基于DBO-LSTM模型的桥梁环境温度及其效应预测方法研究

肖冠英[1] 文亚男[1] 冯若骁[1] 郑易涛[2,*]

（1. 成都市路桥经营管理有限责任公司，成都 610039；2. 四川交大工程检测咨询有限公司，成都 611743）

摘 要 针对传统健康监测系统数据处理复杂及有限元方法在桥梁环境温度效应预测中存在的计算量大、实时性差等问题，提出一种基于蜣螂优化算法（DBO）优化长短期记忆网络（LSTM）超参数的混合模型（DBO-LSTM），用于桥梁环境温度及温度效应的预测。该方法通过DBO算法对LSTM的隐藏层节点数、初始学习率及L2正则化系数三项关键超参数进行全局优化，提升了模型在长序列非线性特征学习过程中的预测精度和稳定性。基于成绵立交主线桥为期一年的温度与温度效应监测数据，对环境温度、伸缩缝位移、主梁梁底应变和墩顶偏位等多项指标进行预测实验，结果显示所建模型在各类预测项中均表现出良好的拟合能力和趋势捕捉能力。决定系数R^2最低为0.966，最高达0.995，平均绝对百分比误差（MAPE）在0.02至0.38之间，预测值与实测值在数值及趋势上高度一致。

关键词 桥梁工程，温度效应，DBO-LSTM，长期监测，预测方法

中图分类号：U446.2 **文献标志码**：A **DOI**：10.15935/j.cnki.jggcs.202604.0008

A Hybrid DBO-LSTM Model for Predicting Bridge Ambient Temperature and Its Thermal Response

XIAO Guanying[1] WEN Yanan[1] FENG Ruoxiao[1] ZHENG Yitao[2,*]

（1. Chengdu Road & Bridge Operation and Management Co.,Ltd, Chengdu 610039, China;
2. Sichuan Jiaoda Engineering Detection Consulting Co.,Ltd, Chengdu 611743, China）

Abstract To address the limitations of traditional bridge health monitoring systems and finite element methods, such as heavy computational demands and poor real-time performance, a hybrid prediction model based on Dung Beetle Optimization and Long Short-Term Memory networks (DBO-LSTM) is proposed for forecasting bridge ambient temperature and temperature-induced effects.The model utilizes the DBO algorithm to optimize three critical hyperparameters of the LSTM network: the number of hidden units, initial learning rate, and L2 regularization coefficient. This optimization enhances the model's ability to learn complex nonlinear dependencies in long-term monitoring data. Using one year of real-time monitoring data from the Chengmian Interchange mainline bridge, the model was applied to predict multiple indicators, including ambient temperature, expansion joint displacement, bottom beam strain, and pier top displacement. The results demonstrate high predictive performance, with coefficients of determination (R^2) ranging from 0.966 to 0.995 and mean absolute percentage errors (MAPE) between 0.02 and 0.38. The predicted values closely match the actual measurements in both magnitude and trend.

Keywords bridge engineering, temperature effect, DBO-LSTM, long-term monitoring, prediction technique

收稿日期：2025-07-02

基金项目：四川交投科研联合项目（编号：HT-GLQ2024-0055）

作者简介：肖冠英（1981-），男，汉族，硕士，高级工程师，从事桥梁建设及管理维护工作。E-mail：1394916417@qq.com

[*] **联系作者**：郑易涛（1990-）男，汉族，本科，工程师，从事桥梁结构检测、监控、鉴定、设计等工作。E-mail：372158397@qq.com

0 引 言

随着城市化进程的不断加快及交通基础设施逐步完善，城市立交桥数量逐渐增加，其服役环境错综复杂[1]。对于城市桥梁，温度作用往往会使其表现出复杂的力学行为，环境温度对桥梁结构的应变、伸缩缝及墩顶偏位等均有较大影响[2-5]，致使桥梁产生各种病害，从而导致人员伤亡与经济损失[6-7]。当前，对桥梁温度及温度效应的分析主要依靠传统健康监测系统和有限元法计算获得[8-10]。然而，传统的健康监测系统仅能记录实时数据，并需对已采集的庞大数据进行处理分析以总结其规律；有限元计算同样存在尺度大、单元多、热力耦合计算复杂、耗时长和硬件设备要求过高等问题[11-12]。

近年来，人工神经网络在各领域均得到了良好的发展和应用，其优秀的非线性泛化能力，使学者们青睐于将其用于预测桥梁结构的健康状况。聂华伟等[13]采用基于双向长短期记忆（Bi-LSTM）模型对桥梁健康监测中挠度、应力和温度三者之间的关系特征进行捕捉，从而准确预测了桥梁挠度值的变化趋势。方佳畅等[14]采用迁移学习和Bi-LSTM神经网络建立了一种斜拉桥温度-应变映射模型，并基于某大跨斜拉桥超过一年的温度和应变数据对模型进行了有效性验证。刘扬等[11]提出基于多层前馈-长短记忆（BP-LSTM）的混合模型对钢-混组合桥面系的温度场和温度效应进行实时评估和预测，并基于实测和有限元计算数据，对模型的精确性进行了验证。Yue等[15]基于LSTM神经网络建立了由温度引起的缆索桥主梁偏移量的预测模型，从而解决了温度与由温度引起的偏移量之间的复杂高阶非线性问题。经验证，所建立的LSTM回归模型，其平均误差仅为1.4%，最大误差仅为6%。然而，人工网络自身存在一定的局限性，如易陷入局部最小值、梯度消失或爆炸，以及参数调整较复杂，需要通过优化算法来提高训练的稳定性和效率[16]。

因此，基于以上分析，考虑到传统健康监测系统和有限元计算方法的不足，现提出一种基于蜣螂优化算法（Dung Beetle Optimization，DBO）优化长短期记忆网络（Long Short-Term Memory，LSTM）超参数的DBO-LSTM混合模型来预测桥梁环境温度及温度效应的变化，并结合某城市立交桥一年期间的温度及温度效应数据对DBO-LSTM混合模型进行验证。

