

# 基于 TCN-BiLSTM 混合神经网络模型的 核素扩散浓度预测方法

王箫箫<sup>1,2</sup> 杨子辉<sup>2</sup> 艾雨星<sup>2,3</sup> 李煜辰<sup>2,3</sup> 莫紫雯<sup>1,2</sup> 袁振豪<sup>1,2</sup> 李桃生<sup>2</sup>

<sup>1</sup> (淮师范大学物理与电子工程学院 淮北 235000)

<sup>2</sup> (中国科学院合肥物质科学研究院 合肥 230031)

<sup>3</sup> (中国科学技术大学科学岛分院 合肥 230026)

**摘要** 为满足核应急对核素扩散分布快速预测的需求,本研究提出了一种基于TCN-BiLSTM混合神经网络模型的核素扩散浓度快速预测方法。通过时序卷积网络TCN提取时序特征,并利用双向长短期记忆网络BiLSTM捕捉双向时序依赖。采用真实的地形数据与气象数据,经拉格朗日扩散模型计算核素浓度分布数据,构成训练时序数据集。选取美国伊利诺伊州电厂SF<sub>6</sub>扩散示踪实验数据集Kincaid,验证TCN-BiLSTM模型的有效性。针对模拟<sup>137</sup>Cs泄漏事故为案例,模型预测值与拉格朗日模型计算结果偏差小于2%,与TCN相比MAE和RMSE分别降低了29.7%和33.3%,该方法可为核素扩散分布预测提供快速有效支持。

**关键词** 时序卷积网络,双向长短期记忆网络,核素大气扩散,浓度预测

**中图分类号** TL7, X591

**DOI:** 10.11889/j.1000-3436.2025-0057

**CSTR:** 32195.14.j.JRRRP.1000-3436.2025-0057

**引用该文:**

王箫箫, 杨子辉, 艾雨星, 等. 基于TCN-BiLSTM混合神经网络模型的核素扩散浓度预测方法[J]. 辐射研究与辐射工艺学报, 2025, 43(6): 060601. DOI: 10.11889/j.1000-3436.2025-0057.  
WANG Xiaoxiao, YANG Zihui, AI Yuxing, *et al.* Prediction of radionuclide dispersion concentration based on TCN-BiLSTM model[J]. Journal of Radiation Research and Radiation Processing, 2025, 43(6): 060601. DOI: 10.11889/j.1000-3436.2025-0057.



基金资助: 安徽省自然科学基金(2008085MA23)、合肥物质科学研究院院长基金(YZJJ202208-TS)、科工局乏燃料后处理专项

第一作者: 王箫箫, 女, 2000年9月出生, 2023年6月于淮师范大学获得学士学位, 现为该校硕士研究生, 电子信息专业, E-mail: xxwang@inest.cas.cn

通信作者: 杨子辉, 副研究员, E-mail: zihui.yang@inest.cas.cn

收稿日期: 初稿 2025-07-11; 修回 2025-09-19

Supported by Natural Science Foundation of Anhui Province (2008085MA23), Director's Fund of Hefei Institutes of Physical Science, CAS (YZJJ202208-TS), and The Spent Fuel Reprocessing Research Project

First author: WANG Xiaoxiao (female) was born in September 2000, and obtained a bachelor's degree from Huaibei Normal University in June 2023, and is currently a master's student at the same university, majoring in Electronic Information, E-mail: xxwang@inest.cas.cn

Corresponding author: YANG Zihui, associate researcher, E-mail: zihui.yang@inest.cas.cn

Received 11 July 2025; accepted 19 September 2025

## Prediction of radionuclide dispersion concentration based on TCN-BiLSTM model

WANG Xiaoxiao<sup>1,2</sup> YANG Zihui<sup>2</sup> AI Yuxing<sup>2,3</sup> LI Yuchen<sup>2,3</sup>

MO Ziwen<sup>1,2</sup> YUAN Zhenhao<sup>1,2</sup> LI Taosheng<sup>2</sup>

<sup>1</sup>(College of Physics and Electronic Engineering, Huaibei Normal University, Huaibei 235000, China)

<sup>2</sup>(Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, China)

<sup>3</sup>(Science Island Branch, University of Science and Technology of China, Hefei 230026, China)

**ABSTRACT** To meet the demand for rapid prediction of radionuclide dispersion in nuclear emergency response, this study proposes a hybrid TCN-BiLSTM model for fast concentration forecasting. Temporal features are extracted by the TCN, while bidirectional dependencies are captured by the BiLSTM. Training data are generated using realistic terrain and meteorological inputs with a Lagrangian dispersion model. The model is validated on the Kincaid SF<sub>6</sub> tracer experiment dataset in Illinois, USA, and further applied to a simulated <sup>137</sup>Cs release case. Results show that prediction errors remain below 2%, and compared with a standalone TCN, the hybrid model reduces MAE and RMSE by 29.7% and 33.3%, respectively, demonstrating its efficiency and accuracy for rapid radionuclide dispersion prediction.

