

采用堆叠长短期记忆神经网络的水质连续预测方法

张建奇^{1,2}, 冯乐源¹, 李东鹤¹, 杨清宇^{1,3}

(1. 西安交通大学自动化科学与工程学院, 710049, 西安; 2. 西安航天自动化股份有限公司, 710065, 西安; 3. 西安交通大学精密微纳制造技术全国重点实验室, 710049, 西安)

摘要: 针对水环境监测中的水质参数异常、预测精度低等问题,提出了一种基于堆叠长短期记忆神经网络(SLSTM)的水质参数预测模型,以解决时序数据不完整带来的挑战。首先,分析了缺失或异常的水质数据时序特征,并基于堆叠长短期记忆网络设计了水质预测的深度神经网络模型;其次,采用逐点预测和多步预测方法对所提模型进行对比实验验证;最后,为了量化模型的预测性能,引入平均绝对百分比误差(MAPE)和均方根误差(RMSE)两类指标,评估 SLSTM 模型相对于支持向量回归(SVR)和自回归综合移动平均(ARIMA)模型的优越性。实验结果表明,在短期(24 h)和长期(48 h)水质余氯预测中,SLSTM 的预测精度显著高于其他两类模型;在多步预测中,SLSTM 的 MAPE 至少比 SVR 降低了 9.15%;逐点预测中,SLSTM 的 RMSE 至少比 SVR 降低了 31.25%。此外,相较于 ARIMA 模型,SLSTM 能够更有效地捕捉水质数据的非线性变化趋势,提升预测稳定性。研究不仅验证了 SLSTM 在水质参数预测中的有效性,还为水环境监测领域提供了新的视角和工具。

关键词: 余氯预测;水质参数预测;数据时序;长短期记忆神经网络

中图分类号: TP31 **文献标志码:** A

DOI: 10.7652/xjtuxb202506010 **文章编号:** 0253-987X(2025)06-0093-10

Continuous Water Quality Prediction Method Based on Stacked Long Short-Term Memory Neural Networks

ZHANG Jianqi^{1,2}, FENG Leyuan¹, LI Donghe¹, YANG Qingyu^{1,3}

(1. School of Automation Science and Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. Xi'an Aerospace Automation Co., Ltd., Xi'an 710065, China; 3. State Key Laboratory For Manufacturing System Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Aiming at the issues of abnormal water quality parameters and low prediction accuracy in water environment monitoring, this paper proposes a water quality parameter prediction model based on stacked long short-term memory neural network (SLSTM) to tackle the challenge of incomplete time series data. First, the timing characteristics of missing or abnormal water quality data were analyzed, and a deep neural network model for water quality prediction was designed based on stacked long short-term memory networks. Second, point-by-point prediction and multistep prediction methods were used to validate the proposed model in comparative experiments.

收稿日期: 2024-12-26。 作者简介: 张建奇(1975—),男,高级工程师;杨清宇(通信作者),男,教授,博士生导师。

基金项目: 国家自然科学基金资助项目(62373297)。

网络出版时间: 2025-02-25

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20250225.1135.006>

Lastly, in order to quantify the prediction performance of the model, two types of metrics were introduced, namely, the mean absolute percentage error (MAPE) and the root-mean-square error (RMSE) to assess the superiority of the SLSTM model over the support vector regression (SVR) and autoregressive integrated moving average (ARIMA) models. The experimental results showed that the prediction accuracy of SLSTM was significantly higher than that of the other two models in short-term (24 h) and long-term (48 h) chlorine residual prediction: the MAPE of SLSTM was at least 9.15% lower than that of SVR for multistep prediction, and the RMSE of SLSTM was at least 31.25% lower than that of SVR for point-by-point prediction. In addition, compared with the ARIMA model, SLSTM can capture the nonlinear trend of water quality data more effectively and improve the prediction stability. This study not only verifies the effectiveness of SLSTM in water quality parameter prediction, but also provides new perspectives and tools for the field of water environment monitoring.

