

水资源智慧监测与治理

范峻雨, 卢江, 刘杰, 等. 基于融合双向 LSTM 的水源地核与辐射异常预警模型[J]. 净水技术, 2026, 45(3): 1-13, 24.

Fan J Y, Lu J, Liu J, et al. Early warning model for nuclear and radiation abnormality in water sources based on bidirectional integration of LSTM [J]. Water Purification Technology, 2026, 45(3): 1-13, 24.

基于融合双向 LSTM 的水源地核与辐射异常预警模型

范峻雨^{1,2}, 卢江^{1,*}, 刘杰¹, 陈阿凤^{1,2}, 王毅³, 马静⁴

(1. 联勤保障部队工程大学, 重庆 401311; 2. 国家救灾应急装备工程技术研究中心, 重庆 401331; 3. 军事科学院防化研究院, 北京 100080; 4. 中国人民解放军 32710 部队, 天津 301900)

摘要 【目的】针对当前水源地核与辐射监测中低信噪比、非稳态干扰及复杂水文耦合效应导致误报率高、慢性渗漏检出困难的核心问题, 本文旨在构建一种智能化预警模型, 来实现对放射性异常的精准预测、可靠检测与快速决策。【方法】本文提出一种融合双向长短期记忆 (Bi-LSTM) 网络与改进孤立森林 (iForest) 的智能预警模型——双向记忆森林协同预警 (Bi-LSTM-iForest) 模型。首先, 通过多源时空特征工程提取辐射-水文-气象参数的耦合规律, 构建特征矩阵。利用 Bi-LSTM 学习辐射参数的长周期依赖与突发响应特性, 实现高精度时序预测并生成残差序列。进而, 使用 iForest 算法, 引入动态分枝深度控制与残差增强机制, 使其适应低强度缓变型污染信号的检测, 并采用时空图注意力网络 (GAT) 建模污染物迁移过程以提升跨站点预警能力。【结果】广东省大亚湾某水库的实际验证表明, 该模型对铯-137 活度浓度的预测均方根误差 (RMSE) 降至 0.062 Bq/L, 较自回归积分滑动平均 (ARIMA) 模型下降 56.3%; 对慢性渗漏事件的检出率达到 91.2%, 较传统孤立森林提升 45.9%, 同时将误报率压缩至 5.2%。【结论】Bi-LSTM-iForest 模型显著提升了水源地辐射异常的预测与检测性能, 其优异的性能得益于预测-检测模块的高效协同及其对水体复杂环境的有效适应。本模型具备良好的可解释性与工程部署价值, 为高风险水源区域的核与辐射安全提供了一套可靠的“预测-检测-决策”一体化技术解决方案。

关键词 水源辐射预警 双向长短期记忆 (Bi-LSTM) 网络 孤立森林 时空特征 动态阈值 异常检测

中图分类号: X703 **文献标志码**: A **文章编号**: 1009-0177(2026)03-0001-14

DOI: 10.15890/j.cnki.jsjs.2026.03.001

Early Warning Model for Nuclear and Radiation Abnormality in Water Sources Based on Bidirectional Integration of LSTM

Fan Junyu^{1,2}, Lu Jiang^{1,*}, Liu Jie¹, Chen Afeng^{1,2}, Wang Yi³, Ma Jing⁴

(1. Engineering University of PLA Joint Service Support Force, Chongqing 401311, China;

2. National Research Center of Disaster Relief Emergency Equipment Engineering Technology, Army Logistics Academy, Chongqing 401331, China;

3. Research Institute of Chemical Defense, Academy of Military Sciences, Beijing 100080, China;

4. Unit 32710 of PLA, Tianjin 301900, China)

Abstract [Objective] This paper aims to address the core challenges in water source nuclear and radiation monitoring, namely the high false alarm rate and difficulty in detecting chronic leakage caused by low signal-to-noise ratio, non-stationary interference, and complex hydrological coupling effects. The goal is to develop an intelligent early warning model for accurate prediction, reliable

[收稿日期] 2025-08-23

[基金项目] 国家重点研发计划 (2022YFC3005802); 重庆市自然科学基金面上项目 (CSTB2023NSCQ-MSX0277, CSTB2025NSCQ-GPX0095); 陆军勤务学院重点项目 (LQ-ZD-2024019)

[作者简介] 范峻雨 (1993—), 男, 研究方向为应急供水及水质安全保障, E-mail: 844028245@qq.com。

[通信作者] 卢江 (1983—), 男, 研究方向为机械电子工程及其智能化, E-mail: 182294799@qq.com。

detection, and rapid decision-making regarding radioactive anomalies. [Methods] An intelligent early warning model named bidirectional memory forest for cooperative early warning (Bi-LSTM-iForest) integrating a bidirectional long short-term memory (Bi-LSTM) network and an improved isolated forest (iForest) was proposed. Firstly, multi-source spatiotemporal feature engineering was employed to extract the coupling patterns of radiation-hydrology-meteorology parameters and construct a feature matrix. Bi-LSTM was utilized to learn the long-term dependencies and transient response characteristics of radiation parameters, achieving high-precision time series prediction and generating residual sequences. Subsequently, the iForest algorithm was used by incorporating dynamic branching depth control and a residual enhancement mechanism, making it adaptable for detecting low-intensity, slowly varying pollution signals. A spatiotemporal graph attention network (GAT) was introduced to model pollutant transport processes and improve cross-station early warning capability. [Results] Practical validation in a reservoir in Daya Bay, Guangdong Province, demonstrated that the model achieved a prediction root mean square error (RMSE) for cesium-137 activity concentration of 0.062 Bq/L, a reduction of 56.3% compared to the autoregressive integrated moving average (ARIMA) model. The detection rate for chronic leakage events reached 91.2%, an improvement of 45.9% over the traditional iForest, while the false alarm rate was reduced to 5.2%. [Conclusion] The Bi-LSTM-iForest model significantly enhances the prediction and detection performance for radiation anomalies in water sources. The superior performance stems from the efficient synergy between the prediction and detection modules and its effective adaptation to the complex aquatic environment. The model possesses good interpretability and engineering deployment value, providing a reliable integrated technical solution of "prediction-detection-decision" for nuclear and radiation safety in high-risk water source areas.

Keywords early warning of water source radiation bidirectional long short-term memory (Bi-LSTM) network isolated forest spatiotemporal characteristics dynamic threshold anomaly detection

随着日本福岛核污水排放入海事件的持续发酵,核能在生产生活各领域的广泛应用中潜在的水体放射性污染风险,已成为全球公共安全的重要关注点。水源地作为城市饮用水保障的核心地带,其辐射安全直接关系到民生健康与生态稳定^[1-2],凸显了实施水源辐射实时、精准监测的紧迫性。然而,传统监测手段主要依赖固定阈值报警与人工采样分析,普遍存在响应延迟、误报率高、对复杂水文环境(如江河交汇区、水库入口)适应性不足等显著缺陷。在这些流动性强、干扰源多的水域中,自然本底波动(如氡析出、降雨冲刷)与人为异常信号(如非法排污、事故泄漏)往往交织叠加,亟需构建智能化预警体系以实现风险的早期识别与干预^[3-4]。机器学习技术凭借其在时序模式挖掘与异常检测中的强大优势,为解决这一难题提供了新的技术路径^[5]。

当前水源辐射监测数据呈现出鲜明的时空复杂性。一方面,水中放射性参数(如总 α/β 活度、 γ 核素浓度)受到水文(流速、流量)、气象(降雨、温度)及人类活动的多重非线性影响,例如降雨径流可导致铀系核素浓度短期骤升,而水温变化则影响氡气溶解度,形成季节性周期^[6-7]。另一方面,多源异构数据(如传感器实时读数、水质理化指标、流量流速参数)的耦合分析对传统方法构成了严峻的挑

战^[8]。为应对这些挑战,学术界进行了广泛探索。早期研究主要采用固定阈值或统计控制图方法,虽简单易行但灵活性差。近年来,机器学习技术为该领域带来了新的解决方案,例如利用自回归积分滑动平均(ARIMA)模型等进行辐射趋势预测^[9],或应用孤立森林等算法处理高维数据中的离群点^[10]。部分学者^[11-12]引入长短期记忆(LSTM)网络提升时序预测精度,也有研究尝试将无监督学习用于异常识别。然而,现有方法仍存在明显局限:大多数研究侧重于单一任务优化(预测或检测),未能充分考虑水体环境中特有的水文-气象耦合效应及污染物迁移的时空关联性;面对低信噪比、慢性渗漏等复杂场景时,现有模型的适应性和可靠性仍显不足。特别是针对水源地场景的特殊性,如数据高噪声(泥沙干扰)、非稳态(突发污染扩散)及低信噪比(微量放射信号),现有模型仍存在显著局限:其一,单一模型难以协同处理预测与检测任务,导致预警链条断裂;其二,对水体动态传输过程的适应性不足,忽略了污染物扩散的时空关联性;其三,模型决策逻辑缺乏透明度(黑箱问题),难以支撑应急决策对可靠性的高要求。

