

DOI:10.20176/j.cnki.nxdz.20260503

基于改进傅里叶神经算子的台风路径与强度预测

骆文海¹, 王磊², 杨轶³, 刘海峰^{1*}

(1. 中山大学 数学学院(珠海), 广东 珠海 519082; 2. 中国人民解放军 63861 部队, 吉林 白城 137001;
3. 南开大学 经济与社会发展研究院, 天津 300071)

摘要:台风是我国东南沿海地区最严重的自然灾害之一,精准预测其移动路径与强度变化,对防灾减灾工作具有重要现实意义。传统数值预报方法物理机制完备,但存在计算成本高昂、对初始气象场高度敏感等问题,难以有效捕捉台风的快速演变特征,应用场景存在明显局限。近年来,以数据驱动为核心的深度学习技术,为台风短临预测研究提供了全新技术范式。文中构建一种基于傅里叶神经算子(Fourier neural operator, FNO)的端到端预测模型,实现我国东南沿海登陆台风路径与强度的联合预测。该模型依托 FNO 在连续函数空间内建模全局依赖的独特优势,高效挖掘气象场时空维度下的非局部动态演化规律,弥补了传统卷积网络与循环神经网络在长程序、空间依赖建模上的固有缺陷。实验采用中国气象局(CMA)发布的 1949—2024 年西北太平洋热带气旋最佳路径数据集,筛选东经 105°—130°、北纬 15°—35°范围内的台风样本,并融合多源再分析气象场作为环境协变量。实验结果表明,所提 FNO 模型的 24 h 路径预平均测误差为 128.6 km,强度预测均方根误差为 6.4 m/s,预测性能显著优于 LSTM、Transformer 等主流深度学习基线模型。

关键词:台风预测;时间序列;傅里叶神经算子

分类号:(中图)P183;P457.8;TP391

文献标志码:A

我国东南沿海地处西北太平洋台风高发区域,涵盖广东、福建、浙江等经济发达、人口密集的省份与沿海城市群,是我国对外开放的前沿地带与经济发展核心区域。该区域每年夏秋季节频繁遭受台风侵袭,台风引发的狂风、暴雨、风暴潮等灾害链,极易诱发洪涝、山体滑坡、建筑损毁、基础设施破坏等次生灾害,严重威胁民众生命财产安全、农业生产秩序、交通运输运行及区域经济平稳发展。因此,精准、高效地开展台风路径与强度预报,是提升东南沿海防灾减灾能力、削减灾害损失、保障社会经济可持续发展的关键前提,对于健全气象灾害预警体系、优化应急管理决策部署,具有重要现实意义与战略价值。

传统台风预报主要依托数值天气预报模式,通过求解耦合多类复杂物理过程的动力学方程组,输出未来数日台风路径与强度的概率预报结果。然

而,数值模式运算复杂度高、计算耗时长,且对初始气象条件高度敏感,难以精准刻画台风内核的精细结构演变。同时,台风观测资料时空分辨率普遍受限,尤其台风中心区域的高精度探测数据较为匮乏,致使数值模式初始场存在显著误差,进而制约整体预报精度。

近年来,随着深度学习理论的持续演进及计算硬件性能的显著提升,越来越多的研究将深度学习技术应用于图像分类^[1]、文字识别任务^[2]等领域,同时也有诸多模型架构适用于台风路径与强度的预测任务^[3]。在早期探索中, Lee 等^[4]构建了一种基于混合径向基函数神经网络(RBF)的台风预测模型。该模型不仅能有效识别热带气旋,还可对其移动轨迹进行预测。实验结果显示,该模型在气旋分类任务中的准确率达 97%,轨迹预测准确率达 86%,是较早将神经网络成功应用于台风预测并取得良好

收稿日期:2025-12-16

基金项目:广东省基础与应用基础研究基金资助项目(2021A1515310003);国家自然科学基金资助项目(12261002)

作者简介:骆文海(2000—),男,硕士研究生,主要从事机器学习、台风路径预测研究,(电子信箱)luowh39@mail2.sysu.edu.cn。

* 通信联系人:刘海峰(1982—),男,副教授,博士,主要从事台风路径预测、稀疏信息处理研究,(电子信箱)liuhf27@mail.sysu.edu.cn。

引用格式:骆文海,王磊,杨轶,等.基于改进傅里叶神经算子的台风路径与强度预测[J].宁夏大学学报(自然科学版中英文),2026,47(3):216-224.