Keywords: chlorine residual prediction; water quality prediction; chronological data; long short-term memory

随着城市人口规模的快速扩大,城市供水系统复杂性显著增加。供水侧作为源头直接决定了城市供水安全,受到降雨、温度、地质条件等自然因素和人类活动的影响,水质呈现出高度动态性和不可控性^[1]。管网侧作为城市供水系统的重要组成部分,规模庞大且分布复杂,更容易受到污染物的入侵。污染物的入侵时间、地点、性质和浓度通常具有较强的不确定性和扩散性,严重威胁供水安全与居民健康^[2]。因此,在供水系统的关键环节进行水质监测,并准确预测反映水中杂质、细菌及化学物质(如pH、浑浊度和余氯等^[3])含量的关键指标,有助于指导企业优化水处理工艺、确保水质稳定达标,为政府制定科学的监管政策、加强水质监测评估提供依据。智能供水系统依托智慧城市网络,通过新一代信息技术与水务技术的深度融合,实现水务业务系统的智能控制、数据资源的精准管理^[4],为城市水质持续预测提供了实时数据与算力算法支撑。水质预测方法大致可分为基于模型的预测和基于数据的预测。

基于模型的预测方法是通过构建水质模型,利用实测数据确定模型参数,从而完成对指定地点水质的预测分析。在河流水质的模拟和预测中,文献[5]将Dobbins方程中的流速项作为随机变量,提出了随机水质微分方程,该方程真实地反映了水质的变化,是外部水文因素随机变化的不确定性与水质本身内在变化确定性的统一。

基于数据的水质预测方法依赖于水质参数的历史数据,通过学习一段时间内水质的变化趋势,能够对未来的水质状况进行有效预测,数据驱动的预测方法在水质监测与评估中展现出较强的实用性和广

泛的适用性。Najah等^[6]提出了一种基于数据融合模块的神经模糊推理系统(WDT-ANFIS)增强小波去噪技术,以准确预测月度水质参数。刘杰等^[7]采用神经网络(MLP)方法对沿海地下水硝酸盐浓度建模具有良好而广泛的适用性。Tu等^[8]提出了一种基于卷积神经网络(CNN)和门控递归神经网络(GRU)的混合水质预测模型。基于模型的预测方法难以准确捕捉水质演化的复杂规律,因其对水质变化机制的假设过于简化,未充分考虑非线性特征,影响实际应用效果;基于数据的预测方法受传统机器学习算法限制,存在泛化能力差、时间滞后等问题,导致预测精度不高。

因此,有必要设计一种新的神经网络来提高预测性能。芮栋妮等^[9]提出了长短期记忆(LSTM)网络,以缓解循环神经网络(RNN)训练过程中的梯度消失问题或梯度爆炸问题。目前LSTM网络已广泛应用于解决各种序列数据问题,包括图像字幕,自动语音识别,基因组分析和自然语言处理。LSTM将模型训练与表征学习相结合,不需要额外的知识,使得模型具有良好的泛化能力,理论上LSTM在水质预测和分析方面可以取得较好的效果^[10-12]。

然而,智能水系统中采集的水质数据可能会因意外因素而出现异常或丢失,短时间内的水质参数不表现出明显的周期性,LSTM难以学习依赖关系,而且传统逐点预测可能会造成误差累积,无法保证长期预测的准确性。针对上述问题,本文构建了一种仅依赖历史水质数据的预测模型,通过学习数据趋势实现高效预测,具有较低的信息需求和较强的泛化能力,提出基于LSTM的水质预测方法,构

建了全面的评估体系,并通过仿真实验验证了 LSTM 模型在短期水质预测中的有效性,不仅提升了预测精度,还增强了模型的稳定性和泛化能力,为水环境监测提供了更可靠的技术支持。

1 相关工作

针对智能水系统,已有研究聚焦于其适应性^[13]、系统框架^[14]和稳定性^[15]等方面。此外,智慧水系统在城市水资源管理中发挥着重要作用,基于物联网架构的智能水系统可以通过传感器和无线网络对水资源进行监控和管理^[16]。文献[17]分析了智能供水系统在城市供水中的应用,探讨了如何建设和应用智能供水系统。Yao 等^[18]使用智能水系统测量水质参数,并使用机器学习设计了水质预测系统。文献[19]提出了一种利用现有安全解决方案和设计模式的智能水管理系统安全架构。

水质预测的理论模型不断发展,包括水质模拟模型、传统数理统计预测方法、机器学习模型和混合预测模型^[20]。自从 Streeter-Phelps 水质模型建立以来,人们对各种水体进行了研究,建立了各种水质模拟模型。传统的水质预测数学方法采用回归分析技术,李如忠等^[20]比较了 10 种学习模型对水质参数数据的预测结果,得出决策树、随机森林模型的预测效果更好。Chen 等^[21]提出了一种基于偏好分类的水质预测方法,不同的水质特征采用不同的预测模型,以达到比单一模型更好的预测效果。

循环神经网络因其记忆和有效处理时间序列问题广泛应用于自然语言处理、语音和视频等领域^[22]。LSTM 作为一种改进的 RNN,解决了训练困难的问题,并取得了良好的预测性能^[23]。Yayan 等^[24]设计了一种堆叠 LSTM,仅使用恒流充电阶段收集的数据就能准确估计电池健康状态(SOH)。

