

DOI: 10.11835/j.issn.2096-6717.2025.018



开放科学(资源服务)标识码 OSID:



基于特征选择的 CNN-LSTM 结构应变响应 预测方法

王维, 姜珊, 胡剑琇, 路国运
(太原理工大学 土木工程学院, 太原 030024)

摘要: 在建筑结构的长期服役过程中, 可能会受到多种外部和内部因素的影响, 导致部分关键构件失效。结构应变响应能直观地反映这些构件的运行状态, 因此, 准确预测结构的应变响应对于建筑结构的长期监测具有重要意义。提出一种基于特征选择的卷积神经网络-长短期记忆网络 (CNN-LSTM) 结构应变响应预测方法, 并基于北疆明珠塔健康监测系统实测数据对该方法进行验证。对输入模型的特征进行 Pearson 相关性分析, 并进一步利用随机森林算法对各特征的重要性进行排序和选择, 确定输入模型的特征。利用该方法建立 CNN-LSTM 结构应变响应预测模型, 采用贝叶斯优化算法对模型超参数进行精细调整以提高模型的预测精度, 并与常规长短期记忆网络 (LSTM) 模型和双向长短期记忆网络 (Bi-LSTM) 模型的预测结果进行比较。结果表明, CNN-LSTM 模型在所有应变测点上的预测值与实际值之间的相关系数均超过了 0.99, 表明该模型在预测构件应变响应方面具有优越性能, 且相较于 LSTM 和 Bi-LSTM 模型, CNN-LSTM 模型具有更高的预测精度。

关键词: 结构健康监测; 应变预测; 卷积神经网络; 长短期记忆网络; 特征选择; 随机森林

中图分类号: TU17 **文献标志码:** A **文章编号:** 2096-6717(XXXX)XX-0001-11

CNN-LSTM structural strain response prediction model based on feature selection

WANG Wei, JIANG Shan, HU Jianxiu, LU Guoyun

(School of Civil Engineering, Taiyuan University of Technology, Taiyuan 030024, P. R. China)

Abstract: During the long-term service of a building structure, various external and internal factors can lead to the failure of key components. The structural strain response serves as an intuitive indicator of the operational status of these components. Therefore, accurately predicting the structural strain response is crucial for the long-term monitoring of building structures. In this paper, we propose a feature selection-based Convolutional Neural Network-Long Short-Term Memory Network (CNN-LSTM) structural strain response prediction method and validate the method based on the measured data of the health monitoring system of the Beijiagang Pearl Tower. The input model's features are determined through Pearson correlation analysis, and their importance is ranked

收稿日期: 2024-09-21

基金项目: 国家自然科学基金(12172244)

作者简介: 王维(1999-), 男, 主要从事机器学习在土木工程中的应用研究, E-mail: wangwei0482@link.tyut.edu.cn。

路国运(通信作者), 教授, 博士生导师, E-mail: luguoyun@tyut.edu.cn。

Received: 2024-09-21

Foundation items: National Natural Science Foundation of China (No. 12172244)

Author brief: WANG Wei (1999-), main research interest: structural health monitoring, E-mail: wangwei0482@link.tyut.edu.cn.

LU Guoyun (corresponding author), professor, doctoral supervisor, E-mail: luguoyun@tyut.edu.cn.

and selected using the random forest algorithm. We developed a CNN-LSTM structural strain response prediction model and applied the Bayesian optimization algorithm to fine-tune the model's hyperparameters, thereby enhancing its prediction accuracy. We then compared the prediction results with those obtained from conventional Long-short Term Memory Networks (LSTM) and Bidirectional Long Short-Term Memory (Bi-LSTM) models. The results demonstrate that the correlation coefficients between the predicted and actual values of the CNN-LSTM model at all strain measurement points exceed 0.99. This indicates the model's superior performance in predicting the strain response of components, as well as its higher prediction accuracy compared to the LSTM and Bi-LSTM models.

Keywords: structural health monitoring; strain prediction; convolutional neural network; long short-term memory network; feature selection; random forest

在过去的几十年里,机器学习在土木工程结构健康监测 (Structural Health Monitoring, SHM) 领域得到广泛的应用。随着计算机算力的提升和数据采集技术的进步,人们开始探索更为复杂的算法来分析监测数据,尤其是机器学习方法的引入为结构健康监测领域带来了革命性的变化^[1]。目前,机器学习已广泛应用于异常监测数据检测及恢复^[2-4]、结构地震响应预测^[5-6]、SHM 信号重建^[7-9]和基于计算机视觉的损伤检测^[10-11]等结构健康监测领域。随着技术的不断进步,未来的研究将更加依赖智能算法,实现更加智能化与自动化的结构健康监测。