效果的代表性工作之一。随后, Ali 等^[5]采用结构相对简单的多层感知机(MLP)开展研究,以过去 12 h 的气象观测数据为输入,用于预测未来 24 h 内热带气旋的经纬度位置。结果显示,该模型在 24 h 内的预测精度较高,但随着预测时间的延长,误差呈快速累积趋势,这也反映出简单前馈网络在处理长时间序列台风轨迹预测任务时存在明显局限。

近十年来,深度学习技术迅猛发展,涌现出大量结构更复杂、表达能力更强的神经网络架构。这些模型能够从高维、非线性的气象数据中挖掘出更深层次的时空关联特征,从而显著提升预测性能。鉴于台风路径本质上是一种典型的时间序列问题,研究者普遍倾向于采用适用于序列建模的循环神经网络(RNN)构建预测系统^[6]。在此基础上, Alemany 等^[7]利用 RNN 捕捉气象变量间复杂的非线性动态关系,实现了对台风路径的中长期预测,其预测精度甚至优于美国国家飓风中心(NHC)当时所采用的传统轨迹预报方法。然而,标准 RNN 在处理长序列时易受梯度消失或梯度爆炸问题的困扰,限制了其在长时间依赖建模中的表现。为克服这一缺陷,长短期记忆网络(LSTM)被提出并广泛应用于气象预测领域^[8]。LSTM 通过引入门控机制(特别是遗忘门)和记忆单元,有效缓解了梯度传播过程中的不稳定问题,显著提升了对长期时间依赖关系的建模能力^[9-10]。

此外,针对台风路径预测中空间结构信息的重要性, Zhang 等^[11]提出了一种矩阵神经网络模型(matrix neural network, MNNs)。该模型在设计上保留了输入数据的空间拓扑结构,避免了传统向量化操作对空间相关性的破坏。在台风路径预测任务中, MNNs 能够更有效地利用气象场的空间分布特征,从而提供精度更高的预测结果。Zhang 等^[12]还提出了一种基于 CNN 和 LSTM 的混合模型,通过融合卫星云图和数值天气预报数据,实现了对未来 72 h 内台风路径的高精度预测。Jiang 等^[13]首次将注意力机制驱动的 CNN 与卡尔曼滤波结合,用于台风强度估计,该方法是一种深度学习与经典滤波技术融合的有效范式。实验结果显示,该方法能够在不增加计算成本的前提下,显著提升台风路径预测效果。类似地,还有基于 U-net 与 LSTM 的混合模型^[14],该模型通过 U-net 和 LSTM 分别提取空间信息和时间信息,再对两类特征进行融合,从而实现台风时空信息的高效挖掘与利用。

传统数值预报方法依赖物理方程求解,普遍存在计算成本高、对初始条件高度敏感等缺陷;深度

学习模型虽可依托数据驱动挖掘气象演变规律,但传统卷积神经网络(CNN)受限于局部感受野特性,循环神经网络(RNN)则易出现长程依赖建模下的梯度消失问题,二者均难以完整捕捉台风的全局时空演化特征。傅里叶神经算子(FNO)广泛适用于偏微分方程(PDE)求解、时空场预测、函数空间映射等研究方向,现已在流体力学^[15]、地球科学与气候预测^[16]、计算物理及工程仿真等领域得到成熟应用^[17]。鉴于 FNO 可在连续函数空间内高效建模长程全局依赖,文中选取该网络作为基础框架,精准捕获气象场时空维度下的非局部动态演变规律,有效突破了卷积网络与循环神经网络在长时序关联建模中的瓶颈,更适配台风大尺度、强非线性、多尺度耦合的复杂演化特性,可实现台风路径与强度的高精度联合预测。

1 方法

文中提出一种基于一维傅里叶神经算子(FNO1d)的台风路径与强度联合预测模型(typhoon-FNO),依托谱域卷积算子挖掘台风时序数据中的全局依赖关系,并结合编码器-解码器架构构建端到端预测范式。这一章将系统阐述该模型的整体设计思路、网络架构组成,以及各核心功能模块的运行机制与技术优势。

1.1 问题定义

台风路径与强度预测可抽象为时序序列映射问题。设模型输入为历史台风气象特征序列,记为 $X \in \mathbf{R}^{B \times T_{in} \times D_{in}}$, 其中 B 为批次大小, T_{in} 为输入时间步的长度, D_{in} 为每个时间步的特征维度,包含台风经度、纬度、中心风速、海平面气压、风向等关键气象因子。模型输出为未来台风路径与强度的预测序列,记为 $Y \in \mathbf{R}^{B \times T_{out} \times D_{out}}$, T_{out} 为输出时间步长, D_{out} 为输出特征维度;其中,对于台风路径预测任务, $D_{out} = 2$;对于台风强度预测任务, $D_{out} = 1$ 。

1.2 核心模块设计

Typhoon-FNO 模型的总体架构分为编码器(FNO1d)与解码器(全连接序列网络)两部分。编码器负责将低维输入序列映射至高维潜在特征空间,挖掘台风演变过程中的非线性时空动力学规律;解码器则将编码后的高维状态向量进行压缩与转换,生成指定长度的输出序列,完成从特征表征到预测值的回归任务。整体流程如图 1 所示。

