

盘古预报产品融合物理约束深度学习 温度预报方法

蒋健¹ 李明志^{1,2} 李超^{3,4,5} 黄开刚^{1,2} 龙柯吉^{6,7}

- 1 广西壮族自治区百色市气象局, 百色 533000
- 2 中国气象局百色岩溶生态气象野外科学试验基地, 百色 533000
- 3 中国气象局武汉暴雨研究所, 武汉 430205
- 4 暴雨监测预警湖北省重点实验室, 武汉 430205
- 5 中国气象局流域强降水重点开放实验室, 武汉 430205
- 6 四川省气象台, 成都 610072
- 7 高原与盆地暴雨旱涝灾害四川省重点实验室, 成都 610072

摘要: 针对复杂地形区域 2 米气温 (T_{2m}) 精细化预报的挑战, 选取广西这一地形复杂的区域为研究对象, 以盘古天气模型 (Pangu-Weather) 预报产品为基础, 提出了一种融合物理约束的深度学习预报模型 PSD-Net。使用 Pangu-Weather 的预报产品 (PANGU) 作为特征变量输入, 通过基于超分辨率生成对抗网络的生成器提取多尺度特征, 在损失函数中显式引入功率谱密度和 Kullback-Leibler 散度两类约束项, 以提高预报结果在频域、概率分布上与实况的一致性。对比 2024 年欧洲中期天气预报中心 (ECMWF)、国家气象中心 T_{2m} 指导产品 (SCMOC) 和 PANGU 这 3 类预报产品在广西区域的预报表现, 结果表明 PSD-Net 的格点预报和站点预报均优于对比产品, 其中格点预报平均绝对误差较 PANGU 降低 37.6%, 准确率提升 17 个百分点; 72 h 时效的 T_{2m} 预报, PSD-Net 的平均绝对误差和均方根误差随预报时效增长的幅度均小于对比产品, 其中 25~72 h 误差增长趋势平缓。本研究验证了物理约束深度学习框架在 T_{2m} 精细化预报中的有效性, 为气象与 AI 模型结合提供新思路。

关键词: 2 米气温, AI, 物理约束, 预报模型, 检验评估

P456, 10.7519/j.issn.1000-0526.2026.030903

Temperature Forecasting Method of Physics-Constrained Deep Learning Integrated with Pangu-Weather Model Forecast Products

JIANG Jian¹ LI Mingzhi^{1,2} LI Chao^{3,4,5} HUANG Kaigang^{1,2} LONG Keji^{6,7}

- 1 Baise Meteorological Office of Guangxi Zhuang Autonomous Region, Baise 533000
- 2 Baise Field Research Station for Karst Ecological Meteorology, CMA, Baise 533000
- 3 Wuhan Institute of Heavy Rain, CMA, Wuhan 430205
- 4 Hubei Key Laboratory for Heavy Rain Monitoring and Warning Research, Wuhan 430205
- 5 CMA Basin Heavy Rainfall Key Laboratory, Wuhan 430205
- 6 Sichuan Meteorological Observatory, Chengdu 610072
- 7 Sichuan Key Laboratory of Heavy Rain and Drought-Flood Disasters in Plateaus and Basins Chengdu 610072

Abstract: Aiming at the fine-scale forecasting challenge of 2 m temperature (T_{2m}) in complex

广西壮族自治区气象局气象科研计划项目 (桂气科 2024M20)、湖北省自然科学基金项目 (2023AFD101)、高原与盆地暴雨旱涝灾害四川省重点实验室科技发展基金项目研究型业务重点专项 (SCQXKJYJXZD202402)、中国气象局航空气象重点开放实验室青年课题 (HKQXQ-2025007) 共同资助

terrain areas, this paper selects the Guangxi region, a typical area with complex terrain, as the research object and proposes a physics-constrained deep learning forecasting model named PSD-Net, which integrates the forecast products of the Pangu-Weather model. The forecast products of Pangu-Weather (PANGU) are used as feature variables input. The generator based on the Super-Resolution Generative Adversarial Network (SRGAN) is employed to extract multi-scale features. Power-spectral-density (PSD) and Kullback–Leibler (KL) divergence terms are explicitly injected into the loss function as constraint term so as to improve the consistency of forecast products with observations in spectral fidelity and probability distribution. Compared to the T_{2m} forecast performance of the ECMWF, SCMOC and PANGU products in the Guangxi region in 2024, both the grided forecasts and station-based forecasts of PSD-Net outperform the compared forecast products. In particular, the absolute mean error of the grided forecasts is reduced by 37.6 % relative to that of PANGU and the accuracy is improved by 17 percentage points. The growths of both MAE and RMSE for the 72 h T_{2m} forecast products from PSD-Net are less than those of the compared forecast products, and there is a gentle error growth at lead time from 25 h to 72 h. In a word, this study has verified the effectiveness of the physics-constrained deep learning framework in fine-scale T_{2m} forecasting which could provide a new approach for the combination of meteorological and AI models.

Key words:

2 m temperature, AI, physics-constrained, forecast model, performance evaluation

引言

2 米气温 (T_{2m}) 是气象预报最基础的业务之一, 其预报精度直接影响天气预警、能源调度与灾害防御等关键决策 (李浙华等, 2024)。准确的 T_{2m} 预报不仅能够为公众提供可靠的天气信息, 还能为能源、农业生产和灾害防御等领域提供科学依据。尽管数值天气预报模式 (NWP) 随观测与算力提升而不断进步, 但受限于物理参数化误差与地形响应不足等因素, 其在复杂地形区、极端事件及长时效预报中预报能力仍有较大提升空间。为降低 NWP 误差, 模式输出统计 (MOS) 等统计后处理方法被广泛应用。薛谔彬等 (2019) 通过动态滑动双权重平均订正法有效降低误差; 赵瑞霞等 (2020) 与陈豫英等 (2011) 分别将 MOS 拓展至短临降水与延伸期气温预报, 提升显著; 齐铎等 (2020) 针对东北地区提出格点偏差订正方法, 有效改善 T_{2m} 预报偏差; 吴启树等 (2016) 提出“准对称混合滑动训练期”改进建模样本, 使福建 T_{2m} 误差较原始产品降低 40%; 潘留杰等 (2017) 也验证了简易格点订正方法的有效性。但复杂物理参数化方案的不确定性、模式系统性误差以及数据间复杂非线性关系依然是制约 T_{2m} 预报提升的瓶颈。近年来, 深度学习快速发展为气象领域发展带来新机遇, 其通过构建非线性映射关系, 能从数据中挖掘潜在的大气动力和热力的关联, 张桃等 (2024) 基于长短期记忆网络 (LSTM) 构建赤道太平洋海表温度 10 天预报模型, 表现良好; 张延彪等 (2022) 构建了融合多气象要素的 Fuse-CUnet 模型, 相比于传统预报订正方法, 显著提升订正效果; 卢姝等 (2025) 融合多类神经网络的模型在湖南复杂地形和极端高温中取得良好效果; 陈鹤等 (2022) 利用全连接网络改善高海拔 T_{2m} 订正效果; 杨彬等 (2024) 构建的 T_{2m} 预报 ATFSAS 模型较 LSTM 模型有显著提升; 陈锦鹏等 (2021)、陈训来等 (2021) 及庄潇然等 (2023) 基于卷积神经网络 (CNN)、卷积门控循环单元 (ConvGRU) 等方法在降水临近预报中取得突破; 杨绚等 (2022) 系统评述了深度学习在智能网格预报中的应用潜力。以华为开发的盘古天气模型 (Pangu-Weather) 为代表的 AI 气象模型取得重要突破 (Bi

第一作者: 蒋健,男,主要从事短期天气预报分析与研究.E-mail:350360059@qq.com

通讯作者: 龙柯吉,女,主要从事天气学与数值预报研究.E-mail:longkeji945@163.com

et al, 2023), Pangu-Weather 基于 3D 地球特定的 Transformer 架构, 在编码阶段通过三维卷积提取大气垂直与水平特征, 解码则利用反卷积输出预报场; 网络引入残差连接与高斯误差线性单元 (GELU) 激活函数缓解梯度消失并增强非线性建模能力, 模型驱动数据采用全球范围的欧洲中期天气预报中心第五代再分析数据集 (ERA5), 水平分辨率为 0.25° ; 包含 5 个近地面要素与 13 个等压面上的 5 个高空变量。模型可通过 4 种时间尺度 (1、3、6、24 h) 迭代生成预报时效为 1~10 d 及以上、水平分辨率 0.25° 的全球多种气象要素场。相比于 NWP, Pangu-Weather 在 T_{2m} 预报平均绝对误差降低 10%~15%, 且速度更快, 约 10 min 完成 1 h 分辨率的未来 96 h 时效全球预报。然而此类模型在 T_{2m} 的区域精细化预报中也面临一些挑战, 例如由于模型缺乏对大气物理过程 (如能量频散等) 的显式融入, 在长时效预报中易产生违背物理规律的解 (Rasp et al, 2018)。为此, 研究者探索引入物理规律约束, Chen et al (2024) 将垂直速度显式嵌入模型, 提升降水预报鲁棒性; 功率谱密度 (PSD) 与 Kullback-Leibler (KL) 散度等统计量约束预报的频域能量分布与概率特性 (徐甜甜等, 2021; Li et al, 2019; 刘云和王梓宇, 2020), 这为提升 T_{2m} 预报提供了新思路。