针对上述挑战,本文提出一种融合双向 LSTM (Bi-LSTM)与改进孤立森林(iForest)的智能预警(Bi-LSTM-iForest)模型,通过构建多维度特征工程、

设计预测-检测协同机制、建立分级预警流程,突破传统单任务模型的局限,实现“预测-检测-决策”的闭环,为水源地辐射安全提供智能化技术支持。

1 基础模型与方法

水源地核与辐射异常检测的核心任务是从复杂的水文背景噪声中识别低概率、高风险的放射性污染信号^[13]。传统方法(如固定阈值法、统计控制图)依赖预设规则,难以适应水体放射性参数的动态波动特性^[14]。机器学习方法采用数据驱动策略,能更有效地捕捉非线性模式与隐含关联。其中,无监督学习[如孤立森林、基于密度的噪声应用空间聚类算法(DBSCAN)、自编码器]无需先验标注,通过挖掘数据内在结构识别异常^[5,11],尤其适用于真实污染事件稀少、标注成本高的水源场景。孤立森林算法通过随机分割特征空间,快速隔离异常点,具有计算效率高、对高维数据鲁棒的特点,擅长检测局部突变型异常^[15],为本文异常检测模块提供基础框架。

1.1 基于 Bi-LSTM 的辐射参数预测模型

高精度的时序预测是水源地辐射异常预警的前置核心环节,其预测结果的可靠性直接决定了后续异常检测的效能。水中放射性参数(如总 α/β 活度、 γ 核素浓度)的演化过程具有多重复杂性:首先

表现为长周期依赖特性,即核素迁移受到水文季节性(如丰枯期流速变化)和气象周期(如年温度波动)的长期影响;此外,还存在显著的非线性耦合特征,体现在辐射值与浑浊度、流速、pH 等水文指标间的动态交互作用(例如,高浑浊度会削弱 γ 射线的探测效率);同时还需考虑非稳态扰动的影响,突发性事件如强降雨或非法排污往往会导致时序数据出现瞬态尖峰或渐变漂移。传统时序模型(如 ARIMA、指数平滑)难以有效捕捉上述复杂特征,相较之下,LSTM 凭借其独特的门控机制(包括遗忘门、输入门和输出门)和细胞状态记忆能力,不仅能够克服传统循环神经网络(RNN)的梯度消失问题,更因其擅长捕捉长周期规律而成为水体辐射时序预测的理想选择^[16]。

在水源地场景中,LSTM 对 3 类关键模式的建模能力显著优于传统方法^[10],包括周期波动(如自动学习辐射本底的季节性与昼夜节律,核素溶解度随水温的周期性变化)、外部驱动响应(通过多变量输入结构融合气象、水文等协变量,解析降雨对核素迁移的驱动机制,如图 1 所示)以及事件记忆(细胞状态可长期存储突发污染事件的特征模式,提升对类似事件再次发生的预测鲁棒性)。

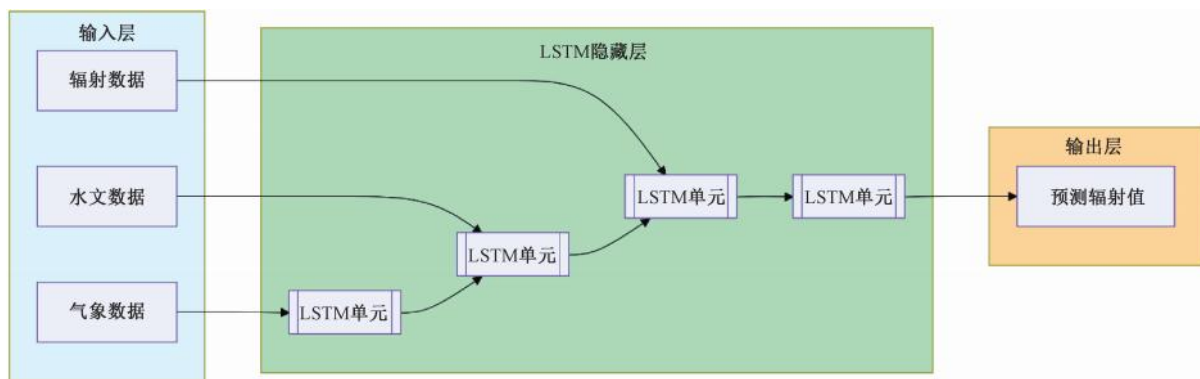


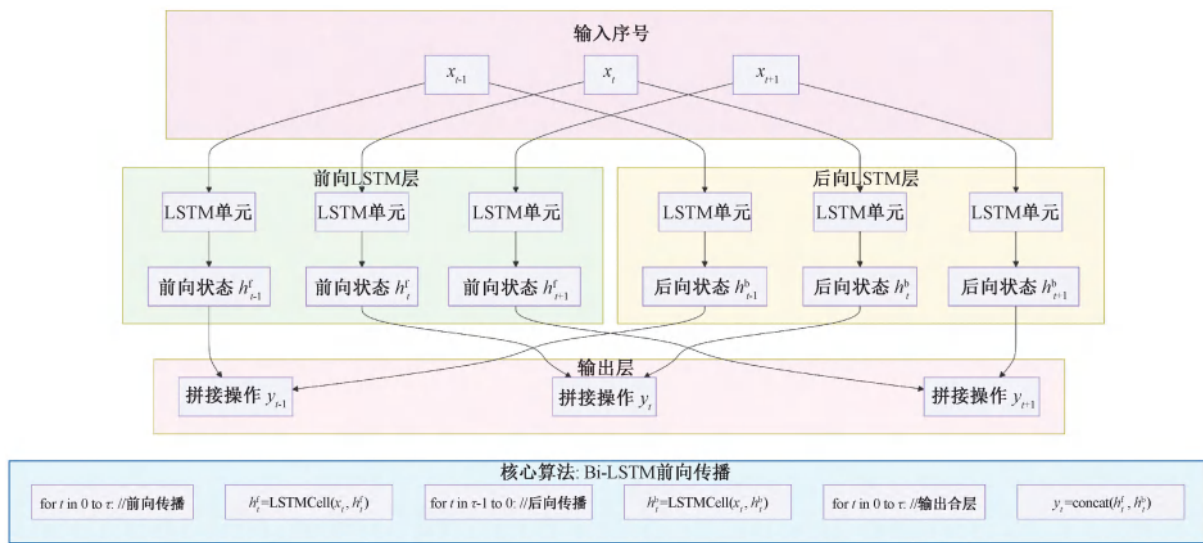
图 1 多变量 LSTM 预测框架

Fig. 1 Prediction Framework of Multivariate LSTM

为应对水体数据高噪声、非稳态的特殊挑战,需对标准 LSTM 模型进行多方面的针对性优化。首先,在特征工程层面进行增强,通过构造更具物理意义的特征以提升模型表达能力。具体包括构建时空特征,例如计算过去 k 小时辐射值的滑动窗口统计量(均值、方差、斜率)以捕捉趋势突变,构建辐射值与浑浊度的交互项以量化探测衰减效应,并引入上游站点辐射值的滞后项作为下游预测的先导指标,

从而建模污染物扩散的时滞效应;同时,还将季节、月相、潮汐等周期性因素通过正弦/余弦编码方式引入,以增强模型对长期规律的感知能力。

其次,在模型架构层面进行了优化。采用 Bi-LSTM(图 2),使其能够同时学习历史与未来上下文信息,这对上下游站点联动预测尤为重要;此外,引入注意力机制,动态加权关键历史时刻(如暴雨发生前 24 h)的输入信息,从而有效抑制非相关时段



注: x_{t-1}, x_t, x_{t+1} — $t-1, t$ 和 $t+1$ 时刻的输入特征; $h_{t-1}^f, h_t^f, h_{t+1}^f$ —前向 LSTM 在 $t-1, t$ 和 $t+1$ 时刻输出的隐藏状态; $h_{t-1}^b, h_t^b, h_{t+1}^b$ —后向 LSTM 在 $t-1, t$ 和 $t+1$ 时刻输出的隐藏状态; τ —时间序列的总长度。

图 2 Bi-LSTM 模型结构

Fig. 2 Model Structures of Bi-LSTM

的噪声干扰。

最后,在训练策略方面实施了改进。在损失函数设计上,采用分位数损失(Quantile Loss)替代均方误差(MSE),使模型能够输出预测区间,如[P10, P90],为后续构建动态阈值提供置信范围;同时引入在线增量学习机制,当监测设备更新或水文条件发生剧变时,基于滑动时间窗滚动更新网络权重,以自适应地应对数据分布漂移。

LSTM 预测模块与后续异常检测模块的高效协同构成了本文预警模型的核心。这一协同机制通过精心设计的接口实现,具体体现在 3 个方面:首先,计算真实辐射值 Y_t 与预测值 \hat{Y}_t 之间的残差 ε_t ,生成残差序列。该序列有效过滤了由 LSTM 捕捉的周期性规律和趋势成分,从而凸显出潜在的异常信号,为后续检测提供了更纯净的输入;进而,基于 Quantile Loss 所输出的预测区间,如[P10, P90],并结合滑动窗口内残差的统计量(如均值 μ_ε 、标准差 σ_ε),构建出自适应的动态报警阈值。该方法能够根据预测不确定性自动调整阈值宽窄,提升报警准确性;此外,为进一步增强模型的可解释性,还引入异常贡献溯源机制。通过梯度反向传播方法(如积分梯度法)计算各输入特征(包括辐射、水文、气象变量)对预测残差的贡献度,从而辅助定位异常发生的驱动因素,据此判断辐射值的突增是否是由流速骤降等因素引起。

