https://doi.org/10.3847/1538-4357/ad0c52).
- Ferreira A A, Borges R A. 2021. Performance analysis of distinct feed-forward neural networks structures on the AE index prediction. //2021 IEEE Aerospace Conference (50100). Big Sky: IEEE, 1-7, doi: [10.1109/AERO50100.2021.9438504](https://doi.org/10.1109/AERO50100.2021.9438504).
- Galvez R, Fouhey D F, Jin M, et al. 2019. A machine-learning data set prepared from the NASA *Solar Dynamics Observatory* Mission. *The Astrophysical Journal Supplement Series*, 242(1): 7, doi: [10.3847/1538-4365/ab1005](https://doi.org/10.3847/1538-4365/ab1005).
- Gao Z X, Chen Y H, Ao X Z, et al. 2025. ISNet: Decomposed dynamic spatio-temporal neural network for ionospheric scintillation forecasts. *Space Weather*, 23(6): e2024SW004239, doi: [10.1029/2024SW004239](https://doi.org/10.1029/2024SW004239).
- Garton T M, Jackman C M, Smith A W, et al. 2021. Machine learning applications to Kronian magnetospheric reconnection classification. *Frontiers in Astronomy and Space Sciences*, 7: 600031, doi: [10.3389/fspas.2020.600031](https://doi.org/10.3389/fspas.2020.600031).
- Getmanov V G, Gvishiani A D, Soloviev A A, et al. 2024. A method for forecasting geomagnetic storms based on deep learning neural networks using time series of matrix observations of the Uragan muon hodoscope. *Geomagnetism and Aeronomy*, 64(5): 701-716, doi: [10.1134/S0016793224600644](https://doi.org/10.1134/S0016793224600644).
- Gowtam V S, Connor H, Kunduri B S R, et al. 2024. Calculating the high-latitude ionospheric electrodynamics using a machine learning-based field-aligned current model. *Space Weather*, 22(4): e2023SW003683, doi: [10.1029/2023SW003683](https://doi.org/10.1029/2023SW003683).
- Gruet M A, Chandorkar M, Sicard A, et al. 2018. Multiple-hour-ahead forecast of the Dst index using a combination of long short-term memory neural network and Gaussian process. *Space Weather*, 16(11): 1882-1896, doi: [10.1029/2018SW001898](https://doi.org/10.1029/2018SW001898).
- Guastavino S, Candiani V, Bemporad A, et al. 2023. Physics-driven machine

- learning for the prediction of coronal mass Ejections' travel times. *The Astrophysical Journal*, 954(2): 151, doi: [10.3847/1538-4357/ace62d](https://doi.org/10.3847/1538-4357/ace62d).
- He K, Zhang X, Ren S, et al. 2016. Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778, <https://doi.org/10.1109/CVPR.2016.90>.
- He X R, Zhong Q Z, Cui Y M, et al. 2022. Solar flare short-term forecast model based on long and short-term memory neural network. *Chinese Journal of Space Science (in Chinese)*, 42(5): 862-872, doi: [10.11728/cjss2022.05.210315028](https://doi.org/10.11728/cjss2022.05.210315028).
- Hecht M, Heidrich-Meisner V, Berger L, et al. 2023. Scope and limitations of ad hoc neural network reconstructions of solar wind parameters. *Astronomy & Astrophysics*, 678: A64, doi: [10.1051/0004-6361/202346714](https://doi.org/10.1051/0004-6361/202346714).
- Ho T K. 1995. Random decision forests. //Proceedings of the 3rd International Conference on Document Analysis and Recognition. Montreal: IEEE, 278-282.
- Hu A, Sisti M, Finelli F, et al. 2020. Identifying magnetic reconnection in 2D hybrid Vlasov Maxwell simulations with convolutional neural networks. *The Astrophysical Journal*, 900(1): 86, doi: [10.3847/1538-4357/aba527](https://doi.org/10.3847/1538-4357/aba527).
- Hu A, Shneider C, Tiwari A, et al. 2022. Probabilistic prediction of *Dst* storms one-day-ahead using full-disk SoHO images. *Space Weather*, 20(8): e2022SW003064, doi: [10.1029/2022SW003064](https://doi.org/10.1029/2022SW003064).
- Hu A, Camporeale E, Swiger B. 2023. Multi-hour-ahead *Dst* index prediction using multi-fidelity boosted neural networks. *Space Weather*, 21(4): e2022SW003286, doi: [10.1029/2022SW003286](https://doi.org/10.1029/2022SW003286).
- Hua M, Bortnik J, Ma D L. 2024. Machine-learning based identification of the critical driving factors controlling storm-time outer radiation belt electron flux dropouts. *Geophysical Research Letters*, 51(10): e2024GL108268, doi: [10.1029/2024GL108268](https://doi.org/10.1029/2024GL108268).
- Huang S, Li W, Shen X C, et al. 2022. Application of recurrent neural network to modeling Earth's global electron density. *Journal of Geophysical Research: Space Physics*, 127(9): e2022JA030695, doi: [10.1029/2022JA030695](https://doi.org/10.1029/2022JA030695).
- Huang X, Wang H N, Xu L, et al. 2018. Deep learning based solar flare forecasting model.I. Results for line-of-sight magnetograms. *The Astrophysical Journal*, 856(1): 7, doi: [10.3847/1538-4357/aaae00](https://doi.org/10.3847/1538-4357/aaae00).
- Huang X, Zhao Z R, Zhong Y F, et al. 2024. Short-term solar eruptive activity prediction models based on machine learning approaches: A review. *Science China Earth Sciences*, 67(12): 3727-3764, doi: [10.1007/s11430-023-1375-2](https://doi.org/10.1007/s11430-023-1375-2).
- Illarionov E A. 2025. Machine learning methods in solar physics. *Physics-Uspekhi*, 68(4): 374-392, doi: [10.3367/UFNe.2025.02.039872](https://doi.org/10.3367/UFNe.2025.02.039872).
- Innocenti M E, Amaya J, Raeder J, et al. 2021. Unsupervised classification of simulated magnetospheric regions. *Annales Geophysicae*, 39(5): 861-881, doi: [10.5194/angeo-39-861-2021](https://doi.org/10.5194/angeo-39-861-2021).
- Israni K, Iyer E J A, Paul N, et al. 2025. Machine learning-based comprehensive space weather monitoring and prediction system. //AIAA AVIATION Forum and ASCEND 2025. Las Vegas: AIAA.
