

ZHONG Jia, ZOU Ziming, WU Kun, XU Jiyao, LU Yang, SUN Longchang, YUAN Wei. Evolution Prediction Model of Equatorial Plasma Bubbles Based on SimVP (in Chinese). *Chinese Journal of Space Science*, 2026, **46**(2): 265–280. CSTR:32142.14.cjss.2025–0046. DOI:10.11728/cjss2026.02.2025–0046

基于 SimVP 的赤道等离子体泡演化预测模型*

钟佳^{1,2,3} 邹自明^{1,3} 吴坤⁴ 徐寄遥¹
陆阳^{1,3} 孙龙昌¹ 袁韦¹

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

3(中国科学院国家空间科学数据中心 北京 101407)

4(长沙理工大学物理与电子科学学院 长沙 410114)

摘要 赤道等离子体泡是日落后低纬电离层中形成的低电子密度空腔结构, 其演化过程会导致无线电信号闪烁与衰减. 对赤道等离子体泡的演化进行精准预测, 在空间天气研究及卫星通信领域意义重大. 提出一个基于 SimVP (Simpler yet Better Video Prediction) 框架的 EPB 演化预测模型, 通过曲靖站历史气辉观测图像学习 EPB 时空演化特征, 实现对未来演化的精准预测, 通过系统实验分析了关键参数对模型性能的影响. 结果表明, 时间分辨率设为 3 min, 采用 6 帧输入图和 6 帧输出图的架构时模型性能最优 (结构相似度为 0.989, 峰值信噪比为 34.704). 实验显示, EPB 空间形态复杂度对预测精度影响显著, 而光污染干扰相对有限. 提出的模型具有较好的跨台站应用鲁棒性, 该模型不仅为 EPB 演化提供了数据驱动的高效预测工具, 还可为受污染气辉观测数据的修复提供技术支撑.

关键词 赤道等离子体泡, 视频预测, SimVP, 时空依赖性

中图分类号 P352

Evolution Prediction Model of Equatorial Plasma Bubbles Based on SimVP

ZHONG Jia^{1,2,3} ZOU Ziming^{1,3} WU Kun⁴ XU Jiyao¹
LU Yang^{1,3} SUN Longchang¹ YUAN Wei¹

1(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

2(University of Chinese Academy of Sciences, Beijing 100049)

3(National Space Science Data Center, Chinese Academy of Sciences, Beijing 101407)

4(School of Physics and Electronic Science, Changsha University of Science and Technology, Changsha 410114)

* 国家重点研发计划项目 (2022YFF0711400), 中国科学院“十四五”网络安全和信息化规划项目 (CAS-WX2022SDC-XK15, CAS-WX2022SF-0103) 和中国科协青年人才托举工程项目 (2021QNRC001) 共同资助

2025-03-31 收到原稿, 2025-05-05 收到修定稿

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

Abstract Equatorial Plasma Bubbles (EPBs) are large-scale depletion structures characterized by significantly reduced electron density, which frequently emerge in the low-latitude ionosphere during post-sunset hours. These dynamic plasma irregularities play a crucial role in space weather phenomena, as their evolution can induce severe amplitude and phase scintillations in radio signals, leading to disruptions in satellite communications, global navigation systems, and radar operations. Given their substantial impact on technological systems, accurate prediction of EPB evolution has become a critical challenge in both space physics research and operational space weather forecasting. To address this challenge, this study introduces a novel data-driven approach for EPB evolution prediction by leveraging the SimVP (Simpler yet Better Video Prediction) framework, an advanced deep learning architecture designed for spatiotemporal sequence forecasting. The proposed model learns the complex nonlinear dynamics of EPB structures from historical airglow image sequences, capturing both their morphological transformations and drift patterns. Through extensive experimentation, we systematically evaluate the influence of key parameters—including time resolution, input/output sequence length, and environmental noise—on prediction performance. Our findings demonstrate that an optimal configuration with a 3 min temporal resolution and a 6-frame input/output structure achieves superior predictive accuracy, as evidenced by high Structural Similarity (SSIM=0.989) and Peak Signal-to-Noise Ratio (PSNR=34.704) metrics. Further analysis reveals that the spatial complexity of EPB structures, such as bifurcation events and irregular boundary deformations, significantly affects prediction fidelity, whereas the impact of light pollution—a common issue in ground-based airglow observations—is comparatively minor. The model proposed in this paper demonstrates robust cross-station applicability. Beyond forecasting, the model also exhibits potential for reconstructing corrupted airglow data, offering a computational solution to enhance observational datasets affected by atmospheric or instrumental noise. This work not only establishes a robust, machine learning-based tool for EPB evolution analysis but also contributes to the broader development of Artificial Intelligence (AI) applications in space weather modeling and ionospheric research.

Key words Equatorial Plasma Bubble (EPB), Video prediction, SimVP, Spatiotemporal dependency

0 引言

赤道等离子体泡 (Equatorial Plasma Bubbles, EPBs) 是夜间赤道电离层 F 区由瑞利-泰勒不稳定性触发的低密度等离子体空腔结构^[1]. 其演化过程会导致无线电信号闪烁与衰减, 严重威胁卫星通信与导航系统的可靠性^[2]. 因此, 预测赤道等离子体泡的发生和演化规律对通信和导航具有重要的应用价值.

EPB 受电离层背景电导率、中性风场等多种因素调控, 通常沿地磁场磁力线延伸, 呈现自东向西漂移、分叉、融合等复杂动态特征^[3,4], 且形态多变 (例如波状结构、C 形结构), 理论预测难度极高^[5]. 目前, 针对 EPB 的预测研究主要分为三类: 早期基于经典物理理论的方法、基于观测数据的统计分析和近年来基于机器学习与人工智能的方法. 经典物理理论建模方面, 例如 Sultan^[6] 提出了基于瑞利-泰勒不稳定性的线性增长率模型, 用于预测 EPBs 的发生条件. Rette-

rer^[7] 利用三维电离层模型模拟等离子体泡的演化, 并探讨其对闪烁的预测能力. Huba 和 Joyce^[8] 开发的三维电离层模拟程序 SAMI3 被用于对赤道扩展 F 层 (ESF) 的起始和演化进行建模. 基于观测数据的统计分析方面, 例如 Aarons^[9] 总结了 EPBs 的全球分布特征及其与闪烁的关联. Su 等^[10] 利用中华卫星一号 (ROCSAT-1) 观测数据统计分析了全球赤道密度不规则体发生率的月变化、季节变化和经度变化特征. Wu 等^[4] 对中国区域分叉 EPB 的发生率进行了统计分析. 机器学习方法预测 EPB 方面: Reddy 等^[11] 利用 Swarm 卫星观测数据开发了基于集成学习的方法, 预测电离层等离子体泡发生率的模型——APE, 该模型技巧得分、关联得分和均方根误差得分分别为 0.96, 0.98 和 0.08. Githio 等^[12] 利用全天空辉观测数据和 GNSS 观测数据, 开发了基于机器学习的方法, 估计赤道等离子体泡的漂移速度. Zhao 等^[13] 以数字测高仪和 GNSS 观测数据为预报因子, 开发了基