**KEYWORDS** Temporal convolutional network, Bidirectional long short-term memory, Radionuclide atmospheric dispersion, Concentration prediction

**CLC** TL7, X591

核电厂事故时放射性核素通过大气释放到环境中，排放到环境中的放射性核素在风和大气湍流作用下不断输送和扩散，在短期内对环境产生大范围的影响，风向、风速、温度等气象条件以及事故周围地区的地形条件影响气态污染物在大气中的扩散状态。风洞实验、大气示踪实验和数值模拟<sup>[1-2]</sup>是核素大气扩散预测的主流研究方法。前两者虽能提供高精度数据，但成本较高且耗时。常用的数值模拟方法包括高斯模型、拉格朗日模型、欧拉模型和计算流体动力学(CFD)模型<sup>[3-6]</sup>等，传统数值模拟模型在处理复杂地形和气象数据时难以兼顾计算效率与预测精度。针对这一问题，赵丹等<sup>[7]</sup>基于CFD方法系统分析了冷却塔对气载放射性核素扩散的影响，结果表明，冷却塔排放会显著改变局地流场和扩散路径，进一步揭示了数值模拟在复杂场景下的挑战与不足。为更直观地展示核素扩散过程，贾亚宁等<sup>[8]</sup>结合开源的量子地理信息系统(QGIS)和三维可视化技术，开发了交互式扩散数据展示平台，直观展示核素的空间分布特征。

近年来，深度学习在核素大气预测领域显示出巨大潜力。Pereira等<sup>[9]</sup>开发一种基于人工神经网络(ANNs)的移动剂量预测系统，证明人工神经网络在核事故中预测放射性物质释放后的辐射剂量

的有效性，集成到移动应用中，为现场应急响应提供实时支持。Desterro等<sup>[10]</sup>将基于图形处理器(Graphics processing unit, GPU)的深度循环神经网络模型应用于核电厂事故的辐射剂量预测任务中。Yue等<sup>[11]</sup>使用反向传播神经网络，通过伽马剂量率和气象数据快速分类核事故的释放类别，结合遗传算法和模拟退火优化训练过程，提升了分类精度。Ling等<sup>[12]</sup>结合时序卷积网络(TCN)和二维卷积神经网络(2D-CNN)，并使用粒子群算法进行优化，实现了对源项的高精度反演。此外，张金龙等<sup>[13]</sup>将深度前馈神经网络与自适应卡尔曼滤波融合，用以改进氙源项反演的准确。罗昭锦等<sup>[14]</sup>将生物启发式网络用于辐射场区全覆盖路径规划，帮助制定核事故现场作业路线，以最小化人员受照剂量。TCN-BiLSTM作为时序预测模型在环境科学研究中展现出独特的优势。Pang等<sup>[15]</sup>提出了一种基于TCN-BiLSTM的氢船推进载荷短期预测模型，为船舶能源管理的实时优化提供了参考。Mao等<sup>[16]</sup>利用改进的鸟群优化算法(SBOA)优化连续变分模态分解(SVMD)，结合TCN-BiLSTM模型对电力负荷序列进行预测。肖裕锋等<sup>[17]</sup>提出了基于XGBoost特征筛选的VMD-TCN-BiLSTM模型，用于巢湖总磷含量预测。宋江涛等<sup>[18]</sup>则利用SGMD-SE与优化的TCN-BiLSTM组合

模型对超短期风功率进行预测。基于 TCN-BiLSTM 在时序预测中的优势, 本文将 TCN-BiLSTM 网络应用于放射性核素扩散预测领域。

本研究基于混合神经网络 TCN-BiLSTM 模型, 构建了一种放射性核素扩散浓度预测方法。该方法面向核素泄漏事故场景, 可利用事故发生后监测点处的放射性核素浓度数据及周边气象数据, 预测核素在大气中的扩散浓度, 当前缺少事故监测数据, 采用模拟计算数据进行模型训练与测试。该方法可支持核事故应急决策与降低应急响应成本。

## 1 方法

### 1.1 核素浓度分布数据集构建

使用拉格朗日粒子模型软件对放射性核素扩散过程进行数值模拟, 以生成核素扩散的原始时序数据, 使用公式见式(1)。

$$C(x, t) = \frac{Q}{N_p} \sum_{k=1}^{N_p} \delta(x - X_p^k(t)) \cdot e^{-\lambda t} \quad (1)$$

式中:  $Q$  为源项释放总量;  $N_p$  为虚拟粒子总数;  $\delta$  为狄拉克函数;  $\lambda$  为放射性衰变常数。

地形数据采用核设施周边几十公里范围的高程数据, 本文选用中国科学院地理空间数据云中开放的数字高程模型(DEM), 精度 30 m, 以栅格形式表示, 每个栅格单元存储着特定地点的高程值。气象数据采用当地不同年份、不同季节历史气象数据, 本文采用美国国家海洋和大气管理局(NOAA)的官网(<https://www.noaa.gov>), 包括风速、风向、温度、大气稳定度等气象参数, 时间分辨率为 1 h。

输入数据包括气象数据、地形数据以及源项数据。基于上述输入参数, 通过拉格朗日粒子模型软件计算, 模拟核素在空间和时间维度上的浓度分布场, 从而获得核设施周边区域在不同气象条件和地形特征下的核素浓度分布数据, 计算流程图如图1所示。