基于上述背景, 针对广西复杂地形区 T_{2m} 精细化预报中 NWP 地形适应性差、AI 模型高频失真及极端高温可靠性不足等问题, 本研究提出一种融合 Pangu-Weather 预报产品 (以下将该产品简称为 PANGU) 与统计量物理约束深度学习框架的 T_{2m} 预报模型: PSD-Net。利用 PANGU 预报产品, 结合地形高程数据及中国气象局陆面数据同化系统 (CLDAS) 实况数据构建数据集 (师春香等, 2019)。在损失函数中融入 PSD 和 KL 散度两类统计量, 以施加物理约束。其中, PSD 损失用于优化 T_{2m} 场的频域能量分布, 提升多尺度连贯性; KL 散度损失约束预测温度分布逼近实况, 增强气温的预报可靠性。利用 2024 年覆盖广西范围的格点、站点资料, 较为全面地评估了 PSD-Net 与对比产品的 T_{2m} 预报表现。

1 数据资料和方法

1.1 数据资料

本研究采用 2019—2024 年每日两次 (08 时、20 时; 北京时, 下同) ERA5 全球数据驱动 Pangu-Weather 输出 96 h 预报时效内的预报产品 PANGU, 研究区域 $19.5^\circ\text{N}\sim 26.5^\circ\text{N}$ 、 $104.2^\circ\text{E}\sim 112.2^\circ\text{E}$, 覆盖广西全域, 水平分辨率 0.25° , 时间分辨率 1 h。

用于对比的数据为 2024 年全年每日两次发布 (08 时、20 时) 的欧洲中期天气预报中心数值模式 72 h 时效内的 T_{2m} 预报产品 (以下将该产品简称为 ECMWF), 国家气象中心 72 h 时效内格点 T_{2m} 指导产品 (以下将该产品简称为 SCMOC)。ECMWF 水平分辨率为 0.125° , 时间分辨率为 3 h; SCMOC 水平分辨率为 0.05° , 时间分辨率为 1 h。

网格实况数据采用 2019—2024 年 CLDAS 逐小时的 T_{2m} 网格数据, 水平分辨率为 0.05° , 其中 2019—2023 年数据用于模型训练, 2024 年数据用于预报产品检验。CLDAS 产品基于多源观测与再分析数据融合, 在复杂地形区域具有良好的空间连续性, 在华南区域 MAE 约 $0.8\sim 0.9^\circ\text{C}$, 在广西 RMSE 约为 0.4°C , 可用性较好, 但随海拔升高误差逐渐增大, 其与站点观测在陡坡、山区等局部地形下仍存在一定差异 (师春香等, 2019; 刘莹等, 2021; 龙柯吉等, 2019)。站点检验的实况数据采用 2024 年广西域内 91 个国家级气象观测站经质量控制后逐小时的 T_{2m} 数据。

地形高程数据水平分辨率 0.05° 。底图采用自然资源部审图号为 GS (2024) 0650 号标准地图, 未作修改。

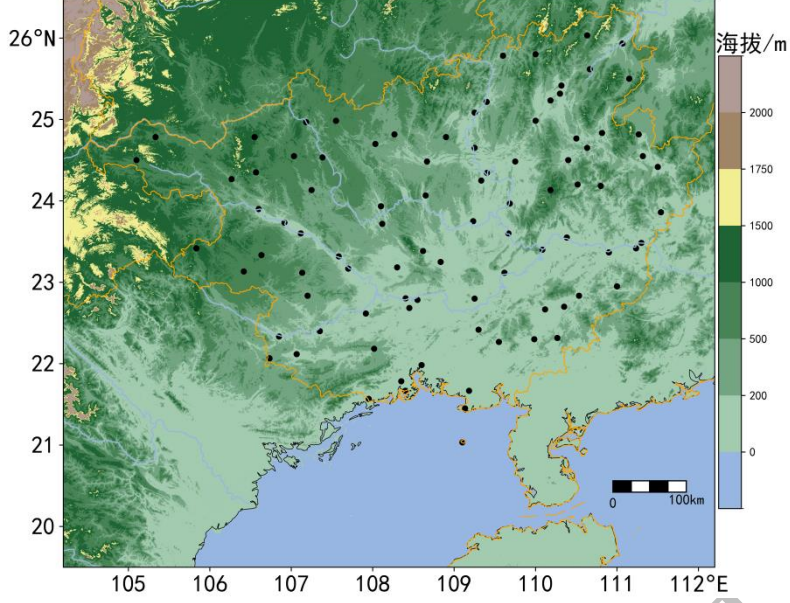


图1 研究区域的地形高程（填色）及广西区域91个国家级地面气象站（黑点）

Fig. 1 Topography of the study area (colored) and the distribution of 91 national meteorological stations (black dots) in the Guangxi Region

1.2 模型基础

超分辨率生成对抗网络（SRGAN）是一种基于深度学习的图像超分辨率技术，其原理是采用多个残差密集块（RDB）组成嵌套残差密集块（RRDB）的生成器提取深层特征，能捕捉图像细节，生成更精细图像（Ledig et al, 2017）。该原理同样适用于捕捉降尺度后 T_{2m} 特征，通过特征订正使结果更接近实况。故本研究构建的 PSD-Net 以 SRGAN 的生成器为核心，旨在提取更高分辨率 T_{2m} 特征，以提升预报准确性。

能量谱损失（ L_{PSD} ）基于 Welch（1967）提出的 PSD 计算方法，用于描述信号在频域上的能量分布，公式如下：

$$P_x(f) = \frac{1}{M \sum_{n=0}^{N-1} w^2(n)} \sum_{i=0}^{M-1} \left| \sum_{n=0}^{N-1} x_i(n) w(n) e^{-j2\pi fn} \right|^2 \quad (1)$$

$$L_{PSD} = \frac{1}{n} \sum_{i=1}^n (P_{pred}(i) - P_{target}(i))^2 \quad (2)$$

式（1）中： N 为每段数据的点数，取值 64， $x_i(n)$ 是信号的第 i 段的第 n 个样本值， $w(n)$ 是 Hanning 窗函数， M 为总段数，取决于信号长度和重叠率， f 为空间频率， j 为虚数单位。式（2）中： P_{pred} 和 P_{target} 分别为预报场和实况场在第 i 个频率点的功率谱密度值，引入 L_{PSD} 力求模型预报的 T_{2m} 空间分布与实况保持一致，重视高频细节，避免只优化时域损失（如平均绝对误差）易导致高频细节丢失。

利用 Kullback and Leibler（1951）提出的 KL 散度计算方法，衡量两个概率分布间的差异。则 KL 散度损失（ L_{KL} ）计算公式如下：

$$L_{KL} = \sum_{i=1}^B P_{pred}(i) \ln \frac{P_{pred}(i)}{P_{target}(i)} \quad (3)$$

式中： B 为直方图数，本研究取值 100， $P(i)$ 表示预报场或实况场在第 i 个直方图区间（bin）的概率密度估计值， P_{pred} 和 P_{target} 分别为预报场和实况场的概率分布，引入 L_{KL} 目的是保留 T_{2m} 部分概率属性，如 T_{2m} 分布或类似高温等局部特征的频率，与实况匹配，从而确保

T_{2m} 预报场在分布和变化趋势与实况场趋于相似。

鉴于此, PSD-Net 的损失函数在 L_{MAE} 基础上引入 L_{PSD} 与 L_{KL} , 得到加权总损失函数 (L_{TOTAL}), 相关公式如下:

$$L_{MAE} = \frac{1}{n} \sum_{i=1}^n |P_{pred}(i) - P_{target}(i)| \quad (4)$$

$$L_{TOTAL} = \alpha L_{MAE} + \beta L_{PSD} + \gamma L_{KL} \quad (5)$$

式中: L_{MAE} 为预报场 P_{pred} 和实况场 P_{target} 的平均绝对误差, α, β, γ 为权重系数。通过 L_{TOTAL} 增强多目标协同并提升模型性能、鲁棒性 (Yang and Shami, 2020)。