1 DBO-LSTM混合模型

1.1 蜣螂优化算法

蜣螂优化算法是由Xue等[17]提出的一种受自然界蜣螂行为启发的优化算法。蜣螂能够将动物粪便滚成球，然后推动这些粪球到适合的地方去埋藏，用于孵化后代或作为食物来源。在此背景下，每一个蜣螂位置代表一个解决方案，蜣螂种群根据其行为分为四类：滚球蜣螂、产卵蜣螂、幼年蜣螂和小偷蜣螂。在整个迭代过程中，这四种蜣螂的位置随着解决方案的演变而不断更新，最终得到全局最优位置。

1）滚球蜣螂

滚球蜣螂通过太阳进行导航，以确保其推动的粪球沿直线路径滚动，采用如下公式进行位置更新：

$$x_i(m+1)=x_i(m)+a\cdot k\cdot x_i(m+1)+b\cdot\Delta x \tag{1}$$

$$\Delta x=\left|x_i(m)-x_c\right| \tag{2}$$

式中：$x_i(m+1)$表示第i只蜣螂在下一次迭代或步骤中的位置；$x_i(m)$表示第i只蜣螂的当前位置；m为迭代次数；a是一个权重因子，根据概率方法分配为−1或1，用于表示是否偏离原始方向；k表示偏转系数，范围在0到0.2之间；b表示常数，范围在0到1之间；x_c表示全局最差位置；Δx用于模拟光强度的变化。

当滚球蜣螂在推动粪球向前滚动遇到阻碍时，会采用一种特殊的行为方式以改变前进方向，这种行为也被称作“跳舞”。具体而言，它利用类似正切函数的方式生成一个新的滚动方向，以避开障碍物，该“跳舞”行为所产生的更新位置如下：

$$x_i(m+1)=x_i(m)+\tan(\theta)\left|x_i(m)-x_i(m-1)\right| \tag{3}$$

式中：θ表示偏转角度，范围在0到π之间，当其等于0、π/2或π时，蜣螂的位置不会更新。

2）产卵蜣螂

产卵蜣螂在边界选择策略中用于模拟雌性蜣螂的产卵区域。产卵区域由式(4)和(5)定义，而产卵蜣螂的位置由式(6)确定。

$$L_b^*=\max[x^*\times(1-R),L_b] \tag{4}$$

$$U_b^*=\min[x^*\times(1-R),U_b] \tag{5}$$

$$B_i(m+1)=x^*+p_1\times[B_i(m)-L_b^*]+p_2\times[B_i(m)-U_b^*] \tag{6}$$

式中：L_b^*和U_b^*分别表示产卵区域的下限和上限；L_b和U_b分别表示优化问题的下界和上界；x^*表示当前的局部最优位置；$R=1-m/m_{max}$，其中m_{max}是迭代次数的上限；$B_i(m+1)$表示在第m次迭代中，第i个产卵蜣螂的位置；p_1和p_2表示两个独立的随机向量，大小为$1\times D$，D表示优化问题的维度。

3）幼年蜣螂

幼年蜣螂需要在最佳觅食区域找到食物并进行觅食行为，最佳觅食区域由式(7)和式(8)定义，而幼年蜣螂的位置更新如式(9)所示。

$$L_b^j=\max[x^j\times(1-R),L_b] \tag{7}$$

$$U_b^j=\min[x^j\times(1-R),U_b] \tag{8}$$

$$x_i(m+1)=x_i(m)+C_1\times[x_i(m)-L_b^j]+C_2\times[x_i(m)-U_b^j] \tag{9}$$

式中：x^j表示当前的局部最优位置；L_b^j和U_b^j分别表示最佳觅食区域的下限和上限；$x_i(m)$表示在第m次迭代中，第i个幼年蜣螂的位置；C_1为用于控制位置更新的步长或调整幅度的常数，是服从正态分布的随机数；C_2为随机向量，其取值在[0，1]之间。

4）小偷蜣螂

小偷蜣螂会在其他蜣螂处进行偷窃行为，采用下式进行位置更新：

$$x_i(m+1)=x^j+Q\times g\times\left(\left|x_i(m)-x^*\right|+\left|x_i(m)-x^j\right|\right) \tag{10}$$

式中：x_j表示小偷蜣螂偷窃的目标位置；$x_i(m)$表示在第m次迭代中，第i个小偷蜣螂的位置；Q为调整系数，为常数；g表示大小为$1\times D$的随机向量，服从正态分布。

1.2 长短期记忆网络

长短期记忆网络是一种特殊的循环神经网络(Recurrent Neural Network，RNN)，由Hochreiter和Schmidhuber[18]于1997年提出，旨在解决传统RNN在处理长序列数据时容易出现的梯度消失和梯度爆炸问题。LSTM通过引入三种关键的门控机制——遗忘门、输入门和输出门——实现对信息流的精细控制，从而保持并传递跨时间步的信息。与RNN相比，LSTM缓解了模型训练中由于反向传播导致的“梯度消失”问题，具备学习长时间依赖的能力，因此在处理交通流数据时更为适用，其示意图如图1所示。

