

•智能交叉科学与工程•

DOI:10.12454/j.jsuese.202401045



本刊网刊

桥梁挠度的DWT-LSTM分离预测模型及工程应用

郑帅¹,姜赫¹,王忠昶¹,丁嘉²,杨益¹

(1.大连交通大学 交通工程学院,辽宁 大连 116028;2.中铁建大桥工程局集团第一工程有限公司,辽宁 大连 116033)

摘要:桥梁挠度具有复杂性及非线性动态变化的特征,以往的预测模型常受挠度响应的滞后性和历史监测数据复杂波形干扰的限制。鉴于此,提出一种基于DWT-LSTM(discrete wavelet transform-long short-term memory)的桥梁挠度分离预测方法。利用小波优化原理将历史桥梁挠度数据分解为趋势项挠度和噪声项挠度;在此基础上结合外界因素构建基于LSTM神经网络的车载、温度和桥梁挠度的噪声项多因素时序预测模型和趋势项时序预测模型,分别对两项挠度序列展开预测并根据时间序列加和原理获得最终的桥梁累积挠度预测值;以雄商高铁跨大广高速桥项目为例,利用该模型分别对短、中、长3个时段的桥梁挠度进行预测,并与传统BP模型和LSSVM模型进行对比,借助最大信息相关系数对噪声项挠度的影响因素展开分析。结果表明:在短、中时段挠度预测中,3种模型的预测结果大致相同;在长时段挠度预测中,基于DWT-LSTM的桥梁挠度分离预测模型能够有效地对两项挠度信号进行预测。以9月11日长时段累积挠度预测为例,相较于LSSVM模型和BP神经网络,本文所提模型的均方根误差分别降低22.70%和28.76%,平均绝对误差分别降低39.26%和41.73%;温度和车载的最大信息相关系数分别为0.35和0.51,表明车载和温度对噪声项挠度均有重要影响且车载的影响要高于温度。研究为桥梁挠度长期预测提供了一种新的思路和方法。

关键词:长短期记忆网络;小波优化;桥梁挠度;多因素预测;车载影响参数

中图分类号:U24

文献标志码:A

文章编号:2096-3246(2026)02-0035-11

桥梁在长期服役的过程中往往会因为环境与运营荷载的耦合作用,结构性能不断退化,甚至引发灾变垮塌事故^[1]。挠度是分析桥梁结构受力及耐久性能的重要参数。利用挠度数据可以分析该桥梁在极端气候、自然灾害等条件下的结构受力情况,从而有效地预防桥梁灾害事故的发生。因此,形成准确的桥梁挠度预测方法,进一步对运营中的桥梁的挠度变化规律进行研究,就能较早地发现桥梁的异常情况^[2],这对桥梁的安全运营和维护有着重要意义。

近年来,随着人工智能技术的不断发展,利用智能化手段对桥梁结构状态和安全状况进行评估已逐渐成为桥梁健康监测的主要发展趋势^[3]。常用的智能预测模型有LSTM^[4-7]、BP神经网络^[8]、随机森林^[9]、ANN^[10]等,这些算法存在一定的局限性,并且由于影响因素的复杂多变,监测数据往往具有高度非线性和

非平稳性的特征,最终影响算法的预测精度。事实上,运营期间监测到的桥梁挠度信号是环境荷载、车辆荷载、材料劣化、噪声等因素共同作用导致的^[11]。准确分离外界因素作用下的桥梁挠度特性,预测结构的长期变形趋势,有助于桥梁性能评估和结构安全预警^[12]。为更好地分离外界因素作用下的桥梁挠度特性,Li等^[13]提出一种基于时变滤波经验模态分解(TVFEMD)、排列熵(PE)和Kullback-Leibler散度(KLD)的挠度分离方法,实现了温度诱导挠度的提取。Xin等^[14]提出一种基于改进的变分模态分解理论(IVMD)对挠度信号进行分解的方法,该方法不仅可以通过Hilbert变换和经验模态分解自适应地优化分解层数,还可以通过Kullback-Leibler散度和Gram-Schmidt正交化来抑制无关分量的干扰。但上述算法均较为复杂且过于追求对挠度信号的多层次分解与预测,大量分解产生的挠度信号分量易导致模型

收稿日期:2024-12-17 修回日期:2025-06-03 网络出版日期:2025-06-12

基金项目:辽宁省自然科学基金项目(2025MS150;2025-BSLH-103);辽宁省交通运输厅科技项目(202508);辽宁省高校基本科研业务费专项资金项目(LJ222410150043);辽宁省教育学科规划项目(JG25DB078;JG25DB080);大连市青年科技之星计划(2024RQ023)

作者简介:郑帅(1992—),男,副教授,博士。研究方向:桥隧工程数字智能化。E-mail:534821326@qq.com

出现过拟合、维度灾难及误差累积等问题,最终影响模型的计算精度及效率,实用性不强。

目前,桥梁结构挠度数据的分析和预测主要集中在温度效应和车载效应。郑秋怡等^[15]基于 LSTM 提出一种考虑温度影响的桥梁位移预测模型,并将其应用于某大桥的热位移预测分析;Deng 等^[16]基于 GRU 提出一种考虑车载和温度影响的桥梁挠度相关性预测模型,并分别考察了模型在短时段和中长时段的预测精度。上述预测方法虽然充分考虑了外界因素对桥梁挠度所造成的影响,验证了考虑温度、荷载等多因素桥梁挠度预测的合理性,但这些预测方法没有充分考虑和区分趋势项和噪声项的数据变化特点及影响,此类预测方法相对简单,不能充分挖掘输入信息的内部规律^[17]。仅采用单一模型反映桥梁结构变形的复杂性和多尺度性,难以充分挖掘不同尺度分量下桥梁挠度响应的特征^[18],且部分研究^[19]在挠度预测过程中忽视了外界因素引发挠度响应的时滞问题,这也影响了模型的预测精度。

针对上述问题,本文提出一种基于 DWT-LSTM 的桥梁挠度分离预测方法,利用不同挠度分量在时间尺度上不耦合的特点,利用小波优化原理分解桥梁历史挠度,结合荷载、温度等外界因素构建基于 LSTM 神

经网络的桥梁挠度噪声项多因素时序预测模型和趋势项时序预测模型,并分别进行预测。该方法能有效解决外界因素响应挠度的时滞问题^[20],并通过分析各挠度分量的变化特征及外界因素的作用,进一步提高模型的预测精度。依托雄商高铁工程项目,应用本文模型实现对未来桥梁挠度变化的超前预测,可解决以往桥梁挠度预测精准度低、误差大的难题。该方法可为桥梁变形安全风险提供新的技术支持。