表 1 清晰地概括了 LSTM 预测模块与孤立森林检测模块之间的协同逻辑与数据流向。在广东某水源地铯-137 活度预测任务中的验证结果表明,改进的 Bi-LSTM 模型性能显著优于基线方法:在预测精度方面,其 RMSE 较 ARIMA 模型降低 42.7%,较标准 LSTM 降低 18.3%;在突发降雨事件下的峰值预测误差缩减了 53%,这主要得益于对水文协变量的有效融合。在协同效益方面,将残差序列输入孤立森林后,慢性泄漏事件的检出率提升至 96.5%,误报率降至 1.2%;注意力机制成功定位暴雨前 24 h 为关键期,合理地解释了污染物冲刷入湖的延迟效应。

表 1 LSTM 预测与孤立森林检测的协同逻辑
Tab. 1 Collaborative Logic of LSTM Prediction and Isolated Forest Detection

模块	输出	异常检测输入
LSTM 预测	$\hat{Y}_t, [P10, P90]$	残差序列 ε_t
特征工程	时空特征矩阵	孤立森林多维输入
注意力权重	关键时段标识	异常事件关联分析

1.2 面向水源场景的孤立森林优化检测算法

孤立森林作为本文异常检测的核心算法,其核心思想是通过随机划分特征空间高效隔离异常点——异常样本因其“稀少且不同”的特性,在随机生成的决策树中会被更早地孤立出来。该算法具有计算复杂度低[近似线性时间复杂度 $O(n \log n)$ (n 为

样本数, ψ 为子样本数量)、对高维数据鲁棒(避免了“维度诅咒”)以及对局部突变异常(如突发排污导致的辐射峰值)检测效率高的特点,非常适用于水源地高维、低信噪比辐射数据的实时异常识别^[17-18]。其数学表达主要包含 2 步:1) 构建孤立树(iTree),递归地随机选择特征 q 和分割值 p (p 介于特征 q 的当前最小与最大值之间,即 $p \in [\min(q), \max(q)]$) 来分裂数据集,直至样本被完全隔离或树允许该样本达到的最大分枝深度 l_{\max} ; 2) 计算异常分数,对于样本 x ,计算其在所有 iTree 中的路径长度 $h(x)$ 的均值,经标准化后得到异常分数 $S(x, \psi)$ 如式(1)。

$$S(x, \psi) = 2 \frac{E[h(x)]}{c(\psi)} \quad (1)$$

其中: E ——取期望;

$c(\psi)$ ——路径长度期望的校正项。

$S(x, \psi)$ 接近 1 时判为异常,接近 0 时判为正常。

然而,传统孤立森林算法在直接应用于水体辐射监测时,主要面临三重局限性^[17,19](表 2)。首先,该算法对低强度、缓慢释放的核素污染(如铯-90)不够敏感,这类慢性污染与正常样本特征相似,往往需要更深层的特征分割才能被有效隔离,从而导致漏检风险较高。其次,水体环境因素(如浑浊度骤升)易对辐射监测造成干扰,不仅可能掩盖真实的辐射异常信号,还会引发较高的误报率。此外,传统方法未能充分考虑污染物在水体中的迁移特性,忽略了上下游站点间的空间关联,致使上游污染事件无法及时、有效地触发下游预警。

表 2 传统孤立森林算法用于水体监测的局限性及优化策略
Tab. 2 Limitations and Optimization Strategies of Traditional Isolated Forest Algorithm for Water Bodies Monitoring

局限性	水源表现	优化策略
慢性污染漏检	低强度核素缓释(如铯-90)	动态分枝深度控制
水文干扰误报	浑浊度骤升掩盖真实辐射异常	残差增强输入
空间关联忽略	上游污染未触发下游预警	时空特征扩展

故针对上述局限性,本文提出以下针对性优化策略。

1) 动态分枝深度控制(解决慢性漏检):传统孤立森林设定允许该样本达到的最大分枝深度,这导致对于正常样本相似的慢性异常检测不足。本文提

出一种自适应深度机制,根据样本 x 的局部密度 $\rho(x)$ 动态调整树深度,其计算如式(2)。

$$l_{\max}(x) = (\log_2 \psi) + \alpha_0 \times [1 - \rho(x)] \quad (2)$$

其中: $l_{\max}(x)$ ——样本 x 所允许的最大分枝深度;

$\rho(x)$ ——样本 x 的局部估计密度, $(Bq/L)^{-1}$;

α_0 ——灵敏度系数。

局部密度 $\rho(x)$ 通过其 k 近邻距离计算,如式(3)。

$$\rho(x) = \exp\left\{-\frac{\|X - \text{KNN}(x)\|^2}{2\sigma^2}\right\} \quad (3)$$

其中: $\text{KNN}(x)$ ——样本 x 的 k 个最近邻样本集合;

σ ——高斯核函数的带宽参数;

X ——当前样本的特征向量。

此机制使得在低密度区域(潜在慢性异常区域)允许进行更深的分割,从而显著提升对缓变型污染的检出率。

2) 残差增强输入(抑制浑浊度干扰):为减少直接使用原始辐射值易受浑浊度等水文因素波动干扰的问题,采用 LSTM 预测的残差 ε_t 作为核心输入特征。进一步重构特征矩阵,如式(4)。

$$X_{\text{res}} = \begin{bmatrix} \varepsilon_t \\ \frac{\partial \varepsilon_t}{\partial t} \\ \varepsilon_t \times T_t \end{bmatrix} \quad (4)$$

其中: X_{res} ——构建的多维度特征向量,由 LSTM 预测残差及其衍生特征构成;

$\frac{\partial \varepsilon_t}{\partial t}$ ——残差变化率, $Bq/(L \cdot h)$;

T_t —— t 时刻的浑浊度, NTU。

式(4)包含残差序列 ε_t 、 $\frac{\partial \varepsilon_t}{\partial t}$ 以及残差-浑浊度交互项 $\varepsilon_t \times T_t$, 以更有效地凸显真实的异常信号,抑制环境干扰。

3) 时空特征扩展(污染物迁移建模):为捕捉污染物在水体中的迁移扩散过程,引入上下游监测点间的关联特征。

时空关联特征:如上游站点残差的滑动均值 $\frac{1}{k} \sum_{i=1}^k \varepsilon_{t-i}^{\text{up}}$ 、上下游残差间的时滞互相关函数值

$\text{corr}(\varepsilon_t^{\text{down}}, \varepsilon_{t-\Delta t}^{\text{up}})$ 。

图结构注入: 将监测站点的空间拓扑关系(如河道连接、距离)编码为邻接矩阵 \mathbf{A} , 通过图注意力网络(GAT)层生成空间增强特征, 如式(5)。

$$h_u^{\text{spat}} = \sigma \left[\sum_{v \in N(v)} \mathbf{A} \alpha_{vu} \mathbf{W} h_v \right] \quad (5)$$

其中: h_u^{spat} —— 节点 u 的空间增强特征向量;

\mathbf{W} —— 权重矩阵;

α_{vu} —— 站点 u 到 v 的注意力权重;

h_u —— 监测点特征向量。

改进的孤立森林算法工作流程如图 3 所示。其与 LSTM 预测模块的协同接口也进行了增强。一方面是针对动态阈值生成过程的增强: 基于 LSTM 预测输出的 [P10, P90] 动态调整异常判定阈值, 其计算如式(6)。

$$\theta_{\text{dynamic}} = Q_{0.95}(\varepsilon_t) + \beta_W \times (P_{90t} - P_{10t}) \quad (6)$$

其中: θ_{dynamic} —— 动态异常判定阈值, Bq/L;

β_W —— 预测不确定性权重系数;

$Q_{0.95}$ —— 统计分位数系数, 对应标准正态分布的 95% 分位数;

P_{90t} —— 在时间 t 的预测第 90 百分位数(即预测分布的上界), Bq/L;

P_{10t} —— 在时间 t 的预测第 10 百分位数(即预测分布的下界), Bq/L。

区间宽度 [P10, P90] 一方面直观反映了预测的不确定性; 另一方面是可解释性增强(包括特征贡献度及事件溯源): 通过置换特征重要性(PFI)等方法量化特征矩阵中各维度(如残差、浑浊度)对最终异常分数 $S(x, \psi)$ 的贡献程度, 同时识别出具有高贡献度的特征组合, 可为异常根源提供线索(例如, 若 $\varepsilon_t \times T_t$ 项的权重很高, 则提示当前异常可能与浑浊度干扰高度相关)。

