



国防科技大学学报

Journal of National University of Defense Technology

ISSN 1001-2486, CN 43-1067/T

《国防科技大学学报》网络首发论文

题目: 高度感知神经算子的空天过渡区风场预测模型研究
作者: 吴洋, 廖麒翔, 盛峰
收稿日期: 2025-08-22
网络首发日期: 2025-12-23
引用格式: 吴洋, 廖麒翔, 盛峰. 高度感知神经算子的空天过渡区风场预测模型研究 [J/OL]. 国防科技大学学报.
<https://link.cnki.net/urlid/43.1067.t.20251223.1110.002>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字符、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

doi: 10.11887/j.issn.1001-2486.25080025

高度感知神经算子的空天过渡区风场预测模型研究

吴 洋, 廖麒翔*, 盛 峥

(国防科技大学 气象海洋学院, 湖南 长沙 410073)

摘要: 针对传统数值预报在空天过渡区风场预测中计算效率低、多高度层物理特征建模不足的问题, 提出高度感知傅里叶神经算子 (height-aware Fourier neural operator, HAFNO) 模型。该模型引入高度感知权重机制, 能自适应区分不同高度层物理差异, 并保持 $O(n \log n)$ 的低计算复杂度; 同时构建了多高度层耦合预处理框架与融合空间梯度约束的自适应损失函数。基于 MERRA-2 数据的实验表明, HAFNO 在 50~70 km 高度层的预测精度均优于 ConvLSTM、DeepONet 等基准模型, 平均均方根误差较标准 FNO 降低 12.8%, 相关系数最高达 0.994, 可为空天过渡区环境保障提供高效的深度学习预测技术途径。

关键词: 空天过渡区; 高度感知机制; 傅里叶神经算子; 风场预测; 深度学习

中图分类号: P49 文献标志码: A

Research on wind field prediction model in aerospace transition

zone based on height-aware neural operator

WU Yang, LIAO Qixiang*, SHENG Zheng

(College of Meteorology and Oceanography, National University of Defense Technology, Changsha 410073, China)

Abstract: To address the issues of low computational efficiency and insufficient modeling of multi-altitude physical characteristics in traditional numerical prediction methods for the aerospace transition zone, a HAFNO (height-aware Fourier neural operator) model was proposed. A height-aware weighting mechanism was introduced to adaptively distinguish physical features across different altitude layers while maintaining $O(n \log n)$ computational complexity. Additionally, a multi-altitude coupled preprocessing framework and an adaptive loss function incorporating spatial gradient constraints were constructed. Experimental results based on MERRA-2 data demonstrate that HAFNO outperforms benchmark models such as ConvLSTM and DeepONet in the 50~70 km altitude range. The average RMSE (root mean square error) is reduced by 12.8% compared to the standard FNO, with a maximum correlation coefficient of 0.994, providing an efficient deep learning technical approach for environmental forecasting in the aerospace transition zone.

Keywords: aerospace transition zone; height-aware mechanism; Fourier neural operator; wind field prediction; deep learning

收稿日期: 2025-08-22

基金项目: 国家自然科学基金资助项目 (42275060, 42405065, 42305048); 国防科技大学自主创新科学基金资助项目 (24-ZZCX-JDZ-45, 25-ZZCX-BC-10)

第一作者: 吴洋 (1995—), 男, 天津滨海新区人, 博士研究生, E-mail: wuy@lzu.edu.cn

*** 通信作者:** 廖麒翔 (1990—), 男, 湖南永州人, 副教授, 博士, 博士生导师, E-mail: liaoqixiang2013@126.com

引用格式: 吴洋, 廖麒翔, 盛峥. 高度感知神经算子的空天过渡区风场预测模型研究 [J]. 国防科技大学学报,

Citation: WU Y, LIAO Q X, SHENG Z, et al. Research on wind field prediction model in aerospace transition zone based on height sensing neural operator [J]. Journal of National University of Defense Technology,

空天过渡区（约 50~150km）作为连接稠密大气层与外层空间的关键区域，内部大气演化和结构组成有其自身的独特性，涵盖平流层顶到中层大气底部区域，呈现出复杂的垂直分层结构^[1,2]。该区域大气密度急剧下降、温度结构复杂多变，且受太阳活动、地磁扰动等多因素耦合作用，呈现出强烈的时空变异性^[3]。近年来研究表明，平流层扰动、重力波活动和湍流过程在空天过渡区表现进一步增加了该区域大气环境的复杂性^[4]。50~70 km 的临近空间是空天过渡区的重要组成部分。由于该区域物理环境独特，准确预测其风场特征对于保障航天器安全运行、优化发射窗口选择以及提升火箭拦截精度等具有重要战略意义^[5-7]。

传统数值天气预报模式在空天过渡区风场预测中面临诸多挑战。现有全球环流模式如欧洲中期天气预报中心（European Centre for Medium-Range Weather Forecasts, ECMWF）再分析数据虽覆盖该高度范围，但受限于稀疏观测网络和复杂物理过程参数化方案，预报精度和时效性难以满足实际需求^[8,9]。其次，多高度层建模不足，缺乏针对不同高度层大气物理特征差异的专门处理策略。此外，50 km 以上高度的风场预报误差较大，制约了航天任务的精确制导能力，且传统数值模式计算复杂度高，难以实现高时空分辨率的实时预测^[10]。

近年来，深度学习技术在气象预测领域展现出巨大潜力^[11]。时空序列预测方法如卷积长短期记忆（convolutional long short-term memory, ConvLSTM）网络^[12]和卷积门控循环单元（convolutional gated recurrent unit, ConvGRU）^[13]通过结合卷积操作与循环神经网络，能够有效捕获大气变量的时空演化特征^[14]。Sun 等^[15]将 ConvLSTM 和 ConvGRU 应用于深度学习的近空间大气温度和风短期预报模型研究，虽然能够有效捕获局部时空特征，但其局部感受野和逐步传播机制限制了对空天过渡区大尺度环流模式的建模能力。

算子学习作为新兴的深度学习范式，通过学习从函数到函数的映射关系，为求解偏微分方程提供了革命性思路。深度算子网络（deep operator network, DeepONet）通过分支网络和主干网络的协同作用，理论上能够逼近任意连续算子，并在多个物理建模任务中展现出良好性能^[16-18]。然而，DeepONet 在处理高维时空数据时面临参数量激增和训练效率低下的问题^[19]。

傅里叶神经算子（Fourier neural operator, FNO）作为另一类算子学习方法，通过在频域建立输入输出函数映射，实现了对偏微分方程解的高效逼近^[20,21]。FNO 利用快速傅里叶变换的全局感受野特性，能够以 $O(n \log n)$ 的计算复杂度捕获大气运动的多尺度相互作用^[22]。Li 等^[23]将 FNO 应用于 Navier-Stokes 方程求解，相比传统有限差分方法提升了 3 个数量级的计算效率。Pathak 等^[24]进一步证明了 FNO 在气候建模中的优越性。但标准 FNO 在处理空天过渡区多高度层耦合特征时存在对不同高度层物理特征差异建模不足等局限性，其在空天过渡区多高度层风场预测中的应用仍待深入探索。

MERRA-2（Modern-Era Retrospective Analysis for Research and Applications, Version 2）再分析数据集基于 GEOS-5 模式，垂直覆盖地表至近 80 km 高度，为空天过渡区大气研究提供了高质量数据基础^[25,26]。充分挖掘 MERRA-2 数据中蕴含的大气动力学规律，结合遥感反演技术和先进的机器学习算法，有望突破传统预报方法的技术瓶颈^[27,28]。