- Jarolim R, Thalmann J K, Veronig A M, et al. 2023. Probing the solar coronal magnetic field with physics-informed neural networks. *Nature Astronomy*, 7(10): 1171-1179, doi: [10.1038/s41550-023-02030-9](https://doi.org/10.1038/s41550-023-02030-9).
- Jeong S H, Lee W K, Kil H, et al. 2024. Deep learning-based regional ionospheric total electron content prediction—Long short-term memory (LSTM) and convolutional LSTM approach. *Space Weather*, 22(1): e2023SW003763, doi: [10.1029/2023SW003763](https://doi.org/10.1029/2023SW003763).
- Jiao Z B, Sun H, Wang X T, et al. 2020. Solar flare intensity prediction with machine learning models. *Space Weather*, 18(7): e2020SW002440, doi: [10.1029/2020SW002440](https://doi.org/10.1029/2020SW002440).
- Johnson J W, Öztürk D S, Hampton D, et al. 2024. Automatic detection and classification of aurora in THEMIS all-sky images. *Journal of Geophysical Research: Machine Learning and Computation*, 1(4): e2024JH000292, doi: [10.1029/2024JH000292](https://doi.org/10.1029/2024JH000292).
- Johnson R, Boubrabimi S F, Bahri O, et al. 2022. Physics-informed neural networks for solar wind prediction. //Pattern Recognition, Computer Vision, and Image Processing. ICPR 2022 International Workshops and Challenges. Montreal: Springer, 273-286, doi: [10.1007/978-3-031-37731-0_21](https://doi.org/10.1007/978-3-031-37731-0_21).
- Johnson R, Filali Boubrabimi S, Bahri O, et al. 2024. Combining empirical and physics-based models for solar wind prediction. *Universe*, 10(5): 191, doi: [10.3390/universe10050191](https://doi.org/10.3390/universe10050191).
- Karlsson T, Raptis S, Trollvik H, et al. 2021. Classifying the magnetosheath behind the quasi-parallel and quasi-perpendicular bow shock by local measurements. *Journal of Geophysical Research: Space Physics*, 126(9): e2021JA029269, doi: [10.1029/2021ja029269](https://doi.org/10.1029/2021ja029269).
- Karniadakis G E, Kevrekidis I G, Lu L, et al. 2021. Physics-informed machine learning. *Nature Reviews Physics*, 3: 422-440, doi: [10.1038/s42254-021-00314-5](https://doi.org/10.1038/s42254-021-00314-5).
- Kasapis S, Zhao L L, Chen Y, et al. 2022. Interpretable machine learning to forecast SEP events for Solar Cycle 23. *Space Weather*, 20(2): e2021SW002842, doi: [10.1029/2021SW002842](https://doi.org/10.1029/2021SW002842).
- Kataoka R, Nakamizo A, Nakano S, et al. 2024. Machine learning-based emulator for the physics-based simulation of auroral current system. *Space Weather*, 22(1): e2023SW003720, doi: [10.1029/2023SW003720](https://doi.org/10.1029/2023SW003720).
- Killey S, Rae I J, Chakraborty S, et al. 2023. Using machine learning to diagnose relativistic electron distributions in the Van Allen radiation belts. *RAS Techniques and Instruments*, 2(1): 548-561, doi: [10.1093/rasti/rzad035](https://doi.org/10.1093/rasti/rzad035).
- Kim J H, Kwak Y S, Kim Y H, et al. 2020. Regional ionospheric parameter estimation by assimilating the LSTM trained results into the SAMI2 model. *Space Weather*, 18(10): e2020SW002590, doi: [10.1029/2020SW002590](https://doi.org/10.1029/2020SW002590).
- Kim J H, Kwak Y S, Kim Y, et al. 2021. Potential of regional ionosphere prediction using a long short-term memory deep-learning algorithm specialized for geomagnetic storm period. *Space Weather*, 19(9): e2021SW002741, doi: [10.1029/2021SW002741](https://doi.org/10.1029/2021SW002741).
- Knudsen D J, Borovsky J E, Karlsson T, et al. 2021. Editorial: Topical collection on auroral physics. *Space Science Reviews*, 217(1): 19, doi: [10.1007/s11214-021-00798-8](https://doi.org/10.1007/s11214-021-00798-8).
- Köhne S, Boella E, Innocenti M E. 2023. Unsupervised classification of fully kinetic simulations of plasmoid instability using self-organizing maps (SOMs). *Journal of Plasma Physics*, 89(3): 895890301, doi: [10.1017/S0022377823000454](https://doi.org/10.1017/S0022377823000454).

- Koller F, Raptis S, Temmer M, et al. 2024. The effect of fast solar wind on ion distribution downstream of earth's bow shock. *The Astrophysical Journal Letters*, 964(1): L5, doi: [10.3847/2041-8213/ad2ddf](https://doi.org/10.3847/2041-8213/ad2ddf).
- Koons H C, Gorney D J. 1991. A neural network model of the relativistic electron flux at geosynchronous orbit. *Journal of Geophysical Research: Space Physics*, 96(A4): 5549-5556, doi: [10.1029/90JA02380](https://doi.org/10.1029/90JA02380).
- Kumar A, Kumar V. 2024. Forecast of solar cycle 25 based on Hybrid CNN-Bidirectional-GRU (CNN-BiGRU) model and Novel Gradient Residual Correction (GRC) technique. *Advances in Space Research*, 73(8): 4342-4362, doi: [10.1016/j.asr.2024.01.019](https://doi.org/10.1016/j.asr.2024.01.019).
- Kumari P, Toshniwal D. 2021. Deep learning models for solar irradiance forecasting: A comprehensive review. *Journal of Cleaner Production*, 318: 128566, doi: [10.1016/j.jclepro.2021.128566](https://doi.org/10.1016/j.jclepro.2021.128566).
- Kvammen A, Wickström K, McKay D, et al. 2020. Auroral image classification with deep neural networks. *Journal of Geophysical Research: Space Physics*, 125(10): e2020JA027808, doi: [10.1029/2020ja027808](https://doi.org/10.1029/2020ja027808).
- Lai C S, Zhong C K, Pan K D, et al. 2021. A deep learning based hybrid method for hourly solar radiation forecasting. *Expert Systems with Applications*, 177: 114941, doi: [10.1016/j.eswa.2021.114941](https://doi.org/10.1016/j.eswa.2021.114941).