1 桥梁挠度变形预测方法

1.1 桥梁挠度分离预测模型

为提高预测精度,改善模型泛化能力,本文基于小波优化和时间序列原理建立了桥梁挠度分离预测模型,其流程如图 1 所示,具体步骤为:1)根据小波优化理论对历史桥梁挠度数据进行降噪并分解;2)选取车载和温度等影响因素,结合噪声项挠度分量构建基于 LSTM 神经网络的噪声项多因素时间序列预测模型;3)利用趋势项挠度分量构建基于 LSTM 的趋势项时间序列预测模型;4)分别对两项序列展开预测,并将获得的两项预测结果根据时间序列原理叠加得到桥梁累积挠度预测值。

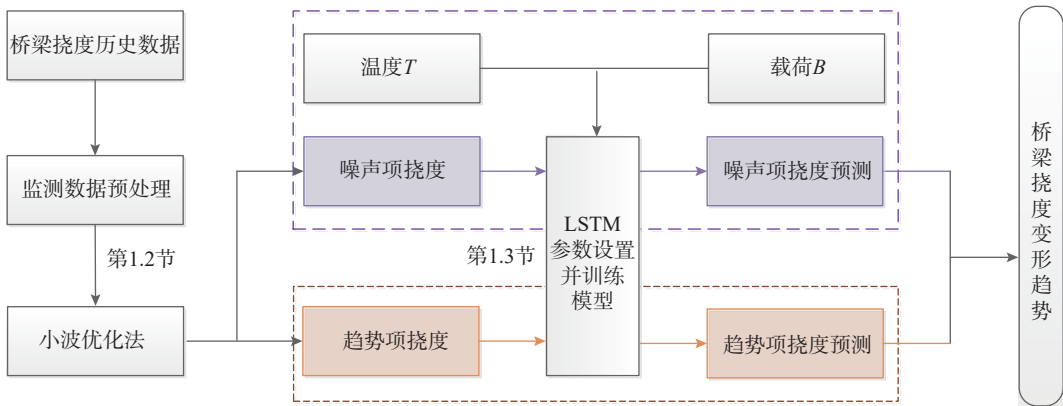


图 1 桥梁挠度变化跨时分项时间序列模型技术流程

Fig. 1 Technical process of time-domain partial time series model of bridge deflection change

1.2 桥梁挠度监测数据预处理

受车载、温度等外界因素的影响,桥梁挠度监测数据往往包含了多种噪声。噪声即高频误差,它的存在将会影响模型对输入信息的学习,降低模型的预测精度。为了实现桥梁挠度的精细化预测,本文提出了基于小波变化 LSTM 的桥梁挠度分离预测模型。利用小波变换原理分离桥梁挠度监测数据中的噪声,构建噪声项挠度,剩余监测数据划分为趋势项挠度。基于此,利用小波优化原理,对历史桥梁挠度数据进行分解,具体如下。

1)对桥梁历史监测数据进行处理,通过剔除异常值和线性插值等方法将数据划分成等距时间

序列。

2)利用选取的分解层数和小波基函数对输入信息进行降噪处理,并将其进一步分解成多个子信号:

$$f(t) = c_{j,k} \sum_k \phi_{j,k} + d_{j,k} \sum_k \psi_{j,k} \quad (1)$$

式中: $f(t)$ 为挠度信号,其中, t 为时间标识; $\phi_{j,k}$ 为近似信号, $\psi_{j,k}$ 为细节信号,其中, j 为分解层数, k 为位置参数, $c_{j,k}$ 与 $d_{j,k}$ 为相应的系数。

接着,设置合理的阈值 T_k ,并将低于该阈值的子信号值降为 0,最终完成对输入信息的降噪过程。常用的阈值计算方法为:

$$T_k = \sigma \sqrt{2 \ln n_0} \quad (2)$$

式中, n_0 为信号的采样长度, σ 为噪声信号的方差^[21]。

最终, 可将桥梁历史监测数据 $f(t)$ 分解成趋势项挠度 $\alpha(t)$ 与噪声项挠度 $\beta(t)$ 之和:

$$f(t) = \alpha(t) + \beta(t) \quad (3)$$

式中, $f(t)$ 为桥梁挠度历史监测数据, $\alpha(t)$ 为分解后的趋势项挠度, $\beta(t)$ 为分解后的噪声项挠度。

1.3 桥梁挠度分离预测模型的构建

采用滚动预测, 假设所监测的序列的前 L 个观测周期对之后的第 p 个周期产生影响, 分别对各个时间序列的样本空间进行重构, 并将其划分为训练集和测试集。为解决以往桥梁挠度预测未充分挖掘桥梁历史数据内在规律的问题, 并合理地分析外界因素对桥梁挠度的影响, 本文引入 LSTM 神经网络, 利用训练集对 LSTM 进行训练并预测, 最终获得趋势项挠度预测值 $\alpha(t)^*$ 。式(4)~(9)为计算过程:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (5)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (6)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \tanh(c_t) \quad (8)$$

$$y_t = \text{softmax}(w_y[h_t, y_{t-1}] + b_y) \quad (9)$$

式(4)~(9)中: f_t 、 i_t 、 o_t 为遗忘门、输入门和输出门的输出向量; x_t 为输入模型序列数据; W_f 、 W_i 、 W_c 、 W_o 为权重系数矩阵; b_f 、 b_i 、 b_o 、 b_y 分别为遗忘门、输入门、输出门和预测结果的偏置项矩阵; c_{t-1} 和 c_t 分别为 LSTM 细胞在上一时刻和当前时刻的细胞状态; h_{t-1} 和 h_t 分别为 LSTM 细胞在上一时刻和当前时刻的输出; σ 为 Sigmoid 函数; \tanh 为双曲正切激活函数; y_t 为桥梁挠度预测值, 也即 $\alpha(t)^*$; softmax 为激活函数; w_y 为权重系数矩阵; y_{t-1} 为上一时刻桥梁挠度监测值^[22]。

为了解决车载与桥梁挠度、温度在时域分布特征上存在的差异, 本文借鉴文献[16]中的车载参数计算方法, 利用桥梁挠度影响线将离散的车载监测数据转化为时间连续的车载影响参数, 并将其与温度一起作为 LSTM 预测模型的输入, 对噪声项挠度 $\beta(t)^*$ 进行预测。

根据时间序列的加法模型, 将两项预测结果相加即可得到桥梁累积挠度预测值 $f(t)^*$:


$$f(t)^* = \alpha(t)^* + \beta(t)^* \quad (10)$$

2 工程应用

2.1 数据来源

雄安特大桥跨大广高速矮塔斜拉桥位于河北省任丘市境内, 于 DK137+485.32 处跨越大广高速, 线路与道路右交角为 $24^\circ 36'$, 设计里程范围为 DK137+267.60~

DK137+709.70, 全长 441.7 m。桥墩范围 798#~801#墩, 结构类型为 CRTS III 型板式无砟轨道(110+220+110) m 预应力混凝土斜拉桥。雄安特大桥跨大广高速矮塔斜拉桥建成通车后结构健康监测即正式开始运行, 监测参数包含温度、结构动力特征、主梁挠度等。主梁挠度检测采用差压变送器的方法, 仪器参考精度为 0.065% (与所设置的量程相关)。测点布置如图 2 所示, 主要位于边跨、辅助跨跨中, 由于主梁挠度较大, 且受荷载影响作用各点挠度变化差异明显, 因此在 1/4 跨、跨中、3/4 跨均布设测点。



