



计算机科学

COMPUTER SCIENCE

基于跨模态融合和多生成器的热带气旋预测

刘倩, 孙虎, 归耀城, 周国强

引用本文

刘倩, 孙虎, 归耀城, 周国强. 基于跨模态融合和多生成器的热带气旋预测[J]. 计算机科学, 2025, 52(12): 81-91.

LIU Qian, SUN Hu, GUI Yaocheng, ZHOU Guoqiang. [Tropical Cyclone Forecasting Based on Cross-modal Fusion and Multi-generators](#) [J]. Computer Science, 2025, 52(12): 81-91.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于知识图谱嵌入的异构图欺诈用户检测](#)

Fraud User Detection Based on Heterogeneous Information Network with Knowledge Graph Embedding

计算机科学, 2025, 52(11A): 250400085-7. <https://doi.org/10.11896/jsjcx.250400085>

[基于时序对抗网络的流量生成方法](#)

Traffic Generation Methods Based on Temporal Generative Adversarial Networks

计算机科学, 2025, 52(11A): 250200021-8. <https://doi.org/10.11896/jsjcx.250200021>

[结合超图学习的多注意力机制新闻推荐方法](#)

Multiple Attention Mechanism News Recommendation Approach with Hypergraph Learning

计算机科学, 2025, 52(11A): 250200067-7. <https://doi.org/10.11896/jsjcx.250200067>

[基于生成模型的学生在线学习表现预测混合方法研究](#)

Research on Hybrid Methods for Predicting Students' Online Learning Performance Based on Generative Model

计算机科学, 2025, 52(11A): 250200029-9. <https://doi.org/10.11896/jsjcx.250200029>

[基于频率通道注意力机制和MSCNet的锂电池剩余使用寿命预测](#)

Remaining Useful Life Prediction of Lithium-ion Batteries Based on Frequency-channel Attention Mechanism and MSCNet

计算机科学, 2025, 52(11A): 241200041-8. <https://doi.org/10.11896/jsjcx.241200041>

基于跨模态融合和多生成器的热带气旋预测

刘倩¹ 孙虎¹ 归耀城² 周国强^{1,3}

1 南京邮电大学计算机学院、软件学院、网络空间安全学院 南京 210023

2 南京邮电大学现代邮政学院 南京 210023

3 地球信息工程国家重点实验室 西安 710018

(qianliu@njupt.edu.cn)

摘要 准确预测热带气旋的运动轨迹和强度对减轻和预防灾害至关重要。基于深度学习的方法虽然表现出出色的预测性能,但这类方法大多只关注单模态数据,忽略了不同模态之间的相关性。为了充分利用多模态数据中的丰富信息,提出一种基于跨模态融合和多生成器的热带气旋预测模型。该模型包括一个多模态特征提取模块、一个跨模态特征融合模块和一个生成对抗网络。多模态特征提取模块从历史最佳轨迹数据、大气再分析数据以及环境场数据中分别提取相应的特征表示。跨模态特征融合模块通过一种新颖的跨模态特征互补策略融合多模态特征。生成对抗网络通过多个生成器生成最终的热带气旋预测结果。此外,还构建了一个特征融合损失以帮助提高模型的性能。实验表明,所提方法不仅能在训练和推理阶段都保持较高的效率,而且具有更好的预测性能。

关键词: 热带气旋预测; 跨模态融合; 多生成器; 注意力机制

中图分类号: TP391.1

Tropical Cyclone Forecasting Based on Cross-modal Fusion and Multi-generators

LIU Qian¹, SUN Hu¹, GUI Yaocheng² and ZHOU Guoqiang^{1,3}

1 School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

2 School of Modern Posts, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

3 State Key Laboratory of Geo-Information Engineering, Xi'an 710018, China

Abstract Accurately predicting the trajectory and intensity of tropical cyclones (TCs) is essential for disaster mitigation and prevention. Although deep learning-based advances have demonstrated great prediction performance, a majority of these methods only focus on unimodal data and overlook the rich correlations between different modalities. To fully leverage the rich information contained in multimodal data, a novel framework for tropical cyclone forecasting based on cross-modal fusion and multi-generators is proposed. The framework includes a multimodal feature extraction module, a cross-model feature fusion module and a generative adversarial network (GAN). The multimodal feature extraction module obtains feature representations from the best historical trajectory data, atmospheric reanalysis data and environmental field data respectively. The cross-model feature fusion module fuses multimodal features through a novel cross-modal feature complementation strategy. GAN produces final TC predictions through multiple generators. Additionally, a feature fusion loss is constructed to help boosting the model's performance. Experiments show that the proposed method can not only maintain high efficiency in training and inference stages, but also achieve better prediction performance.

Keywords Tropical cyclone prediction, Cross-modal fusion, Multiple generators, Attention mechanism

1 引言

热带气旋是源自热带和亚热带海洋地区的极端天气现象,往往会带来很严重的自然灾害,如洪水、风暴潮和强风,严重威胁人类生命、财产安全和社会经济活动。有关政府部门

致力于通过提前预测热带气旋的轨迹和强度来制定更有效的防灾计划,然而,热带气旋发展的不确定性及其运动的复杂性使其预测成为一项非常具有挑战的任务。

传统的热带气旋预测方法主要有3种:动态模型^[1]、统计模型^[2]和动态统计模型^[3]。虽然这些方法对热带气旋预报做

到稿日期:2025-01-06 返修日期:2025-04-25

基金项目:国家重点基础研究计划(2020YFA0713600);国家自然科学基金(62272214);国家对地观测科学数据中心开放课题(NODAOP2024011)

This work was supported by the National Key Basic Research Program (2020YFA0713600), National Natural Science Foundation of China (62272214) and National Earth Observation Data Center Open Project (NODAOP2024011).

通信作者:周国强(zhougq@njupt.edu.cn)

出了重大贡献,但其预测精度、计算成本和时效性仍不能满足现代天气预报的需求。近年来,越来越多的研究人员将深度学习技术应用于现实生活,如交通预测^[4]和人体姿势识别^[5]等。深度学习方法同样适用于热带气旋预测任务,许多学者对其进行了探索,验证了深度学习在该领域的潜力。

在热带气旋轨迹预测任务中,学者通常使用一维时间序列数据或者二维遥感图像。Alemany 等^[6]基于美国国家飓风中心公开的热带气旋一维数据,使用 RNN 预测热带气旋轨迹。虽然 RNN 在短期预测任务中性能较好,但其长期预测能力仍需进一步提升。因此,长短期记忆(Long Short-Term Memory, LSTM)模型被用于提高热带气旋轨迹的长期预测性能^[7-8]。此外,Wang 等^[9]将双通道卫星图像作为模型输入,开发了一个 CNN 网络来预测热带气旋轨迹。

在热带气旋强度预测任务中,学者通常使用富含空间信息且实时性较高的遥感图像。Zhang 等^[10]设计了一个双分支 CNN 来预测热带气旋强度。Zhang 等^[11]将时空编码模块集成到预测模型中。Jiang 等^[12]首次利用卡尔曼滤波对热带气旋强度估计误差进行校正。Ma 等^[13]提出一个基于 Xception 的热带气旋强度估计方法。

然而,从单模态数据中提取的特征十分有限,不能完全捕捉热带气旋的复杂性,导致预测性能不佳。于是,众多研究者受多模态学习^[14]的启发,开始利用多源多模态数据进行热带气旋预测。Wang 等^[15]提出一种将因果关系与多模态数据相结合的热带气旋强度预测模型。Jiang 等^[16]提出一个带空间注意力模块的网络,将多维环境变量和物理因素引入模型。Ma 等^[17]将历史强度序列和外部环境变量引入模型。然而,不同的多模态融合策略获得的特征多样性也不尽相同,多数现有方法是对处理后的多模态特征进行简单相加^[18-19],或沿通道拼接后进行卷积操作^[20]。虽然特征融合后的性能优于融合之前,但其未能深入挖掘各模态特征之间复杂的非线性关联,无法充分利用气象因子(风速、压强)和环境因子(位势高度、海平面温度)等不同模态数据在描述热带气旋特性时的内在互补性,丢失了大量潜在的关键信息,使得对热带气旋的刻画不够全面和精准。