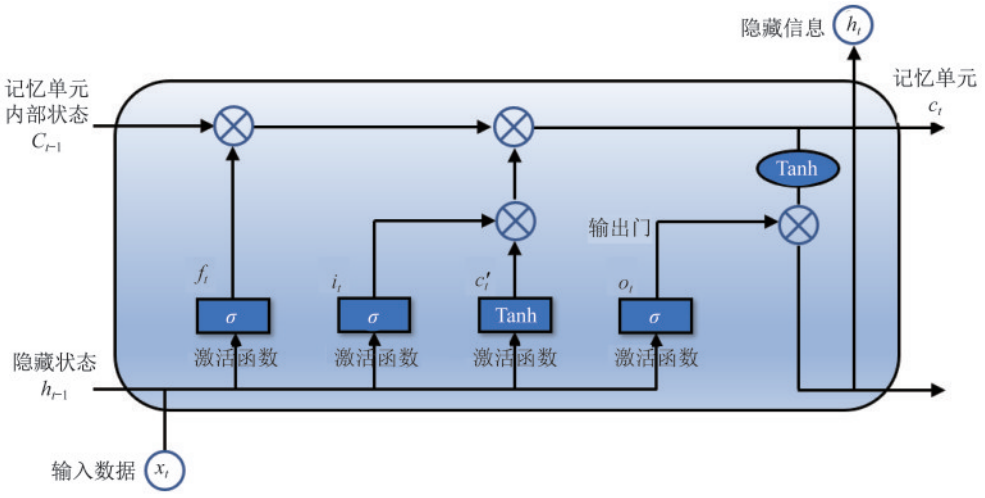


图1 LSTM原理图

Fig.1 Schematic diagram of the LSTM model

图1中相关的函数模型如式(11)—式(16)所示：

$$f_t=\sigma(W_f x_t+U_f h_{t-1}+b_f) \tag{11}$$

$$i_t=\sigma(W_i x_t+U_i h_{t-1}+b_i) \tag{12}$$

$$c_t'=\mathrm{Tanh}(W_c x_t+U_c h_{t-1}) \tag{13}$$

$$c_t=f_t c_{t-1}+i_t c_t' \tag{14}$$

$$h_t=o_t\,\mathrm{Tanh}(c_t) \tag{15}$$

$$o_t=\sigma(W_o x_t+U_o h_{t-1}+b_o) \tag{16}$$

式中：x_t表示该层在时刻t的输入数据；h_t表示该层在时刻t的隐藏信息；f_t表示遗忘门；i_t表示输入门；o_t表示输出门；c_t表示记忆单元。W和U表示权重，b表示偏置，σ表示Sigmoid激活函数，Tanh表示Tanh激活函数。

1.3 蜣螂优化算法改进LSTM模型

DBO-LSTM算法是一种结合了蜣螂优化算法

和长短期记忆网络的先进计算框架。LSTM 模型的性能高度依赖于多项参数的设置，包括层数、每层的神经元数量、批量大小等，选择合适的超参数组合对模型至关重要。为了解决 LSTM 网络中因超参数导致的模型不稳定问题，本文进一步引入 DBO 算法来优化和改进隐藏层节点数、初始学习率和正则化系数三个超参数，并通过多次迭代找到最优的超参数组合。综上所述，DBO 算法能够使 LSTM 模型在验证集上的预测误差最小化，从而提高预测精度和泛化能力。最终，本文所构建的 DBO-LSTM 桥梁环境温度及温度场预测模型的流程如图 2 所示。

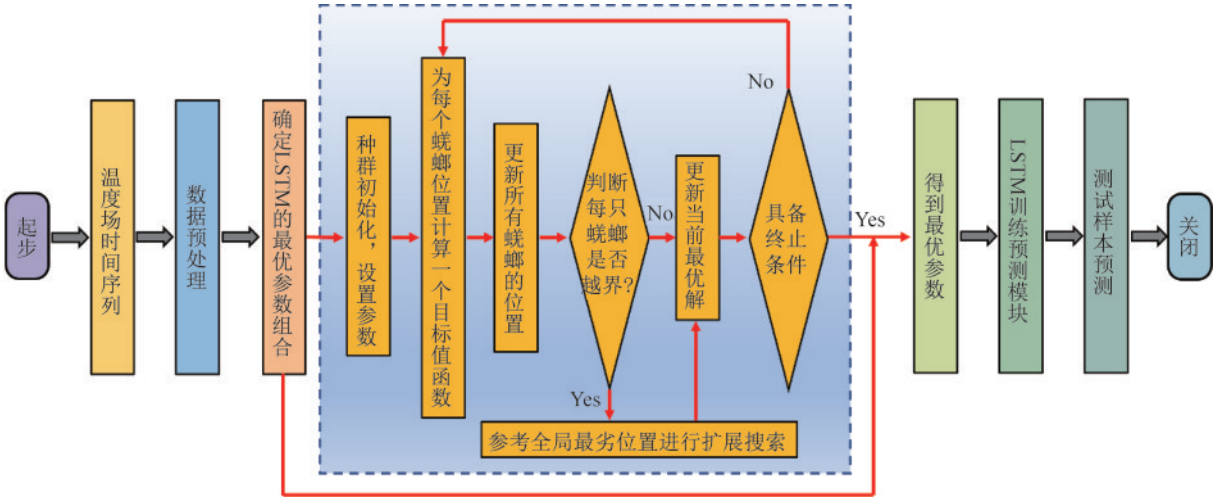


图 2　DBO-LSTM 混合模型原理图

Fig.2　Schematic diagram of the DBO-LSTM hybrid model

2　工程实例应用

2.1　工程概况

成绵立交桥是位于成都三环路与成绵高速公路十字交叉口处的一座全互通立交体系，共计包括 12 座桥梁，总长 2 798 m，桥梁设计荷载等级为城—A 级。其中，三环路主线桥为跨径 5×25+7×25+2×25+2×25+2×25+7×25+7×25（m）的单箱四室预应力混凝土连续梁桥，桥梁总长 816 m，共 7 联。主桥箱梁箱室宽 225 cm，腹板厚 40 cm，顶、底板厚 18 cm，梁体等高度为 140 cm。桥梁各分联间采用牛腿搭接，下部结构采用柱式桥墩，桥墩墩身直径为 1.3 m。墩梁简支墩采用单桩基础，墩梁固接墩采用单排双桩基础，桩基与墩柱间设承台连接。

2.2　长期监测系统

为研究主线桥外环幅温度及行车荷载作用下桥梁结构响应，对桥梁环境温度变化、伸缩缝位移变化及桥墩墩顶偏位进行长期监测，建立了桥梁整体位移的长期监测系统，如图 3 所示。该监测系统主要包括：传感设备、数据采集与传输、防护设备和监测软件平台。安装在现场的传感设备全天候实时监测桥梁的环境因素、力学参数、几何参数等运营环境及结构响应数据，通过采集传输设备将按设定频率采集的监测数据通过有线/无线网络传输到监控中心云平台，供对该桥长期监测进行定量分析评估使用。