1.2.1 频域卷积层(SpectralConv1d) 傅里叶卷积是频域卷积层的核心组件,其本质是将时间或空间域的信号转换至谱域,通过对傅里叶模态的卷积




图 1 TyphoonFNO 模型结构

Fig. 1 The architecture of the TyphoonFNO model

操作捕捉全局特征,再经逆傅里叶变换映射回原域。该模块的设计针对台风时序数据的全局相关性,可有效解决传统卷积局部感受野的固有局限性。SpectralConv1d 模块的实现分为 3 个步骤:

(i) 对输入的时序特征 $X \in \mathbb{R}^{B \times T_m \times D_m}$ 执行一维实数傅里叶变换,得到谱域特征 $x_f \in \mathbb{C}^{B \times T_m \times (D_m/2+1)}$ 。

(ii) 傅里叶模态筛选:保留前 M 个傅里叶模态,其中 M 为 modes 参数,本文初始设为 16,实际受序列长度限制, M 最终取值为 5,以此过滤高频噪声,聚焦台风演化的主要规律(低频模态对应全局趋势,高频模态对应局部波动)。随后通过可学习的复权重矩阵 W ,对筛选后的谱域特征执行爱因斯坦求和操作,实现谱域卷积计算。具体计算方式为

$$x_{it} = x_{it}[:, :, :m] \odot W. \quad (1)$$

(iii) 对谱域卷积后的特征执行一维实数逆傅里叶变换,映射回时间域,得到输出特征。

1.2.2 一维 FNO 网络(FNO1d) FNO1d 为该模型编码器的核心模块,融合傅里叶卷积、逐点卷积、残差连接与非线性激活函数,实现台风时序特征的高维映射与深度抽象提取。FNO1d 模块的整体结构包含:输入升维层、两层傅里叶卷积-逐点卷积残差块、输出降维层及序列长度适配层,完整运算流程如下:首先,通过全连接层输入时序特征 $X \in \mathbb{R}^{B \times T_m \times D_m}$ 映射至高维特征空间 $\mathbb{R}^{B \times T_m \times W_m}$,其中 W_m 为模型宽度;随后经由双频域卷积残差块完成特征增强,计算方式为

$$x \leftarrow \text{SpectralConv1d}(x) + \text{Conv1d}(x). \quad (2)$$

最后,利用全连接层完成特征降维,将高维特征映射至目标输出维度,完成编码过程。

1.2.3 台风专用解码器(TyphoonFNO)

TyphoonFNO 是面向台风路径与强度联合预测的整体模型,采用编码器-解码器架构,融合 FNO1d 的谱域特征提取能力与全连接解码器的高效维度映射能力,构建端到端预测框架。TyphoonFNO 整体由 FNO1d 编码器与全连接解码器两部分构成,完整推理流程可分为 3 个阶段:编码器深度特征提

取、高维特征扁平化、解码器预测结果生成。

编码器输出特征尺寸为 (B, T_m, width) ,其中 B 为批次大小, T_m 为输入序列长度(本文设定为 8), width 为隐层特征通道数(本文设定为 64)。解码器首先将时序特征展平为 $(B, T_m \times \text{width})$,实现多维度时空信息的全局融合;随后经由两层全连接层与 ReLU 激活函数逐层变换,将特征维度映射至 $(B, 128)$,最终映射至 $(B, T_{\text{out}} \times D_{\text{out}})$;再通过维度重塑(reshape)操作,将特征恢复为 $(B, T_{\text{out}}, D_{\text{out}})$,输出未来多步台风路径与强度的联合预测结果。

该模型采用编码器与解码器解耦设计,完全适配合风预测“特征提取-回归预测”的任务逻辑:编码器聚焦于谱域时空依赖建模与关键特征挖掘,解码器负责维度变换与预测输出,整体架构高度贴合台风演变的复杂非线性预测需求。相较于传统 seq2seq 模型,本文解码器依托全连接层直接完成高维特征聚合与目标维度映射,网络结构更加精简,参数量更少,推理计算成本更低。

1.3 损失函数与优化器

台风路径预测的核心难点在于精准量化经纬度坐标的预报误差,而传统欧氏距离度量忽略了地球表面的球面几何特征,度量结果存在明显偏差。为此,本文构建基于哈弗辛距离(Haversine Distance)的位置损失函数,同时引入速度一致性约束,抑制预测轨迹的突变与跳变问题,使预报结果更贴合台风实际运动物理规律。针对多步联合预测任务,进一步采用时间步加权融合损失机制,对短时效预报(如未来 6 h)赋予更高损失权重,契合台风实时预报的业务应用需求。