- Lalti A, Khotyaintsev Y V, Dimmock A P, et al. 2022. A database of MMS bow shock crossings compiled using machine learning. *Journal of Geophysical Research: Space Physics*, 127(8): e2022JA030454, doi: [10.1029/2022ja030454](https://doi.org/10.1029/2022ja030454).
- Lazzús J A, Vega P, Rojas P, et al. 2017. Forecasting the *Dst* index using a swarm-optimized neural network. *Space Weather*, 15(8): 1068-1089, doi: [10.1002/2017SW001608](https://doi.org/10.1002/2017SW001608).
- Legnaro E, Guastavino S, Piana M, et al. 2025. Deep learning for active region classification: A systematic study from convolutional neural networks to vision transformers. *The Astrophysical Journal*, 981(2): 157, <https://doi.org/10.3847/1538-4357/adb8c3>.
- Li H, Wang C, Peng Z. 2013. Solar wind impacts on growth phase duration and substorm intensity: A statistical approach. *Journal of Geophysical Research: Space Physics*, 118(7): 4270-4278, doi: [10.1002/jgra.50399](https://doi.org/10.1002/jgra.50399).
- Li H, Wang C, Tu C, et al. 2020. Machine learning approach for solar wind categorization. *Earth and Space Science*, 7(5): e2019EA000997, doi: [10.1029/2019EA000997](https://doi.org/10.1029/2019EA000997).
- Li J X, Bortnik J, Chu X N, et al. 2023. Modeling ring current proton fluxes using artificial neural network and Van Allen Probe measurements. *Space Weather*, 21(5): e2022SW003257, doi: [10.1029/2022SW003257](https://doi.org/10.1029/2022SW003257).
- Li L C, Liu H J, Le H J, et al. 2024. ED-AttConvLSTM: An ionospheric TEC map prediction model using adaptive weighted spatiotemporal features. *Space Weather*, 22(3): e2023SW003740, doi: [10.1029/2023SW003740](https://doi.org/10.1029/2023SW003740).
- Li S, Sun Y Y, Chen C H. 2023. An interpretable machine learning procedure which unravels hidden interplanetary drivers of the low latitude dayside magnetopause. *Space Weather*, 21(3): e2022SW003391, doi: [10.1029/2022SW003391](https://doi.org/10.1029/2022SW003391).
- Li W B, Liu L B, Chen Y D, et al. 2023. Improving the extraction ability of thermospheric mass density variations from observational data by deep learning. *Space Weather*, 21(7): e2022SW003376, doi: [10.1029/2022SW003376](https://doi.org/10.1029/2022SW003376).
- Li W B, Liu L B, Chen Y D, et al. 2024. Interplanetary influence on thermospheric mass density: Insights from deep learning analyses. *Space Weather*, 22(9): e2024SW003952, doi: [10.1029/2024SW003952](https://doi.org/10.1029/2024SW003952).
- Li Y C, Yang Y, Shen F, et al. 2024. CME arrival time prediction based on coronagraph observations and machine-learning techniques. *The Astrophysical Journal*, 976(1): 141, doi: [10.3847/1538-4357/ad82e5](https://doi.org/10.3847/1538-4357/ad82e5).
- Licata R J, Mehta P M, Weimer D R, et al. 2022. Science through machine learning: Quantification of post-storm thermospheric cooling. *Space Weather*, 20(9): e2022SW003189, doi: [10.1029/2022SW003189](https://doi.org/10.1029/2022SW003189).
- Liemohn M W, Keese A M, Kepko L, et al. 2021. Instigators of future change in magnetospheric research. //Maggiolo R, André N, Hasegawa H, et al eds. *Magnetospheres in the Solar System*. Hoboken: American Geophysical Union, 753-763, doi: [10.1002/9781119815624.ch47](https://doi.org/10.1002/9781119815624.ch47).
- Lin R, Luo Z K, He J S, et al. 2024. Prediction of solar wind speed through machine learning from extrapolated solar coronal magnetic field. *Space Weather*, 22(6): e2023SW003561, doi: [10.1029/2023SW003561](https://doi.org/10.1029/2023SW003561).
- Lin R P, Yang Y, Shen F, et al. 2024. An algorithm for the determination of coronal mass ejection kinematic parameters based on machine learning. *The Astrophysical Journal Supplement Series*, 271(2): 59, doi: [10.3847/1538-4365/ad2dea](https://doi.org/10.3847/1538-4365/ad2dea).
- Liu C, Deng N, Wang J T L, et al. 2017. Predicting solar flares using SDO/HMI vector magnetic data products and the random forest algorithm. *The Astrophysical Journal*, 843(2): 104, doi: [10.3847/1538-4357/aa789b](https://doi.org/10.3847/1538-4357/aa789b).
- Liu H, Liu C, Wang J T L, et al. 2019. Predicting solar flares using a long short-term memory network. *The Astrophysical Journal*, 877(2): 121, doi: [10.3847/1538-4357/ab1b3c](https://doi.org/10.3847/1538-4357/ab1b3c).
- Liu L, Zou S S, Yao Y B, et al. 2020. Forecasting global ionospheric TEC using deep learning approach. *Space Weather*, 18(11): e2020SW002501, doi: [10.1029/2020SW002501](https://doi.org/10.1029/2020SW002501).
- Liu S W, Wang J J, Li M, et al. 2023. A selective up-sampling method applied upon unbalanced data for flare prediction: Potential to improve model performance. *Frontiers in Astronomy and Space Sciences*, 10: 1082694, doi: [10.3389/fspas.2023.1082694](https://doi.org/10.3389/fspas.2023.1082694).
- Liu J, Zhong Z, Mao D, et al. 2024. Forecasting the *Dst* index with temporal convolutional network and integrated gradients. *Solar Physics*, 299: 98, doi: [10.1007/s11207-024-02340-9](https://doi.org/10.1007/s11207-024-02340-9).
- Lugaz N, Liu H X, Hapgood M, et al. 2021. Machine-learning research in the Space Weather journal: Prospects, scope, and limitations. *Space Weather*, 19(12): e2021SW003000, doi: [10.1029/2021SW003000](https://doi.org/10.1029/2021SW003000).
- Ma D L, Bortnik J, Chu X N, et al. 2023. Opening the black box of the radiation belt machine learning model. *Space Weather*, 21(4): e2022SW003339, doi: [10.1029/2022SW003339](https://doi.org/10.1029/2022SW003339).