于卷积神经网络和长短期记忆网络 (LSTM) 的 EPB 发生率的短期预测模型。

基于物理模型的方法 (例如二维和三维数值模型) 计算成本高, 多针对特定案例。基于统计分析的方法, 虽能揭示气候学规律, 但缺乏实时预测能力。基于机器学习的方法主要聚焦于 EPB 发生率及单一参数预测, 而针对其动态演化过程的预测研究仍较为匮乏, 亟待深入探索。

针对上述局限性, 本文提出基于纯数据驱动的 EPB 演化预测模型 (Prediction Model of Equatorial Plasma Bubbles Based on Images, EPB-IPM), 通过时空预测学习框架 SimVP^[14] 将 EPB 形态演化问题转化为基于图像序列预测的时空预测学习问题。该技术已在预测极光^[15,16]、电离层 TEC map^[17-19]、电离层图^[20] 等领域验证了可行性。本研究将其应用于 EPB 演化预测问题的核心优势包括两个方面: 一是高效性, 无需求解复杂物理方程, 仅需历史气辉图像即可预测未来演化; 二是修复能力, 当气辉观测数据因云层或光污染缺失时, 可通过预测模型重构关键时段 EPB 形态, 弥补数据缺口。通过系统性评估模型时间分辨率、输入/输出图像帧数、EPB 空间形态复杂度及光污染等因素对模型性能的影响, 验证了该模型在 EPB 演化预测中的有效性, 并获得了性能最优的模型设置。

1 数据与方法

1.1 数据来源与预处理

研究使用的数据来自中国曲靖站 (地理坐标 25°N, 104°E; 地磁坐标 15.1°N) 和海南富克站 (地理坐标 19.5°N, 109.1°E; 地磁坐标 10.2°N) 的全天气辉成像仪 (ASI) 观测数据。该成像仪主要由鱼眼镜头 (180°视场角)、镜头系统、滤光片 (630.0 nm) 和电热制冷电荷耦合器件组成。图像分辨率为 1024×1024 pixel, 像素深度为 16 位, 时间分辨率为 3 min。关于成像仪的更多信息可以参考文献 [4]。

基于曲靖站气辉观测数据构建 EPB 演化预测模型, 并通过富克站观测数据进行模型的跨台站鲁棒性验证。基于曲靖站 2012 年 1 月 1 日至 2022 年 12 月 31 日的气辉成像观测数据构建 EPB 视频预测数据集。原始数据为时间分辨率 3 min 的静态图像, 共筛

选出曲靖站 4664 张有效 EPB 图像。等离子体泡图像演化预测模型需要基于视频预测技术预测未来等离子体泡图像。为构建适用于视频预测模型的训练样本, 按以下步骤进行处理。

步骤 1 图像序列划分标准。采用 6 min 作为序列分割阈值, 若相邻 EPB 图像时间间隔 ≤ 6 min, 则归为同一序列, 否则视为独立序列。基于该标准, 最终获得了 166 个图像序列。

步骤 2 数据验证。统计显示 2012—2017 年共识别 129 个 EPB 事件日, 与 Wu 等^[4] 的统计结果完全一致。验证了 6 min 阈值能准确反映 EPB 事件的连续性。

步骤 3 时间尺度标准化。不同图像序列持续时间从 30 min 至数小时不等 (分布如图 1 所示, 竖条的不同颜色代表不同时间长度的图像序列, 竖条的长度代表图像序列的个数), 对所有序列按统一时间尺度进行重采样, 确保模型输入一致性。大部分 EPB 图像序列的时间尺度在 2 h 以内, 排除持续时间 ≤ 1 h (20 帧) 的短序列, 确保训练样本具有足够的时间跨度。同时, 为了充分利用 EPB 图像序列信息, 对长时间尺度的序列通过滑动窗口的形式进行 20 帧 (约 1 h) 等时间尺度采样。即滑动窗口大小为 20 帧, 滑动步长为 5 帧。最终获得 584 个 EPB 图像序列。

步骤 4 图像预处理。由于原始图像为 png 格式, 分辨率为 1024×1024 pixel, 为降低训练时内存消耗, 需将其转换为 jpg 格式, 并下采样至 500×500 pixel。采用 MPEG4 编码的 AVI 格式 (5 frame·s⁻¹) 保存图像, 平衡清晰度与存储效率。

此外, 基于富克站 2013 年 1 月至 2014 年 12 月




图 1 覆盖不同时间尺度的 EPB 图像序列数量分布情况
Fig. 1 Number distribution of EPB image sequences covering different time scales

气辉观测数据, 筛选出 883 张有效 EPB 图像, 其中包括 10 个图像数量为 80~100 (约 240~300 min) 不等的图像序列。

1.2 模型架构选择

EPB 演化预测模型基于赤道等离子体泡历史图像序列, 准确预测其未来的演化趋势, 给出 EPB 在未来时间点的形态和位置变化, 最终生成高分辨率的预测图像, 便于分析和应用。该过程的本质是时空预测学习, 使模型能够在无监督的情况下通过给定的过去图像帧预测未来图像帧, 从而学习空间和时间的内在模式。

EPB 演化预测问题形式化定义如下: 给定一个在时间 t 的包含过去 T 帧的 EPB 演化图像序列 $X_{t,T} = \{x_i\}_{i=t-T+1}^t$, 而目标是在时间 t 预测未来的 EPB 图像序列 $Y_{t,T'} = \{x_i\}_{i=t}^{t+T'}$, 该序列包含接下来的 T' 帧, 其中 x_i 是一个具有通道数 C , 高度 H 和宽度 W 的图像。因此, 预测模型是一个映射 $F_\Theta: X_{t,T} \rightarrow Y_{t,T'}$, 其中的可学习参数 Θ 通过以下公式优化:

$$\Theta' = \operatorname{argmin} \mathcal{L}[F_\Theta(X_{t,T}), Y_{t,T'}].$$

其中, $\mathcal{L}$ 可以是各种损失函数。在构建 EPB 视频预测模型时, 主要存在以下技术问题。

(1) 物理过程的复杂性。赤道等离子体泡的演化受到多种物理因素的共同作用, 如太阳活动、磁场、中性风等, 准确建模 EPB 图像演化过程是一个难点。

(2) 高维连续数据的表示与预测。EPB 演化具有强时空依赖性, 需模型能有效捕捉时空关系, 视频预测涉及高维连续数据的处理, 如何有效表示和预测这种复杂的数据分布是一个关键问题。

(3) 模型的泛化能力。赤道等离子体泡的形态和演化过程具有季节性, 且随着不同的太阳水平和地磁活动水平变化, 模型需要具备良好的泛化能力, 以适应不同的观测条件和演化场景。

(4) 计算资源与效率。视频预测模型通常需要大量的计算资源进行训练, 如何在有限的资源下提高计算效率是一个重要问题。

针对 EPB 演化预测的技术问题, 对视频预测框架进行调研和测试。最终选择 SimVP^[14] (Simpler yet Better Video Prediction) 框架构建 EPB 视频预测演化模型。SimVP 是一种简单而高效的视频预测模型, 完全基于卷积神经网络 (Convolutional Neural Network, CNN) 构建, 并通过均方误差 (Mean Squared