1.3 模型结构

采用 2019—2023 年 PANGU 产品中对应区域的 T_{2m} 、850 hPa 气温和比湿、500 hPa 温度预报数据, 结合地形高程数据以及起报时次的 CLDAS 实况场共 6 类作为模型训练的特征量, 由于 PANGU 原始水平分辨率为 0.25° , 故在训练前将各个特征量通过双线性插值至 0.05° , 与地形高程、起报时 CLDAS 实况场一致, 并对数据场进行归一化处理。PSD-Net 模型 (图 2) 核心由 8 个级联的 RRDB 构成, 每个 RRDB 由 3 个 RDB 嵌套组成, 每个 RDB 通过 5 层密集连接实现多尺度特征融合。RDB 每层通过 3×3 卷积核提取特征, 采用带泄露线性整流函数 (Leaky ReLU, 负斜率 0.2) 增强非线性表达 (Florek and Mihsz, 2023)。RDB 内部采用加权残差连接设计, 将原始输入特征与 5 层卷积后的深层特征按 1:0.2 的权重融合, 缓解梯度消失。RRDB 则将 3 个 RDB 的输出特征再次按相同权重比例融合后与自身输入叠加, 进一步强化特征传递稳定性。模型实现从局部到全局特征提取, 最终通过 3×3 卷积将 64 个通道特征映射至单通道输出, 生成归一化 T_{2m} 订正场。

为确保学习样本量充足, PANGU 的 96 h 预报时效内特征数据均纳入数据集, 理论样本总量 420864 个 (2192 天 \times 2 个预报时次/天 \times 96 个预报时效), 实际样本 420315 个, 数据完整率 99.87%。其中 2019—2023 年共 350067 个数据用于训练, 从中随机选取 20% 作为验证集。2024 年全年数据 (70248 个) 独立作测试集, 以评估全年尺度订正效果。训练过程中采用 Adam 优化器, 学习率 1×10^{-4} 。使用时, 模型输入特征经 PSD-Net 生成归一化订正场, 再经反归一化恢复量纲, 输出最终预报产品。

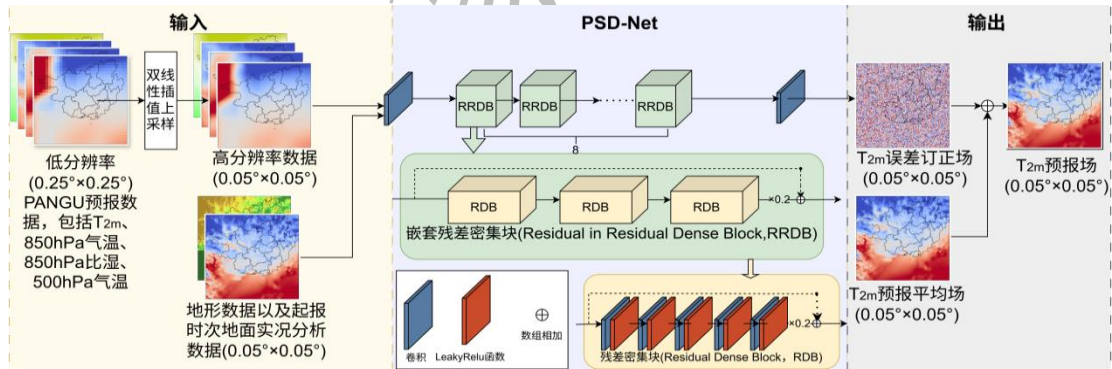


图 2 PSD-Net 架构示意图

Fig. 2 Schematic diagram of the PSD-Net architecture

1.4 预报产品预处理

在检验前需对齐不同产品 (PSD-Net、SCMOC、ECMWF、PANGU) 的时空分辨率, 因此, 时间上将 ECMWF 从 3 h 线性插值至 1 h; 空间上, 将 ECMWF 和 PANGU 均通过双线性插值至 0.05° 。由于 PANGU 存在数据延迟, 其最临近起报时次的预报产品无法满足业务需求, 以 20 时起报为例, 业务要求 16 时前完成未来 7 天预报, 但 20 时起报的 PANGU 产品须待至次日 03 时才输出。因此, PSD-Net (PANGU) 采用预报时效平移方案: 将当日

20 时（或 08 时）发布的 1~72 h 时效预报产品，实际替换为当日 08 时（或前一日 20 时）起报的 13~84 h 时效预报产品进行检验。该方案兼顾了研究连续性与业务可用性。

1.5 检验方法

本研究采用计算平均误差（ME）、平均绝对误差（MAE）、均方根误差（RMSE）、预报准确率（ACC）等 4 类指标（张强等，2009）从格点与站点两方面验证产品。格点验证：将预报场与 CLDAS 实况进行逐格点对；站点验证：由于邻近插值评估结果略优于双线性插值，且插值效率上邻近插值亦更快（龙柯吉等，2019），因此站点验证中给出邻近法插值后的评估结果。计算公式如下：

$$ME = \frac{1}{n} \sum_{i=1}^n (F_i - O_i) \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (8)$$

$$ACC = \frac{N_{\text{correct}}}{N} \times 100\% \quad (9)$$

式（6）~式（9）中， F_i 为预报值， O_i 为实况值， N_{correct} 和 N 分别为预报误差绝对值 ≤ 2 °C 的站点（格点）数与总站点（格点）数。ME、MAE 和 RMSE 越趋近于 0 °C，ACC 越趋近 100%，代表更优。在计算 ME 时，辅以统计预报值与实况值差值为正、负的格点/站点数量占比，以说明偏差。

1.6 损失函数权重确定及消融对比试验

本节设计损失函数权重确定和消融对比试验。为确保模型评估的可比性，所有试验均在相同设定下进行：使用相同训练集，在 5 个训练周期（epoch）内完成训练，均以测试集上的 MAE、ACC 作为评估指标。

为优化式（5）中的 α ， β ， γ ，采用网格搜索策略：（1）将 L_{MAE} 的权重 α 固定为 1.0，提供稳定的梯度预报误差基准与量纲（Yang and Shami, 2020）；（2） L_{PSD} 权重 β 经超参搜索从 0.1（弱约束）至 0.9（强约束）取 7 个候选值：0.1、0.3、0.4、0.5、0.6、0.7、0.9；（3） L_{KL} 的权重 γ 也取 7 个候选值：0.1、0.2、0.3、0.4、0.5、0.7、0.9，匹配概率分布约束常规强度；（4）由此构建 49 种 (β, γ) 组合，对比后发现（表 1），最优组合为 $\beta=0.5$ 、 $\gamma=0.3$ （MAE=1.06 °C、ACC=85.26 %），此时 PSD 约束与 KL 散度约束较平衡，既保持场空间结构特征，又确保概率分布合理。因此后续研究、试验均采用该组合。

表 1 最优排名前 4 组损失权重组合模型的 T_{2m} 格点预报 MAE 和 ACC 对比

Table 1 Comparison of MAE and ACC of gridded T_{2m} forecasts from four best-performing loss-weighted combination models

β	γ	MAE/°C	ACC/%
0.5	0.3	1.064	85.26
0.3	0.4	1.076	84.42
0.3	0.3	1.079	84.21
0.9	0.5	1.082	84.01

为验证 PSD-Net 对细节提取的能力，引入 U-Net 作为参照（组 1）：其编码器-解码器结构含 4 级下采样与上采样，通过跳跃连接融合多尺度特征，仅学习输入到输出的映射，损

失函数仅保留 L_{MAE} , 无约束项。同时为量化 L_{PSD} 、 L_{KL} 独立贡献, 设置 4 组消融试验 (组 2~组 5)。结果表明 (表 2), 组 5 (即 PSD-Net) 为最优: 较组 1, MAE 降低约 5.9%, ACC 提升约 1.78 个百分点; 较组 2, MAE 降低 11.2%。

表 2 消融试验组 (含 PSD-Net) 及 U-Net 的 T_{2m} 格点预报 MAE 和 ACC 对比

Table 2 Comparison of MAE and ACC of gridded T_{2m} forecasts between four ablation experiments (including PSD-Net) and U-Net

组号	方案	MAE/ $^{\circ}\text{C}$	ACC/%
1	U-Net	1.131	83.48
2	L_{MAE} (1.0)	1.199	81.62
3	L_{MAE} (1.0) + L_{KL} (0.3)	1.175	82.27
4	L_{MAE} (1.0) + L_{PSD} (0.5)	1.115	83.79
5	L_{MAE} (1.0) + L_{PSD} (0.5) + L_{KL} (0.3)	1.064	85.26

进一步分析两类约束。功率谱密度引入对数 L2 距离 (the L2 distance of logarithmic, $\lg L2$), 以衡量预报场与实况场在空间尺度能量分布上的差异; 概率密度函数 (Probability Density Function, PDF) 使用 KL 散度, 以衡量与 CLDAS 实况 PDF 之间的分布偏差。两项指标均无量纲, 且数值越小表示预报越接近实况。组 5 在高频段 (尺度 ≤ 50 km) 的能量明显增强 (图 3a), 其 $\lg L2$ 较所有对照组为最小, 最接近 CLDAS 实况, 可见其提升中小尺度高频结构准确性。图 3b 可见, 组 5 的 KL 散度最低, 在 $T_{2m} \geq 25$ $^{\circ}\text{C}$ 区域修正更明显, PDF 更贴近实况曲线。PSD 和 KL 散度协同使组 5 在 $\lg L2$ 和 KL 散度上均达到最优, 精度与稳定均提升。