图1 核素浓度数据计算流程图

Fig.1 Flowchart of radionuclide concentration calculation

本文采用前向填充方法处理缺失值, 以保持时间序列的连续性, 确保时间步长的一致性和物理含义不受影响。

由于不同参数的量纲会影响模型学习中每个特征的权值, 因此, 本文采用最大最小值标准化方式将数据集归一化处理到[0,1]范围内, 计算公式为式(2)。

$$v_i = \frac{V_i - \min(V_i)}{\max(V_i) - \min(V_i)} \quad (2)$$

式中:  $V_i$  为归一化变量值;  $\max(V_i)$  和  $\min(V_i)$  分别为变量的最大值和最小值。

使用滑动窗口技术来处理时序数据集, 通过设定一个固定大小的窗口, 从原始数据中提取输入特征和目标输出。具体来说, 从时间序列中截

取一个大小为  $T \times F$  的窗口, 其中,  $T$  表示时间步的数量(即窗口内的时间序列长度),  $F$  表示每个时间步的特征数量, 作为模型的输入特征。

### 1.2 混合神经网络模型构建

TCN 的因果卷积和扩展卷积结构能有效提取输入数据的时间序列特征, 残差连接单元促进网络的快速收敛, 扩展卷积的使用扩大了感受野, 增强对长时序依赖的捕捉能力。BiLSTM 通过双向网络结构, 能够同时捕捉数据中的前向和反向时序依赖。本文将 TCN 模型与 BiLSTM 模型相结合, 建立多因素影响核素浓度非线性特征的 TCN-BiLSTM 放射性核素扩散浓度预测模型。模型架构如图2所示。

TCN-BiLSTM模型预测放射性核素浓度的主要流程如图3所示。(1)对气象数据和基于传统拉格朗日模型计算的放射性核素浓度数据先进行前向填充,再进行归一化处理,将归一化后的数据按8:2的比例划分为训练集和测试集。训练集作为TCN模型的输入,TCN通过多个卷积层和扩张卷积操作对输入信息进行特征提取。TCN模型对数据进行提取,减少数据噪声,增强特征表现,为BiLSTM模型提供清晰的输入特征。(2)在BiLSTM模型中输入TCN模型提取的特征,BiLSTM模型

通过遗忘门、输入门和输出门控制网络的输出,筛选需长期记忆或遗忘的内容。这使得模型能够处理时间跨度较长的序列数据,根据前 $T$ 步历史浓度数据来预测下一时间步的放射性核素浓度。(3)在训练阶段,比较训练集的预测结果与真实目标值,计算损失函数值,并对模型参数进行优化以降低损失,确保模型能达到最佳状态。在模型训练完成且损失收敛后,使用预留的测试集数据评估模型性能,确认其预测能力,完成预测任务。




图2 TCN-BiLSTM混合神经网络模型:(a)TCN;(b)BiLSTM;(c)TCN-BiLSTM  
Fig.2 TCN-BiLSTM hybrid neural network model: (a) TCN; (b) BiLSTM; (c) TCN-BiLSTM




图3 基于TCN-BiLSTM混合神经网络模型的核素浓度预测流程图  
Fig.3 Flowchart for predicting nuclide concentration based on TCN-BiLSTM hybrid neural network model

### 1.3 评价指标

因放射性核素浓度随时间变化显著波动, 所以选择平均绝对误差(MAE)作为损失函数, 选择平均绝对误差、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和对称平均绝对百分比误差(SMAPE)来评估模型预测性能, 其计算见式(3)~(6)。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (5)$$

$$\text{SMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{(|\hat{y}_i| + |y_i|)/2} \times 100\% \quad (6)$$

式中:  $\hat{y}_i$  是预测值;  $y_i$  是真实值;  $n$  为样本数量。

在基于示踪实验数据集的迁移适应验证中, 为更全面反映模型在扩散场景下的应用可接受性, 增加了3个大气扩散模型常用指标: 比例两倍因子(FAC2)、比例偏差(FB)标准化均方误差(NMSE)。一般来说模型的统计结果满足  $\text{FAC2} > 0.5$ ,  $-0.3 < \text{FB} < 0.3$ ,  $\text{NMSE} < 1.5$ , 则可认为模型的模拟结果是有效的<sup>[19]</sup>。此外, 本研究还增加了加权 RMSE (WRMSE)、对数尺度 RMSE (Log-RMSE) 和分位数误差( $P_p$ ), 以辅助评价模型在不同浓度水平下的适用性。其定义见式(7)~(12)。

$$\text{FAC2} = \frac{1}{n} \sum_{i=1}^n I \left( 0.5 \leq \frac{\hat{y}_i}{y_i} \leq 2 \right) \quad (7)$$

$$\text{FB} = \frac{\bar{\hat{y}} - \bar{y}}{0.5(\bar{\hat{y}} + \bar{y})} \quad (8)$$

$$\text{NMSE} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n y_i^2} \quad (9)$$

$$\text{WRMSE} = \sqrt{\frac{\sum_{i=1}^n w_i (y_i - \hat{y}_i)^2}{\sum_{i=1}^n w_i}} \quad (10)$$

$$\text{Log - RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\lg(y_i) - \lg(\hat{y}_i))^2} \quad (11)$$

$$\text{Log - RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\lg(y_i) - \lg(\hat{y}_i))^2} \quad (12)$$

式中:  $I(\cdot)$  为指示函数, 条件成立时取 1, 否则取 0;  $\bar{\hat{y}}$  和  $\bar{y}$  分别是预测值与真实值的均值;  $w_i$  是样本的权重。