卷积神经网络 (CNN) 和长短期记忆网络 (LSTM) 是两种经典的机器学习模型。CNN 神经网络适合从数据中提取隐藏的空间特征^[12-14],并已广泛用于图片处理及处理大规模监测数据。Oh 等^[15]提出了一种基于空气温度与结构响应强相关性的混凝土结构长期应变测量数据预测方法,经实例验证,通过训练后的 CNN 神经网络,利用来自气象站的空气温度数据来估计结构的应变,验证了其可行性和准确性。邓扬等^[16]根据卷积神经网络和监测数据频域特征建立了监测数据质量评价方法,并利用某桥梁实际监测数据验证该方法,结果表明该方法具有较高的准确性;长短期记忆网络 (LSTM) 是 RNN 神经网络的一种变体,相较于传统的 RNN 神经网络,除了能够更好地克服时间数据序列的长期依赖性以外,还能有效减少梯度爆炸问题的出现,广泛应用于建筑结构各大领域。张立奎等^[17]提出了一种基于多层堆叠 LSTM 神经网络的桥梁变形重构方法,利用应变模态和加速度数据训练 LSTM 神经网络,训练后的模型能够准确重构桥梁的变形,通过数值模拟和试验验证了该方法的准确性。梁煜婉等^[18]提出了一种真空预压地基处理沉降预测方法,选取两个区域的实测沉降数据作为数据基础,与对比传统沉降预测法相比, LSTM 神经网络预测结果更加准确,验证了该方法的可行性。

笔者提出一种基于特征选择的 CNN-LSTM 结构应变响应预测方法,将 CNN 神经网络提取输入数据空间特征的能力与 LSTM 神经网络提取输入数据的时间序列特征的能力相结合,并利用贝叶斯优化算法确定预测模型参数。利用北疆明珠观光塔健康监测系统采集到的实测数据对提出的方法进行验证。从监测点中选取旋转餐厅转换层 4 个关键位置的测点,采用 Pearson 相关性分析和随机森林算法对各特征进行重要性分析和选择,构建 CNN-LSTM 神经网络模型,以经过选择的特征为输入特征预测结构应变响应,并对比分析该模型与 LSTM 变种模型之间的预测效果。

1 基于特征选择的结构应变预测方法

1.1 LSTM 神经网络模型及其变体模型

1) 长短期记忆网络

长短期记忆网络 (Long-short Term Memory Networks, LSTM) 是 RNN 神经网络的一种变体,由 Hochreiter 等^[19]在 1997 年提出,是一种具有记忆长短期信息的能力的神经网络, LSTM 神经网络结构图 1 所示。




图 1 LSTM 神经网络示意图

Fig. 1 Schematic diagram of the LSTM neural network

LSTM 神经网络通过“门”单元 (即遗忘门、输入门、输出门) 解决长期依赖问题。其中,输入门决定有多少新的信息加入到细胞当中,遗忘门控制每一时刻信息是否会被遗忘,输出门决定每一时刻是否有信息输出,通过门单元的逻辑控制决定数据是

否更新或是选择丢弃,克服了RNN权重影响过大、容易产生梯度消失和爆炸的缺点,使网络可以更好、更快地收敛,能够有效提高预测精度。

2) 双向长短期记忆网络

双向长短期记忆网络(Bidirectional Long Short-Term Memory, Bi-LSTM)模型^[20]以两层异向的LSTM网络为基础,考虑前后不同时刻时序数据之间的相互影响,克服了LSTM中数据单向流动的局限性,可以更充分地学习特征序列的时间依赖性,从而对未知时间序列进行有效预测,Bi-LSTM神经网络结构如图2所示。




图2 Bi-LSTM神经网络示意图

Fig. 2 Schematic diagram of Bi-LSTM neural network

3) 卷积神经网络-长短期记忆网络

卷积神经网络-长短期记忆网络(Convolutional Neural Network - Long Short-Term Memory, CNN-LSTM)模型^[21]结合了CNN和LSTM的优点。CNN-LSTM神经网络结合了CNN的空间特征提取能力和LSTM的时间序列处理能力。CNN-LSTM神经网络通过有效的特征提取和利用时间依较信息,通常能提供比单独的LSTM更高的预测准确性,并且在不同的数据集上表现出更好的泛化能力,CNN-LSTM神经网络结构如图3所示。




图3 CNN-LSTM神经网络示意图

Fig. 3 Schematic diagram of CNN-LSTM neural network

1.2 预测流程概述

提出一种基于特征选择的CNN-LSTM结构应变响应预测方法,采用该方法预测结构响应的流程如图4所示,主要包含以下内容:

1) 数据采集及预处理。取北疆明珠健康监测系统采集监测数据,包括温度、湿度等环境监测数

据以及应变、位移和速度等结构响应监测数据,在原始监测数据的基础上采用归一化等数据处理手段,构建初始数据集。

2) 特征选择。对1)中原始数据集中的各特征参数进行Pearson相关性分析,选择相关性较弱的特征作为输入特征,并进一步通过随机森林(RF)对特征进行重要性排序,确定输入模型的特征数量,针对不同测点建立不同特征数据集。

3) 建立神经网络模型,对比分析预测结果。建立CNN-LSTM神经网络,将2)中选择的特征集和目标集传入神经网络模型,并按7:3的比例划分训练集和测试集用作训练和测试。对模型超参数优化,包括神经元个数、初始学习率等。

4) 模型评估和比较。采用决定系数(R)、平均绝对误差(MAE)和均方根误差(RMSE)等参数作为评价指标,对模型预测效果进行评估,并与Bi-LSTM模型和LSTM模型的预测效果进行了比较。

2 应用实例

北疆明珠观光塔^[22-23]位于内蒙古自治区呼伦贝尔市满洲里市市区以西9 km处国门景区内,建筑结构形式为高耸结构,建筑标高为208 m。地上主体及塔身为钢结构,由钢管混凝土柱、钢管柱、钢平台梁及支撑等结构构成,地下室采用框架混凝土剪力墙结构。地下1层,层高5.20 m;地上25层,其中主体裙楼为2层,每层高6.20 m,塔身每层高6.20 m。餐厅整体钢结构重量为850 t,位于北疆明珠塔结构124~148.325 m处,建筑实物如图5(a)所示。

为了对北疆明珠观光塔进行全寿命周期的健康监测,在结构各部位安装了多种传感器,包括应变传感器、速度传感器、温度传感器以及风速、风向传感器等装置。在观光塔的整个使用寿命期间,该系统实时采集到应变、速度等结构响应数据,并记录建筑周围温度、风速和风向等环境因素数据。为验证所提方法的有效性,以旋转餐厅底部4个测点的应变响应作为研究对象,测点位置如图5(b)所示,各测点应变响应变化如图6所示。使用2023-12-01日—2024-02-29日共3个月的监测数据,并以7:3的比例划分测试集和验证集。

从图6中可以看出各测点的应变响应情况,各测点的响应值具有相同的变化趋势,且没有明显的周期性变化。图7为数据采集期间风速的变化,图8为数据采集期间风向的变化,图9为数据采集期间当地气温的变化情况,北疆明珠观光塔布有速度传感器,可以拾取对应的速度监测数据,用于计算结





图 4 结构应变响应预测流程图

Fig. 4 Structural strain response flow diagram



(a) 北疆明珠塔实物图 (b) 研究部位与测点位置示意图

图 5 北疆明珠塔及研究部位示意图

Fig. 5 Beijing Pearl Tower and schematic diagram of the study site




图 6 各测点应变数据变化图

Fig. 6 Variation of strain data at each measurement point

构振动频率及振型等振动特征,图 10 为某速度测点的振动特征。




图 7 风速特征变化图

Fig. 7 Variation of wind speed characteristics




图 8 风向特征变化图

Fig. 8 Map of changes in wind characteristics

2.1 数据集制备及预处理

为消除不同输入参数间单位尺度不同的影响,使深度学习结果更加精确,每个输入数据序列都需要进行归一化处理,如式(1)所示。

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x 和 x_{norm} 是原始和归一化的数据序列; $x_{\max}$ 是输入数据序列的最大值; $x_{\min}$ 是输入数据序列的最




图 9 温度特征变化图

Fig. 9 Variation in temperature characteristics




图 10 振动特征变化图

Fig. 10 Variation of vibration characteristics

小值。

2.2 特征选择

结构响应预测模型映射了结构响应与特征之间复杂的非线性关系。在建模过程中,输入特征对模型的性能有着重要的影响,一方面,输入模型中的冗余特征可能会导致过拟合;另一方面,特征输入过少则可能会忽略数据之间的潜在关系,并导致欠拟合。为了解决上述问题,使用了一种基于随机森林(RF)^[24-25]的特征因子选取方法。

结构应变会随着结构振动而不断发生变化,风速决定了作用在结构上的风荷载大小,风向决定了结构上风荷载的作用方向,二者都对结构应变有着较大影响,而温度变化导致结构材料力学性能发生变化,进而影响结构的应变。以速度测点、温度测点、风速测点以及风向测点采集到的 4 种类型的监测数据为基础,测点位置如图 5(b)所示,构建原始数据集,每类监测数据对应一种特征,4 种类型的特征共计 19 个特征因子,依据特征类型对特征因子赋予特征编号,如表 1 所示,北疆明珠健康监测系统通过布置速度传感器拾取结构振动及振形等振动特征,振动特征仅由速度监测数据构成,此外,振动特征按照传感器装置布置位置的不同,进一步细分为核心筒振动特征、悬挑结构振动特征和塔顶振动特征。