注: P 为压力传感器, T 为温度传感器, W 为 WIN 传感器。

图 2 监测点布置

Fig. 2 Monitoring point layout

短、中期挠度预测可以验证桥梁在特殊荷载作用下的力学响应, 而长期挠度预测可有效预警桥梁潜在损伤。为了更准确地考察模型的预测精度和泛化能力, 参考文献[23]中的时段划分方法, 分别从短(秒级)、中(分钟级)、长(小时级) 3 个时段对模型预测能力进行考察。

2.2 短、中时段模型预测结果

首先, 分别建立短、中两个时段的桥梁挠度分离预测模型, 考察模型在秒级和分钟级两种不同时间尺度上的预测精度。选取现场 21:00—21:04 和 21:00—22:00 两组监测数据, 分别划分为短时段和中时段, 每组数据集中包含 120 个数据样本点。选取前 75% 数据 (3、45 min) 为训练集, 后 25% 数据 (1、15 min) 为测试集。采用 BP 神经网络、LSSVM 和 LSTM 神经网络 3 种模型对桥梁挠度进行预测, 并比较 3 种模型对挠度数据的预测精度。为了更科学合理地对比模型预测精度, 本文采用具有较强泛化能力的径向基函数^[24]作为 LSSVM 的核函数进行模型预测精度的验证。同时, 结合现有研究结果, 分别采用 tansig 函数和 purelin 函数作为 BP 模型的隐含层传递函数和输出层传递函数^[25], 并基于经验公式确定隐含层节点数量 h :

$$h = \sqrt{m+n} + a \quad (11)$$

式中, m 为输出层节点个数, n 为输入层节点个数, a 为

[0,10]之间的常数。

BP神经网络的隐藏层节点的计算结果为21。为更好地衡量模型的预测精度,本文采用相关性系数 R (式(12))、均方根误差(E_{RMS})和平均绝对误差(E_{MA})3项指标评价模型预测精度。

$$R = \frac{\sum_{i=1}^N (d_i - \bar{d})(\hat{d}_i - \bar{\hat{d}})}{\sqrt{\sum_{i=1}^N (d_i - \bar{d})^2 \sum_{i=1}^N (\hat{d}_i - \bar{\hat{d}})^2}} \quad (12)$$

式中, N 为样本总数, i 为样本编号, d_i 为监测数据, \hat{d}_i 为预测数据, \bar{d} 为监测值均值, $\bar{\hat{d}}$ 为预测值均值。

2.2.1 趋势项挠度预测及分析

分别采用本文模型、LSSVM模型和BP神经网络预测模型对矮塔斜拉桥短、中时段趋势项挠度进行预测。预测结果见图3。表1为短、中时段趋势项挠度预测精度及误差。

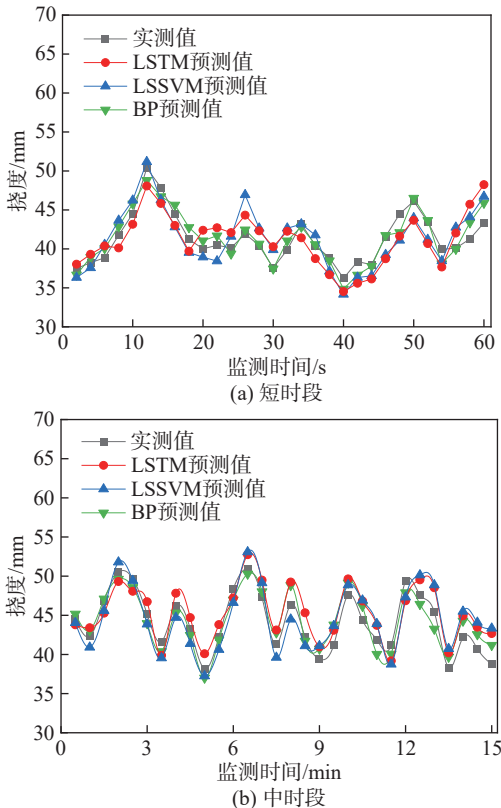


图3 短、中时段趋势项挠度预测结果

Fig. 3 Trend deflection prediction results of short-term and middle-term

由图3可知,在对短、中时段趋势项挠度的预测中,BP预测模型的预测效果均明显优于LSTM神经网络和LSSVM预测模型。结合表1进一步分析可知:在短时段趋势项挠度预测中,LSTM预测精度略低于LSSVM;但在中时段桥梁挠度预测中,LSTM模型的均方根误差和平均绝对误差与BP模型相比分别降低

12.4%、12.8%,预测精度有所提升。

表1 短、中时段趋势项挠度预测精度及其误差

Tab. 1 Trend deflection prediction accuracies and errors of short-term and middle-term

预测模型	R		E_{RMS}/mm		E_{MA}/mm	
	短时段	中时段	短时段	中时段	短时段	中时段
LSTM	0.74	0.88	2.36	2.10	2.20	1.95
LSSVM	0.82	0.85	2.17	2.14	1.96	1.99
BP	0.93	0.92	1.44	1.46	0.98	1.31

2.2.2 噪声项挠度预测及分析

采用上述3种模型对斜拉索桥的噪声项挠度展开预测,3种模型在短、中时段预测结果见图4,两时段的模型预测精度及误差见表2。

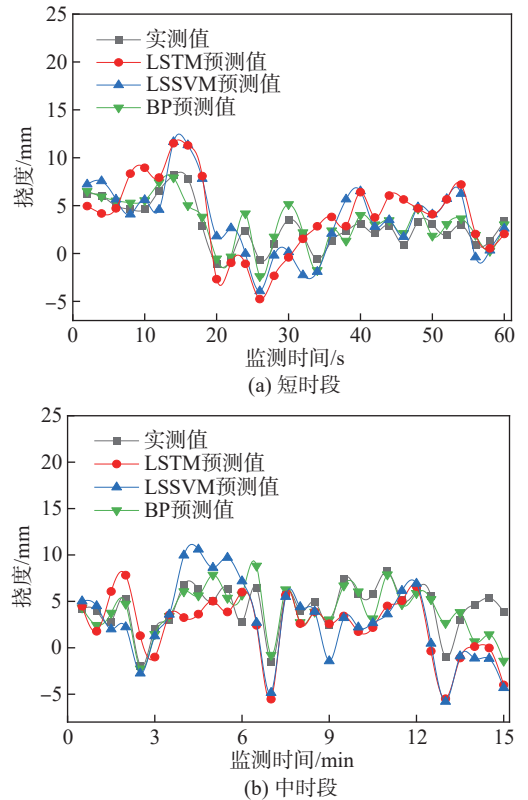


图4 短、中时段噪声项挠度预测结果

Fig. 4 Noise term deflection prediction results of short-term and middle-term

表2 短、中时段噪声项挠度精度及其误差

Tab. 2 Noise deflection accuracies and errors of short-term and middle-term

预测模型	R		E_{RMS}/mm		E_{MA}/mm	
	短时段	中时段	短时段	中时段	短时段	中时段
LSTM	0.74	0.63	2.89	3.45	2.50	2.86
LSSVM	0.77	0.54	2.46	3.62	2.09	3.01
BP	0.91	0.72	1.09	1.95	0.93	1.40