### 1.4 超参数设置

本文使用网格搜索的方法对卷积通道数、BiLSTM单元数、学习率三类关键超参数进行组合遍历。在预设取值范围内遍历全部组合, 评估各参数组合 MAE、RMSE、MAPE 和 SMAPE 的值, 以 MAE 值最小作为确定最优组合的标准。各组合的性能比较结果见表 1。

网格搜索比较所有参数组合, 当学习率为 0.001、卷积通道数为 64、BiLSTM 单元数为 128 时性能最优, 其余超参数保持不变, 具体取值见表 2。

表 1 网格搜索超参数结果  
Table 1 Results of grid search on selected hyperparameters

|                      | 卷积通道数<br>Filters | MAE  |      |      | RMSE |      |      | MAPE / % |      |     | SMAPE / % |      |     |
|----------------------|------------------|------|------|------|------|------|------|----------|------|-----|-----------|------|-----|
|                      |                  | 64   | 128  | 256  | 64   | 128  | 256  | 64       | 128  | 256 | 64        | 128  | 256 |
| BiLSTM 单元数           |                  | 64   | 128  | 256  | 64   | 128  | 256  | 64       | 128  | 256 | 64        | 128  | 256 |
| BiLSTM units         |                  |      |      |      |      |      |      |          |      |     |           |      |     |
| 学习率=0.001            | 32               | 3.13 | 3.42 | 3.11 | 4.87 | 3.94 | 3.74 | 5.1      | 5.4  | 2.8 | 4.14      | 4.4  | 3.8 |
| learning_rate=0.001  | 64               | 3.30 | 2.20 | 3.49 | 4.23 | 2.92 | 3.98 | 5.7      | 2.9  | 4.8 | 4.24      | 2.8  | 4.4 |
|                      | 128              | 8.37 | 9.07 | 9.51 | 9.15 | 9.41 | 9.62 | 13.2     | 17.4 | 9.4 | 10.8      | 15.0 | 8.8 |
| 学习率=0.000 5          | 32               | 3.62 | 3.66 | 3.50 | 3.71 | 3.90 | 3.91 | 5.9      | 5.8  | 4.6 | 4.8       | 4.5  | 5.1 |
| learning_rate=0.0005 | 64               | 3.44 | 2.81 | 3.55 | 3.99 | 2.89 | 4.49 | 5.3      | 3.1  | 5.7 | 4.8       | 2.9  | 4.5 |
|                      | 128              | 4.55 | 3.99 | 3.61 | 5.84 | 4.14 | 5.61 | 5.7      | 5.2  | 5.5 | 4.9       | 4.4  | 4.5 |

表 2 超参数设置  
Table 2 Hyperparameter settings

| 超参数            | 值     | 超参数            | 值            |
|----------------|-------|----------------|--------------|
| Hyperparameter | Value | Hyperparameter | Value        |
| 学习率            | 0.001 | 卷积核大小          | 4            |
| Learning_rate  |       | Kernel_size    |              |
| 卷积通道数          | 64    | 扩张系数           | (1, 2, 4, 8) |
| Filters        |       | Dilations      |              |
| 迭代次数           | 200   | BiLSTM 单元数     | 128          |
| Epochs         |       | BiLSTM units   |              |
| 批量大小           | 16    | Dropout        | 0.3          |
| Batch_size     |       |                |              |

## 2 测试案例

### 2.1 基于示踪实验数据集的迁移适应验证

为检验 TCN-BiLSTM 模型在不同场景条件下

表 3 Kincaid 数据集示例  
Table 3 Example from the Kincaid dataset

| 时间              | 风向 / (°)       | 风速 / 节     | 排放速率 / ( $\text{g} \cdot \text{s}^{-1}$ ) | 浓度 / ( $\mu\text{g} \cdot \text{m}^{-3}$ ) |
|-----------------|----------------|------------|-------------------------------------------|--------------------------------------------|
| Time            | Wind direction | Wind speed | Emission rate                             | Concentration                              |
| 1980-4-20-14:00 | 29             | 12         | 10.2                                      | 0.748                                      |
| 1980-4-20-15:00 | 29             | 14         | 8.2                                       | 0.442                                      |
| 1980-4-25-12:00 | 30             | 6          | 11.2                                      | 1.854                                      |
| 1980-4-25-13:00 | 20             | 4          | 11.2                                      | 0.599                                      |
| 1980-4-25-14:00 | 1              | 8          | 11.3                                      | 1.540                                      |
| 1980-4-25-15:00 | 31             | 10         | 11.1                                      | 1.300                                      |

图 4 显示了 Kincaid 数据集中浓度样本的分布情况，样本主要集中在低浓度区间，分布不均




图 4 浓度直方图  
Fig.4 Concentration histogram

超参数设置与表 2 一致，将数据集按照时间顺序进行划分，以 8:2 的比例划分为训练集与测试集，并在训练集上对模型进行训练，从而评估其

的预测效果，本文选取 Kincaid 数据集作为独立案例进行测试与对比分析。Kincaid 野外实验是美国电子能源研究院 (EPRI) 烟羽模型验证与开发项目的一部分，于 1980 年至 1981 年在美国伊利诺伊州电厂进行。实验从一个高度 187 m、直径 9 m 的电厂烟囱释放  $\text{SF}_6$  气体，监测器分别布置在距源 0.5~50 km 范围内的 12 条弧线上。地形以平坦农田为主以及少量湖泊，地表粗糙度约 10 cm。气象数据从美国国家气象局 (NWS) 监测站点收集，包括风向、风速、温度等数据，时间分辨率为 1 h。