- Ma D L, Bortnik J, Ma Q, et al. 2024. Machine learning interpretability of outer radiation belt enhancement and depletion events. *Geophysical Research Letters*, 51(1): e2023GL106049, doi: [10.1029/2023GL106049](https://doi.org/10.1029/2023GL106049).
- Maimaiti M, Kunduri B, Ruohoniemi J M, et al. 2019. A deep learning-based approach to forecast the onset of magnetic substorms. *Space Weather*, 17(11): 1534-1552, doi: [10.1029/2019SW002251](https://doi.org/10.1029/2019SW002251).
- Malanushenko A, Flyer N, Gibson S. 2020. Convolutional neural networks

- for predicting the strength of the near-earth magnetic field caused by interplanetary coronal mass ejections. *Frontiers in Astronomy and Space Sciences*, 7: 62, doi: [10.3389/fspas.2020.00062](https://doi.org/10.3389/fspas.2020.00062).
- Masson A, Fung S F, Camporeale E, et al. 2024. Heliophysics and space weather information architecture and innovative solutions: Current status and ways forward. *Advances in Space Research*, doi: [10.1016/j.asr.2024.05.052](https://doi.org/10.1016/j.asr.2024.05.052).
- Matamba T M, Habarulema J B. 2018. Ionospheric responses to CME- and CIR-driven geomagnetic storms along 30°E–40°E over the African sector from 2001 to 2015. *Space Weather*, 16(5): 538–556, doi: [10.1029/2017SW001754](https://doi.org/10.1029/2017SW001754).
- Mathews A, Francisquez M, Hughes J W, et al. 2021. Uncovering turbulent plasma dynamics via deep learning from partial observations. *Physical Review E*, 104(2): 025205, doi: [10.1103/PhysRevE.104.025205](https://doi.org/10.1103/PhysRevE.104.025205).
- Maulud D, Abdulazeez A M. 2020. A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(2): 140–147, doi: [10.38094/jastt1457](https://doi.org/10.38094/jastt1457).
- McCuen B A, Moldwin M B, Steinmetz E S, et al. 2023. Automated high-frequency geomagnetic disturbance classifier: A machine learning approach to identifying noise while retaining high-frequency components of the geomagnetic field. *Journal of Geophysical Research: Space Physics*, 128(2): e2022JA030842, doi: [10.1029/2022JA030842](https://doi.org/10.1029/2022JA030842).
- McGranaghan R M, Bhatt A, Matsuo T, et al. 2017. Ushering in a new frontier in geospace through data science. *Journal of Geophysical Research: Space Physics*, 122(12): 12586–12590, doi: [10.1002/2017JA024835](https://doi.org/10.1002/2017JA024835).
- McGranaghan R M, Mannucci A J, Wilson B D, et al. 2018. New capabilities for prediction of high-latitude ionospheric scintillation: A novel approach with machine learning. *Space Weather*, 16(11): 1817–1846, doi: [10.1029/2018SW002018](https://doi.org/10.1029/2018SW002018).
- McGranaghan R M, Ziegler J, Bloch T, et al. 2021. Toward a next generation particle precipitation model: Mesoscale prediction through machine learning (a case study and framework for progress). *Space Weather*, 19(6): e2020SW002684, doi: [10.1029/2020SW002684](https://doi.org/10.1029/2020SW002684).
- Moreland K, Dayeh M A, Bain H M, et al. 2024. MEMPSEP-III.A machine learning-oriented multivariate data set for forecasting the occurrence and properties of solar energetic particle events using a multivariate ensemble approach. *Space Weather*, 22(9): e2023SW003765, doi: [10.1029/2023SW003765](https://doi.org/10.1029/2023SW003765).
- Moschou S P, Hicks E, Parekh R Y, et al. 2023. Physics-informed neural networks for modeling astrophysical shocks. *Machine Learning: Science and Technology*, 4(3): 035032, doi: [10.1088/2632-2153/acf116](https://doi.org/10.1088/2632-2153/acf116).
- Nair M, Redmon R, Young L Y, et al. 2023. MagNet—A data-science competition to predict disturbance storm-time index (*Dst*) from solar wind data. *Space Weather*, 21(10): e2023SW003514, doi: [10.1029/2023SW003514](https://doi.org/10.1029/2023SW003514).
- Nakano S, Kataoka R. 2022. Echo state network model for analyzing solar-wind effects on the AU and AL indices. *Annales Geophysicae*, 40(1): 11–22, doi: [10.5194/angeo-40-11-2022](https://doi.org/10.5194/angeo-40-11-2022).
- Nanjo S, Nozawa S, Yamamoto M, et al. 2022. An automated auroral detection system using deep learning: Real-time operation in Tromsø, Norway. *Scientific Reports*, 12(1): 8038, doi: [10.1038/s41598-022-11686-8](https://doi.org/10.1038/s41598-022-11686-8).
- Narock T, Pal S, Arsham A, et al. 2024. Classifying different types of solar-wind plasma with uncertainty estimations using machine learning. *Solar Physics*, 299(9): 131, doi: [10.1007/s11207-024-02379-8](https://doi.org/10.1007/s11207-024-02379-8).
- Nevskii D V, Lavrukhin A S, Alexeev I I. 2023. Automatic detection of bow shock and magnetopause positions at Mercury's magnetosphere using MESSENGER magnetometer data. *Cosmic Research*, 61(3): 194–205, doi: [10.1134/S0010952522600081](https://doi.org/10.1134/S0010952522600081).
- Nguyen G, Aunai N, Fontaine D, et al. 2019. Automatic detection of interplanetary coronal mass ejections from in situ data: A deep learning approach. *The Astrophysical Journal*, 874(2): 145, doi: [10.3847/1538-4357/ab0d24](https://doi.org/10.3847/1538-4357/ab0d24).
- Nguyen G, Aunai N, de Welle B M, et al. 2022. Massive multi-mission statistical study and analytical modeling of the Earth's magnetopause: 1. A gradient boosting based automatic detection of near-Earth regions. *Journal of Geophysical Research: Space Physics*, 127(1): e2021JA029773, doi: [10.1029/2021JA029773](https://doi.org/10.1029/2021JA029773).
- Niu C, Yang Q J, Ren S, et al. 2019. Instance segmentation of auroral images for automatic computation of arc width. *IEEE Geoscience and Remote Sensing Letters*, 16(9): 1368–1372, doi: [10.1109/lgrs.2019.2901803](https://doi.org/10.1109/lgrs.2019.2901803).