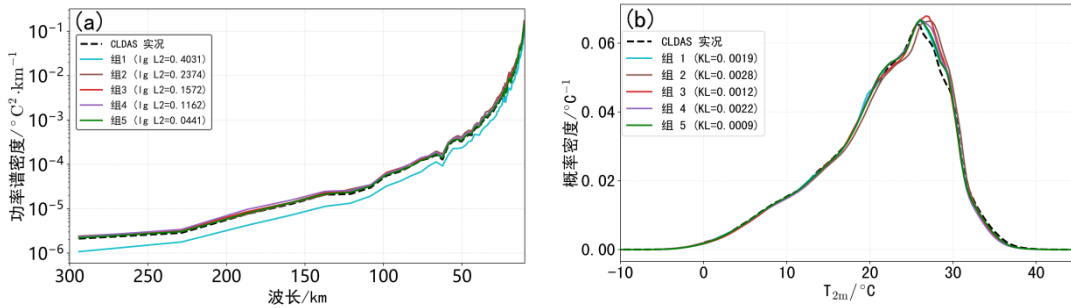


图 3 消融试验组 (含 PSD-Net) 及 U-Net 的 T_{2m} 格点预报和实况对比

(a) 功率谱密度, (b) 概率密度函数

Fig. 3 Comparison of gridded T_{2m} forecasts from four ablation experiments (including PSD-Net) and U-Net with observations

(a) power spectral density, (b) probability density function

2 2024 年产品对比检验分析

2.1 预报总体检验

根据 2024 年四家预报产品 72 h 预报时效内总体的检验结果 (表 3), 在格点预报中, PSD-Net 表现最优, MAE 与 RMSE 最低, ACC 最高, 且 ME 接近中性 (0.02°C)。其余方法误差较大, 且 ME 表现出不同偏差: ECMWF 存在冷偏差 ($\text{ME} = -0.41^{\circ}\text{C}$, 负值格点数量

占比 59.8%)；PANGU 的 ME 为 +0.17 °C，但其 ME 正值占比 52.7%，表明其暖偏差空间分布不均；SCMOC 的 ME 偏差极小，但 MAE 却最大。

在站点预报中，PSD-Net 的 MAE (1.09 °C) 与 ACC 仍为最佳，但较其格点预报表现下降，格点订正效果优于站点。ECMWF 和 PANGU 的偏差特征在站点有所增大，其中：ECMWF 冷偏差进一步增大 (ME=-0.57 °C，负值站点数占比 64.4%)，表现较差；PANGU 表现为冷偏差，ME 负值站点数占比 52.42%；而 SCMOC 站点表现优于格点。

表 3 2024 年 PSD-Net 与对比产品的 72 h 时效 T_{2m} 预报主要评估指标

Table 3 ME, MAE, RMSE and ACC of 72 h T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in 2024

预报产品	ME/°C		MAE/°C		RMSE/°C		ACC/%	
	格点	站点	格点	站点	格点	站点	格点	站点
ECMWF	-0.41	-0.57	1.52	1.62	2.05	2.09	71.5	68.7
SCMOC	0.01	0.23	1.59	1.57	2.13	2.07	70.5	71.1
PANGU	0.17	-0.12	1.49	1.34	2.00	1.76	72.8	77.3
PSD-Net	0.02	0.23	0.93	1.09	1.27	1.46	89.8	85.5

对比各家格点预报产品的 PSD 和 PDF (图 4)，PSD-Net 表现最佳：lg L2 (0.0092) 与 KL 散度 (0.0008) 均为最小，表明其在逼近真实温度分布方面最优。SCMOC 在 PSD 上表现次优，PDF 上也较接近实况，与其 ME 近 0 °C 对应，可靠性和可订正性较高。ECMWF 与 PANGU 在 PSD 上的误差显著较大，在中小尺度上 PSD 频谱衰减快，空间细节刻画能力不足；二者在 PDF 上亦存在明显偏差，PANGU 的 $T_{2m} \geq 25$ °C 的部分较 CLDAS 偏高，ECMWF 温度分布整体偏左。综上，PSD-Net 在空间结构与统计分布两方面表现最优。




图 4 2024 年 PSD-Net 与对比产品的 T_{2m} 格点预报和实况的对比

(a)功率谱密度 (PSD)，(b)概率密度函数 (PDF)

Fig. 4 Comparison of gridded T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU with observations in 2024

(a) power spectral density and (b) probability density function.

2.2 预报时效检验

分析四家产品的 72 h 时效预报的内逐小时偏差，格点和站点预报偏差趋势一致但前者偏差小于后者 (图略)，重点对格点预报偏差进行分析 (图 5)。由图可见，PSD-Net 始终保持最优，其格点 MAE 仅从约 0.95 °C 缓慢升至 1.2 °C，RMSE 增幅 31.8%。其余产品误

差增大更明显：ECMWF 站点 MAE 从 1.25 °C 升至 1.89 °C，RMSE 增幅约 50 %；SCMOC 站点 MAE 则从 1.28 °C 升至 1.82 °C；PANGU 站点 MAE 由约 1.1 °C 升至 1.82 °C，且部分时效出现明显的周期性“跳变”。分析表明，PANGU 这一现象可能与模型在推理阶段采用多时间模型迭代的“贪婪策略”有关，不同推理步骤的累加可能导致误差在特定时效升高，例如 8 h 预报采用“6+1+1”三次推理，其误差可能高于采用“6+3”两次推理的 9 h 预报。在 ACC 方面，PSD-Net 表现最优，其余产品 ACC 多集中在 70 %~80 % 之间且波动较大。综上，PSD-Net 在预报准确性、误差稳定性及抑制周期性异常波动方面均表现较好，引入的 PSD 约束损失进一步提升 PANGU 预报场结构一致性。

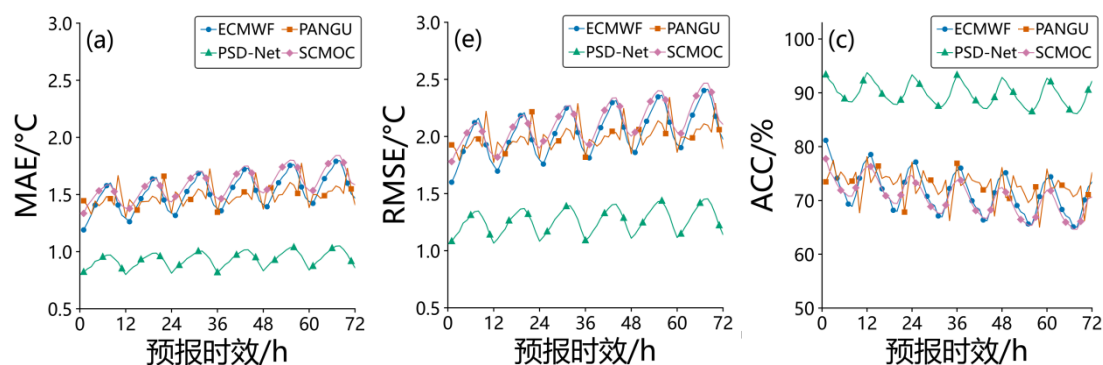
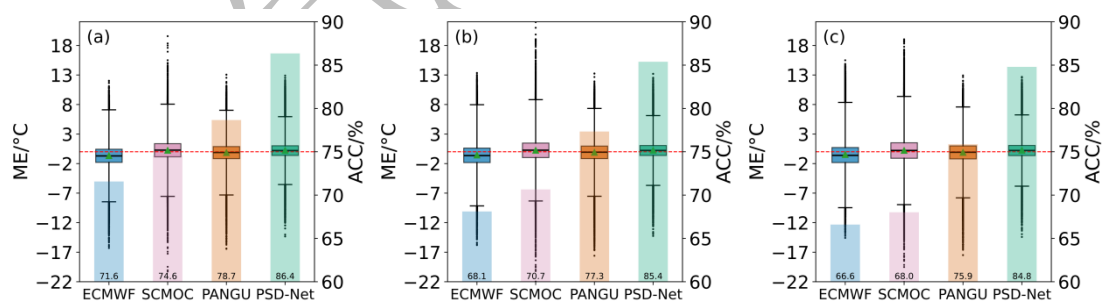


图 5 2024 年 PSD-Net 与对比产品的 72 h 时效 T_{2m} 格点预报(a)MAE、(b)RMSE 和(c)ACC 随预报时效的变化

Fig. 5 Variation of (a) MAE, (b) RMSE, and (c) ACC of 72 h gridded T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in 2024

进一步对不同时效段内（1~24 h、25~48 h、49~72 h）四家预报产品的 ME 及 ACC 进行分析（图 6）。PSD-Net 在各时段均保持稳定，平均 ACC 高于 82 %，ME 接近中性。PANGU 表现次之，各时段 ACC 维持在 75 %~80 %，整体误差控制较好。SCMOC 虽在整体 T_{2m} 分布（PDF，图 4b）上与实况较一致，但站点误差离散度大、异常值偏多，表明其平滑作用较强，对局地性、温度变化（变温）捕捉能力仍有不足，未能有效响应短时较大变化。ECMWF 则存在冷偏差，且 ACC 随预报时效下降。综上，PSD-Net 通过功率谱与概率双重约束，在分布一致性和稳定性方面均优于其他产品。