2 水质预测模型理论基础

2.1 循环神经网络

循环神经网络(RNN)不同于传统的神经网络,后者通常只能将输入数据映射到目标向量,RNN 则专门用于序列学习^[25]。通过在有向循环中建立神经元之间的连接,使得 RNN 能够从历史输入中映射目标向量,RNN 可以在其内部状态中存储一些历史输入信息。对于监测任务,神经网络还可以采用反向传播算法进行时间序列训练。RNN 的展开结构如图 1 所示,图中: $\mathbf{x}$ 是一个向量,表示输入层的值; $\mathbf{s}$ 为向量,表示隐藏层的值; $\mathbf{U}$ 为输入层到隐藏层

的权值矩阵; $\mathbf{O}$ 为向量,表示输出层的值; $\mathbf{V}$ 是隐含层到输出层的权值矩阵。循环神经网络隐含层的值 $\mathbf{s}$ 不仅取决于当前输入 $\mathbf{x}$,还取决于最后一层隐含层的值 $\mathbf{s}$ 。权值矩阵 $\mathbf{W}$ 是隐藏层最后一个值作为输入的权值。网络在时刻 t 接收到输入 x_t 后,隐藏层的值为 s_t ,输出值为 o_t , s_t 的值不仅取决于输入向量 x_t ,还取决于之前的隐藏状态 s_{t-1} 。 s_t 、 o_t 的计算式为

$$s_t = A(Ux_t + Ws_{t-1}) \tag{1}$$

$$o_t = A(Vs_t) \tag{2}$$

式中: A 为激活函数,包括 ReLU 和 sigmoid 函数。




图 1 RNN 的展开结构
Fig. 1 Unfolding architecture of RNN

2.2 长短期记忆网络

为了解决传统的 RNN 无法获得长期依赖的问题,提出了 LSTM 网络^[9]。LSTM 使用一个特殊的存储单元存储信息,虽然这些存储单元的结构类似,但重复模块的结构有所不同,LSTM 的模块化结构如图 2 所示,其中包含多个相互作用的模块。




图 2 LSTM 模块化结构
Fig. 2 LSTM modular construction

与 RNN 只有一个对短期状态敏感的隐藏状态不同,LSTM 中存在另一个状态来保持长期状态,解决了 RNN 无法处理长期依赖的问题。LSTM 单元中有输入门、遗忘门和输出门 3 种类型的门,LSTM 网络通过这些门存储和更新信息,遗忘门负责从单元状态中删除信息,更新信息的过程可以通过输入门来完成,输出门负责从当前单元状态中选择有用的信息,从而为网络提供内存。LSTM 的核

心思想是在每个时间步长使用一些门来控制信息沿序列的传输,这样可以更准确地获得长期依赖关系。在时间步长 t 处,LSTM 隐藏层的输入和输出向量分别表示为 x_t, h_t , 存储单元为 c_t 。输入门信息量为

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (3)$$

式中: W 为一个变换矩阵; b 为偏差值; σ 为 sigmoid 型函数。

遗忘门是 LSTM 单元的关键部件,可以控制哪些信息可以保留在网络中,哪些信息可以被遗忘,避免了梯度反向传播时出现的梯度消失问题和梯度爆炸问题。遗忘门控制自连接单元,可以确定需要遗忘的历史信息,可以确定存储在存储单元 c_{t-1} 上的信息 f_t 对当前存储单元 c_t 的影响,即

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (5)$$

输出门控制存储单元 c_t 对输出值 h_t 的影响,决定了存储在内存单元 c_t 中的信息将输出的时间 t 的哪一部分,取值可以表示为

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (6)$$

LSTM 在时间 t 的输出 h_t 可以表示为

$$h_t = o_t \odot \tanh(c_t) \quad (7)$$

与传统 RNN 相比,LSTM 可以捕获时间序列数据中的长期依赖关系和非线性因素^[26],LSTM 在许多领域都具有优势,并得到了包括语音识别、图像识别^[27]、手写识别、基因组分析、自然语言处理^[28]等应用。

3 水系统模型与水质预测模型构建

3.1 智能供水系统模型

随着物联网技术的发展,大量城市着手建设和完善智能供水系统,实现对整个城市供水系统的监控、调度和管理。本文所提水质参数预测模型,依靠智能水系统中终端传感器采集的水质相关数据进行模型训练,训练后的模型嵌入智能水系统中,随时预测未来水质,成为智能水系统智能管理的一部分。