针对空天过渡区不同高度层大气物理特征存在显著差异的特点，现有研究缺乏专门的高度感知建模策略。传统 FNO 对所有高度层采用相同的处理方式，难以有效区分不同高度层的物理重要性。因此，发展能够自适应处理多高度层特征差异的改进算子学习方法，对提升空天过渡区风场预测精度具有重要意义。

1 数据与方法

1.1 数据源与预处理

1.1.1 MERRA-2 再分析数据

实验采用美国国家航空航天局（National Aeronautics and Space Administration, NASA）提供的 MERRA-2 再分析数据集^[26]。该数据集基于 GEOS-5 模式，垂直覆盖地表至 80 km 高度，为空天过渡区研究提供了高质量数据基础。选取 2020 年 1 月至 2024 年 12 月期间的纬向风（U）、经向风（V）数据，聚焦中国及周边区域（15° N—55° N, 70° E—140° E），涵盖 50 km、60 km、70 km 等关键高度层。

数据时间分辨率为 3 h，每日 8 个时次，共获得约 14 600 个时次样本。原始数据空间维度为 81 × 113 网格点，对应纬度方向 0.5° 间隔、经度方向 0.625° 间隔的空间分辨率。基于纬向风 U 和

经向风 V 计算风速场:

$$\text{风速} = \sqrt{(U^2 + V^2)} \quad (1)$$

数据预处理过程中, 进行了数据质量控制, 在物理合理性方面, 剔除负风速值、超出物理上限的极值和存在明显不连续跳跃的异常数据点。在时间一致性上, 识别时间序列中的突变点, 采用 3σ 准则剔除偏离时间平均超过 3 个标准差的数据。空间一致性中, 对每个格点的数据与其 8 个邻近格点进行对比, 剔除空间梯度异常的数据点。同时对缺失率 $<5\%$ 的时间序列采用线性插值, 缺失率 $>5\%$ 的序列标记为无效并从训练集中剔除, 确保了训练数据的质量。进一步提取空天过渡区对应 50 km、60 km、70 km 高度层数据, 与 MERRA-2 数据集中模式层一一对应。

1.1.2 多高度层感知预处理

针对空天过渡区不同高度层大气环境的显著差异, 设计了多高度层感知的数据预处理框架。空天过渡区大气密度从 50 km 的约 10^{-3} kg/m³ 递减至 70 km 的约 10^{-5} kg/m³, 风速变异性随高度显著增强, 传统的全局标准化方法难以有效处理这种多尺度变化特征。

采用鲁棒标准化方法分别对各高度层风速数据进行归一化处理:

$$\tilde{u}_{h,i,j} = \frac{u_{h,i,j} - \text{median}(u_h)}{IQR(u_h)} \quad (2)$$

其中, $\tilde{u}_{h,i,j}$ 为标准化后的风速值; $u_{h,i,j}$ 为原始风速数据; h 表示高度层; (i,j) 为空间网格坐标; $\text{median}(u_h)$ 表示第 h 高度层所有数据的中位数; $IQR(u_h)$ 表示第 h 高度层数据的四分位距。

为保持空天过渡区垂直大气结构的物理连续性, 引入高度层间耦合调整机制:

$$v_{h_Coupled} = w_{\text{main}} * v_{h_Original} + w_{\text{Coupled}} * \sum_{k \in N_h} w_k * v_{k_Original} \quad (3)$$

其中, $v_{h_Coupled}$ 为第 h 高度层耦合调整后的风速数据, $v_{h_Original}$ 为第 h 高度层的原始风速数据, w_{main} 为主导权重系数, 控制当前层自身信息

的保留程度, w_{Coupled} 为耦合权重系数, 控制相邻层信息的融合程度, N_h 表示第 h 高度层的邻近高度层索引集合, w_k 为邻近层 k 的归一化权重, 满足 $\sum_{k \in N_h} w_k = 1$ 。

因大气垂直结构具有连续性, 相邻高度层之间存在动力学和热力学联系。主导权重 s 确保每层保持主要的大气特征, 耦合权重项 w_{Coupled} 引入相邻层的影响, 模拟大气动力学中重力波传播、湍流扩散等垂直耦合过程, 具有物理意义。

1.2 损失函数设计

考虑到不同高度层物理特征差异, 设计了融合空间梯度约束的自适应损失函数:

$$L_{\text{Total}} = \alpha L_{\text{mse}} + \beta L_{\text{gard}} + \gamma L_{\text{height}} \quad (4)$$

$$L_{\text{mse}} = \frac{1}{N} \sum_{i=1}^N \sum_{h=1}^H w_h \| u_{\text{pred}}^{(h,i)} - u_{\text{true}}^{(h,i)} \|_2^2 \quad (5)$$

$$L_{\text{gard}} = \frac{1}{N} \sum_{i=1}^N \sum_{h=1}^H (\| \nabla_x u_{\text{pred}}^{(h,i)} - \nabla_x u_{\text{true}}^{(h,i)} \|_2^2 + \| \nabla_y u_{\text{pred}}^{(h,i)} - \nabla_y u_{\text{true}}^{(h,i)} \|_2^2) \quad (6)$$

$$L_{\text{height}} = \frac{1}{H} \sum_{h=1}^H w_h \cdot \frac{1}{N_h} \sum_{i=1}^{N_h} (y_i^{(h)} - \hat{y}_i^{(h)})^2 \quad (7)$$

其中, L_{Total} 为总损失函数, L_{mse} 为均方误差损失, L_{gard} 为空间梯度损失, 用于约束预测场的空间连续性。 L_{height} 为高度感知权重正则化损失 α 为均方误差权重, β 为梯度损失权重, γ 为高度正则化权重。

多项损失函数的设计兼顾了预测精度、空间连续性和物理合理性三个方面, 彰显了高度感知傅里叶神经算子 (height-aware Fourier neural operator, HAFNO) 对大气物理约束的综合考虑。

1.3 模型方法

为全面评估 HAFNO 在空天过渡区风场预测中的性能优势, 选择了四种代表性深度学习模型作为基准: FNO、ConvLSTM、ConvGRU 和 DeepONet 模型。各模型的算法特征和参数设置

如表 1 所示。

表 1 基准模型算法特征与参数设置对比

Tab.1 Algorithm characteristics and parameter settings
comparison of baseline models

模型	时间复杂度	主要参数设置	相对训练时间 /倍	相对推理时间 /倍
频率模式: 16×16				
HAFNO	$O(n \log n)$	高度层权重: 可学习参数	1.15	1.18
频率模式: 16×16				
FNO	$O(n \log n)$	频率截断策略: 统一处理	1.00	1.00
卷积核: 3×3				
ConvLSTM	$O(k n)$	门控机制: 输入门 + 遗忘门 + 输出门	2.8	2.6
卷积核: 3×3				
ConvGRU	$O(k n)$	门控机制: 重置门 + 更新门	2.4	2.2
分支网络: 128 维 全连接 主干网络: 128 维 全连接				
DeepONet	$O(mn+np)$		4.2	3.8

注: n 为空间网格总数; k 为卷积核大小; m 为分支网络输入维度; p 为基函数个数。

HAFNO 具有全局感受野和高度感知权重机制, 计算效率高; FNO 具有全局感受野和分辨率不变性, 但缺乏高度层差异化处理能力; ConvLSTM 和 ConvGRU 时空建模能力强, 但受限于局部感受野; DeepONet 理论基础完备, 但高维处理效率低。

1.3.1 傅里叶神经算子

傅里叶神经算子由 Li 等^[20]提出, 是一种基于频域操作的神经网络架构, 专门用于学习无限维函数空间之间的映射关系。FNO 的核心思想是利用傅里叶变换将输入函数从空间域转换到频域, 在频域中进行卷积操作, 然后通过逆傅里叶变换返回空间域^[21]。

