

DOI: 10.19479/j.2095-719x.2501061

# 基于 Bi-LSTM 神经网络的高层建筑塔吊安全预测方法

李景新, 杨国庆, 徐 增  
(天津城建大学 控制与机械工程学院, 天津 300384)

**摘 要:** 智慧工地的高层建筑塔吊安全是在建筑行业亟待解决的关键问题之一, 塔身倾斜度是塔吊运动控制中的一个重要监测指标, 为解决塔吊倾角预测精度不高问题, 提出了残差学习(Res-Net)-双向长短期记忆神经网络(Bi-directional Long Short-Term Memory)模型预测高层建筑塔吊塔身各段倾角的方法. 以分段监测的塔身倾角为输入, 对塔吊塔身各段倾角实时监测预测. 采用鲸鱼算法对模型进行优化, 以最小化 Res-Bi-LSTM 网络的均方根误差为目标, 寻找最优超参数, 使得网络的误差最小. 最终实现对塔身各段倾角的有效预测. 实验结果分析提出的模型均方根误差(RMSE)降低到 0.8%, 模型的拟合优度达到 94.96%, 均优于对比实验的 RNN、Bi-LSTM 模型. 本文所提出的模型具有更高的预测精度.

**关键词:** 高层建筑塔吊; 分段监控系统; 时间预测序列; 鲸鱼优化算法; Bi-LSTM

**中图分类号:** TU974 **文献标志码:** A **文章编号:** 2095-719X(2025)01-0061-08

## Research on Safety Prediction Method of Tower Crane for High-rise Buildings Based on Bi-LSTM Neural Network

LI Jingxin, YANG Guoqing, XU Zeng

(School of Control and Mechanical Engineering, TCU, Tianjin 300384, China)

**Abstract:** The safety of tower cranes for high-rise buildings at smart construction sites is one of the key problems to be solved in the construction industry, and the inclination of the tower body is an important monitoring index in the tower crane motion control. To address the issue of low inclination prediction accuracy of tower cranes, this paper presents a residual learning-Bi-directional Long Short-Term Memory neural network model to predict the tilt angles of tower cranes in tall buildings. The real-time monitoring and prediction of each dip angle of the tower crane was carried out based on the input of the segmental monitoring. The whale algorithm was used to optimize the model, aiming to minimize the RMSE of Res-Bi-LSTM network, and to find the optimal hyperparameters to minimize the error of the network. It could ultimately realize the effective prediction of the inclination of each section of the tower. The root mean square error (RMSE) of the proposed model is reduced to 0.8%, and the goodness of fit of the model reaches 94.96%, both of which are better than the RNN and Bi-LSTM models of the comparison experiment. The model proposed in this paper has higher prediction accuracy.

**Key words:** high-rise building tower crane; segmentation monitoring system; time forecast series; whale optimization algorithm; Bi-LSTM

随着城市现代化的推进, 高层建筑, 特别是超高层建筑不断涌现. 由于高层建筑规模大、施工时间长、风险大、施工难度系数高, 现场施工率增加, 故高层建筑塔吊施工安全问题已经成为建筑施工过程中关键问题之一.

塔吊是高层、超高层建筑施工首选的起重设备. 然而高层建筑塔吊倒塌事故常发. 塔吊因为超载、长

时间施工以及天气的影响等而引起结构受力变化, 从而导致塔吊塔身倾斜、变形直至倒塌, 造成重大安全事故, 因此高层建筑塔吊倾角是评估塔吊稳定与否的重要指标. 为了避免不可逆事故的发生, 对塔吊塔身倾斜角的监测是必要的.

Jiang 等<sup>[1]</sup>基于比例模型构建了人机交互施工活动的数字孪生(DT)框架, 得到了塔式起重机随动载荷递

收稿日期: 2023-08-24; 修订日期: 2023-09-18

基金项目: 天津市研究生科研创新项目(2022SKYZ324)

作者简介: 李景新(1998—), 女, 山东菏泽人, 天津城建大学硕士生

通讯作者: 杨国庆(1974—), 男, 副教授, 硕士. 研究方向: 楼宇智能化与智慧城市. E-mail: tjcj2008@163.com.