线性特征的输入会导致模型过拟合,为了选择最优特征建立结构应变响应预测模型,采用 Pearson 相关系数分析特征之间的相关性,选择性剔除具有线性关系的特征。Pearson 相关系数反映了两个变

表 1 特征编号表

Table 1 Feature numbering table

特征类型	特征编号
核心筒振动特征	$H_i(i=1,2,3,4)$
悬挑结构振动特征	$X_i(i=1,2,3,4,5,6)$
塔顶振动特征	$D_i(i=1,2,3)$
温度特征	T_1, T_2
风速特征	F_1, F_2
风向特征	F_3, F_4

量之间的相关性,其取值范围为-1~1, Pearson 相关系数计算表达式如式(2)所示。

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2)$$

式中: r 为 Pearson 相关系数,表示两个变量 $X=[x_1, x_2 \cdots x_n]^T$ 和 $Y=[y_1, y_2 \cdots y_n]^T$ 之间的相关程度。 $\bar{x}$ 是变量 X 中数据的平均值, $\bar{y}$ 是变量 Y 中数据的平均值。一般来说, $|r|>0.8$ 表示两个变量之间的显著相关性;当 $0.5<|r|<0.8$ 时,表示中度相关;当 $0.3<|r|<0.5$,表示两个变量之间的相关性较低;当 $|r|<0.3$,它表明这两个变量之间几乎没有相关性。

图 11 为特征间的皮尔逊相关系数热图,图中直观地显示了每个特征因子之间的相关性。从浅黄色到深蓝色的颜色变化表示相关系数由-1.0变化到 1.0。从图 11 可以看出,布置在同一结构部位上的振动特征间相关性较高,即 H_i 之间、 X_i 之间以及 D_i 之间均具有显著相关性,这是因为在外界激励作用下,同一结构部位上各测点的结构响应往往具有相似的变化趋势;布置在不同结构部位上的振动特征间不具有显著的相关性,即 H_i 与 X_i 以及 D_i 均不具有显著相关性,这是结构各部位所用材料的以及构造方式不同,导致结构各部位表现出不同的力学性能,在面对外部激励作用时结构响应呈现出不同的变化趋势。温度测点位置如图 5(b)所示,由测量结果可知,悬挑结构振动测点位置处的温度数据较为准确,而塔顶振动测点和核心筒振动测点位置处的实际数据与测得的温度数据存在一定的偏差。因此,悬挑结构振动特征 X_i 与温度特征 T_1, T_2 之间表现出了一定的相关性,而核心筒振动特征 H_i 以及塔顶振动特征 D_i 与温度特征之间未表现出显著的相关性。此外,塔顶振动特征 D_i 与风速特征 F_1, F_2 之间也未呈现出显著的相关性。主要原因在于北疆明珠塔顶部主要设计功能为观光平台,其结构形式与主体结构不同,质量较小而刚度较大,因此对风速变化的敏感性较低。此外,北疆明珠塔为高耸建筑,其结构沿竖向受非线性风荷载后的响应较为复杂,而风速测点位于结构顶部,核心筒振动测点则

位于结构底部,导致核心筒振动特征 H_i 与风速特征 F_1 、 F_2 之间也未表现出显著的相关性。




图 11 输入特征间 Pearson 相关性热图

Fig. 11 Pearson correlation heat map between input features

输入特征间具有相关性会导致多重共线性的发生,故根据 Pearson 相关性分析计算结果可初步确定输入模型的特征,根据 Pearson 相关性分析计算结果,筛选出 7 个不具有显著相关性的特征,分别为:核心筒振动特征 H_1 、悬挑结构振动特征 X_6 、塔顶振动特征 D_1 、温度特征 T_1 、 T_2 、风速特征 F_1 和风向特征 F_4 。

随机森林(RF)是一种结合决策树和 Bootstrap 响应技术的集成学习算法。在构建树模型的过程中,每个特征都有一个对应的重要性得分。特征参与叶节点分裂的次数越多,它获得的分数就越大。RF 用于特征重要性评估的思想是查看每个特征对每个树的相对贡献。

为进一步探究各特征对测点应变结构响应的影响,依次对 21F-1#、21F-2#、21F-3#和 21F-4#四个应变测点进行 RF 特征重要性计算,计算结果如图 12 所示,根据计算结果对各特征排序得到表 2。可以看出,4 个测点具有相似的特征重要性分布特点,其中 21F-1#和 21F-2#两个测点,温度和振动分量均占比较大且所占比例相近,分别占 29.59%、28.87%和 32.55%、32.55%。而 21F-3#和 21F-4#两点处振动所占比例最大,分别为 45.75%和 43.69%。由此可知,在影响结构应变响应的各因素中,风速、风向特征对结构应变响应影响较小,而温度和振动因素是导致结构应变响应的主要因素。此外还可以看出,在影响结构应变响应的各特征因子中,振动特征重要性分量所占比例最高,分别合计占比 42.23%、43.67%、53.38%和 52.15%。其次是温度特征,分别合计占比 42.82%、42.59%、

