

基于 LSTM-SSA-BDLM 的桥梁结构变形性能动态预测与预警

屈 广^{1,2}, 孙利民^{1,2}, 辛公锋³

(1. 同济大学 土木工程学院, 上海 200092; 2. 同济大学 土木工程防灾国家重点实验室, 上海 200092;

3. 山东省高速公路技术和安全评估重点实验室, 山东 济南 250098)

摘要: 掌握桥梁结构预期行为可以提早识别潜在的结构问题或失效模式。提出了一种新型的基于长短期记忆网络 (LSTM) 的桥梁结构性能动态预测框架。研究采用 Block Maxima (BM) 方法从每小时监测数据中提取挠度极值, 作为评估桥梁安全性能的关键指标。该方法通过对具有周期性的挠度极值序列进行滑动窗口 LSTM 预测, 结合奇异谱分析 (SSA) 和考虑误差更新的贝叶斯动态线性模型 (BDLM), 有效地提取了由环境因素引起的长期趋势和周期性挠度变化。这一过程有效降低了噪声的影响, 同时保留了车辆荷载效应的关键信息。在实际工程案例中的三组监测数据应用表明, 该方法在预测精度上相较于滑动窗口 LSTM 和 BDLM 方法有显著提升。此外, 还提出了一种基于极值理论的动态预警阈值设定方法, 有效避免了静态预警指标的局限性, 并利用预测结果的置信区间实现了提前预警。

关键词: 结构性能; 结构预期行为; 长短期记忆网络; 挠度; 预警

中图分类号: TU312

文献标志码: A

Dynamic Prediction and Early Warning of Bridge Structural Deformation Performance Based on LSTM-SSA-BDLM

QU Guang^{1,2}, SUN Limin^{1,2}, XIN Gongfeng³

(1. College of Civil Engineering, Tongji University, Shanghai 200092, China; 2. State Key Laboratory of Disaster Reduction in Civil Engineering, Tongji University, Shanghai 200092, China; 3. Shandong Key Laboratory of Highway Technology and Safety Assessment, Jinan 250098, China)

Abstract: Understanding the anticipated behavior of bridge structures is crucial for early identification of potential structural issues or failure modes. This paper

proposes a novel predictive framework for bridge structural performance based on Long Short-Term Memory Networks (LSTM). The block maxima (BM) method is employed to extract hourly deflection extremes from monitoring data, which serve as key indicators for assessing bridge safety. The method involves sliding window LSTM predictions for periodic deflection extreme sequences, integrating Singular Spectrum Analysis (SSA) and error-updating Bayesian Dynamic Linear Models (BDLM) to effectively extract long-term trends and cyclic deflection changes caused by environmental factors. This process effectively reduces the impact of noise while preserving the critical information of vehicle load effects. Applications in three real engineering cases demonstrate that proposed method significantly improves prediction accuracy compared to sliding window LSTM and BDLM approaches. Furthermore, the paper proposes a dynamic warning threshold setting method based on extreme value theory, which effectively avoids the limitations of static warning indicators and utilizes the confidence intervals of predictions for proactive warning.

Keywords: structural performance; structural anticipated behavior; long short-term memory; deflection; early warning

近年来, 面对现有桥梁结构逐渐老化、交通负载的不断增长以及自然灾害的频繁发生, 针对桥梁安全性能的评估需求已变得尤为迫切^[1-2]。估计桥梁结构预期行为可以提早识别潜在的结构问题或失效模式, 从而及时进行干预和维护, 防止进一步恶化甚至灾难性事故。因此, 通过结构健康监测 (SHM) 系统

收稿日期: 2023-04-06

基金项目: 国家自然科学基金面上项目 (52378187); 上海市科委期智研究院科技合作项目 (SQZ202310)

第一作者: 屈广, 博士生, 主要研究方向为桥梁健康监测。E-mail: 2011528@tongji.edu.cn

通信作者: 孙利民, 教授, 博士生导师, 工学博士, 主要研究方向为桥梁健康监测与振动控制。

E-mail: lmsun@tongji.edu.cn



论文
拓展
介绍

收集的数据对桥梁进行性能预测是特别关键的,尤其是在桥梁老化时^[3-4]。这些信息可以协助桥梁实时预警、维修保养,以及成本效益的优化干预策略^[5]。

挠度监测信息作为桥梁健康监测系统的关键性能指标,能够直接反映结构的刚度。目前,桥梁变形预测方法大致可分为两类:基于物理的方法和数据驱动的方法^[6]。基于物理的方法依赖于机械模型,这通常需要预先了解结构特性及外部载荷与结构变形之间的关系。例如,基于测量应力值更新有限元模型,实现桥梁的概率疲劳寿命预测^[7]。然而,由于真实桥梁变形的高度复杂机制,例如与本构理论、材料退化机制和不同桥梁结构类型(如梁桥、拱桥和斜拉桥)相关的不确定性,基于物理的方法在应用于其他桥梁时通常泛化性较低^[8]。

