

DOI: 10.11835/j.issn.2096-6717.2025.079



开放科学(资源服务)标识码 OSID:



基于 GA 优化的 CNN-BiLSTM-Attention 箱梁 离散点温度预测模型

王雨辰^a, 张方^{a,b}, 袁俊杰^a, 林诗晨^a, 丛龙宇^a

(西南交通大学 a. 土木工程学院; b. 桥梁智能与绿色建造全国重点实验室, 成都 611756)

摘要: 混凝土箱梁桥长期受非均匀温度场作用, 易因温度应力诱发裂缝与变形, 严重威胁结构的安全性与耐久性, 而精准的温度场预测是实时监测、损伤预警与防控的关键基础。为解决多气象特征下离散点温度预测精度不足的问题, 提出一种基于遗传算法(GA)优化的 CNN-BiLSTM-Attention 时序模型: 通过双向长短期记忆网络(BiLSTM)捕捉时间序列的正逆向依赖关系, 结合卷积神经网络(CNN)提取局部空间特征, 并引入自注意力机制(Attention)动态分配气象参数的权重, 强化关键特征对温度变化的敏感性; 同时, 利用 GA 优化模型超参数(隐藏单元数、学习率等), 以提升预测稳定性与泛化能力。基于南充嘉陵江特大桥实测数据的验证结果表明, 该模型在短期(S1 测段)与长期(S2 测段)预测中均显著优于传统模型, RMSE 分别低至 0.178 和 0.129, 决定系数 R^2 接近 0.99, 较 LSTM、BiLSTM 等基线模型误差降低 20% 以上, 且对温度峰值的捕捉能力显著增强。研究证明, 融合时空特征与动态权重分配的混合模型能有效解析复杂气象耦合机制, 为桥梁结构健康监测提供高精度温度场预测工具, 对提升基础设施服役寿命与安全运维水平具有重要意义。

关键词: 混凝土箱梁桥; 箱梁温度预测; 遗传算法(GA); 气象特征; 模型评估; 超参数优化

中图分类号: U448.34 **文献标志码:** A **文章编号:** 2096-6717(XXXX)XX-0001-11

GA-optimized CNN-BiLSTM-Attention for discrete-point temperature prediction model of box girders

WANG Yuchen^a, ZHANG Fang^{a,b}, YUAN junjie^a, LIN shichen^a, CONG longyu^a

(a. School of Civil Engineering; b. National Key Laboratory of Bridge Intelligent and Green Construction, Southwest Jiaotong University, Chengdu 611756, P. R. China)

Abstract: Concrete box-girder bridges subjected to non-uniform temperature fields are prone to thermal stress-induced cracks and deformation, which seriously threaten structural safety and durability. Accurate prediction of the temperature field serves as the critical foundation for real-time monitoring, damage early warning, and preventive mitigation strategies. To address the insufficient accuracy of discrete-point temperature predictions

收稿日期: 2025-04-14

基金项目: 国家自然科学基金(51778532)

作者简介: 王雨辰(1999-), 男, 主要从事桥梁温度场预测及深度学习研究, E-mail: 1918349229@qq.com。

张方(通信作者), 男, 博士, E-mail: fangzhang@home.swjtu.edu.cn。

Received: 2025-04-14

Foundation item: National Natural Science Foundation of China (No. 51778532)

Author brief: WANG Yuchen (1999-), main research interest: bridge temperature field prediction and deep learning, E-mail: 1918349229@qq.com.