注：箱线箱体中横线为中位数，箱体上端及下端分别为第 75 % 和 25 % 分位值，触须的上端代表除异常值外的最大值和最小值，尾端实心点为超出第 75 % 分位值差 3 倍距离异常值；柱状底标记 ACC 值，图中红色虚线为 ME 为 0 °C 线

图 6 2024 年 PSD-Net 与对比产品的 72 h 时效 T_{2m} 站点预报在不同时段(a:1~24 h, b:25~48 h, c:49~72 h)的 ME(箱线)和平均 ACC(柱状)

Fig. 6 ME (box plot) and mean ACC (bar chart) of station-based 72 h T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in the time periods of (a) 1-24 h, (b) 25-48 h and (c) 49-72 h in 2024:

2.3 月度结果检验

对 72 h 预报时效的结果进行月度统计,分析格点和站点表现(图 7, 站点图略), ECMWF: 站点 MAE (1.62 °C) 和 RMSE (2.09 °C) 最高, ACC (68.7 %) 最低; 格点 MAE 在冬季升至 1.95~2.06 °C, 冬季预报较差。SCMOC: 格点 MAE (1.59 °C) 略优于 ECMWF, 6 月最佳时为 1.38 °C, 但冬季仍达 1.61~2.04 °C。PANGU: 相对稳定, 且站点 MAE (1.34 °C) 表现优于其格点 (MAE 约为 1.49 °C), 显示其对站点适应性较好; PSD-Net: 格点 MAE (0.93 °C) 最低, 其中夏季仅 0.80~0.87 °C、冬季在 1.00~1.13 °C 且 ACC (89.8 %) 为最优; 但站点 RMSE 相较格点上升 0.19 °C。综上, PSD-Net 在各项指标上优于其他产品, 在格点订正表现较站点更好; 各产品在夏季预报优于冬季, 季节特征明显; ECMWF 及 SCMOC 的冬季预报能力较差。

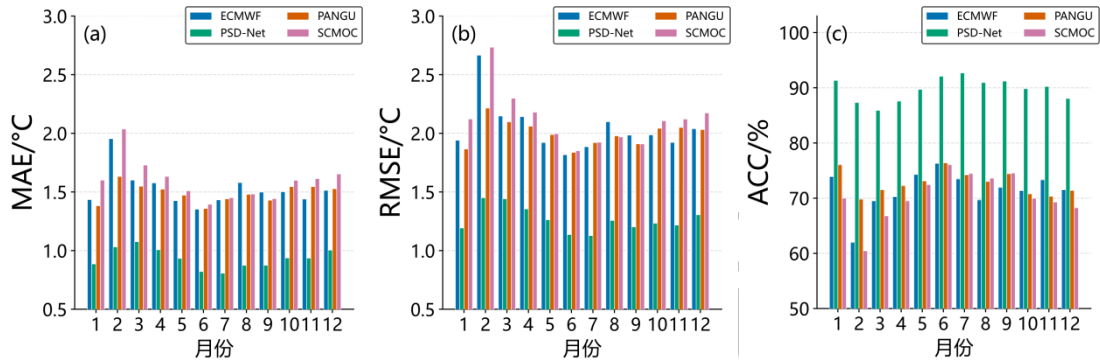


图 7 2024 年 PSD-Net 与对比产品的 T_{2m} 格点预报(a)MAE、(b)RMSE 和(c)ACC 的月变化

Fig. 7 Monthly variation of (a) MAE, (b) RMSE and (c) ACC of gridded T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in 2024

2.4 预报误差日变化特征

对 2024 年各家产品站点误差的 72 h 预报时效的平均日变化偏差分析(图 8), 产品的 ME 差异明显, MAE 与 ACC 呈现反相关系。ECMWF 表现为冷偏差, 其 MAE 在 15—18 时显著升高(超过 2.1 °C); SCMOC 维持轻微正偏差, 但 MAE 呈现“双峰”型日变化, 在清晨和午后误差较大; PANGU 的 ME 偏差较小, 但在傍晚前后出现明显的误差加大, 这可能与边界层热力及稳定度变化较大时段物理约束不足及变温阶段局地热力变化更大有关 (Rasp et al., 2018); PSD-Net 的 ME 在 12—18 时存在正偏差, 但其 MAE 其余时段保持在较低水平 (0.9~1.4 °C), ACC 始终较高, 在日变化、稳定性方面最优。

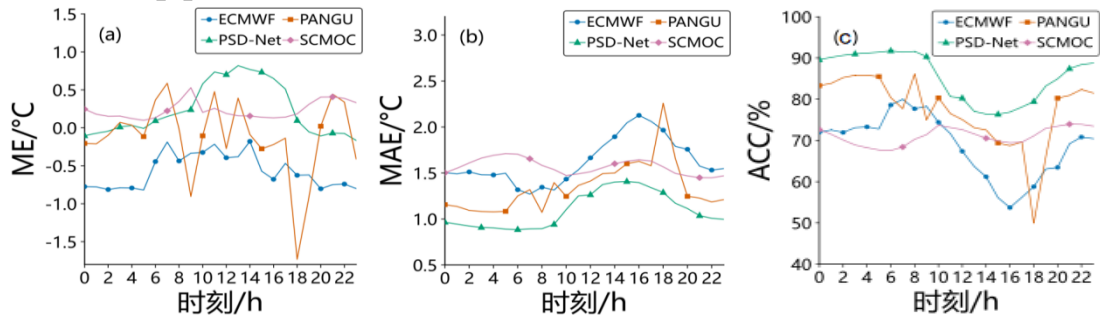


图 8 2024 年 PSD-Net 与对比产品的 T_{2m} 站点预报 (a)ME、(b)MAE、(c)ACC 的平均日变化

Fig. 8 Diurnal average variations of (a) ME, (b) MAE and (c) ACC of station-based T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in 2024

2.5 超阈值气温事件效果评估

对 2024 年站点超阈值的高温 ($T_{2m} \geq 35\text{ }^{\circ}\text{C}$) 及低温 ($T_{2m} \leq 0\text{ }^{\circ}\text{C}$) 事件进行统计, 由于偏差波动大, 经测试, 分别对高温和低温事件的预报结果采用 11 个和 4 个预报时效的滑动平均进行处理, 以分析偏差趋势 (图 9)。在高温事件中, 各产品在 72 h 预报时效内的 ME 在 $-4 \sim 0\text{ }^{\circ}\text{C}$ 间波动, 即对 T_{2m} 预报偏低, 且误差随预报时效而增加。PSD-Net 的误差最小, 表现最优; SCMOC 次之, ME 在 $-2 \sim -1\text{ }^{\circ}\text{C}$ 间波动, MAE 和 RMSE 均随时效而增大; PANGU 的趋势与 ECMWF 相似, 但 ECMWF 的 MAE 和 RMSE 偏差明显更大。在低温事件中, 4 家产品对 T_{2m} 预报偏高, PSD-Net 在 72 h 预报时效内整体表现优于其他产品。SCMOC、PANGU 和 ECMWF 趋势较一致, 其中: SCMOC 的 MAE 最低约 $1\text{ }^{\circ}\text{C}$, RMSE 最低约 $1.5\text{ }^{\circ}\text{C}$, 但在 36 h 预报时效之后 RMSE 上升, 偏差加大; ECMWF 在 72 h 预报时效内的 MAE 在 $1 \sim 1.8\text{ }^{\circ}\text{C}$ 波动; PANGU 与之相近, 但波动幅度相对较小。