- O'Brien C, Walsh B M, Zou Y, et al. 2024. PRIME-SH: A data-driven probabilistic model of Earth's magnetosheath. *Journal of Geophysical Research: Machine Learning and Computation*, 1(3): e2024JH000235, doi: [10.1029/2024JH000235](https://doi.org/10.1029/2024JH000235).
- Oliveira D M, Allen R C, Alves L R, et al. 2024. Predicting interplanetary shock occurrence for solar cycle 25: Opportunities and challenges in space weather research. *Space Weather*, 22(8): e2024SW003964, doi: [10.1029/2024SW003964](https://doi.org/10.1029/2024SW003964).
- Olshesky V, Khotyaintsev Y V, Lalti A, et al. 2021. Automated classification of plasma regions using 3D particle energy distributions. *Journal of Geophysical Research: Space Physics*, 126(10): e2021JA029620, doi: [10.1029/2021JA029620](https://doi.org/10.1029/2021JA029620).
- Pankratius V, Li J, Gowanlock M, et al. 2016. Computer-aided discovery: Toward scientific insight generation with machine support. *IEEE Intelligent Systems*, 31(4): 3–10, doi: [10.1109/MIS.2016.60](https://doi.org/10.1109/MIS.2016.60).
- Pinto V A, Keesee A M, Coughlan M, et al. 2022. Revisiting the ground magnetic field perturbations challenge: A machine learning perspective. *Frontiers in Astronomy and Space Sciences*, 9: 869740, doi: [10.3389/fspas.2022.869740](https://doi.org/10.3389/fspas.2022.869740).
- Poduval B, Pitman K M, Verkhoglyadova O, et al. 2023a. Applications of statistical methods and machine learning in the space sciences. Lausanne: Frontiers Media SA, doi: [10.3389/978-2-83252-058-1](https://doi.org/10.3389/978-2-83252-058-1).
- Poduval B, McPherron R L, Walker R, et al. 2023b. AI-ready data in space science and solar physics: Problems, mitigation and action plan. *Frontiers in Astronomy and Space Sciences*, 10: 1203598, doi: [10.3389/fspas.2023.1203598](https://doi.org/10.3389/fspas.2023.1203598).
- Priyadarshi S, Yang J, Sun W Q. 2021. Modeling and prediction of near-earth plasma sheet parameters using the rice convection model and the recurrent neural network. *Frontiers in Astronomy and Space Sciences*, 8: 691000, doi: [10.3389/fspas.2021.691000](https://doi.org/10.3389/fspas.2021.691000).

- Qahwaji R, Colak T, Al-Omari M, et al. 2008. Automated prediction of CMEs using machine learning of CME-flare associations. *Solar Physics*, 248(2): 471-483, doi: [10.1007/s11207-007-9108-1](#).
- Qian Y D, Yang J W, Zhang H, et al. 2020. An hourly prediction model of relativistic electrons based on empirical mode decomposition. *Space Weather*, 18(8): e2018SW0022078, doi: [10.1029/2018SW002078](#).
- Raju H, Das S. 2021. CNN-based deep learning model for solar wind forecasting. *Solar Physics*, 296(9): 134, doi: [10.1007/s11207-021-01874-6](#).
- Raptis S, Aminalragia-Giamini S, Karlsson T, et al. 2020. Classification of magnetosheath jets using neural networks and high resolution OMNI (HRO) data. *Frontiers in Astronomy and Space Sciences*, 7: 24, doi: [10.3389/fspas.2020.00024](#).
- Ren X C, Zhao B Q, Ren Z P, et al. 2024. Deep learning-based prediction of global ionospheric TEC during storm periods: Mixed CNN-BiLSTM method. *Space Weather*, 22(7): e2024SW003877, doi: [10.1029/2024SW003877](#).
- Ren X D, Yang P X, Mei D K, et al. 2023. Global ionospheric TEC forecasting for geomagnetic storm time using a deep learning-based multi-model ensemble method. *Space Weather*, 21(3): e2022SW003231, doi: [10.1029/2022SW003231](#).
- Roberts D A, Karimabadi H, Sipes T, et al. 2020. Objectively determining states of the solar wind using machine learning. *The Astrophysical Journal*, 889(2): 153, doi: [10.3847/1538-4357/ab5a7a](#).
- Ronneberger O, Fischer P, Brox T. 2015. U-Net: Convolutional networks for biomedical image segmentation. //18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 234-241.
- Rosofsky S G, Huerta E A. 2023. Magnetohydrodynamics with physics informed neural operators. *Machine Learning: Science and Technology*, 4(3): 035002, doi: [10.1088/2632-2153/ace30a](#).
- Sado P, Clausen L B N, Miloch W J, et al. 2022. Transfer learning aurora image classification and magnetic disturbance evaluation. *Journal of Geophysical Research: Space Physics*, 127(1): e2021JA029683, doi: [10.1029/2021ja029683](#).
- Sado P, Clausen L B N, Miloch W J, et al. 2023. Substorm onset prediction using machine learning classified auroral images. *Space Weather*, 21(2): e2022SW003300, doi: [10.1029/2022sw003300](#).
- Shen B, Marena M, Li C Y, et al. 2024. Deep computer vision for solar physics big data: Opportunities and challenges. //Proceedings of the IEEE International Conference on Big Data. Washington: IEEE, 1860-1864.
- Sherstinsky A. 2020. Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404: 132306, doi: [10.1016/j.physd.2019.132306](#).
- Shi S S, Zhang K F, Wu S Q, et al. 2022. An investigation of ionospheric TEC prediction maps over China using bidirectional long short-term memory method. *Space Weather*, 20(6): e2022SW003103, doi: [10.1029/2022SW003103](#).
- Shi Y F, Yang C, Wang J, et al. 2023. A hybrid deep learning-based forecasting model for the peak height of ionospheric F2 layer. *Space Weather*, 21(10): e2023SW003581, doi: [10.1029/2023SW003581](#).
- Shi Y R, Chen Y H, Liu S Q, et al. 2021. Predicting the CME arrival time based on the recommendation algorithm. *Research in Astronomy and Astrophysics*, 21(8): 190, doi: [10.1088/1674-4527/21/8/190](#).
- Shi Y R, Wang J J, Chen Y H, et al. 2022. Impacts of CMEs on Earth based on logistic regression and recommendation algorithm. *Space: Science & Technology*, 2022: 9852185, doi: [10.34133/2022/9852185](#).