增的稳定性变化规律.表明倾斜吊装是引起塔机失稳的最危险行为. Zhou 等<sup>[2]</sup>提出了一种基于数字孪生的港口起重机运行状态监测系统框架. 框架以数字化双港起重机为核心, 结合多传感器数据采集方法、OPC UA 信息模型和插件编程方法, 实现多源异构虚实数据融合. Gutierrez<sup>[3]</sup>提出一种基于视觉的 3D 起重机系统运动控制方法, 采用了基于位移的解析模型、实验模型以及自适应优化算法. Liu 等<sup>[4]</sup>提出了一种带状态约束 4-DOF 的塔式起重机抗摆动轨迹规划方法. Yang<sup>[5]</sup>提出了一种基于 RNN 的长短时记忆(LSTM)事故诊断算法. Lin<sup>[6]</sup>提出 BP 神经网络模型对高层建筑起重机的风险进行预测, 可较准确地预测倾角的变化趋势. 合肥工业大学史露强<sup>[7]</sup>提出了稀疏残差 LSTM 算法预测输电塔倾角. 文献[8]提出软摆索模型、包括悬垂摆动模型和吊索波动模型, 从而实现对塔吊的防摆控制. 华中科技大学张潇等<sup>[9]</sup>提出一套基于物联网的塔式起重机安全监控系统. 建立了塔吊结构安全监测体系和监测方法, 可实时监控塔式起重机的结构和作业状态. 兰州交通大学王金辉等<sup>[10]</sup>采用贝叶斯网络评估塔吊作业安全风险, 推理出塔吊安全的最大影响因素. Zhu 等<sup>[11]</sup>提出并设计了一种基于力反馈的防摇控制方法, 提出的基于触觉的力平衡控制方法在性能和主观评价方面均优于自动方法. Lu 等<sup>[12]</sup>基于各种 CFD 模拟, 根据各种施工场景确定主建筑的形状系数, 预测风速的不确定性、过载和连接刚度. El Ouni 等<sup>[13]</sup>提出了传感器和执行器相匹配的智能塔吊来减轻风速, 结果证明智能塔式起重机模型在减轻湍流风载荷方面非常有效. Chen 等<sup>[14]</sup>研究提出了风荷载波动下塔式起重机安全评价的总体方案; 通过计算流体力学与自回归方法分别计算出模型塔吊的风荷载系数和时程, 并将风荷载时程用于塔机模型. Sun 等<sup>[15]</sup>提出了一种基于改进灰狼优化算法(IGWO-LQR)的 LQR 控制器, 结果表明所提出的模型可以显著减少有效载荷摆动, 提高工作效率. 针对塔式起重机有效载荷摇摆控制, 文献[16]提出的基于触觉的力平衡控制方法用于重型机器稳定性控制. 文献[17]提出了减少塔式起重机结构振动的防摇方法. 文献[18]提出基于神经网络的输入整形器, 控制塔式起重机的有效载荷摆动.

以上关于塔吊安全预测预警的研究, 从不同的角度出发, 但仍存在不足: ①现有的监测很少进行对塔身分段数据监测. ②现有的塔吊预测方法很少考虑时间因素的影响, 无法精准地预测未来某一段时间塔吊的倾角及危险程度. 由于以上原因, 提出基于 Bi-LSTM 算法的塔身各段倾角预测模型, 引入残差学习

法, 减少梯度消失; 同时引入鲸鱼算法进行超参数寻优, 提高模型的训练精度.

## 1 预测模型

本节简要介绍基于 RNN 网络改进的 LSTM 模型、Bi-LSTM 模型、残差的 Bi-LSTM 模型, 为了提高塔吊倾角数据精准预测, 提出 WOA-Res-Bi-LSTM 模型.

### 1.1 LSTM 模型

循环神经网络(recurrent neural networks, RNN)引入了时序概念, 在描述序列特征方面具有很大优势. 在训练 RNN 网络模型的过程中, 长期记忆信息不容易保存; 同时激活函数在隐藏层中的导数会逐渐减小, 产生消失梯度现象; 故提出 LSTM 网络, 结构如图 1 所示. LSTM(long short-term memory)神经网络<sup>[19]</sup>可以有效地保留长期记忆信息, 是一种特殊的递归神经网络. LSTM 在 RNN 的基础上改进了隐藏层结构, 具有长期时间依赖特性, 同时受梯度消失、梯度爆炸的影响较小. LSTM 单元包含 3 个门控制器(输入门  $i_t$ , 遗忘门  $f_t$  和输出门  $o_t$ ), 一个记忆单元遗忘门决定了多少信息应该丢弃或保留.  $t$  时刻遗忘门的输出向量是

$$f_t = \sigma(W_f \cdot [s_{t-1}, x_t] + b_f) \quad (1)$$

式中:  $\sigma(\cdot)$  为 Sigmoid 函数表示遗忘门  $f_t$  的输出;  $W_f$  表示遗忘门函数矩阵的权重;  $s_{t-1}$  表示  $t-1$  时刻的输出量;  $x_t$  表示  $t$  时刻本层的输入;  $b_f$  表示遗忘门的偏置项.