该系统的智能分析平台包括数据监控和统计分析,数据监控可以实现水量(瞬时入水量、瞬时出水量、累计出水量、管道压力等)和水质(pH、余氯、浑浊度、色度、电导率)的实时监控,透明、准确地掌握该地区的用水量、水质等信息。统计分析部分除了对数据监控模块采集的数据进行基础分析外,还负责包括用户用水习惯、区域用水和水费支付、水表故障等更深层次的分析。智能供水系统模型如下。

智能供水系统管网节点平衡方程为

$$\sum_{j \in i(i)} Q_{ji} = \sum_{k \in o(i)} Q_{ik} \quad (8)$$

式中: $i(i), o(i)$ 分别为流入和流出节点 i 的管道集合; Q_{ji}, Q_{ik} 分别为从节点 j 到 i 和从节点 i 到 k 的流量。

管道连续方程为

$$Q_{ij} = Q_{ji} \quad (9)$$

式中: Q_{ij}, Q_{ji} 分别为从节点 i 到节点 j 和从节点 j 到节点 i 的流量。

能量守恒方程为

$$H_i - H_j = f_{ij} \frac{L_{ij}}{D_{ij}} \frac{v_{ij}^2}{2g} \quad (10)$$

式中: H_i, H_j 分别为节点 i 和 j 的水头; f_{ij} 为摩擦系数; L_{ij} 为管道长度; D_{ij} 为管道直径; v_{ij} 为管道中的流速; g 为重力加速度。

3.2 水质预测模型评价指标

平均绝对百分比误差(MAPE)表示式为

$$E_1 = \frac{1}{n} \sum_{i=1}^n \frac{|p_i - y_i|}{y_i} \quad (11)$$

式中: p_i, y_i 分别为预测值和实际值; n 为数据量。

均方根误差(RMSE)即预测值与实际值之间的平均误差,表示式为

$$E_2 = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2} \quad (12)$$

对同一地区水源在等时间间隔内监测某些指标得到的数据,可以表示为该水源水质参数的时间序列。水质会受到地理条件、人类生产生活和当地工业化水平的影响,当前的水质水平与过去一段时间的水质水平相关。本文通过探索当前水质与过去水质之间的潜在关系,由当前和过去的水质 $[x_{t-k+1}, \dots, x_{t-2}, x_{t-1}, x_t]$ 来预测下一刻 x_{t+1} , 甚至未来 $[x_{t+1}, x_{t+2}, \dots, x_{t+n}]$ 时刻的水质。

利用一维水质时间序列生成一个 $m+n$ 维的矩阵,其中前 m 维向量作为一组训练输入,最后 n 维为其对应的输出。训练的目标是最小化输入映射和输出之间的误差。损失函数可用均方误差(MSE)表示为

$$E_3 = \frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2 \quad (13)$$

对于上述模型,使用深度神经网络的方法进行训练。通过不断调整神经网络的参数,得到一组理想的输入输出函数关系,使损失函数最小。

4 基于 LSTM 的水质预测方法

4.1 模型结构

供水点水质预测是对影响水质的参数进行预

测,参数由智能水系统监测,并以离散顺序数据的形式收集。取时间 t 前 m 次水质余氯量历史观测值 $[x_{t-k+1}, \cdots, x_{t-2}, x_{t-1}, x_t]$ 作为 LSTM 网络的输入。取时刻 t 后数据作为模型的期望输出(实际值),并与预测值进行比较。采用堆叠 LSTM 结构构建预测模型,依次构造 LSTM 层、Dropout 层、LSTM 层、LSTM 层、Dropout 层和全连接层,结构如图 3 所示。




图 3 LSTM 预测模型的结构

Fig. 3 Structure of LSTM prediction model

对于归一化的水质参数序列,不仅要分析每次输入的信息,还需分析整体的变化趋势。LSTM 层可以保留过去输入的部分信息,实现长期记忆,因此是预测模型的核心。然而,多层 LSTM 网络的叠加大大提高了训练时间,但并没有显著提高预测精度,因此模型采用 3 层 LSTM。此外,预测延迟时间 D 和神经元数量 n 是模型的关键参数。通过多次实验,选择了 10 天延迟和 80 个隐藏神经元的网络,取得了良好的效果。