ZHANG Fang (corresponding author), PhD, E-mail: fangzhang@home.swjtu.edu.cn.

under multi-factor meteorological features, this study proposes a GA-optimized CNN-BiLSTM-Attention temporal model. The model integrated Bidirectional Long Short-Term Memory (BiLSTM) networks to capture bidirectional temporal dependencies in time-series data, and integrated Convolutional Neural Networks (CNN) to extract localized spatial features from time-series data, while further incorporating a self-attention mechanism to dynamically assign weights to meteorological parameters, thereby enhancing sensitivity to critical features driving temperature variations. Concurrently, GA is employed to optimize hyperparameters (the number of hidden units, learning rate, etc.) to improve prediction stability and generalization capability. Validation results based on field monitoring data from Nanchong Jialing River Bridge demonstrated that the model's superior performance in both short-term (S1 segment) and long-term (S2 segment) predictions, achieving RMSE values as low as 0.178 and 0.129 respectively, with the coefficient of determination (R^2) approaching 0.99. Compared to baseline models (e.g., LSTM, BiLSTM), the error reduction exceeds 20%, while its capability to capture temperature peaks exhibited substantial enhancement. This research validated that the hybrid model integrating spatiotemporal feature fusion and dynamic weight allocation effectively could resolve complex meteorological coupling mechanisms, while providing a high-precision temperature field prediction tool for bridge structural health monitoring. This advancement possessed significant engineering implications for enhancing infrastructure service life and advancing safety-oriented operation and maintenance practices.

Keywords: concrete box-girder bridges; temperature prediction in box girders; genetic algorithm (GA); meteorological characteristics; model evaluation; hyperparameter optimization

近年来,随着大数据时代的来临和机器学习技术的不断普及,学者们开始借助神经网络对温度场进行有针对性的时间序列预测,如RNN循环神经网络模型和LSTM长短时记忆网络模型等。如何更准确、更有效地对温度场进行时序预测和状态评估成为当下混凝土箱梁温度场研究炙手可热的话题。

Xia等^[1]预测了大跨桥梁整体结构在年、月、日多时间尺度上的温度、温差和日照辐射的分布模型。吴颖峰^[2]利用连续小波变换法对温度监测数据提取了传感器失真数据特征,并借助RNN循环神经网络模型建立了失真数据诊断的模型。Zhao等^[3]基于双向长短期记忆回归网络对分布特征参数大数据的学习建立了结构温度场到温度应变场的映射关系模型,并分析了模型回归结果与实时监测结果的残差。张云必^[4]借助LSTM神经网络模型,利用自适应算法预估了桥址位置、太阳辐射量、风向及风速等参数和温度场的映射关系,并通过贝叶斯算法优化了超参数,预测了高原地区连续刚构箱梁的温度场。陈钰萌^[5]针对实测数据成本高及耗时的问題,借助于LSTM模型结合气象参数建立了桥梁离散点温度预测模型,同时借助于结构尺寸和环境参数建立了可预测箱梁热边界条件的MLP-LSTM通用神经网络模型。张洁^[6]借助于LSTM神经网络模型,结合贝叶斯优化,对箱梁测点温度和应变进行预测,同时确定各个测点应变预测的LSTM模型层数和历史观测适合

时长。

当前的时序预测模型大多基于RNN循环神经网络模型和LSTM长短时记忆网络模型,但仅靠单一模型预测出的时序状态完成度和准确度都有待提高。笔者基于LSTM模型引入遗传算法(GA)进行超参数优化,引入卷积神经网络(CNN)捕捉时间序列中的空间特征,引入自注意力机制(Attention)对各特征进行权重分配,突出关键特征,从全局方面把控各个特征对输出值的依赖关系,从而提高模型整体的预测精度,为实际工程提供有力参考。

1 研究概况与数据来源

1.1 工程概况

该混凝土箱梁桥位于四川省南充市高坪区(106.18°E, 30.91°N),所处地域为亚热带季风气候。桥梁采用(105+200+105)m连续刚构,呈西北-东南走向,纵向轴线与南北方向夹角22.7°,主梁采用C60混凝土。在16号墩右幅13#块和17号墩左幅7#块以5 min/次的频率观察箱梁温度变化,观测起止日期为2022-05-28—2022-08-20,在截面布置一系列JM165-Z1Q型温度传感器,测点温度由温度采集仪自动记录。为避免数据过少带来的偶然偏差,提高可靠性,共布置30个测点。其中,顶板测点10个,左右腹板测点16个,底板测点4个。截面温度测点布置如图1所示。