- Shih C Y, Lin C Y T, Lin S Y, et al. 2024. Forecasting of global ionosphere maps with multi-day lead time using Transformer-based neural networks. *Space Weather*, 22(2): e2023SW003579, doi: [10.1029/2023SW003579](#).
- Shin D K, Lee D Y, Kim K C, et al. 2016. Artificial neural network prediction model for geosynchronous electron fluxes: Dependence on satellite position and particle energy. *Space Weather*, 14(4): 313-321, doi: [10.1002/2015SW001359](#).
- Siciliano F, Consolini G, Tozzi R, et al. 2020. Forecasting SYM-H index: A comparison between long short-term memory and convolutional neural networks. *Space Weather*, 19(2): e2020SW002589, doi: [10.1029/2020SW002589](#).
- Siddique T, Mahmud M S. 2022. Ensemble deep learning models for prediction and uncertainty quantification of ground magnetic perturbation. *Frontiers in Astronomy and Space Sciences*, 9: 1031407, doi: [10.3389/fspas.2022.1031407](#).
- Sisti M, Finelli F, Pedrazzi G, et al. 2021. Detecting reconnection events in kinetic Vlasov hybrid simulations using clustering techniques. *The Astrophysical Journal*, 908(1): 107, doi: [10.3847/1538-4357/abd24b](#).
- Sitnov M, Stephens G, Motoba T, et al. 2021. Data mining reconstruction of magnetotail reconnection and implications for its first-principle modeling. *Frontiers in Physics*, 9: 644884, doi: [10.3389/fphy.2021.644884](#).
- Smirnov A G, Berrendorf M, Shprits Y Y, et al. 2020. Medium energy electron flux in earth's outer radiation belt (MERLIN): A machine learning model. *Space Weather*, 18(11): e2020SW002532, doi: [10.1029/2020SW002532](#).
- Smith A W, Rae I J, Forsyth C, et al. 2020. Probabilistic forecasts of storm sudden commencements from interplanetary shocks using machine learning. *Space Weather*, 18(11): e2020SW002603, doi: [10.1029/2020SW002603](#).
- Staples F, Kellerman A, Green J. 2024. On the performance of a real-time electron radiation belt specification model. *Space Weather*, 22(12): e2024SW003950, doi: [10.1029/2024SW003950](#).
- Stephens G K, Sitnov M I. 2021. Concurrent empirical magnetic reconstruction of storm and substorm spatial scales using data mining and virtual spacecraft. *Frontiers in Physics*, 9: 653111, doi: [10.3389/fphy.2021.653111](#).
- Stephens G K, Sitnov M I, Weigel R S, et al. 2023. Global structure of magnetotail reconnection revealed by mining space magnetometer data. *Journal of Geophysical Research: Space Physics*, 128(2): e2022JA031066, doi: [10.1029/2022JA031066](#).
- Stringer G A, Heuten I, Salazar C, et al. 1996. Artificial Neural Network (ANN) forecasting of energetic electrons at geosynchronous orbit. //Lemaire J F, Heynderickx D, Baker D N eds. Radiation Belts: Models and Standards. Washington: American Geophysical Union, 291-295,

- doi: [10.1029/GM097p0291](https://doi.org/10.1029/GM097p0291).
- Stumpo M, Benella S, Laurenza M, et al. 2021. Open issues in statistical forecasting of solar proton events: A machine learning perspective. *Space Weather*, 19(10): e2021SW002794, doi: [10.1029/2021SW002794](https://doi.org/10.1029/2021SW002794).
- Sun S J, Ban P P, Chen C, et al. 2011. Low-latitude storm time ionospheric predictions using support vector machines. *Advances in Space Research*, 47(12): 2194-2198, doi: [10.1016/j.asr.2010.10.014](https://doi.org/10.1016/j.asr.2010.10.014).
- Sun X J, Lin R L, Liu S Q, et al. 2023. Prediction models of ≥ 2 MeV electron daily fluences for 3 days at GEO orbit using a long short-term memory network. *Remote Sensing*, 15(10): 2538, doi: [10.3390/rs15102538](https://doi.org/10.3390/rs15102538).
- Suthaharan S. 2016. Machine learning models and algorithms for big data classification: Thinking with examples for effective learning. Springer Science + Business Media. <https://doi.org/10.1007/978-1-4899-7641-3>.
- Swiger B M, Liemohn M W, Ganushkina N Y. 2020. Improvement of plasma sheet neural network accuracy with inclusion of physical information. *Frontiers in Astronomy and Space Sciences*, 7: 42, doi: [10.3389/fspas.2020.00042](https://doi.org/10.3389/fspas.2020.00042).
- Tan Y, Hu Q H, Wang Z, et al. 2018. Geomagnetic index Kp forecasting with LSTM. *Space Weather*, 16(4): 406-416, doi: [10.1002/2017SW001764](https://doi.org/10.1002/2017SW001764).
- Tang R X, Wang Z H, Li H M, et al. 2023. The study on modeling of global plasmaspheric hiss amplitude based on deep learning algorithm. *Space Weather*, 21(3): e2022SW003342, doi: [10.1029/2022SW003342](https://doi.org/10.1029/2022SW003342).
- Temmer M, Scolini C, Richardson I G, et al. 2023. CME propagation through the heliosphere: Status and future of observations and model development. *Advances in Space Research*, 72(6): 1548-1592, doi: [10.1016/j.asr.2023.07.003](https://doi.org/10.1016/j.asr.2023.07.003).
- Tian P H, Yu B K, Ye H L, et al. 2024. Deep learning insights into ionospheric Sporadic E irregularities under different solar activity conditions. *Journal of Geophysical Research: Machine Learning and Computation*, 1(4): e2024JH000279, doi: [10.1029/2024JH000279](https://doi.org/10.1029/2024JH000279).
- Tiwari A K, Tremblay B, Hu A, et al. 2020. SEARCH: SEgmentation of poLAR Coronal Holes. 34th Conference on Neural Information Processing Systems (NeurIPS), Third Workshop on Machine Learning and the Physical Sciences. <https://doi.org/10.5281/zenodo.4566697>.
- Toy-Edens V, Mo W L, Raptis S, et al. 2024. Classifying 8 years of MMS dayside plasma regions via unsupervised machine learning. *Journal of Geophysical Research: Space Physics*, 129(6): e2024JA032431, doi: [10.1029/2024JA032431](https://doi.org/10.1029/2024JA032431).