由于深度学习模型较复杂,大规模训练数据对模型鲁棒性非常重要,但水质预测数据有限,因此添加 Dropout 层防止过拟合。Dropout 会随机屏蔽部分神经元,使其不影响正向传播,而在测试时恢复所有神经元输出。为此,在第 1、2 层 LSTM 之间加入一个 Dropout 层,并在全连接层前再加一个,隐藏概率分别为 0.5、0.3。全连接层将前两个 LSTM 层的输出传递给多个隐藏层,每层的计算式为

$$o_i = \sigma(W_i h_i + b_i) \tag{14}$$

式中: o_i 、 h_i 分别为全连通层的输入和输出值; W_i 、 b

为变换矩阵和偏置项。

4.2 仿真流程

采用 Python Version 3.9 中的 Keras 和 TensorFlow 构建了水质预测的深度学习神经网络模型。由于原始水质数据并不总是在 $(-1,1)$ 的范围内,模型可能无法收敛。因此,需要在将数据输入神经网络之前对其进行归一化处理,而不是直接使用原始数据。剔除异常数据后,将剩余数据按等比例映射到区间 $(0,1)$ 。在预测过程结束时,再将预测数据恢复到实际水质数据。数据归一化计算式为

$$x_{ii} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \tag{15}$$

式中: x_i 为原始序列的第 i 个值; x_{ii} 为归一化序列的第 i 个值; $x_{\max}$ 、 $x_{\min}$ 分别为原始水质数据的最大值和最小值。




图 4 基于 LSTM 神经网络的水质预测流程

Fig. 4 Water quality prediction process based on LSTM neural network

本文使用两种方法预测未来的数据,其中一种是直接使用连续的多矩数据向量作为网络的输出,每次预测产生一段时间的预测值,称为多步预测;另一种是只对下一时刻的数据进行预测的模型,并将该数据加入到测试集中,然后利用新的测试集再次给出下一时刻的预测,这种在一段时间内逐点进行预测的方法被称为逐点预测。多步预测方法需要 $[x_{t-k+1}, \cdots, x_{t-1}, x_t]$ 作为模型输入,时刻 t 后的序列 $[x_{t+1}, x_{t+2}, \cdots, x_{t+m}]$ 作为模型的输出,即该实验过程可同时实现对 m 个节点水质参数的预测。对于逐点预测方法,同样使用 $[x_{t-k+1}, \cdots, x_{t-1}, x_t]$ 作为模型的输入,但只使用时刻 $t+1$ 的数据 x_{t+1} 作为模型的输出。在此测试过程中使用滑动窗口来预测时间

$t+1$ 的数据,在预测数据 x_{t+1} 后,使用 $[x_{t-t+1}, \cdots, x_t, x_{t+1}]$ 作为模型的新输入得到数据 x_{t+2} ,以此类推 m 次迭代得到水质参数 $x_{t+1}, x_{t+2}, \cdots, x_{t+m}$ 。多步预测方法通过对 40 h 内 20 组数据的训练,给出了未来 24 h 的 12 组数据预测。

4.3 模型训练和参数配置

本文将迭代次数设置为 400,并使用迷你梯度下降(MBGD)方法对训练数据集进行分组,然后利用 MSE 建立损失函数。LSTM 误差项的反向传播包括沿时间的反向传播,即从当前时间 t 开始计算每次的误差项,并将误差项传播到上层。根据相应的误差项,计算各权值的梯度,并采用梯度下降法对参数进行迭代。采用自适应矩估计(Adam)作为优化算法对模型进行调整,更新权值和偏差参数,在实际应用中取得了良好的效果。

5 仿真实验

5.1 数据预处理

数据集来源于昌吉市西外环以北某供水点 2021 年 5 月 1 日至 2021 年 6 月 30 日的水质监测数据。分别采集 pH、浊度、余氯量 3 项水质指标。两个月内 pH 和浊度变化不明显,变化趋势平稳,因此本文选择余氯量代表水质参数,预测一段时间后的水质。余氯的作用是保证连续杀菌,防止水被再污染,但如果余氯量超标,可能会加重水中酚类等有机物产生的味道和气味,并可能产生对健康有害的有机氯化物质。由于传感器故障、网络故障或偶发事件等原因,采集到的数据存在异常,将收集到的数据以 2 h 为单位取平均值,表示这 2 h 内的余氯量,得到 736 组数据,如图 5 所示。




图 5 1 440 h 余氯量变化趋势


Fig. 5 Trend in chlorine residual at 1 440 hours

用过去 m 次的用水量来预测下一次的用水量,在逐点预测时,根据该模型将标准化数据生成 $k+1$ 维矩阵。将前 k 维用作训练输入,第 $k+1$ 维用作训练输出,在进行多步预测时,根据该模型将标准化数

据生成成为 $k+n$ 维矩阵。前 k 维用作训练输入,后 n 维用作训练输出,前 2/3 的数据作为训练集用于训练 LSTM 模型,后 1/3 的数据作为测试集用于测试模型的性能。