为了解决传统单任务预测方法预测精度低的问题,不少学者开始探索多任务预测方法。为了解决热带气旋强度和尺寸估计任务收敛速度不一致的问题,Tian 等^[21]提出一种具有自适应损失平衡的模型。为了实现短期热带气旋轨迹和强度预测,Gan 等^[22]采用了 4 种主流深度学习模型,并探讨了预测策略中关键参数对预测结果的影响。Na 等^[23]使用回声状态网络创建了一个轻量级的模型。Tong 等^[24]利用改进的 ConvLSTM^[25]模型进行预测,具有很好的稳定性和较高的预测精度。概率锥预测能够预测一组潜在的轨迹和强度,形成一个轨迹锥体,能更生动地展示热带气旋可能的移动区域,提供更丰富的天气信息,更贴近实际应用场景^[26]。已有工作^[27]验证了基于多生成器的生成对抗网络(Generative Adversarial Network, GAN)在预测行人轨迹方面的潜力。受此启发,基于多生成器的 GAN 模型^[28]被提出并用于热带气

旋预测。但对西北太平洋台风的 24 h 预测实践发现,该模型存在明显问题:一方面,预测粒度较粗,难以精确到对小型路径偏移和强度小范围波动的预测;另一方面,模型结构复杂,参数众多,计算成本高昂,而且模型的可解释性差,调试与优化难度加重。

针对上述问题,本文提出一种基于跨模态融合和多生成器的热带气旋预测模型(CMF-TCMG),用于预测未来 6~24 h 热带气旋的运动趋势和强度。为了提高模型的预测性能,设计了一个跨模态融合模块,以充分利用多模态数据的互补信息。为了解决模型预测粒度和长期预测能力不足的问题,利用多个生成器生成概率锥。为了进一步促进多模态数据的有效融合,构建了一个融合损失。为了降低模型的复杂度,本文未使用生成器选择网络和蒙特卡罗采样^[28],而是采用了一种更简单的多轨迹生成策略。这种模型的简化在一定程度上减少了模型参数和运行时间,同时也降低了模型对季节变化和气旋强度的敏感性。本研究的主要贡献如下:

1) CMF-TCMG 利用多生成器和跨模态融合来提高热带气旋预测的准确性和可靠性,不仅能有效控制模型复杂度,而且提高了模型的预测性能。

2) 提出一种新的跨模态特征互补方法,通过特征互补获取多样化的特征,用于促进热带气旋的短期和长期预测。

3) 额外构建了融合损失函数,在训练过程中使用该损失函数能促进多模态特征的有效融合。

2 数据

2.1 数据集说明

本文使用的数据包括:中国气象局(China Meteorological Administration, CMA)最佳轨迹数据 CMA-BST¹⁾、欧洲中期天气预报中心发布的第五代再分析数据 ERA5²⁾和环境场数据。CMA-BST 中的气象因子刻画了热带气旋的基本特征。ERA5 中的环境因子为模型提供了丰富的气象背景信息,有助于模型理解热带气旋所处的宏观环境。环境场数据包括但不局限于前两者,进一步补充了热带气旋周围环境对其可能产生影响的相关特征。

CMA 最佳轨迹数据集(CMA-BST)^[29]由中国气象局负责收集、整理和发布,以文本形式进行存储,用于记录有关热带气旋历史路径的详细信息及其移动过程中的变化趋势,如气旋中心的维度、强度类别、历史风向等。这些数据对于了解热带气旋的特性、路径预测以及气象研究具有重要意义。本文选取热带气旋中心所对应的经度、纬度、压强和风速这 4 个气象因子,度量单位分别为 $^{\circ}$, $^{\circ}$, hPa 和 m/s,旨在挖掘热带气旋的深层特性。CMA 数据的时间分辨率为 6 h,时间范围为 1950—2019 年,研究区域包括西北太平洋($100^{\circ}\text{E}-180^{\circ}\text{E}$, $0^{\circ}\text{N}-60^{\circ}\text{N}$)。本文旨在通过分析这些气象因子,深入探索热带气旋的潜在特征,提高对其行为的理解。

ERA5 再分析数据集由欧洲中期天气预报中心发布,提供了大气、地面和海洋各种气象要素的高分辨率时空数据,且

¹⁾ <https://tcdata.typhoon.org.cn/zjljsjj.html>

²⁾ <https://cds.climate.copernicus.eu/cdsapp#! /dataset/reanalysis-era5-pressure-levels?tab=overview>

数据以网格的形式存储。它通过重新分析过去几十年的观测数据而得,包括对地面观测、卫星数据、飞机观测和其他来源的数据,以确保数据的质量和有效性。本文采用“ERA5 hourly data on pressure levels from 1979 to present in ERA5”子集中的位势高度(Geopotential Height,GPH),空间分辨率为 0.25° ,与CMA数据的时间分辨率和周期相匹配,压强为 500 hPa ^[19]。

选择合适的环境因子对增强热带气旋发展过程的理解至关重要^[28]。环境场数据(Env-Data)包括但不限于从CMA-BST和ERA5数据集获得的要素。本文Env-Data包括风速、强度等级、24h历史强度变化、经度、纬度等。表1列出了环境场的详细信息。

表1 环境场的详细信息

Table 1 Detailed component of the environmental field

环境因子	描述
WND	风速
INT_CLS	强度类别
V	移动速度
ΔINT_{24}	历史强度变化(24h)
MONTH	—
LON	经度
LAT	纬度
DIR_{12}	历史气流方向(12h)
DIR_{24}	历史气流方向(24h)
SubTH	亚热带高度

2.2 数据集处理和划分

在模型训练之前,本文对数据进行了标准化处理,以加速模型的收敛。CMA数据和ERA5数据的标准化规则分别为Z-score和Max-Min,具体如下:

$$x_{\text{norm}}^{\text{CMA}} = \frac{x - \mu}{\sigma} \quad (1)$$

$$x_{\text{norm}}^{\text{ERA5}} = \frac{x - \text{Min}}{\text{Max} - \text{Min}} \quad (2)$$

其中, x_{norm} 和 x 分别表示规范化数据和原始数据, μ 和 σ 分别表示输入的平均值和标准差, Min 和 Max 表示输入数据的最小值和最大值。

CMA-BST数据集分为3部分:训练集、验证集和测试集。从1950—2016年的数据中随机选择80.3%(1317个热带气旋)进行训练,剩下的19.7%(323个热带气旋)为验证集。2017—2019年间共82个热带气旋被用作评估模型性能的测试集。具体的划分情况如表2所列。其中,气旋数量代表相应年份区间内发生的热带气旋例数,样例数量代表相应数据集中包含的气旋样本数据点数目(时间分辨率为6h)。ERA5数据集与环境场数据的划分情况与CMA-BST一致。

表2 数据集的划分详情

Table 2 Division of datasets

数据集	年份	气旋数量	样例数量
训练集	1950—2016	1317	43370
验证集	1950—2016	323	10902
测试集	2017—2019	82	2567

3 方法

3.1 问题定义

本文提出的CMF-TCMG模型用于预测未来时刻的热带

气旋轨迹和强度。该任务可视为一个时空预测问题,输入数据分3部分。1)CMA数据:由经度LON、纬度LAT、风速WND和压强P组成,记为 $Data_{\text{CMA}} = \{LON, LAT, WND, P\}$ 。2)ERA5数据:由位势高度(GPH)再分析数据组成,记为 $Data_{\text{ERA5}} = \{GPH\}$ 。3)环境场数据:记为 $Data^{\text{Env}}$,其具体构成详见表1。假设输入的历史数据为 $X = \{x_1, \dots, x_i, \dots, x_n; Data_{\text{CMA}}^{\text{Env}}, Data_{\text{ERA5}}^{\text{Env}}\}$,其中 $x_i = \{Data_{\text{CMA}}^i, Data_{\text{ERA5}}^i\}$,即每个时刻 i 的输入 x_i 包含了对应时刻的CMA数据和ERA5数据。预测的序列为 $\hat{Y} = \{\hat{y}_{n+1}, \dots, \hat{y}_{n+j}, \dots, \hat{y}_{n+m}\}$,其中 $\hat{y}_{n+j} = \{\hat{y}_{\text{LON}}^{n+j}, \hat{y}_{\text{LAT}}^{n+j}, \hat{y}_{\text{WND}}^{n+j}, \hat{y}_{\text{P}}^{n+j}\}$;真实的未来轨迹和强度序列为 $Y = \{y_{n+1}, \dots, y_{n+j}, \dots, y_{n+m}\}$,用于评估模型预测的准确性。模型的整体训练目标如下:

$$\hat{Y} = \text{argmax } P(Y|X) \quad (3)$$

3.2 模型整体架构

CMF-TCMG模型的整体架构如图1所示,包括3个主要部分:多模态特征提取、跨模态特征融合和生成对抗网络。

多模态特征提取模块有3个分支,分别以CMA数据、ERA5数据和环境场数据为输入。每个分支都有相应的特征编码器用于特征提取,因此在设计特征编码器时应充分考虑不同数据的特点。