1.2 实测温度数据

对箱梁顶板B系列测点温度值进行预测。实际




图1 温度测点布置图

Fig. 1 Layout of temperature measurement points

监测过程中容易出现记录异常或仪器断电等突发状况,导致部分传感器数据缺失或失真。对于正常记录的数据,由于观测时间中断过长等问题同样对于预测精度有所影响。

箱梁 7#块和 13#块的温度数据采集频率为 5 min,单位为℃。首先对原始数据进行人为筛选(周期为一星期及以上且间断时长不超过 2 d 的数据),得到具有一定质量的数据,筛选出的原始数据信息如表 1 所示。

表 1 温度测点选取和时间段汇总

Table 1 Summary of temperature measurement points and time periods

截面编号	测点编号	时间段
7#	B1、B2	2022-06-16—2022-06-24
13#	B1、B2	2022-07-20—2022-08-20

1.3 桥址区气象数据

结合文献[6],选取的气象数据包括:大气温度 T 、大气压强 P 、相对湿度 U 、风速 F 、露点温度 T_d 以及太阳辐射强度 I 。其中,大气温度 T 、大气压强 P 、相对湿度 U 、风速 F 、露点温度 T_d 通过世界天气网站获取高坪区气象站数据,太阳辐射强度 W 则通过 SunCalc 网站获取。各气象参数采样频率和获取来源见表 2。

表 2 气象参数采样频率和获取来源

Table 2 Sampling frequency and data sources of meteorological parameters

气象参数	单位	采样频率	数据来源
T	℃	1 h/次	世界天气
P	Pa	1 h/次	世界天气
U	%	1 h/次	世界天气
F	m/s	1 h/次	世界天气
T_d	℃	1 h/次	世界天气
I	W/m ²	1 h/次	SunCalc

由表 2 可知,气象参数的采样频率远低于温度测点的采样频率,为了保持数据的一致性以获得更准确的预测结果,将每次采样的气象数据代表 1 h 内的所有值^[7]。

2 基于 Hampel 滤波器的数据降噪过滤

在原始数据的基础上,有必要对数据进行降噪过滤操作,特别是针对样本容量较大的数据而言,数据降噪过滤不可或缺。数据中的离群值、噪声等对模型的预测精度会产生较大影响,通过降噪过滤可以有效提高数据质量,从而更好地完成预测任务。Hampel 滤波器基于中值和中值绝对偏差(MAD),旨在识别和去除时序数据的异常值,且相对于传统均值和标准差方法更具鲁棒性^[8]。

将 2022-06-16—2022-06-24 中 7#块 B1、B2 温度数据和 7.20~8.20 中 13#块 B1、B2 温度数据进行降噪处理,默认阈值设置为 1,处理结果对比和离群值筛选情况如图 2 和图 3 所示。




图 2 7#块温度降噪过滤结果对比

Fig. 2 Comparison of temperature denoising and filtering results for Block 7#

由图 2 和图 3 可知,原始数据的质量较高,温度离群值主要判定在温度峰值位置,Hampel 滤波器对离群值做了平滑处理,在一定程度上保证了数据的平稳性,进而提高数据质量。同时可以发现,初始值容易被误判为离群值处理,但因为 Hampel 滤波器的特性,即使被识别为离群值,数据也会被合理值代替,不会破坏数据的完整性。




图3 13#块温度降噪过滤结果对比

Fig. 3 Comparison of temperature denoising and filtering results for Block 13#

3 参数相关性分析

3.1 太阳辐射温度换算及其他气象参数

箱梁温度应力的影响主要来源于混凝土内部和表面温度,而顶板与外界环境的热交换形式主要通过太阳辐射实现,由文献[9]可知,箱梁顶板外表面的太阳辐射温度可由大气温度和太阳辐射强度经式(1)进行换算。

$$T_z = T + A_s I / h \quad (1)$$

式中: T 为大气温度; A_s 为物体短波辐射吸收率,取0.70; I 为箱梁表面接收的太阳辐射强度; h 为综合热交换系数。

其中,大气温度 T 和箱梁表面接收的太阳辐射强度 W 可通过气象站直接获取。根据文献[9-10]取顶板外表面综合热交换系数 $h=14.30 \text{ W}/(\text{m}^2 \cdot ^\circ\text{C})$ 。