FNO 通过在频域中参数化积分算子实现函数到函数的映射。对于输入函数 u , FNO 通过学习算子 G , 使得 $G(u) = v$, v 为输出函数。核心的傅里叶积分算子定义为:

$$R_\phi(x) = \int_D K(x, y)\phi(y)dy \quad (8)$$

通过快速傅里叶变换, 该积分在频域中变为简单的乘法运算:

$$F(R_\phi) = R \cdot F(\phi) \quad (9)$$

其中 R 为频域中的可学习权重矩阵。标准 FNO 的更新规则为:

$$v_{l+1} = \sigma(W \cdot v_l + K(v_l)) \quad (10)$$

其中, $K(\phi)(x) = F^{-1}(R \cdot F(\phi))(x)$ 为傅里叶积分算子, W 为线性变换矩阵, σ 为激活函数, l 为层索引。

FNO 实现了 $O(n \log n)$ 的计算复杂度, 显著优于传统卷积神经网络的 $O(k^2 n)$ 复杂度, 同时具有分辨率不变性, 即在任意网格分辨率上训练的模型可以直接应用于其他分辨率^[23]。Pathak 等^[24]将 FNO 应用于全球天气预报, 相比传统数值模式显著提升了计算效率。

标准 FNO 采用统一的频率截断策略, 保留前 16×16 个频率模式, 包含 4 层傅里叶积分算子层, 隐藏维度设置为 64。然而, 标准 FNO 在处理空天过渡区多高度层数据时存在局限性: 对所有输出通道采用相同的处理策略, 无法区分不同高度层的物理特征差异, 难以有效处理空天过渡区垂直结构的复杂性。

1.3.2 高度感知傅里叶神经算子 (HAFNO)

针对空天过渡区不同高度层大气物理特征差异显著的特点, 提出高度感知傅里叶神经算子 (HAFNO)。HAFNO 在标准 FNO 基础上引入高度感知权重机制, 实现对不同高度层的自适应建模。模型架构包含四个关键组件:

1) 输入投影层

将多时间步、多高度层输入数据投影至高维特征空间:

$$v_0(x) = P(u(x)) \quad (11)$$

其中 P 为输入投影层; 将输入维度 $[8, 3, 81, 113]$ (时间步 \times 高度层 \times 纬度 \times 经度) 提升至模型隐藏维度 $d=64$ 。

2) 高度感知傅里叶积分算子层

设高度层数为 H , 对高度 h 的原始风场记为 $u_h(i, j, t)$ 。定义高度权重参数向量 $\mathbf{b} = [b_1, \dots, b_H]$ 高度权重为:

$$\alpha_h = \frac{\exp(b_h)}{\sum_{r=1}^H \exp(b_r)}, \quad h=1, \dots, H. \quad (12)$$

每一层傅里叶积分算子在频域上以 R_h^l 表示，

对第 h 层的特征 v_h^l 的操作为：

$$K_h^l(v_h^l) = F^{-1} \left(R_h^l \odot F(v_h^l) \right) \quad (13)$$

其中 F 与 F^{-1} 分别为傅里叶变换与逆变换， \odot 表示逐元素乘法。

结合高度感知权重机制，HAFNO 层的更新规则为：

$$v_h^{l+1} = \sigma(K_h(v_h^l) + W_h(v_h^l))\alpha_h \quad (14)$$

其中 W_h^l 为第 l 层中针对第 h 高度层的频域权重矩阵。

训练中高度感知权重 α_h 会在物理过程活跃的高度层会获得较大权重，噪声较大的高度层权重会抑制。通过特定的权重矩阵 W_h^l 对中小尺度扰动（高频成分）及大尺度环流模式（低频成分）进行频域分层处理。高度感知权重的更新遵循大气分层稳定性原理，通过损失函数中的正则化项确保相邻高度层权重符合物理规律。

3) 输出投影层

将高维特征映射回目标空间：

$$u(x) = Q \left(\sum_{h=1}^H \alpha_h \odot v_h^L(x) \right) \quad (15)$$

其中， Q 为输出投影层； L 为 HAFNO 层数。

HAFNO 相对于标准 FNO 的主要改进体现在以下方面：

1) 高度感知权重机制

通过可学习的高度层权重 α_h ，HAFNO 能够自适应学习不同高度层的重要性，针对空天过渡区各高度层大气密度、动力学特征的显著差异进行专门处理。

2) 多高度层耦合处理

HAFNO 在数据预处理阶段采用高度层间耦合调整机制，在模型架构中通过加权融合保持空天过渡区垂直大气结构的物理连续性。

3) 自适应损失函数

HAFNO 采用融合空间梯度约束和高度感知权重的自适应损失函数，能够更好地约束预测场的空间连续性和物理合理性。

HAFNO 理论优势具体体现在：

1) 全局感受野特性

HAFNO 继承了 FNO 的全局感受野特性，通过快速傅里叶变换直接在频域操作，能够一步捕获任意距离的空间相关性，对空天过渡区大尺度环流模式和波动传播过程的建模起关键作用。

2) 计算复杂度优势

HAFNO 的计算复杂度为 $O(n \log n)$ ，高度感知权重机制仅为每个高度层增加少量可学习参数，对整体计算复杂度影响微乎其微。

3) 高度感知建模能力

通过公式(12)-(15)的高度感知权重机制，HAFNO 能够自动学习不同高度层的相对重要性，实现了针对空天过渡区垂直结构特征的专门优化。

4) 高度感知权重的物理意义

高度感知权重机制的设计基于空天过渡区垂直分层的物理特征。该区域不同高度层的大气密度、观测数据质量和动力学过程复杂度存在显著差异^[29]。通过引入可学习的高度权重，模型能够自适应地调整对不同高度层的关注程度，在数据质量较好的低层发挥更强的拟合能力，同时对高层数据的不确定性具有一定的抑制作用。模型经训练后，呈现出权重随高度递减的现象，与物理规律相符，同时与大气密度的垂直衰减特征以及观测数据质量的垂直分布相一致。使用数据驱动与物理约束相结合的建模方式，使 HAFNO 能够更有效地处理空天过渡区多高度层的复杂特征。

5) 与现有分层方法的比较

当前常见的方法包括逐高度独立建模、多分支或多尺度方法以及基于嵌入或注意力机制的方法。前者通常为每个高度层单独训练模型，难以体现层间物理联系，且参数开销较大；多分支或多尺度方法主要针对空间尺度特征分解，未对高度层差异进行专门优化；而嵌入或注意力机制虽然能够在时空网络中引入高度信息，但多停留在输入特征层面，未在核心算子上直接作用^[30-32]。

与这些方法不同，HAFNO 在傅里叶算子层面引入高度感知机制，使不同高度层在频域的特征表达既能共享，又能区分，从而在效率与差异化建模之间实现平衡，具有更强的空天过渡区多高度层风场预测能力。

HAFNO 多高度层风场预测技术流程如图 1

所示。

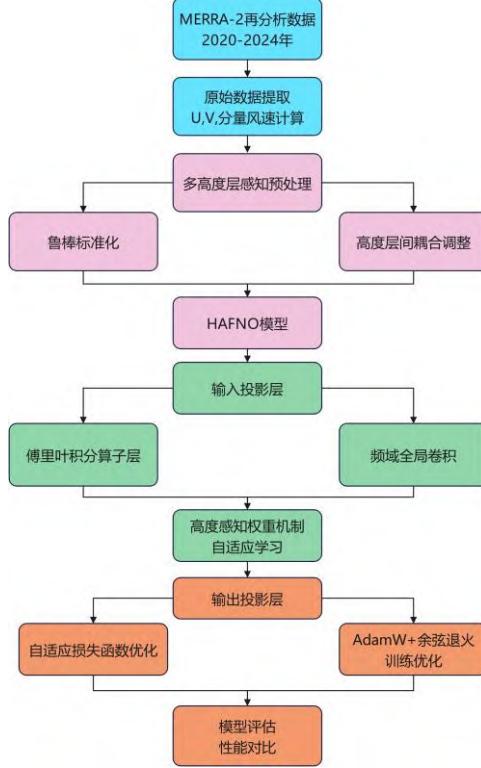


图 1 HAFNO 多高度层风场预测框架流程图
Fig.1 HAFNO multi-altitude layer wind field prediction framework flowchart.