跨模态特征融合模块以CMA数据、ERA5数据和环境场数据编码后的特征作为输入。首先利用跨模态特征互补模块(Cross-modal Feature complementary Module,CMFC)实现CMA数据和ERA5数据之间的特征互补。然后将融合后的特征与ERA5和环境场特征拼接,生成最终的融合特征。该过程有利于捕获局部和全局多个维度的特征,增强模型的长期预测能力。

生成对抗网络模块利用跨模态特征融合模块的输出以及随机噪声作为输入。该模块的每个子生成器独立学习一个潜在的运动趋势,然后对其进行集成。鉴别器根据实际数据评估生成的轨迹,从生成器输出的概率锥中选择最佳轨迹。生成器和鉴别器之间的动态交互使得生成的轨迹更接近真实数据,提高了模型的性能和泛化能力。

3.3 多模态特征抽取

1)CMA数据特征提取。图1的红色分支表示CMA数据特征提取过程,以 $Data_{\text{CMA}}$ 为输入,用 $Encoder_{\text{CMA}}$ 进行编码得到特征 $F_{\text{CMA}}^{\text{En}}$,过程如下:

$$F_{\text{CMA}}^{\text{En}} = \mathcal{O}(Data_{\text{CMA}}; \mathbf{W}_{\text{MLP}_{\text{CMA}}}) \quad (4)$$

其中, $\mathcal{O}(\cdot)$ 表示多层感知器模块, $\mathbf{W}_{\text{MLP}_{\text{CMA}}}$ 表示其权重矩阵。

2)ERA5数据特征提取。图1蓝色分支表示ERA5数据特征提取过程。考虑到3D U-Net^[30]的优异性能,并受文献^[28]启发,使用3D U-Net对不同时刻的ERA5数据进行特征提取。该分支以 $Data_{\text{ERA5}}$ 为输入,3D U-Net有两个功能:一方面从历史序列数据中提取时空特征 $F_{\text{ERA5}}^{\text{En}}$,另一方面预测未来时刻的大气再分析图 $F_{\text{ERA5}}^{\text{De}}$,过程如下:

$$F_{\text{ERA5}}^{\text{En}}, F_{\text{ERA5}}^{\text{De}} = Encoder_{\text{ERA5}}(Data_{\text{ERA5}}; \mathbf{W}_{Encoder_{\text{ERA5}}}) \quad (5)$$

其中, $Encoder_{\text{ERA5}}$ 由3D U-Net和一个多层感知器组成, $\mathbf{W}_{Encoder_{\text{ERA5}}}$ 表示其权重矩阵。

3)环境场数据特征提取。图1中的黄色分支表示从环境场数据中提取特征。本文采用与文献^[28]类似的方法对环境

场数据进行特征提取。环境场由时间序列和特定时间的环境信息组成,详见表1。该分支利用多层感知器和CNN作为编码器,分别从CMA数据和ERA5数据中提取特征。编码后的特征记为 F^{Env} ,过程如下:

$$F_{CMA}^{Env} = \mathcal{O}(Data_{CMA}^{Env}; W_{MLP_{Env}}) \quad (6)$$

$$F_{ERA5}^{Env} = \mathcal{O}(Data_{ERA5}^{Env}; W_{CNN_{Env}}) \quad (7)$$

$$F^{Env} = \mathcal{O}(Concat(F_{CMA}^{Env}, F_{ERA5}^{Env}); W_{MLP_{Envfs}}) \quad (8)$$

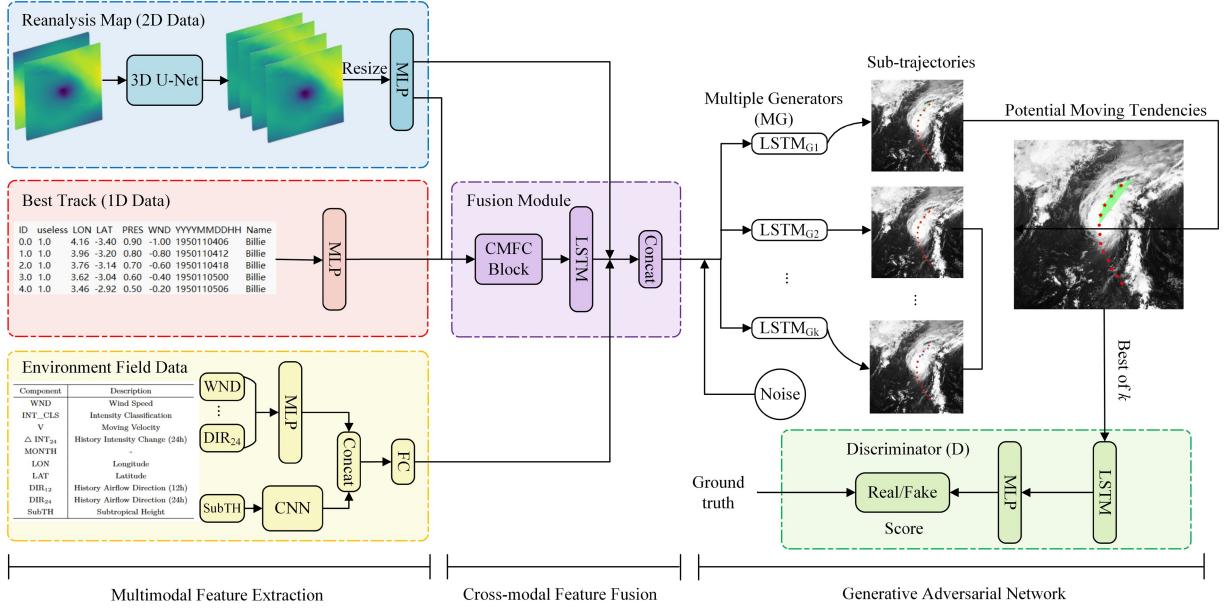


图1 CMF-TCMG模型的整体架构(电子版为彩图)

Fig. 1 Overall architecture of the CMF-TCMG model

3.4 跨模态特征融合

跨模态特征融合的整体过程如图1中紫色块所示,是模型的重要组成部分,可分为两个阶段。

第一阶段如图2所示,本文设计了跨模态特征互补模块(CMFC)以促进不同模态之间的特征互补。CMFC的第一个分支以特征 F_{CMA}^{En} 和 F_{ERA5}^{En} 为输入。 F_{CMA}^{En} 先经过具有不同粒度卷积核(Conv 3×3 , Conv 5×5 和 Conv 7×7)的卷积层,以充分挖掘CMA数据中的空间信息。接着对卷积层的输出依次进行取均值和Softmax运算,得到 F_{CMA}^{En} 的注意力权重矩阵 A_{CMA} 。同理,CMFC的第二个分支输出 F_{ERA5}^{En} 的注意力权重矩阵 A_{ERA5} 。然后将 F_{CMA}^{En} 乘以 A_{CMA} 得到自身模态的增强特征,将

F_{CMA}^{En} 乘以 A_{ERA5} 得到跨模态互补特征,两者取均值后得到增强后的CMA数据编码特征 F_{CMA}^{En} 。同理,可得到增强后的ERA5数据编码特征 F_{ERA5}^{En} 。最后,将 F_{CMA}^{En} 和 F_{ERA5}^{En} 拼接后送入多层感知器层生成初始的融合特征 F_{fusion}^{En} 。与单模态特征相比,跨模态信息丰富了特征多样性,更利于热带气旋的长期预测。第一阶段的跨模态特征融合过程如下:

$$F_{CMA}^{En}, F_{ERA5}^{En} = CMFC(F_{CMA}^{En}, F_{ERA5}^{En}; W_{CMFC}) \quad (9)$$

$$F_{fusion}^{En} = \mathcal{O}(Concat(F_{CMA}^{En}, F_{ERA5}^{En}); W_{MLP_{fs}}) \quad (10)$$

其中,CMFC(\cdot)用于实现第一阶段的跨模态特征融合, W_{CMFC} 表示CMFC(\cdot)的权值矩阵, $W_{MLP_{fs}}$ 表示多层感知器层的权值矩阵。