Error, MSE) 损失函数以端到端的方式进行训练。在不引入对抗训练和采样学习等任何额外技巧和复杂策略的情况下, 该卷积模型可以在 5 个基准数据集上实现较先进的性能, 且 SimVP 在现实世界数据集上具有很强的泛化性和可扩展性。SimVP 实验显示, 在有限计算成本下, SimVP 框架相比于 Transformer 等具有训练时间更短、精度更高的优势。众多时空预测算法中, SimVP 是一种较简单但更好的 CNN 视频预测模型, 且计算成本较低, 已广泛应用于动态物体行为预测、交通流量分析和自动监控系统等领域。

SimVP 由编码器 (Encoder)、翻译器 (Translator) 和解码器 (Decoder) 组成, 所有部分均基于 CNN 实现。如图 2 所示, Encoder 用于提取 EPB 图像空间特征, 编码器通过堆叠 N_s 个卷积模块 (ConvNormReLU 块, 即 Conv2d + LayerNorm + LeakyReLU) 来提取空间特征, 消除背景误差; Translator 翻译器由 N_t 个 Inception 模块组成, 用于学习时间演化, 主要关注预测 EPB 的位置和内容; Decoder 解码器由 N_s 个 unConvNormReLU 块 (ConvTranspose2d + GroupNorm + LeakyReLU) 整合时间和空间信息, 以预测未来的视频帧, 并优化预测 EPB 的形状。

编码器在 (H, W) 上进行 C 通道的卷积。隐藏特征表示如下:

$$z_i = \sigma(z_{i-1})_{\text{Conv2d} \rightarrow \text{LayNorm}}, \quad 1 \leq i \leq N_s. \quad (1)$$

其中, 输入 z_{i-1} 和输入 z_i 的形状分别为 (T, C, H, W) 和 $(T, C, \hat{H}, \hat{W})$; N_s 表示卷积模块数量, 这里为 4; Conv2d 为 3×3 的卷积, 保持空间分辨率 (stride=1, padding=1); LayerNorm 表示对每个样本的 C, H, W 纬度归一化; σ 表示激活函数, 此处采用 LeakyReLU 激活函数允许负数输入产生非零梯度, 从而缓解梯度消失并提升模型训练稳定性。

翻译器在 (H, W) 上进行 $T \times C$ 通道的卷积。其中 Inception 模块主要是通过不同尺度的卷积核和池化操作来提取特征, 并通过合并层将这些特征合并在一起。Inception 模块由一个 1×1 大小的 Conv2d 后接并行的卷积核大小分别为 (3, 5, 7, 11) 的 GroupConv2d 操作符完成, 最后将特征图进行拼接。其中, 不同尺寸的卷积核用于捕捉局部/全局运动模式。隐藏特征表示为


图 2 不同 SimVP 模型结构^[14]

Fig. 2 Different SimVP model structures

$$z_j = (z_{j-1})_{\text{Inception}}, \quad N_s < j \leq N_s + N_t. \quad (2)$$

其中, 输入 z_{j-1} 和输入 z_j 的形状分别为 $(T \times C, H, W)$ 和 $(\hat{T} \times \hat{C}, H, W)$; N_s 表示前述卷积模块数量; N_t 表示 Inception 模块数量, 这里取为 8, 分别表示 Inception 模块个数. SimVP 模型在 Translator 通过 Inception 单元堆叠出了一个 Encoder-Decoder 结构, 即 Inception 模块处于编码器深层和解码器浅层结构位置. 这个 Encoder-Decoder 结构的深度共有 8 层, 通过这种方式提取时间特征, 从而得到时间演化效果.

解码器在 (H, W) 上进行 C 通道的卷积, 实现对翻译器信息的解码工作, 解码器与编码器近乎相似, 只是将卷积操作改成了反卷积操作. 隐藏特征表示为

$$z_k = \sigma(z_{k-1})_{\text{unConv2d} \rightarrow \text{GroupNorm}}, \quad N_s + N_t < k \leq 2N_s + N_t. \quad (3)$$

其中, 输入 z_{k-1} 和输入 z_k 的形状分别为 $(\hat{T}, \hat{C}, \hat{H}, \hat{W})$ 和 (T, C, H, W) ; unConv2d 表示反卷积操作, 主要作用是进行上采样, 即增大特征图的尺寸. 本文使用 ConvTransposed2d 作为 unConv2d 的操作符. GroupNorm 将输入特征图 (feature map) 的通道 (channel) 分成若干组, 每组内部进行归一化处理, 其优点是性能不依赖于批量大小. N_s 表示反卷积模块数量, 文中取为 4, N_t 表示前述 Inception 模块数量.

EPB 演化具有明显的时空依赖性, SimVP 的时

空建模能力可以较好地处理这一问题. 同时, EPB 数据通常具有较高的时空分辨率, SimVP 的低计算成本适合处理此类数据. SimVP 简化了视频预测任务, 减少了模型复杂性, 同时能保持较高的预测性能.

1.3 实验设计

1.3.1 数据集划分

为了保证模型具备良好的泛化能力, 模型训练过程中, 尽量满足训练数据、验证数据和测试数据独立同分布原则. 考虑到 EPB 演化过程受季节变化和太阳活动影响显著, 且其形态演化 (包括分叉、融合和膨胀) 和漂移过程具有高度复杂性, 进行数据集划分时, 应尽量保证以上三类数据集均包含不同季节、不同太阳活动水平和各类形态演化特征的样本.

因此, 按年份和季节进行分组. 对同一年份同一季节的数据, 按照 7:1.5:1.5 的比例随机划分, 并对划分获得的数据集进行微调, 以确保三类样本里面 EPB 形态的多样性. 最终将 2012—2022 年的 584 个气辉图像视频样本划分为 374 个训练样本 (64%)、93 个验证样本 (16%) 和 117 个测试样本 (20%).

1.3.2 评估指标

验证指标采用均方差 E_{MSE} (Mean Squared Error, MSE)、平均绝对误差 E_{MAE} (Mean Absolute Error, MAE)、峰值信噪比 R_{PSN} (Peak Signal-to-Noise

Ratio, PSNR) 和结构相似性指数 I_{SSIM} (Structural Similarity Index Measure, SSIM).

给定一个大小为 $m \times n$ 的原始图像 I 和噪声图像 K , 均方差定义为

$$E_{\text{MSE}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - K(i, j)]^2. \quad (4)$$

平均绝对误差是一种常用的回归问题评估指标, 用于衡量预测值与真实值之间的平均绝对差异. 其直观反映了预测误差大小, 且对异常值不敏感, 有

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (5)$$

其中, y_i 是第 i 个真实值, $\hat{y}_i$ 是第 i 个预测值, n 是样本总数, $|\cdot|$ 表示绝对值.