基础哈弗辛距离位置损失函数定义为

$$\mathcal{L}_{\text{pos}} = \frac{1}{N} \sum_{i=1}^N \sum_{t=1}^T d_{\text{haversine}}(p_i(t), y_i(t)), \quad (3)$$

其中: N 为批次样本总量; T 为预测时步长; $p_i(t) = (\phi_p, \lambda_p)$, 为第 i 个样本在 t 时刻的预测经纬度; $y_i(t) = (\phi_y, \lambda_y)$, 为对应时刻的真实观测经纬度。哈弗辛距离的具体计算公式为

$$d_{\text{haversine}} = 2R \arcsin \left(\sqrt{\sin^2 \left(\frac{\Delta \phi}{2} \right) + \cos \phi_y \cos \phi_p \cdot \sin^2 \left(\frac{\Delta \lambda}{2} \right)} \right), \quad (4)$$

其中:地球半径 $R = 6371 \text{ km}$; $\Delta \phi = \phi_p - \phi_y$ 为纬度差; $\Delta \lambda = \lambda_p - \lambda_y$ 为经度差。引入速度一致性约束后,模型总体损失函数为

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{pos}} + \lambda_{\text{speed}} \mathcal{L}_{\text{speed}}, \quad (5)$$

其中:速度约束损失为

$$\mathcal{L}_{\text{speed}} = \frac{1}{N} \sum_{i=1}^N \sum_{t=1}^{T-1} |\Delta v_p(t) - \Delta v_y(t)|, \quad (6)$$

$\Delta v_p(t)$ 和 $\Delta v_y(t)$ 分别为预测速度和真实速度。在固定时间采样间隔下, $\Delta v_p(t)$ 和 $\Delta v_y(t)$ 可通过相邻时刻轨迹点间的哈弗辛距离间接求解,以此约束台风前后时刻移动速度的连续性与一致性。实验中,惩罚系数 λ_{speed} 初始默认设置为0.1。

模型训练采用 Adam 优化器(adaptive moment estimation)。该优化器结合一阶矩估计(动量机制)与二阶矩估计(RMSProp),自适应动态更新各网络参数的学习率,有效降低人工调参成本,提升训练稳定性与收敛效率。

2 实验

为了评估本研究所提方法的有效性,在中国气象局(CMA)发布的1949—2024年西北太平洋热带气旋最佳路径数据集^[18]上进行数值实验,本章将详细介绍数据集详情、实验设计细节,并展示实验结果与分析。

2.1 数据集介绍

中国气象局(CMA)台风最佳路径数据集由上海台风研究所编制,是记录1949年至今西北太平洋及南海区域热带气旋的权威数据集,涵盖台风移动路径、强度等级、中心气压等关键气象信息,按6 h频次进行观测记录。该数据集经过多源数据融合处理与严格质量控制^[19-20],数据可靠性与完整性较高,为台风相关科研、业务预报预警及防灾减灾工作提供了核心基础支撑。样例数据如表1所示。

2.2 数据清洗

CMA 台风最佳路径数据集虽经官方质量控制,但受观测技术演进、多源数据融合差异及极端天气干扰等因素影响,仍可能存在数据异常,直接使用易导致分析偏差或模型预测失真。具体异常情况主要包括3方面:其一,早期(1949—1970年)依赖常规观测手段,部分记录存在经纬度定位偏差、中心气压缺失等问题;其二,数据整编过程中可能出现格式不统一、重复记录及异常值(如风速远超

物理阈值)等情况;其三,加密观测时段与标准观测时段的衔接处,易出现时间序列不连续问题。因此,数据清洗是保障后续台风路径分析、强度建模及灾害评估准确性的关键前置环节。

针对CMA数据集的上述特点,采用针对性清洗策略,具体如下:一是缺失值处理,对少量缺失的中心气压、风速等关键字段,采用相邻时间步插值法补充;对于移动方向等非数值型特征,先将方向字符串标准化为16个方位角,再经过正余弦编码构造新的方位特征;二是格式与冗余处理,统一日期时间格式(换算为UTC标准时间),剔除重复的“国际编号-时间”组合记录,确保同一台风的轨迹序列连续完整。经过上述清流程洗后,筛选出1970—2024年的热带气旋共计1 316个。

训练数据生成以“时序特征提取、样本结构化、适配模型输入”为目标,基于台风数据的时序连续性,构建“输入历史序列-输出预测序列”的监督学习样本对。具体生成流程如下:首先按台风国际编号进行分组,再对每个台风采用滑动窗口法构造样本序列;对于每个观测时刻,选取前8个时间步长(单个时间步长为6 h)的气象特征作为输入,后4个时间步长的路径与强度信息作为输出,形成单一样本对。数据集划分采用时序划分方式:1970—2021年的热带气旋数据作为训练集,2022—2024年的热带气旋数据作为测试集。最终构造得到26 462个训练样本与1 868个测试样本,满足模型训练与性能评估需求。