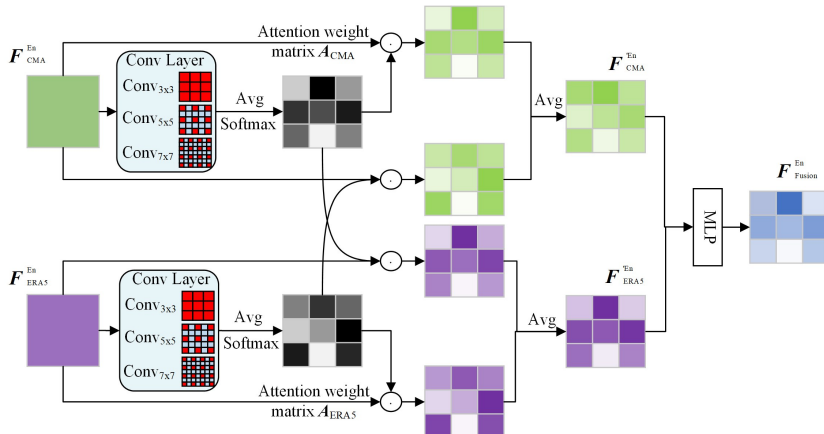


图2 跨模态特征互补模块结构

Fig. 2 Structure of cross-modal feature complementation module

第二阶段的跨模态特征融合利用 $Encoder_{LSTM}$ 从 F_{fusion}^{En} 中提取时间特征,得到时空特征 \mathbf{h} ,然后以时空特征 \mathbf{h} 、编码器 $Encoder_{ERA5}$ 输出的大气再分析图特征 F_{ERA5}^{De} 和环境场数据的编码特征 F^{Env} 为输入,将其拼接起来输出最终的融合特征。第二阶段的跨模态特征融合过程如下:

$$\mathbf{h} = Encoder_{LSTM}(F_{fusion}^{En}; \mathbf{W}_{EnLSTM}) \quad (11)$$

$$F_{fusion} = Concat(\mathbf{h}; F_{ERA5}^{De}; F^{Env}) \quad (12)$$

其中, $Encoder_{LSTM}$ 为用于编码的 LSTM 层, \mathbf{h} 为从历史 TC 数据中提取的时空特征, \mathbf{W}_{EnLSTM} 为 LSTM 层的权重矩阵。

3.5 生成对抗网络

1) 多生成器 (MG)。文献 [26] 验证了基于单生成器的 GAN 模型进行热带气旋预测的有效性。虽然该方法在短期预测方面有明显的优势,但单生成器的学习能力不足,预测性能仍有待提高。受文献 [28] 启发,本文利用多个生成器来解决单生成器预测粒度不足和长期预测能力不足的问题。

生成器的主模块是 LSTM,每个子生成器 $LSTM_{G_i}$ 经过训练后形成自己的预测趋势(如图 1 右侧的子轨迹所示),进而构成热带气旋未来潜在的运动区域,为其预测提供更合理的选择范围。所有生成器采用相同的结构,但不共享权重。生成器生成的“最佳”预测基于 MoN (Minimum-of-N) 损失 [31] 来选择,以鼓励模型生成更精确的轨迹,详情见 3.6 节。此外,引入随机噪声 $z_t \sim N(0, 1)$, $LSTM_{G_i}$ 的输入为跨模态特征融合模块的输出特征 $F_{fusion} = [\mathbf{h}; F_{ERA5}^{De}; F^{Env}]$,输出是预测的热带气旋轨迹和强度。生成器 G_i 的主要实现过程如下:

$$\hat{Y}_t = LSTM_{G_i}(F_{fusion}, z_t; \mathbf{W}_{LSTM_{G_i}}) \quad (13)$$

其中, $t \in \{1, 2, \dots, k\}$, k 为生成器的个数; $LSTM_{G_i}(\cdot)$ 为第 t 个生成器的解码器; $\mathbf{W}_{LSTM_{G_i}}$ 表示 $LSTM_{G_i}$ 中的权重矩阵。

本文采用一种简单的子轨迹生成策略,即所有子生成器都可以在每次迭代中学习生成规律和输出预测结果。该方法预测热带气旋 24 h 内的潜在移动区域,通过集成所有子生成器的输出生成一个更全面的预测,有助于提高模型的整体效率和泛化能力。文献 [28] 也生成了一组预测,但其提出的生成器选择网络引入了更多参数。本文策略使模型更易在实际应用中部署和使用。两种模型复杂度的比较见 4.5 节。

2) 鉴别器 (D)。为了促使生成器生成更逼真的样本,本文构建鉴别器 D 来检验生成器的生成效果。鉴别器 D 由一个改进的 LSTM 构成,即将 LSTM 最后一层的输出替换为判别结果。鉴别器 D 的训练目标为找到一种平衡,既能正确分类真实样本,又能准确辨别出生成器生成的假样本。

3) 概率锥预测。概率锥预测方法生成一组可能的轨迹和强度,从而产生轨迹锥,与预测单一轨迹和强度的方法相比具有明显优势。轨迹锥提供多种可能的轨迹,为决策者提供更有价值的信息。

如图 1 右半部分所示,跨模态特征融合模块的输出与随机噪声一起作为多个子生成器的输入,且每个子生成器分别预测未来 24 h 的热带气旋轨迹和强度。多条子轨迹通过凸包 (Convex Hull) 算法构成一个概率锥,包含未来可能的轨迹和强度范围,提供了更全面和丰富的预测信息。

3.6 损失函数

1) 对抗损失。基于 GAN 的深度学习模型通常用对抗损失 [32] 优化生成器 (G) 和鉴别器 (D)。本文也使用对抗损失来促进生成器产生更真实和准确的结果。对抗损失公式如下:

$$\begin{aligned} \mathcal{L}_{adv} &= \min_G \max_D \mathcal{L}_{GAN}(G, D) \\ &= \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \end{aligned} \quad (14)$$

其中, x 为真实数据, $p_{data}(x)$ 为其样本分布, z 为随机噪声, $p_z(z)$ 为其在潜在空间的先验分布。

2) MoN 损失。MoN (Minimum-of-N) 损失 [31] 将每个生成器的预测与真实值进行比较,并根据特定的标准来选择“最佳”结果,以生成更可信和更真实的未来轨迹。MoN 损失的定义如下:

$$\mathcal{L}_{MoN} = \min_{s \leq k} \|Y - \hat{Y}^s\|_2 \quad (15)$$

其中, $s \in \{1, 2, \dots, k\}$, k 表示生成器的个数; \hat{Y}^s 表示第 s 个生成器的预测; $\|\cdot\|_2$ 表示 L_2 范数。

3) 编码器损失。编码器损失用于优化 ERA5 数据编码器 $Encoder_{ERA5}$ 。本文利用 3D U-Net 预测未来的 $Data_{ERA5}$ 序列 \hat{Y}_{ERA5} 。编码器损失基于 \hat{Y}_{ERA5} 和真实 $Data_{ERA5}$ 序列 Y_{ERA5} 间的像素差来计算,过程如下:

$$\mathcal{L}_{En} = \frac{1}{h \times w \times c \times m} \|Y_{ERA5}^{h \times w \times c \times m} - \hat{Y}_{ERA5}^{h \times w \times c \times m}\|_1 \quad (16)$$

其中, h, w 和 c 分别为二维图像的高度、宽度和通道数; m 为预测序列的长度; $\|\cdot\|_1$ 表示 L_1 范数。

4) 融合损失。多模态融合利用不同模态之间的互补性,通过融合各种特征来获取更全面和更丰富的特征表示,进而提高模型的性能和泛化能力。本文使用余弦相似度来衡量融合后的特征向量与真实特征向量之间的相似性,进而体现跨模态特征融合模块的融合效果。损失函数如下:

$$\mathcal{L}_{fusion} = 1 - \frac{\mathbf{F}_{real} \cdot \mathbf{F}_{fusion}}{\|\mathbf{F}_{real}\| \|\mathbf{F}_{fusion}\|} \quad (17)$$

其中, \mathbf{F}_{fusion} 表示跨模态特征融合模块输出的特征向量, \mathbf{F}_{real} 表示真实数据输入到相应编码模块后得到的特征向量。

综上,本文的优化目标如下所示:

$$\min_G \max_D \mathcal{L}_{adv} + \alpha \mathcal{L}_{MoN} + \beta \mathcal{L}_{En} + \gamma \mathcal{L}_{fusion} \quad (18)$$