36.06%和 38.62%,风速特征以及风向特征占比较少。结果表明,温度因素和振动因素是影响结构应变响应的主导因素。




图 12 各测点 RF 重要性计算结果

Fig. 12 Calculation results of RF importance of each measurement point

表 2 各测点特征重要性排序

Table 2 Ranking of the importance of the characteristics of each measurement point

重要性排序	测点编号			
	21F-1#	21F-2#	21F-3#	21F-4#
1	T ₁	T ₁	H ₁	H ₁
2	H ₁	H ₁	T ₁	T ₁
3	F ₁	F ₁	T ₂	T ₂
4	T ₂	X ₆	F ₁	X ₆
5	X ₆	T ₂	X ₆	F ₁
6	F ₂	F ₂	F ₂	F ₂
7	D ₁	D ₁	D ₁	D ₁

基于表 2 中的顺序,逐渐增加输入到 RF 模型中特征的数量,并且进行模型训练和测试。图 13 显示了不同特征输入数量情况下的结果。可以看出,对所有测点使用一个特征的训练集和测试集的 MAE 相对较大。这是由于输入模型的特征变量包含的信息不足以反映结构应变响应的非线性特征。当逐步增加输入模型的具有高特征重要性的特征数

量时,MAE 值逐步降低并达到其最低点。如果此时特征因子的数量进一步增加,MAE 值也随之增加。这是因为冗余特征的输入会对模型的性能产

生负面影响。因此,基于图 13 中的计算结果,获得了最佳特征集,即 $X=[H_1,X_6,T_1,T_2,F_1]$,作为最终输入模型的特征。




图 13 不同数量输入特征的 MAE 曲线图

Fig. 13 Curve of MAE with different number of features input

2.3 实验参数配置

使用的模型是基于 Keras 3.0.5 构建的。CNN-LSTM 模型是 CNN 和 LSTM 的组合。模型的超参数分别为: N_c 为卷积核的大小, N_d 为密集块的数量,epoch 为 LSTM 的训练轮数,batch_size 为批次大小, T 为时间步长的数量, N_u 为 LSTM 单元的数量, l_r 为学习率。

为了比较不同模型的预测效果,并选择出最优预测模型,同时建立了 CNN-LSTM、Bi-LSTM 和 LSTM 的模型,通过预测同一数据集上的结构应变响应来比较不同模型预测效果。为了更好地对比模型性能,LSTM 模型以及 Bi-LSTM 模型中的参数与 CNN-LSTM 模型中的参数保持一致,并且为使预测效果更加准确,使用贝叶斯优化算法确定模型最佳的超参数,超参数搜索范围见表 3,最终确定各模型的最佳超参数见表 4。

表 3 贝叶斯优化算法超参数搜索范围

Table 3 Bayesian optimization algorithm hyperparameter search range	
待优化参数	搜索范围
$N_c, N_d, \text{batch_size}, N_u$	(32, 64, 128, 256, 512)
T	[1, 40]
l_r	[0.000 01, 0.000 1]

表 4 不同模型参数

Table 4 Different model parameters	
模型	参数
CNN-LSTM	$N_c=128, N_d=64, \text{epoch}=100, \text{batch_size}=512, T=35, N_u=128, l_r=0.000\ 81$
Bi-LSTM	$\text{epoch}=100, \text{batch_size}=512, T=35, N_u=128, l_r=0.000\ 81$
LSTM	$\text{epoch}=100, \text{batch_size}=512, T=35, N_u=128, l_r=0.000\ 81$

3 结果分析

3.1 模型预测效果

使用一种基于特征选择的 CNN-LSTM 结构应变响应预测方法,预测 4 个测点 21F-1#、21F-2#、21F-3# 和 21F-4# 的结构应变响应。将时间序列的真实值与特征选择前后的预测值进行比较并给出了数据分布,结果如图 14 所示。

图 14 显示了 CNN-LSTM 模型对不同测量点的预测结果。实际应变测量值用黑色实线表示,预测应变值用红色实线表示。从图中可以看出,预测值与实测值高度一致,预测值分布在中心线附近, CNN-LSTM 在 21F-1#、21F-2#、21F-3# 和 21F-4# 的结构应变响应预测效果方面表现良好, CNN-