输入门决定了输入的信息有多少能保留到记忆单元  $C_t$  中. 输入门有两个部分, 第一部分更新输入信息其表达式为

$$i_t = \sigma(W_i \cdot [s_{t-1}, x_t] + b_i) \quad (2)$$

式中:  $i_t$  表示输入门的输出;  $W_i$  表示  $t$  输入层的权重;  $b_i$  表示为输入层的偏置项.

第二部分  $t$  时刻候选值信息更新的表达式为

$$\tilde{c}_t = \tanh(W_c \cdot [s_{t-1}, x_t] + b_c) \quad (3)$$

式中:  $W_c$  表示时刻输入层的权重;  $b_c$  表示为候选值的偏置项.

输出门决定了输入信息有多少信息输出到下一时刻隐藏层中.  $t$  时刻输出门的输出表达式为

$$s_t = o_t \otimes \tanh(C_t) \quad (4)$$

$$o_t = \sigma(W_o \cdot [s_{t-1}, x_t] + b_o) \quad (5)$$

式(4)中:  $o_t$  为  $t$  时刻输出层的状态;  $C_t$  表示经过遗忘门和输出门的输出. 式(5)中:  $W_o$  表示  $t$  输出层的权重;  $b_o$  表示输出层的偏置项.

当前  $t$  时刻记忆单元  $C_t$  的表达式为

$$C_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \quad (6)$$

式中:  $c_{t-1}$  表示上一时刻单元状态.




图 1 LSTM 模型

### 1.2 残差学习优化 Bi-LSTM

Bi-LSTM 神经网络输出的表达式为

$$\vec{s}_t = f(\vec{b} + [x_t, s_{t-1}] \times \vec{w}) \quad (7)$$

$$\leftarrow s_t = f(\leftarrow b + [x_t, s_{t-1}] \times \leftarrow w) \quad (8)$$

式(7)中:  $f$  为激活函数;  $\vec{s}_t$  表示 LSTM 神经网络的正向输出;  $\vec{b}$  表示正向偏置;  $\vec{w}$  表示权重. 式(8)中:  $\leftarrow s_t$  表示 LSTM 神经网络的反向输出;  $\leftarrow b$  表示反向偏置;  $\leftarrow w$  表示权重.

将 LSTM 网络正向、反向输出一起计算, 得到 Bi-LSTM 神经网络的输出  $y_t$

$$y_t = c + g([\vec{s}_t, \leftarrow s_t] \times U) \quad (9)$$

式中:  $g$  表示激活函数;  $c$  表示偏置;  $U$  表示权重.

残差网络(Res-Net)通过在网络层间引入“快捷连接”进行残差学习. 残差网络如图 2 所示. 当输入为  $x$  时, 原网络模型的输出函数为




图 2 残差网络

$$y = F(x) \quad (10)$$

此时, 长序列的反向传播过程中, 梯度在每个时间步上都会被乘以一个相同的权重矩阵, 导致梯度值逐渐变小, 最终消失. 但是, 在添加残差结构后, 网络的输出函数变为

$$y = F(x) + x \quad (11)$$

Res-Net 将 Bi-LSTM 神经网络的输入与输出相连, 输入信息跳过网络层输出, 由于剩余的连接没有阻碍的梯度, 仅在原来网络层的输出上叠加了网络的输入  $x$ , 有效解决神经网络梯度消失问题.

提出残差网络(Res-Net)优化 Bi-LSTM 网络, 如图 3 所示.




图 3 Res-Bi-LSTM 模型

### 1.3 鲸鱼算法

Mirjalili 在智能算法领域创造性地提出了鲸鱼优化算法(WOA). 该算法本质上是一种基于群体智能模拟的元启发式算法. 相较于粒子群优化算法、蛙跳算法、鱼群算法等, 鲸鱼算法是一种操作简单、参数少、优化性能好的智能优化算法. 通过模拟鲸鱼捕食机制来表征算法的寻优过程, 较好地权衡和量化了全局和局部搜索能力.