其中, α, β 和 γ 表示不同损失的可调加权系数,具体数值将在实验部分介绍。

4 实验

4.1 实现细节

所有实验的硬件配置为 Intel^(R) Xeon^(R) Platinum 8352V CPU, 90 GB 内存,单张显存为 24 GB 的 GeForce RTX 4090 显卡。模型代码基于 PyTorch 2.0.0 开源框架,使用 Python 3.8 编译和执行,所用显卡的 CUDA 版本为 12.2。使用 Adam 优化器 [33] 来优化模型,初始学习率为 1×10^{-4} ,训练批大小为 96。生成器数量设 $k=6$,详见 4.4 节。利用过去 48 h ($n=8$) 的数据来预测未来 24 h ($m=4$) 的信息。对于损失函数的超参数, α 和 β 均设为 1, γ 设为 0.01。

4.2 评价指标

采用平均距离误差(MDE)和平均绝对误差(MAE)来评估不同模型的预测性能。对于轨迹预测,通过计算预测与真实轨迹之间的距离来确定距离误差。强度预测包括压强和风速两部分,通过计算预测与实际强度之间的绝对误差而得。本文还用确定系数(R^2)来描述预测值与真实值之间的关系。各评价指标的具体计算过程如下:

$$LAT_{dis} = \|LAT - \widehat{LAT}\| \times 111 \quad (19)$$

$$LON_{dis} = \cos \frac{LON_{\pi}}{180} \|LON - \widehat{LON}\| \times 111 \quad (20)$$

$$MDE = \frac{1}{L} \sum_{l=1}^L \sqrt{LAT_{dis,l}^2 + LON_{dis,l}^2} \quad (21)$$

$$MAE = \frac{1}{L} \sum_{l=1}^L \|y_l - \hat{y}_l\| \quad (22)$$

$$R^2 = 1 - \frac{\sum_{l=1}^L (y_l - \hat{y}_l)^2}{\sum_{l=1}^L (y_l - \bar{y})^2} \quad (23)$$

其中, LAT 和 LON 为真实经纬度, \widehat{LAT} 和 \widehat{LON} 为预测经纬度; LAT_{dis} (LON_{dis})为真实纬(经)度与预测纬(经)度的距离差; y_l , \hat{y}_l 和 \bar{y} 分别为第 l 个数据的真实值、预测值和所有数据的平均值。

4.3 融合方法选择

本文对不同的特征融合方法进行多组对比实验,用于探讨各种融合方法对热带气旋预测性能的影响。除本文方法外,还

考虑了3种常见的特征融合方法,即加法融合、最大融合和卷积融合。 F_{M1} 和 F_{M2} 为模态一数据和模态二数据的特征。

加法融合的目的是实现特征图内的区域增强,因为线性求和容易出现区域中和现象,进而造成特征丢失。加法融合方法如下:

$$F_{fusion}^{Add} = F_{M1} + F_{M2} \quad (24)$$

最大融合的目的是突出特征图中的高响应区域,但每次都仅选择高响应区域的特征会导致低响应区域的特征丢失。最大融合方法如下:

$$F_{fusion}^{Max} = \text{Max}(F_{M1}, F_{M2}) \quad (25)$$

其中, $\text{Max}(\cdot)$ 是选取最大值的函数。

卷积融合的目的是用卷积操作对拼接后的特征沿通道维度进行融合。卷积融合方法如下:

$$F_{fusion}^{Conv} = \text{Conv}(\text{Concat}(F_{M1}, F_{M2})) \quad (26)$$

其中, $\text{Concat}(\cdot)$ 代表 F_{M1} 和 F_{M2} 在通道维度被拼接, $\text{Conv}(\cdot)$ 代表卷积操作。

如表3所列,本文跨模态特征融合方法在各种指标上均优于其他融合方法。在轨迹预测方面,该方法获得了最优性能。在压强预测方面,该方法在6~18h预测方面优于其他方法,然而其24h预测结果与最优结果相差1.71%。对于风速预测,该方法在预测6h风速方面优于其他方法。然而,随着预测范围扩大,该方法与最大融合方法之间的性能差距越来越大。这可能归因于本文的融合方法会在一定程度上削弱与风速预测相关的特征。

表3 不同数据融合方法的比较

Table 3 Comparisons of different data fusion methods

融合方法	MDE(距离)				MAE(压强)				MAE(风速)			
	6h	12h	18h	24h	6h	12h	18h	24h	6h	12h	18h	24h
ADD	22.84	<u>40.82</u>	<u>60.19</u>	<u>83.30</u>	1.19	1.58	1.98	2.40	0.63	0.91	1.14	1.42
MAX	<u>22.43</u>	40.84	60.88	84.78	1.12	1.56	1.99	2.34	<u>0.60</u>	0.85	1.10	1.31
CONV	22.95	41.67	61.25	83.95	1.10	<u>1.53</u>	<u>1.96</u>	2.43	0.60	0.85	<u>1.11</u>	1.38
本文	21.04	38.87	58.31	82.31	1.04	1.51	1.93	<u>2.38</u>	0.59	<u>0.86</u>	<u>1.11</u>	<u>1.37</u>

4.4 生成器数量选择

从表4可以看出,增加生成器的数量 n_{gs} 可以提高热带气旋预测的性能。随着 n_{gs} 的增加,可训练参数的数量 n_{param} 也在增加。然而,模型训练达到收敛所需的时间 t 并不具有相同

的规律。当 $n_{gs} = 6$ 时, t 达到最小值。为了保持实验的公平性,本文采用与文献[28]和官方气象预报机构中国中央气象台(CMO)相同的方法,设 $n_{gs} = 6$,即生成器预测6种可能的运动趋势。

表4 模型使用不同数量的生成器的结果对比

Table 4 Comparison of different numbers of generators employed in the proposed model

n_{gs}	t	n_{param}	MDE(距离)				MAE(压强)				MAE(风速)			
			6h	12h	18h	24h	6h	12h	18h	24h	6h	12h	18h	24h
2	3794	3906778	32.50	60.45	90.30	125.53	2.09	3.28	4.35	5.32	1.24	1.97	2.57	3.12
4	4280	3958180	26.31	48.54	72.15	100.72	1.40	2.06	2.66	3.22	0.80	1.17	1.51	1.83
6	2928	4009576	21.04	38.87	58.31	82.31	1.04	1.51	1.93	2.38	0.59	0.86	1.11	1.37
8	4030	4060984	19.40	35.81	53.59	75.03	0.92	1.34	1.74	2.26	0.52	0.73	0.96	1.22
10	3971	4112386	18.48	32.25	48.12	69.23	0.82	1.13	1.47	1.85	0.43	0.60	0.79	1.02

4.5 实验结果对比

本文共选取9个基线方法。首先,选取4个典型的单模态方法LSTM^[34],GRU^[35],NMPT^[7]和DLM^[36],仅预测气旋轨迹或强度的一种。其次,选取4个典型的多模态方法SGAN^[31],GBRNN^[6],MMSTN^[26]和MGTCF^[28],同时预测轨迹和强度。此外,还有中国权威的气象预报机构CMO。

各模型未来24h轨迹和强度的预测性能如表5所列。评价指标采用MDE和MAE。从表5可看出,多模态方法明显优于单模态方法,表明热带气旋的预测性能受模态特征多样性的影响。本文方法能有效增强模态特征的多样性,又引入了融合损失进行优化,因此获得了整体最优性能。对于轨迹预测,本文方法在6~24h的距离预测方面分别比目前最好的

方法 MGTCF^[28] 提高 9.08%, 10.38%, 13.09% 和 11.57%; 27.66%; 6~24 小时的风速预测分别提高 19.18%, 26.50%, 6~24 h 的压强预测分别提高 24.09%, 25.98%, 27.44% 和 28.39% 和 26.34%。

表 5 不同模型在 CMA-BST 数据集上基于评价指标 MDE 和 MAE 的比较

Table 5 Comparison of different models on the CMA-BST dataset based on MDE and MAE