2.2.3 累积挠度预测及分析

利用时序分析原理,将两项挠度预测值进行叠

加,得到短、中时段桥梁累积挠度预测结果。3种模型在短、中时段预测结果见图5,两时段的模型预测精度及误差见表3。




图5 短、中时段累积挠度预测结果

Fig. 5 Cumulative deflection prediction results of short-term and middle-term

表3 短、中时段累积挠度精度及其误差

Tab. 3 Cumulative deflection accuracies and errors of short-term and middle-term

预测模型	R		E_{RMS}/mm		E_{MA}/mm	
	短时段	中时段	短时段	中时段	短时段	中时段
LSTM	0.93	0.92	1.93	1.99	1.74	1.85
LSSVM	0.95	0.93	1.69	2.01	1.57	1.88
BP	0.96	0.91	1.36	1.66	1.26	1.60

由图5可知, BP模型精度最高, 挠度预测结果与实际值基本一致。结合表3进一步分析可知, 在短、中时段挠度预测过程中, 3种模型误差指标均相差不大, 都收获了较为满意的预测结果, 也进一步验证了3种模型用于短、中时段挠度预测的可靠性。另外, LSSVM模型在中时段挠度预测过程中出现了“过拟合”问题, 即模型前期拟合效果较好, 后期性能下降较快, 这主要由于LSSVM模型为静态模型, 无法利用新的监测数据更新网络, 因此随着监测时间的延长, 模型泛化能力变差, 从而出现较大的预测误差。

2.3 长时段模型预测结果

在桥梁监测系统长期运行过程中, 大量有用信息会被掩盖, 给信号分析带来困难^[26]。因此, 将长期监测数据进行有效分离并开展高精度预测, 对运营状态下桥梁安全状况的评估具有重要的现实意义。为此, 本文建立长时段的桥梁挠度分离预测模型, 选取2023年9月11日和9月13日两天的现场监测数据(共240个时间点), 分别划为长时段1和长时段2, 用于该模型预测精度验证。取两时段前75%(18 h)的数据训练LSTM预测模型, 后25%(6 h)的数据测试模型的预测能力, 考察3种模型在小时级时间尺度上的桥梁挠度预测能力。采用第2.2节所述的两种模型对本文模型的预测精度进行验证。

2.3.1 趋势项挠度预测及分析

分别利用3种模型对长时段桥梁趋势项挠度进行预测, 预测结果见图6, 两时段预测精度及误差见表4。

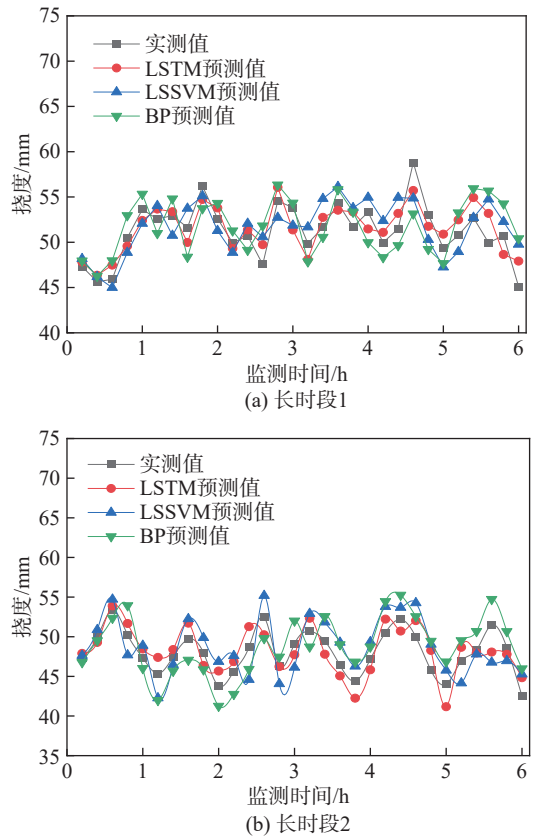


图6 长时段趋势项挠度预测结果

Fig. 6 Prediction results of long-term trend deflection

表4 长时段趋势项挠度预测精度及其误差

Tab. 4 Prediction accuracies and errors of long-term trend deflection

预测模型	R		E_{RMS}/mm		E_{MA}/mm	
	长时段1	长时段2	长时段1	长时段2	长时段1	长时段2
LSTM	0.83	0.81	1.70	1.76	1.54	1.60
LSSVM	0.70	0.70	2.31	2.57	2.03	2.36
BP	0.57	0.72	2.79	2.60	2.41	2.44

由图6可知,在长时段桥梁趋势项挠度的预测中,LSTM预测模型的整体预测精度要高于BP神经网络和LSSVM。结合表4进一步分析,以LSTM预测模型在两个长时段的趋势项挠度预测为例,相关性系数分别达到了0.83和0.81,均方根误差分别为1.70和1.76 mm,平均绝对误差分别为1.54和1.60 mm,3项误差指标均以本文模型最佳,预测精度最高,误差最小,进一步验证了本文模型的工程实用性。

2.3.2 噪声项挠度预测及分析

分别利用3种模型对长时段1和长时段2两个时段桥梁噪声项挠度进行预测,预测结果见图7,两时段预测精度及误差见表5。对比图3、4、6和7可知:图3、6中的趋势项挠度信号为长周期、低频率的大比重时间序列,反映桥梁变形的主要趋势,是由桥梁长期服役所引发的结构老化、预应力损伤等因素决定;图4、7中的噪声项挠度信号则是一组短周期、高频率的小比重时间序列,波动较为剧烈,主要反映桥梁所受温度、动荷载等外界因素的影响。针对上述两种特征尺度不同的挠度序列,单一的预测模型往往难以充分挖掘两项挠度信号的内部规律,最终导致模型预测结果偏差较大^[27]。这也进一步验证了采用组合模型预测的必要性。

表5 长时段噪声项挠度预测精度及其误差

Tab. 5 Prediction accuracies and errors of long-term noise deflection

预测模型	R		E_{RMS}/mm		E_{MA}/mm	
	长时段1	长时段2	长时段1	长时段2	长时段1	长时段2
LSTM	0.74	0.77	2.52	2.19	2.29	2.20
LSSVM	0.43	0.48	4.20	4.32	3.77	3.52
BP	0.59	0.37	4.39	4.90	3.93	3.53