2.3 实验设置

本实验的实验配置环境如下:CPU为Intel(R) Core(TM) i5-8265U,主频1.80 GHz;内存(RAM)为8.00 GB(可用7.85 GB),GPU型号为RTX3060(显存12 GB);操作系统为64位 Windows 11家庭中文版。实验编程语言采用Python 3.10版本,深度学习框架PyTorch版本为2.2.2+cu121。

实验设计具体如下:针对台风路径与强度预测任务,模型输入为连续48 h的气象序列,包含经纬度、风速分量、海平面气压、移动速度、方向角正余

表 1 CMA-BST数据集示例
Tab. 1 Examples of the CMA-BST dataset

台风编号	当前台风时间	东经/(°)	北纬/(°)	台风强度	台风等级	风速/(m·s ⁻¹)
194501	1945-04-19T12:00:00	160.3	9.5	热带低压(TD)	6	12
194501	1945-04-19T18:00:00	159.9	9.6	热带低压(TD)	7	15
194501	1945-04-20T00:00:00	159.7	9.6	热带低压(TD)	7	17
194501	1945-04-20T06:00:00	159.3	9.7	热带风暴(TS)	8	20

弦及台风等级,共 8 维特征;输出为未来 24 h 的台风经纬度坐标(用于路径预测)或最大风速(用于强度预测)。训练过程采用 Adam 优化器,设置学习率为 1×10^{-4} ,批量大小为 32,在 NVIDIA RTX3060 GPU 上完成端到端训练,总训练轮次(epoch)为 30。损失函数采用带速度惩罚项的哈弗辛距离损失函数,并为未来 24 h 内的 4 个预测时间步(每 6 h 为一个步长)分配递减权重[1.0, 0.9, 0.8, 0.7],以突出短时效(近期)预测的精度优先级。评估指标设置如下:台风路径预测采用哈弗辛距离对应的平均绝对误差(MAE,单位:km)、均方根误差(RMSE),以及预测误差的最大值(Maxerr)与最小值(Minerr);台风强度预测采用最大风速对应的 RMSE(单位:m/s)。各评估指标定义的具体定义如下:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |d_i|, \quad (7)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N d_i^2}, \quad (8)$$

$$\text{Max}_{\text{err}} = \max_i d_i, \quad (9)$$

$$\text{Min}_{\text{err}} = \min_i d_i. \quad (10)$$

其中:对于台风路径预测, d_i 为第 i 个样本的哈弗辛距离,由式(4)计算得到;对于台风强度预测, d_i 对应第 i 个样本的预测风速与实际最大风速之差,单位为 m/s。

为全面验证所提 TyphoonFNO 模型的预测性能,选取多种代表性深度学习方法作为对比基线,具体包括:经典循环神经网络模型长短期记忆神经网络(long short term memory, LSTM)^[8]、双向长短期记忆神经网络(bi-directional long short-term memory, BiLSTM)^[21];自注意力机制架构模型 Transformer^[22];以及近年来提出的全连接类模型 Mlp-Mixer^[23]、卷积类模型时间卷积神经网络(temporal convolutional neural network, TCN)^[24]。所选对比基线涵盖循环(RNN)、卷积(CNN)、注意力(Transformer)、全连接(MLP)四大主流深度学习范式,且均在时空序列预测、轨迹建模等相关领域有成熟应用案例,能够充分覆盖不同建模思路的性能差异。为保障实验对比的公平性,所有基线模型均在与本文 TyphoonFNO 模型完全一致的数据划分、数据预处理条件下重新训练,统一训练超参数(如学习率、批量大小、训练轮次等),确保实验结果的可比性与可靠性。TyphoonFNO 模型的训练损失(loss)曲线如图 2 所示。




图 2 台风路径预测模型训练损失

Fig. 2 The training loss of the typhoon track prediction model

2.4 实验结果与分析

2.4.1 台风路径预测实验结果 热带气旋路径预测实验结果见表 2(其中黑体数据为最优值,下同略)。由表 2 数据可知,所提 TyphoonFNO 模型在 CMA-BST 数据集的热带气旋路径预测任务中,6、12、18、24 h 四个时间步的平均绝对误差(MAE)分别为 51.15、69.85、94.59、128.58 km,各项指标均显著优于 LSTM、BiLSTM、Transformer 等所有对比基线方法,充分表明所提模型在路径预测准确性上具备明显优势。在预测误差稳定性方面,除 24 h 预测的最大误差外,本文模型在其余时间步的最大预测误差均低于所有对比方法,说明 TyphoonFNO 模型在捕捉台风移动轨迹、抑制极端预测偏差方面表现更优,预测稳定性更具竞争力。综上,实验结果充分验证了本文提出的 TyphoonFNO 模型在热带气旋路径预测任务中的有效性与优越性。