在本研究中，选取气象数据、释放数据以及前 4 个时间步的气体浓度数据作为输入变量，来预测下一时刻的浓度值。其中，气象数据包括风向、风速，释放数据为  $\text{SF}_6$  排放速率。为保证数据质量，仅保留记录完整且无异常的样本，共计 586 条，数据样本如表 3 所示。

在不同场景下的泛化能力。TCN-BiLSTM 对 Kincaid 数据集的预测结果如图 5 所示。

Kincaid 数据集低浓度样本占比较高，微小的预测偏差会显著放大相对误差。模型在该数据集上的 MAE 为 0.09、RMSE 为 0.12，绝对误差较小，且 FAC2 为 0.92，FB 为 0.15，NMSE 为 0.079，满足  $\text{FAC2} > 0.5$ ， $-0.3 < \text{FB} < 0.3$ ， $\text{NMSE} < 1.5$ ，表明模型预测结果可靠。为进一步分析模型误差结构，绘制了残差的  $Q-Q$  图。从图 6 可以看出，绝大多数点分布在理论分布直线上，表明残差近似服从正态分布，仅在分布两端存在轻微偏离。这说明模型在不同场景下具有较好的泛化能力，预测误差结构合理，未出现系统性偏差。

为检验模型在不同浓度水平下的适用性，图 7 展示了 FAC2 在浓度分位区间内的分布情况。可以看出，除最低浓度区间外，其余各区间 FAC2 均保持在 0.9 以上，且大部分达到 1.0，表明模型在中高浓度区间具有稳定而可靠的预测性能。




图5 TCN-BiLSTM模型预测结果散点图

Fig.5 Scatter plot of TCN-BiLSTM model predictions




图6 Q-Q图

Fig.6 Quantile-quantile plot

本研究选取了ARIMA、TCN、BiLSTM以及CNN-BiLSTM作为对照模型，并在相同数据划分与参数设置条件下进行对比。各模型在Kincaid数据集上的预测结果如表4所示。可以看出，

ARIMA模型的MAE和RMSE指标明显偏大，FAC2为0.34，FB为0.56，不满足 $FAC2 > 0.5$ 和 $-0.3 < FB < 0.3$ 的要求，预测性能最差。深度学习模型整体上优于传统方法，TCN、BiLSTM和CNN-BiLSTM在各项指标上与TCN-BiLSTM相近，但TCN-BiLSTM模型的MAPE为52.54%，相较于表现较好的BiLSTM模型的MAPE还降低了16.94%，所以TCN-BiLSTM模型整体性能最佳。




图7 FAC2 vs. 浓度分位数

Fig.7 FAC2 vs. concentration quantiles

表 4 不同模型对比结果  
Table 4 Comparison Results of different models

| 模型<br>Model | MAE  | RMSE | MAPE / % | SMAPE / % | WRMSE | Log-<br>RMSE | $P_{50}$ / % | FAC2 | FB   | NMSE |
|-------------|------|------|----------|-----------|-------|--------------|--------------|------|------|------|
| ARIMA       | 0.47 | 0.51 | 487.88   | 92.76     | 0.45  | 2.15         | 29.81        | 0.34 | 0.56 | 0.35 |
| TCN         | 0.12 | 0.19 | 100.35   | 37.94     | 0.30  | 1.57         | 23.99        | 0.82 | 0.07 | 0.23 |
| BiLSTM      | 0.11 | 0.12 | 60.85    | 27.68     | 0.18  | 1.52         | 17.89        | 0.93 | 0.13 | 0.09 |
| CNN-BiLSTM  | 0.10 | 0.14 | 68.26    | 31.30     | 0.21  | 1.45         | 22.96        | 0.90 | 0.14 | 0.13 |
| TCN-BiLSTM  | 0.09 | 0.12 | 52.54    | 32.19     | 0.18  | 1.72         | 20.07        | 0.92 | 0.15 | 0.10 |

2.2 模拟<sup>137</sup>Cs泄漏事故

本文选取浙江省某县的核设施厂址周边9 km×9 km的区域作为研究对象，其地貌特性主要以丘陵和平原为主，周围有丰富的水源资源，靠近东海。如图8所示。




图 8 某县地形(彩色见网络版)  
Fig.8 County topography (color online)

将研究区域划分为45×45的网格，气象数据涵盖了2010年1月至2020年8月期间。在模拟发生<sup>137</sup>Cs泄漏事故时，排放浓度为3×10<sup>11</sup> Bq/m<sup>3</sup>，排放速率为1×10<sup>10</sup> Bq/s，排放时间为1 d，红色点为释放位置。结合核设施周围的地理特征以及人口分布情况，选取了一个面积为200 m×200 m的区域进行预测，对应网格坐标为(6,18)，如图9所示。将数据集按8:2的比例划分为训练集和测试集，风向、风速和前T时间步的核素浓度数据作为输入变量，下一时间步的放射性核素浓度数据作为输出变量。数据共有3 415条，数据样本如表5所示。

经网格搜索对比不同时间步设定，结果如表6所示。发现时间步长过短不能充分捕捉时序依赖，时间步长过长导致噪声累积。因此时间步长设定为5，即模型每次预测使用该监测点的前5个时间步的数据预测下一时刻的核素浓度。输入张量形