图 3　桥梁健康监测系统示意图

Fig.3　Schematic diagram of the bridge health monitoring system

为实现对桥梁梁端伸缩缝位移、墩顶偏位及梁底应力情况进行实时监测，沿纵向选取第 3、4、5 联每跨梁端等 6 个截面［编号 D1—D6，图 4（a）］为梁端伸缩缝位移监测截面，每个截面布置 6 个

位移测缝计[图4(b)];选取第3、4、5联每跨跨中等6个截面[编号Y1—Y6,图4(a)]为应力监测截面,每个截面布置3个应力测点[图4(b)];选取15#墩盖梁及17-2#墩柱顶面下50 cm处等2个截面[编号P1—P2,图5(a)]为墩顶偏位监测截面,各布置4个倾角传感器[图5(b)]。

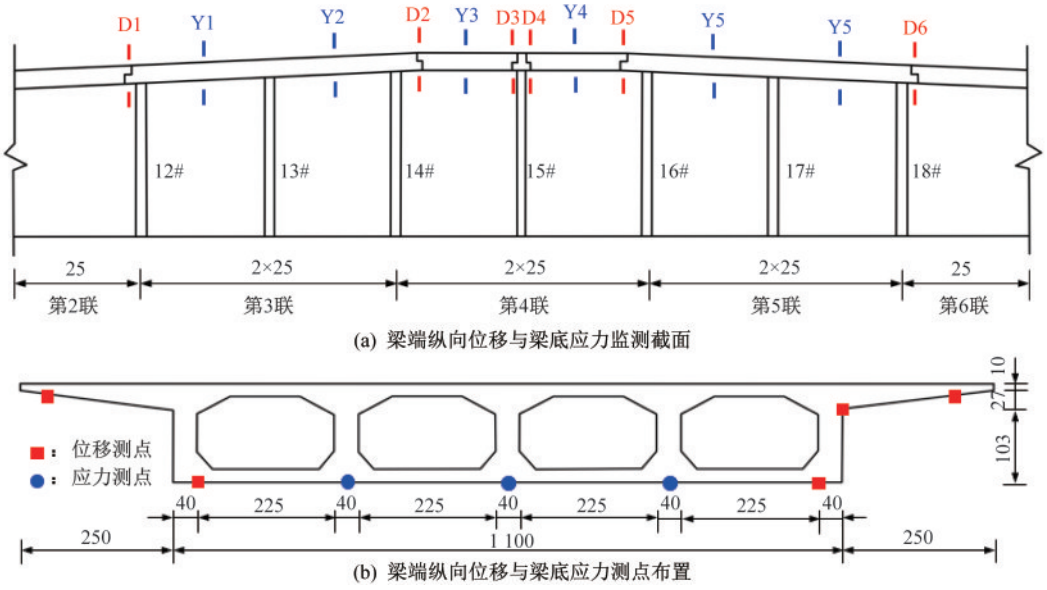


图4 梁端纵向位移与梁底应力监测截面及测点布置示意图[单位:m(a),cm(b)]

Fig.4 Schematic diagram of monitoring sections and measuring point layout for longitudinal displacement at beam ends and bottom beam stress [Unit: m(a),cm(b)]

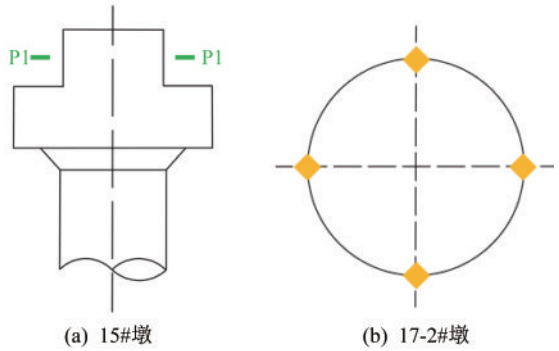


图5 15#墩和17-2#墩墩顶偏位测点布置示意图

Fig.5 Schematic diagram of the layout of measuring points for top deviation at pier 15 and pier 17-2

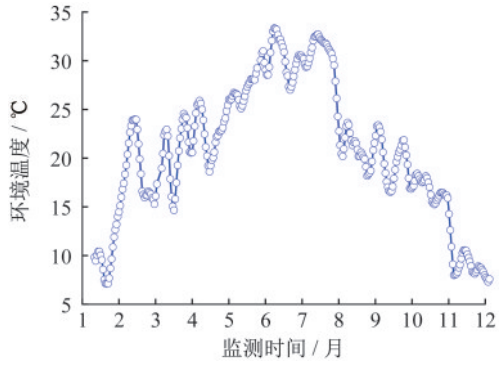


图6 环境温度监测曲线

Fig.6 Monitoring curve of ambient temperature

2.3 监测结果与分析

2.3.1 环境温度及伸缩缝位移

针对主线桥12#墩、14#墩、15#墩、16#墩、18#墩墩顶伸缩缝的监测数据,取2022年完整年度周期内的监测数据,绘制环境温度监测曲线及各桥墩伸缩缝位移时程曲线,如图6和图7所示。

由图6和图7可知,从数据长期变化角度来看,墩顶处梁体伸缩缝间隙与温度变化成反比,在各测点处环境温度最高时刻,各桥墩墩顶处梁体伸缩缝变化处于最大值;随着环境温度的降低,其

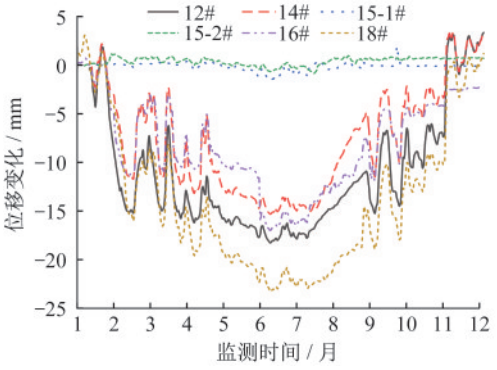


图7 伸缩缝位移监测曲线

Fig.7 Monitoring curves of expansion joint displacement

伸缩缝逐渐减小，并于测点处环境温度最低时刻恢复至基准位置。其中，12#墩、14#墩、15#墩小里程侧、16#墩、18#墩墩顶伸缩缝于7月9日达到最大值，分别为−18.49 mm、−15.51 mm、−1.56 mm、−17.27 mm 和 −23.55 mm，此时环境温度达到39.2 ℃，而15#墩大里程侧墩顶伸缩缝于10月30日环境温度为22.9 ℃时达到最大值5.17 mm。除15#墩大里程侧墩顶外，伸缩缝位移数据均为负值，表明相对于该状态，伸缩缝位移减小，主梁缩短。