峰值信噪比是通过比较两幅图像的每个像素值的差异 (噪声), 来衡量预测图像与原始图像之间的差异. 其通过计算图像的最大可能信号强度与噪声强度之间的比率来量化图像的失真程度. 峰值信噪比的值越大模型性能越好. 如果两幅图像完全相同, 那么噪声为零, 峰值信噪比为无穷大, 即

$$R_{\text{PSN}} = 10 \times \lg \left(\frac{P_{\text{max}}^2}{E_{\text{MSE}}} \right). \quad (6)$$

其中, P_{max} 为图像像素值的最大可能值. 对于 8 位图像 (像素值范围为 $0 \sim 255$), $P_{\text{max}} = 255$, E_{MSE} 为均方误差.

结构相似性指数基于人眼会提取图像中结构化信息的假设, 比较两幅图像的相似度. 其更关注图像的细节、纹理和边缘信息. 结构相似性指数基于样本 x 和 y 之间的三个比较衡量: 亮度 (luminance)、对比度 (contrast) 和结构 (structure), 有

$$I_{\text{SSIM}} = [l(x, y)]^\alpha [c(x, y)]^\beta [s(x, y)]^\gamma. \quad (7)$$

其中, $\alpha > 0$, $\beta > 0$, $\gamma > 0$, 用于调整亮度、对比度与结构之间的相对重要性; $l(x, y)$ 为亮度比较; $c(x, y)$ 为对比度比较 (图像明暗变化的剧烈程度), 即

像素的标准差; $s(x, y)$ 为结构比较, 有

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}, \quad (8)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad (9)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3}. \quad (10)$$

其中, μ_x, μ_y 及 σ_x, σ_y 分别表示 x 和 y 的平均值和标准差; σ_{xy} 表示 x 和 y 的协方差; C_1, C_2, C_3 为常数, 用于维持结果的稳定. 结构相似性指数 I_{SSIM} 值在 $-1 \sim 1$ 之间, 值越大, 表示两幅图越相似.

1.3.3 模型训练方法

将基于前序 N_{pre} 帧图像为输入, 后续 N_{aft} 帧图像为输出, 训练得到的收敛模型定义为 $\text{Model } N_{\text{pre}} \times N_{\text{aft}}$. 输入、输出图像和模型时间分辨率定义为 t . 模型测试时, 输入帧数必须固定为 N_{pre} (与训练一致), 输出帧数可自由扩展 (支持多步预测).

为系统评估模型性能, 以控制时间分辨率、输入帧长度、输出帧长度三类变量进行对比实验, 探讨其对模型预测性能的影响, 从而筛选出最优的模型设置. 具体的实验设计列于表 1.

1.3.3.1 不同时间分辨率模型训练

高性能 EPB 图像演化预测模型的核心在于准确建模等离子体泡的动态演化过程. 时间分辨率作为关键参数, 直接影响模型对物理过程的表征能力, 其作用机制在于时间分辨率与信息完整性: 高时间分辨率 (例如 3 min), 连续帧间相似度高, 能捕捉快速演化特征 (例如瞬时分叉、快速漂移), 保留精细时空变化模式. 低时间分辨率 (例如 10 min) 可能丢失短时现象、平滑化快速动态过程. 比如漂移速度过快的等离子体泡, 有可能在短时间内出现又消失, 而低时间分辨率的图像中则无法观测到相关演化信息.

定义当前帧时刻 T_1 , 输入的前序图像帧的时间起点为 T_0 , 预测的未来图像帧时间终点为 T_2 , 则输入和

表 1 实验变量设计
Table 1 Design of experimental variables

实验维度	研究目标	参数设置
时间分辨率 t/min	最优观测时间间隔	$t \in \{3, 3.8, 5.18, 8.14\}$
输入帧长度 $N_{\text{pre}}/\text{frame}$	前序观测时长的影响	$N_{\text{pre}} \in \{4, 6, 8, 10, 12, 14\}$
输出帧长度 $N_{\text{aft}}/\text{frame}$	预测时间跨度的极限	$N_{\text{aft}} \in \{4, 6, 8, 10\}$

表 2 不同时间分辨率的模型输入输出参数设置

Table 2 Configuration of input/output parameters for models with different temporal resolutions

模型名称	N_{pre}	N_{aft}	t/min	$(T_1 - T_0)/\text{min}$	$(T_2 - T_1)/\text{min}$
Model 4×4	4	4	8.14	24.42	32.56
Model 6×6	6	6	5.18	25.9	31.08
Model 8×8	8	8	3.8	26.6	30.4
Model 10×10	10	10	3	27	30

输出图像帧的时间尺度分别为 $T_1 - T_0$ 和 $T_2 - T_1$, 时间分辨率均为

$$t = \frac{T_1 - T_0}{N_{\text{pre}} - 1} = \frac{T_2 - T_1}{N_{\text{aft}}}. \quad (11)$$

基于构建的 EPB 图像视频数据集 (每个样本 20 帧, 时间分辨率 3 min, 时间跨度 57 min), 将每个视频样本按时间均分为两部分, 并进行下采样生成时间分辨率更低的样本, 分别作为模型输入段和模型输出段, 具体实验设置如表 2 所示. 基于以上设置, 训练收敛后获得 4 种不同时间分辨率的 EPB 预测模型, 包括 Model 4×4, Model 6×6, Model 8×8 和 Model 10×10. 最后, 基于测试集分别评估以上模型在预测未来 4, 6, 8, 10 帧的性能表现.

1.3.3.2 不同输出图像帧数的模型训练

为系统评估 EPB 预测模型对不同输出帧的建模能力及其时间维度上的泛化能力, 包括模型对长期依赖关系的捕捉能力和性能随时间尺度的衰减规律. 通过观察模型在不同时间尺度下的表现, 可以判断其预测是否稳定.

以时间分辨率为 3 min 的 EPB 图像数据训练多个 EPB 图像演化预测模型, 包括 Model 6×4, Model 6×6, Model 6×8 和 Model 6×10, 具体的训练配置如表 3 所示. 测试所有模型在预测未来 1~11 帧 (约 3~33 min) 图像的性能.

1.3.3.3 不同输入图像帧数的模型训练

为确定最优的前序观测时长, 研究系统评估不同输入帧数对 EPB 演化预测性能的影响, 重点解决建模 EPB 演化过程所需的最小观测时长, 输入帧数增加与预测性能的边际效益关系. 以时间分辨率为 3 min 的数据进行模型训练, 设置不同的输入帧数和相同的输出帧数, 具体模型训练参数配置如表 4 所

表 3 不同时间尺度输出的模型参数设置

Table 3 Parameter configuration for models with varying output time scales

模型名称	N_{pre}	N_{aft}	Time/min		
			t	$T_1 - T_0$	$T_2 - T_1$
Model 6×4	6	4	3	15	12
Model 6×6	6	6	3	15	18
Model 6×8	6	8	3	15	24
Model 6×10	6	10	3	15	30

表 4 不同时间尺度输入的模型参数设置

Table 4 Parameter configuration for models with varying input time scales

模型名称	N_{pre}	N_{aft}	Time/min		
			t	$T_1 - T_0$	$T_2 - T_1$
Model 4×6	4	6	3	9	18
Model 6×6	6	6	3	15	18
Model 8×6	8	6	3	21	18
Model 10×6	10	6	3	27	18
Model 12×6	12	6	3	33	18
Model 14×6	14	6	3	39	18

示. 最终, 建模形成 Model 4×6, Model 6×6, Model 8×6, Model 10×6, Model 12×6, Model 14×6, 共 6 个 EPB 图像演化预测模型. 最后, 基于测试数据评估所有模型在预测未来 6 帧 (18 min) 图像时的性能.