状为（时间步×特征数），通过扩张系数（1,2,4,8），模型逐步扩展感受野，能够有效覆盖5步时间窗的时序依赖。




图 9 研究区域  
Fig.9 Location of the study area

表 5 <sup>137</sup>Cs泄漏模拟数据示例  
Table 5 Example of simulated <sup>137</sup>Cs leak data

| 时间<br>Time | 风向 / (°)<br>Wind<br>direction | 风速 / 节<br>Wind<br>speed | 浓度 / (Bq·m <sup>-3</sup> )<br>Concentration |
|------------|-------------------------------|-------------------------|---------------------------------------------|
| 2010-01-10 | 23.0                          | 10                      | 196.50                                      |
| 2010-01-11 | 26.5                          | 12                      | 240.27                                      |
| 2010-01-15 | 6.5                           | 9                       | 235.66                                      |
| 2010-01-21 | 5.5                           | 13                      | 180.52                                      |

2.2.1 与拉格朗日模型计算结果对比

基于TCN-BiLSTM的放射性核素浓度预测模型，对模拟事故中<sup>137</sup>Cs泄漏浓度进行预测，图10(a)和(b)显示了模拟浓度和预测浓度的分布热图。模型对模拟<sup>137</sup>Cs泄漏的预测结果如图11所示，预测值与真实值非常接近，尽管在预测某些极值仍

存不足,但模型的预测趋势与真实值结果一致,表明模型预测精度较高,具有良好的应用效果。

表 6 网格搜索时间步长结果  
Table 6 Grid search results for time step setting

| 时间步长 Time_steps | MAE  | RMSE | MAPE / % | SMAPE / % |
|-----------------|------|------|----------|-----------|
| 3               | 2.93 | 3.04 | 3.3      | 3.6       |
| 5               | 2.20 | 2.92 | 2.9      | 2.8       |
| 7               | 3.06 | 3.49 | 4.25     | 3.56      |
| 9               | 2.99 | 3.92 | 3.61     | 3.57      |




图 10 核素浓度分布 heatmap (彩色见网络版)  
Fig.10 Radionuclide concentration distribution heatmap (color online)

### 2.2.2 与其他模型对比

为保证实验的公平性,所有模型的网络结构参数均保持一致,并在同一数据集上进行训练与测试。以拉格朗日扩散模型计算结果为基准,选取两组模型与 TCN-BiLSTM 模型进行对比:第一组为只考虑时间序列特征的单一模型,包括 LSTM、BiLSTM 和 TCN;第二组为同时考虑周期性与时间序列特征的混合模型,包括 CNN-LSTM 和 CNN-BiLSTM。不同模型对  $^{137}\text{Cs}$  核素浓度预测的结果如图 11 所示。

LSTM 和 BiLSTM 模型明显偏离真实值,TCN-BiLSTM 模型与真实值拟合效果最好,TCN 和 CNN-LSTM 以及 CNN-BiLSTM 模型与真实值均有显著偏差。可以看出,TCN-BiLSTM 模型对  $^{137}\text{Cs}$  核素浓度预测精度优于其他模型。

由表 7 可知,TCN-BiLSTM 模型的 MAE 为 2.20, RMSE 为 2.92, MAPE 为 2.9%, SMAPE 为 2.8%,均低于其他模型,结果表明,模型预测精准。与 TCN 相比,MAE、RMSE、MAPE 和 SMAPE 分别降低 29.7%、33.3%、35.6% 和 31.7%;

与 LSTM 相比,分别降低 89.8%、88.4%、84.0% 和 83.2%;与 BiLSTM 相比,分别降低 90.5%、89.5%、84.8% 和 84.2%;与 CNN-LSTM 相比,分别降低 47.7%、43.6%、35.6% 和 37.8%;与 CNN-BiLSTM 相比,分别降低 45.5%、42.1%、46.3% 和 34.9%。结果表明,TCN-BiLSTM 在各项误差指标上均显著优于对比模型,预测精度提升明显。

数据表明,单一模型的时序建模能力有限,简单增加模型复杂度并不能提升预测性能,TCN-BiLSTM 模型通过结合 TCN 的局部特征提取和 BiLSTM 的双向时序依赖捕捉能力,能够更好地捕捉核素扩散过程中的非线性关系与复杂时空特征,显著提升了预测精度。

### 2.2.3 鲁棒性验证

为了进一步评估 TCN-BiLSTM 模型的鲁棒性,本文采用蒙特卡罗时间序列交叉验证方法,对模型进行 100 次的独立重复实验。在每轮验证中,数据集均被随机划分为 80% 的训练集与 20% 的测试集,避免分区偏差。为了确保实验的可重复性,所有相关操作均统一设置了随机种子(SEED=42)。




图 11 不同模型的实际值与预测值对比(彩色见网络版)  
Fig.11 Actual vs. predicted values for different models (color online)

| 表 7 不同模型评价指标<br>Table 7 Evaluation metrics of different models |       |       |          |           |
|----------------------------------------------------------------|-------|-------|----------|-----------|
| 模型 Model                                                       | MAE   | RMSE  | MAPE / % | SMAPE / % |
| TCN                                                            | 3.13  | 4.38  | 4.5      | 4.1       |
| LSTM                                                           | 21.65 | 25.26 | 18.1     | 16.7      |
| BiLSTM                                                         | 23.09 | 27.69 | 19.1     | 17.7      |
| CNN-LSTM                                                       | 4.21  | 5.18  | 4.5      | 4.5       |
| CNN-BiLSTM                                                     | 4.04  | 5.04  | 5.4      | 4.3       |
| TCN-BiLSTM                                                     | 2.20  | 2.92  | 2.9      | 2.8       |