图 14 CNN-LSTM预测效果图

Fig. 14 Prediction effect of CNN-LSTM

LSTM模型能够准确预测结构应变响应变化趋势,4个测点预测值与实际值的绝对值误差最大值为0.618,造成误差的原因主要是用于训练模型的训练集数据不够充分以及计算机算力不足导致的。结果表明,CNN-LSTM结构响应预测模型是一种有效的结构应变响应预测方法。

3.2 与其他深度学习模型预测效果对比

以平均绝对误差(MAE)系数、均方根误差(RMSE)和相关系数(R)3类评价指标对模型进行评价,这些指标的数学表达式如下。

1) 平均绝对值误差(MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

2) 相关系数评价准则(R)

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (4)$$

3) 均方根误差评价准则(RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

根据3类模型评价指标对比分析LSTM、Bi-LSTM和CNN-LSTM三种模型预测效果,结果如表5所示。

表 5 不同模型预测效果对比


Table 5 Comparison of the prediction effect of different models

测点 编号	模型名称	特征选择前			特征选择后		
		MAE	R	RMSE	MAE	R	RMSE
21F-1#	CNN-LSTM	0.763	0.987	0.984	0.547	0.995	0.673
	Bi-LSTM	0.942	0.985	1.131	0.564	0.994	0.696
	LSTM	1.049	0.982	1.255	0.575	0.994	0.710
21F-2#	CNN-LSTM	0.538	0.988	0.656	0.368	0.999	0.462
	Bi-LSTM	0.578	0.988	0.742	0.446	0.998	0.552
	LSTM	0.596	0.987	0.759	0.442	0.998	0.560
21F-3#	CNN-LSTM	0.883	0.989	0.969	0.618	0.992	0.753
	Bi-LSTM	1.232	0.970	1.481	0.665	0.991	0.814
	LSTM	1.453	0.956	1.791	0.738	0.989	0.903
21F-4#	CNN-LSTM	0.544	0.992	0.655	0.376	0.996	0.469
	Bi-LSTM	0.781	0.983	0.939	0.377	0.995	0.473
	LSTM	0.833	0.982	0.966	0.413	0.995	0.513

注:标黑表示预测效果更优

如表5所示,经过特征选择后,3种模型的预测准确性均得到提高,以21F-2#测点为例,特征选择后,CNN-LSTM模型的MAE、R以及RMSE三项指标由0.538、0.988以及0.656优化为0.368、0.999和0.462;Bi-LSTM模型的3项指标由0.578、0.988和0.742优化为0.446、0.998和0.552;LSTM模型的3项指标由0.596、0.987和0.759优化为0.442、0.998和0.560,这表明特征选择对提升模型预测性能具有重要作用。3种模型均有良好的预测性能,其中CNN-LSTM模型在预测结构应变的过程中表现最好,Bi-LSTM模型预测效果其次,LSTM模型排在最后。CNN-LSTM模型采用CNN模型与LSTM模型相结合的方式,其性能优于单独的LSTM模型和Bi-LSTM模型。分别以经过选择和未经选择的特征为输入特征预测结构应变响应,图15是3种的模型预测效果对比图,对于21F-1#、21F-2#、21F-3#以及21F-4#四个测点采集到的4组数据,从3项评价指标以及图15来看,特征选择前CNN-LSTM模型的预测效果优于Bi-LSTM模型以及LSTM模型;而特征选择后,CNN-LSTM模型的决定系数R分别为0.995、0.999、0.992以及0.996,平均绝对值误差分别为0.547、0.368、0.618和0.376,均方根误差分别为0.673、

0.462、0.753 和 0.469, 这些指标均表明 CNN-LSTM 模型在特征选择后依然保持优于 Bi-LSTM 模型和 LSTM 模型的预测性能。结果表明, CNN-LSTM 模型在预测性能方面显著优于 LSTM 模型和 Bi-LSTM 模型, 特征选择进一步提升了其预测精度和稳定性, 验证了该模型在结构应变预测中的优越性。



注:图中 ori 表示未经过特征选择的原始数据预测结果。

图 15 CNN-LSTM、Bi-LSTM 和 LSTM 模型性能对比图

Fig. 15 Performance comparison of CNN-LSTM, Bi-LSTM, and LSTM models

从图 15 可以看出, 所有模型都可以预测测量值的趋势, 并且特征选择后的模型预测的趋势更加准确。在数据波动较大的情况下, Bi-LSTM 模型和 LSTM 模型无法捕捉到关键信息, 相比之下, 即使数据中存在很大的波动, CNN-LSTM 模型也可以捕捉趋势并预测更为准确的结果。它还表明, CNN-LSTM 模型的绝对预测误差低于 Bi-LSTM