1.3.3 ConvLSTM 模型

ConvLSTM 将传统 LSTM 的全连接操作替换为卷积操作，能够同时捕获时间依赖性和空间相关性^[12]。其核心更新方程为：

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \cdot C_{t-1} + b_i) \quad (16)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \cdot C_{t-1} + b_f) \quad (17)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \cdot C_t + b_o) \quad (18)$$

$$\tilde{C}_t = \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (19)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (20)$$

$$H_t = o_t \cdot \tanh(C_t) \quad (21)$$

式中：*表示卷积操作，·表示 Hadamard 积；

i_t, f_t, o_t 分别为输入门、遗忘门和输出门。实验中采用 3 层 ConvLSTM 结构，卷积核大小设置为 3×3 ，隐藏状态维度为 64。

1.3.4 ConvGRU 模型

ConvGRU 通过简化 LSTM 的门控结构，在保持时空建模能力的同时降低了计算复杂度^[13]。其更新机制为

$$z_t = \sigma(W_{xz} * X_t + W_{hz} * H_{t-1} + b_z) \quad (22)$$

$$r_t = \sigma(W_{xr} * X_t + W_{hr} * H_{t-1} + b_r) \quad (23)$$

$$\tilde{H}_t = \tanh(W_{xh} * X_t + W_{hh} * (r_t \cdot H_{t-1}) + b_h) \quad (24)$$

$$H_t = (1 - z_t) \cdot H_{t-1} + z_t \cdot \tilde{H}_t \quad (25)$$

实验配置与 ConvLSTM 相同，同样采用 3 层结构。

1.3.5 DeepONet 模型

DeepONet 由分支网络（Branch Net）和主干网络（Trunk Net）组成，学习从输入函数到输出函数的算子映射 $G: u \rightarrow G(u)$ 分支网络处理输入函数的离散化表示^[16]。主干网络处理查询点坐标，两者通过内积操作实现算子逼近，输入函数 $u(x)$ 和查询点 y ，DeepONet 的输出为：

$$G(u)(y) = \sum_{k=1}^p b_k(u) \cdot t_k(y) \quad (26)$$

其中， $b_k(u)$ 为分支网络输出， $t_k(y)$ 为主干网络输出， p 为基函数个数。

2 实验结果与结果分析

2.1 实验设置

将 2020—2024 年 MERRA-2 数据按时间顺序划分为训练集（70%）、验证集（15%）和测试集（15%）。采用滑动窗口方式构建输入输出序列，所有模型采用 AdamW 优化器，设置初始学习率，权重衰减系数，使用余弦退火学习率调度策略、早停策略和梯度裁剪。所有实验均在 NVIDIA RTX4090 GPU 上进行。

模型泛化能力方面，HAFNO 的设计原理具有全球适用性。傅里叶神经算子的分辨率不变性使其可适应不同空间分辨率，高度感知权重机制基于大气垂直分层的物理规律（密度指数衰减、温度结构分层），这些规律在全球范围内普遍，频域操作不依赖特定的地理坐标系统。中国及周边区域（ 15° N- 55° N, 70° E- 140° E）涵盖热带至温带多种气候带，包含青藏高原、山地、平原、海洋等复杂地形，具有丰富的大气动力学特征（东亚季风、西风急流、高原热力强迫等），对验证模型的泛化能力具有代表性。

参数敏感性分析方面，对 HAFNO 的关键超参数进行敏感性测试，傅里叶模式数 16×16 为最优设置， 8×8 时性能下降约 12% 左右， 32×32 时提升有限但计算成本增加明显；隐层宽度 64 为最

优, FNO 层数 4 层最优, 2 层时性能下降约 15%, 6 层及以上时出现过拟合现象。

2.2 评估指标

气象预报模型评估需要从预测精度、相关性和偏差等多个维度进行综合评价。根据世界气象组织 (World Meteorological Organization, WMO) 推荐的标准气象预报评估框架和空天过渡区风场预测的特殊要求, 采用四个标准评估指标:

1) 均方根误差 (root mean square error, RMSE)

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (27)$$

2) 平均绝对误差 (mean absolute error, MAE)

$$M_{\text{AE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (28)$$

3) 皮尔逊相关系数 (pearson correlation coefficient, R)

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (29)$$

4) 决定系数 (coefficient of determination, R^2)

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (30)$$

其中: y_i 为观测值; \hat{y}_i 为预测值; \bar{y} 为观测值均值; $\bar{\hat{y}}$ 为预测值均值; n 为样本数。

四个指标相互补充, 能够全面评估 HAFNO 在空天过渡区风场预测中的性能表现。

2.3 模型性能对比

2.3.1 各高度层预测性能比较

为全面评估 HAFNO 模型在空天过渡区风场预测中的性能优势, 对比了五种模型在不同高度层的预测准确性、空间误差特征和极值响应能力。表 2 展示了五种模型在 50 km、60 km、70 km 高度层的平均预测性能。

表 2 不同模型在各高度层的预测性能对比

Tab.2 Prediction performance comparison of different models at each altitude layer

模型	高度层/km	RMSE (m/s)	MAE (m/s)	Corr	R^2
----	--------	---------------	--------------	------	-------

模型	高度层/km	RMSE (m/s)	MAE (m/s)	Corr	R^2
HAFNO	50	2.065	1.572	0.994	0.988
	60	3.001	2.274	0.990	0.980
	70	4.975	3.837	0.973	0.947
FNO	50	2.250	1.726	0.993	0.985
	60	3.242	2.474	0.988	0.976
	70	5.356	4.153	0.969	0.938
ConvLSTM	50	2.531	1.921	0.990	0.981
	60	3.632	2.780	0.985	0.970
	70	5.777	4.483	0.964	0.929
ConvGRU	50	2.622	1.984	0.990	0.979
	60	3.374	2.843	0.984	0.968
	70	5.819	4.506	0.963	0.928
DeepONet	50	6.352	4.478	0.944	0.882
	60	7.403	5.336	0.940	0.877
	70	8.856	6.788	0.914	0.831

从整体性能来看, HAFNO 在所有高度层和评估指标上均展现出最优性能。在 50 km 高度层, HAFNO 的 RMSE 为 1.572 m/s, MAE 为 2.065 m/s, 相关系数高达 0.994, 决定系数 R^2 达到 0.988。相比标准 FNO, HAFNO 在 50 km、60 km、70 km 高度层的 RMSE 分别降低 11.8%、12.8%、11.7%, 平均降幅达 12.1%。ConvLSTM 和 ConvGRU 的性能相近, RMSE 分别为 1.921 m/s 和 1.984 m/s, 而 DeepONet 的性能明显落后, RMSE 高达 4.478 m/s, 相关系数仅为 0.944。

随着高度增加, 各模型的预测误差均有增长, 这种误差增长趋势与空天过渡区大气密度急剧下降、观测资料稀缺以及物理过程复杂度增加密切相关。但 HAFNO 增长幅度最小, 展现出其良好的高度适应性与稳定性。特别是在 70 km 高度层, HAFNO 相比其他模型的优势更加明显, 体现了高度感知权重机制的有效性。