交叉验证结果如表8所示, TCN-BiLSTM模型的各项评价指标的标准差均小于0.52, 在小范围内波动, 表明模型在多次随机数据划分下的预测表现相对稳定, 具备较好的鲁棒性。在此基础上, 使用MC Dropout方法对预测结果的不确定性进行量化, 通过多次随机采样获得预测均值及95%预测区间(PI)。

| 表 8 蒙特卡罗交叉验证结果<br>Table 8 Monte Carlo cross-validation results |        |        |        |        |
|----------------------------------------------------------------|--------|--------|--------|--------|
| n_iterations                                                   | MAE    | RMSE   | SMAPE  | MAPE   |
| 1                                                              | 1.92   | 2.46   | 1.8%   | 1.8%   |
| 2                                                              | 1.71   | 2.41   | 1.9%   | 1.9%   |
| ....                                                           | ...    | ...    | ...    | ...    |
| 100                                                            | 2.01   | 2.67   | 2.1%   | 2.0%   |
| 平均值 Mean value                                                 | 1.98   | 2.31   | 2.2    | 3.2    |
| 95%置信区间<br>95% confidence interval                             | ± 0.43 | ± 0.51 | ± 0.37 | ± 0.48 |

结果如图12所示, 预测区间大多数情况下能够覆盖真实值, 且区间宽度适中, 表明该模型不仅能提供稳定的点预测, 还能给出可靠的区间估计, 从而提升了模型在应急应用中的可靠性。模型误差的分布情况如图13所示, 各项误差指标的分布相对集中, 进一步验证了模型的鲁棒性。




图12 预测区间(彩色见网络版)  
Fig.12 Prediction interval (color online)




图13 交叉验证中的误差分布  
Fig.13 Error distribution in cross-validation

### 3 结论

本文提出一种基于TCN-BiLSTM混合神经网络的放射性核素浓度预测方法,以拉格朗日扩散模型计算的核素浓度数据和2010年1月至2020年8月的气象数据构建训练数据集,实现核素扩散浓度的快速精准预测。选取EPRI发布的Kincaid数据集作为独立测试集,验证了TCN-BiLSTM模型在新场景中的稳定性。以核设施厂址模拟 $^{137}\text{Cs}$ 泄漏事故为案例,TCN-BiLSTM模型在与拉格朗日模型计算值的对比中表现出最低的预测误差,低于其他神经网络模型。与TCN模型相比,该模型在MAE、RMSE、MAPE和SMAPE指标分别减少29.7%、33.3%、35.6%和31.7%。使用蒙特卡罗方法对模型进行100次的交叉验证,验证结果表明,TCN-BiLSTM模型具有较好的鲁棒性。下一步工作将考虑使用CFD进行模拟预测,拓展输入特征,如边界层高度、地表类型、降水、速度梯度等环

境因子,提升模型在复杂场景下的适应能力;增加雷诺数、速度梯度、温度梯度等物理参数,结合特征重要性分析,优化模型结构并提高物理可解释性。

**作者贡献声明** 王箫箫是本研究的执行者,并完成了论文撰写;杨子辉、李桃生提出研究思路,负责论文的最终修订、审阅及定稿等;艾雨星、李煜辰、莫紫雯、袁振豪参与了数据分析过程。所有作者均已阅读并认可论文最终版的所有内容。

### 参考文献

- 1 Leelőssy Á, Lagzi I, Kovács A, *et al.* A review of numerical models to predict the atmospheric dispersion of radionuclides[J]. *Journal of Environmental Radioactivity*, 2018, **182**: 20-33. DOI: 10.1016/j.jenvrad.2017.11.009.
  - 2 Leelőssy Á, Molnár F, Izsák F, *et al.* Dispersion modeling of air pollutants in the atmosphere: a review[J]. *Central European Journal of Geosciences*, 2014, **6**(3): 257-278. DOI: 10.2478/s13533-012-0188-6.
  - 3 Apsley D D, Castro I P. Numerical modelling of flow and dispersion around cinder cone butte[J]. *Atmospheric Environment*, 1997, **31**(7): 1059-1071. DOI: 10.1016/S1352-2310(96)00213-0.
  - 4 Guo D P, Han T X, Yang F, *et al.* Numerical simulation studies of the flow field and pollutant diffusion around street canyons under different thermal stratifications[J]. *Atmospheric Pollution Research*, 2023, **14**(8): 101829. DOI: 10.1016/j.apr.2023.101829.
  - 5 Jeong H, Park M, Jeong H, *et al.* Terrain and building effects on the transport of radioactive material at a nuclear site[J]. *Annals of Nuclear Energy*, 2014, **68**: 157-162.
  - 6 Leelőssy Á, Mészáros R, Kovács A, *et al.* Numerical simulations of atmospheric dispersion of iodine-131 by different models[J]. *PLoS One*, 2017, **12**(2): e0172312. DOI: 10.1371/journal.pone.0172312.
  - 7 赵丹, 张俊芳, 吕明华, 等. 冷却塔对气载放射性核素扩散影响的计算流体力学数值模拟[J]. *辐射研究与辐射工艺学报*, 2024, **42**(4): 040701. DOI: 10.11889/j.1000-3436.2023-0069.
- ZHAO Dan, ZHANG Junfang, LYU Minghua, *et al.* Computational fluid dynamics numerical simulation of the effect of cooling towers on the diffusion of airborne radionuclides[J]. *Journal of Radiation Research and*