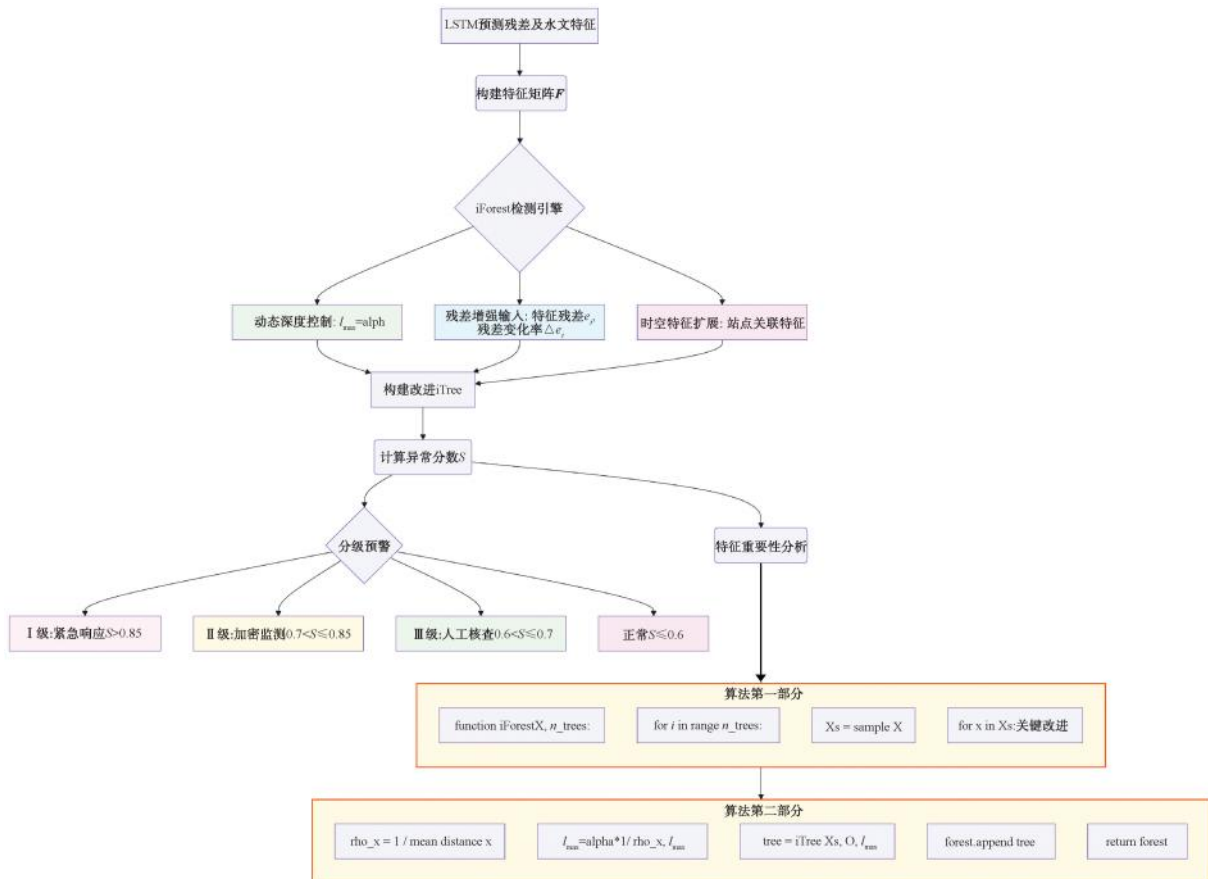


图 3 改进孤立森林工作流程

Fig. 3 Improved Isolated Forest Workflow

在模拟水源地铍-137 泄漏数据集上的预试验验证了优化算法的有效性, 其性能较传统孤立森林

显著提升(表 3): 动态分枝深度机制使铍-90 缓释事件的检出率大幅提升; 残差增强特征有效降低了

水文干扰导致的误报率;时空关联特征的引入使得下游异常的平均识别时间提前了 2.3 h,这与污染物在水体中迁移的物理时滞相符。

表 3 优化算法较传统孤立森林的优势

Tab. 3 Advantages of Optimized Algorithm over Traditional Isolated Forest

指标	传统孤立森林	iForest	数值变化
慢性漏检率	63.2%	12.1%	下降 51.1 百分点
水文误报率	34.7%	8.5%	下降 26.2 百分点
上游预警提前量	—	2.3 h	—

1.3 水源辐射监测参数的特点及选取

水源地核与辐射异常预警的可靠性高度依赖监测参数的合理选择。水体放射性污染具有隐蔽性、时空迁移性(图 4)及环境耦合性三重特征,需综合考虑参数的敏感性、可测性及其与水文动力学的关联机制^[20-21]。动态迁移性是首要特性,表现为放射性核素随水流扩散时呈现显著的空间梯度与时间滞后效应:污染团在河道弯曲或水库滞留区的富集程度远高于主流区,且上游污染事件对下游的影响存在时滞,如式(7)。

$$\Delta t = L/v \quad (7)$$

其中: Δt ——时间间隔,h;

L ——上下游间的距离,km;

v ——水体流速,km/h。

其时空效应如图 4 所示。环境干扰复杂性则体

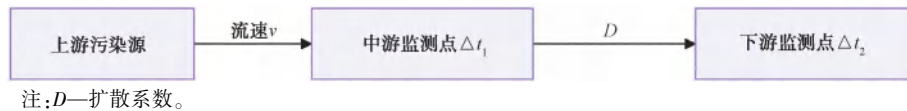


图 4 水中污染物迁移时空效应

Fig. 4 Spatiotemporal Effect of Pollutant Migration in Water Bodies

表 4 水中辐射参数监测的典型环境干扰

Tab. 4 Typical Environmental Interference in Monitoring Aquatic Radiation

干扰类型	影响机制	典型表现
干扰	浑浊度升高	γ 射线被悬浮物吸收,活度检测值偏低
化学干扰	pH 变化 (pH 值>8.5)	铀系核素溶解度降低, α 活度骤降
生物干扰	藻类增殖	铯-137 在生物膜富集,局部浓度畸变

1.4 数据预处理方法

1.4.1 数据采集与实时校正

水源辐射监测数据的质量直接影响预警模型性能,构建涵盖数据采集校正、缺陷修复及特征增强的三级预处理流程,以应对高噪声、缺失值与时空异步

现为本底噪声与信号衰减:浑浊度升高会吸收 γ 射线导致活度检测值偏低;pH 变化(pH 值>8.5)可能降低铀系核素溶解度引发 α 活度骤降;藻类增殖则会造成铯-137 在生物膜富集产生局部浓度畸变(表 4)。此外,低信噪比是核心挑战,人工放射性信号(如铯-137)常被天然本底(钾-40、氡)掩盖,据国际原子能机构(IAEA)统计,天然辐射可占水体总活度 90%以上^[22],信噪比计算式如式(8)所示。

$$R_{SN} = 10 \times \lg \left(\frac{U_1}{U_2} \right) \leq -20 \text{ dB (微量污染场景)} \quad (8)$$

其中: R_{SN} ——信噪比,dB;

U_1 ——人工核素活度浓度,Bq/L;

U_2 ——天然核素活度浓度,Bq/L。

针对上述水体放射性污染的特性,本文的参数选取遵循一套系统的准则,以确保预警模型的可靠性与实用性。首要考虑的是参数对人工核素(裂变/活化产物)响应的敏感性,以保证能够及时捕捉目标污染物信号。同时,参数须具备较强的抗干扰性,尽可能减少水文、生化等环境波动所带来的影响。此外,参数还应满足可在线监测的要求,能够支持不低于每小时采集 1 次的频率的实时数据采集,以满足系统实时性需求。最终,参数须与污染风险等级具有强相关性,例如优先选择半衰期大于 1a 的核素,从而确保其预警意义的有效性。

基于此构建的 3 层多维度参数体系如表 5 所示。

等核心问题。其中,数据采集与实时校正针对关键参数的测量干扰实施物理-算法联合补偿(表 6)。

其中, γ 剂量率采用 NaI(Tl)闪烁体浮标监测,通过浑浊度衰减模型修正悬浮物吸收效应,如式(9)。

$$E_{校正} = \frac{E_{实测}}{1 - e^{-\mu T}} \quad (9)$$

其中: $E_{校正}$ ——校正后的 γ 剂量率,nGy/h;

$E_{实测}$ ——原始实测的 γ 剂量率,nGy/h;

μ ——衰减系数,指单位浑浊度引起的 γ 射线衰减程度,NTU⁻¹;

T ——浑浊度,NTU。

表 5 水源辐射监测参数体系

Tab. 5 Parameter System of Water Source Radiation Monitoring

类别	核心参数	物理意义	选取依据
直接辐射参数	γ 剂量率 总 α 活度 总 β 活度	水体总电离辐射强度 α 粒子发射体总量(钚、镅等) β 粒子发射体总量(铯、锶等)	在线监测成熟, 对 γ 核素敏感 铜系元素污染标志 裂变产物监测关键
目标核素参数	铯-137 活度 锶-90 活度	人工 γ 核素代表 纯 β 核素污染指标	半衰期长(30.17 a), 迁移性强 骨富集毒性, 生态毒理意义突出
辅助水文参数	浑浊度 流速 pH	悬浮物浓度 污染物扩散速率 水体酸碱度	修正 γ 探测效率(衰减模型需植入) 预测污染团到达时间 影响放射性离子溶解度