2.3.2 计算效率分析

基于表 1 的理论复杂度和实际测试结果, HAFNO 的计算复杂度为 $O(n \log n + H \cdot c)$, 其中高度感知处理的额外成本 $H \cdot c$ 相对较小, 且 $H \ll n$ ($H=3$, $n=9,153$), 总体复杂度仍主要由 $O(n \log n)$ 项主导。实际测试验证了这一复杂度特征, HAFNO 相对于 FNO 增加 15% 的训练时间和 18% 的推理时间, ConvLSTM 和 ConvGRU 的计算开销分别是 FNO 的 2.8 倍和 2.4 倍, DeepONet 为 4.2 倍。结果表明, HAFNO 在不同数据规模下均

s 保持良好的计算效率，实现了效率与精度的良好平衡。

2.3.3 空间误差分布分析

图 2 展示了 HAFNO 模型在不同高度层的空间场分布对比。从预测值平均场可以看出，HAFNO 能够准确重现不同高度层的风速空间分

布特征，预测场与真实场高度一致。误差场分析显示，50 km 和 60 km 的误差主要集中在地形复杂区域，与地形强迫和海陆热力差异密切相关。70 km 误差分布相对均匀，反映出高层大气受地形影响减弱的物理特征。误差幅度整体可控，说明 HAFNO 具备较强的空间泛化能力。

