

# 一种融合多要素时空特征的数值预报风场订正模型

谢凯文<sup>1</sup>, 杨昊<sup>1</sup>, 邹茂扬<sup>2</sup>, 徐虹<sup>1</sup>, 马亚宇<sup>1</sup>

(1. 成都信息工程大学 计算机学院; 2. 成都信息工程大学 区块链产业学院, 四川 成都 610225)

**摘要:** 目前, 数值天气预报产品已广泛应用于气象预报业务中。针对数值预报模式本身不足导致的预报误差, 为进一步提高其预报准确率, 提出一种融合多要素时空特征的基于U-net和3D注意力机制的风场订正模型。采用该模型对中国气象局研发的国家气象中心GRAPES-3KM模式预报的近地面10 m风场进行偏差订正, 以RMSE、MAE作为评价指标, 与原数值预报产品、传统订正方法以及U-net、CU-net模型进行比较。实验结果表明, 经过所提模型订正后的10 m纬向风RMSE相较原预报数据、LASSO回归、U-net、CU-net模型降低了4.19%~42.67%, MAE降低了6.06%~45.29%; 10 m经向风RMSE指标降低了8.55%~41.35%, MAE降低了6.54%~40.82%; 10 m全风速RMSE降低了6.14%~29.41%, MAE降低了1.5%~21.08%。所提模型相较对照模型有更好的订正效果, 同时未出现订正结果过于平滑的情况。

**关键词:** 数值天气预报; 深度学习; 偏差订正; 多要素融合; 3D注意力

DOI: 10.11907/tj.dk.232189

开放科学(资源服务)标识码(OSID):



中图分类号: TP181

文献标识码: A

文章编号: 1672-7800(2024)011-0084-09

## A Model for Correcting Numerical Wind Field Forecast with Multifactor Spatiotemporal Features

XIE Kaiwen<sup>1</sup>, YANG Hao<sup>1</sup>, ZOU Maoyang<sup>2</sup>, XU Hong<sup>1</sup>, MA Yayu<sup>1</sup>

(1. School of Computer Science, Chengdu University of Information Technology;

2. College of Blockchain Industry, Chengdu University of Information Technology, Chengdu 610225, China)

**Abstract:** At present, numerical weather forecasting products have been widely used in meteorological forecasting operations. A wind field correction model based on U-net and 3D attention mechanism that integrates multiple spatiotemporal features is proposed to further improve the accuracy of numerical forecasting models due to their inherent shortcomings. This model is used to correct the deviation of the near ground 10 meter wind field forecast by the GRAPES-3KM model developed by the China Meteorological Administration. RMSE and MAE are used as evaluation indicators to compare with the original numerical forecast products, traditional correction methods, and U-net and CU net models. The experimental results show that the RMSE of the 10 m meridional wind corrected by the proposed model has decreased by 4.19% to 42.67% compared to the original forecast data, LASSO regression, U-net, and CU net models, and the MAE has decreased by 6.06% to 45.29%; The RMSE index of the 10 meter meridional wind decreased by 8.55%~41.35%, and the MAE decreased by 6.54%~40.82%; The RMSE of 10 m full wind speed decreased by 6.14%~29.41%, and the MAE decreased by 1.5%~21.08%. The proposed model has better correction effect compared to the control model, and there is no situation where the correction results are too smooth.

**Key Words:** numerical weather prediction; deep learning; bias correction; multifactor fusion; 3D attention

收稿日期: 2023-11-22

扫描二维码阅读全文:



基金项目: 四川省科技计划项目(2022YFS0542, 2023JDZH0034)

**作者简介:** 谢凯文(1997-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为大数据挖掘与高性能计算; 杨昊(1981-), 男, 博士, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为大数据挖掘与高性能计算、人工智能与智慧气象; 邹茂扬(1974-), 女, 博士, 成都信息工程大学区块链产业学院教授, 研究方向为基于人工智能的图形图像处理、基于数据挖掘的学习分析; 徐虹(1967-), 女, 博士, 成都信息工程大学计算机学院教授, 研究方向为操作系统与实时软件工程; 马亚宇(1990-), 女, 博士, 成都信息工程大学计算机学院讲师, 研究方向为气象遥感、气候预测。本文通讯作者: 杨昊。

## 0 引言

天气预报一直是人类社会的重要课题之一。由于大气系统极其复杂, 预测天气仍然是一项具有挑战性的任务。为提高天气预报的准确性, 科学家们一直在不断努力, 研究设计了各种新技术和新方法。目前, 天气和气候预测大多基于纯物理模型的计算<sup>[1]</sup>。数值天气预报(Numerical Weather Prediction, NWP)是目前预报天气的通用工具, 其通过求解描述天气演化过程的流体力学与热力学方程组预测未来一段时间内的大气运动状态<sup>[2]</sup>。例如, 曾晓青等<sup>[3]</sup>指出由于模拟大气的数值模式初值场的不确定性与模式的自身缺陷, 预报模式产品具有不确定性与不准确性; 张萌等<sup>[4]</sup>对 GRAPES\_GFS 模式的误差进行评估, 结果表明预报误差有所减小, 但仍未消除; Klein 等<sup>[5]</sup>提出完全预报法(Perfect Prognostic, PP)对预报结果进行订正; Glahn 等<sup>[6]</sup>提出模式输出统计法(Model Output Statistics, MOS), 对前期数值预报的输出结果与观测的天气要素建立关系, 从而预报未来天气, 该方法得到了广泛应用; Homleid 等<sup>[7]</sup>使用卡尔曼滤波对预报结果进行订正。