2.3.2　主梁梁底应变

通过对主线桥各跨梁底应变进行监测，取2022年完整年度周期内的监测数据，绘制各跨中梁底应变曲线，如图8所示。由图8可知，随着环境温度的升高，各跨跨中梁底应变增大。其中，当环境温度升高时，第13#、14#、16#跨跨中梁底应变为正，梁底受拉；第15#、17#、18#跨跨中梁底应变为负，梁底受压。对年度监测周期内各跨梁底应变变化最大值及其对应的环境温度及时间节点进行分析，分析结果见表1。由表1可知，主线桥各跨跨中梁底应变变化最大值在(43.61~88.18)×10^{-6}范围内；其应变变化最小值在(−40.95~−13.72 με)×10^{-6}范围内，应变变化量在合理范围内，梁体处于安全状态。

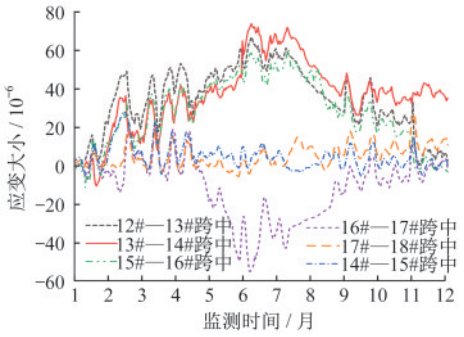


图8　主梁跨中梁底应变监测曲线

Fig.8　Monitoring curves of mid-span bottom strain of the main girders

表1　梁底应变变化最大值及其对应的环境温度及时间节点

Table 1　Maximum bottom beam strain variation with corresponding ambient temperatures and times

位置	应变变化					
	最大值/×10^{-6}	时间	环境温度/℃	最小值/×10^{-6}	时间	环境温度/℃
12#—13#跨中	45.96	2022/11/30	5.95	−26.57	2022/9/28	28.01
13#—14#跨中	79.23	2022/7/8	36.25	−13.72	2022/2/21	5.98
14#—15#跨中	43.61	2022/5/14	14.20	−30.58	2022/4/8	20.29
15#—16#跨中	62.69	2022/7/9	37.65	−28.36	2022/2/15	15.01
16#—17#跨中	88.18	2022/4/30	18.48	−25.91	2022/2/26	9.12
17#—18#跨中	64.11	2022/11/30	5.68	−40.95	2022/6/5	27.26

注：应变变化以梁底受拉为正，受压为负。

2.3.3　墩顶偏位

采用高精度倾角仪对主线桥关键墩柱墩顶纵桥向及横桥向偏位角度进行监测，以横桥向往市中心方向为正，纵桥向向大里程侧为正。以此为基础，得到监测周期内主线桥关键墩柱墩顶偏位倾角变化曲线，如图9所示。

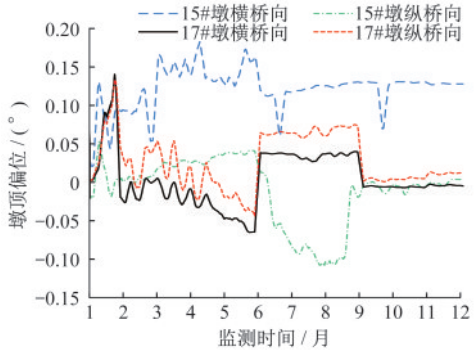


图9　墩顶偏位监测曲线

Fig.9　Monitoring curves of pier top deviation

由图9可知，15#墩及17#墩墩顶横向偏位及纵向偏位变化趋势基本一致。15#墩墩顶横向偏位最大值及最小值分别为0.28°、0.02°，纵向偏位最大值、最小值分别为0.07°、−0.30°；17#墩墩顶横向偏位最大值及最小值分别为0.19°、−0.33°，纵向偏位最大值及最小值分别为0.09°、−0.15°。由此可知，桥墩墩顶偏位值在合理范围内，梁体处于安全状态。

3　桥梁环境温度及温度效应预测

3.1　数据预处理

为显著提升数据处理和模型分析的准确性与效率，对基于长期健康监测的桥梁环境温度和温度效应数据进行以下处理：

（1）长期监测数据中难免存在噪声或异常

值，这些极端值会对数据分析带来较大影响。对其进行平滑处理，可以在一定程度上降低这些极端值的影响，使模型对异常值不那么敏感，提高分析结果的稳定性和准确性。

（2）数据连续性对于分析结果的稳定性和可靠性非常关键。在长期监测过程中数据可能会因为短期内的严重环境变化（如极端天气事件）或在数据传输过程中的技术干扰（如信号丢失）而出现丢失，由于桥梁的温度及温度效应参数在短时间内变化不大，所以采用相邻时间点的数据对缺失数据进行替代。

（3）温度和温度效应数据通常具有不同的物理量纲和数量级。温度可能在几十摄氏度的范围内变化，而温度效应（应力、位移）是微小变化。通过标准化处理，可以将这些数据映射到统一的范围，消除量纲差异的影响，使模型不受数据量级差异的干扰，更专注于识别数据间的相对变化关系。归一化公式如下：

$$X_{\text{norm}}=\frac{X-X_{\min}}{X_{\max}-X_{\min}}\times\left(r_{\max}-r_{\min}\right)+r_{\min} \tag{17}$$

式中：X为原始数据；$X_{\min}$和$X_{\max}$分别为原始数据的最小值和最大值；$r_{\min}$和$r_{\max}$是标准化后的目标范围；X_{norm}为标准化后数据。