- Turner D L, Li X L. 2008. Quantitative forecast of relativistic electron flux at geosynchronous orbit based on low-energy electron flux. *Space Weather*, 6(5): S05005, doi: [10.1029/2007SW000354](https://doi.org/10.1029/2007SW000354).
- Upendran V, Cheung M C M, Hanasoge S, et al. 2020. Solar wind prediction using deep learning. *Space Weather*, 18(9): e2020SW002478, doi: [10.1029/2020SW002478](https://doi.org/10.1029/2020SW002478).
- Upendran V, Tigas P, Ferdousi B, et al. 2022. Global geomagnetic perturbation forecasting using deep learning. *Space Weather*, 20(6): e2022SW003045, doi: [10.1029/2022SW003045](https://doi.org/10.1029/2022SW003045).
- Wang J J, Zhang Y H, Hess Webber S A, et al. 2020. Solar flare predictive features derived from polarity inversion line masks in active regions using an unsupervised machine learning algorithm. *The Astrophysical Journal*, 892(2): 140, doi: [10.3847/1538-4357/ab7b6c](https://doi.org/10.3847/1538-4357/ab7b6c).
- Wang J J, Luo B X, Liu S Q, et al. 2023. A machine learning-based model for the next 3-day geomagnetic index (Kp) forecast. *Frontiers in Astronomy and Space Sciences*, 10: 1082737, doi: [10.3389/fspas.2023.1082737](https://doi.org/10.3389/fspas.2023.1082737).
- Wang J Q, Wang R C, Li D L, et al. 2024. OESA-UNet: An adaptive and attentional network for detecting diverse magnetopause under the limited field of view. *Remote Sensing*, 16(6): 994, doi: [10.3390/rs16060994](https://doi.org/10.3390/rs16060994).
- Wang J Y, Liu X, Dai F Z, et al. 2025a. Automated plasma region classification and boundary layer identification using machine learning. *Remote Sensing*, 17(9): 1565, doi: [10.3390/rs17091565](https://doi.org/10.3390/rs17091565).
- Wang J Y, Liu X, Dai F Z, et al. 2025b. Velocity and magnetic fluctuations across machine learning defined regions of the magnetotail plasma sheet. *Journal of Geophysical Research: Space Physics*, 130(8): e2025JA034259, doi: [10.1029/2025JA034259](https://doi.org/10.1029/2025JA034259).
- Wang R Y, Wang J H, Liang T, et al. 2024. Short-term prediction of the Dst index and estimation of efficient uncertainty using a hybrid deep learning network. *Space Weather*, 22(12): e2024SW004002, doi: [10.1029/2024SW004002](https://doi.org/10.1029/2024SW004002).
- Wang T Y, Luo B X, Chen Y H, et al. 2024. Modeling next 3-day Kp index forecasting with neural networks and exploring the application of explainable AI. *Chinese Journal of Space Science (in Chinese)*, 44(3): 437-445, doi: [10.11728/cjss2024.03.2023-0107](https://doi.org/10.11728/cjss2024.03.2023-0107).
- Wang T Y, Luo B X, Wang J J, et al. 2025. Forecasting of the geomagnetic activity for the next 3 days utilizing neural networks based on parameters related to large-scale structures of the solar corona. *Space Weather*, 23(2): e2024SW004090, doi: [10.1029/2024SW004090](https://doi.org/10.1029/2024SW004090).
- Wang Z, Zhan M Y, Gao P D, et al. 2023. Automatic detection and classification of Spread-F from Ionosonde at Hainan with image-based deep learning method. *Space Weather*, 21(11): e2023SW003498, doi: [10.1029/2023SW003498](https://doi.org/10.1029/2023SW003498).
- Waters C L, Eastwood J P, Fargette N, et al. 2024. Classifying magnetic reconnection regions using k -means clustering: Applications to energy partition. *Journal of Geophysical Research: Space Physics*, 129(10): e2024JA033010, doi: [10.1029/2024JA033010](https://doi.org/10.1029/2024JA033010).
- Wei L H, Zhong Q Z, Lin R L, et al. 2018. Quantitative prediction of high-energy electron integral flux at geostationary orbit based on deep learning. *Space Weather*, 16(7): 903-916, doi: [10.1029/2018SW001829](https://doi.org/10.1029/2018SW001829).
- Wheatland M S. 2023. Real-time solar coronal modelling. *Nature Astronomy*, 7(10): 1150-1151, doi: [10.1038/s41550-023-02085-8](https://doi.org/10.1038/s41550-023-02085-8).
- Whitman K, Egeland R, Richardson I G, et al. 2023. Review of solar energetic particle prediction models. *Advances in Space Research*, 72(12): 5161-5242, doi: [10.1016/j.asr.2022.08.006](https://doi.org/10.1016/j.asr.2022.08.006).
- Wik M, Pirjola R, Lundstedt H, et al. 2009. Space weather events in July 1982 and October 2003 and the effects of geomagnetically induced currents on Swedish technical systems. *Annales Geophysicae*, 27(4): 1775-1787, doi: [10.5194/angeo-27-1775-2009](https://doi.org/10.5194/angeo-27-1775-2009).
- Wu J G, Lundstedt H. 1997. Geomagnetic storm predictions from solar wind data with the use of dynamic neural networks. *Journal of Geophysical Research: Space Physics*, 102(A7): 14255-14268, doi: [10.1029/1029-1029](https://doi.org/10.1029/1029-1029).

97JA00975.

- Wu J L, Xiao H, Paterson E. 2018. Physics-informed machine learning approach for augmenting turbulence models: A comprehensive framework. *Physical Review Fluids*, 3(7): 074602, doi: [10.1103/physrevfluids.3](https://doi.org/10.1103/physrevfluids.3).
- Xiang Z, Li X L, Kapali S, et al. 2021. Modeling the dynamics of radiation belt electrons with source and loss driven by the solar wind. *Journal of Geophysical Research: Space Physics*, 126(6): e2020JA028988, doi: [10.1029/2020JA028988](https://doi.org/10.1029/2020JA028988).
- Xu B Y, Huang W Q, Ren P, et al. 2024. Modeling and forecasting ionospheric foF2 variation based on CNN-BiLSTM-TPA during low-and high-solar activity years. *Remote Sensing*, 16(17): 3249, doi: [10.3390/rs16173249](https://doi.org/10.3390/rs16173249).