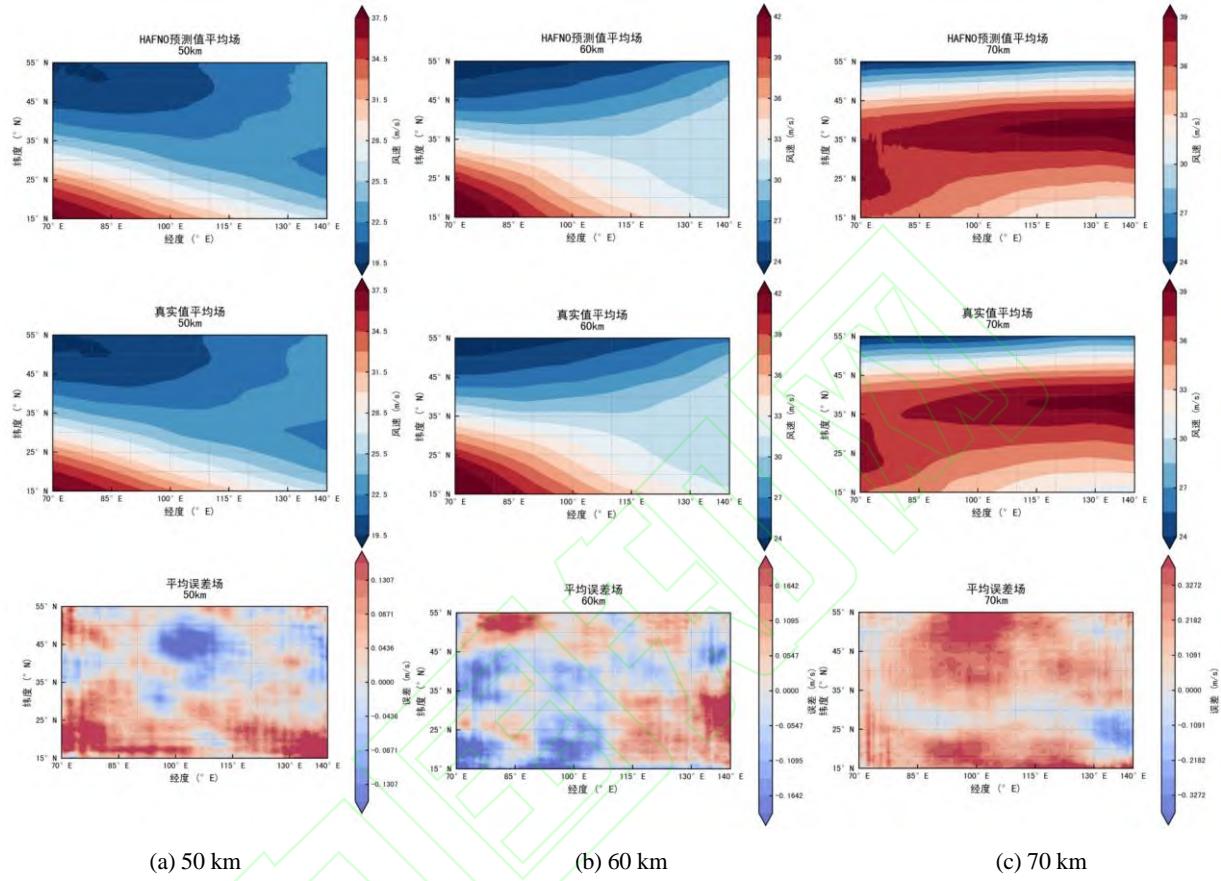


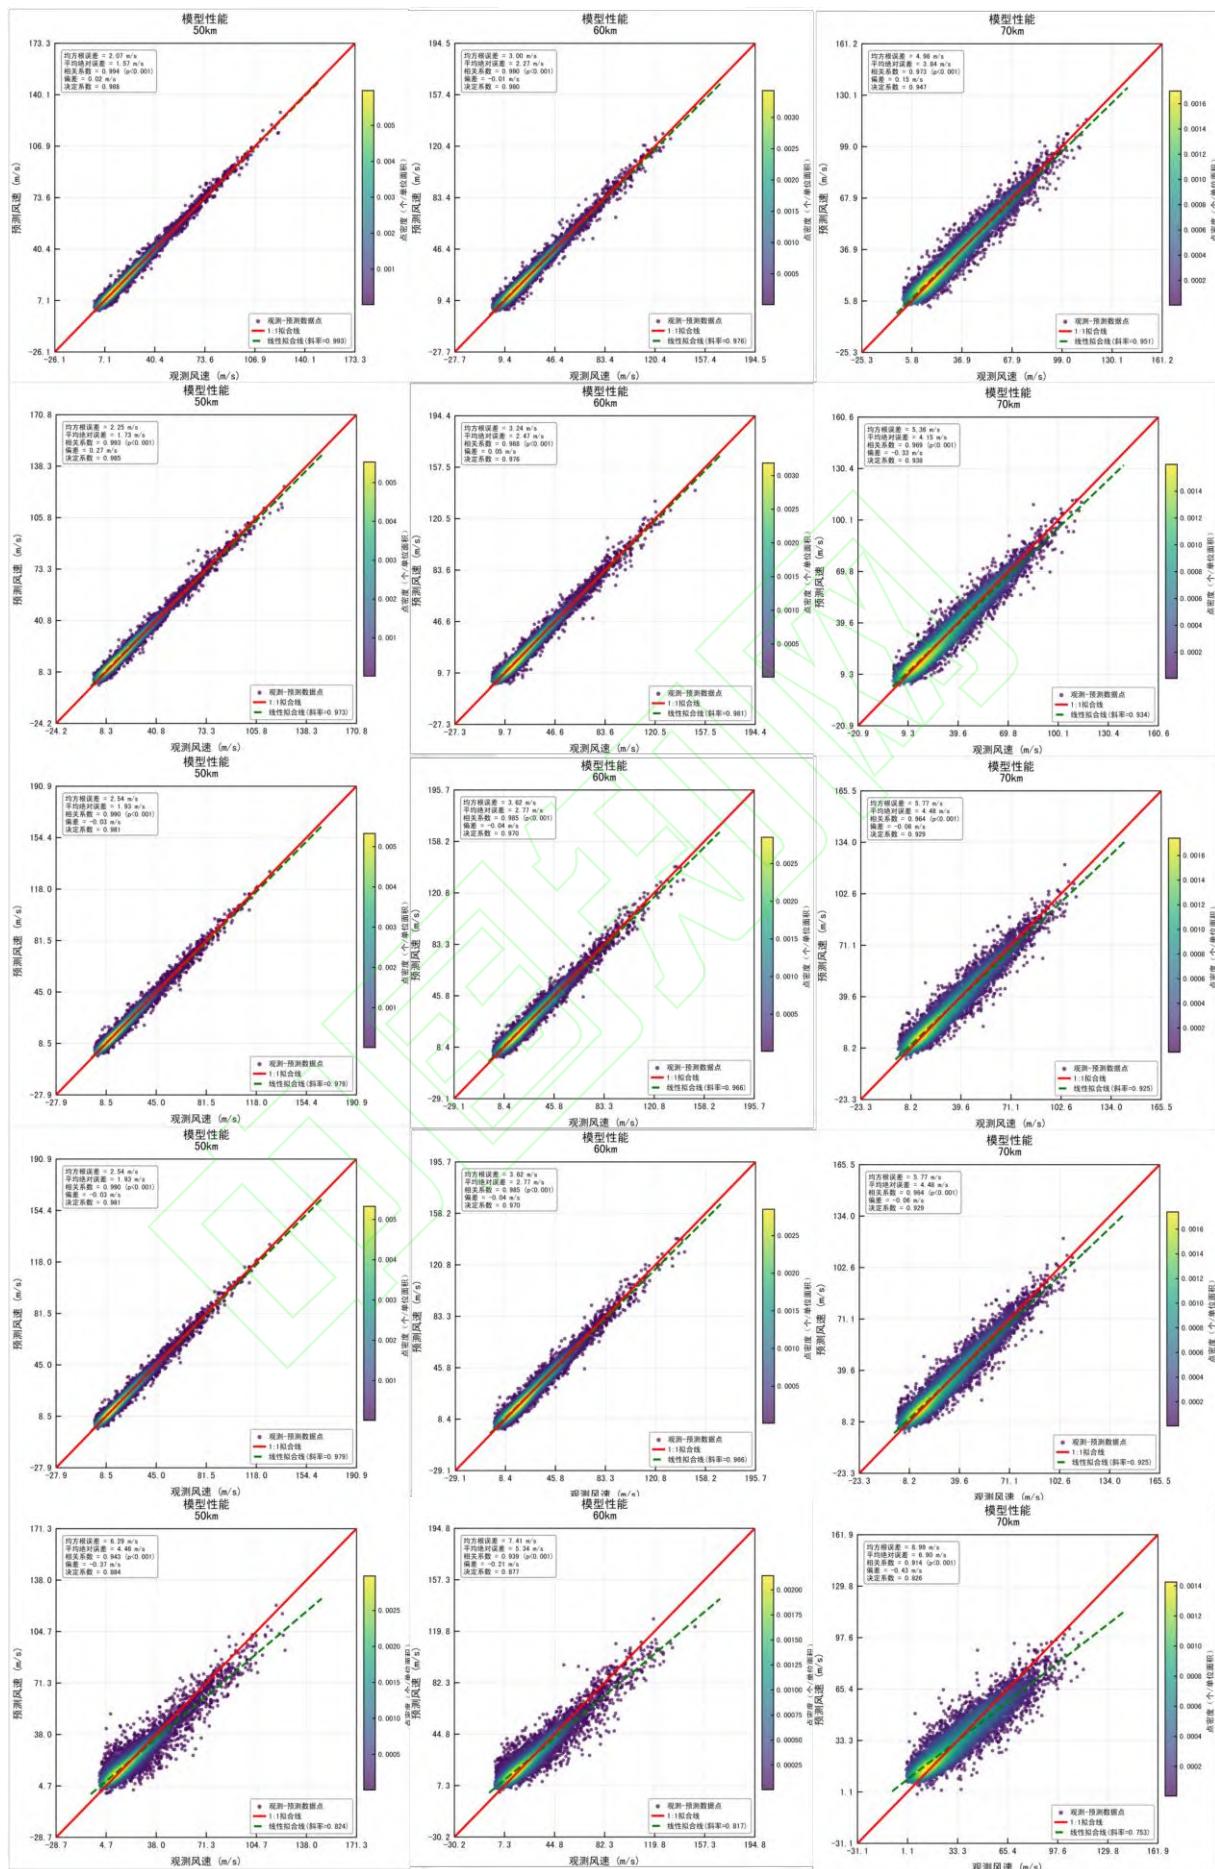
图 2 HAFNO 在 50-70km 高度层的风场预测结果

Fig.2 Wind field prediction results of HAFNO at altitude layers of 50-70km

2.3.4 预测性能散点图分析

图 3 展示了 HAFNO 和 FNO、ConvLSTM、ConvGRU 以及 DeepONet 基准模型在不同高度层的预测性能散点图。散点图显示 HAFNO 在所有高度层均展现出优异的预测性能，预测值与观测

值高度一致，数据点紧密分布在 1:1 线附近。随着高度增加，虽然数据离散度有所增加，但各项评价指标依然保持较高水平，体现了 HAFNO 良好的高度适应性。



(a) 50 km

(b) 60 km

(c) 70 km

图 3 各模型在 50-70km 高度层预测性能散点图

Fig.3 Scatter plot of prediction performance of each model at an altitude of 50-70km

误差分布直方图显示, HAFNO 的预测误差呈近似正态分布, 误差均值接近零, 表明模型无明显系统性偏差。50 km 高度层误差标准差最小, 60 km 和 70 km 高度层误差标准差逐渐增大, 但增长幅度合理且可控, 符合空天过渡区大气物理特性随高度变化的规律。HAFNO 的散点图数据点分布集中, 误差分布的正态性显著, 反映出 HAFNO 在减少异常预测、提高预测稳定性方面的优势。

2.3.5 模型综合性能对比分析

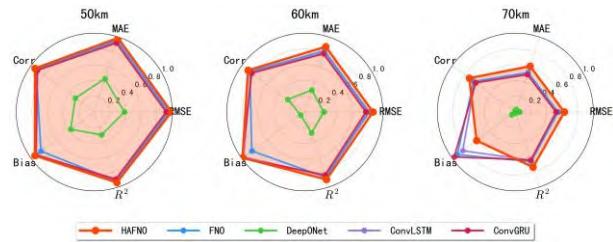
图 4 展示了五种深度学习模型在空天过渡区风场预测中的全方位性能对比分析, 包括多维度雷达图矩阵和综合性能评估条形图。雷达图采用归一化处理, 将 RMSE、MAE、相关系数、偏和决定系数等五个关键指标统一映射至[0,1]区间, 其中 1 表示最优性能, 便于直观比较不同模型在各评估维度的相对优势。

从雷达图矩阵可以看出, HAFNO 在所有高度层和评估指标上均表现出最均衡且优异的性能。在 50 km 高度层, HAFNO 的雷达图呈现最接近外圈的五边形, 表明其在各项指标上均达到最优水平。随着高度增加至 60 km 和 70 km, 虽然所有模型的整体性能均有所下降, 但 HAFNO 的性能衰减幅度最小, 保持了良好的高度适应性和预测稳定性。

FNO 作为 HAFNO 的基线模型, 在各高度层均表现出次优性能, 但相比 HAFNO 在高度感知能力方面存在明显不足。ConvLSTM 和 ConvGRU 的雷达图形状相似, 在时空建模方面具有一定优势, 但受限于局部感受野特性, 在捕获大尺度大气环流模式方面能力有限。DeepONet 在理论完备性方面具有优势, 但在处理高维时空数据时性能明显落后于其他模型。