EPB 图像演化预测模型训练的相关硬件信息, 包括 Ubuntu 22.04, CPU 内存 100 G, 1 张 NVIDIA A10 (显存 24 GB). 采用 Pytorch 时空预测框架*进行所有模型的开发和测试. 以前序输入图像 6 帧, 后续预测图像 6 帧为例, 训练过程中的其他超参数设置列

* <https://sourceforge.net/projects/openstl/>

于表 5.

EPB 图像演化预测模型训练过程如下. 模型接收前序 N_{pre} 帧图像序列作为输入, 通过时空特征提取网络生成未来 N_{aft} 帧预测结果, 并利用预测的图像与真实的图像进行对比, 计算 MSE 损失函数, 通过反向传播算法计算梯度, 优化损失函数直至其收敛, 最终获得训练较好的模型.

图 3 和图 4 表示 Model 6×6 预测模型训练过程中损失函数曲线和性能指标曲线. 从图中可知, 大约在 300 个 epoch 之后, 损失函数值较为稳定, 同时模型的 MSE 和 MAE 值也基本保持不变, 模型基本收敛, 此时的模型可以作为最终的 EPB 图像演化预测

表 5 EPB 演化预测模型训练中使用的部分超参数
Table 5 Some hyperparameters used in the training of the EPB evolution prediction model

Parameter	Value
Loss function	MSE
N_{pre}	6
N_{aft}	6
Epoch	1000
Scheduler	0.001
N_S	4
N_T	8
Hid_S	64
Hid_T	256
Batchsize	1




图 3 EPB 演化预测模型损失函数值随训练周期的变化

Fig. 3 Variation of loss function value with training epochs for the EPB evolution prediction model

模型.

2 结果分析与讨论

基于前文训练设置, 最终获得所有收敛的 EPB 图像演化预测模型, 并在 117 个测试样本上进行性能测试, 评估模型在不同时间分辨率、不同数量前序输入帧和后续预测帧、不同 EPB 空间尺度和光污染条件下的性能表现, 并分析导致其性能变化的可能原因.

2.1 不同时间分辨率模型的性能

最终获得的 4 个不同时间分辨率的预测模型, 在相同时间尺度测试集上的性能表现如表 6 所示, 性能指标代表测试集上所有图像序列预测性能的平均值.

从表 6 可知, 分辨率与指标正向相关, 随着模型分辨率的提升 ($4 \times 4 \rightarrow 10 \times 10$), 模型 MSE 和 MAE 逐渐降低, PSNR 逐渐升高, 代表预测图像与真实图像中像素值差异逐渐减小. 这主要是因为输入数据时间尺度相同时, 更大时间分辨率的模型需要更多数量的输入帧. 同时前后两帧图像代表的 EPB 演化过程更为平缓, 图像信息更连续. 这有助于模型学到更多的演化细节, 提高特征追踪的连续性, 从而建立更精确的时空关联, 增强其预测能力. 指标的非单调性, SSIM 在 6×6 模型出现下降 (与 4×4 相比), 但在 10×10 模型恢复至最大. 说明 SSIM 指数与 MSE, MAE 和 PSNR 并非完全同步变化. 这主要是由于 SSIM 对结构相似性敏感, 受纹理平滑化影响. 而 MSE/MAE/




图 4 EPB 演化预测模型在验证集上的均方差 (MSE) 和平均绝对误差 (MAE) 随训练周期的变化

Fig. 4 Variations of MSE and MAE on the validation set versus training epochs for the EPB evolution prediction model

PSNR 对像素级误差更敏感, 随分辨率单调改善. 但整体上指标的变化趋势一致. 最优模型特征, Model 10×10 (3 min 分辨率) 表现出最佳综合性能.

因此, 基于更高时间分辨率数据训练的 EPB 图像演化预测模型, 能更准确建模 EPB 连续图像内部的时空依赖关系, 进而获得更优的预测性能.

2.2 不同时间尺度输出帧对模型性能的影响

最终获得基于 6 帧输入帧与不同数量输出帧 (4, 6, 8, 10) 构建的 4 个 EPB 演化预测模型, 在测试集上预测未来 1~11 帧 EPB 图像时的性能表现, 性能指标代表测试集上所有图像序列预测性能的平均值, 具体结果如图 5 所示. 基于图 5 的实验结果, 可以得出以下重要结论.

(1) 预测误差的时间依赖性. 所有模型均表现出一致趋势. 4 个模型的 MSE/MAE 随帧数单调递增, 而 SSIM 和 PSNR 指标主要呈递减趋势. 说明预测的时间尺度越长, 模型的表现越差. 这主要因为 EPB 受瑞利-泰勒不稳定性、电离层背景电导率、中性风场、梯度漂移不稳定性等多种因素调控, 且会呈现自东向西漂移、分叉、融合等复杂动态特征^[3,4], 随着预测时间延长, 未来帧的不确定性增加, 模型难以精确预测复杂动态变化.

(2) 模型架构的临近效应. Model 6×4 模型在预测 ≤ 4 帧时, 误差可控; 预测 > 4 帧, 性能断崖式下降. MSE, MAE, SSIM 和 PSNR 指标均出现剧烈变化. 这主要是因为模型仅建模了前序帧与未来 4 帧图像时空关联, 导致超过 4 帧图像时, 难以准确预测. 然而, 对比模型 Model 6×6, Model 6×8, Model 6×10 均保持线性衰减, 体现出了建模前序帧与未来 6 帧以上序列的时空关联的可外推性.

(3) 最优模型分析. Model 6×6 的 MSE, MAE, PSNR 指标均是所有模型中最优的. 说明预测模型能最准确地建模前序 6 帧图像与后续 6 帧图像的内在

时空关系, 且建模的时空关系外推性最好. 这可能与 SimVP 网络模型本身的建模能力及赤道等离子体泡的演化过程具有紧密联系. Model 6×6 可能最能匹配 EPB 典型演化周期, 且能平衡信息量 (12 帧) 与建模难度, 而建模超过 12 帧后, 信息熵增益边际效益下降. 一方面, 受限于网络架构, SimVP 网络的长时序建模能力逐渐衰减. 另一方面, 受到 EPB 物理特征变化影响, 比如等离子体泡在午夜前的发生率、漂移速度通常高于午夜后^[21,22], 可能导致午夜前后演化复杂度差异. 因此, 更长时间尺度的序列很可能包含复杂演化, 导致建模更为困难. 此外, 还可能受到信息关联尺度的影响. 例如后续帧超过 6 帧时, 与前序帧的时空相关性减弱.