#### 1.3.1 包围猎物

鲸鱼算法进入本地搜索阶段, 一种是收缩包围法, 另一种是螺旋更新法. WOA 将猎物位置视为最优目标或近似最优解, 其他种群中的个体在此基础更新自己的位置. 在包围猎物阶段, WOA 算法设置个体最优解, 其他个体根据最优解更新其位置. 该过程数学表达式如下

$$D = |C \cdot X^*(t) - X(t)| \quad (12)$$

$$X(t+1) = X^*(t) - A \cdot D \quad (13)$$

式(12)中:  $D$  代表随机距离;  $t$  代表迭代次数. 式(13)中  $X_t$  为位置向量;  $X^*$  表示最优解位置向量.

系数向量计算表达式为

$$C = 2r \quad (14)$$

$$A = 2ar - a \tag{15}$$

其中  $a = 2 - \frac{2t}{t_{max}}$ ,  $a$  从 2 减小到 0;  $r$  表示区间  $[0, 1]$  内的随机生成值.

### 1.3.2 泡泡网攻击

这种行为的数学模型是:其中:  $L = |X^*(t) - X(t)|$  表示鲸鱼和猎物间距离,  $b$  是常数,  $d$  是  $[-1, 1]$  之间随机生成的值. 在自然界中, 鲸鱼通过盘旋在猎物周围捕食, 同时不断地收缩它们的外壳. 因此, WOA 被设计为模拟这种行为. 当  $p \geq 0.5$  时, 进行泡泡网攻击狩猎行为. 螺旋更新数学表达式如下

$$X(t+1) = D \cdot e^{bl} \cos(2\pi l) + X^*(t) \tag{16}$$

式中:  $D = |X^* - X(t)|$  代表鲸鱼和猎物距离;  $b$  是常系数;  $l$  是  $(-1, 1)$  之间随机生成值.

在自然界中, 鲸鱼通过盘旋在猎物周围捕食, 同时不断地收缩它们的外壳. 因此, WOA 设计模拟这种行为, 假设有  $1 - P_i$  的概率选择螺旋模型更新位置和  $P_i$  的概率选择收缩包围机制, 该算法的数学模型表达式为

$$X(t) = \begin{cases} X^*(t) - A \cdot D & p < P_i \\ D \cdot e^{bl} \cos(2\pi l) + X^*(t) & p \geq P_i \end{cases} \tag{17}$$

式中:  $p$  是  $[0, 1]$  区间随机生成值.

### 1.3.3 搜索猎物

当  $p < 0.5$  且  $A > 1$  时, 执行随机搜寻猎物, 该过程数学表达式为

$$D = |CX_{rand} - X| \tag{18}$$

$$X(t+1) = X_{rand} - A \cdot D \tag{19}$$

式(18)中:  $X_{rand}$  从当前种群中随机选择的鲸鱼;  $X(t+1)$  为当前鲸鱼个体在第  $(t+1)$  代的位置.

### 1.4 WOA 优化 Res-Bi-LSTM 超参数

通过 WOA 算法对 Res-Bi-LSTM 神经网络的隐含层节点  $L1$ 、 $L2$  和学习率 3 个参数进行优化, 寻找到最优参数, 使得 Res-Bi-LSTM 误差最小. 利用实验室模型获取的数据作为训练集输入, 建立适用于高层建筑塔吊的安全预测的 WOA-Res-Bi-LSTM 网络模型. 模型预测流程如图 4 所示, 具体步骤如下:

步骤 1: 对鲸鱼算法参数进行初始化设置, 初始化的参数分别为鲸鱼种群数、最大迭代数、个体维度.

步骤 2: 确定需要优化的 Res-Bi-LSTM 神经网络的隐含层节点和学习率. 同时确定寻优范围.

步骤 3: 使用群体中超参数的可能组合来训练 Res-Bi-LSTM 模型, 并且计算这组超参数的适应度. 在本文中, 使用 RMSE 作为适应度函数.

步骤 4: 使用鲸鱼优化算法更新种群, 选择适应度最优的超参数组合, 同时生成新的超参数组合.

步骤 5: 反复进行步骤 3 和步骤 4, 判断是否满足条件, 若满足则输出最优超参数.