雷达图中数值已归一化至[0,1]范围, 1 表示最优性能, 综合性能评估采用加权平均方法, 综合得分权重分配为 RMSE(25%), MAE(20%), Corr(25%), Bias(10%)和 R^2 (20%)。HAFNO 的综合得分达到 0.843, 显著优于其他四种模型。HAFNO 相比标准 FNO 提升了 7.4%, 相比最佳循环神经网络模型 ConvLSTM 提升了 12.0%, 相比神经算子模型 DeepONet 提升了 38.4%。HAFNO 在高度感知建模能力方面的显著优势。通过引入可学习的高度权重机制, HAFNO 能够自适应调整不同

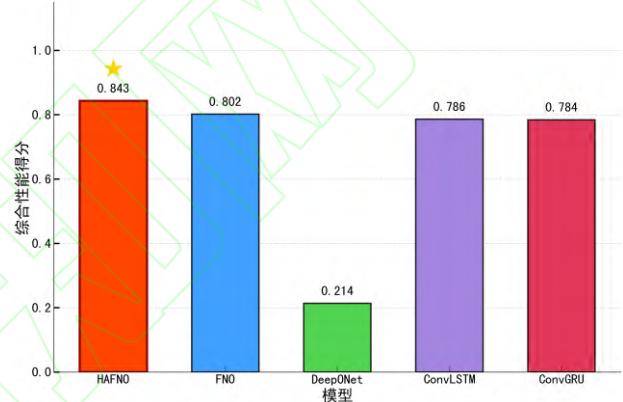
高度层的重要性, 有效处理空天过渡区垂直结构的复杂性。



(a) 各模型在不同高度层 (50 km, 60 km, 70 km)

的归一化性能雷达图对比

(a) Normalized performance radar chart comparison of all models at different altitudes



(b) 各模型综合性能评估条形图

(b) Comprehensive performance evaluation bar chart of all models

图 4 模型性能全方位对比分析

Fig.4 Comprehensive performance comparison analysis of models.

2.3.6 统计显著性检验

在表 2 给出常规精度指标的基础上, 为进一步验证模型性能差异的显著性与稳健性, 本研究采用了三种非参数统计检验方法: Wilcoxon 秩和检验、Friedman 检验与 Kolmogorov-Smirnov (KS) 检验^[33-35]。结果表明, HAFNO 与对比模型之间的性能差异在统计意义上均显著 ($p<0.01$), 验证了 HAFNO 模型的有效性与稳健性。

2.3.7 长期预测性能评估

为测试 HAFNO 在长时间预报中的误差累积特性, 我们进行了预测实验, 即将前一时刻的预测结果作为下一时刻的输入, 逐步推进至 12 小时和 24 小时。实验结果如表 3 所示。结果表明,

HAFNO 的预测误差随时长呈次线性增长: 24 小时 RMSE 相对 3 小时的增长倍数为 2.45-3.67 倍, 优于传统数值模式误差增长^[36]。12 小时预测时, 所有高度层相关系数仍保持在 0.944 以上, $R^2 > 0.89$, 显示出较好的中期稳定性。实际应用中可通过定期同化观测数据来重置模型状态, 有效抑制误差累积, 为今后业务化应用提供可能。

表 3 HAFNO 长期预测稳定性测试结果

Tab.3 Long-term forecast stability test results of HAFNO

高度层 /km	预测时长/h	RMSE /(m/s)	MAE /(m/s)	相关系数	误差增长倍数
50	3	1.572	2.065	0.994	1.00×
	12	4.653	3.440	0.966	2.96×
	24	5.773	4.122	0.947	3.67×
60	3	2.274	3.001	0.990	1.00×
	12	5.770	4.313	0.957	2.54×
	24	7.329	5.338	0.924	3.22×
70	3	3.837	4.975	0.973	1.00×
	12	7.617	5.965	0.944	1.99×
	24	9.400	7.104	0.907	2.45×

3 结论

针对空天过渡区复杂大气环境下风场预测的技术挑战, 创新性地将傅里叶神经算子引入该领域, 提出了高度感知傅里叶神经算子 (HAFNO) 风场预测方法。通过引入高度感知权重机制、多高度层鲁棒标准化预处理和融合空间梯度约束的自适应损失函数, 实现了空天过渡区 50~70 km 高度范围内风速场的高精度预测。基于 2020—2024 年 MERRA-2 数据的对比实验验证了方法的有效性, 主要结论如下:

1) HAFNO 在 50~70 km 空天过渡区各高度层风场预测中均表现最优。50 km 高度层 RMSE 为 1.572 m/s, 相关系数达到 0.994; 70 km 高度层 RMSE 为 3.837 m/s, 相关系数保持 0.973。相比 ConvLSTM 和 ConvGRU, 平均 RMSE 分别降低 18.1% 和 16.8%; 相比 DeepONet 降低 47.2%。

2) 创新性地提出的高度感知权重机制有效解决了传统 FNO 难以处理多高度层物理特性差异的技术难题。该机制通过可学习参数自适应调整不同高度层的重要性, 使模型能够突出物理过程活跃的高度层, 抑制噪声较大高度层的影响。

3) HAFNO 通过频域全局感受野有效捕获了

空天过渡区大气运动的多尺度特征。误差分布分析表明, 模型预测误差近似对称、偏度接近零, 未呈现显著系统性偏差; 同时, Wilcoxon 秩和检验与 Friedman 检验结果表明, HAFNO 相较其他方法的性能提升具有统计显著性 ($p < 0.01$)。此外, HAFNO 通过空间梯度损失项隐式考虑了地形影响, 该损失项约束预测场的空间连续性, 能够部分补偿复杂地形引起的流场扭曲。

4) HAFNO 继承了傅里叶神经算子 $O(n \log n)$ 计算复杂度和分辨率不变性优势, 理论上可处理任意分辨率输入数据。高度感知权重机制仅增加极少参数, 对计算效率影响微乎其微, 为空天过渡区大气环境实时预测提供了高效技术途径。

研究成果为空天过渡区大气环境建模提供了新的技术路径, 在航天器轨道预报、高超声速飞行器设计、导弹防御系统等关键领域具有重要应用价值^[30,37-39]。该方法在预测精度、计算效率和物理合理性方面的显著优势, 为空天过渡区大气环境的精确预测和实时监测奠定了技术基础。

未来工作将重点关注以下方向:

- 1) 在全球多区域 (赤道、极地、南半球等) 开展进一步验证, 全面评估模型的全球适用性。
- 2) 探索 HAFNO 与数据同化技术的结合, 建立预报-同化循环系统, 提升长期预测的稳定性和精度。
- 3) 扩展至更高高度层 (80~150 km) 的预测, 为临近空间环境监测提供更全面的技术支撑。进一步提升空天过渡区大气环境预测的综合能力和实用性。

参考文献 (References)

- [1] SHENG Z, HE Y, WANG S C, et al. Dynamics, chemistry, and modeling studies in the aviation and aerospace transition zone[J]. The Innovation, 2025, 6(8): 101012.
- [2] PARK S, LEE S H, IM B, et al. Improvement of a multi-rotor UAV flight response simulation influenced by gust[J]. Aerospace Science and Technology, 2023, 134: 108156.
- [3] KUTIEV I, TSAGOURI I, PERRONE L, et al. Solar activity impact on the Earth's upper atmosphere[J]. Journal of Space Weather and Space Climate, 2013, 3: A06.
- [4] LIAO Q X, MAI Y B, SHENG Z, et al. The comparison of long short-term memory neural network and deep forest for the evaporation duct height prediction[J]. IEEE Transactions on Antennas and Propagation, 2023, 71(5): 4444-4450.
- [5] 程胡华, 武帅, 张入财, 等. 预报风强度对火箭最大气动载荷精度影响及建模分析[J]. 国防科技大学学报,