和 LSTM 模型。这些结果表明, CNN-LSTM 模型预测效果优于 Bi-LSTM 模型以及 LSTM 模型。

4 结论

提出一种基于特征选择的 CNN-LSTM 结构应变响应预测方法, 并利用北疆明珠观光塔健康监测系统采集到的实测数据对提出的方法进行验证。采用 Pearson 相关性分析和随机森林算法对各特征进行重要性分析和选择, 在此基础上构建了 CNN-LSTM 神经网络模型, 以经过选择的特征为输入特征预测结构应变响应, 并对比分析 CNN-LSTM 模型与 Bi-LSTM 和 LSTM 模型预测效果, 得到的主要结论如下:

1) 基于 Pearson 相关性分析计算和随机森林的结构应变响应特征选择方法, 能够选择出准确反映结构应变响应非线性特征的重要特征。该方法可以有效地减少多重共线性特征和冗余特征对结构应变响应预测精度的影响, 提高了模型预测的准确性。减少输入特征的数量, 从而节省计算机算力。研究还发现, 影响结构应变响应的主要因素为结构振动和温度。

2) 基于提出的结构应变响应预测方法建立的 CNN-LSTM 模型稳定性较好, 预测精度较高, 可用于结构健康监测。各项评价指标中, 4 个关键测点的决定系数 R 值均高于 0.99, 表明预测值与真实值具有较高的一致性, 而平均绝对值误差分别为 0.547、0.368、0.618 和 0.376, 均方根误差分别为 0.673、0.462、0.753 和 0.469, 表明采用该方法建立的 CNN-LSTM 模型预测结构应变响应具有较高的精度。

3) CNN-LSTM 模型用于预测结构应变响应具有较好的预测效果。在所有测点上, 特征选择前后, CNN-LSTM 模型的平均绝对误差 (MAE)、决定系数 (R) 和均方根误差 (RMSE) 3 项指标与 Bi-LSTM 模型和 LSTM 模型相比, 准确性较高。这表明 CNN-LSTM 模型在预测精度上具有一定的优越性。

参考文献

- [1] PARK H S, AN J H, PARK Y J, et al. Convolutional neural network-based safety evaluation method for structures with dynamic responses [J]. Expert Systems with Applications, 2020, 158: 113634.
- [2] 高珂, 翁顺, 陈志丹, 等. 基于模式识别的结构健康监测异常数据诊断 [J]. 建筑结构学报, 2024, 45(3): 113-122.
- GAO K, WENG S, CHEN Z D, et al. Pattern