步骤 6: 将最优超参数传给 Res-Bi-LSTM 神经网络, 对倾角数据进行训练预测, 训练并测试神经网络, 通过鲸鱼算法寻优到的最优超参数, 使得测试集误差最小.

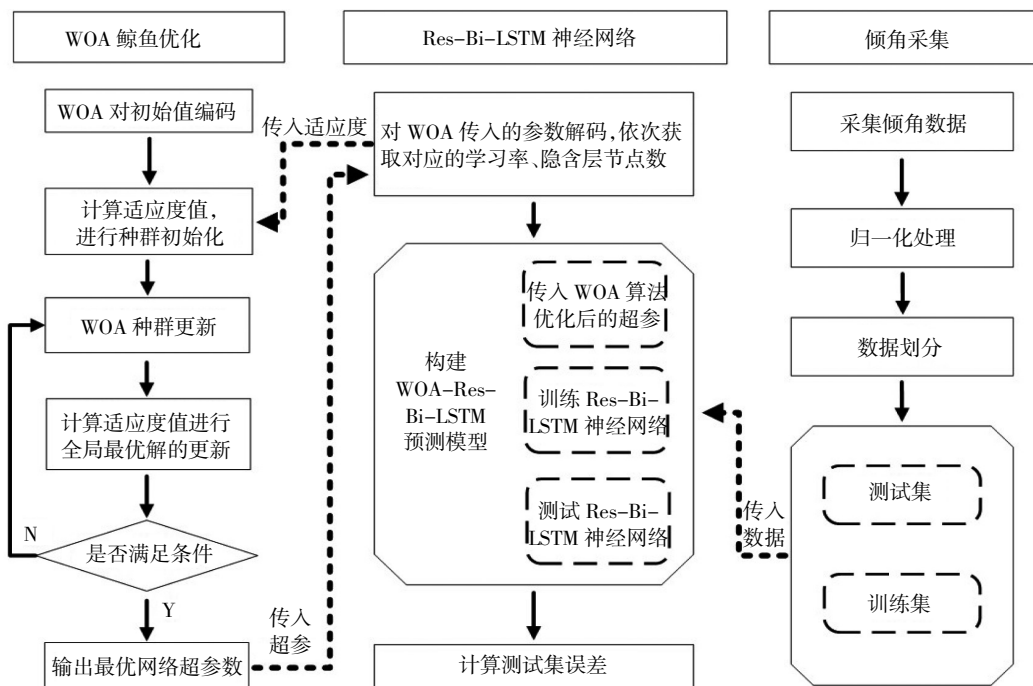


图 4 模型预测流程图

## 2 实验设置

### 2.1 实验室模型的建立

首先,本文采用现代信息技术与智能算法相结合,设计了应用于智慧工地的多功能智能塔吊安全监测模型;其次,利用监测模型对高层建筑塔吊所监测的数据进行分析.本文研究对象为型号 TC6013 的上回转式塔吊,是工程建设中常用的上回转式塔吊.其最大起升高度( $H$ )为 150 m,最大起重臂幅( $L$ )为 60 m,起重臂长( $R$ )为 61.03 m.

本研究所采用的实验模型为 TC6013 塔吊模型,其具备严谨的技术规格.具体而言,该模型的高度( $H$ )为 1.28 m,起重臂臂长( $R$ )为 0.92 m,起重臂距地面( $H_1$ )为 1 m.在系统控制方面,采用 STM32F103 系列芯片作为主控芯片,结合 NB-IOT 无线网络以及 5G 网络进行信息传输,以确保高效的数据传输和处理.为获取塔吊倾斜度数据,使用 MPU-6050 模块中集成的三轴加速度计,有助于准确测量塔吊的倾斜角度.实验平台的详细结构如图 5 所示,在塔吊的 3 个不同节点安置了传感器,以实现数据的实时传输和监测.MPU-6050 模块作为运动处理单元,采用数据驱动的方法对相关模型进行动态训练.




图 5 实验数据采集装置

### 2.2 塔身垂直度指标

根据《建筑机械使用安全技术规程》的要求<sup>[20]</sup>:塔身在无荷载的情况下,塔身垂直度允许偏差应为 0.4%.对塔吊进行实时监测,记录塔吊各时间各段偏移情况,将监测到的数据与工程要求标准进行比较,确定塔吊指标是否处在安全范围内.