2.4.2 台风强度预测实验结果 台风强度预测的数据集划分方式与模型输入设置,均与台风路径预测保持一致;模型输出为 4 个时间步对应的台风中心附近最大风速,通过预测热带气旋中心附近最大风速,实现台风强度定量预估,预测结果见表 3。由表 3 可见,在 6、12 h 预报时效下,本文所提方法的平均绝对误差均优于其他对比模型,且全时间步长的均方根误差(RMSE)同样低于各对比方法。结果表明,该模型具备优异的台风强度预测能力,验证了方法在台风强度预报任务中的有效性与优越性。

2.4.3 消融实验 为证明所提方法的有效性,进行了消融实验,探究损失函数中速度一致性约束对模型性能的影响,实验结果见表 4。

表 2 热带气旋路径预测实验结果

Tab. 2 Experimental results of the tropical cyclone track predictions

模型	预测时长/ h	MAE/ km	RMSE/ km	最大误差/ km	最小误差/ km	模型	预测时长/ h	MAE/ km	RMSE/ km	最大误差/ km	最小误差/ km
LSTM	6	66.47	75.76	247.78	2.27	MLP-Mixer	6	91.7	103.48	326.89	0.56
	12	80.38	93.58	350.52	1.84		12	111.92	126.95	335.86	1.3
	18	100.32	118.07	426.8	1.09		18	134.79	156.48	597.36	3.57
	24	130.53	155.27	606.71	2.43		24	176.31	205.01	718.64	4.59
BiLSTM	6	97.22	121.89	626.65	2.01	TCN	6	126.55	149.27	451.06	3.14
	12	121.22	150.93	765.85	2.54		12	138.22	163.2	524.74	3.07
	18	151.79	187.56	905.91	4.71		18	159.16	187.95	630.09	2.28
	24	189.07	234.73	1087.1	8.66		24	190.32	225.52	802.16	6.41
Transformer	6	99.78	106.33	226.05	3.29	FNO	6	51.15	58.8	206.72	0.19
	12	118.01	125.01	304.94	14.33		12	69.85	79.88	274.8	0.19
	18	142.52	155.15	416.28	3.38		18	94.59	108.06	378.85	3.37
	24	153.64	174.69	520.07	10.09		24	128.58	147.8	558.76	4.1

表 3 台风强度预测实验结果

Tab. 3 Experimental results of the tropical cyclone intensity predictions

模型	预测时长/ h	MAE/ (m·s ⁻¹)	RMSE/ (m·s ⁻¹)	最大误差/ (m·s ⁻¹)	模型	预测时长/ h	MAE/ (m·s ⁻¹)	RMSE/ (m·s ⁻¹)	最大误差/ (m·s ⁻¹)
FNO	6	2.56	3.55	18.96	MLP-Mixer	6	3.20	4.31	18.26
	12	4.17	5.63	28.43		12	4.89	6.47	27.36
	18	5.40	7.22	30.96		18	5.96	7.92	30.3
	24	6.40	8.60	35.83		24	6.75	8.94	32.31
LSTM	6	2.61	3.89	25.54	TCN	6	3.19	4.43	20.69
	12	4.24	6.14	35.17		12	4.49	6.22	28.22
	18	5.40	7.74	37.82		18	5.5	7.56	33.86
	24	6.33	8.97	38.91		24	6.34	8.65	36.71
BiLSTM	6	3.24	4.4	23.55	Transformer	6	2.9	3.96	20.05
	12	4.68	6.30	29.44		12	4.27	5.94	28.24
	18	5.78	7.87	35.63		18	5.41	7.53	35.91
	24	6.63	9.07	40.4		24	6.39	8.92	41.17

表 4 速度一致性约束惩罚因子对台风路径预测的影响

Tab. 4 The influence of the speed consistent constraint penalty factor on the typhoon track prediction

λ	MAE/km	
	6 h	24 h
0	64.66	146.67
0.05	52.36	133.49
0.10	51.15	128.58
0.20	52.91	132.07

2.4.4 与主流模型复杂度对比 模型基于一维 FNO 构建,其核心频域运算通过快速傅里叶变换 (FFT)实现。设输入序列长度为 L ,模型宽度为 w ,则单层 SpectralConv1d 的时间复杂度为 $O(wL \ln L)$,整体模型时间复杂度为 $O(wL \ln L + w^2L)$ 。该复杂度低于 Transformer 的 $O(wL^2)$,模型实际推理速度与 LSTM 基本持平,同时具备长距离全局特征建模能力。




图3 台风路径预测示例:历史轨迹与未来路径(真实值 vs 预测值)

Fig. 3 Examples of typhoon track prediction: historical and future paths(true vs predicted)