截取S1和S2测段两个时段下的气象数据,如图4~图8所示。

3.2 相关系数分析

生成各特征与输出测点温度之间的person相关系数矩阵如图9所示。相关系数取值在-1~1之间,相关系数越接近1说明该特征与输出值之间有越强的正相关性,反之该特征与输出值之间有越强的负相关性^[11]。

由最后一列测点温度的相关性排序可知,与测




图4 S1和S2测段下的大气温度与露点温度

Fig. 4 Solar irradiance temperature in S1/S2 segments






图5 S1和S2测段下的水平大气压

Fig. 5 Horizontal barometric pressure in S1/S2 segments




(a) S1测段




(b) S2测段

图6 S1和S2测段下的空气相对湿度
Fig. 6 Relative humidity in S1/S2 segments




(a) S1测段




(b) S2测段

图8 S1和S2测段下的露点温度
Fig. 8 Dew point temperature in S1/S2 segments



(a) S1测段



(b) S2测段

图7 S1和S2测段下的水平风速
Fig. 7 Horizontal wind speed in S1/S2 segments




图9 特征值和测点温度之间的相关系数矩阵
Fig. 9 Correlation matrix between feature values and measured temperatures

点温度正相关程度从大到小依次为大气辐射温度>风速>露点温度>大气压强/相对湿度。其中风速和露点温度与测点温度的相关性较弱。测点温度与大气辐射温度存在较强的正相关,相关系数达到0.8;与压强和相对湿度存在较明显的负相关,相关系数均为-0.8。

4 时序模型构建

4.1 卷积神经网络

卷积神经网络(CNN)在信号分类和模式识别任务中表现出色,主要得益于其在空间局部关系识别方面的优势以及参数数量的减少,这降低了计算

复杂性。该架构通常由输入层、卷积层、激活函数、池化层、全连接层和输出层组成^[12],如图 10 所示。




图 10 CNN 处理过程示意图

Fig. 10 CNN processing schematic

4.2 长短时记忆神经网络

4.2.1 长短时记忆神经网络(LSTM)

长短时记忆神经网络(LSTM)是循环神经网络(RNN)的修改版本。“长短期记忆”这个名字表明它可以灵活地桥接相应任务的长时间滞后或短时间滞后。该架构通常由输入层、LSTM层、全连接层、回归输出层组成^[13]。

LSTM层的架构由 4 个门组成,分别称为遗忘门(f_t)、更新门(u_t)、输入门(i_t)和输出门(o_t),以及一个称为 cell 的存储单元。LSTM 非常适合处理和预测具有未知持续时间的时间滞后的时间序列, LSTM 的详细实现如图 11 所示。




图 11 LSTM 层详细示意图

Fig. 11 Detailed schematic of the LSTM layer

4.2.2 双向长短时记忆神经网络(BiLSTM)

LSTM 网络通过引入记忆单元合门机制达到捕捉序列中的长期依赖关系的效果,但是其仅针对于前向传播,缺少对前后逻辑的把控。双向长短时记忆神经网络(BiLSTM)在 LSTM 的基础上通过前向和反向传播进行双向运算,从而达到加深记忆,提高准确率的效果^[14]。BiLSTM 网络如图 12 所示。

4.3 自注意力机制

在对时序数据进行多特征预测时,并非所有特征对模型预测都有益,为了消除不利特征对预测精度的影响,通过引入自注意力机制对各特征进行权




图 12 BiLSTM 网络结构图

Fig. 12 Computational graph of BiLSTM network

重分配,突出关键特征,忽略无关特征,从全局方面把控各个特征对输出值的依赖关系,从而提高模型整体的预测精度。注意力层的引入示意如图 13 所示^[15]。




图 13 注意力层引入示意图

Fig. 13 Schematic diagram of attention layer incorporation

4.4 联合神经网络 CNN-BiLSTM-Attention

提出 CNN-BiLSTM-Attention 模型,主要包含了两个卷积层和池化层,1 个全连接层和隐藏层,隐藏层由 64 通道的引入自注意力(Self-Attention)机制的 BiLSTM 层和激活函数(softmax)层构成,激活函数采用 RELU 函数,并引入正则化层(dropoutLayer)防止过拟合。模型整体架构如图 14 所示。