## 3 实验研究

### 3.1 实验数据集介绍

建立上回转式塔吊实验室模型动态记录加速度计原始输出数据,利用处理后的加速度计和陀螺仪的融合数据集,验证预测模型输出的准确性.每组数据集包含 4 000 多个连续记录,选取实验室模型 2022 年 12 月 8 日,早 8:00 至晚 5:00 3 个监测位置的部分数据,组成数据集,每组数据集共 3 035 个数据,80%作为训练集,20%作为测试集.

### 3.2 模型参数优化

WOA-Res-Bi-LSTM 模型结构包括输入层、隐含层和输出层.WOA 损失函数采用均方根误差,构建的 Res-Bi-LSTM 模型使用 Adam 优化器进行梯度下降优化权值.

最优超参数可以提高 Res-Bi-LSTM 神经网络学习的性能和效果.采用 WOA 算法对 Res-Bi-LSTM 模型中隐含层神经元数量  $L1$ 、 $L2$ 、学习率  $\alpha$  3 个超参数进行优化.设置鲸鱼种群数为 50,迭代次数为 30,个体维度为 3.隐含层神经元数量  $L1$ 、 $L2$  与初始学习率的搜索空间分别为  $[1, 100]$ 、 $[1, 100]$  和  $[0.001, 0.01]$ .每个 Res-Bi-LSTM 单元的 dropout 设为 0.5.训练次数 100 次.经过优化,随迭代次数的递增,WOA-Res-Bi-LSTM 模型可以在搜索空间中快速找到近似最优解,将搜寻到的最优超参数带入模型中进行网络训练预测.

### 3.3 预测精度评价指标

为了评价模型的预测效果,文中使用以下 5 个评价指标:RMSE、MSE、MAE、MAPE 以及拟合优度.

均方根误差(root mean square error, RMSE)

$$E_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (20)$$

均方误差(mean square error, MSE)

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (21)$$

平均绝对误差(mean absolute error, MAE)

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (22)$$

平均绝对百分比误差(mean absolute percentage error, MAPE)

$$E_{\text{MAPE}} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \quad (23)$$

拟合优度  $R^2$ (R-Square)

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{24}$$


### 3.4 实验结果与分析

采用数据集中节点 1、节点 2、节点 3 倾斜度数据进行实验仿真. WOA 优化 Res-Bi-LSTM 网络获得最优超参数. 在节点 1 实验中, WOA-Res-Bi-LSTM 模型的最优超参数设置为第一隐含层神经元数量 L1 为 64, 第二隐含层神经元数量 L2 为 32, 学习率为 0.02. 在节点 2 实验中 WOA-Res-Bi-LSTM 模型的最优超参数设置为 L1 为 32, L2 为 16, 学习率为 0.02. 在节点 3 实验中 WOA-Res-Bi-LSTM 模型的最优超参数设置 L1 为 64, L2 为 16, 学习率为 0.02. 利用 Bi-LSTM 模型与 WOA-Res-Bi-LSTM 模型进行对比实验, 实验结果如图 6、图 7、图 8 所示. 从图 6-8 中曲线拟合程度可


以看出 WOA-Res-Bi-LSTM 模型预测效果更好.

本文采用 3 种算法 RNN 模型、Res-Bi-LSTM 模型、WOA-Res-Bi-LSTM 模型对塔吊不同节点的倾斜度进行预测, 预测结果曲线如图 9 所示. 从图 9(a)、图 9(b)和图 9(c)预测曲线可以看出, 对于 RNN 模型、Res-Bi-LSTM 模型、WOA-Res-Bi-LSTM 模型预测值与真实值曲线的吻合程度从高到低依次为 WOA-Res-Bi-LSTM 模型、Res-Bi-LSTM 模型、RNN 模型. WOA-Res-Bi-LSTM 模型是三者中最接近真实的数据样本的训练模型, 这说明鲸鱼优化算法优化的 Res-Bi-LSTM 神经网络具有更好的预测性能.