3 总结

本文提出了一种基于一维傅里叶神经算子(FNO1d)的台风路径与强度联合预测模型,有效融合了气象场的全局时空依赖与局部动态演变特征。针对台风轨迹预测任务,模型依托频域运算捕捉长程空间关联,同时结合残差式局部卷积强化精细化细节建模能力;在台风强度预测层面,将最大风速预估建模为连续回归任务,采用共享编码器提取统一时空表征,实现台风路径与强度的协同同步预测。实验结果验证了所提模型与方法的有效性。未来研究可针对频繁变向热带气旋预测、24 h以上长时效路径推演两类难点场景开展优化,进一步提升模型的泛化能力与鲁棒性。

参考文献:

- [1] 单飞龙,吕鹏远,李梦晨. 基于CNN-Transformer半监督交叉学习的遥感图像场景分类方法[J]. 宁夏大学学报(自然科学版),2024,45(3):325-332.
- [2] 赵心怡,史伟,李国民. 基于小样本的西夏文字识别模

型的提升方法[J]. 宁夏大学学报(自然科学版中英文), 2025, 46(2): 134-142.

- [3] JIANG Guoqing, XU Jing, WEI Jun. A deep learning algorithm of neural network for the parameterization of typhoon-ocean feedback in typhoon forecast models[J]. Geophysical Research Letters, 2018, 45(8): 3706-3716.
- [4] LEE R S T, LIU J N K. Tropical cyclone identification and tracking system using integrated neural oscillatory elastic graph matching and hybrid RBF network track mining techniques [J]. IEEE Transactions on Neural Networks, 2000, 11(3): 680-689.
- [5] ALI M M, KISHTAWAL C M, JAIN S. Predicting cyclone tracks in the north Indian Ocean: An artificial neural network approach [J]. Geophysical Research Letters, 2007, 34 (4) : L04603. DOI: 10.1029/2006GL028353.
- [6] MORADI KORDMAHALLEH M, GORJI SEFIDMAZGI M, HOMAIFAR A. A sparse recurrent neural network for trajectory prediction of Atlantic hurricanes[C]//Proceedings of the Genetic and Evolutionary Computation Conference 2016. Denver, Colorado, USA: ACM, 2016: 957-964. <https://doi.org/10.1145/2908812.2908834>.

- [7] ALEMANY S, BELTRAN J, PEREZ A, et al. Predicting hurricane trajectories using a recurrent neural network [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2019: 468-475. <https://doi.org/10.1609/aaai.v33i01.3301468>.
- [8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [9] KOLEN J F, KREMER S C. Gradient flow in recurrent nets: The difficulty of learning long-term dependencies [C]//A Field Guide to Dynamical Recurrent Networks. New York: Wiley-IEEE Press, 2001: 237-243. <http://doi.org/10.1109/9780470544037.ch14>.
- [10] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. *IEEE Transactions on Neural Networks*, 1994, 5(2): 157-166.
- [11] ZHANG Yanfei, CHANDRA R, GAO Junbin. Cyclone track prediction with matrix neural networks [C]//International Joint Conference on Neural Networks (IJCNN). Piscataway, NJ, USA: IEEE, 2018: 1-8. <http://doi.org/10.1109/IJCNN.2018.8489077>.
- [12] ZHANG Y, LI H, CHEN J. Typhoon track prediction based on convolutional neural network and long short-term memory network. *Advances in Atmospheric Sciences*, 2020, 37(1): 69-82.
- [13] JIANG Wenjun, HU Gang, WU Tiantian T, et al. DMANet_KF: Tropical cyclone intensity estimation based on deep learning and Kalman filter from multi-spectral infrared images [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 4469-4483.
- [14] LI Tongfei, CHE Kaihua, LU Jiadong, et al. Tropical cyclone ensemble forecast framework based on spatiotemporal model [J]. *Earth Science Informatics*, 2024, 17(5): 4791-4807.
- [15] LÜ Yanfang, ZHAO Xiaoyu, GONG Zhiqiang, et al. Multi-fidelity prediction of fluid flow based on transfer learning using Fourier neural operator [J]. *Physics of Fluids*, 2023, 35(7): 077118. DOI: 10.1063/5.0155555.
- [16] KURTH T, SUBRAMANIAN S, HARRINGTON P, et al. FourCastNet: Accelerating global high-resolution weather forecasting using adaptive Fourier neural operators [C]//Proceedings of the Platform for Advanced Scientific Computing Conference. Davos, Switzerland: ACM, 2023: 13. <https://doi.org/10.1145/3592979.3593412>.
- [17] WEI Wei, FU Liyun. Small-data-driven fast seismic simulations for complex media using physics-informed Fourier neural operators [J]. *Geophysics*, 2022, 87(6): T435-T446.
- [18] LI Guancheng, CHENG Lijing, ZHU Jiang, et al. Increasing ocean stratification over the past half-century [J]. *Nature Climate Change*, 2020, 10(12): 1116-1123.
- [19] YING Ming, ZHANG Wei, YU Hui, et al. An overview of the China meteorological administration tropical cyclone database [J]. *Journal of Atmospheric and Oceanic Technology*, 2014, 31(2): 287-301.
- [20] ZHANG Changjiang, WANG Xiaojie, MA Leiming, et al. Tropical cyclone intensity classification and estimation using infrared satellite images with deep learning [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 2070-2086.
- [21] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. The performance of LSTM and BiLSTM in forecasting time series [C]//IEEE International Conference on Big Data (Big Data). Piscataway, NJ, USA: IEEE, 2020: 3285-3292. <http://doi.org/10.1109/BigData47090.2019.9005997>.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.
- [23] TOLSTIKHIN I O, HOULSBY N, KOLESNIKOV A, et al. MLP-mixer: An all-MLP architecture for vision [EB/OL]. (2021-06-11)[2025-12-16]. <https://doi.org/10.48550/arXiv.2105.01601>.
- [24] HEWAGE P, BEHERA A, TROVATI M, et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station [J]. *Soft Computing*, 2020, 24(21): 16453-16482.