2.3.3 累积挠度预测及分析

将两项时序挠度预测值进行加和处理,最终得出长时段桥梁累积挠度预测值,预测结果如图8所示,两时段累计挠度预测精度及误差见表6。


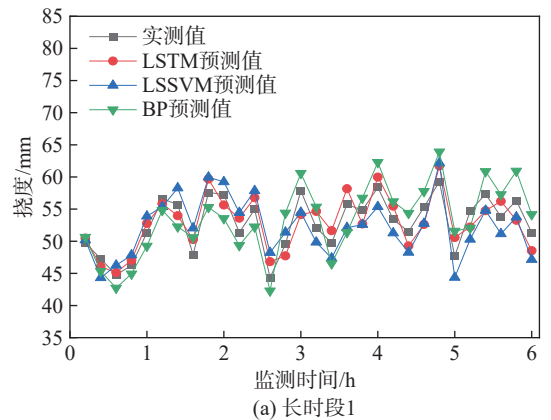


图8 长时段累积挠度预测结果

Fig. 8 Prediction results of long-term cumulative deflection

表6 长时段累积挠度预测精度及其误差

Tab. 6 Prediction accuracies and errors of long-term cumulative deflection

预测模型	R		E_{RMS}/mm		E_{MA}/mm	
	长时段1	长时段2	长时段1	长时段2	长时段1	长时段2
LSTM	0.86	0.77	2.18	2.20	2.05	1.91
LSSVM	0.80	0.59	2.82	3.52	2.45	3.13
BP	0.84	0.60	3.06	3.53	2.89	3.24

从图8可以看出,LSTM神经网络模型的挠度预测结果明显优于BP神经网络和LSSVM模型。这是由于

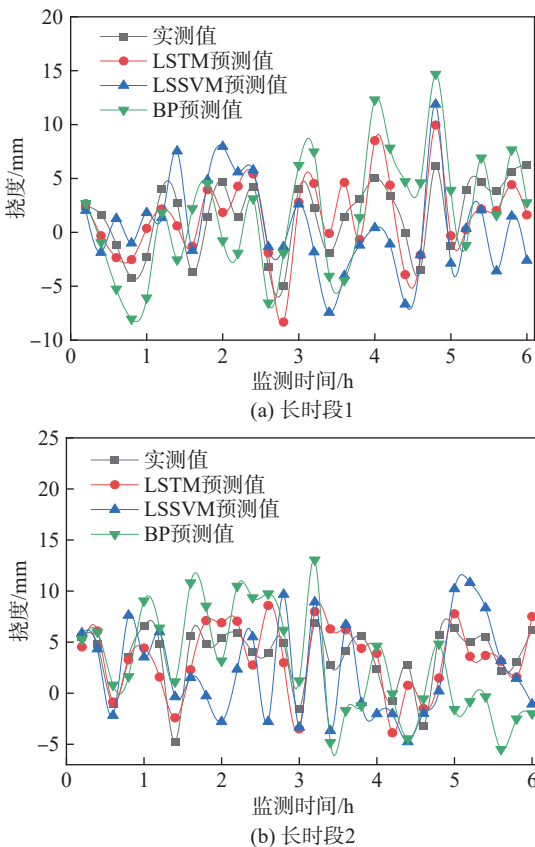


图7 长时段噪声项挠度预测结果

Fig. 7 Prediction results of long-term noise term deflection

BP模型仅在不同隐含层之间建立权连接,并通过激活函数控制输出,无法挖掘时间序列数据的内部模式,在长距离传递信息时容易产生梯度消失和梯度爆炸等问题,而LSSVM预测模型在长时段预测过程中再次出现了较为严重的过拟合问题。由表6可知,在长时段累积挠度预测中,LSTM的 R 分别达到了0.86和0.77, E_{RMS} 分别为2.18和2.20 mm, E_{MA} 分别为2.05和1.91 mm,本文模型预测精度在3种模型中最高,模型稳定性最好,实用效果最佳。

对比表3和6可知:在短、中时段预测中,BP神经网络的预测精度要明显优于LSSVM模型和LSTM神经网络;而在长时段预测中,LSTM的预测精度为3种模型中最高。这是由于短、中时段的数据关系相对简单,BP神经网络可以利用较少的参数和浅层结构快速捕捉局部特征;而LSTM受限于细胞单元的门控机制,精度较低;LSSVM则是受到训练样本高频波动的干扰及模型的平滑性假设,预测精度相对较低。在长时段预测中,BP神经网络在滚动预测的过程中预测误差会逐步积累且受限于其网络结构特性,难以有效建立长周期时序依赖关系;而LSSVM则受限于过拟合和样本数据复杂波形,预测精度较低。相比上述两种模型,LSTM凭借着门控单元实现了对无关噪声的过滤,同时提取时间序列的多尺度特征,并借助细胞状态更新实现对记忆信息的传递,从而展现出较强的动态适应能力。

3 讨 论

3.1 小波优化分解的必要性验证

为验证本文预测方法的可靠性,以现场9月11日桥梁挠度数据为例,将本文的桥梁挠度分离预测方法与LSTM模型进行比较,图9为两种方法的预测结果与实际测量挠度的对比。

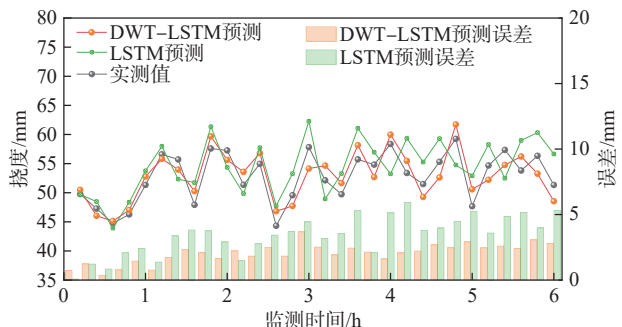


图9 预测挠度与实际挠度对比

Fig. 9 Comparison of predicted deflection and actual deflection

由图9可知:相比较于本文的LSTM挠度分离预测方法,采用单一LSTM预测模型的预测结果与监测值偏差较大,预测精度较低,其均方根误差为

3.74 mm,平均绝对误差为3.45 mm,两项误差指标均高于本文预测模型;相比之下,基于DWT-LSTM挠度分离预测模型的预测精度最高,其 E_{RMS} 仅2.18 mm, E_{MA} 仅2.05 mm。两种模型精度相差较大的原因在于本文构建的模型充分考虑了噪声项和趋势项序列的变化特征,利用组合模型分别反映不同尺度分量上的桥梁挠度变化特征,弥补了单一预测模型在反映桥梁结构复杂多尺度变形时的局限性,从而表现出更好的预测性能。

3.2 考虑影响因素预测的必要性验证

为验证影响因素在桥梁噪声项挠度预测中的必要性,继续以现场9月13日桥梁挠度数据为例,将本文的预测方法分别与未考虑影响因素的LSTM挠度分离预测、考虑温度因素的LSTM挠度分离预测、考虑荷载因素的LSTM挠度分离预测进行对比,图10为4种工况下预测结果与实际测量挠度的对比。图10中,工况1考虑温度和荷载影响,工况2只考虑荷载因素,工况3只考虑温度因素,工况4不考虑影响因素。