- recognition-based data anomaly detection for structural health monitoring [J]. *Journal of Building Structures*, 2024, 45(3): 113-122. (in Chinese)
- [3] 鞠翰文, 邓扬, 李爱群. 基于 GRU 神经网络的结构异常监测数据修复方法[J]. *振动与冲击*, 2023, 42(9): 328-338.
- JU H W, DENG Y, LI A Q. Restoring method of structural abnormal monitoring data based on GRU neural network [J]. *Journal of Vibration and Shock*, 2023, 42(9): 328-338. (in Chinese)
- [4] 杨娜, 付颖煜, 李天昊. 基于局部离群因子的数据异常识别方法及其在古建筑结构监测中的应用[J]. *建筑结构学报*, 2022, 43(10): 68-75.
- YANG N, FU Y Y, LI T H. Data anomaly identification method based on local outlier factor and application in monitoring data of heritage building structure [J]. *Journal of Building Structures*, 2022, 43(10): 68-75. (in Chinese)
- [5] 张云浩, 李波, 严国度, 等. 基于能量平衡的基础隔震结构地震响应预测及优化设计法研究[J]. *振动与冲击*, 2021, 40(17): 32-40.
- ZHANG Y H, LI B, YAN G Q, et al. Seismic response prediction and optimization design method for base isolated structure based on energy balance [J]. *Journal of Vibration and Shock*, 2021, 40(17): 32-40. (in Chinese)
- [6] 赵煜东, 许卫晓, 于德湖, 等. 基于人工神经网络的 RC 框架结构地震响应预测方法[J]. *地震研究*, 2024, 47(1): 123-134.
- ZHAO Y D, XU W X, YU D H, et al. Response prediction method of the RC frame structure based on the artificial neural network [J]. *Journal of Seismological Research*, 2024, 47(1): 123-134. (in Chinese)
- [7] OH B K, KIM J. Optimal architecture of a convolutional neural network to estimate structural responses for safety evaluation of the structures [J]. *Measurement*, 2021, 177: 109313.
- [8] TANG Z Y, BAO Y Q, LI H. Group sparsity-aware convolutional neural network for continuous missing data recovery of structural health monitoring [J]. *Structural Health Monitoring*, 2021, 20(4): 1738-1759.
- [9] WANG Z W, LI A D, ZHANG W M, et al. Long-term missing wind data recovery using free access databases and deep learning for bridge health monitoring [J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2022, 230: 105201.
- [10] JIANG F, DING Y L, SONG Y S, et al. Automatic pixel-level detection and measurement of corrosion-related damages in dim steel box girders using Fusion-Attention-U-net [J]. *Journal of Civil Structural Health Monitoring*, 2023, 13(1): 199-217.
- [11] RAHMAN A, WU Z Y, KALFARISI R. Semantic deep learning integrated with RGB feature-based rule optimization for facility surface corrosion detection and evaluation [J]. *Journal of Computing in Civil Engineering*, 2021, 35(6): 04021018.
- [12] 张加劲. 基于注意力机制和 CNN-BiLSTM 模型的航空发动机剩余寿命预测[J]. *电子测量与仪器学报*, 2022, 36(8): 231-237.
- ZHANG J J. Remaining useful life estimation of aeroengine based on CNN-BiLSTM and attention mechanism [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(8): 231-237. (in Chinese)
- [13] LIU Y, XUE J H, LI D X, et al. Image recognition based on lightweight convolutional neural network: Recent advances [J]. *Image and Vision Computing*, 2024, 146: 105037.
- [14] TIAN Y H. Artificial intelligence image recognition method based on convolutional neural network algorithm [J]. *IEEE Access*, 2020, 8: 125731-125744.
- [15] OH B K, PARK H S, 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.
- [16] 邓扬, 张强, 钟国强, 等. 桥梁拉索动力响应监测数据质量评价方法[J/OL]. *土木与环境工程学报(中英文)*. <https://link.cnki.net/urlid/50.1218.TU.20230808.1440.008>.
- DENG Y, ZHANG Q, ZHONG G Q, et al. Data quality evaluation method for dynamic response monitoring of bridge cables[J/OL]. *Journal of Civil and Environmental Engineering*. <https://link.cnki.net/urlid/50.1218.TU.20230808.1440.008>. (in Chinese)
- [17] 张立奎, 段大猷, 王佐才. 基于 LSTM 神经网络的多源数据融合桥梁变形重构方法[J]. *土木与环境工程学报(中英文)*, 2022, 44(3): 37-43.
- ZHANG L K, DUAN D Y, WANG Z C. A multi-source data fusion method for bridge displacement reconstruction based on LSTM neural network [J]. *Journal of Civil and Environmental Engineering*, 2022, 44(3): 37-43. (in Chinese)
- [18] 梁煜婉, 肖朝昀, 李明广, 等. 基于 LSTM 的真空预压地基沉降预测[J/OL]. *上海交通大学学报*. <https://doi.org/10.16183/j.cnki.jsjtu.2023.340>.
- LIANG Y W, XIAO C Y, LI M G, et al. Ground settlement prediction by vacuum preloading based on LSTM [J/OL]. *Journal of Shanghai Jiaotong University*. <https://doi.org/10.16183/j.cnki.jsjtu.2023.340>. (in Chinese)
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8):

1735-1780.

[20] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks [J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.

[21] HU L, WANG J, LEE H P, et al. Wear prediction of high performance rolling bearing based on 1D-CNN-LSTM hybrid neural network under deep learning [J]. Heliyon, 2024, 10(17): e35781.

[22] 冯凌斐, 李宏武, 张星魁, 等. 高耸结构整体提升施工过程模拟分析[J]. 建筑结构学报, 2023, 44(2): 284-293. FENG L F, LI H W, ZHANG X K, et al. Simulation analysis of construction process of overall lifting of towering structure [J]. Journal of Building Structures, 2023, 44(2): 284-293. (in Chinese)

[23] 张星魁, 郑芳俊, 李宏武, 等. 北疆明珠塔旋转餐厅整体提升施工模拟与监测[J]. 施工技术(中英文), 2022, 51(8): 35-40. ZHANG X K, ZHENG F J, LI H W, et al. Simulation and monitoring of integral lifting construction of revolving restaurant of Beijiang pearl tower [J]. Construction Technology, 2022, 51(8): 35-40. (in Chinese)

[24] ZHANG Y, ZHONG W, LI Y L, et al. A deep learning prediction model of DenseNet-LSTM for concrete gravity dam deformation based on feature selection [J]. Engineering Structures, 2023, 295: 116827.

[25] 周静雷, 周智, 崔琳. 应用变分模态分解和随机森林特征选择算法的扬声器异常声分类[J]. 振动与冲击, 2022, 41(20): 277-283. ZHOU J L, ZHOU Z, CUI L. Loudspeaker abnormal sound classification using variational modal decomposition and the random forest feature selection algorithm [J]. Journal of Vibration and Shock, 2022, 41(20): 277-283. (in Chinese)

(编辑 XXX)