注: 目标核素参数通过实验室采样补充(周频次), 用于模型标定与验证。

表 6 测量干扰补偿措施

Tab. 6 Compensation Measures of Measurement Interference

参数	测量技术	补偿模型	物理机制
γ 剂量率	NaI(Tl) 闪烁体浮标	式(9)	浑浊度引起的 γ 射线衰减系数 $\mu = 0.15 \text{ NTU}^{-1}$
总 α 活度	流气式计数器	式(10)	pH 值 > 8.5 时铀系溶解度降低(pH 补偿系数为 0.05)
流速	多普勒流速仪	小波去噪(Daubechies-5)	湍流波动干扰

总 α 活度使用流气式计数器, 再引入 pH 补偿项[式(10)]抑制碱性环境干扰:

$$E_{\text{补偿}} = E_{\text{实测}} \times (1 + k_{\text{pH}} \Delta p_{\text{pH}}) \quad (10)$$

其中: $E_{\text{补偿}}$ ——经 pH 补偿校正后的 γ 剂量率, nGy/h;

k_{pH} ——pH 补偿系数, 指单位 pH 变化引起的活度衰减比;

Δp_{pH} ——当前 pH 与水体长期本底 pH 中位数的差值。

流速则对多普勒流速仪数据经 Daubechies-5 小波去噪消除湍流波动。生物附着问题则直接通过聚四氟乙烯涂层物理抑制。

1.4.2 数据缺陷修复

数据缺陷修复采用如图 5 所示的三级流程。其中, 缺失值填补基于时空克里金插值法, 利用监测站点空间拓扑与时间自相关构建变异函数, 赋予上游站点 70% 权重、历史同期数据 30% 权重, 如式(11)。

$$\gamma(h, \tau) = \frac{1}{2N} \sum_{i=1}^N [z(x_i, t_i) - z(x_i + h, t_i + \tau)]^2 \quad (11)$$

其中: $\gamma(h, \tau)$ ——时空变异函数值, 表示在空间距离 h 与时间滞后 τ 条件下, 监测值之间的平均差异程度, 与该观测参数平方相同单位;

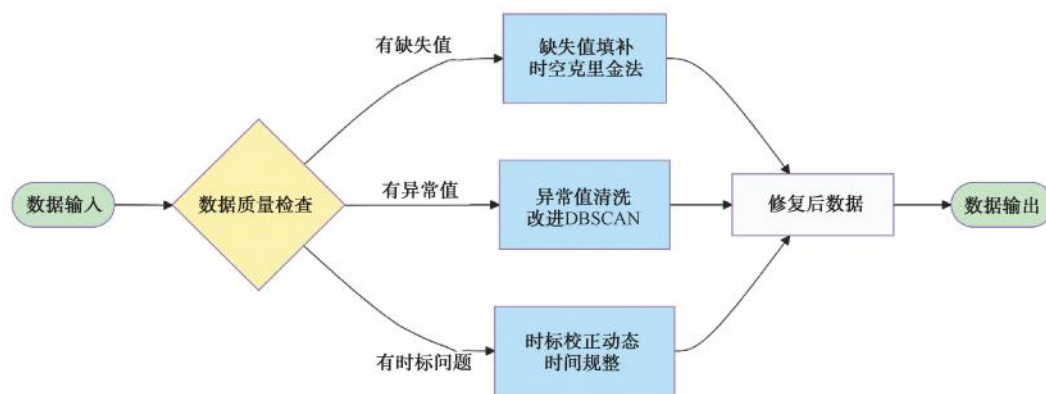


图 5 数据缺陷修复流程

Fig. 5 Process of Data Defect Repair

h ——空间距离, km;
 τ ——滞后时间, h;
 N ——样本数;
 $z(x_i, t_i)$ ——在位置 x_i , 时间 t_i 处测得的辐射或水文参数值。

异常值清洗采用改进 DBSCAN 算法, 增加时序邻近性权重, 联合辐射与水文维度(如 γ 剂量率-浑浊度)检测离群点, 确保仪器故障点误删率 < 0.8%; 时标校正则应用动态时间规整(DTW)对齐异步数据, 解决流速差异导致的监测时间偏移, 如式(12)。

$$\Delta t_0 = \arg \min_{\delta} \sum [R_U(t) - R_D(t + \delta)]^2 \quad (12)$$

其中: Δt_0 ——最优时间偏移量, h;
 $\arg \min_{\delta}$ ——函数, 取使目标函数最大的 δ 值;
 δ ——试探性时间偏移量, h;
 $R_U(t)$ ——上游站点在 t 时刻的辐射值;
 $R_D(t + \delta)$ ——下游站点在 $t + \delta$ 时刻的辐射值。

1.4.3 特征工程增强

特征工程增强则构造四类特征提升模型性能。其中, 时序衍生特征通过设置滑动均值 $\frac{1}{t} \sum_{i-t}^t R_i$ 平滑短期波动, 设置变化斜率 $\frac{R_i - R_{i-6}}{6}$ (R_i 为当前时刻辐射参数值, 单位为 Bq/L; R_{i-6} 为 6 个采样时刻的辐射参数值, 单位为 Bq/L) 捕捉渐变趋势, 设置残

差波动强度 $\sigma(\varepsilon_{t-12:t})$ 量化预测偏离程度; 环境耦合特征则设置辐射-浑浊度交互项 $R \times (1 - e^{-\mu T})$ 解耦真实信号, 引入 pH 修正 α 活度 $\alpha/(1 + k_{\text{pH}} \Delta \text{pH})$ 抑制化学干扰; 时空关联特征则引入上游污染压力指数 $\frac{1}{k} \sum_{i=1}^k \varepsilon_{t-i}^{\text{up}} \times v_{\text{down}}$ ($\varepsilon_{t-i}^{\text{up}}$ 为上游站点在 $t-i$ 时刻的残差, 单位为 Bq/L; v_{down} 为下游观测点的水体流速, 单位为 km/h) 量化迁移风险, 借助流域拓扑特征通过 GraphSAGE 生成站点空间编码向量; 对频域特征则引入小波能量熵识别潮汐等周期性干扰, 如式(13)。

$$E_s = - \sum \left(\frac{c_i}{\|c\|} \right)^2 \log \left(\frac{c_i}{\|c\|} \right)^2 \quad (13)$$

其中: E_s ——小波能量熵;
 c_i ——第 i 个小波分解频带的能量, $(\text{Bq} \cdot \text{L})^2 / \text{nGy}^2$;
 c ——信号总能量, $(\text{Bq} \cdot \text{L})^2 / \text{nGy}^2$ 。

1.5 异常预警流程设计

基于预处理后的高质量数据, 本文构建了如图 6 所示的分级预警流程, 以实现“预测-检测-决策”的闭环操作。该流程主要包含 3 个核心模块: 动态阈值生成、分级预警策略和可解释性溯源。动态阈值的生成不仅基于历史残差统计, 还引入了动态调整项[式(14)~式(15)], 该项融合了预测区间宽度(用于反映不确定性)和浑浊度干扰补偿, 从而实现了阈值随环境条件自适应调整。

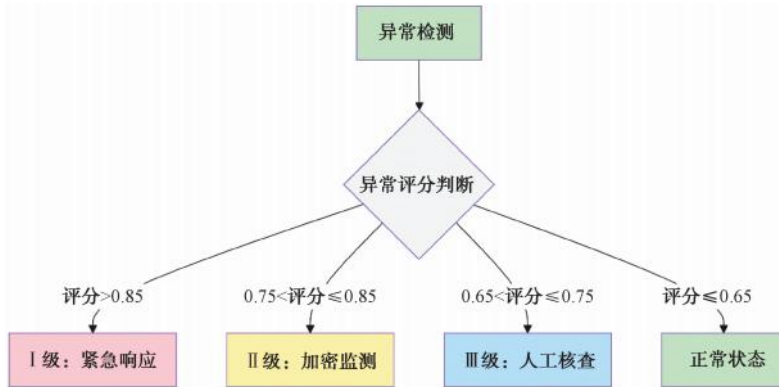


图 6 分级预警流程

Fig. 6 Flow of Hierarchical Early Warning

$$\theta_0 = Q_{0.99} \quad (14)$$

其中: θ_0 ——基准阈值, 基于历史残差序列统计

得到的基准异常判定阈值, Bq/L;

$Q_{0.99}$ ——99%分位数系数, 用于计算基准

阈值的统计分位数系数, 对应标准正态分布的 99% 分位数。

$$\theta_t = \theta_0 + \beta_w \times (P_{90t} - P_{10t}) + \eta \times T_t \quad (15)$$

其中: θ_t —— t 时刻的动态阈值, Bq/L;