- Yan S N, Cui Y M, Luo B X, et al. 2025. Research on $F_{10.7}$ index prediction based on factor decomposition and feature enhancement. *The Astrophysical Journal Supplement Series*, 276(1): 28, doi: [10.3847/1538-4365/ad90a2](https://doi.org/10.3847/1538-4365/ad90a2).
- Yan Y, Xie Z K, Yue C, et al. 2025. Storm-time ring current plasma pressure prediction based on the multi-output convolutional neural network model. *Space Weather*, 23(1): e2024SW003947, doi: [10.1029/2024SW003947](https://doi.org/10.1029/2024SW003947).
- Yang Q J, Xie M H, Su H, et al. 2024. Statistical characteristics of multi-scale auroral arc width based on machine learning. *Journal of Geophysical Research: Space Physics*, 129(1): e2023JA031954, doi: [10.1029/2023JA031954](https://doi.org/10.1029/2023JA031954).
- Yang Y, Shen F, Yang Z C, et al. 2018. Prediction of solar wind speed at 1 AU using an artificial neural network. *Space Weather*, 16(9): 1227-1244, doi: [10.1029/2018SW001955](https://doi.org/10.1029/2018SW001955).
- Yang Y, Shen F. 2019. Modeling the global distribution of solar wind parameters on the source surface using multiple observations and the artificial neural network technique. *Solar Physics*, 294(8): 111, doi: [10.1007/s11207-019-1496-5](https://doi.org/10.1007/s11207-019-1496-5).
- Yang Y, Shen F. 2021. Three-dimensional MHD modeling of interplanetary solar wind using self-consistent boundary condition obtained from multiple observations and machine learning. *Universe*, 7(10): 371, doi: [10.3390/universe7100371](https://doi.org/10.3390/universe7100371).
- Yang Y, Shen F. 2022. Predict the amplitude of recurrent geomagnetic disturbance using NARX neural network. //Jia Y M, Zhang W C, Fu Y L, et al eds. Proceedings of 2021 Chinese Intelligent Systems Conference. Singapore: Springer, 1-9, doi: [10.1007/978-981-16-6320-8_1](https://doi.org/10.1007/978-981-16-6320-8_1).
- Yang Y, Ni Y W, Chen P F, et al. 2025. Predicting solar flares using a convolutional neural network with extreme-ultraviolet images. *The Astrophysical Journal*, 985(1): 104, doi: [10.3847/1538-4357/adc88e](https://doi.org/10.3847/1538-4357/adc88e).
- Yeakel K L, Vandegriff J D, Garton T M, et al. 2022. Classification of Cassini's orbit regions as magnetosphere, magnetosheath, and solar wind via machine learning. *Frontiers in Astronomy and Space Sciences*, 9: 875985, doi: [10.3389/fspas.2022.875985](https://doi.org/10.3389/fspas.2022.875985).
- Yu Y Q, Koller J, Jordanova V K, et al. 2014. Application and testing of the L^* neural network with the self-consistent magnetic field model of RAM-SCB. *Journal of Geophysical Research: Space Physics*, 119(3): 1683-1692, doi: [10.1002/2013JA019350](https://doi.org/10.1002/2013JA019350).
- Yue C, Wang C P, Lyons L, et al. 2015. A 2-D empirical plasma sheet pressure model for substorm growth phase using the Support Vector Regression Machine. *Journal of Geophysical Research: Space Physics*, 120(3): 1957-1973, doi: [10.1002/2014JA020787](https://doi.org/10.1002/2014JA020787).
- Zewdie G K, Valladares C, Cohen M B, et al. 2021. Data-driven forecasting of low-latitude ionospheric total electron content using the random forest and LSTM machine learning methods. *Space Weather*, 19(6): e2020SW002639, doi: [10.1029/2020SW002639](https://doi.org/10.1029/2020SW002639).
- Zhang H, Xu H R, Peng G S, et al. 2022. A prediction model of relativistic electrons at geostationary orbit using the EMD-LSTM network and geomagnetic indices. *Space Weather*, 20(10): e2022SW003126, doi: [10.1029/2022SW003126](https://doi.org/10.1029/2022SW003126).
- Zhang H Y, Jing J, Wang J T L, et al. 2025. Prediction of halo coronal mass ejections using SDO/HMI vector magnetic data products and a transformer model. *The Astrophysical Journal*, 981(1): 37, doi: [10.3847/1538-4357/adafa0](https://doi.org/10.3847/1538-4357/adafa0).
- Zhelavskaya I S, Shprits Y Y, Spasojević M. 2017. Empirical modeling of the plasmasphere dynamics using neural networks. *Journal of Geophysical Research: Space Physics*, 122(11): 11227-11244, doi: [10.1002/2017JA024406](https://doi.org/10.1002/2017JA024406).
- Zhelavskaya I S, Aseev N A, Shprits Y Y. 2021. A combined neural network- and physics-based approach for modeling plasmasphere dynamics. *Journal of Geophysical Research: Space Physics*, 126(3): e2020JA028077, doi: [10.1029/2020JA028077](https://doi.org/10.1029/2020JA028077).
- Zheng Y F, Qin W S, Li X B, et al. 2023. Comparative analysis of machine learning models for solar flare prediction. *Astrophysics and Space Science*, 368(7): 53, doi: [10.1007/s10509-023-04209-y](https://doi.org/10.1007/s10509-023-04209-y).
- Zhong Y F, Ye R C, Liu T T, et al. 2020. Automatic aurora image classification framework based on deep learning for occurrence distribution analysis: A case study of all-sky image data sets from the Yellow River Station. *Journal of Geophysical Research: Space Physics*, 125(9): e2019JA027590, doi: [10.1029/2019JA027590](https://doi.org/10.1029/2019JA027590).

附中文参考文献

- 何欣燃, 钟秋珍, 崔延美等. 2022. 基于长短期记忆神经网络的太阳耀斑短期预报. *空间科学学报*, 42(5): 862-872, doi: [10.11728/cjss2022.05.210315028](https://doi.org/10.11728/cjss2022.05.210315028).
- 王听雨, 罗冰显, 陈艳红等. 2024. 基于神经网络的未来 3 天 Kp 指数预报建模与可解释 AI 应用. *空间科学学报*, 44(3): 437-445, <https://doi.org/10.11728/cjss2024.03.2023-0107>.

(本文编辑 何燕)