模型	MDE(距离)				MAE(压强)				MAE(风速)			
	6h	12h	18h	24h	6h	12h	18h	24h	6h	12h	18h	24h
LSTM	44.23	102.24	177.60	270.84	—	—	—	—	—	—	—	—
GRU	45.85	104.07	180.29	275.77	—	—	—	—	—	—	—	—
NMPT	44.10	101.72	177.06	270.91	—	—	—	—	—	—	—	—
DLM	—	—	—	—	—	—	—	—	1.09	1.85	2.48	3.04
SGAN	28.88	61.75	98.74	140.61	1.91	3.12	4.20	5.12	1.05	1.69	2.28	2.81
GBRNN	29.93	65.06	105.74	152.06	—	—	—	—	1.16	1.89	2.52	3.10
MMSTN	27.57	59.09	96.54	139.19	1.69	2.86	3.94	4.74	0.95	1.52	2.10	2.55
MGTCF	<u>23.14</u>	<u>43.37</u>	<u>67.09</u>	<u>93.08</u>	<u>1.37</u>	<u>2.04</u>	<u>2.66</u>	<u>3.29</u>	<u>0.73</u>	<u>1.17</u>	<u>1.55</u>	<u>1.86</u>
CMO	37.08	52.93	<u>60.69</u>	75.49	2.67	4.30	5.04	6.31	2.29	3.45	2.75	5.00
本文模型	21.04	38.87	58.31	<u>82.31</u>	1.04	1.51	1.93	2.38	0.59	0.86	1.11	1.37

本文模型与次优模型 MGTCF^[28] 的复杂度比较如表 6 所列。本文采用一种简单的子轨迹生成策略,即允许所有子生成器在每次迭代中学习生成规律并产生预测结果。MGTCF 使用生成器选择网络,这会为模型增加额外的参数。与 MGTCF 相比,本文模型可训练参数量 n_{param} 从 4 062 612 减少到 4 009 576,减少了 1.31%,模型训练达到收敛所需的时间 t 从 4 686 s 减少到 2 928 s,减少了 37.52%。

表 6 模型复杂度对比

Table 6 Comparison of the model complexity

模型	t	n_{param}
MGTCF	4 686	4 062 612
本文方法	2 928	4 009 576

与 CMO 相比,本文模型在强度预测和短期轨迹预测方面都有显著改进。未来 6~18 h,本文模型的轨迹预测准确率

分别比 CMO 提高 43.26%, 26.56% 和 3.92%; 在 24 h 的预测中,本文模型的轨迹准确率仅次于 CMO,相差 9.03%。在强度预测方面,6~24 h 的压强预测分别比 CMO 高 61.05%, 64.88%, 61.71% 和 62.28%。在 6~24 h 的风速预测分别比 CMO 高 74.24%, 75.07%, 59.64% 和 72.60%。尽管 CMO 在 24 h 轨迹预测方面具有更优性能,但其预测过程依赖于昂贵的超级计算机,计算成本较高。相反,本文模型只需一个 GPU,成本更低且耗时更短。总之,与基线模型相比,本文模型具有最佳的整体性能。

4.6 消融实验

本节通过消融实验来验证模型中各个模块,即环境场分支(ENV)、GAN 中的多生成器(MG)、跨模态特征互补块(CMFC)和融合损失函数(FL)的必要性和有效性。实验结果如表 7 所列。

表 7 消融实验结果

Table 7 Ablation results

模型	ENV	MG	CMFC	FL	MDE(距离)				MAE(压强)				MAE(风速)			
					6h	12h	18h	24h	6h	12h	18h	24h	6h	12h	18h	24h
M1					38.20	71.57	108.76	149.62	3.06	5.26	7.46	9.23	1.81	3.04	4.39	5.58
M2	✓				37.71	71.30	107.33	149.23	2.86	4.60	6.26	7.72	1.69	2.74	3.73	4.59
M3	✓			✓	37.57	70.05	105.81	147.19	2.80	4.55	6.13	7.58	1.65	2.65	3.56	4.28
M4	✓	✓			22.63	39.94	60.84	85.90	1.07	1.60	2.08	2.52	0.60	0.86	1.13	1.40
M5	✓	✓	✓		22.01	39.73	58.43	82.43	1.19	1.64	2.07	2.56	0.59	0.88	1.16	1.39
M6	✓	✓	✓	✓	21.04	38.87	58.31	82.31	1.04	1.51	1.93	2.38	0.59	0.86	1.11	1.37

1) M2 vs. M1。结果显示,包含环境场数据的模型(M2)比仅用 $Data_{1d}$ 和 $Data_{2d}$ 的模型(M1)性能更好。预测轨迹方面,M2 的 6~24 h 距离预测比 M1 高 1.28%, 0.38%, 1.31% 和 0.26%。强度预测方面,M2 的 6~24 h 压强预测分别比 M1 高 6.54%, 12.55%, 16.09% 和 16.36%。风速预测方面,M2 的 6~24 h 预测分别比 M1 高 6.63%, 9.87%, 15.03% 和 17.74%。验证了环境场的有效性。

2) M3 vs. M2。结果显示,与单生成器模型(M2)相比,加入 CMFC 模块的模型(M3)预测性能有所提高。轨迹预测方面,M3 的 6~24 h 距离预测分别比 M2 提高 0.37%, 1.75%, 1.42% 和 1.37%。强度预测方面,M3 的 6~24 h 压强预测分别比 M2 提高 2.10%, 1.09%, 2.08% 和 1.81%。风速预测方面,M3 分别比 M2 提高 2.37%, 3.28%, 4.56% 和 6.75%。

3) M4 vs. M2。结果显示,使用多个生成器的模型(M4)

明显优于仅使用单个生成器的模型(M2)。轨迹预测方面,M4 的 6~24 h 距离预测分别比 M2 提高 39.99%, 43.98%, 43.32% 和 42.44%。强度预测方面,M4 的 6~24 h 压强预测分别比 M2 提高 62.59%, 65.22%, 66.77% 和 67.36%。风速预测方面,M4 分别比 M2 提高 64.50%, 68.61%, 69.71% 和 69.50%。验证了多生成器的有效性。

4) M6 vs. M5。结果显示,与不考虑融合损失的模型(M5)相比,使用所有模块的模型(M6)在预测性能上进一步提升。轨迹预测方面,M6 的 6~24 h 距离预测分别比 M5 高 4.41%, 2.16%, 0.21% 和 0.15%。强度预测方面,M6 的 6~24 h 压强预测分别比 M5 高 12.61%, 7.93%, 6.76% 和 7.03%。风速预测方面,M6 分别比 M5 高 0%, 2.27%, 4.31% 和 1.44%。

5 分析和讨论

5.1 轨迹预测的定性分析

为提高模型的可解释性,本文以概率锥的形式呈现轨迹预测结果。图3显示了本文模型与目前最优的MGTCF模型对未来24h不同热带气旋的预测差异。

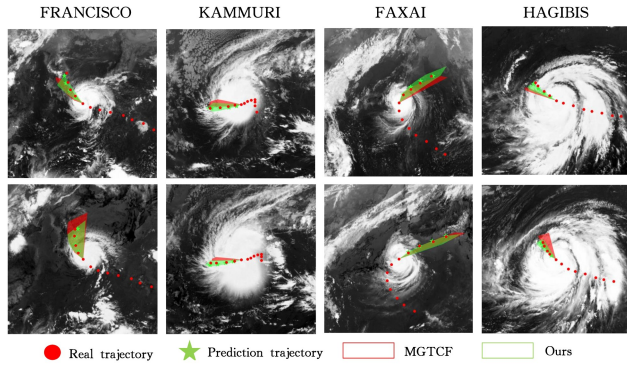


图3 2019年4个热带气旋的6~24h轨迹预测示例以及本文方法与MGTCF的比较(电子版为彩图)

Fig. 3 Examples of trajectory predictions from 6h to 24h and comparisons between the proposed method and MGTCF for four TCs in 2019

图中红点为真实轨迹,绿星为预测轨迹。红色和绿色半

透明区域表示MGTCF和本文模型的预测结果形成的概率锥。预测案例的背景图像来源于相应时刻Himawari-8卫星在红外通道4拍摄的卫星云图。为进一步探讨季节和气旋强度等因素对模型的影响,本文选择了2019年4个不同的气旋:FRANCISCO(TS,夏季),KAMMURI(TY,冬季),FAXAI(STY,夏季)和HAGIBIS(SuperTY,夏季)。其中TS为热带风暴,TY为台风,STY为强台风,SuperTY为超级台风。除“KAMMURI”在冬季外,其他台风都在夏季。图3中绿色半透明区域是本文模型多个子生成器的预测结果。本文模型对最后4个红点(真实数据)的覆盖较为准确,表明该模型能较好地适应不同的强度等级和季节。表8列出了图3所有图像的详细数据,结果验证了本文模型在所有季节和强度水平上均优于MGTCF。