目前, 国内订正 NWP 主要采用统计学方法, 包括滑动双权重法<sup>[8-9]</sup>、贝叶斯模型<sup>[10-12]</sup>、MOS 法<sup>[13-14]</sup>等。例如, 孙全德等<sup>[15]</sup>使用传统机器学习方法 LASSO 回归和随机森林对华北地区近地面 10 m 风速进行订正, 实验结果表明机器学习方法的订正效果明显优于 MOS 方法; 韩念霏等<sup>[16]</sup>使用梯度提升回归树算法、XGBOOST、堆叠集成学习等方法对京津冀地区复杂地形下的多种气象要素进行站点预报误差订正, 结果表明以上机器学习方法可有效降低系统原始预报误差; Zhang 等<sup>[17]</sup>对西北太平洋地区风场进行了滚动偏差订正分析, 设计了多任务双解码器轨迹门控循环神经网络模型, 订正后风速和风向偏差分别减少了 8%~11% 和 9%~14%; Han 等<sup>[18]</sup>提出一种名为 CU-net 的深度学习方方法, 将预测校正问题转化为 CU-net 框架下的图像对图像翻译问题, 与常规异常数值订正方法相比展示出更好的性能; Tekin 等<sup>[19]</sup>提出一种使用卷积长短期记忆网络结合注意力机制提取预报数据时间特征和空间特征的深度学习模型, 并在与 ConvLSTM<sup>[20]</sup>和 U-Net<sup>[21]</sup>基线模型的比较中取得了不错表现。

在网格风场数据中, 各要素不仅在时间维度上相互影响, 在空间纬度上也存在相互影响。传统的循环神经网络(Recurrent Neural Network, RNN)对时间纬度上的关系有较好的提取效果, 但对空间关系不敏感<sup>[22]</sup>。因此, 本文提出一种同时关注时间维度与空间维度特征的结合经典卷积神经网络(Convolutional Neural Networks, CNN)模型 U-net 与注意力机制<sup>[23-24]</sup>的多要素时空特征数值天气预报订正模型 MCU-net(Multiple-factors Correction U-net), 对 NWPC-GRAPES-3KM(Numerical Weather Prediction Cen-

ter-Global Regional Assimilation and Prediction System-3KM)数值预报产品的 10 m 风格点数据进行偏差订正; 同时将订正结果与 LASSO 回归、U-net 基线模型、CU-net 订正模型等方法结果进行比较, 采用均方根差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)作为评价指标, 以验证所提模型的性能。

## 1 实验数据

### 1.1 数据来源

本文对数值预报产品 NWPC-GRAPES-3KM 的风场格点预报数据进行偏差订正<sup>[25-26]</sup>。该气象产品是由国家气象局数值预报中心发行的高分辨率数值模式预报产品, 空间范围为东经 70°至东经 145°, 北纬 10°至北纬 60.1°, 空间分辨率为 0.03°, 起报时刻为 00 时、03 时、06 时、09 时、12 时、15 时、18 时、21 时, 预报时间间隔为 1 h, 存储格式为 grb2 文件格式。

实况数据采用中国气象局高分辨率陆面数据同化系统(High Resolution China Meteorological Administration Land Data Assimilation System, HRCLDAS)提供的全国 10 m 风场数据<sup>[27]</sup>。该数据时间分辨率为 1 h, 空间分辨率为 0.01°, 空间范围为东经 70.031 2°至东经 140.021 0°, 北纬 15.031 3°至北纬 60.021 3°, 存储格式为 grb2 文件格式。

### 1.2 数据选取

预报数据选取 NWPC-GRAPES-3KM 格点预报 00UTC 起报数据, 气象要素包括 2 m 温度(t2m)、10 m 纬向风分量(10u)、10 m 经向风分量(10v)、表面气压(sp)、2 m 相对湿度(r2)以及 10u 与 10v 合成的 10 m 全风速(10w)。预报时效为 24 h, 时间范围为 2021 年 1 月 1 日至 2021 年 12 月 31 日; 空间范围选择东经 101.41°至东经 105.49°, 北纬 29.31°至 33.15°。该区域位于四川盆地边缘与高原交界处, 包含平原、山地、丘陵与高原多种地理环境, 有利于对订正结果进行综合性分析以验证针对不同地形的订正有效性。实况数据选择 HRCLDAS 提供的 10 m 风场数据, 时间和空间范围与预报数据一致。

### 1.3 数据处理

#### 1.3.1 预报数据处理

对原始预报数据进行多要素提取后再对各要素数据进行裁剪, 裁剪区域经纬度范围为东经 97.81°至东经 105.49°, 北纬 26.31°至 33.99°。起报时间选择 00 时, 时效为 24 h。共计获得 10v、10u、t2m、sp、r2 共 5 种预报要素, 根据 10u、10 v 计算 10 m 全风速数据。公式为:

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

式中:  $W$  表示合成后风速,  $U$  表示纬向风,  $V$  表示经向风。

#### 1.3.2 实况数据处理

实况数据选择与预报数据时刻一致的 10u、10v 以及

10w。由于实况数据空间分辨率为 $0.01^\circ$ ，为了与预报数据匹配，使用双线性插值法对实况数据进行插值处理，将实况数据插值到分辨率为 $0.03^\circ$ 的网格上，以实现经纬度、分辨率与预报数据相对应。双线性插值公式为：

$$f(R_1) = \frac{x_2 - x}{x_2 - x_1} f(Q_{11}) + \frac{x - x_1}{x_2 - x_1} f(Q_{21}) \quad (2)$$

$$f(R_2) = \frac{x_2 - x}{x_2 - x_1} f(Q_{12}) + \frac{x - x_1}{x_2 - x_1} f(Q_{22}) \quad (3)$$

$$f(P) = \frac{y_2 - y}{y_2 - y_1} f(R_1) + \frac{y - y_1}{y_2 - y_1} f(R_2) \quad (4)$$

式中： $P(x, y)$ 为插值目标； $Q_{11}(x_1, y_1)$ 、 $Q_{12}(x_1, y_1)$ 、 $Q_{21}(x_2, y_1)$ 、 $Q_{22}(x_2, y_2)$ 分别为插值目标 $P(x, y)$ 周围的点。将公式化简可得：

$$f(x, y) = f(Q_{11})\omega_{11} + f(Q_{21})\omega_{21} + f(Q_{12})\omega_{12} + f(Q_{22})\omega_{22} \quad (5)$$

由于时间跨度较大，两种数据均存在不同程度的缺失，本文对两种数据进行时间匹配，提取二者共同包含的时间范围，以连续的12 h为一组数据，将不连贯的数据按组进行剔除处理，以保证处理后数据均为12 h内的连续数据。