倾角值各模型预测误差对比如表 1 所示, 节点 1 的 WOA-Res-Bi-LSTM 的评价指标 MSE、RMSE、MAE、MAPE 和  $R^2$  分别为 0.000 06, 0.008, 0.005, 0.298 9 和 0.935 9. 相较于 RNN、Bi-LSTM 模型预测精度分别提高了 9.08%, 4.82%. 节点 2 的 Res-Bi-LSTM 的评价指标 MSE、RMSE、MAE、MAPE 和  $R^2$  分别为 0.000 06,




(a)节点 1 Bi-LSTM 模型预测结果




(b)节点 1 WOA-Res-Bi-LSTM 模型预测结果

图 6 节点 1 倾角预测结果




(a)节点 2 Bi-LSTM 模型预测结果




(b)节点 2 WOA-Res-Bi-LSTM 模型预测结果

图 7 节点 2 倾角预测结果

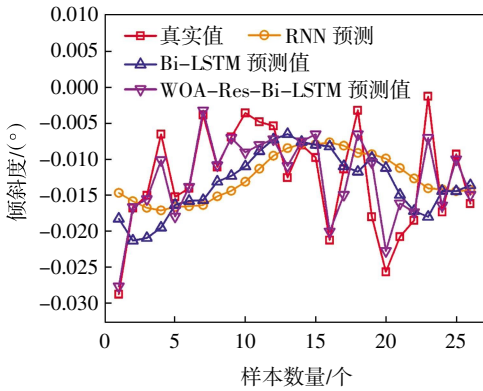


(a)节点 3 Bi-LSTM 模型预测结果




(b)节点 3 WOA-Res-Bi-LSTM 模型预测结果

图 8 节点 3 倾角预测结果




(a)节点 1-测试样本预测值与实际值对比



(c)节点 3-测试样本预测值与实际值对比

图 9 误差对比图



(b)节点 2-测试样本预测值与实际值对比

0.009 0,0.006 3,1.120 1 和 0.949 6. 相较于 RNN、Bi-LSTM 预测精度分别提高了 13.9%,9.02%. 节点 3 的 WOA-Res-Bi-LSTM 的评价指标 MSE、RMSE、MAE、MAPE 和  $R^2$  分别为 0.000 67,0.025 8,0.009 7,0.208 2、0.943 0. 相较于 RNN、Bi-LSTM 预测精度分别提高了 8.29%,7.21%. 各项评价指标均优于 Bi-LSTM 模型. 本文所提出的模型很好地预测了未来一段时间内各段塔吊倾角变化的趋势, 具有较好的预测能力. 同时

表 1 倾角值各模型预测误差对比

节点	模型	$R^2$	MSE	RMSE	MAE	MAPE
节点 1	RNN	0.845 1	0.000 08	0.009 3	0.006 5	0.339 0
	Bi-LSTM	0.887 7	0.000 07	0.008 8	0.006 3	0.326 7
	WOA-Res-Bi-LSTM	0.935 9	0.000 06	0.008 0	0.005 0	0.298 9
节点 2	RNN	0.810 6	0.000 16	0.012 7	0.007 3	1.287 2
	Bi-LSTM	0.859 4	0.000 12	0.011 2	0.006 7	1.204 6
	WOA-Res-Bi-LSTM	0.949 6	0.000 06	0.009 0	0.006 3	1.120 1
节点 3	RNN	0.860 1	0.001 48	0.038 4	0.018 5	0.298 4
	Bi-LSTM	0.870 9	0.001 24	0.035 2	0.012 6	0.278 3
	WOA-Res-Bi-LSTM	0.943 0	0.000 67	0.025 8	0.009 7	0.208 2

可知,WOA-Res-Bi-LSTM 相比于其他两种模型拟合优度更高,预测精度更高(见图 10)。

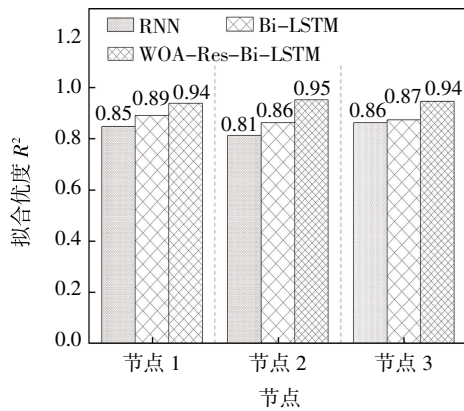


图 10 各模型拟合优度  $R^2$

## 4 结论

对于智慧工地的高层建筑塔吊安全预测方法研究,本文利用实验室模型对塔身各段安装传感器监测采集数据,获得数据集.实现对高层建筑塔吊各段各时间数据实时监测、预测分析,得出以下结论。