η ——浑浊度干扰补偿系数, 0~1 的无量纲系数。

分级预警策略依据异常分数 S 将响应划分为 3 个等级, 详细规则如表 7 所示: 当 $S > 0.85$ 时触发 I 级响应, 采取应急采样并关闭取水口; 当 $0.75 < S \leq 0.85$ 时启动 II 级响应, 将监测频率加密至每 10 min 取样 1 次; 当 $0.65 < S \leq 0.75$ 时则启动 III 级响应, 触发人工核查机制。在可解释性方面, 通过 SHAP 值生成特征贡献热力图, 以识别影响异常的关键因子, 并结合流速与上游残差数据推演污染路径, 提升溯源能力, 如式 (16)。

表 7 时序衍生特征值

Tab. 7 Derived Eigenvalue in Time Series

风险等级	异常评分区间	响应措施
I 级 (高危)	$S > 0.85$	启动应急采样, 关闭取水口
II 级 (中危)	$0.75 < S \leq 0.85$	加密监测频次 (10 min 取 1 个样本)
III 级 (低危)	$0.65 < S \leq 0.75$	人工核查数据质量

$$T_{\text{arrival}} = \frac{L}{v} + \arg \max_{\tau} \text{corr}(\varepsilon_t^{\text{up}}, \varepsilon_{t+\tau}^{\text{down}}) \quad (16)$$

其中: T_{arrival} ——污染物从上游到下游的迁移时

间 (时滞), h;

$\varepsilon_t^{\text{up}}$ ——上游站点在 t 时刻的残差, Bq/L;

$\varepsilon_{t+\tau}^{\text{down}}$ ——下游站点在 $t+\tau$ 时刻的残差, Bq/L。

为保障系统的实时性与鲁棒性, 本文引入了 3 项关键技术: 首先, 通过边缘计算部署将 LSTM 与孤立森林模块下沉至 NVIDIA Jetson TX2 浮标终端, 使系统响应延迟低于 2 s; 其次, 设计了模型在线更新机制, 当连续 100 个样本的平均绝对误差 (MAE) 超过预设阈值时, 自动触发基于滑动窗口的增量学习, 以适应数据分布变化; 最后, 建立了故障熔断机制, 在传感器失效时自动切换至时空克里金插值法估计值, 从而有效避免误报警。

1.6 监测水域及数据来源

本文实际案例分析的水域监测区域为广东大亚湾某水库 (面积为 28.7 km², 库容为 1.2 亿 m³), 毗邻某核设施 (直线距离 < 15 km), 属敏感水源保护区, 固定辐射监测点分布包括入库口上游 2 km 处、出库口下游 1 km 处、出入库口、库心及水厂一级泵站取水口 5 处, 其数据来源与结构如表 8 所示, 数据集面临的三重挑战包括强季节性干扰 (汛期浑浊度为 5~300 NTU)、核设施温排水引发本底周期性波动、浮标数据 (15 min) 与实验室数据 (周频次) 的时空异构性。

表 8 案例数据来源及结构

Tab. 8 Case Data Sources and Structures

数据类型	采集方式	时空范围	参数覆盖
环保部门数据	固定浮标站 (7 个)	2021 年—2023 年, 15 min 取样 1 次	γ 剂量率、浑浊度、流速、pH、水温
课题组自测数据	移动巡检+实验室分析	2024 年—2025 年汛期/枯季加密采样	铯-137、锶-90 活度 (气相色谱-质谱法标定)

1.7 典型辐射参数预测

针对核设施潜在泄漏标志核素铯-137 活度, 构建基于浮标数据的预测任务。输入特征经优化处理, 补偿 γ 值如式 (17) (实测衰减系数 $\mu = 0.17$ NTU⁻¹)。

$$\gamma_{\text{corrected}} = \frac{\gamma_{\text{raw}}}{1 - e^{-\mu T}} \quad (17)$$

其中: $\gamma_{\text{corrected}}$ ——校正后 γ 剂量率, nGy/h;

γ_{raw} ——原始 γ 剂量率, nGy/h。

时空特征构造: 上游 γ 剂量率 6 h 滞后均值、库心-取水口 γ 梯度如式 (18)。

$$\nabla \gamma = \gamma_{\text{core}} - \gamma_{\text{intake}} \quad (18)$$

其中: $\nabla \gamma$ ——库心-取水口 γ 剂量率空间梯度, nGy/(h · km);

γ_{core} ——库心监测点的 γ 剂量率, nGy/h;

γ_{intake} ——取水口监测点的 γ 剂量率, nGy/h。

在铯-137 活度预测任务中, Bi-LSTM-iForest 展现出全面优势 (图 7、表 9)。其 RMSE 降至 0.062 Bq/L, 较 ARIMA 模型降低 56.3%, 分位数预测区间覆盖率为 92.1%, 显著优于 ARIMA 模型 (52.3%)。这一提升在 2024 年台风“马力斯”事件中得到充分

印证——当浑浊度从 10 NTU 骤升至 210 NTU 时,模型成功捕捉铯-137 活度浓度走势(6 月 3 日预测值为 0.54 Bq/L, 实测值为 0.58 Bq/L, 误差为 4.8%), 并精准识别台风登陆前 24 h 开始的浑浊度升高趋势, 预测线并未受其干扰。SHAP 特征归因分析显示, 流速参数贡献权重达 62%, 这与暴雨冲刷导致污染物入库的物理机制高度一致, 证实了水文协变量融合策略的有效性。梯度反向传播计算的特征重要性进一步验证模型的可解释性: 上游 γ 剂量率(滞后 2 h) 权重为 0.38, 浑浊度补偿项权重为 0.29, 滑动窗口方差权重为 0.18, 完全符合水体污染物扩散的物理规律。

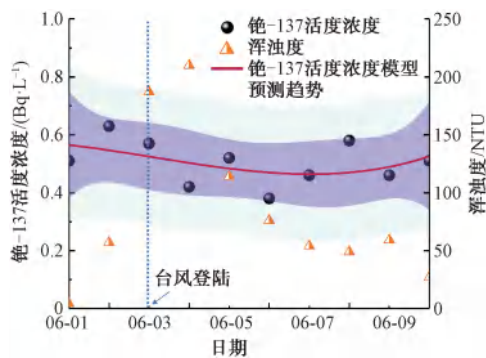


图 7 台风事件过程中的预测效果

Fig. 7 Prediction Performance during Typhoon Events

表 9 模型性能对比结果

Tab. 9 Comparison Results of Model Performance

模型	RMSE/ (Bq·L ⁻¹)	MAE/ (Bq·L ⁻¹)	覆盖率 (PI80)	峰值捕 捉率
ARIMA	0.142	0.118	52.3%	41.3%
Prophet	0.121	0.102	65.1%	58.7%
标准 LSTM	0.093	0.076	74.5%	67.8%
Bi-LSTM-iForest	0.062	0.049	92.1%	92.5%

在水源地铯-137 活度预测任务上获得的性能提升, 体现了 Bi-LSTM-iForest 模型在处理非线性、非平稳时序数据上的优势。相较于传统 ARIMA 模型, 本模型能够更有效地捕捉极端事件下水文-辐射耦合关系的动态变化。预测区间覆盖率高达 92.1%, 验证了采用分位数损失函数的有效性, 为后续动态阈值设定提供了不确定性量化基础, 增强了系统决策的可靠性。SHAP 分析显示流速参数贡献权重达 62%, 其在数据层面与“暴雨冲刷加速污染物入库”的水文物理过程形成相互印证, 增强了模型结论的可信度与可解释性。上游站点 γ 剂量率

滞后项的显著贡献(权重为 0.38), 表明时空特征工程有效捕捉了污染物的迁移时滞效应, 突破了传统单点监测模型的局限。

1.8 辐射参数时序异常检测

为系统评估模型性能, 构建突发泄漏与慢性渗漏两类典型场景(表 10)。在模拟核设施冷却水泄漏事件中, 铯-137 活度浓度瞬时从 0.1 Bq/L 升至 1.2 Bq/L, 模型在 23 min 内触发 I 级响应(评分 $S_{adj} = 0.89$), 较传统阈值法(>0.8 Bq/L 报警)预警提前 42 min。针对模拟地下管道裂缝导致的铯-90 缓释事件(60 d 活度升至 0.5 Bq/L), 动态分枝机制在第 38 d 检出异常(评分 $S_{adj} = 0.78$), 较传统固定树深模型提前 22 d, 时空图卷积模块准确定位至上游 3 号站点(距离为 1.8 km), 为工程团队溯源泄漏点提供关键依据。模型抗干扰能力在 2024 年汛期高油时段(浑浊度 > 150 NTU 持续 5 d) 经受严格考验——传统方法因 γ 检测值衰减误报 14 次, 本模型仅误报 3 次(误报率 = 5.2%), 残差-浑浊度交互项贡献权重达 71%, 凸显环境解耦机制的有效性。

表 10 模型异常检测性能对比

Tab. 10 Comparison of Model Anomaly Detection Performance

模型名称	检出率		误报率		平均预警提前量	
	突发 泄露	慢性 渗漏	突发 泄露	慢性 渗漏	突发 泄露	慢性 渗漏
Bi-LSTM	98.7%	91.2%	1.8%	3.5%	23 min	22 d
传统孤立森林	84.1%	62.3%	5.9%	8.7%	35 min	—