### 1.3.3 数据加载预处理

由于不同要素之间存在不同的量级和单位，为加快模型收敛速度，消除量纲影响，需对输入数据进行标准化处

理。本文使用零均值化(Zero-Centered)方法对所有数据进行预处理，使每个特征均服从标准正态分布，从而消除特征分布不同导致的结果不同现象。处理公式为：

$$x' = \frac{x - x_{mean}}{x_{std}} \quad (6)$$

式中： $x'$ 为处理后数据， $x_{mean}$ 为该批次样本均值， $x_{std}$ 为该批次样本标准差。

## 2 风场订正模型

### 2.1 MCU-net模型

MCU-net是一种编码器—解码器结构的模型，通过3D卷积与3D注意力机制获取不同气象要素间的关系。模型结构如图1所示。解码器通过一个Attention gates生成注意力特征图并与该层上采样数据进行concat，然后使用双3D卷积调整通道数，再进行上采样。输入数据以连续12 h的时间序列为一组，每组包含6个要素，输入数据性状为 $\{b, c, E, H, W\} = \{1, 12, 6, 128, 128\}$ ，每经过一层编码器，通道数增加一倍，长、宽缩小为原来的1/2，经过4层编码器后最终获得形状为 $\{1, 512, 6, 16, 16\}$ 的向量；然后进入解码器进行上采样，将形状恢复为 $\{1, 12, 6, 128, 128\}$ ；最后使用卷积融合多要素数据得到 $\{1, 12, 1, 128, 128\}$ 的连续12 h输出结果。

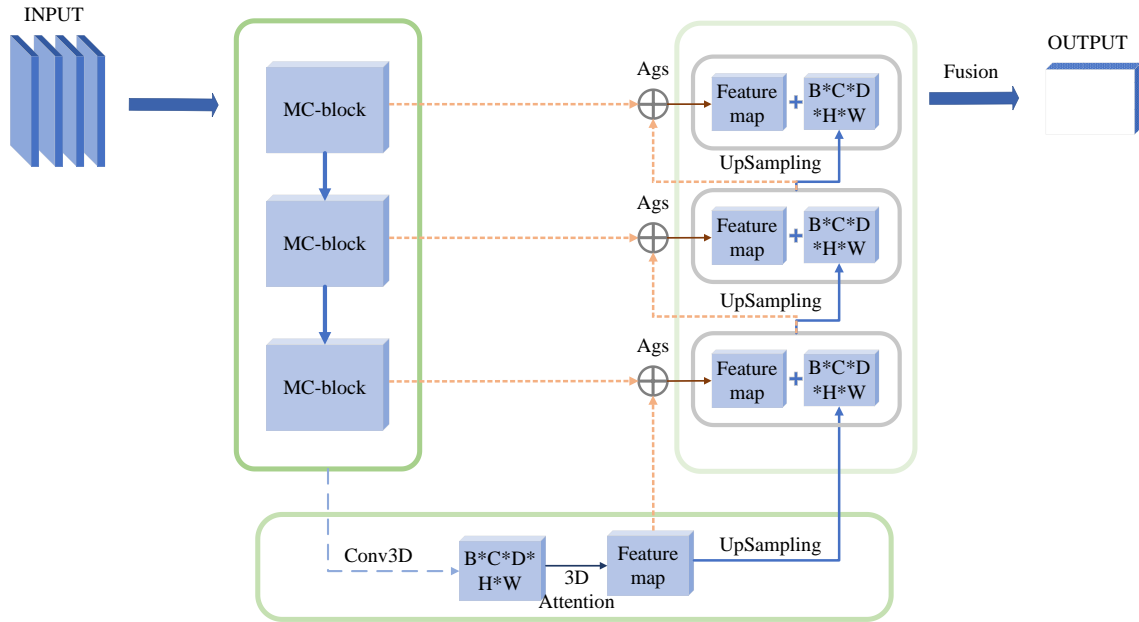


Fig. 1 Model structure

图1 模型结构

#### 2.1.1 编码器

如图2所示，编码器由3个MC-block模块堆叠而成，每个MC-block模块包含1个双卷积结构、注意力模块以及1个MaxPooling3D下采样结构，每个3D注意力模块又由1个3D通道注意力模块和1个3D空间注意力模块组成。编码器每次输入一组连续的12 h气象数据进行卷积与注意

力计算，使用生成的注意力特征图作为跳跃连接输入Attention gates。

注意力模块结构如图3所示。该模块由通道注意力与空间注意力两种注意力模块组成，输入数据首先经过通道注意力获得注意力特征图，并与原始数据进行融合；然后再进行空间注意力计算，与注意力特征图融合得到最终

输出结果。

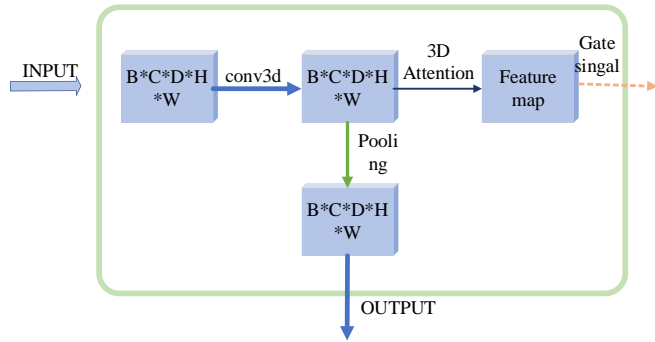


Fig. 2 Encoder structure

图 2 编码器结构




Fig. 3 Attention block structure

图 3 注意力模块结构

### 2.1.2 解码器

解码器每一层由 1 个双卷积和 Attention gates 组成, Attention gates 的两个输入分别为同一层编码器的跳跃连接与上层解码器的 Upsampling 输出, Attention gates 的输出与对应解码器层数据进行 concat 操作, 使该层向量  $H$ 、 $W$  不变, 通道数翻倍, 然后进行双卷积。除了上述结构外, 最后一层解码器额外使用一个  $1 \times 1$  卷积对所有要素进行融合, 从而获得最终输出。解码器结构如图 4 所示。