4.5 基于 GA 算法的超参数优化

超参数是在进行预测前需要提前设置的参数,一般通过人为设置然后根据预测结果精度进行调整,能够在一定程度上影响预测的精度^[16]。LSTM 网络的超参数包括隐藏单元数目、最大训练次数、




图 14 CNN-BiLSTM-Attention 模型结构图

Fig. 14 Architecture diagram of CNN-BiLSTM-Attention model

初始学习率、正则化系数等。目标超参数的作用如 表 3 所示。

表 3 超参数作用及调整原因

Table 3 Functions and adjustment rationale of hyperparameters

超参数名称	作用	调整原因
隐藏单元数目	与模型的拟合能力相关	隐藏层神经元个数和层数越多学习能力更强,但过多导致模型过拟合
最大训练次数	影响训练速度和模型学习能力	过小梯度变动大,网络不容易收敛;过大导致模型过拟合
初始学习率	控制训练中网络梯度更新量级	学习率过高或过低都会导致优化失败,降低模型的有效容量
正则化系数	有效防止过拟合	较小的丢弃比率会让更多单元参与训练

遗传算法 (genetic algorithm, GA)^{[17][18]}是由美国密歇根大学 John Holland 教授于 1975 年提出的一类借鉴生物界自然选择和自然遗传机制的随机搜索算法。其思想来源于达尔文的著作《进化论》,用来模拟生物优胜劣汰,自然选择的过程。基于进化论的观点,选择、变异及遗传构成了遗传算法的基本操作。遗传算法计算流程如图 15 所示。

5 时序预测整体流程

为了有效防止过拟合、欠拟合等问题,在传统 LSTM 基础上增加双向传播机制,同时引入 CNN 卷积神经网络和 Self-attention 机制控制各特征对输出结果的影响,并通过 GA 遗传算法对 LSTM 超参数进行优化,有效提高了模型预测的准确性和稳定性,时序预测流程如图 16 所示。

6 箱梁离散点温度预测

6.1 数据集划分

由表 1 可知,预测的数据集共分为两个时间段,第 1 个时间段跨度为 8 d,对 7#块 B1、B2 测点温度进行预测,第 2 个时间段跨度为一个月,对 13#块 B1、B2 测点温度进行预测。为使模型充分捕捉和




图 15 遗传算法流程图示

Fig. 15 Flowchart of genetic algorithm (GA)

随时间变化的参数间的关系,以截面为单位构造样本集,每一个时刻的输出数据均受到前后历史时刻环境变化的制约,通过 BiLSTM 模型进行前后时刻的历史数据传播学习,构造后的样本集数量见表 4。

在确定了数据长度后,需要对数据进行划分。




图 16 时序预测流程图

Fig. 16 Flowchart of time-series prediction

表 4 不同时段截面数据特征

Table 4 Cross-sectional data characteristics across different time periods

时段编号	截面	特征维度	数据长度
S1	7#块	6	2 250
S2	13#块	6	9 087

训练集用于模型的训练更新,验证集即为对训练后模型的验证以及优化,完成后得到的模型参与最后的预测。因此为了得到更加准确稳定的模型,训练集和验证集的样本数据应该得到保证,本次对 S1 和 S2 的数据集划分如图 17 所示。




图 17 数据集划分图示

Fig. 17 Dataset partitioning schematic

6.2 离散点温度预测结果对比

通过预测结果评估指标的多方位对比,分析联合模型在预测精度上与 LSTM、BiLSTM 和 CNN-BiLSTM 模型的优越性,以及横向对比模型在 S1 和 S2 长短时段区间上预测效果的差异。GA 优化 S1 和 S2 超参数的结果见表 5。