（4）在数据分析程序的最后阶段进行逆归一化处理，从而将模型的预测结果还原到原始数据的尺度，使得结果更具解释性和实用性。归一化数据虽然适合算法处理，但缺乏直观性，尤其在温度、位移等具有实际物理意义的数据中，预测结果应当回归到具体的单位制和范围上，使预测结果能够直观地反映数据的大小和变化趋势。

3.2 模型参数与评价指标

本文构建了一个DBO-LSTM混合模型以预测桥梁的温度及温度效应，其中模型样本总数为320，训练集取70%，预测集取30%。采用DBO算法对隐藏层节点数、初始学习率和L2正则化系数三个超参数进行优化和改进，其设置范围见表2。在DBO算法中，设置种群数量为40，最大迭代次数为12。为在性能和训练时间之间取得平衡，避免过拟合或欠拟合状态的发生，将时间步长设置为3，批次大小设置为64，并采用Adam作为训练优化器。

为准确评估预测模型的准确性，引入决定系数（Coefficient of Determination，R^2）和平均绝对百分比误差（Mean Absolute Percentage Error，MAPE）对模型进行评价。桥梁环境温度和温度效应数据往往具有显著的趋势性和周期性波动，决定系数R^2反映了模型对数据变异的解释能力，数值范围在[0,1]之间，其能够量化模型具体在某种程度上捕捉了这些变动趋势。MAPE是一种基于百分比的误差指标，衡量预测值与实际值的相对偏差。较低的MAPE值表明模型在各个数据点上的预测误差较小，这对桥梁健康监测中的异常检测和风险预警等应用具有重要意义。评价指标的计算公式为

表2 基于DBO算法的超参数设置

Table 2 Configuration of hyperparameters optimized by the DBO algorithm

模型参数	数值范围
隐藏层节点数	[10, 100]
初始学习率	[1×10^{-6}, 0.002]
L2正则化系数	[1×10^{-8}, 0.01]

$$R^2=1-\frac{\sum\left(y_i-\hat{y}_i\right)^2}{\sum\left(y_i-\bar{y}\right)^2} \tag{18}$$

$$\text{MAPE}=\frac{1}{n}\sum\left|\frac{y_i-\hat{y}_i}{y_i}\right|\times 100\% \tag{19}$$

式中：y_i为实际值；$\hat{y}_i$为预测值；$\bar{y}$为实际值的平均值；i为样本序号；n为样本数量。

3.3 模型预测结果分析

基于长期监测系统中为期一年的监测数据，采用已建立的DBO-LSTM混合模型对桥梁的温度及温度效应进行预测，预测结果如图10—图13、表3所示（为清晰直观地展现模型的预测效果，仅给出每种评估类型中一条代表性曲线的预测结果）。

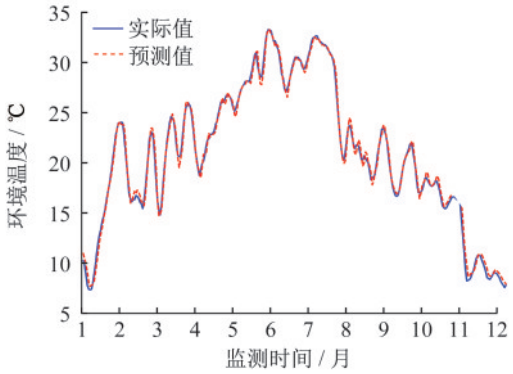


图10 环境温度监测曲线

Fig.10 Monitoring curves of ambient temperature

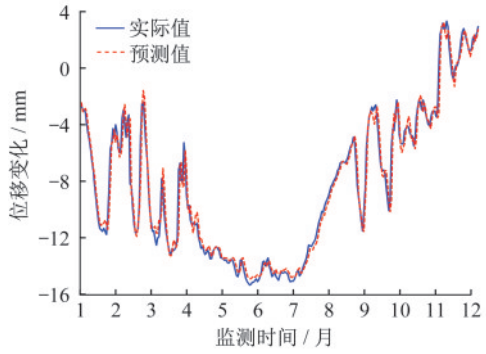


图 11　14#伸缩缝位移监测曲线

Fig.11　Monitoring curves of expansion joint displacement at pier 14

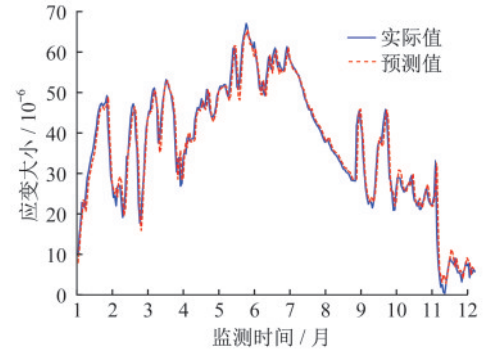


图 12　12#—13#主梁跨中梁底应变监测曲线

Fig.12　Mid-span bottom strain monitoring curves between piers 12 and 13

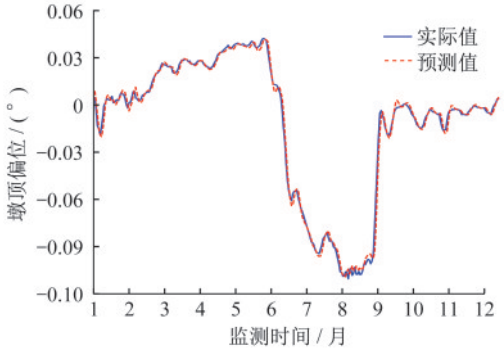


图 13　15#纵桥向墩顶偏位监测曲线

Fig.13　Monitoring curves of longitudinal top deviation at pier 15

由图 10—图 13 可以看出，基于 DBO-LSTM 混合模型对桥梁环境温度、伸缩缝位移、梁底应变和墩顶偏位进行预测所得的预测值与实际值之间的误差较小，预测值曲线和实际值曲线在数值大小上相差不大，在趋势走向上完全一致。由表 3 可知，DBO-LSTM 混合模型对桥梁环境温度的预测效果最优。在对 4 种不同类型温度及温度效应的预测中，最大回归系数 a_{max} 为 0.992，最小回归系数 a_{min} 为 0.952；最大回归系数 b_{max} 为 1.766，最小回归系数 b_{min} 为 −0.127；最大决定系数 R^2_{max} 为 0.995，最小决定系数 R^2_{min} 为 0.966；最大 MAPE 值为 0.38，最小 MAPE 值为 0.02。其中，所有评估项的回归系数 a 与决定系数 R^2 均趋近于 1，回归系数 b 趋近于 0 且 MAPE 值均小于 0.5，表明采用 DBO-LSTM 混合模型对桥梁环境温度和温度效应进行预测具有良好的精度，可用于桥梁长期温度及温度效应预测。