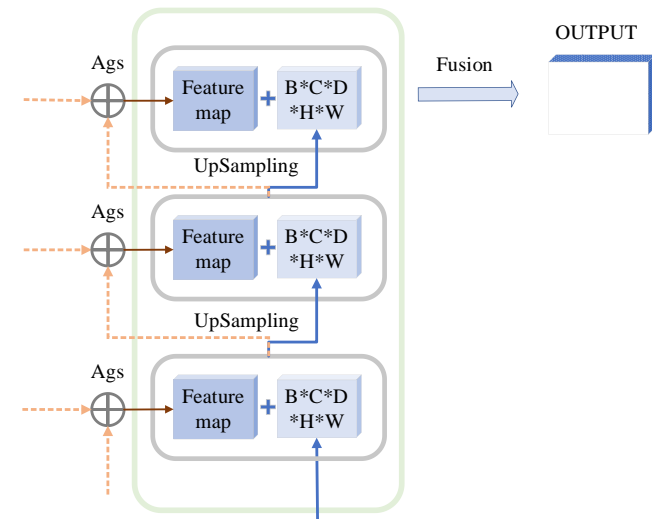


Fig. 4 Decoder structure

图 4 解码器结构

## 2.2 特征提取

### 2.2.1 多要素特征提取

在计算机视觉领域, 能够将注意力聚集在图像重要区域而丢弃掉不相关数据的方法被称为注意力机制, 可以看

作是对图像输入重要信息的动态选择过程, 主要用于提高神经网络在处理序列数据时的性能。针对数值预报网格数据, 本文使用一种融合多要素的 3D 注意力机制。该机制包含空间注意力和通道注意力, 分别实现输入数据空间维度特征与通道间特征的提取。通道注意力结构如图 5 所示。其使用 1 个 3D 最大池化层和 1 个 3D 平均池化层提取多通道信息, 后方连接 1 个多层感知器网络生成通道注意力特征图。




Fig. 5 Channel attention structure

图 5 通道注意力结构

空间注意力结构如图 6 所示。其使用 1 个 3D 最大池化层和 1 个 3D 平均池化层进行特征提取, 然后进行 concat 操作, 最后使用 3D 卷积进行特征融合以获得空间注意力特征图。




Fig. 6 Spatial attention structure

图 6 空间注意力结构

### 2.2.2 Attention Gates

Attention Gates 是神经网络中的常用结构, 用于调控信息流动和集中关注输入数据的特定部分, 抑制低相关度区域特征的响应。其结构如图 7 所示。首先, 对两个输入向量分别进行  $1 \times 1 \times 1$  的卷积操作并进行 add 与 ReLU 操作; 其次, 进行 1 次  $1 \times 1 \times 1$  卷积与 Sigmoid 操作; 最后, 对输出数据形状进行还原, 并与原始输入信号进行融合, 获得最后输出向量。




Fig. 7 Attention gates structure

图 7 Attention gates 结构

### 3 实验方法与结果分析

#### 3.1 实验设置

实验统一使用00时起报数据进行偏差订正,时效为24 h。经过数据预处理,共获得GRAPES-3KM模式气象要素6种,分别为t<sub>2m</sub>、sp、r<sub>2</sub>、10v、10u、10w;以及HRCLDAS实况数据气象要素3种,分别为10v、10u、10w。输入数据以连续12 h为一组,GroundTruth采用对应时刻的实况数据,最终得到模型输入数据大小为[12, 6, 128, 128],GroundTruth大小为[12, 1, 128, 128]。将所有要素经过零均值化后输入网络模型,以对应时刻的订正目标要素作为标签。

模型训练采用Adam作为优化器,初始学习率为0.000 1,学习率降低因子为0.1,使用ReduceLRonPlateau动态调整学习率。分别对每个batch数据进行零均值化以加快模型收敛速度,同时避免不同量纲数据的影响。采用smooth\_l1\_loss作为损失函数,其公式为:

$$SmoothL_1(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (7)$$

采用RMSE、MAE指标对订正效果进行评价,并与原始预报数据、LASSO回归方法以及U-net、CU-net模型输出的风场订正结果进行比较。RMSE、MAE的计算公式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (y_i - \tilde{y}_i)^2} \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - \tilde{y}_i| \quad (9)$$

式中:n表示测试集样本数量;y<sub>i</sub>和 $\tilde{y}_i$ 分别表示测试集的观测值和模型订正值。

#### 3.2 10u订正结果

表1为MCU-net模型与其他方法在测试集上对预报数据10u的订正结果。可以看出,使用不同方法订正后,RMSE与MAE均有不同程度的降低,其中MCU-net模型订正后的RMSE与MAE降低幅度最大。与原始预报数据相比RMSE降低了42.67%,MAE降低了45.29%;与LASSO回归方法相比,其RMSE降低了26.34%,MAE降低了29%;与U-net模型相比,其RMSE降低了1.45%,MAE降低了4.12%;与CU-net模型相比,其RMSE降低了4.19%,MAE降低了6.06%。

Table 1 10u correction results

表1 10u订正结果

评价指标	GRAPES-3KM	LASSO	U-net	CU-net	MCU-net
RMSE	2.39	1.86	1.39	1.43	1.37
MAE	1.70	1.31	0.97	0.99	0.93

图8、图9分别为不同订正方法的RMSE、MAE指标变化趋势。可以看出,基于深度学习方法的U-net、CU-net与MCU-net模型的RMSE和MAE始终处于较低水平,其中

MCU-net在大部分时间内都优于U-net, CU-net次之;而LASSO回归方法的订正结果虽然相较原始数据已极大改善,但是与深度学习方法相比仍有一定差距。




Fig. 8 10u correction result RMSE curve

图8 10u订正结果RMSE曲线




Fig. 9 10u correction result MAE curve

图9 10u订正结果MAE曲线

图10为不同模型订正后的10u风速分布情况。可以看出,该地区整体10u风速变化范围较大,风速相对较高的10u多发生于高原与山地地区,即图中左上区域;图中右下区域多为盆地,风速相对较小,在盆地与高原交界处风速相对较大,HRCLADS实况数据、原始预报数据及各模型订正结果对此均有所体现。从10u订正结果来看,MCU-net对于较高风速的订正效果明显优于其他方法,其中LASSO回归方法的订正结果过于平滑,这表明多要素输入与3D注意力机制能有效提高复杂地形下的风场订正效果。