5.2 水质预测结果

为全面分析模型的预测性能,采用多步预测和逐点预测两种方法将预测结果与实际监测数据进行对比分析,实验结果如图 6、7 所示。可以看出,多步预测和逐点预测的预测值与实际监测值在测试数据集中拟合效果较高,整体预测精度较高,这表明基于 LSTM 神经网络的预测模型在水质参数预测任务中具有较强的适用性和有效性。实验结果揭示了 LSTM 和深度学习在水质预测领域的潜力,为制定水源保护政策和具体措施提供可靠的方法。在训练集和测试集预测曲线的拟合中,逐点预测的拟合精度高于多步预测,这主要是由于多步预测的输出是一个 12 维向量,即同时预测未来 24 h 的数据,而在绘制预测曲线时,仅选取该向量的第一维数据进行拟合,不能完全代表多步预测的短期预测结果,但可以解释逐点预测在未来 2 h 内的水质预测效果优于多步预测。




(a) 训练集拟合曲线

(b) 测试集拟合曲线

图 6 多步预测在训练集中的拟合曲线与测试集中的预测曲线

Fig. 6 Multi-step prediction of the fitted curves in the training set versus the predicted curves in the test set



(a) 训练集拟合曲线

(b) 测试集预测曲线

图 7 逐点预测在训练集中的拟合曲线与测试集中的预测曲线

Fig. 7 Point-by-point prediction of the fitted curves in the training set versus the prediction curves in the test set

对于模型验证,处理后的数据集包含 730 个关于水中余氯量的时刻数据,本文选择最后 1/3 作为测试集。多步预测法和逐点预测法未来 24 h 内的预测结果图 8、9 所示。




图 8 随机时间多步预测法余氯量变化曲线

Fig. 8 Change curve of residual chlorine amount by random time multistep prediction method




图 9 随机时间逐点预测法余氯量预测变化曲线

Fig. 9 Random time point-by-point prediction method of residual chlorine amount prediction change curve

为了清晰地对比预测效果,在测试集中随机选取 4 个时间点,并在这些时间点显示未来 24 h 水中余氯的预测模型结果。对于多步预测方法,模型的输出是一个 12 维向量,因为每个节点代表 2 h。将预测结果与实际水质数据进行了比较,逐点预测法以滑动窗口的形式迭代 12 次,得到 12 个节点的水质数据进行比较。结果表明,两种方法均能较好地预测未来 24 h 的余氯。两种方法对任意节点的 MAPE 均小于 10%,各节点 RMSE 平均值均小于 0.01 mg/L,逐点预测方法的预测效果略好于多步预测。

5.3 与其他时间序列预测模型的比较

为了验证基于 LSTM 深度神经网络的水质预测模型的预期结果,将该模型与经典的时间序列预测模型支持向量回归(SVR)进行了比较。本文选择 RBF 作为非线性核函数,将参数和惩罚因子 C 分

别设置为 0.01 和 100。在训练集和测试集中对模型进行了评估,结果如图 10 所示。




图 10 SVR 模型训练集拟合曲线与测试集预测曲线

Fig. 10 Fitted curves in the training set and predicted curves in the test set of SVR model

SVR 是一种对未来数据逐点预测的方法,可以直接与基于 LSTM 神经网络模型的逐点预测方法进行比较。对比图 10、图 7 可以看出,两种方法在测试数据集上都有很好的预测性能。基于 SVR 模型的预测曲线也能很好地拟合实际观测数据,实现了对未来水质的预测,但预测精度与基于 LSTM 神经网络的预测精度仍有显著差异,SVR 对 24、48 h 内随机时刻的预测结果变化曲线如图 11、12 所示。

本文比较了所提模型与自回归综合移动平均模型(ARIMA)的预测效果。ARIMA 是一种常用的时间序列预测分析方法,其基本原理是将非平稳时间序列转化为平稳时间序列,然后将因变量仅对其滞后值和随机误差项的现值和滞后值回归到所建立的模型中。将预处理后的水质参数时间序列数据在 ARIMA 模型上进行训练,然后在相应的时间点进行检验,ARIMA 在 24 h 内随机时刻预测结果如图 13 所示。




图 11 SVR 模型随机时刻余氯量预测曲线

Fig. 11 SVR model random moment chlorine residual prediction curve





图 12 SVR 模型随机时刻余氯量预测曲线(48 h)

Fig. 12 SVR model random moment chlorine residual prediction curve (48 h)





图 13 ARIMA 模型随机时刻余氯量预测曲线

Fig. 13 ARIMA model prediction curve of residual chlorine amount at random moments