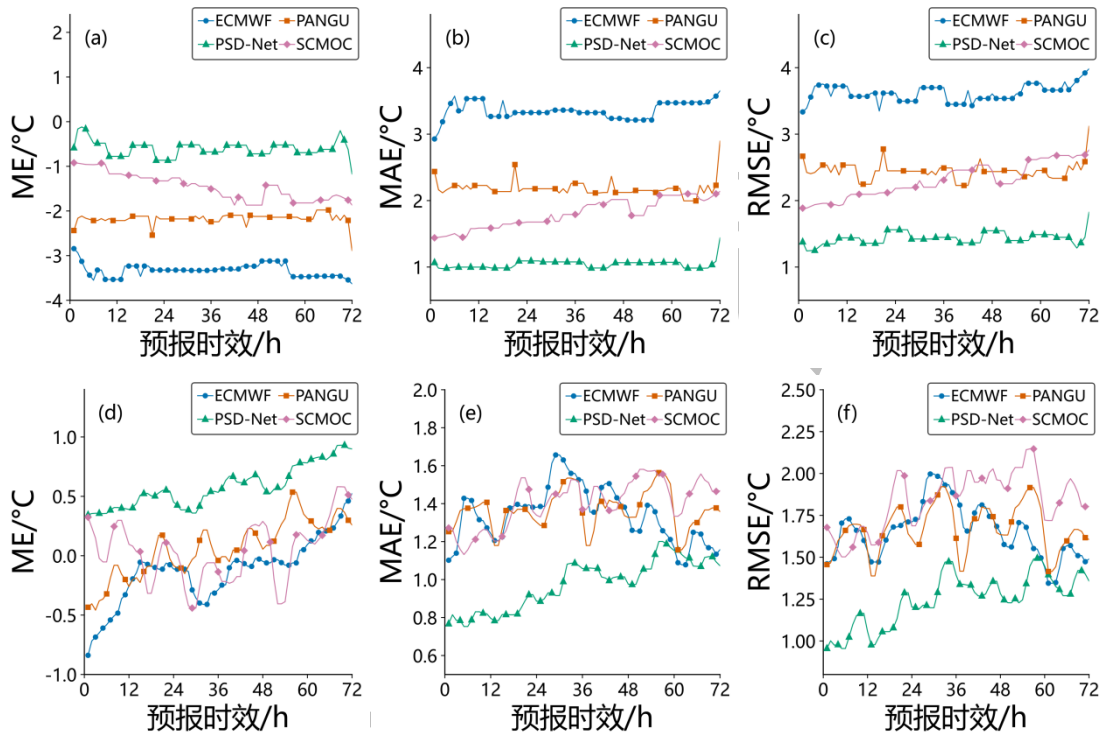


图 9 PSD-Net 与对比产品对 2024 年(a~c)高温、(d~f)低温事件的 72 h 时效 T_{2m} 站点预报的(a、d)ME、(b、e)MAE 和(c、f)RMSE 随预报时效的变化

Fig. 9 Hourly variations of (a, d) ME, (b, e) MAE and (c, f) RMSE of station-based 72 h T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU during (a-c) high temperature and (d-f) low temperature events in 2024

2.6 预报误差空间分布检验

针对 2024 年四家产品 72 h 预报时效的 T_{2m} 格点误差进行空间分布评估 (图 10), 着重分析预报产品 MAE 和 ME 的空间分布。广西以喀斯特地貌为主 (图 1), 北部、西部为云贵高原边缘山地, 地形起伏较大, 中部、东部和南部沿海区域以平原为主, 海拔较低, 明显的地形梯度对不同产品 T_{2m} 预报误差的空间差异具有显著影响。ECMWF: MAE 的空间分布呈现显著的地形相关性, 高值区集中于北部山地 (最大值达 $5.7\text{ }^{\circ}\text{C}$), 这可能与起伏地形导致的热力过程模拟偏差有关; ME 整体表现为冷偏差 (均值 $-0.31\text{ }^{\circ}\text{C}$)。SCMOC: 预报误差空间格局与 ECMWF 相似但量值更大, MAE 高值区同样显著, ME 转为轻微正偏差 (均

值 +0.14 °C)。PANGU: MAE 空间异质性最强, ME 呈现明显暖偏差。PSD-Net: MAE 均值降至约 1.0 °C, 在复杂地形下空间变率最小, ME 接近中性, 显示出最优空间一致性; 说明其表现最优且空间分布最均衡。

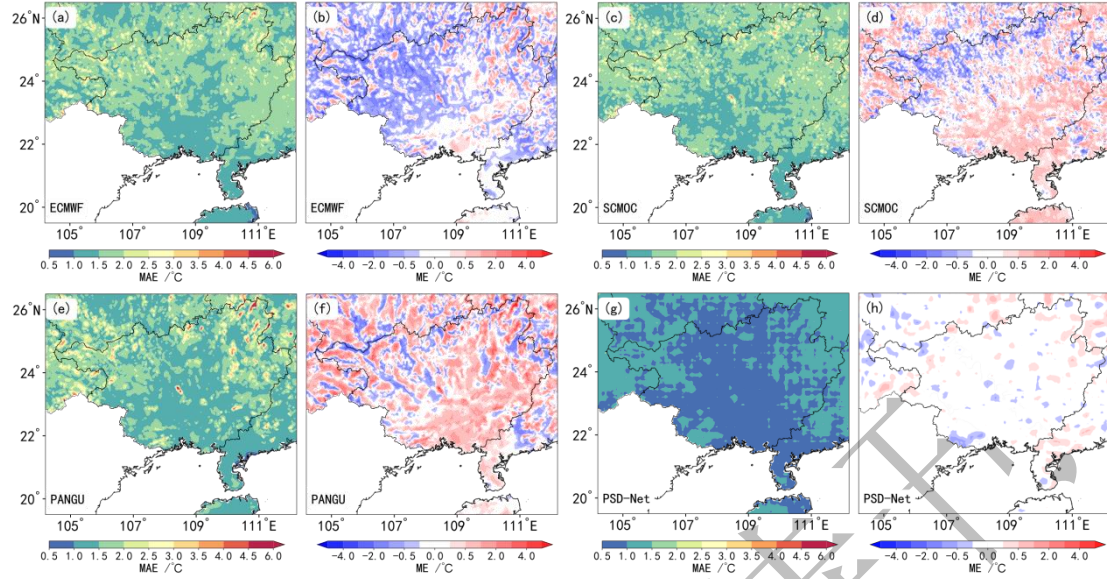


图 10 2024 年 PSD-Net 与对比产品的 T_{2m} 格点预报(a,c,e,g)MAE 和(b,d,f,h)ME 空间分布

Fig. 10 Spatial distribution of (a, c, e, g) MAE and (b, d, f, h) ME of gridded T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in 2024

进一步分析海拔高度与站点预报误差关联性, 依据检验站海拔高度分区: 海拔 <200 m (I 区, 样本量约 310 万)、200~500 m (II 区, 约 115 万)、500~1000 m (III 区, 约 47 万) 和 >1000 m (IV 区, 约 5 万), 对各产品站点 72 h 预报时效指标统计后进行分区分析 (表 4)。ECMWF: 在各区 MAE、RMSE 处于中等水平, ME 呈现负偏差; 在 II、III 区误差随海拔升高而增大, 表明其对中高海拔地形适应性有限; 在 IV 区, 偏差虽减小 (ME 为 -0.5 °C), 但 MAE、RMSE 仍较高。SCMOC: 整体表现略优于 ECMWF, ME 在低海拔区为正偏差, 随海拔升高逐渐转为负值。PANGU: 在 I 区表现优于 ECMWF 和 SCMOC, 但随海拔升高, MAE 和 RMSE 误差增幅最大, ME 也在 IV 区出现 +1.36 °C, 不如 ECMWF 和 SCMOC; 原因可能是其用于训练的地形掩膜分辨率在 0.25° (Bi et al, 2023), 对区域地形的学习相对不足有关, 未能充分学习区域热力特征, 加之广西地形复杂, 因此在陡坡、河谷过渡等区域出现偏差极大值。PSD-Net 在 4 个分区表现最优, ME 为小幅正偏差, 表现稳定, I 区 MAE 较 PANGU 降低 18%。表明引入地形高程作为辅助特征, 可增强模型对复杂地形的适应能力 (Han et al, 2021), 有效订正纯数据模型 (PANGU) 在高海拔区的高估偏差。

表 4 2024 年 PSD-Net 与对比产品的 T_{2m} 格点预报在不同海拔分区的 MAE 和 RMSE

Table 4 MAE and RMSE of gridded T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU in different elevation ranges in 2024

产品	评估指标/°C	<200m	200~500m	500~1000m	>1000m
		(I 区)	(II 区)	(III 区)	(IV 区)
ECMWF	ME	-0.39	-0.82	-1.17	-0.5
	MAE	1.55	1.74	1.82	1.48
	RMSE	2.0	2.22	2.32	1.9
SCMOC	ME	0.36	0.16	-0.39	-0.01

	MAE	1.53	1.6	1.75	1.4
	RMSE	2.02	2.11	2.28	1.83
	ME	-0.09	-0.33	-0.01	1.36
PANGU	MAE	1.29	1.40	1.52	1.67
	RMSE	1.7	1.82	1.98	2.01
	ME	0.19	0.39	0.13	0.48
PSD-Net	MAE	1.06	1.18	1.14	1.12
	RMSE	1.41	1.56	1.52	1.48

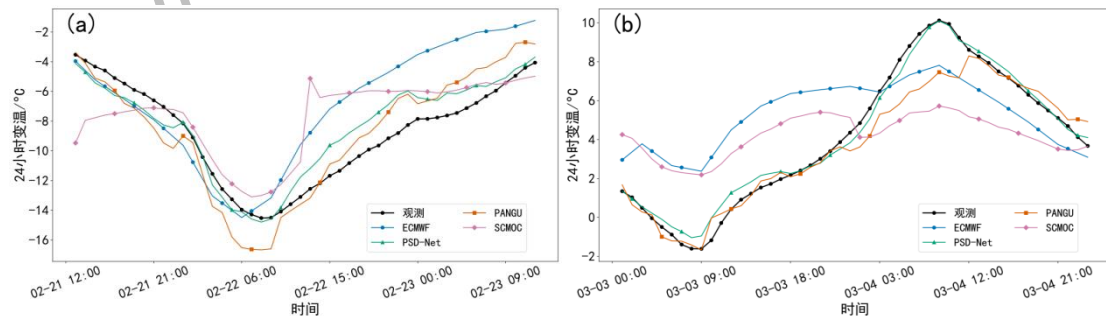
2.7 变温过程个例评估

高性能预报产品需兼顾平稳天气的稳定性与转折天气的预报准确性。选取2024年2月21—23日降温和3月3—5日升温过程作为转折性天气个例，分别检验评估2月21日20时、3月2日20时起报的各家预报产品对站点实况的误差（图11）。