#### 3.3 10v订正结果

表2为不同方法对10v的订正结果。可以看出,MCU-net模型的RMSE与MAE均为最低,相较原始预报数据的RMSE降低了41.35%,MAE降低了40.82%;与LASSO回归方法相比,其RMSE降低了17.26%,MAE降低了14.52%;与U-net模型相比,其RMSE降低了11.46%,MAE降低了10.71%;与CU-net模型相比,其RMSE降低了8.55%,MAE降低了6.54%。

图11、图12为各模型对测试集10v订正结果的RMSE与MAE变化曲线。可以看出,10v订正结果与10u基本一致,在大部分时间,MCU-net模型的RMSE与MAE比LAS-

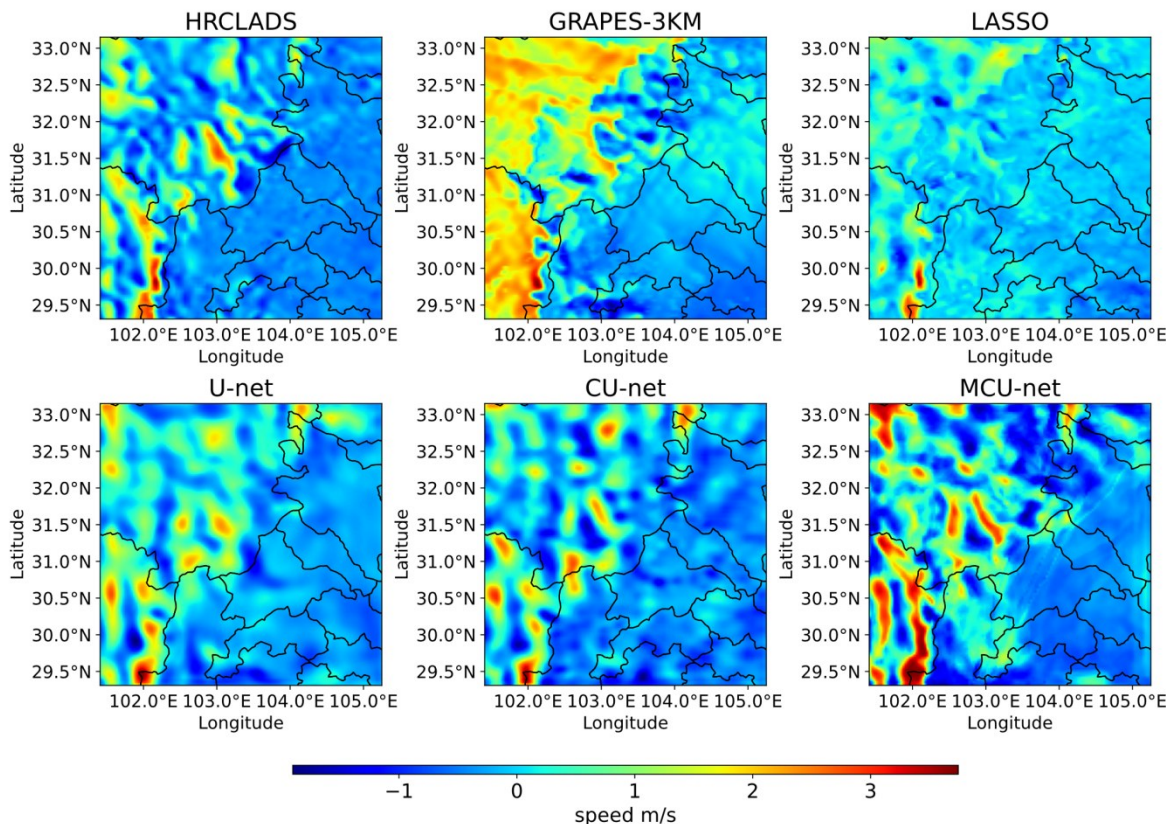


Fig. 10 10u wind speed distribution

图 10 10u 风速分布

Table 2 10v correction results

表 2 10v 订正结果

评价指标	GRAPES-3KM	LASSO	U-net	CU-net	MCU-net
RMSE	2.37	1.68	1.57	1.52	1.39
MAE	1.69	1.17	1.12	1.07	1.00

SO 回归方法、U-net、CU-net 模型更低, CU-net 与 MCU-net 的订正结果较为接近。所有模型订正结果指标变化趋势较为一致且均小于原始预报数据的 RMSE、MAE。

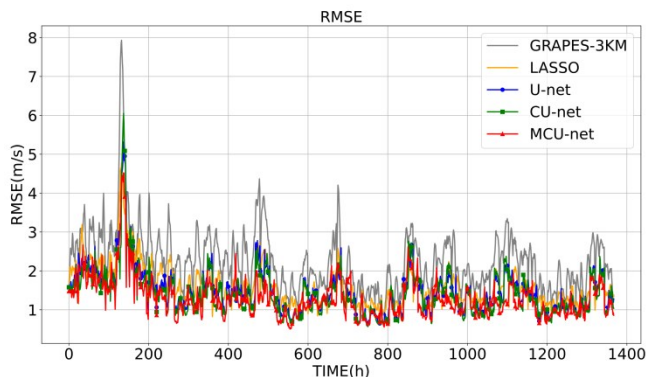


Fig. 11 10v correction result RMSE curve

图 11 10v 订正结果 RMSE 曲线

图 13 为 10v 风速订正结果分布情况。可以看出, 10v 风速与地形也呈现出明显的相关性, 高原山地地区 10v 风速明显大于盆地地区。MCU-net 与 CU-net 模型的订正结