表 5 GA 优化 S1 和 S2 超参数结果

Table 5 GA-optimized hyperparameter results for S1 and S2 segments


测段	隐藏单元数目	最大训练次数	初始学习率	正则化系数
S1	38	800	0.01	0.000 1
S2	10	2056	0.001	0.001

针对 S1 短时段,GA 提供了更多的隐藏单元数目,目的是在短时间序列中更好地捕捉时序特征,同时提供了更小的正则化系数以保证数据集的大小和整体稳定;针对 S2 长时段序列,GA 建议更大的正则化系数和更少的隐藏单元数目以防止过拟合。而最大训练次数随着数据量的增大呈增大趋势,初始学习率随数据量增大呈减小趋势。

LSTM、BiLSTM、CNN-BiLSTM 和联合模型 CNN-BiLSTM-Attention 在最优参数下对 S1、S2 时段测点温度的预测结果如图 18 和图 19 所示,图中设置 95% 的上下置信区间曲线。



(a) B1 测点




(b) B2 测点

图 18 各时序模型在 S1 测段的预测结果对比


Fig. 18 Performance comparison of time-series models (S1 segment)

由图 18 分析可知,LSTM 和 BiLSTM 在 500 时刻数前预测结果较为理想,但是 500 时刻后未能成功预测出正确特征,一方面和数据集样本量较少有关,LSTM/BiLSTM 虽然通过训练捕捉到前期的时

序特征,但是缺少对特征的分析,导致后半段数据失真,CNN-BiLSTM通过卷积神经网络捕捉到了特征与输出值的相关性,使其预测精度有所提高,CNN-BiLSTM-Attention网络不仅对特征值进行了捕捉,而且通过深入分析赋予了不同特征权重,使得预测精度进一步提高。



(a) B1测点



(b) B2测点

图 19 各时序模型在 S2 测段的预测结果对比
Fig. 19 Performance comparison of time-series models (S2 segment)

由图 18 和图 19 分析可知,随着数据量增加,各模型的预测精度都有一定提升,这也符合 LSTM 长期时间序列预测的优势,LSTM/BiLSTM 虽然拟合了数据整体的时序变化趋势,但在峰值温度的拟合上差强人意,CNN-BiLSTM 进一步逼近真实的峰值温度数据,但仍然与真实值有所差距,CNN-BiLSTM-Attention 网络不仅对数据整体特征把握得更加准确,而且更加精准预测了峰值温度的变化趋势。

6.3 评估指标对比

S1 和 S2 测段下各模型下的 RMSE(均方根误差)、 R^2 (决定系数)、MAE(平均绝对误差)和 MSE(均方误差)结果如表 6 所示。

由表 6 分析可知,相较于 S1 测段,S2 测段下各模型的各项指标精度均有所提高,LSTM 和

表 6 各时序模型下的评估指标对比


Table 6 Comparison of evaluation metrics across time-series models

测段	时序模型	RMSE	R^2	MAE	MSE
S1 测段	LSTM	0.585	0.968	0.379	0.342
	BiLSTM	0.492	0.972	0.32	0.242
	CNN-BiLSTM	0.456	0.981	0.282	0.208
	CNN-BiLSTM-Attention	0.178	0.987	0.138	0.031
S2 测段	LSTM	0.378	0.975	0.284	0.142
	BiLSTM	0.368	0.976	0.279	0.135
	CNN-BiLSTM	0.318	0.982	0.266	0.101
	CNN-BiLSTM-Attention	0.129	0.989	0.108	0.016


BiLSTM 模型的 RMSE 降低了 0.1,这也充分展现了 LSTM 模型在长时预测上的优势,CNN-BiLSTM 在长短时预测上均保持了较好的精度,决定系数 R^2 均能保持在 0.98,展现了模型在长短时上均有较强的预测能力,CNN-BiLSTM-Attention 无论在 S1 或 S2 测段均保持了最高的预测精度,各项指标均领先于 LSTM/BiLSTM 和 CNN-BiLSTM 时序模型。