2月21—23日，受冷空气南下影响，研究区域内出现雨雪冰冻天气，广西于2月23日发布低温蓝色等预警。降温初期（图11a），ECMWF、PANGU和PSD-Net均能较好地报出降温趋势，而SCMOC在过程开始前高估降温强度（ $-10\text{ }^{\circ}\text{C}$ ）。22日00时出现分歧：PANGU在06时高估负变温；ECMWF和PSD-Net趋势较准，其中PSD-Net最接近变温实况；SCMOC则从21日23时起持续低估变温幅度，在22日14时，观测的变温仍有 $-12.5\text{ }^{\circ}\text{C}$ ，而SCMOC则为 $-6.4\text{ }^{\circ}\text{C}$ ，偏差较大。从MAE分析（图11c），PSD-Net和PANGU整体较低（分别为 $1.78\text{ }^{\circ}\text{C}$ 、 $1.85\text{ }^{\circ}\text{C}$ ），表现优于SCMOC和ECMWF（分别为 $2.50\text{ }^{\circ}\text{C}$ 、 $2.60\text{ }^{\circ}\text{C}$ ），后两者误差上升幅度大，其中SCMOC在25~26h时效出现明显误差，稳定性相对不足。

3月3—5日受西南暖低压影响，广西出现显著升温。过程前期受弱冷空气补充影响出现小幅负变温，PSD-Net和PANGU成功预报出这一波动，而SCMOC和ECMWF未报出（图11b）。升温开始后，PSD-Net和PANGU保持较高准确性，SCMOC和ECMWF则高估升温幅度 $2\sim 3\text{ }^{\circ}\text{C}$ 。至4日02时后升温趋势减弱，PSD-Net准确把握趋势，其他产品均出现不同程度低估。对MAE分析（图11d），PSD-Net与PANGU总体MAE较低（分别为 $1.41\text{ }^{\circ}\text{C}$ 、 $1.61\text{ }^{\circ}\text{C}$ ），SCMOC和ECMWF则为 $2.27\text{ }^{\circ}\text{C}$ 、 $2.38\text{ }^{\circ}\text{C}$ ，且ECMWF的MAE在12h时效后波动明显（ $2.0\sim 4.0\text{ }^{\circ}\text{C}$ ），稳定性较差。

综上，各产品在升温过程中表现优于降温过程；PSD-Net表现最优，物理约束保持波动能量分布与统计特性使得PSD-Net在变温过程中对 T_{2m} 能量频散以及分布起到积极效果；PANGU虽偶现局部高估，但整体稳健；ECMWF与SCMOC误差偏高，对变温预报较差。



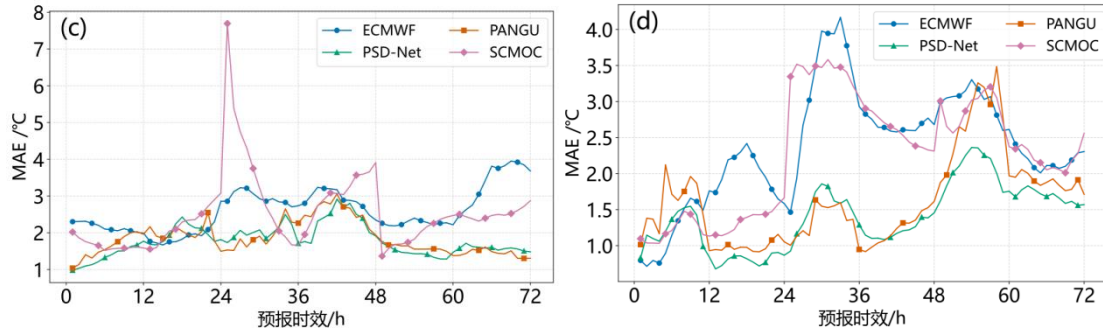


图 11 2024 年(a, c) 2 月 21—23 日降温过程和(b, d)3—5 日升温过程中 PSD-Net 与对比产品的 72 h 时效 T_{2m} 预报的(a,b) 24 h 变温与实况的对比, (c, d) 24 h 变温 MAE 随预报时效的变化

Fig. 11 (a, b) Comparison of 24 h temperature change with observations and (c, d) variation of MAE of 24 h temperature change with forecast lead time for the 72 h T_{2m} forecast products from PSD-Net as well as ECMWF, SCMOC and PANGU during (a,c) the cooling event from 21 to 23 February and (b,d) the warming event from 3 to 5 March 2024

3 结论与讨论

本研究提出的 PSD-Net 模型通过融合 Pangu-Weather 预报产品,并在损失函数中引入功率谱密度(PSD)和 KL 散度作为约束,是一种融合物理约束的深度学习预报模型。通过对广西地区 2024 年 T_{2m} 的预报检验,从总体误差、时效演变、月际变化、日变化、极端事件、空间分布、海拔分区和典型变温过程等方面,较为全面地评估了 PSD-Net 及对比产品的表现。主要结论如下:

(1) 全年检验结果表明,PSD-Net 在 2024 年格点与站点的 T_{2m} 预报均优于 ECMWF、SCMOC 及 PANGU。格点预报方面,PSD-Net 的 MAE 较 PANGU 降低了 37.6%,ACC 提升 17 个百分点;站点预报方面,PSD-Net 的 MAE 较 PANGU 降低 18.7%,ACC 提升 7.7 个百分点。

(2) 不同预报时效段的检验结果表明,PSD-Net 的 MAE 和 RMSE 随预报时效增长的幅度均小于 ECMWF、SCMOC 及 PANGU;ACC 方面,PSD-Net 的 1~24 h 预报的结果稳定超过 85%,25~72 h 预报误差增长缓慢,72 h 预报持在 82%,且误差受季节变化影响较小。

(3) 从预报误差的空间分布上看,PSD-Net 在广西复杂地形区的预报误差明显小于 ECMWF、SCMOC 及 PANGU。其格点预报的 MAE 在大部分区域为 0.8~1.5 °C,而 ECMWF、SCMOC 及 PANGU 在山区(尤其是北部山地)的 MAE 可达 1.5~6.0 °C。

(4) 对于高温($T_{2m} \geq 35$ °C)及低温($T_{2m} \leq 0$ °C)事件,PSD-Net 的 ME 稳定在 -1~1 °C,MAE 与 RMSE 波动更小,较 ECMWF、SCMOC 及 PANGU 偏差更小。

(5) 对于 2024 年 2 月降温和 3 月升温两次转折性天气过程个例,PSD-Net 表现优于 ECMWF、SCMOC 及 PANGU,相较而言,其对升温过程的订正能力优于降温过程。

PSD-Net 为 T_{2m} 精细化预报与 AI 天气模型产品后处理和应用提供新思路。但本研究仍有若干局限:权重系数未进行全样本的敏感性试验;研究基于 2024 年广西区域数据进行验证,在其他区域及更长时效的能力有待检验;所用 PSD 和 KL 散度在降水等其他气象要素的预报适用性仍需探索;个例仅选取两个变温过程,未来可增加不同类型天气(如强对流等