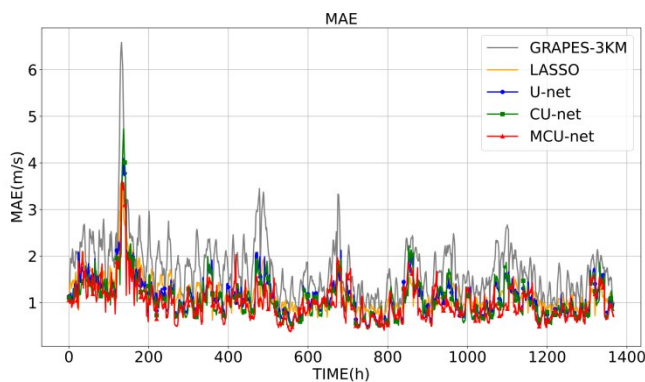


Fig. 12 10v correction result MAE curve

图 12 10v 订正结果 MAE 曲线

果空间分布与实况数据较为一致, 其中 MCU-net 的整体订正效果最好, 与实况数据最为接近, 其次为 CU-net 与 U-net 模型, LASSO 回归方法在方向上误差较大。

### 3.4 10w 订正结果

表 3 为不同方法对 10w 的订正结果。可以看出, MCU-net 模型的 RMSE 与 MAE 均为最低, 相较原始预报数据的 RMSE 降低了 29.41%, MAE 降低了 21.08%; 与 LASSO 回归方法相比, RMSE 降低了 16.83%, MAE 降低了 0.75%; 与 U-net 模型相比, RMSE 降低了 5.61%, MAE 与 U-net 持平; 与 CU-net 模型相比, RMSE 降低了 6.14%, MAE 降低了 1.5%。

图 14、图 15 为不同方法对测试集 10w 订正结果的

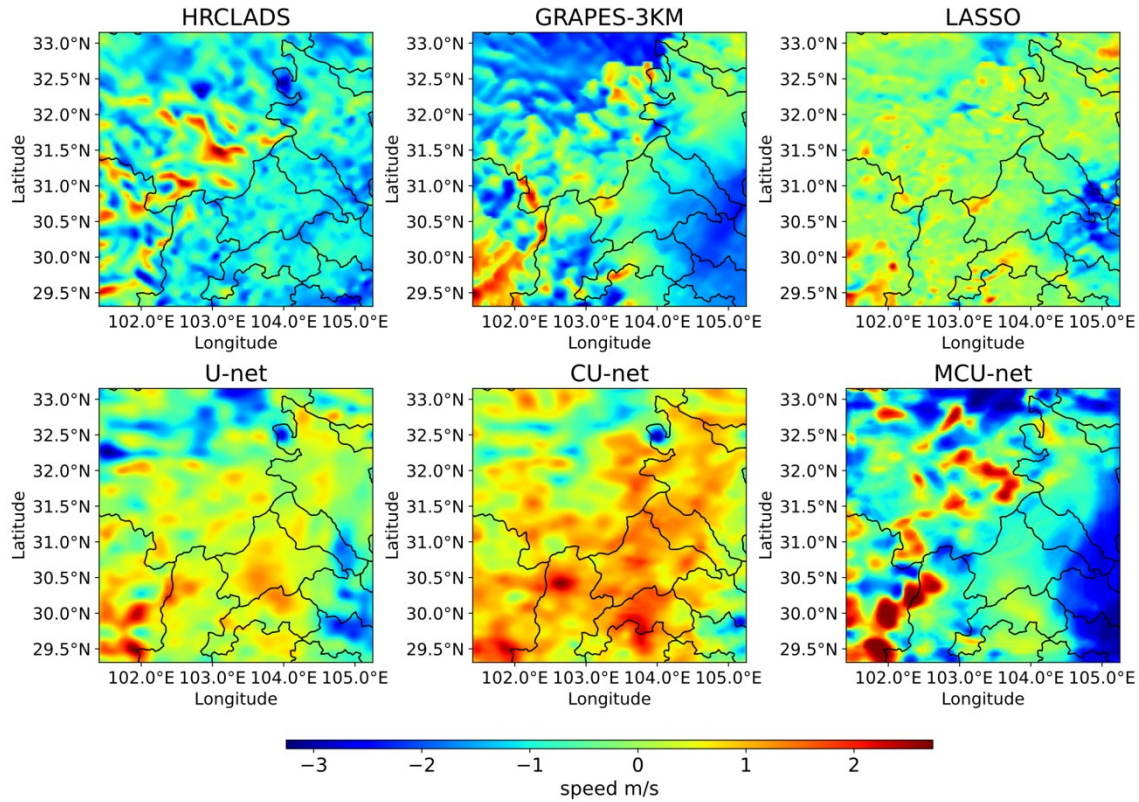


Fig. 13 10v wind speed distribution

图 13 10v 风速分布

Table 3 10w correction results

表 3 10w 订正结果

评价指标	GRAPES-3KM	LASSO	U-net	CU-net	MCU-net
RMSE	2.38	2.02	1.78	1.79	1.68
MAE	1.66	1.32	1.31	1.33	1.31

RMSE与MAE变化曲线。可以看出,MCU-net、CU-net、U-net模型的变化趋势较为一致,且MCU-net在大部分时间内的RMSE、MAE均小于CU-net和U-net模型;LASSO回归方法的变化幅度较大,订正效果不稳定,部分时间订正结果优于深度学习方法,也有部分时间RMSE与MAE大幅高于深度学习方法。