本文所提模型对 48 h 内随机时刻多步预测和逐点预测的结果变化曲线如图 14、15 所示。由图 11~15 对比分析可知,在 24 h 水质余氯预测中,基于 LSTM 模型的两种预测方法均显著优于 SVR、ARIMA 模型。由于 ARIMA 模型主要适用于线性时间序列数据,对非线性模式的捕捉能力较弱,导致其在水质余氯预测中的表现较差,尤其在未来趋势预测方面存在较大局限性。在 48 h 水质余氯预测中,SVR 模型表现较差,存在较大的高频偏差,且模型对趋势变化的响应较为迟钝,容易过早地陷入缓慢状态,未能准确跟踪数据的变化趋势。多步预测和逐点预测具有不同的特点,逐点预测的结果误差最小,MAPE 小于 10%,RMSE 也最小,能够较好地捕捉未来一段时间内水中余氯的变化趋势,精度较高。多步预测虽然在一定程度上也表现出了较为理

想的预测能力,但与逐点预测相比,预测精度较低。实验结果表明,基于 LSTM 神经网络的逐点预测方法取得了最佳预测效果,其次是多步预测方法,而 SVR、ARIMA 模型则表现不理想,尤其是在处理长期预测时其预测性能显著下降。




图 14 基于 LSTM 模型多步预测法余氯量预测曲线

Fig. 14 Prediction curve of residual chlorine amount based on LSTM model multi-step prediction method




图 15 基于 LSTM 模型逐点预测法余氯量预测曲线

Fig. 15 Prediction curve of residual chlorine amount based on LSTM model point-by-point prediction method

6 结 论

本文实现了智能水系统中水质指标的短期准确预测。首先,对智能水系统监测到的水质数据进行评估和分析,获得其与时间的相关性;然后,建立了水质预测模型 SLSTM 对供水点余氯量水质指标进行监测,LSTM 网络具有记忆性,能够捕捉序列的长期相关性,具有较好的预测性能;进而,采用逐点预测和多步预测对所建立的预测模型进行了预测,并对预测效果进行了比较;最后,通过仿真验证了

SLSTM 预测模型的有效性,并与传统的 SVR 和 ARIMA 模型进行了比较。与 SVR、ARIMA 模型相比,SLSTM 网络的预测模型在不同时间尺度上具有更高的精度和更相似的变化趋势,并且逐点预测方法比多步预测方法具有更好的预测精度。

在处理长时间跨度的预测任务时,虽然逐点预测和多步预测方法有一定效果,但误差仍会随时间累积,影响长期预测的准确性;模型对数据质量依赖较大,若数据存在大量异常或缺失,可能影响模型性能。

参考文献:

[1] 程婉清,袁定波,熊鹏,等. 基于多种机器学习算法的水质指数预测模型构建与评估 [J]. 环境科学学报, 2023, 43(11): 144-152.
CHENG Wanqing, YUAN Dingbo, XIONG Peng, et al. Construction and evaluation of city water quality index prediction model based on multiple machine learning algorithms [J]. Acta Scientiae Circumstantiae, 2023, 43(11): 144-152.

[2] 王梓璇. 山地城市供水管网水质预警系统研究 [D]. 重庆: 重庆大学, 2022.

[3] 王亦琳,陶涛,赵平伟,等. 基于 Elman 神经网络的供水管网浊度预测研究 [J]. 中国市政工程, 2022 (1): 64-68.
WANG Yilin, TAO Tao, ZHAO Pingwei, et al. Research on turbidity prediction of water supply pipe network based on Elman neural network [J]. China Municipal Engineering, 2022(1): 64-68.

[4] YING F. Analysis of quality control for water environment monitoring [EB/OL]. [2024-11-12]. http://en.cnki.com.cn/Article_en/CJFDTotat-SXJL201801038.htm.

[5] THOMANN R V. The future “golden age” of predictive models for surface water quality and ecosystem management [J]. Journal of Environmental Engineering, 1998, 124(2): 94-103.

[6] NAJAH A A, EL-SHAFIE A, KARIM O A, et al. Water quality prediction model utilizing integrated wavelet-ANFIS model with cross-validation [J]. Neural Computing and Applications, 2012, 21(5): 833-841.

[7] 刘杰,陈前,许妍,等. 长江流域洞庭湖区出入湖磷通量模拟及水质预测: 机器学习与传统水文模型耦合方法 [J]. 地球科学, 2024, 49(11): 3995-4007.
LIU Jie, CHEN Qian, XU Yan, et al. Simulation of phosphorus inflow and outflow fluxes and water quality prediction in Dongting Lake area of the Yangtze Riv-

er basin: a coupled approach of machine learning and traditional hydrological modeling [J]. Earth Science, 2024, 49(11): 3995-4007.