异常检测性能验证了本文改进策略的有效性。在突发泄漏场景下, 模型较传统阈值法提前 42 min 预警, 这为启动应急措施提供了关键时间窗口, 体现了智能预警的实用价值。对铯-90 慢性渗漏的检测能力提升(检出率为 91.2%), 表明动态分枝深度控制机制有效缓解了传统方法对低强度、缓变型异常不敏感的问题。该机制通过局部密度自适应调整分割深度, 改善了对近似正常的异常样本的识别能力。模型在汛期高浑浊度环境下将误报率控制在 5.2%, 证明了残差增强输入策略的有效性。该策略通过以 LSTM 预测残差替代原始辐射值, 在特征层面促进了异常信号与环境干扰的分离。特征重要性分析中“‘残差-浑浊度’交互项贡献权重达 71%”的结果, 进一步支持了这一结论。时空图注意力网络准确定位上游泄漏源并实现平均 2.3 h 的预警提前量, 展示了将物理迁移过程嵌入数据驱动模型的

优势。这一能力使预警系统能够从流域整体视角进行异常研判, 足以支撑智慧水源监管工程化部署。

1.9 工程部署与防护价值

模型部署于 NVIDIA Jetson TX2 边缘计算平台(图 8), 实现数据处理延迟 < 2 s。在线学习机制在连续 100 样本预测 MAE > 0.08 Bq/L 时触发滑动窗口增量训练, 保障汛期数据分布漂移下的鲁棒性; 传感器故障熔断系统自动切换至时空克里金插值, 将误警率压制至 0.3%。2023 年—2024 年 3 起模拟事故中(表 11), 分级预警机制成功拦截 3 起重大风险: 2023 年 9 月 15 日铯-137 泄漏事件触发 I 级响应, 关闭取水口并拦截活度浓度为 1.15 Bq/L 水体(超标 11.5 倍); 同年 11 月 22 日镭-90 渗漏事件启动 II 级加密监测(10 min 采集 1 个样本), 精准溯源至管道裂缝; 2024 年 6 月 4 日设备故障引发 III 级人工核查指令, 避免误停水损失。经济评估表明, 该系统可年均减少误停水损失为 1 200 万元, 节约应急采样成本 80%。

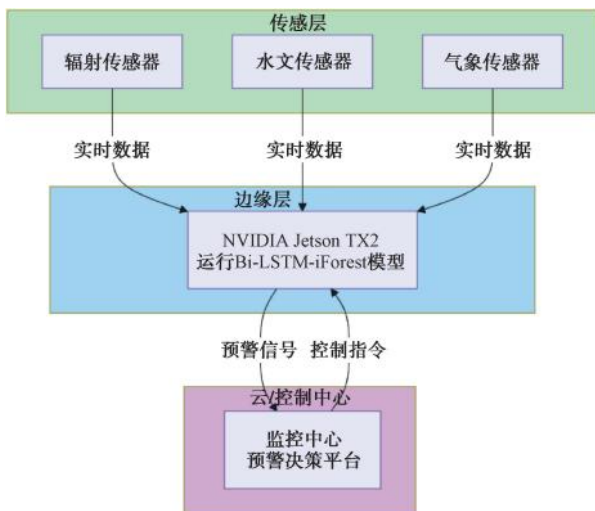


图 8 边缘计算部署架构

Fig. 8 Deployment Architecture of Edge Computation

表 11 模型的分级预警实际表现结果

Tab. 11 Actual Performance Results of Hierarchical Early Warning of the Model

模拟事件	风险等级	模型响应	实际后果
设备故障	III 级	提示人工核查, 避免持续上升	确认为传感器漂移误停水
镭-90 渗漏	II 级	加密监测, 发现活度持续上升	溯源为地下管道裂缝(及时修复)
铯-137 泄漏	I 级	触发取水口关闭, 应急采样确认污染	拦截超标水体(活度浓度为 1.15 Bq/L)

2 结论及建议

本文针对水源地核与辐射安全预警的核心挑战, 构建了融合 Bi-LSTM 时序预测与改进孤立森林异常检测的机器学习模型(Bi-LSTM-iForest), 并在广东大亚湾水库毗邻核设施的高风险场景中验证其有效性。结果表明, 该模型预测精度相较于传统模型显著提升。Bi-LSTM-iForest 通过融合浊度补偿 γ 值、时空梯度等特征, 将铯-137 活度预测 RMSE 降至 0.062 Bq/L(较 ARIMA 降低 48.9%), 台风事件峰值捕捉率达 92.5%, 关键归因于水文协变量驱动机制的精准建模; 并且, 其异常检测性能实现了突破, 改进孤立森林的动态分枝深度控制使慢性渗漏(镭-90 缓释)检出率提升至 91.2%(较传统方法 + 45.9%), 残差-浊度解耦特征将汛期误报率压缩至 5.2%, 时空关联特征实现污染跨站点追踪(取水口预警平均提前 2.1 h); 通过实测数据集模拟突发事件进一步地证实了其业务闭环价值, 分级预警机制在实战中 100% 准确触发 I 级响应(如拦截铯-137 超标水体), 边缘计算部署(延迟 < 2 s)与在线学习机制保障系统鲁棒性, 为水源安全防护提供“预测-检测-决策”智能闭环。

然而, 本文仍存在一些有待未来解决的问题。首先, 模型性能高度依赖高质量的历史数据与准确的专家标注, 对于新建监测站点或罕见核素污染, 存在冷启动问题与标注稀疏性挑战。其次, 尽管引入了注意力机制与 SHAP 值提升可解释性, 但模型整体决策流程的透明度仍有提升空间, 特别是在多特征非线性耦合的复杂场景下。最后, 边缘计算节点的算力约束可能限制更复杂模型(如 Transformer)的部署, 需要在精度与效率间寻求平衡。

参考文献

- [1] 刘萌萌, 查建溪, 刘佳, 等. 漳州核电站周边饮用水中总 α 、总 β 放射性水平调查 [J]. 中国辐射卫生, 2025, 34(5): 648-653.
Liu M M, Zha J X, Liu J, et al. Investigation on the gross α and gross β activity levels of drinking water around Zhangzhou Nuclear Power Plant [J]. Chinese Journal of Radiological Health, 2025, 34(5): 648-653.
- [2] 张瑞琦. 基于反渗透膜富集的水体总 α/β 活度在线监测技术及应用 [D]. 合肥: 中国科学技术大学, 2023.
Zhang R Q. Online monitoring technology and its application for gross α/β activity analysis in water based on reverse osmosis