图 16 为 10w 风速订正结果分布情况。可以看出,10w

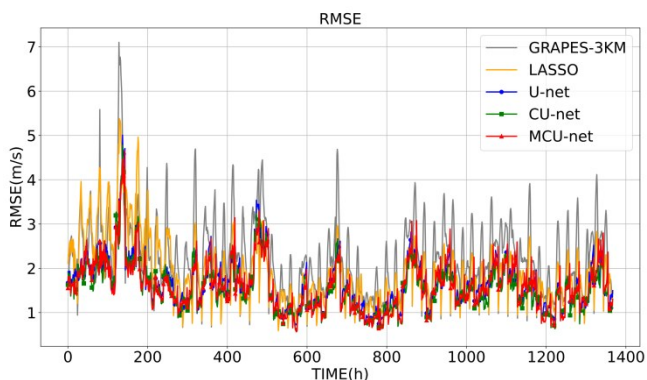


Fig. 14 10w correction result RMSE curve

图 14 10w 订正结果 RMSE 曲线




Fig. 15 10w correction result MAE curve

图 15 10w 订正结果 MAE 曲线

风速的空间分布与10u和10v一致。高原山地风速相对较高,盆地风速相对较低。MCU-net模型对极大风和极小风的订正结果分布情况与实况数据较为接近,其他深度学习方法的订正结果均优于Lasso回归方法。从实况数据来看,大风情况空间分布较为离散,与原始预报数据有一定差异,3种深度学习方法对此均有所改善,其中CU-net模型在盆地地区表现较好,MCU-net模型在高原山地区域表现更好。

### 3.5 消融实验

表4为多要素输入U-net基线模型、使用3D注意力机制加强特征提取的3D-Attention-Unet模型以及加入Attention-gats结构后的MCU-net模型对10u、10v、10w订正结果

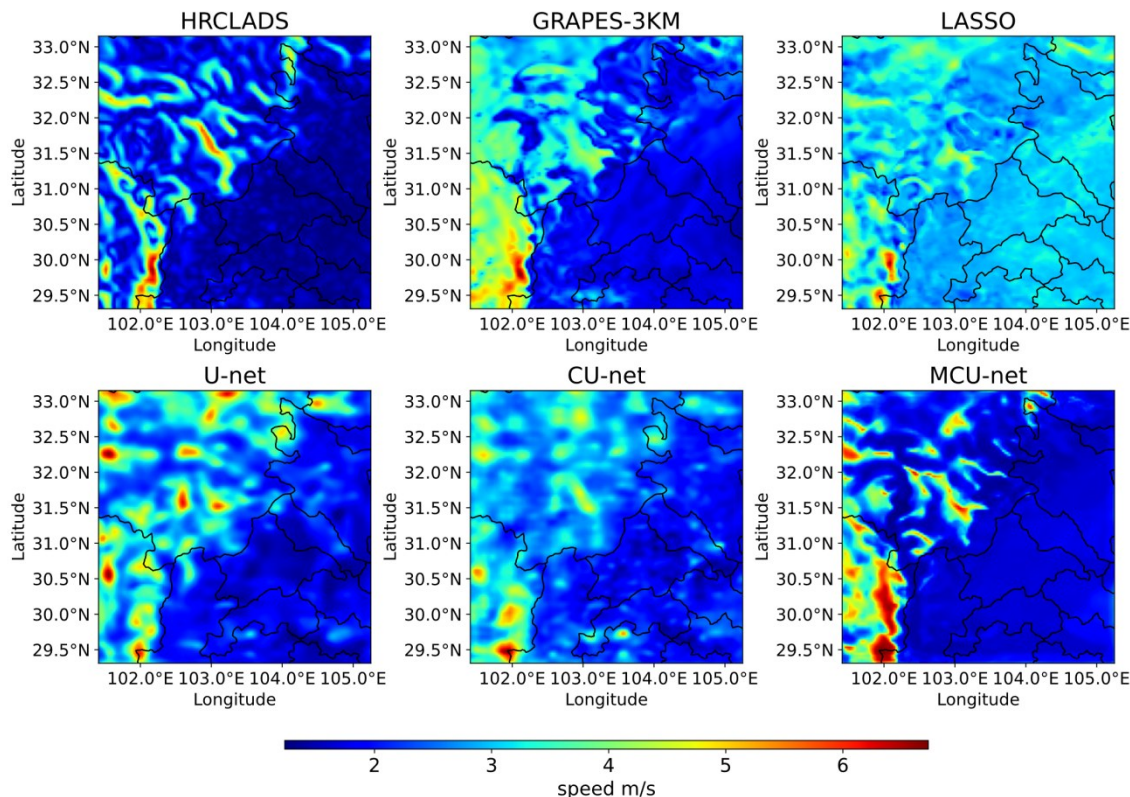


Fig. 16 10w wind speed distribution

图 16 10w 风速分布

的 RMSE 与 MAE 指标情况。可以看出, 3D 注意力机制在多要素特征提取方面相较基线模型有一定提升, Attention-gates 在增大感受野的同时对特征图高相关性区域有更好的强化效果, 对整体订正效果有较大提升。

Table 4 Ablation experiment results

表 4 消融实验结果

风向	评价指标	基线模型	3D-Attention-Unet	MCU-net
10u	RMSE	1.51	1.50	1.37
	MAE	1.08	1.03	0.93
10v	RMSE	1.84	1.63	1.39
	MAE	1.25	1.16	1.00
10w	RMSE	1.85	1.83	1.68
	MAE	1.71	1.36	1.31

#### 4 结语

为提高 NWP 风场预报的准确率, 本文设计了一种融合多种气象要素与时间空间特征的风场订正模型 MCU-net。实验结果表明, 该模型各项评价指标均优于同属深度学习方法的 CU-net 与 U-net, 在高风速情况下表现更佳, 且未出现订正结果过于平滑的情况。然而本文研究尚有较大改进空间: 当前使用的气象要素只有 6 种, 而影响风速的要素多种多样, 未来可考虑使用随机森林、主成分分析等方法筛选高相关性要素进行模型训练; 还可结合地理要素, 如地形、海拔、植被、河流等信息, 同时增加数据集大小, 从而进一步提升订正效果。