表 3　各参数预测评估结果

Table 3　Evaluation results of prediction performance for each parameter

评估项	回归系数		R^2	MAPE
	a	b		
温度	0.979	0.496	0.995	0.02
伸缩缝位移	0.982	−0.127	0.981	0.24
梁底应变	0.952	1.766	0.966	0.18
墩顶偏位	0.992	−0.000 2	0.995	0.38

为进一步验证所提出模型的预测性能及优越性，本文分别选取 BP 神经网络、LSTM、CNN-LSTM、Bi-LSTM 以及所提出的 DBO-LSTM 模型，对环境温度的预测结果进行了对比分析，如图 14 所示。将不同模型预测结果的评价指标（MAPE、RMSE、MAE）进行对比，对比结果见表 4，其中均方根误差（RMSE）和平均绝对误差（MAE）的计算公式如下：

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2} \tag{20}$$

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{21}$$

式中：y_i 为实际值；$\hat{y}_i$ 为预测值；$\bar{y}$ 为实际值的平均值；i 为样本数量。

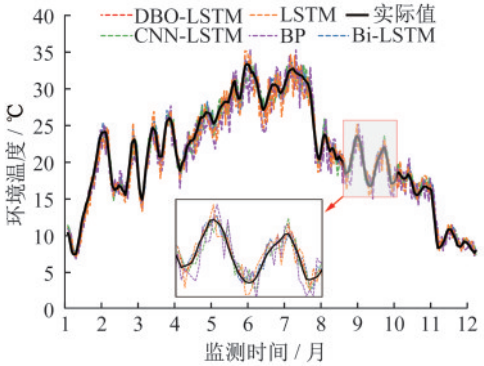


图 14　各模型环境温度预测值与实测值间差异

Fig.14　Differences between predicted and measured values of environmental temperature for each model

表4 环境温度预测模型评价表

Table 4 Evaluation of environmental temperature prediction models %

模型	MAPE	RMSE	MAE
BP	0.687	1.689	1.374
LSTM	0.056	1.374	1.122
CNN-LSTM	0.045	1.078	0.884
Bi-LSTM	0.034	0.816	0.663
DBO-LSTM	0.023	0.506	0.397

由图14可知，DBO-LSTM模型的预测曲线与实测曲线贴合度最高，表现出最佳的拟合效果；而BP、LSTM和CNN-LSTM模型的预测曲线与实测曲线存在不同程度的波动，说明上述三种模型的预测精度和稳定性均不及DBO-LSTM模型。此外，由表4可知，在5个用于环境温度预测的模型中，本文提出的DBO-LSTM模型预测精度最高，其MAPE、RMSE和MAE值分别为0.023、0.506和0.397。BP神经网络模型的预测误差最大，这是由于其为传统的浅层网络，难以有效捕获温度序列的复杂非线性变化规律；LSTM模型通过长短期记忆单元结构，能够较好地学习序列数据的长期依赖关系，预测误差显著降低，但与其他模型相比仍有较大差距。CNN-LSTM模型通过卷积操作提取局部特征，在预测精度上进一步提升，但仍不及Bi-LSTM模型。Bi-LSTM模型利用双向信息传播结构，比LSTM和CNN-LSTM模型的预测效果好。然而，本文所提的DBO-LSTM模型在LSTM的基础上引入蜣螂优化算法，对模型参数进行有效优化，使其预测准确性明显优于另外4个模型，说明所提出的DBO-LSTM模型在环境温度预测任务中具有更强的特征捕获能力、更高的预测精度以及更好的泛化性能。

4 结 论

本文针对成绵立交三环路主线桥的温度及温度效应问题，依托长期监测系统采集的环境温度和结构响应数据，开展了桥梁温度效应特性分析与预测模型研究。通过构建基于蜣螂优化算法优化LSTM超参数的DBO-LSTM混合模型，对温度及温度效应进行高精度预测，并将其与传统预测模型进行性能对比与验证。主要结论如下：

（1）根据长期监测数据分析，桥梁伸缩缝变化量、主梁梁底应变及墩顶转角变化量均较小，表明桥梁结构整体处于安全状态。

（2）DBO-LSTM混合模型能够有效优化LSTM的隐藏层节点数、初始学习率和L2正则化系数等超参数，获得最优超参数组合，从而显著提升模型的预测性能。

（3）DBO-LSTM模型在不同类型预测项中的决定系数R^2最高达0.995，最低为0.966；MAPE值最高为0.38，最低为0.02，说明该模型预测精度较高，可用于长期监测基础上的温度及温度效应预测。

（4）与BP、LSTM、CNN-LSTM和Bi-LSTM等模型对比，DBO-LSTM模型对环境温度的预测精度最高，其MAPE、RMSE和MAE值分别为0.023、0.506和0.397。结果表明，引入蜣螂优化算法有效增强了模型的特征捕获能力、预测精度和泛化性能，适用于桥梁温度效应的高精度预测。

参 考 文 献

[1] 占玉林，斯睿哲，臧亚美.混凝土桥梁耐久性2020年度研究进展[J].土木与环境工程学报（中英文），2021，43(S1)：100-106.
Zhan Yulin，Si Ruizhe，Zang Yamei.Research progress in durability of concrete bridges in 2020[J].Journal of Civil and Environmental Engineering（Chinese and English），2021，43(S1)：100-106.(in Chinese)