因此, 模型通常能较好地预测近期的帧, 随着时间尺度的增加, 预测难度上升. 模型建模 Model 6×6 具有最优性能, 其建模的时空关系能外推到更长时间尺度的未来帧.

2.3 不同时间尺度输入帧对模型性能的影响

基于前文设置, 最终获得基于不同数量输入帧 (4, 6, 8, 10, 12) 与 6 帧输出帧构建的 6 个 EPB 演化预测模型, 在测试集上预测未来 6 帧 EPB 图像时的性能表现, 性能指标代表测试集上所有图像序列预测性能的平均值, 具体结果如图 6 所示. 根据图 6 实验结果, 系统分析前序图像帧数对预测性能的影响规律.

性能指标的非线性变化特征. 前序图像帧数从 4 帧增加至 14 帧时, MSE 和 MAE 先降后升, SSIM 和 PSNR 先升后降, 均代表模型性能先增强后降低. 这主要是因为模型更多的前序图像信息, 有助于模型学到更强的拟合能力, 从而降低损失函数.

最优模型特征. 其中图 6(b)(c)(d) 均显示当前序图像帧为 6 帧时, 性能指标表现最优 (MSE=558.808, MAE=9658.856, SSIM=0.989, PSNR=34.704), 前序图像帧超过 6 帧后, 性能指标不再提升. 与前文分析

表 6 不同时间分辨率模型的性能比较
Table 6 Performance comparison of models with different temporal resolutions

预测类型	MSE	MAE	SSIM	PSNR
Model 4×4	1586.788	17551.615	0.978	29.843
Model 6×6	1477.651	16772.386	0.976	30.038
Model 8×8	1152.504	14463.274	0.977	31.518
Model 10×10	1120.877	13889.469	0.982	31.860




图 5 不同数量输出帧构建的 EPB 演化预测模型预测未来不同数量 EPB 图像帧时的性能比较

Fig. 5 Performance comparison of EPB evolution models with different output frame configurations for forecasting varying numbers of future EPB image frames

的情况一致, 这可能与 SimVP 网络模型的建模能力及赤道等离子体泡的演化过程具有紧密联系. 与前文分析情况相似, Model 6 $\times$ 6 时实现了信息量与建模复杂度的平衡. 一方面, SimVP 网络的建模能力可能随着时间尺度增加而衰减. 另一方面, 更长时间尺度的输入数据可能包含更复杂的 EPB 演化信息, 导致模型学习的难度增大. 此外, 前 6 帧图像可能已经足够给出未来 6 帧 EPB 图像演化的隐含信息, 而更多的前序图像则提供了冗余信息, 甚至干扰了模型对未来

EPB 图像演化的学习过程.

因此, 当以前序 6 帧输入图像建模时, 训练得到的 EPB 图像演化预测模型在预测后 6 帧图像时性能最好.

2.4 演化预测模型鲁棒性检验

2.4.1 等离子体泡空间形态复杂度与光污染对模型性能的影响

不同 EPB 覆盖的图像像素空间范围差异较大, 同时呈现出简单的 I 形和复杂的 Y 形、波状结构等.

同时, 气辉观测易受到月光、浓云等自然条件的污染, 导致 EPB 信号被干扰. 此外, 由于 EPB 区域等离子体密度相比于背景等离子体密度可能没有特别明显的降低, 存在部分耗散强度较弱的 EPB. 为了进一步评估模型针对不同空间尺度、不同复杂形态 EPB 及其在光污染条件下的鲁棒性, 基于训练好的最优模型, 测试其在以上场景下的性能表现.

基于时间分辨率 3 min 的 Model 6×6 EPB 演化预测模型, 利用前序 6 帧图像预测未来 6 帧图像的结果如图 7~10 所示, 其中 True 代表真实图像, Predict 代表预测图像, T+N 表示后续帧序号, T 表示当

前时刻, N 表示未来帧序号. 具体如图 7~10 所示.

图 7 中 EPB 结构较为简单, 未呈现大量分叉, 同时其空间尺度较小, 不到整个视场的 1/4, 且前后图像帧中 EPB 形态随时间变化缓慢. EPB 演化预测模型获得未来 6 帧图像的预测结果与真实图像较为接近. 而图 8 中, EPB 结构呈现大量分叉, 且其空间覆盖了最高接近视场的 1/2, 且在当前观测时间范围内 EPB 具有明显的东向漂移特征, 前后图像帧内容变化较快, 导致 EPB 演化预测模型从第 3 帧开始就产生了较大的误差. 图 9 显示强光污染条件下, 视野中观测到的气辉图像暗区信息不够明显, 预测结果中的




图 6 预测未来 6 帧 EPB 图像时不同数量输入帧构建的 EPB 演化预测模型性能比较

Fig. 6 Performance comparison of EPB evolution prediction models with different input frames configurations for predicting the next six frames of EPB images

EPB 信号则更弱. 图 10 中观测视野中的气辉暗区信息同样较弱, 但是预测结果图像中的 EPB 信号却未有明显弱于原图像中 EPB 信号. 说明无强光干扰时, 即使 EPB 信号较弱, 也能获得较好的预测效果.

从预测效果图看, 图像 7 和图 10 的预测效果最好, 其次是图 9, 图 8 预测效果最差. 主要是因为图 7 和图 10 中 EPB 结构简单, 未发生明显的形态变化, 且漂移速度较慢, 相比于图 8 中发生大量分叉和更快漂移的 EPB, 图 7 和图 10 图中各个区域像素的变化更缓慢, 预测模型更容易捕捉 EPB 信号变化. 同时, EPB 图像像素区域的快速变化反映了 EPB 受瑞利-泰勒不稳定性、电离层背景电导率、中性风场等多种因素的综合调控, 该物理过程非常复杂, 导致预测模型学习 EPB 演化行为更加困难. 而图 9 虽然受到强光的干扰, 但是 EPB 形态结构较为简单, 演化过程缓慢, 图中各个像素区域像素的变化更缓慢, 可能反映了控制 EPB 演化的物理因素未发生明显变化, 模

型依然能学到 EPB 演化行为.

因此, EPB 空间尺度及形态复杂度对模型预测性能影响较大, 主要是 EPB 形态演化受到各种物理因素调制, 导致模型学习演化行为较为困难. 强光污染不会影响 EPB 形态演化, 仅导致 EPB 信号变弱, 预测模型依然能较好地学到 EPB 演化行为.

2.4.2 模型时长测试与跨台站性能检验

前文筛选最优模型参数的实验结果显示, EPB 演化预测的时间尺度越长, 模型的表现越差. 为了评估模型在可接受的精度下, 预测时间尺度最长可以达到多少, 需进一步检验模型的时长预测能力. 当前 EPB 演化预测模型是基于中国曲靖站气辉观测数据训练得到的, 为了评估模型是否具有普适性, 需开展跨台站预测性实验. 因此, 本文基于训练获得的最优模型 (时间分辨率 3 min 的 Model 6×6 模型), 利用海南富克站和云南曲靖站的 EPB 图像序列测试模型在长时间序列图像上的性能表现.