#### 参考文献:

- [1] BROMBERG C L, GAZEN C, HICKEY J J, et al. Machine learning for precipitation nowcasting from radar images [DB/OL]. <https://arxiv.org/abs/1912.12132>.
- [2] BJERKNES V, VOLKEN E, BRONNIMANN S. The problem of weather prediction, considered from the viewpoints of mechanics and physics [J]. *Meteorologische Zeitschrift*, 2009, 18(6): 663-667.
- [3] ZENG X Q, XUE F, ZHAO R X, et al. Comparison study on several grid temperature rolling correction forecasting schemes [J]. *Meteorological Monthly*, 2019, 45(7): 1009-1018.  
曾晓青, 薛峰, 赵瑞霞, 等. 几种格点化温度滚动订正预报方案对比研究 [J]. *气象*, 2019, 45(7): 1009-1018.
- [4] ZHANG M, YU H P, HUANG J P, et al. Assessment on unsystematic errors of GRAPES\_GFS 2.0 [J]. *Journal of Applied Meteorological Science*, 2019, 30(3): 332-344.  
张萌, 于海鹏, 黄建平, 等. GRAPES\_GFS 2.0 模式非系统误差评估 [J]. *应用气象学报*, 2019, 30(3): 332-344.
- [5] KLEIN W H, LEWIS B M, ENGER I. Objective prediction of five-day mean temperatures during winter [J]. *Journal of Atmospheric Sciences*, 1959, 16(6): 672-682.
- [6] GLAHN H R, LOWRY D A. The use of model output statistics (MOS) in objective weather forecasting [J]. *Journal of Applied Meteorology and Climatology*, 1972, 11(8): 1203-1211.
- [7] HOMLEID M. Diurnal corrections of short-term surface temperature forecasts using the Kalman filter [J]. *Weather and Forecasting*, 1995, 10: 689-707.
- [8] WANG J, XU Z F, FAN G Z, et al. Study on bias correction for the 2 m temperature forecast of GRAPES\_RAFS [J]. *Meteorological Monthly*, 2015, 41(6): 719-726.

- 王婧,徐枝芳,范广洲,等. GRAPES\_RAFS系统2 m温度偏差订正方法研究[J]. 气象,2015,41(6):719-726.
- [9] CAI Y, XU Z F, ZHU K Y, et al. Diagnosis of 2 m temperature prediction by CMA-MESO system with 3 km resolution[J]. Meteorological Monthly, 2023,49(4):400-414.  
蔡怡,徐枝芳,朱克云,等. CMA-MESO 3 km系统2 m温度预报诊断[J]. 气象,2023,49(4):400-414.
- [10] HENDERSON S B, SHAHIRINIA A H, TAVAKOLI B M. Bayesian estimation of copula parameters for wind speed models of dependence[J]. IET Renewable Power Generation, 2021, 15(16):3823-3831.
- [11] DUCA V E L A, FONSECA T C O, OLIVEIRA F L C. Joint modelling wind speed and power via Bayesian dynamical models[J]. Energy, 2022, 247:123431.
- [12] YE X W, DING Y, WAN H P. Probabilistic forecast of wind speed based on Bayesian emulator using monitoring data[J]. Structural Control and Health Monitoring, 2021, 28(1):e2650.
- [13] PAN J, CHEN Z R, HUANG Y B, et al. Refined prediction of maximum wind speed in autumn and winter along the coast of Guangxi Beibu Gulf based on MOS[J]. Journal of Meteorological Research and Application, 2022,43(1):26-30.  
潘静,陈峥嵘,黄燕波,等. 基于MOS的广西北部湾沿海秋冬极大风速精细化预报[J]. 气象研究与应用,2022,43(1):26-30.
- [14] CHEN Y Y, CHEN X G, MA J R, et al. A study on subtle mos forecasting method of wind[J]. Journal of the Meteorological Sciences, 2006(2):210-216.  
陈豫英,陈晓光,马金仁,等. 风的精细化MOS预报方法研究[J]. 气象科学,2006(2):210-216.
- [15] SUN Q D, JIAO R L, XIA J J, et al. Adjusting wind speed prediction of numerical weather forecast model based on machine learning methods[J]. Meteorological Monthly, 2019,45(3):426-436.  
孙全德,焦瑞莉,夏江江,等. 基于机器学习的数值天气预报风速订正研究[J]. 气象,2019,45(3):426-436.
- [16] HAN N F, YANG L, CHEN M X, et al. Machine learning correction of wind, temperature and humidity elements in Beijing-Tianjin-Hebei region[J]. Journal of Applied Meteorological Science, 2022, 33(4):489-500.  
韩念霏,杨璐,陈明轩,等. 京津冀站点风湿温要素的机器学习订正方法[J]. 应用气象学报, 2022,33(4):489-500.
- [17] ZHANG W, JIANG Y, DONG J, et al. A deep learning method for real-time bias correction of wind field forecasts in the Western north pacific[J]. Atmospheric Research, 2023,284:106586.
- [18] HAN L, CHEN M, CHEN K, et al. A deep learning method for bias correction of ECMWF 24-240 h forecasts[J]. Advances in Atmospheric Sciences, 2021,38(9):1444-1459.
- [19] TEKIN S F, KARAAHMETOGLU O, ILHAN F, et al. Spatio-temporal weather forecasting and attention mechanism on convolutional lstms[DB/OL]. <http://arxiv.org/abs/2102.00696>.
- [20] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[DB/OL]. <https://arxiv.org/abs/1506.04214>.
- [21] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015:234-241.
- [22] LIPTON Z C, BERKOWITZ J, ELKAN C. A critical review of recurrent neural networks for sequence learning[DB/OL]. <https://arxiv.org/abs/1506.00019>.
- [23] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [24] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision, 2018:3-19.
- [25] ZHANG X W, TANG W Y, ZHENG Y G, et al. Comprehensive evaluations of GRAPES\_3 km numerical model in forecasting convective storms using various verification methods[J]. Meteorological Monthly, 2020,46(3):367-380.  
张小雯,唐文苑,郑永光,等. GRAPES\_3 km数值模式对流风暴预报能力的多方法综合评估[J]. 气象,2020,46(3):367-380.
- [26] ZHANG H, WANG Y, CHEN D, et al. Temperature forecasting correction based on operational GRAPES-3km model using machine learning methods[J]. Atmosphere, 2022, 13(2):362.
- [27] JIANG Y, HAN S, SHI C, et al. Evaluation of HRCCLDAS and ERA5 datasets for near-surface wind over Hainan island and south China sea[J]. Atmosphere, 2021,12(6):766.

(责任编辑:尹晨茹)