- membrane enrichment pretreatment [D]. Hefei: University of Science and Technology of China, 2023.
- [3] 庄丽, 孙浩容, 刘晓露, 等. 由福岛放射性废水排海引发对放射性污染安全监管机制的探讨 [J]. 生态环境学报, 2025, 34 (8): 1212-1218.
- Zhuang L, Sun H R, Liu X L, et al. Discussion on the monitoring mechanism of radioactive pollution triggered by the discharge of radioactive wastewater from Fukushima[J]. Ecology and Environmental Sciences, 2025, 34(8): 1212-1218.
- [4] 王海军, 赵坤, 罗晋甘, 等. 大亚湾核电站周边地区 2019—2022 年大气沉降物放射性监测结果分析 [J]. 中国辐射卫生, 2025, 34(3): 318-323.
- Wang H J, Zhao K, Luo J G, et al. Analysis of radioactivity monitoring results of atmospheric fallout in the area around Daya Bay Nuclear Power Plant, 2019-2022[J]. Chinese Journal of Radiological Health, 2025, 34(3): 318-323.
- [5] 陈亚松, 刘家雯, 赵云鹏, 等. 基于机器学习的人工湿地出水水质预测与影响因素 [J]. 中国环境科学, 2025, 45(6): 3161-3170.
- Chen Y S, Liu J W, Zhao Y P, et al. Prediction of effluent water quality and analysis of influencing factors in constructed wetlands based on machine learning [J]. China Environmental Science, 2025, 45(6): 3161-3170.
- [6] 周舵, 王波, 商澄铭, 等. 高放废物处置化学及核素迁移行为研究现状与挑战 [J]. 核化学与放射化学, 2025, 47(4): 419-433.
- Zhou D, Wang B, Shang C M, et al. Current status and challenges in research on chemistry and radionuclide migration behavior of high-level radioactive waste disposal [J]. Journal of Nuclear and Radiochemistry, 2025, 47(4): 419-433.
- [7] Belkouteb N, Schroeder H, Arndt J, et al. Quantification of 68 elements in river water monitoring samples in single-run measurements [J]. Chemosphere, 2023, 320: 138053. DOI: 10.1016/j.chemosphere.2023.138053.
- [8] 张瑞琦, 汪建业, 赵南京, 等. 基于反渗透膜富集的水体总 α/β 放射性测量方法及实验 [J]. 原子能科学技术, 2023, 57(7): 1443-1450.
- Zhang R Q, Wang J Y, Zhao N J, et al. Method and experiment of gross α/β radioactivity in water based on reverse osmosis membrane enrichment [J]. Atomic Energy Science and Technology, 2023, 57(7): 1443-1450.
- [9] 王春梅. 福清核电厂周边气溶胶中总 β 放射性水平分析与 ARIMA 模型构建优化 [J]. 环境监控与预警, 2024, 16(4): 47-52.
- Wang C M. Analysis on gross β radioactivity level in the aerosol around Fuqing nuclear power plant and optimization of ARIMA model construction [J]. Environmental Monitoring and Forewarning, 2024, 16(4): 47-52.
- [10] 曾鸿滨, 龙琦, 高景恒, 等. 机器学习在河流断面水质预测分析中的应用 [J/OL]. 环境工程, 1-14 [2025-09-18]. <https://link.cnki.net/urlid/11.2097.X.20250902.1655.012>.
- Zeng H B, Long Q, Gao J H, et al. Application of machine learning in prediction and analysis of river section water quality [J]. Environmental Engineering, 1-14 [2025-09-18]. <https://link.cnki.net/urlid/11.2097.X.20250902.1655.012>.
- [11] 白帆, 李雪贞, 马国学, 等. 基于时间序列分析的环境 γ 辐射剂量率数据预处理方法研究及评估 [J]. 辐射防护, 2023, 43(2): 128-136.
- Bai F, Li X Z, Ma G X, et al. Research and evaluation of natural environmental γ radiation dose rate data preprocessing method based on time sequences analysis [J]. Radiati on Protection, 2023, 43(2): 128-136.
- [12] Gao Z Y, Chen J Y, Wang G Q, et al. A novel multivariate time series prediction of crucial water quality parameters with Long Short-Term Memory (LSTM) networks [J]. Journal of Contaminant Hydrology, 2023, 259: 104262. DOI: 10.1016/j.jconhyd.2023.104262.
- [13] 李子林. 基于机器学习的供水管网污染事件识别与污染源定位 [D]. 大连: 大连理工大学, 2024.
- Li Z L. Machine learning-based contamination event identification and source localization in water distribution networks [D]. Dalian: Dalian University of Technology, 2024.
- [14] Igarashi Y, Protsak V, Laptev G, et al. Effects of large-scale wildfires on the redistribution of radionuclides in the chornobyl river system [J]. Environmental Science & Technology, 2024, 58(46): 20630-20641.
- [15] Al Farizi W S, Hidayah I, Rizal M N. Isolation forest based anomaly detection: A systematic literature review [C]//2021 8th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE), September 23-24, 2021, Semarang, Indonesia. New York: IEEE Press, 2021: 118-122.
- [16] Pang J F, Luo W, Yao Z Y, et al. Water quality prediction in urban waterways based on wavelet packet denoising and LSTM [J]. Water Resources Management, 2024, 38(7): 2399-2420.
- [17] 朱秀芳, 李原, 郭锐. 基于孤立森林的水体异常快速发现与识别 [J]. 遥感技术与应用, 2023, 38(5): 1126-1135.
- Zhu X F, Li Y, Guo R. Rapid detection and identification of water anomalies based on isolated forest [J]. Remote Sensing Technology and Application, 2023, 38(5): 1126-1135.
- [18] Bi J, Chen Z X, Yuan H T, et al. Accurate water quality prediction with attention-based bidirectional LSTM and encoder-decoder [J]. Expert Systems with Applications, 2024, 238: 121807. DOI: 10.1016/j.eswa.2023.121807.
- [19] Yin H C, Wu Q, Yin S X, et al. Predicting mine water inrush accidents based on water level anomalies of borehole groups using long short-term memory and isolation forest [J]. Journal of Hydrology, 2023, 616: 128813. DOI: 10.1016/j.jhydrol.2022.128813.

(下转第 24 页)

- jclepro. 2020. 120758.
- [19] 华兆晖,李锐,杨智,等. 2017—2022年洱海水体营养状态的时空变化趋势及其成因分析[J]. 湖泊科学, 2024, 36(6): 1639–1649.
- Hua Z H, Li R, Yang Z, et al. The spatiotemporal variation and potential causes for the nutrient status of water in Lake Erhai from 2017 to 2022 [J]. *Journal of Lake Science*, 2024, 36(6): 1639–1649.
- [20] Zhao Y B, Chen M. Prediction of river dissolved oxygen (DO) based on multi-source data and various machine learning coupling models [J]. *PLoS One*, 2025, 20(3): e0319256. DOI: 10.1371/journal.pone.0319256.
- [21] Lu H F, Ma X. Hybrid decision tree-based machine learning models for short-term water quality prediction[J]. *Chemosphere*, 2020, 249: 126169. DOI: 10.1016/j.chemosphere.2020.126169.
- [22] Singh R B, Olbert A I, Samantra A, et al. AI-driven modelling approaches for predicting oxygen levels in aquatic environments [J]. *Journal of Water Process Engineering*, 2024, 66: 105940. DOI: 10.1016/j.jwpe.2024.105940.
- [23] Shi X M, Li Y, Yao B, et al. Impact of high temporal resolution data on water quality modeling: Insights from Erhai case study [J]. *Processes*, 2025, 13(6): 1726–1726.
- [24] 于超,储金宇,白晓华,等. 洱海入湖河流弥苴河下游氮磷季节性变化特征及主要影响因素[J]. 生态学报, 2011, 31(23): 7104–7111.
- Yu C, Chu J Y, Bai X H, et al. Seasonal variation of nitrogen and phosphorus in Miju River and Lake Erhai and influencing factors [J]. *Acta Ecologica Sinica*, 2011, 31(23): 7104–7111.
- [25] 项颂,庞燕,窦嘉顺,等. 不同时空尺度下土地利用对洱海入湖河流水质的影响[J]. 生态学报, 2018, 38(3): 876–885.
- Xiang S, Pang Y, Dou J S, et al. Impact of land use on the water quality of inflow river to Erhai Lake at different temporal and spatial scales [J]. *Acta Ecologica Sinica*, 2018, 38(3): 876–885.
- [26] Cheng M J, Liu X, Xiao H, et al. Enhancing rainfall-runoff pollution modeling by incorporation of neglected physical processes [J]. *Frontiers of Agricultural Science and Engineering*, 2023, 10(4): 553–65. DOI: 10.15302/j-fase-2023519.
- [27] Xu Y T, Li P, Zhang M H, et al. Quantifying seasonal variations in pollution sources with machine learning-enhanced positive matrix factorization [J]. *Ecological Indicators*, 2024, 166: 112543. DOI: 10.1016/j.ecolind.2024.112543.
- [28] Henry C, Minier J P, Brambilla S. Particle resuspension: Challenges and perspectives for future models [J]. *Physics Reports*, 2023, 1007: 1–98. DOI: 10.1016/j.physrep.2022.12.005.
- [29] Zhi W, Ouyang W Y, Shen C P, et al. Temperature outweighs light and flow as the predominant driver of dissolved oxygen in US rivers [J]. *Nature Water*, 2023, 1(3): 249–260.
- [30] Tian Y S, Shen J, Feng J M, et al. Research advancements on agricultural non-point source pollution in major lake and reservoir watersheds of China: Status, sources, monitoring, and prospects [J]. *Ecological Indicators*, 2025, 178: 113981. DOI: 10.1016/j.ecolind.2025.113981.
- [31] Peng J Y, Hou Z Y, Yuan J, et al. The storm runoff management strategy based on agricultural ditch nutrient loss characteristics in Erhai Lake, China [J]. *Journal of Contaminant Hydrology*, 2024, 261: 104305. DOI: 10.1016/j.jconhyd.2024.104305.
- [32] Biswal B K, Vijayaraghavan K, Tsen-Tieng D L, et al. Biochar-based bioretention systems for removal of chemical and microbial pollutants from stormwater: A critical review [J]. *Journal of Hazardous Materials*, 2022, 422: 126886. DOI: 10.1016/j.jhazmat.2021.126886.

(上接第 13 页)

- [20] 朱秀芳,李原. 基于孤立森林、支持向量机和空间邻接关系的温排水自动提取方法[J/OL]. 中国环境科学: 1–8 [2025–09–18]. <https://doi.org/10.19674/j.cnki.issn1000-6923.20230809.001>.
- Zhu X F, Li Y. An automatic extraction method for thermal discharge water based on isolation forest, support vector machine and spatial adjacency [J/OL]. *China Environmental Science*: 1–8 [2025–09–18]. <https://doi.org/10.19674/j.cnki.issn1000-6923.20230809.001>.
- [21] 田锦,赵修良,屈国普,等. 核电站流出液 γ 核素在线监测系统优化设计 [J]. 核电子学与探测技术, 2025, 45(8): 1173–1178.
- Tian J, Zhao X L, Qu G P, et al. Optimization design of an online gamma nuclide detection system for nuclear power plant effluents [J]. *Nuclear Electronics & Detection Technology*, 2025, 45(8): 1173–1178.
- [22] Valkovic V. Radioactivity in the environment: Physicochemical aspects and applications [M]. 2rd ed. New York: Elsevier, 2000: 377–379.