图 7 模型预测小尺度且结构简单 EPB 的未来 6 帧 (18 min) 图像

Fig. 7 Model predicts six future frames (18 min) of a small-scale EPB with simple structures




图 8 模型预测大尺度且结构复杂 EPB 的未来 6 帧 (18 min) 图像

Fig. 8 Model predicts six future frames (18 min) of a large-scale EPB with complex structures




图 9 模型预测强光污染条件下 EPB 的未来 6 帧 (18 min) 图像

Fig. 9 Model predicts six future frames (18 min) of EPBs under strong light pollution conditions




图 10 模型预测没有光污染的弱 EPB 未来 6 帧 (18 min) 图像

Fig. 10 Model predicts six future frames (18 min) of weak EPBs without light pollution

实验过程中, 利用前序 6 帧图像预测未来 6~84 帧 (约 18~252 min) 图像. 考虑到短期内预测性能指标变化较小, 本文采用间隔采样方法 (间隔大小为 6 帧) 计算模型性能指标, 即分别计算模型预测未来 6, 12, 18 帧等的性能. 此方法既能保证性能指标变化趋势基本不受到影响, 又能加快计算速度. 具体性能如图 11 所示.

图 11 表明随着预测的未来图像帧数量的增加, 模型在富克站和曲靖站的观测数据上均表现出性能下降的趋势, 其中 MSE 和 MAE 逐渐升高, SSIM 和 PSNR 逐渐降低. 同时, 模型在曲靖站数据与富克站数据上的测试表现不同, 曲靖站 MSE, MAE, SSIM 和 PSNR 的误差棒随预测图像帧数量增加变化较大, 而基于富克站测试的各项性能指标误差棒变化较小. 此外, 图 11(c)(f)(i)(l) 显示模型在预测未来帧数小于 75 帧时, 在曲靖站数据上的性能表现 (SSIMSSIM 约

0.88~0.98, PSNR 约为 22~28.5) 优于富克站数据的性能表现 (SSIM 约 0.88~0.95, PSNR 约为 18~27). 当预测的未来图像数量超过 75 帧时, 模型在富克站数据上的性能表现开始优于曲靖站数据.

模型预测性能随预测帧数量的增加呈现减小趋势. 一方面, 由于随观测时间的增长, 待预测的未来图像帧与前序输入帧信息关联减小. 另一方面, EPB 受瑞利-泰勒不稳定性、电离层背景电导率、中性风场、梯度漂移不稳定性等多种因素调控, 增加了演化过程的不确定性. 模型针对曲靖站数据测试时误差波动更大, 提示预测结果波动更显著. 这可能是因为 EPB 本身演化受随机因素 (例如突发性电场、重力波) 强烈调制, 曲靖站观测数据中 EPB 时空演化更多变, 模型捕捉 EPB 时空演化规律的能力不稳定. 此外, 由于赤道等离子体泡沿地磁南北方向生长, 同时具有纬向漂移特征, 而曲靖站和富克站所处的空间位置差异, 理




图 11 模型针对曲靖站和富克站气辉观测数据的预测性能比较 (红色竖线代表一个标准误差大小)

Fig. 11 Comparison of model prediction performance for airglow observation data between Qijing Station and Fuke Station (red vertical bars indicating one standard error)

论上观测到的电离层等离子体泡 (EPB) 在形态和演化上存在差异. 因此, 本文基于曲靖观测数据训练得到的模型, 针对富克站数据进行测试时, 性能表现更差. 当预测的未来图像帧数据超过 50 帧后, 模型在曲靖站数据的测试指标波动 (PSNR 波动超过 7), 相比

于富克站数据的测试指标波动 (PSNR 波动约 4.5) 越来越显著. 预测性能不稳定性的增加, 进一步导致了预测帧数超过 75 帧时, 模型在富克站数据上表现更优.

综上提出的 EPB 演化预测模型针对富克站数据

有不错的鲁棒性. 当预测的未来帧数小于 50 帧时, 模型在曲靖和富克站上性能表现均较为稳定 ($SSIM > 0.9$, $PSNR > 20$), 且模型在曲靖站数据上的表现更优于富克站数据.

3 结论与展望

基于 SimVP 框架, 利用云南曲靖站气辉观测数据训练并构建了 EPB 演化预测模型. 围绕模型时间分辨率、输入/输出图像帧参数对模型性能的影响开展实验, 筛选出参数最优的模型 (时间分辨率 3 min 的 Model 6×6 模型), 进一步探讨了 EPB 空间形态复杂度和光污染等因素对模型性能的影响, 并测试了模型的时长预测能力与跨台站应用的鲁棒性. 主要结论如下.

(1) 高时间分辨率 (3 min) 数据能更精确地表征 EPB 演化的时空依赖性, 使模型获得最优预测性能 ($SSIM=0.989$, $PSNR=34.704$).

(2) 模型对近期帧 (<6 帧, 18 min) 的预测精度最高, 预测误差随时间跨度增加而累积. 当模型建模 12 帧 (36 min) 以上图像时, 模型可有效学习时空依赖关系并外推至更长时间尺度. 而建模时设置输入/输出帧数为 6, 训练得到的预测模型性能最优.

(3) EPB 空间尺度及形态复杂度显著影响预测精度, 模型对光污染和弱信号场景均表现出较强鲁棒性.

(4) 针对富克站数据测试表明模型具有不错的跨台站应用鲁棒性. 当预测的未来帧数小于 50 帧时, 模型在曲靖和富克站上性能表现均较为稳定 ($SSIM > 0.9$, $PSNR > 20$), 且模型在曲靖站数据上的表现更优于富克站数据.

研究提出的数据驱动方法为 EPB 演化预测提供了创新性解决方案, 同时为受污染气辉观测数据的修复提供了新的技术途径. 该技术框架具有普适性, 可拓展应用于极光活动、电离层闪烁等其他空间天气现象的图像预测研究.

鉴于 EPB 演化过程涉及复杂的多物理场耦合机制, 以及现有 EBP 图像预测模型在长期预报性能上的局限性, 未来研究将重点发展融合多源观测数据与物理约束的新型 EPB 演化预测模型. 具体而言, 拟通过整合 GNSS-TEC 数据、气辉成像、卫星原位观测

等多模态数据, 结合太阳活动指数 ($F_{10.7}$)、地磁指数 (Kp 和 Dst) 等空间环境参数, 构建基于物理约束的 Transformer 多模态预测框架. 该模型初步技术方案如下.

(1) 多模态特征提取. 包括图像分支和数值分支, 前者利用改进的 Vision Transformer^[23] 处理气辉图像数据, 捕捉 EPB 的空间结构特征, 后者利用 1 D CNN^[24] 提取太阳活动参数和地磁数据等数值数据的多尺度时序特征.

(2) 多模态特征融合. 通过层级交叉注意力^[25] 机制动态捕捉不同模态之间的关联, 并通过特征加权融合将这些信息进行整合, 权重由交叉注意力机制动态确定, 以反映不同特征的重要性. 融合过程增强了特征表达能力, 有助于提高模型准确率和鲁棒性.