图10 预测挠度与实际挠度对比

Fig. 10 Comparison of predicted deflection and actual deflection

由图10可知,未考虑影响因素的LSTM分离预测结果的误差最大,其 E_{RMS} 为3.91 mm, E_{MA} 为3.38 mm。对比仅考虑单一影响因素的两种工况,考虑荷载因素的LSTM分离预测结果与实际测量值的一致性更好,其 E_{RMS} 为2.81 mm, E_{MA} 为2.65 mm。与这3种方法对比,本文所提出的方法具有最好的预测效果和精度,其 E_{RMS} 为2.18 mm, E_{MA} 为2.05 mm。说明本研究所建立的预测模型考虑荷载因素与温度因素是必要的。

3.3 噪声项挠度优势影响因素分析

为进一步研究本文所建立的噪声项桥梁挠度多因素预测模型中考虑温度、荷载的必要性,仍以现场9月11日18:00—24:00的噪声项挠度数据为例,对其部分影响因素(温度、荷载)进行分析,结果如图11所示。

本文借鉴最大信息相关系数(MIC),将其引入噪

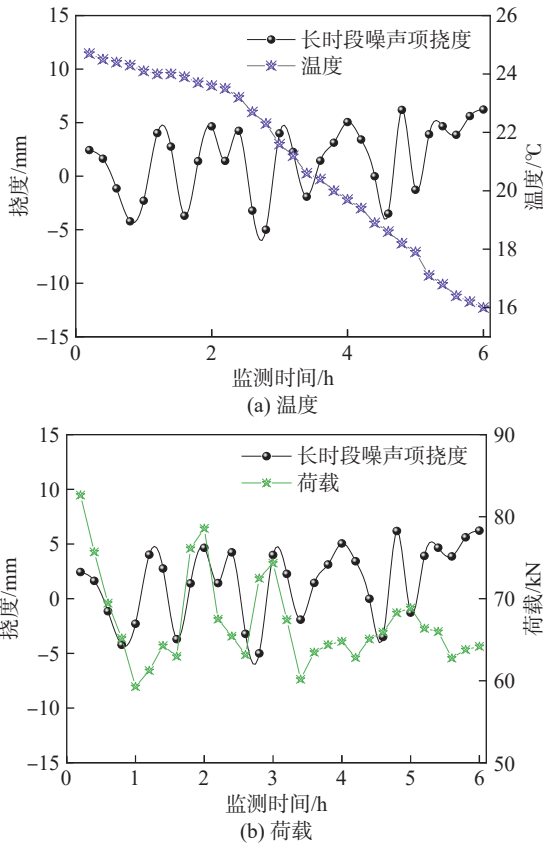


图 11 外界影响因素与噪声项挠度变化的数据统计

Fig. 11 Data statistics of external influence factors and deflection change of noise term

声项挠度优势影响因素分析中。MIC 是 Reshef 等^[28]提出的大数据探索性统计分析方法,旨在挖掘大量信息中数据的相关性。信息熵 $H(X)$ 的表达式为^[29]:

$$H(X) = - \sum p(x_i) \ln(p(x_i)), i = 1, 2, \dots, n \quad (13)$$

式中, X 为随机变量, x_i 为随机变量的值, $p(x_i)$ 为发生的概率。

MIC 值越高,说明参数对结果的影响越大^[30]。计算结果表明,温度、荷载等影响因素均与桥梁噪声项挠度变化存在较强的相关性,关联度指标分别为 0.35 和 0.51。根据关联度指标排序,两因素对桥梁噪声项挠度的影响由大到小为荷载 > 温度。由此可见,在建立桥梁挠度分项时序预测模型过程中,考虑外界影响因素是必要的。

4 结 论

1) 本文使用小波优化法对桥梁历史挠度数据进行分解和降噪,降低了监测数据的复杂性。在此基础上,结合荷载、温度等外界影响因素构建了基于 LSTM 神经网络的噪声项多因素时间序列预测模型和趋势项时间序列预测模型并分别进行预测,在反映出各序列自身尺度特征的同时也提高了桥梁挠度预测的准

确性。研究结果表明,在长时段桥梁挠度预测中,本文模型预测精度最高且误差最小,具有最佳的泛化能力,验证了本文模型的合理性及工程实用性。

2) 雄安特大桥跨大广高速矮塔斜拉桥的挠度变化受桥梁结构预应力、荷载和温度等多因素的综合影响。与不考虑和仅考虑单一影响因素的噪声项时序预测模型相比,本文所用的考虑多因素的噪声项时序预测模型预测结果最优,实现了对桥梁挠度变化的精细化预测。

3) 通过与 LSSVM 模型和 BP 模型在短、中、长 3 个时段的挠度预测结果进行对比可知,在短、中时段 3 种模型的挠度预测结果大致相同,但在长时段桥梁挠度预测中,考虑时滞效应的 LSTM 预测精度最高且具有最好的泛化能力。

4) 通过最大信息相关系数对本文所建立的跨区域分项时序预测模型中各影响因素与桥梁噪声项挠度的相关性进行分析,发现荷载对桥梁噪声项挠度的影响程度高于温度,研究结果可为后续更精确地预测桥梁变形提供借鉴。

参考文献:

- [1] Li Hui, Bao Yuequan, Li Shunlong, et al. Data science and engineering for structural health monitoring[J]. Engineering Mechanics, 2015, 32(8): 1-7. [李惠, 鲍跃全, 李顺龙, 等. 结构健康监测数据科学与工程[J]. 工程力学, 2015, 32(8): 1-7.]
- [2] Chen Shuyang, Xu Linrong, Cao Lulai. Prediction of subsidence of high-speed railway considering regional subsidence using dynamic neural network method[J]. Journal of the China Railway Society, 2015, 37(5): 83-87. [陈舒阳, 徐林荣, 曹禄来. 基于动态神经网络法考虑区域沉降的高速铁路沉降预测[J]. 铁道学报, 2015, 37(5): 83-87.]
- [3] Editorial Department of China Journal of Highway and Transport. Review on China's bridge engineering research: 2021[J]. China Journal of Highway and Transport, 2021, 34(2): 1-97. [《中国公路学报》编辑部. 中国桥梁工程学术研究综述·2021[J]. 中国公路学报, 2021, 34(2): 1-97.]
- [4] Zhu Siyu, Yang Mengxue, Xiang Tianyu, et al. Advanced time-series prediction of bridge long-term deflection using the learning models[J]. Structures, 2024, 67: 106967.
- [5] Ju Hanwen, Shi Huaiyuan, Shen Weicheng, et al. An accurate and low-cost vehicle-induced deflection prediction framework for long-span bridges using deep learning and monitoring data[J]. Engineering Structures, 2024, 310: 118094.
- [6] Yue Zixiang, Ding Youliang, Zhao Hanwei. Deep learning-based minute-scale digital prediction model of temperature-induced deflection of a cable-stayed bridge: Case study[J]. Journal of Bridge Engineering, 2021, 26(6): 05021004.