在简单的线性预测示例中(例如FAXAI的第二张图),本文方法和MGTCF都提供了精准的范围。从表8可以看出,本文模型在经度方面不如MGTCF,但在纬度方面明显更优。当面对复杂的非线性预测问题时,不同子生成器所预测的轨迹差异较大,这也解释了为何非线性预测的概率锥范围比线性预测的更大。例如,FRANCISCO的第二张图,本文方法比MGTCF预测的潜在运动区域更准确。如表8所列,虽然本文模型在纬度上与MGTCF相比有些劣势,但在经度上却优于MGTCF。

表8 本文模型未来24h的最佳预测结果与次优模型MGTCF的比较

Table 8 Comparison of the best prediction results from the proposed model and the suboptimal model MGTCF in the future 24h

名称	等级	季节	图像编号	模型	纬度(°)				经度(°)			
					6h	12h	18h	24h	6h	12h	18h	24h
FRANCISCO	TS	夏季	1	真实	130.60	129.80	129.40	129.20	33.00	34.00	35.20	36.70
				MGTCF	130.57	129.62	128.92	128.44	32.61	33.60	34.70	35.74
				本文	130.63	129.75	129.17	128.97	32.90	34.03	35.16	36.29
	2	真实	129.80	129.40	129.20	129.30	34.00	35.20	36.70	37.80		
		MGTCF	129.51	129.02	129.01	129.17	33.96	35.18	36.29	37.33		
		本文	129.99	129.43	129.26	129.40	34.07	35.22	36.28	37.27		
KAMMURI	TY	冬季	1	真实	134.90	133.80	132.50	130.90	13.70	13.50	13.30	13.20
				MGTCF	135.03	133.55	132.06	131.59	13.49	13.58	13.62	13.47
				本文	134.95	133.71	132.33	130.95	13.51	13.28	13.17	13.10
	2	真实	133.80	132.50	130.90	130.00	13.50	13.30	13.20	13.20		
		MGTCF	133.93	132.50	131.29	130.19	13.67	13.73	13.66	13.51		
		本文	133.64	132.36	131.09	129.88	13.46	13.21	13.02	12.90		
FAXAI	STY	夏季	1	真实	139.70	140.90	142.40	144.20	35.40	36.30	37.30	38.40
				MGTCF	139.47	140.67	142.58	144.85	35.37	36.45	37.14	37.89
				本文	139.54	140.76	142.38	144.29	35.25	36.35	37.27	38.07
	2	真实	142.40	144.20	146.40	148.50	37.30	38.40	39.10	39.90		
		MGTCF	142.40	144.35	146.49	148.70	37.05	38.02	38.69	39.27		
		本文	142.51	144.37	146.25	148.18	37.39	38.37	39.06	39.59		
HAGIBIS	SuperTY	夏季	1	真实	142.70	141.80	140.80	140.40	17.70	18.40	19.30	19.80
				MGTCF	142.56	141.38	140.17	139.26	17.46	17.94	18.42	18.99
				本文	142.78	141.77	140.87	140.12	17.54	18.18	18.90	19.62
	2	真实	140.80	140.40	139.90	139.70	19.30	19.80	20.60	21.20		
		MGTCF	141.04	140.42	140.00	139.69	19.14	20.05	21.02	21.90		
		本文	141.01	140.41	139.89	139.38	19.08	19.84	20.50	21.08		

在季节对热带气旋预测的影响方面,普遍观察到冬季气旋强度一般小于夏季。因此,像KAMMURI这样的冬季气旋更有可能被准确预测,从而更容易预测其路径。随着气旋

强度的增加,其运动的不可预测性也会增加。像FAXAI这样的高强度气旋更容易产生不可预测的运动,因此与低强度气旋相比,其预测精度较低。

实验结果表明,与 MGTCF 相比,本文方法对季节变化和气旋强度的敏感性较低,预测粒度更细,预测性能更好。

5.2 轨迹与强度的误差分布分析

图 4 展示了本文模型预测的未来 24h 热带气旋轨迹和强度的预测分布。图 4 中横坐标代表 CMA-BST 的真实数据;纵坐标代表本文模型的预测结果;对角线上的虚线表示函数 $y=x$; R^2 表示预测数据的确定系数,取值范围为 $0\sim 1$ 。确定系数接近 1 表明模型拟合较好,预测数据在图像对角线附

近分布更加集中。拟合的线性方程也反映了模型的性能,即当线性方程的斜率越接近 1,纵截距越接近 0 时,模型预测性能越好。该模型在轨迹预测(即经纬度)方面表现优异,受预测时长的影响较小。相反,随着时间的推移,强度的预测误差逐渐增大,压强的确定系数从 0.96 下降到 0.71,风速的确定系数从 0.96 下降到 0.71。压强的预测误差随压强的增加而减小,风速的预测误差随风速的增加而增大。在未来的研究中,需要进一步提高强度方面的预测能力。

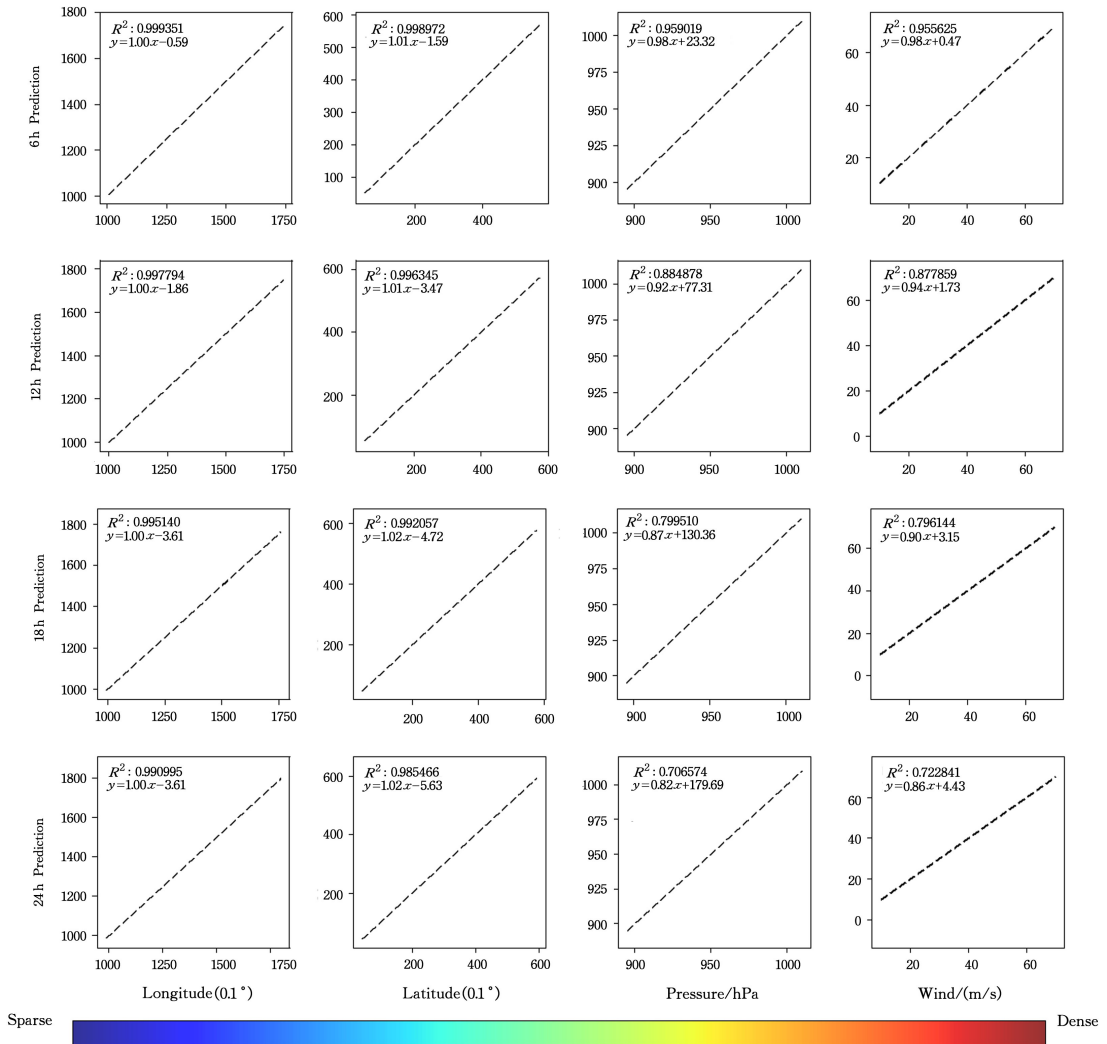


图 4 未来 24h 热带气旋轨迹和强度的预测分布

Fig. 4 Prediction distribution of trajectory and intensity in the future 24 h

结束语 本文提出了基于多生成器和跨模态融合的热带气旋预测模型 CMF-TCMG。该模型在预测热带气旋强度和轨迹的同时,还能提供热带气旋的潜在运动趋势,更加贴合实际应用场景;设计了一个跨模态融合模块来促进模态间的特征融合,有效丰富了模态特征的多样性。此外,构建了一个特征融合损失函数进一步促进多模态融合。在 CMA-BST 数据集上的大量实验证明了该方法的实用性和鲁棒性。未来的工作将集中在以下两个领域:1)将与热带气旋强度相关的其他环境因子,如海表温度、水平风速分量、垂直风速分量等引入数据集;2)加入实时性更强的卫星观测