(3) 混合训练策略. 利用物理信息神经网络 (Physics-Informed Neural Networks, PINNs)^[26] 结合数据驱动方法与物理约束指导模型学习. 损失函数包含常规数据拟合项 (MSE) 和物理约束项 (连续性方程残差、能量守恒判据). 采用渐进式训练流程, 先预训练单模态基础模型, 再进行多模态联合微调.

通过以上设计, EPB 演化预测模型既能捕捉图像的时空特征, 又能融合数值参数的物理规律, 最终输出符合科学约束的 EPB 演化预测结果.

致谢 国家空间科学数据中心 (<https://www.nssdc.ac.cn>) 提供了数据资源、计算服务和数据分析环境, 子午工程提供气辉数据支持, 中国科学院国家空间科学中心的空间科学数据融合计算平台提供了计算服务.

参考文献

- [1] OTT E. Theory of Rayleigh-Taylor bubbles in the equatorial ionosphere[J]. *Journal of Geophysical Research: Space Physics*, 1978, **83**(A5): 2066-2070
- [2] KELLEY M C, HEELIS R A. The Earth's Ionosphere: Plasma Physics and Electrodynamics[M]. 2nd ed. New York: Academic Press, 2009
- [3] TAKAHASHI H, TAYLOR M J, PAUTET P D, et al. Simultaneous observation of ionospheric plasma bubbles and mesospheric gravity waves during the spreadfex campaign[J]. *Annales Geophysicae*, 2009, **27**(4): 1477-1487
- [4] WU K, XU J Y, ZHU Y J, et al. Occurrence characteristics of branching structures in equatorial plasma bubbles: a statistical study based on all-sky imagers in China[J]. *Earth and Planetary Physics*, 2021, **5**(5): 407-415
- [5] YOKOYAMA T. A review on the numerical simulation of

- equatorial plasma bubbles toward scintillation evaluation and forecasting[J]. *Progress in Earth and Planetary Science*, 2017, **4**(1): 37
- [6] SULTAN P J. Linear theory and modeling of the Rayleigh-Taylor instability leading to the occurrence of equatorial spread F[J]. *Journal of Geophysical Research: Space Physics*, 1996, **101**(A12): 26875-26891
- [7] RETTERE J M. Forecasting low-latitude radio scintillation with 3-D ionospheric plume models: 1. Plume model[J]. *Journal of Geophysical Research: Space Physics*, 2010, **115**(A3): A03306
- [8] HUBA J D, JOYCE G. Global modeling of equatorial plasma bubbles[J]. *Geophysical Research Letters*, 2010, **37**(17): L17104
- [9] AARONS J. Global morphology of ionospheric scintillations[J]. *Proceedings of the IEEE*, 1982, **70**(4): 360-378
- [10] SU S Y, CHAO C K, LIU C H. On monthly/seasonal/longitudinal variations of equatorial irregularity occurrences and their relationship with the postsunset vertical drift velocities[J]. *Journal of Geophysical Research: Space Physics*, 2008, **113**(A5): A05307
- [11] REDDY S A, FORSYTH C, ARULIAH A, *et al.* Predicting swarm equatorial plasma bubbles via machine learning and shapley values[J]. *JGR Space Physics*, 2023, **128**(6): e2022JA031183
- [12] GITHIO L, LIU H X, ARAFA A A, *et al.* A machine learning approach for estimating the drift velocities of equatorial plasma bubbles based on all-sky imager and GNSS observations[J]. *Advances in Space Research*, 2024, **74**(11): 6047-6064
- [13] ZHAO X K, LI G Z, XIE H Y, *et al.* A novel short-term prediction model for regional equatorial plasma bubble irregularities in East and Southeast Asia[J]. *Space Weather*, 2025, **23**(2): e2024SW004224
- [14] GAO Z Y, TAN C, WU L R, *et al.* SimVP: simpler yet better video prediction[C]//Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE, 2022: 3160-3170
- [15] HU Z J, HAN B, ZHANG Y S, *et al.* Modeling of ultraviolet aurora intensity associated with interplanetary and geomagnetic parameters based on neural networks[J]. *Space Weather*, 2021, **19**(11): e2021SW002751
- [16] JIANG J N, ZOU Z M, LU Y. A ConvLSTM-based prediction model of aurora evolution during the substorm expansion phase[J]. *Earth and Space Science*, 2023, **10**(4): e2022EA002721
- [17] LIU L, ZOU S S, YAO Y B, *et al.* Forecasting global ionospheric TEC using deep learning approach[J]. *Space Weather*, 2020, **18**(11): e2020SW002501
- [18] LIU P, YOKOYAMA T, SORI T, *et al.* Channel mixer layer: multimodal fusion toward machine reasoning for spatio-temporal predictive learning of ionospheric total electron content[J]. *Space Weather*, 2024, **22**(12): e2024SW004121
- [19] SHIH C Y, LIN C Y T, LIN S Y, *et al.* Forecasting of global ionosphere maps with multi-day lead time using Transformer-based neural networks[J]. *Space Weather*, 2024, **22**(2): e2023SW003579
- [20] GAO P D, CAI J H, WANG Z, *et al.* Prediction of ionograms with/without Spread-F at Hainan by a combined spatio-temporal neural network[J]. *Space Weather*, 2024, **22**(1): e2023SW003727
- [21] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, *et al.* An image is worth 16×16 words: transformers for image recognition at scale[OL]. arXiv preprint arXiv: 2010.11929, 2020. DOI:10.48550/arXiv.2010.11929
- [22] KIRANYAZ S, AVCI O, ABDELJABER O, *et al.* 1D convolutional neural networks and applications: a survey[J]. *Mechanical Systems and Signal Processing*, 2021, **151**: 107398
- [23] AARONS J. The longitudinal morphology of equatorial F-layer irregularities relevant to their occurrence[J]. *Space Science Reviews*, 1993, **63**(3-4): 209-243
- [24] SINGH S, BAMGBOYE D K, MCCLURE J P, *et al.* Morphology of equatorial plasma bubbles[J]. *Journal of Geophysical Research: Space Physics*, 1997, **102**(A9): 20019-20029
- [25] GHEINI M, REN X, MAY J. Cross-attention is all you need: adapting pretrained transformers for machine translation[OL]. arXiv preprint arXiv: 2104.08771, 2021
- [26] CHEN Z, LIU Y, SUN H. Physics-informed learning of governing equations from scarce data[J]. *Nature Communications*, 2021, **12**(1): 6136

作者简介



钟佳男, 中国科学院国家空间科学中心高级工程师, 主要研究方向为空间天气数据挖掘与机器学习建模、科学可视化技术。

E-mail: zhongjia@nssc.ac.cn



邹自明(通信作者) 男, 中国科学院国家空间科学中心研究员, 国家空间科学数据中心主任, 中国科学院大学博士生导师, 主要从事空间科学与数据科学交叉领域研究, 在科学数据治理理论、标准研制、空间信息组织与互操作、日地空间大数据系统工程、空间天气领域数据挖掘与知识发现等方面开展研究。

E-mail: mzou@nssc.ac.cn