- [7] Wang Manyang, Ding Youliang, Zhao Hanwei. Digital prediction model of temperature-induced deflection for cable-stayed bridges based on learning of response-only data[J]. *Journal of Civil Structural Health Monitoring*, 2022, 12(3): 629–645.
- [8] Wang Xudong, Miao Changqing, Wang Xiaoming. Prediction analysis of deflection in the construction of composite box-girder bridge with corrugated steel webs based on MEC-BP neural networks[J]. *Structures*, 2021, 32: 691–700.
- [9] Van Le M, Nguyen D D, Ha H, et al. Ensemble soft computing models for prediction of deflection of steel-concrete composite bridges[J]. *Arabian Journal for Science and Engineering*, 2024, 49(4): 5505–5515.
- [10] Kumar S, Patel K A, Chaudhary S, et al. Rapid prediction of long-term deflections in steel-concrete composite bridges through a neural network model[J]. *International Journal of Steel Structures*, 2021, 21(2): 590–603.
- [11] Zong Zhouhong, Zhong Rumian, Zheng Peijuan, et al. Damage and safety prognosis of bridge structures based on structural health monitoring: Progress and challenges[J]. *China Journal of Highway and Transport*, 2014, 27(12): 46–57. [宗周红, 钟儒勉, 郑沛娟, 等. 基于健康监测的桥梁结构损伤预后和安全预后研究进展及挑战[J]. *中国公路学报*, 2014, 27(12): 46–57.]
- [12] Chen Guoliang, Lin Xungen, Yue Qing, et al. Study on separation and forecast of long-term deflection based on time series analysis[J]. *Journal of Tongji University(Natural Science)*, 2016, 44(6): 962–968. [陈国良, 林训根, 岳青, 等. 基于时间序列分析的桥梁长期挠度分离与预测[J]. *同济大学学报(自然科学版)*, 2016, 44(6): 962–968.]
- [13] Li Shuangjiang, Xin Jingzhou, Jiang Yan, et al. Temperature-induced deflection separation based on bridge deflection data using the TVFEMD-PE-KLD method[J]. *Journal of Civil Structural Health Monitoring*, 2023, 13(2): 781–797.
- [14] Xin Jingzhou, Jiang Yan, Zhou Jianting, et al. Bridge deformation prediction based on SHM data using improved VMD and conditional KDE[J]. *Engineering Structures*, 2022, 261: 114285.
- [15] Zheng Qiuyi, Zhou Guangdong, Liu Dingkun. Method of modeling temperature-displacement correlation for long-span arch bridges based on long short-term memory neural networks[J]. *Engineering Mechanics*, 2021, 38(4): 68–79. [郑秋怡, 周广东, 刘定坤. 基于长短时记忆神经网络的大跨拱桥温度-位移相关模型建立方法[J]. *工程力学*, 2021, 38(4): 68–79.]
- [16] Deng Yang, Ju Hanwen, Zhai Wenqiang, et al. Correlation model of deflection, vehicle load, and temperature for in-service bridge using deep learning and structural health monitoring[J]. *Structural Control and Health Monitoring*, 2022, 29(12): e31113.
- [17] Wang Shuhong, Zhu Baoqiang. Time series prediction for ground settlement in portal section of mountain tunnels[J]. *Chinese Journal of Geotechnical Engineering*, 2021, 43(5): 813–821. [王述红, 朱宝强. 山岭隧道洞口段地表沉降时序预测研究[J]. *岩土工程学报*, 2021, 43(5): 813–821.]
- [18] Tadesse Z, Patel K A, Chaudhary S, et al. Neural networks for prediction of deflection in composite bridges[J]. *Journal of Constructional Steel Research*, 2012, 68(1): 138–149.
- [19] Faridmehr I, Shariq M, Plevris V, et al. Novel hybrid informational model for predicting the creep and shrinkage deflection of reinforced concrete beams containing GGBFS[J]. *Neural Computing and Applications*, 2022, 34(15): 13107–13123.
- [20] Xiao Xinhui, Wang Zepeng, Zhang Haiping, et al. A novel method of bridge deflection prediction using probabilistic deep learning and measured data[J]. *Sensors*, 2024, 24(21): 6863.
- [21] Qian Jianguo, Wu Anhai, Ji Jun, et al. Prediction for nonlinear time series of geotechnical engineering based on wavelet-optimized LSTM-ARMA model[J]. *Journal of Tongji University(Natural Science)*, 2021, 49(8): 1107–1115. [钱建固, 吴安海, 季军, 等. 基于小波优化 LSTM-ARMA 模型的岩土工程非线性时间序列预测[J]. *同济大学学报(自然科学版)*, 2021, 49(8): 1107–1115.]
- [22] Li Tao, Shu Jiajun, Wang Yanlong, et al. Horizontal deformation prediction of deep foundation pit support piles based on decomposition methods model[J]. *Rock and Soil Mechanics*, 2024, 45(Suppl): 496–506. [李涛, 舒佳军, 王彦龙, 等. 基于模态分解方法的深基坑支护桩水平变形预测[J]. *岩土力学*, 2024, 45(增刊): 496–506.]
- [23] Ju Hanwen, Deng Yang, Li Aiqun. Correlation model of deflection-temperature-vehicle load monitoring data for bridge structures[J]. *Journal of Vibration and Shock*, 2023, 42(6): 79–89. [鞠翰文, 邓扬, 李爱群. 桥梁结构挠度-温度-车辆荷载监测数据相关性模型[J]. *振动与冲击*, 2023, 42(6): 79–89.]
- [24] Lekomtsev A, Keykhosravi A, Moghaddam M B, et al. On the prediction of filtration volume of drilling fluids containing different types of nanoparticles by ELM and PSO-LSSVM based models[J]. *Petroleum*, 2022, 8(3): 424–435.
- [25] Wang Chunsheng, He Wenlong, Zhang Wenting, et al. Static system reliability analysis of cable-stayed bridge based on improved BP neural network[J]. *Journal of Traffic and Transportation Engineering*, 2024, 24(5): 86–100. [王春生, 何文龙, 张文婷, 等. 基于改进 BP 神经网络的斜拉桥静力体系可靠度分析[J]. *交通运输工程学报*, 2024, 24(5):