数据,提高预报的实时性。此外,虽然 CMF-TCMG 在西北太平洋表现良好,但还需要进一步的实验来评估其在其他海洋区域的适用性。

参考文献

- [1] WANG Y, LI Y, XU J, et al. The intensity dependence of tropical cyclone intensification rate in a simplified energetically based dynamical system model [J]. Journal of the Atmospheric Sciences, 2021, 78(7): 2033-2045.
- [2] JING R, LIN N, EMANUEL K, et al. A comparison of tropical

- cyclone projections in a high-resolution global climate model and from downscaling by statistical and statistical-deterministic methods [J]. *Journal of Climate*, 2021, 34(23):9349-9364.
- [3] KIM S H, AHN J B, SUN J. Dynamical-statistical long-term prediction for tropical cyclone landfalls in east asia [J]. *International Journal of Climatology*, 2022, 42(4):2586-2600.
- [4] LIU Y, RASOULI S, WONG M, et al. Rt-gcn: Gaussian-based spatiotemporal graph convolutional network for robust traffic prediction [J]. *Information Fusion*, 2024, 102:102078.
- [5] JIANG Z, ZHOU Z, LI L, et al. Back to optimization: Diffusion-based zero-shot 3d human pose estimation [C] // *IEEE/CVF Winter Conference on Applications of Computer Vision*. 2024: 6142-6152.
- [6] ALEMANY S, BELTRAN J, PEREZ A, et al. Predicting hurricane trajectories using a recurrent neural network [C] // *AAAI Conference on Artificial Intelligence*. 2019:468-475.
- [7] GAO S, ZHAO P, PAN B, et al. A nowcasting model for the prediction of typhoon tracks based on a long short term memory neural network [J]. *Acta Oceanologica Sinica*, 2018, 37:8-12.
- [8] FARMANIFARD S, ALESHEIKH A A, SHARIF M. A context-aware hybrid deep learning model for the prediction of tropical cyclone trajectories [J]. *Expert Systems with Applications*, 2023, 231:120701.
- [9] WANG C, XU Q, LI X, et al. CNN-based tropical cyclone track forecasting from satellite infrared images [C] // *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2020:5811-5814.
- [10] ZHANG R, LIU Q, HANG R. Tropical cyclone intensity estimation using two-branch convolutional neural network from infrared and water vapor images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 58(1):586-597.
- [11] ZHANG Z, YANG X, WANG X, et al. A neural network with spatiotemporal encoding module for tropical cyclone intensity estimation from infrared satellite image [J]. *Knowledge-Based Systems*, 2022, 258:110005.
- [12] JIANG W, HU G, WU T, et al. Dmanet kf: Tropical cyclone intensity estimation based on deep learning and kalman filter from multispectral infrared images [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16:4469-4483.
- [13] MA Z, YAN Y, LIN J, et al. A multiscale and multilayer feature extraction network with dual attention for tropical cyclone intensity estimation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62:1-15.
- [14] NGIAM J, KHOSLA A, KIM M, et al. Multimodal deep learning [C] // *The 28th International Conference on Machine Learning*. 2011:689-696.
- [15] WANG X, CHEN K, LIU L, et al. Global tropical cyclone intensity forecasting with multi-modal multi-scale causal autoregressive model. [J]. *arXiv:2402.13270*, 2024.
- [16] JIANG S, FAN H, WANG C. Improvement of typhoon intensity forecasting by using a novel spatio-temporal deep learning model [J]. *Remote Sensing*, 2022, 14(20):5205.
- [17] MA D, WANG L, FANG S, et al. Tropical cyclone intensity prediction by interand intra-pattern fusion based on multi-source data [J]. *Environmental Research Letters*, 2023, 18(1):014020.
- [18] QIN W, TANG J, LU C, et al. A typhoon trajectory prediction model based on multimodal and multitask learning [J]. *Applied Soft Computing*, 2022, 122:108804.
- [19] LIU Z, HAO K, GENG X, et al. Dual-branched spatio-temporal fusion network for multihorizon tropical cyclone track forecast [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15:3842-3852.
- [20] XU G, LIN K, LI X, et al. Saf-net: A spatio-temporal deep learning method for typhoon intensity prediction [J]. *Pattern Recognition Letters*, 2022, 155:121-127.
- [21] TIAN W, ZHOU X, NIU X, et al. A lightweight multitask learning model with adaptive loss balance for tropical cyclone intensity and size estimation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 16:1057-1071.
- [22] GAN S, FU J, ZHAO G, et al. Short-term prediction of tropical cyclone track and intensity via four mainstream deep learning techniques [J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2024, 244:105633.
- [23] NA Y, NA B, SON S. Near real-time predictions of tropical cyclone trajectory and intensity in the northwestern pacific ocean using echo state network [J]. *Climate Dynamics*, 2022, 58(3/4):651-667.
- [24] TONG B, WANG X, FU J, et al. Short-term prediction of the intensity and track of tropical cyclone via convlstm model [J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2022, 226:105026.
- [25] SHI X, CHEN Z, WANG H, et al. Convolutional lstm network: a machine learning approach for precipitation nowcasting [C] // *The 28th International Conference on Neural Information Processing Systems*. 2015:802-810.
- [26] HUANG C, BAI C, CHAN S, et al. Mmstn: A multi-modal spatial-temporal network for tropical cyclone short-term prediction [J]. *Geophysical Research Letters*, 2022, 49(4):1-11.
- [27] DENDORFER P, ELFLEIN S, LEAL-TAIX E L. Mg-gan: A multi-generator model preventing out-of-distribution samples in pedestrian trajectory prediction [C] // *IEEE/CVF International Conference on Computer Vision*. 2021:13158-13167.
- [28] HUANG C, BAI C, CHAN S, et al. Mgtcf: multi-generator tropical cyclone forecasting with heterogeneous meteorological data [C] // *AAAI Conference on Artificial Intelligence*. 2023:5096-5104.
- [29] YING M, ZHANG W, YU H, et al. An overview of the china meteorological administration tropical cyclone database [J]. *Journal of Atmospheric and Oceanic Technology*, 2014, 31(2):287-301.
- [30] ÇIÇEK O, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse anno-

tation [C] // The 19th International Conference on Medical Image Computing and Computer-Assisted Intervention; Part II. 2016:424-432.

[31] AGRIM G, JUSTIN J, LI F, et al. Social gan; Socially acceptable trajectories with generative adversarial networks [C] // IEEE Conference on Computer Vision and Pattern Recognition. 2018: 2255-2264.

[32] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C] // Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, MA; MIT, 2014: 2672-2680.

[33] KINGMA D P, BA J. Adam: A method for stochastic optimization [C] // The 3rd International Conference on Learning Representations. 2015.

[34] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.

[35] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using rnn encoder-decoder for statistical machine translation [C] // The 2014 Conference on Empirical

Methods in Natural Language Processing. 2014: 1724-1734.

[36] PAN B, XU X, SHI Z. Tropical cyclone intensity prediction based on recurrent neural networks [J]. Electronics Letters, 2019, 55(7): 413-415.



LIU Qian, born in 1986, Ph.D, lecturer, is a member of CCF(No. 98989M). Her main research interests include artificial intelligence and sentiment analysis.



ZHOU Guoqiang, born in 1968, Ph. D, associate professor. His main research interests include machine learning, distributed computing and data analysis.

(责任编辑:何杨)