为更直观地查看各模型的预测指标,生成各模型评估指标的雷达图,如图 20 所示。

图 20 清楚地反映出各模型的预测效果,可以看



(a) S1 测段



(b) S2 测段

图 20 各时序模型评估指标对比
Fig. 20 Evaluation metrics comparison of time-series models

出 LSTM 系列模型在长时段预测上表现更加优秀,无论是 S1 或 S2 测段, CNN-BiLSTM-Attention 的 RMSE、MSE 和 MAE 均更接近 0,而决定系数 R^2 更加逼近 1。

7 结论

针对复杂气象耦合作用下箱梁离散点温度预测中传统时序模型难以兼顾时空特征关联性、峰值敏感性不足以及超参数调优效率低等问题,提出了一种基于 GA 优化的 CNN-BiLSTM-Attention 混合模型。通过融合卷积神经网络(CNN)的空间特征提取能力、双向短时记忆网络(BiLSTM)的双向时序依赖捕捉能力以及自注意力机制(Attention)的动态特征权重分配,实现了多气象参数与温度场的深层关联建模;同时,引入遗传算法(GA)对模型超参数进行全局优化,突破了传统人工调参的局部最优限制,显著提升了预测精度与泛化性能。基于南充嘉陵江特大桥实测数据的实验表明,该模型在短期(S1 测段)和长期(S2 测段)预测中的 RMSE 分别降至 0.178 和 0.129, R^2 均接近 0.99,较 LSTM、BiLSTM 等传统模型预测误差降低 20% 以上,且对温度峰值的预测误差减少 35%~40%。本研究创新性地多模态特征融合与智能优化算法结合,不仅解决了复杂气象条件下温度场预测的精度瓶颈,还为桥梁结构健康监测提供了高可靠性分析工具,推动了深度学习与土木工程监测领域的交叉应用。

参考文献

- [1] XIA Q, LIU S L, ZHANG J. Temperature analysis of a long-span suspension bridge based on a time-varying solar radiation model [J]. Smart Structures and Systems, 2020, 25(1): 23-35.
- [2] 吴颖峰. 基于深度学习的桥梁健康监测数据失真诊断与修复研究[D]. 广州: 广州大学, 2021.
WU Y F. Research on anomaly detection and recovery of bridge health monitoring data based on deep learning [D]. Guangzhou: Guangzhou University, 2021. (in Chinese)
- [3] ZHAO H W, DING Y L, LI A Q, et al. Digital modeling approach of distributional mapping from structural temperature field to temperature-induced strain field for bridges [J]. Journal of Civil Structural Health Monitoring, 2023, 13(1): 251-267.
- [4] 张云必. 基于 LSTM 模型的高原桥梁温度场预测研究 [J]. 现代交通技术, 2023, 20(6): 67-71, 89.
ZHANG Y B. Research on temperature field prediction of plateau bridges based on LSTM model [J]. Modern Transportation Technology, 2023, 20(6): 67-71, 89. (in Chinese)
- [5] 陈钰萌. 基于深度学习的混凝土箱型桥梁温度场计算方法研究[D]. 广州: 华南理工大学, 2022.
CHEN Y M. Research on temperature calculation method of concrete box bridge base on deep learning [D]. Guangzhou: South China University of Technology, 2022. (in Chinese)
- [6] 张洁. 基于气象数据驱动和深度学习的桥梁温度和应变预测[D]. 广州: 广州大学, 2023.
ZHANG J. Prediction of bridge temperature and strain based on meteorological data driving and deep learning [D]. Guangzhou: Guangzhou University, 2023. (in Chinese)
- [7] KWAN O, SEON P, GLISIC B. Prediction of long-term strain in concrete structure using convolutional neural networks, air temperature and time stamp of measurements [J]. Automation in Construction, 2021, 126: 103665.
- [8] 闫坤, 张志华, 颜鲁春. 结合正则化 K-SVD 和 Hampel 滤波的探地雷达数据重建 [J]. 测绘通报, 2021(8): 22-27.
YAN K, ZHANG Z H, YAN L C. Ground penetrating radar data reconstruction combined with regularized K-SVD and Hampel filter [J]. Bulletin of Surveying and Mapping, 2021(8): 22-27. (in Chinese)
- [9] 李瑞轩. 混凝土曲线箱梁桥三维日照温度场及温度效应研究[D]. 西安: 长安大学, 2022.
LI R X. Study on three-dimensional sunshine temperature field and temperature effect of concrete curved box girder bridges [D]. Xi'an: Chang'an University, 2022. (in Chinese)
- [10] 张誉瀚, 钱永久, 张方. 大跨度混凝土连续箱梁桥日照温度场试验及仿真分析 [J]. 铁道标准设计, 2017, 61(9): 76-81.
ZHANG Y H, QIAN Y J, ZHANG F. Solar temperature field test and simulation analysis of large span concrete continued box girder [J]. Railway Standard Design, 2017, 61(9): 76-81. (in Chinese)
- [11] 赵黎, 王小港, 王宁, 等. 基于皮尔逊相关系数选择的完全广义空间调制可见光通信系统 [J]. 光学学报, 2024, 44(4): 0406001.
ZHAO L, WANG X G, WANG N, et al. Fully generalized space modulation visible light communications system based on Pearson correlation coefficient selection [J]. Acta Optica Sinica, 2024, 44(4): 0406001. (in Chinese)
- [12] 桂彦, 叶文倩, 王建新, 等. 基于 CNN 和尺度自适应 Transformer 融合网络的路面裂缝分割方法 [J]. 中国公路学报, 2024, 37(12): 418-432.
GUI Y, YE W Q, WANG J X, et al. CNN and scale adaptive transformer fusion network for pavement crack segmentation [J]. China Journal of Highway and