[8] TU Jichang, YANG Xueqin, CHEN Chaobo, et al. Water quality prediction model based on GRU hybrid network [C]//2019 Chinese Automation Congress. Piscataway, NJ, USA: IEEE, 2019: 1893-1898.

[9] 芮栋妮,马燕燕,叶林. 机器学习方法在污水处理系统中的应用 [J]. 环境工程, 2022, 40(6): 145-153.
RUI Dongni, MA Yanyan, YE Lin. Application of machine learning methods in wastewater treatment systems [J]. Environmental Engineering, 2022, 40 (6): 145-153.

[10] LIU Gang, GUO Jiabao. Bidirectional LSTM with attention mechanism and convolutional layer for text classification [J]. Neurocomputing, 2019, 337: 325-338.

[11] PALANGI H, WARD R, DENG Li. Distributed compressive sensing: a deep learning approach [J]. IEEE Transactions on Signal Processing, 2016, 64 (17): 4504-4518.

[12] SHENG Liming, JIAN Zhou, XIN Li, et al. Water quality prediction method based on preferred classification [J]. IET Cyber-Physical Systems: Theory & Applications, 2020, 5(2): 176-180.

[13] HARI K N, JAGRAT J. Adaptability of smart water systems in urban belt: a case study at Sastra University, Thanjavur [J]. Asian Journal of Management, 2020, 11(1): 21-25.

[14] LI Jiada, YANG Xiafei, SITZENFREI R. Rethinking the framework of smart water system: a review [J]. Water, 2020, 12(2): 412.

[15] MARCHESE D, JIN A, FOX-LENT C, et al. Resilience for smart water systems [J]. Journal of Water Resources Planning and Management, 2020, 146(1): 02519002.

[16] CUI Bo, MENG Qinghong. Smart water monitoring and management system based on the architecture of internet of things [J]. Applied Mechanics and Materials, 2013, 278-280: 1822-1825.

[17] BHARATH SINGH J, NIRMITHA S, KAVIYA S S. Smart urban water quality prediction system using machine learning [C]//Journal of Physics: Conference Series. Bristol, UK: IOP Publishing, 2021: 012057.

[18] YAO Fengchun. Study on the application of smart water system in urban water supply [J]. Science Innovation, 2021, 9(4): 176-178.

[19] NTULI N, ABU-MAHFOUZ A. A simple security

- architecture for smart water management system [J]. *Procedia Computer Science*, 2016, 83: 1164-1169.
- [20] 李如忠. 水质预测理论模式研究进展与趋势分析 [J]. 合肥工业大学学报(自然科学版), 2006, 29(1): 26-30.
- LI Ruzhong. Advance and trend analysis of theoretical methodology for water quality forecast [J]. *Journal of Hefei University of Technology (Natural Science)*, 2006, 29(1): 26-30.
- [21] CHEN Kangyang, CHEN Hexia, ZHOU Chuanlong, et al. Comparative analysis of surface water quality prediction performance and identification of key water parameters using different machine learning models based on big data [J]. *Water Research*, 2020, 171: 115454.
- [22] PUROHIT S K, PANIGRAHI S, SETHY P K, et al. Time series forecasting of price of agricultural products using hybrid methods [J]. *Applied Artificial Intelligence*, 2021, 35(15): 1388-1406.
- [23] CHEN M Y, CHIANG H S, SANGAIAH A K, et al. Recurrent neural network with attention mechanism for language model [J]. *Neural Computing and Applications*, 2020, 32(12): 7915-7923.
- [24] YAYAN U, ARSLAN A T, YUCEL H. A novel method for SoH prediction of batteries based on stacked LSTM with quick charge data [J]. *Applied Artificial Intelligence*, 2021, 35(6): 421-439.
- [25] DAHL G E, YU Dong, DENG Li, et al. Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition [J]. *IEEE Transactions on Audio Speech and Language Processing*, 2012, 20(1): 30-42.
- [26] BALI N, SINGLA A. Deep learning based wheat crop yield prediction model in Punjab region of North India [J]. *Applied Artificial Intelligence*, 2021, 35(15): 1304-1328.
- [27] FARABET C, COUPRIE C, NAJMAN L, et al. Learning hierarchical features for scene labeling [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1915-1929.
- [28] PLANK B, SØGAARD A, GOLDBERG Y. Multilingual part-of-speech tagging with bidirectional long short-term memory models and auxiliary loss [C]// *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*. Stroudsburg, PA, USA: ACL, 2016: 412-418.

(编辑 赵炜 武红江)