- 2024, 46(1): 63-73.
- CHENG H H, WU S, ZHANG R C, et al. Influence of forecasting wind intensity on rocket maximum aerodynamic load accuracy and modeling analysis[J]. Journal of National University of Defense Technology, 2024, 46(1): 63-73. (in Chinese)
- [6] 张荣升, 吴燕生, 秦旭东, 等. 基于深度学习的高空风在线估计及预报方法[J]. 航空学报, 2023, 44(13): 327860.
- ZHANG R S, WU Y S, QIN X D, et al. A real-time in-flight wind estimation and prediction method based on deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(13): 327860. (in Chinese)
- [7] SONG Y Y, HE Y, LENG H Z. Analysis of atmospheric elements in near space based on meteorological-rocket soundings over the East China Sea[J]. Remote Sensing, 2024, 16(2): 402.
- [8] PALMER T, STEVENS B. The scientific challenge of understanding and estimating climate change[J]. Proceedings of the National Academy of Sciences of the United States of America, 2019, 116(49): 24390-24395.
- [9] MOLOD A, TAKACS L, SUAREZ M, et al. Development of the GEOS-5 atmospheric general circulation model: evolution from MERRA to MERRA2[J]. Geoscientific Model Development, 2015, 8(5): 1339-1356.
- [10] BI K F, XIE L X, ZHANG H H, et al. Accurate medium-range global weather forecasting with 3D neural networks[J]. Nature, 2023, 619(7970): 533-538.
- [11] WU Y, QIAN C H, HUANG H J. Enhanced air quality prediction using a coupled DVMD informer-CNN-LSTM model optimized with dung beetle algorithm[J]. Entropy, 2024, 26(7): 534.
- [12] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[EB/OL]. (2015-09-19)[2024-12-20]. <https://arxiv.org/abs/1506.04214>.
- [13] CHUNG J Y, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2014-12-11)[2024-12-20]. <https://arxiv.org/abs/1412.3555>.
- [14] LIAO Q X, SHENG Z, ZHOU S D, et al. A preliminary study on the inversion method for the refraction structure parameter from vortex electromagnetic waves[J]. Remote Sensing, 2023, 15(12): 3140.
- [15] SUN X X, ZHOU C, FENG J, et al. Research on short-term forecasting model of global atmospheric temperature and wind in the near space based on deep learning[J]. Atmosphere, 2024, 15(9): 1069.
- [16] LU L, JIN P Z, PANG G F, et al. Learning nonlinear operators via DeepONet based on the universal approximation theorem of operators[J]. Nature Machine Intelligence, 2021, 3(3): 218-229.
- [17] CHEN T P, CHEN H. Universal approximation to nonlinear operators by neural networks with arbitrary activation functions and its application to dynamical systems[J]. IEEE Transactions on Neural Networks, 1995, 6(4): 911-917.
- [18] LU L, MENG X H, MAO Z P, et al. DeepXDE: a deep learning library for solving differential equations[J]. SIAM Review, 2021, 63(1): 208-228.
- [19] CHEN B, SHENG Z, HE Y. High-precision and fast prediction of regional wind fields in near space using neural-network approximation of operators[J]. Geophysical Research Letters, 2023, 50(22): e2023GL106115.
- [20] LI Z Y, KOVACHKI N, AZIZZADEHESHELI K, et al. Fourier neural operator for parametric partial differential equations[EB/OL]. (2021-05-17)[2024-12-20]. <https://arxiv.org/abs/2010.08895>.
- [21] LI Z Y, ZHENG H K, KOVACHKI N, et al. Physics-informed neural operator for learning partial differential equations[J]. ACM/IMS Journal of Data Science, 2024, 1(3): 1-27.
- [22] LIU S J, YU Y, ZHANG T, et al. Architectures, variants, and performance of neural operators: a comparative review[J]. Neurocomputing, 2025, 648: 130518.
- [23] LI Z Y, KOVACHKI N, AZIZZADEHESHELI K, et al. Neural operator: graph kernel network for partial differential equations[EB/OL]. (2020-03-07) [2024-12-20]. <https://arxiv.org/abs/2003.03485>.
- [24] PATHAK J, SUBRAMANIAN S, HARRINGTON P, et al. FourCastNet: a global data-driven high-resolution weather model using adaptive fourier neural operators[EB/OL]. (2022-02-22) [2024-12-20]. <https://arxiv.org/abs/2202.11214>.
- [25] RANDLES C A, DA SILVA A M, BUCHARD V, et al. The MERRA-2 aerosol reanalysis, 1980 - onward, part I: system description and data assimilation evaluation[J]. Journal of Climate, 2017, 30(17): 6823-6850.
- [26] GELARO R, MCCARTY W, SUÁREZ M J, et al. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2)[J]. Journal of Climate, 2017, 30(13): 5419-5454.
- [27] HE Y, ZHU X Q, SHENG Z, et al. Identification of stratospheric disturbance information in China based on the round-trip intelligent sounding system[J]. Atmospheric Chemistry and Physics, 2024, 24(6): 3839-3856.
- [28] LI B, CUI R F, WENG L B. Investigation of the solar activity and QBO effects on the near-space environment[J]. Acta Geophysica, 2025, 73(2): 2127-2136.
- [29] JIANG P S, YANG Z, WANG J L, et al. Efficient super-resolution of near-surface climate modeling using the Fourier neural operator[J]. Journal of Advances in Modeling Earth Systems, 2023, 15(7): e2023MS003800.
- [30] COSTA ROCHA P A, VAN GRIENSVEN THÉ J, OLIVEIRA SANTOS V, et al. Deep learning for atmospheric modeling: a proof of concept using a Fourier neural operator on WRF data to accelerate transient wind forecasting at multiple altitudes[J]. Atmosphere, 2025, 16(4): 394.
- [31] HAKIMI A, GHAFARIAN P. Simultaneous prediction

of 10 m and 100 m wind speeds using a model inspired by brain emotional learning[J]. *Scientific Reports*, 2025, 15(1): 4304.

[32] YE F, ZHANG X X, STEIN M, et al. DeepMIDE: a multivariate spatio-temporal method for ultra-scale offshore wind energy forecasting[EB/OL]. (2024-10-26)[2024-12-20]. <https://arxiv.org/abs/2410.20166>.

[33] WILCOXON F. Individual comparisons by ranking methods[J]. *Biometrics Bulletin*, 1945, 1(6): 80-83.

[34] GARCÍA S, FERNÁNDEZ A, LUENGO J, et al. Advanced nonparametric tests for multiple comparisons in the design of experiments in computational intelligence and data mining: Experimental analysis of power[J]. *Information Sciences*, 2010, 180(10): 2044-2064.

[35] LANZANTE J R. Testing for differences between two distributions in the presence of serial correlation using the Kolmogorov–Smirnov and Kuiper’s tests[J]. *International Journal of Climatology*, 2021, 41(14): 6314-6323.

[36] FRITTS D C, ALEXANDER M J. Gravity wave dynamics and effects in the middle atmosphere[J]. *Reviews of Geophysics*, 2003, 41(1): 2001RG000106.

[37] LAM R, SANCHEZ-GONZALEZ A, WILLSON M, et al. GraphCast: learning skillful medium-range global weather forecasting[J]. *Science*, 2023, 382(6677): 1416-1421.

[38] HE Y, ZHU X, SHENG Z, et al. Resonant waves play an important role in the increasing heat waves in Northern Hemisphere mid-latitudes under global warming[J]. *Geophysical Research Letters*, 2023, 50(14): e2023GL104839.

[39] 盛峥, 虢盛, 冷洪泽, 等. 空天过渡区大气动力学研究重要进展[J]. *空间科学学报*, 2025, 45(4): 899-912. SHENG Z, GUO S, LENG H Z, et al. Major advances in aerospace transition zone atmospheric dynamics research[J]. *Chinese Journal of Space Science*, 2025, 45(4): 899-912. (in Chinese)