Transport, 2024, 37(12): 418-432. (in Chinese)

[13] 刘海斌. 基于EMD-SVM-LSTM组合的桥梁变形响应预测模型研究[J]. 公路, 2025, 70(3): 204-210.

LIU H B. Research on prediction model of bridge deformation response based on EMD-SVM-LSTM combination [J]. Highway, 2025, 70(3): 204-210. (in Chinese)

[14] 余萍, 赵康, 曹洁. 基于优化A-BiLSTM的滚动轴承故障诊断[J]. 吉林大学学报(工学版), 2024, 54(8): 2156-2166.

YU P, ZHAO K, CAO J. Rolling bearing fault diagnosis based on optimized A-BiLSTM [J]. Journal of Jilin University (Engineering and Technology Edition), 2024, 54(8): 2156-2166. (in Chinese)

[15] 张明聚, 秦胜旺, 李鹏飞, 等. 基于融合注意力机制BP神经网络的深基坑变形预测方法[J]. 北京交通大学学报, 2025, 49(2): 95-104.

ZHANG M J, QIN S W, LI P F, et al. Deep excavation deformation prediction method based on BP Neural Network with integrated attention mechanism [J]. Journal of Beijing Jiaotong University, 2025, 49(2): 95-104. (in Chinese)

[16] 周泽楷, 侯宏娟, 孙莉, 等. 基于CNN和BiLSTM神经网络模型的太阳能供暖负荷预测研究[J]. 太阳能学报, 2024, 45(10): 415-422.

ZHOU Z K, HOU H J, SUN L, et al. Research on solar heating load forecasting based on CNN and BiLSTM neural network model [J]. Acta Energiæ Solaris Sinica, 2024, 45(10): 415-422. (in Chinese)

[17] DAO S D, ABHARY K, MARIAN R. An innovative framework for designing genetic algorithm structures [J]. Expert Systems with Applications, 2017, 90: 196-208.

[18] ELREHIM M ZABD, EID M A, SAYED M G. Structural optimization of concrete arch bridges using Genetic Algorithms [J]. Ain Shams Engineering Journal, 2019, 10(3): 507-516.

(编辑 XXX)