这些因素的复杂效应难以使用基于物理的方法进行建模,但可以通过数据驱动的方法学习^[9]。近年来,随着结构健康监测(SHM)技术的发展,数据驱动方法越来越受到关注。例如,一种基于自回归积分移动平均模型(ARIMA)的动态预测方法^[10],使用SHM数据有效检测港珠澳大桥沉管隧道的异常,并提高了SHM数据管理的效率。变异异质高斯过程方法被用于在台风事件期间预测应变并量化不确定性,为评估大型悬索桥的结构状况提供了宝贵的见解^[11]。通过使用SHM数据实施先进的数据驱动算法,例如深度神经网络和长短期记忆(LSTM),建立了有效的预警系统^[12]。此外,一些研究采用复杂的线性或非线性数据驱动算法,使用SHM数据预测桥梁变形^[13-15]。然而,目前的研究在非平稳数据,尤其是具有周期性趋势的数据方面研究有限。一些方法尝试将非平稳监测数据分解为不同的组成部分,然后采用单独的方法直接预测每个部分,最后进行汇总。例如,Li^[16]等人提出了一种综合预测模型,使用时间序列分解奇异谱分析将测量的接缝数据分解为非线性趋势和残差组成部分,从而利用支持向量回归预测沉管隧道的变形。Ge等人^[17]提出了一种预测桥梁耦合极端应力响应的方法,使用希尔伯特信号分解算法对测量的极端应力数据进行解耦,然后使用希尔伯特动态线性模型进行建模和预测。然而,受限于采用的方法限制,这些方法并不能学习到监测数据确定的周期模式^[18],反而因为只学习到部分线性和非线性趋势而易导致累积误差。尽管在变形预测中对上述方法进行了许多研究,但将其应用于周期性桥梁结构挠度变形预测仍存在以下问题:周期性变形监测数据具有复杂的非线性周期模式和

非光滑特征,如果直接预测,则可能导致大的预测偏差;尽管广泛使用的LSTM模型,能捕捉交通荷载(短期依赖)和温度荷载(长期依赖)等特征,从而提升预测准确性,但在处理噪声时容易出现过拟合;常用的预测方法大多仅能提供点估计,并不能提供具有参考价值的结构行为预期范围,且有些方法提供的预警范围由于过度依赖历史信息或不准确的分布类型而导致参考价值降低。

为了解决上述问题,本文提出了一种改进的LSTM预测模型,利用LSTM对周期性监测数据进行动态滑动窗口预测,并结合工程先验知识,将预测结果利用SSA方法分解为两部分并进行调整:受气候或环境因素影响的长期趋势与周期性趋势;LSTM的输出与前一项数据的残差,即可认为是车辆荷载效应与噪声等。之后利用考虑工程先验知识的贝叶斯动态线性模型(BDLM)对上面第二项数据进行动态修正以降低噪声和不确定性,提升LSTM的预测准确性。通过3个工程案例来对所提出的结合工程先验知识的预测模型进行了验证,并与其他方法进行对比说明。最后结合极值分布理论,提出了一种自适应更新的动态预警阈值指标。研究成果可以为在役桥梁结构的动态安全性能评估和预警提供依据和支持。

1 SSA-LSTM-BDLM 预测框架

桥梁所处力学环境复杂,监测数据不可避免地具有一定的噪声。LSTM在处理小样本或噪声数据时容易过拟合^[19]。因此结合了工程先验知识来对LSTM的预测结果动态调整,即通过SSA方法将LSTM的输出分为周期性趋势的温度荷载效应,以及残差数据作为车辆荷载效应与噪声,结合BDLM方法降低噪声并且利用工程先验信息对输出进行动态修正,以增加模型的准确性和稳定性,并能缓解过拟合的风险。