- Radiation Processing, 2024, **42**(4): 040701. DOI: 10.11889/j.1000-3436.2023-0069.
- 8 贾亚宁, 郑晓磊, 陈春花, 等. 大规模核素扩散数据可视化方法研究与应用[J]. 辐射研究与辐射工艺学报, 2018, **36**(5): 050701. DOI: 10.11889/j.1000-3436.2018.rrj.36.050701.  
JIA Yaning, ZHENG Xiaolei, CHEN Chunhua, *et al.* Research and application of large-scale radionuclide diffusion data visualization methods[J]. Journal of Radiation Research and Radiation Processing, 2018, **36**(5): 050701. DOI: 10.11889/j.1000-3436.2018.rrj.36.050701.
- 9 Pereira C M N A, Schirru R, Gomes K J, *et al.* Development of a mobile dose prediction system based on artificial neural networks for NPP emergencies with radioactive material releases[J]. Annals of Nuclear Energy, 2017, **105**: 219-225. DOI: 10.1016/j.anucene.2017.03.017.
- 10 Desterro F S M, Santos M C, Gomes K J, *et al.* Development of a deep rectifier neural network for dose prediction in nuclear emergencies with radioactive material releases[J]. Progress in Nuclear Energy, 2020, **118**: 103110. DOI: 10.1016/j.pnucene.2019.103110.
- 11 Yue Q, Jia W B, Huang T, *et al.* Method to determine nuclear accident release category via environmental monitoring data based on a neural network[J]. Nuclear Engineering and Design, 2020, **367**: 110789. DOI: 10.1016/j.nucengdes.2020.110789.
- 12 Ling Y S, Liu C F, Shan Q, *et al.* Inversion method for multiple nuclide source terms in nuclear accidents based on deep learning fusion model[J]. Atmosphere, 2023, **14**(1): 148. DOI: 10.3390/atmos14010148.
- 13 张金龙, 崔威杰, 栗再新. 基于自适应卡尔曼滤波和深度前馈神经网络的氚源项反演[J]. 辐射研究与辐射工艺学报, 2023, **41**(6): 060602. DOI: 10.11889/j.1000-3436.2022-0104.  
ZHANG Jinlong, CUI Weijie, LI Zaixin. Tritium source term inversion based on adaptive Kalman filtering and deep feedforward neural networks[J]. Journal of Radiation Research and Radiation Processing, 2023, **41**(6): 060602. DOI: 10.11889/j.1000-3436.2022-0104.
- 14 罗昭锦, 刘程峰, 贾文宝, 等. 基于生物启发神经网络的核辐射场区全覆盖路径规划[J]. 辐射研究与辐射工艺学报, 2024, **42**(1): 010601. DOI: 10.11889/j.1000-3436.2023-0093.  
LUO Zhaojin, LIU Chengfeng, JIA Wenbao, *et al.* Full-coverage path planning of nuclear radiation field based on bio-inspired neural networks[J]. Journal of Radiation Research and Radiation Processing, 2024, **42**(1): 010601. DOI: 10.11889/j.1000-3436.2023-0093.
- 15 Pang S, Zou L, Zhang L, *et al.* A hybrid TCN-BiLSTM short-term load forecasting model for ship electric propulsion systems combined with multi-step feature processing[J]. Ocean Engineering, 2025, **316**: 119808. DOI: 10.1016/j.oceaneng.2024.119808.
- 16 Yang M, Chen Y M, Fang G Z, *et al.* A short-term power load forecasting method based on SBOA-SVMD-TCN-BiLSTM[J]. Electronics, 2024, **13**(17): 3441. DOI: 10.3390/electronics13173441.
- 17 肖裕锋, 张代青. 可解释性融合神经网络在巢湖总磷浓度预测中的应用[J]. 中国农村水利水电, 2025(7): 44-51.  
XIAO Yufeng, ZHANG Daiqing. Application of interpretable fusion neural networks in predicting total phosphorus concentration in Chaohu Lake[J]. China Rural Water and Hydropower, 2025(7): 44-51.
- 18 宋江涛, 崔双喜, 樊小朝, 等. 基于 SGMD-SE 与优化 TCN-BiLSTM/BiGRU 的超短期风功率预测[J]. 太阳能学报, 2024, **45**(10): 588-596.  
SONG Jiangtao, CUI Shuangxi, FAN Xiaochao, *et al.* Ultra-short-term wind power forecasting based on SGMD-SE and optimized TCN-BiLSTM/BiGRU[J]. Acta Energeticae Solaris Sinica (Journal of Solar Energy), 2024, **45**(10): 588-596.
- 19 Chang J C, Hanna S R. Air quality model performance evaluation[J]. Meteorology and Atmospheric Physics, 2004, **87**(1/2/3): 167-196.