[2] 廖聿宸，张坤，杜孟林，等.基于长期监测的开口截面组合梁斜拉桥温度场分析[J].东南大学学报（自然科学版），2023，53(6)：1080-1090.
Liao Yuchen，Zhang Kun，Du Menglin，et al. Temperature field analysis of cable-stayed bridge with composite girders of open sections based on long-term monitoring [J]. Journal of Southeast University（Natural Science Edition），2023，53(6)：1080-1090.(in Chinese)

[3] 周云，危俊杰，李剑，等.基于InSAR技术的大跨桥梁温度变形监测研究[J].湖南大学学报（自然科学版），2024，51(3)：39-50.
Zhou Yun，Wei Junjie，Li Jian，et al. Monitoring of temperature deformation of long-span bridges based on InSAR technology [J]. Journal of Hunan University（Natural Science Edition），2024，51(3)：39-50.(in Chinese)

[4] 卫俊岭，王浩，茅建校，等.混凝土连续箱梁桥温度场数值模拟及实测验证[J].东南大学学报（自然科学版），2021，51(3)：378-383.
Wei Junling，Wang Hao，Mao Jianxiao，et al.Numerical

simulation and field verification of temperature field in continuous concrete box girder bridges[J]. Journal of Southeast University (Natural Science Edition), 2021, 51(3): 378-383.(in Chinese)

[5] 张玉平,李思阳,李传习,等.基于气象参数的钢箱梁竖向温度梯度模式[J].公路交通科技,2025,42(1):147-155.
Zhang Yuping, Li Siyang, Li Chuanxi, et al. Vertical temperature gradient pattern of steel box girders based on meteorological parameters [J]. Highway and Transportation Technology, 2025, 42(1): 147-155.(in Chinese)

[6] 胡安庆,邓长军,任东华,等.某立交匝道桥墩梁"抵触"病害长期监测分析[J].公路,2021,66(10):118-124.
Hu Anqing, Deng Changjun, Ren Donghua, et al. Long-term monitoring and analysis of pier-girder "conflict" damage in a ramp bridge of an interchange [J]. Highway, 2021, 66(10): 118-124.(in Chinese)

[7] 郭桥,梁柱,沈国栋,等.基于知识图谱及机器学习的桥梁病害智能诊断方法[J].公路,2023,68(10):329-334.
Guo Qiao, Liang Zhu, Shen Guodong, et al. Intelligent diagnosis method for bridge diseases based on knowledge graph and machine learning[J]. Highway, 2023, 68(10): 329-334.(in Chinese)

[8] 朱颖,郭辉,孙大奇,等.运营期公铁两用悬索桥温度效应研究[J].铁道学报,2024,46(6):156-166.
Zhu Ying, Guo Hui, Sun Daqi, et al. Study on temperature effects of highway-railway suspension bridges during operation period [J]. Journal of the China Railway Society, 2024, 46(6): 156-166. (in Chinese)

[9] 郭风俊.基于ANSYS的不平衡日照混凝土箱梁温度场分布研究[J].西安建筑科技大学学报(自然科学版),2020,52(2):207-212.
Guo Fengjun. Study on temperature field distribution of concrete box girders under uneven solar radiation based on ANSYS [J]. Journal of Xi'an University of Architecture & Technology (Natural Science Edition), 2020, 52(2): 207-212.(in Chinese)

[10] 陈鹏,郭佳,张俊豪,等.整体式T梁桥温度荷载效应可靠性概率评价[J].公路交通科技,2023,40(6):140-147.
Chen Peng, Guo Jia, Zhang Junhao, et al. Probabilistic reliability assessment of temperature load effects in integral T-beam bridges [J]. Highway and Transportation Technology, 2023, 40(6): 140-147.(in Chinese)

[11] 刘扬,向胜涛,王达.基于BP-LSTM混合模型的钢-混组合桥面系空间温度场及温度效应实时评估及预测[J].土木工程学报,2021,54(11):57-70,78.
Liu Yang, Xiang Shengtao, Wang Da. Real-time assessment and prediction of spatial temperature field and temperature effect of steel-concrete composite bridge deck system based on BP-LSTM hybrid model [J]. China Civil Engineering Journal, 2021, 54(11): 57-70, 78.(in Chinese)

[12] 惠迎新,孙晓荣,王红雨,等.大跨变截面混凝土箱梁施工期温度效应研究[J].公路交通科技,2023,40(1):98-105.
Hui Yingxin, Sun Xiaorong, Wang Hongyu, et al. Study on temperature effects during construction of long-span variable-section concrete box girders [J]. Highway and Transportation Technology, 2023, 40(1): 98-105.(in Chinese)

[13] 聂华伟,应江虹,邓捷.基于Bi-LSTM模型的桥梁健康监测挠度预测方法[J].公路,2024,69(10):213-219.
Nie Huawei, Ying Jianghong, Deng Jie. Deflection prediction method for bridge health monitoring based on Bi-LSTM model[J]. Highway, 2024, 69(10): 213-219.(in Chinese)

[14] 方佳畅,黄天立,李苗,等.基于迁移学习和Bi-LSTM神经网络的桥梁温度-应变映射建模方法[J].振动与冲击,2023,42(12):126-134,186.
Fang Jiachang, Huang Tianli, Li Miao, et al. Bridge temperature-strain mapping modeling method based on transfer learning and Bi-LSTM neural network[J]. Journal of Vibration and Shock, 2023, 42(12): 126-134, 186.(in Chinese)

[15] Yue Z, Ding Y, Zhao H, et al. Mechanics-guided optimization of an LSTM network for real-time modeling of temperature-induced deflection of a cable-stayed bridge[J]. Engineering Structures, 2022, 252: 113619.

[16] 黄孝彬,王永凯.基于改进蜣螂优化算法的电站NO_x排放预测[J].科学技术与工程,2024,24(23):9929-9936.
Huang Xiaobin, Wang Yongkai. Prediction of power plant NO_x emissions based on improved dung beetle optimization algorithm [J]. Science Technology and Engineering, 2024, 24(23): 9929-9936.(in Chinese)

[17] Xue J, Shen B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization [J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.

[18] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.