An Improved Fourier Neural Operator for Joint Prediction of Typhoon Track and Intensity

LUO Wenhai¹, WANG Lei², YANG Yi³, LIU Haifeng^{1*}

(1. School of Mathematics (Zhuhai), Sun Yat-sen University, Zhuhai 519082, China;

2. Unit 63861 of the Chinese People's Liberation Army, Baicheng 137001, China;

3. College of Economic and Social Development, Nankai University, Tianjin 300071, China)

Abstract: Typhoons are among the most severe natural disasters impacting the southeastern coastal regions of China, and accurately predicting their tracks and intensities is crucial for effective disaster prevention and mitigation. Traditional numerical forecasting methods, while comprehensive in their physical mechanisms, face challenges such as high computational costs, sensitivity to initial meteorological conditions, and limitations in capturing the rapid evolution of typhoons. In recent years, data-driven deep learning methods have introduced a novel paradigm for typhoon prediction. This study presents an end-to-end model based on the Fourier Neural Operator(FNO)for the joint prediction of typhoon tracks and intensities upon landfall in southeastern China. By leveraging the unique capability of FNO to model global dependencies in continuous function spaces, this method effectively captures the non-local spatiotemporal dynamics of meteorological fields, addressing the inherent limitations of traditional convolutional and recurrent neural networks in long-range dependency modeling. The experiments utilized the 1949-2024 best-track dataset of tropical cyclones from the China Meteorological Administration(CMA), focusing on typhoon samples that entered the region between 105°E-130°E and 15°N-35°N. Additionally, multi-source reanalysis meteorological fields were integrated as environmental covariates. The results show that the proposed FNO model achieves an average 24-hour track prediction error of 128. 6km and an intensity prediction root mean square error(RMSE)of 6. 4 m/s, significantly outperforming state-of-the-art deep learning models such as LSTM and Transformer.

Key words: typhoon prediction; time series; Fourier neural operator

(责任编辑 张 娣)

(上接第 215 页)

Dynamic Modeling of Spinal Central Pattern Generators and Quadruped Gait Regulation

HAN Fang¹, ZHU Qinghua², WANG Qingyun^{1,3}, WEI Xindan⁴

(1. School of Mathematics and Statistics, Ningxia University, Yinchuan 750021, China;

2. School of Data Science, Zhejiang University of Finance and Economic, Hangzhou 310018, China;

3. Department of Dynamics and Control, Beihang University, Beijing 100191, China;

4. College of Information and Intelligent Sciences, Donghua University, Shanghai 201620, China)

Abstract: Central Pattern Generators (CPGs) in the spinal cord serve as the neural control centers for rhythmic limb movements in mammals and are crucial for understanding the mechanisms of motor control. However, the organizational structure of spinal cord neural circuits and the specific mechanisms by which they regulate rhythmic limb movements remain poorly understood. This paper systematically reviews biological experimental findings and advances in computational modeling related to spinal CPGs in quadruped animals. By integrating physiological experimental data, it constructs spinal CPG model featuring an asymmetric cervical-lumbar spine layout. This model simulates and implements biologically accurate quadruped gait patterns under the combined regulation of spinal drive, specific ion current, and sensory feedback. The results provide new insights into the mechanisms of central rhythmic motion control in the spinal cord and offer guidance for further biological experiments related to quadrupedal motion. Additionally, these findings hold significant value for developing gait control strategies for bionic quadrupedal and bipedal robots. Finally, this paper identifies current challenges faced by this research field and discusses future research directions.

Key words: neuromotor control; spinal CPGs; quadrupedal gaits; computational modeling; neurodynamics

(责任编辑 张 娣)