(1)为了提高塔吊倾角预测模型的预测精度,本文提出了使用鲸鱼算法优化 Res-Bi-LSTM 的高层建筑塔吊倾角预测模型.结合残差学习法和 Bi-LSTM 神经网络优点,利用鲸鱼算法对模型超参数寻优,获得最优超参数.因此,所提出的 WOA-Res-Bi-LSTM 模型预测的精度提高。

(2)文中提出 RNN 模型、Bi-LSTM 模型与 WOA-Res-Bi-LSTM 模型进行对比实验,WOA-Res-Bi-LSTM 模型预测精度达到 94.96%,证明 WOA-Res-Bi-LSTM 模型能够实现更快、更准确的智能预测.在高层建筑塔吊安全预测预警领域具有一定的实用价值。

### 参考文献:

- [1] JIANG W, DING L, ZHOU C. Digital twin: stability analysis for tower crane hoisting safety with a scale model[J]. Automation in Construction, 2022, 138: 104-109.
- [2] ZHOU Y, FU Z, ZHANG J, et al. A digital twin-based operation status monitoring system for port cranes[J]. Sensors, 2022, 22(9): 32-43.
- [3] GUTIERREZ R, MAGALLON M. Vision-based system for 3D tower crane monitoring[J]. IEEE Sensors Journal, 2020, 21(10): 11935-11945.
- [4] LIU Z, YANG T, SUN N, et al. An antiswing trajectory planning method with state constraints for 4-DOF tower cranes: design and experiments[J]. IEEE Access, 2019, 7: 62142-62151.
- [5] YANG J, KIM J. An accident diagnosis algorithm using long short-term memory[J]. Nuclear Engineering and Technology, 2018, 50(4): 582-588.
- [6] LIN N. Simulation and prediction of the safety risk of Tower Crane for super high-rise buildings through back propagation neural network[C]//IOP Conference Series: Earth and Environmental Science. London, United Kingdom, 2021, 783(1): 012-030.
- [7] 史露强. 输电杆塔姿态在线监测关键技术研究[D]. 合肥: 合肥工业大学, 2020: 21-95.
- [8] 符裕. 双桅杆式起重机系统的协作消摆控制研究[D]. 天津: 南开大学, 2021: 12-92.
- [9] 张潇, 张伟. 塔式起重机安全事故统计分析[J]. 工业安全与环保, 2019, 45(9): 24-29.
- [10] 王金辉, 郝伟, 陶泽, 等. 基于模糊贝叶斯网络的塔吊作业安全风险评估[J]. 安全与环境工程, 2021, 28(4): 15-20.
- [11] ZHU Q, ZHOU T Y, DU J. Haptics-based force balance controller for tower crane payload sway controls[J]. Automation in Construction, 2022, 144: 104-111.
- [12] LU Y, GAO M X, LIANG T, et al. Wind-induced vibration assessment of tower cranes attached to high-rise buildings under construction[J]. Automation in Construction, 2022, 135: 36-45.
- [13] EL OUNI M H, BEN KAHLA N, ISLAM SAIFUL, et al. A smart tower crane to mitigate turbulent wind loads[J]. Structural Engineering International, 2021, 31(1): 18-29.
- [14] CHEN W, QIN X, YANG Z, et al. Wind-induced tower crane vibration and safety evaluation[J]. Journal of Low Frequency Noise, Vibration and Active Control, 2020, 39(2): 65-76.
- [15] SUN M, JI C, LUAN T, et al. LQR pendulation reduction control of ship-mounted crane based on improved grey wolf optimization algorithm[J]. International Journal of Precision Engineering and Manufacturing, 2023, 11: 1-13.
- [16] ZHU Q, ZHOU T, DU J. Haptics-based force balance controller for tower crane payload sway controls[J]. Automation in Construction, 2022, 144: 104-117.
- [17] CAPORALI P. Anti-sway method for reducing vibrations on a tower crane structure[J]. International Journal of Nonlinear Sciences and Numerical Simulation, 2023, 24.1: 171-184.
- [18] FASIH M, MOHAMED Z, RAMLI L, et al. Payload swing control of a tower crane using a neural network-based input shaper[J]. Measurement and Control, 2020, 53(7/8): 1171-1182.
- [19] 张冬雪. 基于 LSTM 和 ARIMA 的风速时间序列预测研究[D]. 兰州: 兰州大学, 2020: 116-130.
- [20] 梁陆军, 张智皓, 陆龙耀, 等. 基于物联网的塔吊工作过程分段监控[J]. 建筑施工, 2022, 44(1): 156-159.