- 86–100.]
- [26] Tan Dongmei, Guo Tai, Gan Qinlin. Separation of temperature effect in monitored deflection of bridges based on VMD–SVD[J]. *Bridge Construction*, 2023, 53(3): 87–94. [谭冬梅, 郭泰, 甘沁霖. 基于 VMD–SVD 的桥梁挠度监测温度效应分离方法研究[J]. *桥梁建设*, 2023, 53(3): 87–94.]
- [27] Xiao Xinhui, Liu Xian, Zhang Haiping, et al. Research on deflection prediction and early warning method of suspension bridge girder based on CNN–LSTM–GD[J]. *Vibration and Impact*, 2025, 44(14): 84–94. [肖新辉, 刘贤, 张海萍, 等. 基于 CNN–LSTM–GD 的悬索桥主梁挠度预测与预警方法研究[J]. *振动与冲击*, 2025, 44(14): 84–94.]
- [28] Reshef D N, Reshef Y A, Finucane H K, et al. Detecting novel associations in large data sets[J]. *Science*, 2011, 334(6062): 1518–1524.
- [29] Mei Shengqi, Liu Xiaodong, Wang Xingju, et al. Prediction of high strength concrete creep based on parametric MIC analysis and machine learning algorithm[J]. *Journal of Jilin University(Engineering and Technology Edition)*, 2025, 55(5): 1595–1603. [梅生启, 刘晓东, 王兴举, 等. 基于参数相关性分析和机器学习算法的高强混凝土徐变预测[J]. *吉林大学学报(工学版)*, 2025, 55(5): 1595–1603.]
- [30] Tang Libin, Na S. Comparison of machine learning methods for ground settlement prediction with different tunneling datasets[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2021, 13(6): 1274–1289.

DWT–LSTM Separation Prediction Model for Bridge Deflection and Its Engineering Application

ZHENG Shuai¹, JIANG He¹, WANG Zhongchang¹, DING Jia², YANG Yi¹

(1. School of Transportation Engineering, Dalian Jiaotong University, Dalian 116028, China;

2. China Railway Construction Bridge Bureau Group 1st Engineering Co. Ltd., Dalian 116033, China)

Abstract:

Objective Accurate prediction of deflection variation holds significant importance for bridge operation and maintenance. The complex and non-linear dynamic characteristics of bridge deflection consistently challenge traditional prediction models, as hysteresis in the deflection response and interference from irregular waveforms in historical monitoring data reduce prediction accuracy. This study proposes a deflection separation-prediction model for bridges by integrating wavelet optimization and long short-term memory networks to capture multi-scale features of deflection signals and account for external influences.

Methods Firstly, an Internet of Things monitoring system was employed to investigate the deflection behavior of in-service bridges. Focusing on the Xiongshang High-speed Railway Bridge over the Daguang Expressway, sensors installed on the structure were utilized to record variations in deflection, dynamic load, and temperature. Secondly, given the decoupling of different deflection components across multiple time scales, a wavelet-based optimization approach was applied to decompose historical monitoring data into trend deflection generated by prestress loss and noise deflection induced by external influences such as temperature and dynamic loads. Thirdly, based on the decomposed deflection components and the associated external factors, two LSTM-based time series prediction models were developed, including a multi-factor model for noise deflection and a single-factor model for trend deflection. Vehicle load, temperature, and noise deflection served as the inputs for the noise model, while trend deflection was used as the sole input for the trend model. Separate predictions were conducted, and the final cumulative bridge deflection was obtained by summing both predicted components based on the principle of time series superposition. Traditional models were adopted for comparison across short-term, medium-term, and long-term periods to evaluate prediction accuracy. Prediction performance was assessed using three metrics: correlation coefficient (R), root mean square error (E_{RMS}), and mean absolute error (E_{MA}). Fourthly, a comparative analysis was performed between the proposed model and the single LSTM prediction model to demonstrate the necessity of the combined model for forecasting bridge deflection. Fifthly, in order to verify the necessity of incorporating external factors, the proposed model was compared to a time series model including a single external factor and another excluding external influences, emphasizing differences in prediction accuracy. Sixthly, the maximal information coefficient was introduced to identify the dominant factors affecting noise deflection by analyzing its correlation with temperature and dynamic load.

Results and Discussions 1) Comparison of the prediction results for short-term, medium-term, and long-term periods with the BP neural network and LSSVM models showed that the prediction accuracy for all three models remained similar in the short and medium periods. However, in the long-term deflection prediction, the DWT–LSTM-based bridge deflection separation model achieved the highest accuracy and demonstrated stronger generalization ability, with correlation coefficients of 0.86 and 0.77, E_{RMS} of 2.18 and 2.20 mm, and mean absolute errors (E_{MA}) of 2.05 and 1.91 mm. In contrast, the LSSVM model produced E_{RMS} values of 2.82 and 3.52 mm, with E_{MA} values of 2.45 and 3.13 mm. The BP neural network produced E_{RMS} values of 3.06 and 3.53 mm, with E_{MA} values of 2.89 and 3.24 mm. Compared to the LSSVM model, the DWT–LSTM deflection separation model reduced E_{RMS} by 22.70% and 37.50% and reduced E_{MA} by 39.26% and 38.98%. Compared to the BP neural network,

the DWT-LSTM deflection separation model reduced E_{RMS} by 28.76% and 37.68% and reduced E_{MA} by 29.07% and 41.05%. 2) Compared to the DWT-LSTM deflection separation model, the prediction accuracy decreased when the single LSTM model was used. The E_{RMS} reached 3.74 mm, and the E_{MA} reached 3.45 mm. These relatively large deviations indicated that this model had limited suitability for bridge deflection prediction. 3) Compared to the time series models that considered only temperature, only vehicle load, or excluded external factors, the model that excluded external factors exhibited the lowest prediction accuracy, with E_{RMS} of 3.91 mm and E_{MA} of 3.38 mm. Among the models that considered a single external factor, the time series model that considered load showed higher prediction accuracy, with E_{RMS} of 2.81 mm and E_{MA} of 2.65 mm, outperforming the temperature-only model, which had E_{RMS} of 2.97 mm and E_{MA} of 2.83 mm. In contrast, the DWT-LSTM deflection separation model achieved the highest accuracy, with E_{RMS} of only 2.18 mm and E_{MA} of only 2.05 mm. 4) Analysis of the dominant factors that influenced noise deflection using the Maximal Information Coefficient (MIC) showed correlation coefficients of 0.35 for temperature and 0.51 for load, indicating that vehicle load has a greater impact on noise deflection than temperature.

Conclusions This study presents a DWT-LSTM-based bridge deflection separation prediction model that is suitable for predicting long-term deflection variation patterns. Compared to traditional prediction models, the proposed model shows higher accuracy, reduced errors, and improved capability in addressing time-lag effects, providing a new approach and method for long-term bridge deflection prediction.

Key words: long short-term memory; wavelet optimization; bridge deflection; multi-factor prediction; vehicle impact parameters

(编辑 周 璇)

引用格式: Zheng Shuai, Jiang He, Wang Zhongchang, et al. Bridge deflection separation prediction model based on DWT-LSTM and its engineering application[J]. *Advanced Engineering Sciences*, 2026, 58(2): 35-45. [郑帅, 姜赫, 王忠昶, 等. 桥梁挠度的DWT-LSTM分离预测模型及工程应用[J]. *工程科学与技术*, 2026, 58(2): 35-45.]