个例以全面检验模型适应性；此外，模型基于格点场训练，站点订正能力弱于格点，后续可引入可变形卷积构建“格点-站点”耦合机制以提升站点预报精度。

参考文献

- 陈鹤, 蔡荣辉, 陈静静, 等, 2022. 基于深度学习方法的温度预报技术应用与评估[J]. 气象, 48(11): 1373-1383. Chen H, Cai R H, Chen J J, et al, 2022. Application and evaluation of temperature forecast based on deep learning method[J]. Meteor Mon, 48(11): 1373-1383 (in Chinese).
- 陈锦鹏, 冯业荣, 蒙伟光, 等, 2021. 基于卷积神经网络的逐时降水预报订正方法研究[J]. 气象, 47(1): 60-70. Chen J P, Feng Y R, Meng W G, et al, 2021. A correction method of hourly precipitation forecast based on convolutional neural network [J]. Meteor Mon, 47(1): 60-70 (in Chinese).
- 陈训来, 刘军, 郑群峰, 等, 2021. 基于卷积门控循环单元神经网络的临近预报方法研究[J]. 高原气象, 40(2): 411-423. Chen X L, Liu J, Zheng Q F, et al, 2021. A study on Radar Echo Nowcasting based on convolutional gated recurrent unit neural network[J]. Plateau Meteor, 40(2): 411-423 (in Chinese).
- 陈豫英, 陈楠, 王素艳, 等, 2011. MOS 方法在动力延伸期候平均气温预报中的应用[J]. 应用气象学报, 22(1): 86-95. Chen Y Y, Chen N, Wang S Y, et al, 2011. Application of MOS method on pentad mean temperature prediction in dynamical extended range[J]. J Appl Meteor Sci, 22(1): 86-95 (in Chinese).
- 李浙华, 肖安, 郑丽君, 2024. 基于高分辨率数值预报和深度学习的地面气温预报研究[J]. 高原气象, 43(2): 464-477. Li Z H, Xia A, Zheng L J, 2024. Research on surface temperature prediction based on high-resolution numerical prediction products and deep learning[J]. Plateau Meteor, 43(2): 464-477 (in Chinese).
- 刘云, 王梓宇, 2020. 无偏 KL 散度算法对时空异常区间检测的优化研究[J]. 计算机工程与科学, 42(7): 1318-1324. Liu Y, Wang Z Y, 2020. Optimization of the spatio-temporal anomalous regions detection by unbiased KL divergence algorithm[J]. Comput Eng Sci, 42(7): 1318-1324 (in Chinese).
- 刘莹, 师春香, 王海军, 等, 2021. CLDAS 气温数据在中国区域的适用性评估[J]. 大气科学学报, 44(4): 540-548. Liu Y, Shi C X, Wang H J, et al, 2021. Applicability assessment of CLDAS temperature data in China[J]. Trans Atmos Sci, 44(4): 540-548 (in Chinese).
- 龙柯吉, 师春香, 韩帅, 等, 2019. 中国区域高分辨率温度实况融合格点分析产品质量评估[J]. 高原山地气象研究, 39(3): 67-74. Long K J, Shi C X, Han S, et al, 2019. Quality assessment of high resolution temperature merged grid analysis product in China[J]. Plateau Mountain Meteor Res, 39(3): 67-74 (in Chinese).
- 卢姝, 陈鹤, 陈静静, 等, 2025. 基于改进长短期记忆网络的湖南网格气温预报模型[J]. 气象, 51(4): 431-445. Lu S, Chen H, Chen J J, et al, 2025. Gridded temperature forecast model in Hunan based on improved long short-term memory networks [J]. Meteor Mon, 51(4): 431-445 (in Chinese).
- 潘留杰, 薛春芳, 王建鹏, 等, 2017. 一个简单的格点温度预报订正方法[J]. 气象, 43(12): 1584-1593. Pan L J, Xue C F, Wang J P, et al, 2017. A simple grid temperature forecast correction method[J]. Meteor Mon, 43(12): 1584-1593 (in Chinese).
- 齐锋, 刘松涛, 张天华, 等, 2020. 基于格点的中国东北中北部 2 m 温度数值预报检验及偏差订正[J]. 干旱气象, 38(1): 81-88. Qi D, Liu S T, Zhang T H, et al, 2020. Grid temperature numerical forecast verification and correction over central and north region of Northeast China[J]. J Arid Meteor, 38(1): 81-88 (in Chinese).
- 师春香, 潘昉, 谷军霞, 等, 2019. 多源气象数据融合格点实况产品研制进展[J]. 气象学报, 77(4): 774-783. Shi C X, Pan Y, Gu J X, et al, 2019. A review of multi-source meteorological data fusion products[J]. Acta Meteor Sin, 77(4): 774-783 (in Chinese).
- 吴启树, 韩美, 郭弘, 等, 2016. MOS 温度预报中最优训练期方案[J]. 应用气象学报, 27(4): 426-434. Wu Q S, Han M, Guo H, et al, 2016. The optimal training period scheme of MOS temperature forecast[J]. J Appl Meteor Sci, 27(4): 426-434 (in Chinese).
- 徐甜甜, 韩光洁, 邹岩, 等, 2021. 基于混合机器学习的电磁功率谱密度预测模型[J]. 太赫兹科学与电子信息学报, 19(4): 623-627. Xu T T, Han G J, Zou Y, et al, 2021. Electromagnetic power spectrum density prediction model based on hybrid mac

- hine learning[J]. *J Terahertz Sci Electr Informat Technol*, 19(4): 623-627 (in Chinese).
- 薛湛彬, 陈娴, 张瑛, 等, 2019. ECMWF 高分辨率模式 2 m 温度预报误差订正方法研究[J]. *气象*, 45(6): 831-842. Xue C B, Chen X, Zhang Y, et al, 2019. Bias correction method for the 2 m temperature forecast of ECMWF high resolution model [J]. *Meteor Mon*, 45(6): 831-842 (in Chinese).
- 杨彬, 马廷淮, 黄学坚, 2024. 基于注意力机制与自适应时序分解的气温预报模型[J]. *气象*, 50(6): 723-732. Yang B, Ma T H, Huang X J, 2024. Air temperature forecasting model based on attention mechanism and AdaSTL[J]. *Meteor Mon*, 50(6): 723-732 (in Chinese).
- 杨绚, 代刊, 朱跃进, 2022. 深度学习技术在智能网格天气预报中的应用进展与挑战[J]. *气象学报*, 80(5): 649-667. Yang X, Dai K, Zhu Y J, 2022. Progress and challenges of deep learning techniques in intelligent grid weather forecasting[J]. *Acta Meteor Sin*, 80(5): 649-667 (in Chinese).
- 张强, 熊安元, 张金艳, 等, 2009. 晴雨(雪)和气温预报评分方法的初步研究[J]. *应用气象学报*, 20(6): 692-698. Zhang Q, Xiong A Y, Zhang J Y, et al, 2009. Preliminary study on the scoring methods of cloud-free rainfall/snowfall and air temperature forecasts[J]. *J Appl Meteor Sci*, 20(6): 692-698 (in Chinese).
- 张桃, 林鹏飞, 刘海龙, 等, 2024. 利用长短期记忆网络 LSTM 对赤道太平洋海表面温度短期预报[J]. *大气科学*, 48(2): 745-754. Zhang T, Lin P F, Liu H L, et al, 2024. Short-term sea surface temperature forecasts for the equatorial Pacific based on long short-term memory network[J]. *Chin J Atmos Sci*, 48(2): 745-754 (in Chinese).
- 张延彪, 陈明轩, 韩雷, 等, 2022. 数值天气预报多要素深度学习融合订正方法[J]. *气象学报*, 80(1): 153-167. Zhang Y B, Chen M X, Han L, et al, 2022. Multi-element deep learning fusion correction method for numerical weather prediction[J]. *Acta Meteor Sin*, 80(1): 153-167 (in Chinese).
- 赵瑞霞, 代刊, 金荣花, 等, 2020. OTS、MOS 和 OMOS 方法及其优化组合应用于 72 h 内逐 3 h 降水预报的试验分析研究[J]. *气象*, 46(3): 420-428. Zhao R X, Dai K, Jin R H, et al, 2020. Comparison of OTS, MOS, OMOS methods and their combinations applied in 3 h precipitation forecasting out to 72 h[J]. *Meteor Mon*, 46(3): 420-428 (in Chinese).
- 庄潇然, 郑玉, 王亚强, 等, 2023. 基于深度学习的融合降水临近预报方法及其在中国东部地区的应用研究[J]. *气象学报*, 81(2): 286-303. Zhuang X R, Zheng Y, Wang Y Q, et al, 2023. A deep learning-based precipitation nowcast model and its application over East China[J]. *Acta Meteor Sin*, 81(2): 286-303 (in Chinese).
- Bi K F, Xie L X, Zhang H H, et al, 2023. Accurate medium-range global weather forecasting with 3D neural networks[J]. *Nature*, 619(7970): 533-538.
- Chen Y T, Wang Y, Huang G, et al, 2024. Coupling physical factors for precipitation forecast in China with graph neural network[J]. *Geophys Res Lett*, 51(2): e2023GL106676.
- Florek D, Miłosz M, 2023. Comparison of an effectiveness of artificial neural networks for various activation functions[J]. *Journal of Computer Sciences Institute*, 26: 7-12.
- Han L, Chen M X, Chen K K, et al, 2021. A deep learning method for bias correction of ECMWF 24-240 h forecasts[J]. *Adv Atmos Sci*, 38(9): 1444-1459.
- Kullback S, Leibler R A, 1951. On information and sufficiency[J]. *Ann Mathemat Statistics*, 22(1): 79-86.
- Ledig C, Theis L, Huszár F, et al, 2017. Photo-realistic single image super-resolution using a generative adversarial network[C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE: 105-114.
- Li X F, Leglaive S, Girin L, et al, 2019. Audio-noise power spectral density estimation using long short-term memory[J]. *IEEE Signal Process Lett*, 26(6): 918-922.
- Rasp S, Pritchard M S, Gentine P, 2018. Deep learning to represent subgrid processes in climate models[J]. *Proc Natl Acad Sci USA*, 115(39): 9684-9689.
- Welch P, 1967. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms[J]. *IEEE Trans Audio Electroacoust*, 15(2): 70-73.
- Yang L, Shami A, 2020. On hyperparameter optimization of machine learning algorithms: theory and practice[J]. *Neurocomputing*, 415: 295-316.