1.1 LSTM网络

LSTM(长短期记忆)是一种递归神经网络(RNN)类型,其结构包括三个门:输入门、遗忘门和输出门。输入门控制新信息进入记忆单元的流动,而遗忘门控制旧信息从记忆单元流出。输出门控制信息从记忆单元流向网络中的下一层。LSTM^[19]的方程式如下:

(1)遗忘门 f_t 决定了模型在当前时间步中应该保留多少以前的信息。

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

式中: $\sigma(\cdot)$ 表述 Sigmoid 函数; x_t 表示当前输入。 h_{t-1} 为隐藏状态, 使用权重 W_f 和偏置项 b_f 进行线性变换。

(2) 输入门 i_t 控制 LSTM 网络将多少新信息 $\tilde{c}_t$ 存储到当前细胞状态 c_t 中, 即

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

(3) 候选记忆 $\tilde{c}_t$ 通过应用双曲正切 (tanh) 激活函数来创建一个新的信息向量:

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

式(3)类似于遗忘门, 但权重和偏置项 (W_i 和 b_i) 不同, 下标 c 表示对应的细胞状态, 即 LSTM 网络中存储长期记忆的信息状态。

(4) 记忆单元:

$$c_t = f_i c_{t-1} + i_t \tilde{c}_t \quad (4)$$

(5) 输出门:

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

式中: W_o 和 b_o 分别为权重和偏置项。

(6) 隐藏状态 h_t 是 LSTM 的输出, 由细胞状态 c_t 和输出门 o_t 的加权积生成:

$$h_t = o_t \tanh(c_t) \quad (6)$$

本文的 LSTM 参数设置如下:

对 LSTM 的输入进行差分处理, 并堆叠了两个 LSTM 层, 这有可能捕捉到更复杂的时间依赖性。参数设置如下: 使用 Adam 优化器^[20], 训练集的最大训练轮数为 200, 每个小批量包含 10 个样本, 初始学习率为 0.005, 每 100 个迭代周期降低一次学习率, 学习率降低的比例设置为 0.1。本文所描述的神经网络由一个输入大小为 24 的序列输入层组成, 用来捕捉监测数据的周期性, 后跟两个具有 100 个隐藏单元的 LSTM 层。每个 LSTM 层后都添加一个丢弃比例为 10% 的丢弃层, 防止过拟合, 用于在训练过程中随机丢弃部分网络连接。此外, 模型包括一个全连接输出层。最佳模型的选择是基于验证集上的均方误差损失, 在训练期间使用了回归层来计算这一损失值。

1.2 奇异谱分析方法

奇异谱分析 (Singular Spectrum Analysis, SSA) 的目的是将原始序列分解为少量独立可解释分量的和^[21]。本文主要结合 SSA 方法提取出极值挠度序列中的长期趋势和周期项, 方法步骤如下^[21]:

(1) 选择合适的窗口长度 L 将原始序列 $\{x_1, x_2, \dots, x_n\}$ 进行滞后排列, 得到轨迹矩阵如下:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_{n-L+1} \\ x_2 & x_3 & \cdots & x_{n-L+2} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_n \end{bmatrix} \quad (7)$$

式中: n 为序列长度, L 取序列的周期长度。

(2) 对轨迹矩阵进行奇异值分解 (SVD)。SVD 会将轨迹矩阵分解为三个矩阵: 一个正交矩阵 U , 一个对角矩阵 S 和另一个正交矩阵 V :

$$X = USV^T \quad (8)$$

(3) 主成分分组: 通过将 U 、 S 和 V 中的对应列进行分组, 可以得到时间序列的主成分 (或称奇异模式)。这些主成分可以表示时间序列的不同特征, 例如趋势、周期性和噪声等, 对于第 i 个主成分, 有

$$T_i = s_i u_i v_i^T \quad (9)$$

式中: s_i 为对角矩阵 S 的对角线上的元素, 称为奇异值, 表示时间序列中各个成分的能量大小。 u_i 和 v_i 分别为 U 和 V 的列向量, 分别表示左奇异向量和右奇异向量。

(4) 序列重构: 将所选的主成分进行逆变换, 从而获得重构后的序列。对于本文中选定的主成分 (长期趋势与周期, 根据工程经验确定为前 2 阶) 重构序列如下:

$$X_2 = T_1 + T_2 \quad (10)$$

之后进行对角线平均以转换回原始序列格式。

1.3 考虑误差更新的 BDLM 方法

BDLM 是一种基于贝叶斯统计方法的动态线性模型。BDLM 模型中的动态部分由一个线性状态空间模型组成, 用于描述系统的状态随时间的变化^[14]。由于采用了 BDLM 来动态调整 LSTM 的预测, 因此 LSTM 的预测误差分布参数是需要用先验知识来估计并结合实测数据不断更新的, 误差参数更新的 BDLM 方法核心思想是利用 t 分布来近似总体误差分布^[22], 可定义如下:

监测方程:

$$y_t = \theta_t + v_t, v_t \sim N(0, V) \quad (11)$$

结合物理先验知识, 车辆荷载效应和噪声等在监测时间内呈线性趋势, 为了估计消除噪声后的真实状态信息, 状态方程可以写为

$$\theta_t = G_t \theta_{t-1} + w_t, w_t \sim N(0, W_t) \quad (12)$$

初始信息:

$$(\theta_0 | D_0, \varphi) \sim N(m_0, V_0 C_0) \quad (13)$$

$$(\varphi | D_0) \sim \Gamma[n_0/2, d_0/2] \quad (14)$$

式中: y_t 和 θ_t 分别为观测值和状态值; v_t 和 w_t 为独立

且相互独立的监测和状态误差; $G_t=1$ 为状态转移系数; V_t 为监测误差的未知方差, W_t 为状态误差方差; $N(\cdot)$ 为正态概率密度函数; $\Gamma(\cdot)$ 为卡方分布概率密度函数; $\varphi^{-1}=V_t^{-1}$ 。

其详细概率递推方法^[22-23]如下:

(1) $t-1$ 时刻的后验分布:

$$(\theta_{t-1}|D_{t-1}) \sim T(m_{t-1}, C_{t-1}) \quad (15)$$

$$(\phi_{t-1}|D_{t-1}) \sim \Gamma\left(\frac{n_{t-1}}{2}, \frac{d_{t-1}}{2}\right) \quad (16)$$

(2) t 时刻的先验分布:

$$(\theta_t|D_{t-1}) \sim T(m_t, C_t) \quad (17)$$

$$(y_t|D_{t-1}) \sim T_n(f_t, Q_t) \quad (18)$$

(3) t 时刻后验分布

$$(\theta_t|D_t) \sim T(m_t, C_t) \quad (19)$$

其递推关系: $m_t = G_t m_{t-1} + A_t e_t$, $C_t = (S_t/S_{t-1})[R_t - A_t A_t' Q_t]$, $n_t = n_{t-1} + 1$, $d_t = d_{t-1} + S_{t-1} e_t^2 / Q_t$, $S_t = d_t / n_t$, $e_t = y_t - f_t A_t = R_t / Q_t$ 。噪声分布参数 V_t 初始值由估计 S_{t-1} 代替。

1.4 LSTM-SSA-BDLM方法

本文建立的LSTM-SSA-BDLM状态空间方程如下:

$$\tilde{Z}_t = G(Z_{t-1}) = X_t + Y_t + v_t + u_t, \quad u_t, v_t \sim N(0, V), \quad u_t \sim N(0, U) \quad (20)$$

$$X_t = X_{t-1} + w_t, \quad w_t \sim N(0, W_t) \quad (21)$$

式中, $G(\cdot)$ 表示LSTM预测函数,输入 Z_{t-1} 是 $t-1$ 时刻传感器监测数据, $\tilde{Z}_t$ 是 t 时刻基于LSTM网络更新的预测值,由于存在预测误差,可以视为预测分布的期望。 X_t 表示车辆荷载效应, Y_t 为SSA分解得到的长期趋势和周期性趋势数据。 v_t 为车辆荷载噪声, u_t 为由SSA方法分解得到的长期趋势及周期性趋势的随机波动。其中 u_t 足够小,可以忽略不计。在预测框架中,通过SSA方法剔除了LSTM输出中温度引起的趋势项,并通过BDLM方法对残差部分(交通荷载效应和噪声)进行修正,以估计估计当前 t 时刻的状态值 X_t ,从而 $X_t + Y_t$ 作为 t 时刻的最终输出,即预测结果。这一过程有效降低了噪声的影响,同时保留了车辆荷载效应的关键信息。

模型的预测精度可用均方根误差(RMSE)衡量,它对一组测量值中特大或特小误差反映非常敏感,因此可以很好地反映预测的精度,计算如下:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{n}} \quad (22)$$

式中: y_i 和 $\tilde{y}_i$ 分别为监测值和预测值; n 为预测样本个数。

本文提出的SSA-LSTM-BDLM预测框架如图1所示:




图1 LSTM-SSA-BDLM框架

Fig. 1 The framework of LSTM-SSA-BDLM

2 超限阈值的动态修正

预警超限阈值设定为在监测指标达到特定水平时发出的警戒信号,旨在降低潜在风险或危害。这些阈值通常依据统计方法确定,以判断结构荷载效应是否超越历史监测周期内的正常变化范围。一般而言,阈值基于特定样本数量和置信水平的统计数据,如利用基于正态分布假设的拉依达准则(3 σ 准则)来预警桥梁支座性能^[24]。此准则假定99.73%的数据位于平均值3个标准差之内,超出这一范围则指示潜在问题的存在。然而,正态分布不适用于本文关注的极值挠度数据,且由于在役桥梁监测数据的趋势随环境变化(如温度、交通等)而变,基于历史数据设定的静态置信水平阈值可能导致误报。

动态预警阈值设置在工程实践中至关重要,因为它更准确地捕捉桥梁的实时状态,并提供实时预警信息,从而更有效地反映桥梁在不同工况和环境下的实际状况。这有助于及早发现潜在问题。本研究首先使用前文提出的方法基于实时监测信息来预测未来每小时的监测截面的极大挠度值,考虑到这些极值对结构的影响最为显著。随后,基于极值分布理论,结合实时预测极值数据和历史监测信息来设定和更新动态阈值,从而更全面地评估桥梁在极端事件下的风险。这种方法考虑了概率分布的尾部特性,为阈值设定提供全面的风险信息。本文的监测数据采用Block Maxima(BM)方法^[25]将原始数据分为长度相同的若干组(本文中长度设置为1h),然后在每组中选取最大值构成极值数据序列。

理论上可证明在一定条件下,由此构造出的极值数
据序列近似服从广义极值分布^[25]。广义极值分布的
累积分布函数如下:

$$F(x; \mu, \sigma, \xi) = \exp \left\{ - \left[1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi}} \right\} \quad (23)$$

式中: μ 是位置参数; σ 是尺度参数 ($\sigma > 0$); ξ 是形状参
数。在 $\xi < 0$ 的情况下,该分布就是 Weibull 分布的广
义极值形式。事实上,经 Kolmogorov - Smirnov 检验^[26],
本文采用的研究数据符合 Weibull 分布。在确定预警
阈值时,本文首先设定了一个显著性水平,仿照正态分
布的做法,采用 99.73% 的置信水平。进而,考虑到极
值分布的尾部特征,对应于 $p = 99.73\%$ 置信水平的预
警阈值表达式为

$$s_t = \mu + \frac{\sigma}{\xi} \left(\left(-\ln(p) \right)^{-\xi} - 1 \right) \quad (24)$$

为了动态更新这一阈值,在新观测值到来时使用
上述极值理论和极大似然估计方法^[27]来更新式
(23) 中参数,并据式 (24) 更新分位数 s_t , 以便能够更
准确地提供预警信息。

3 工程实例

外滩大桥位于宁波市甬江桥下游,江北区与江
东区交界处,连接西岸的宁波港客运码头和东岸的
江东区渔轮厂,是地处市中心的一座景观桥梁,桥长
为 1 039.90m,其中主桥长 337.00m,主要由钢箱梁
组成。主梁跨中挠度可以很直观有效地反应主梁的
安全状态,对于确保结构安全至关重要,因此配以传
感器监测主梁的变形。图 2 展示了变形测点的布
局,用 PT1-20 表示。




图 2 主梁变形监测点

Fig. 2 Main girder deformation monitoring points

外滩大桥采用的应变传感器采样频率为 1Hz,
其监测值为相对值。2019 年 5 月至 6 月期间,收集到
了 1 000h 的监测信息,并通过 BM 方法^[25]转换为挠
度极值序列。由于监测到的极值对结构影响最为显
著,本文选择了小时极值挠度(即每小时中的极大
值)为研究对象。在实时监测桥梁的极端挠度时,所
获得的数据综合反映了结构在温度、交通负荷以及
其他外力作用下的响应,这些信息对于全面评估桥
梁的运营状态至关重要。因此,在本研究的分析过
程中,没有排除由温度变化引起的影响,而是将其视
为一个重要的评价指标。在预测框架中,采用 SSA
方法分离出温度变化引起的趋势项。随后,利用贝

叶斯动态线性模型(BDLM)对剩余部分进行修正,
这一部分包括交通荷载效应和随机噪声,从而得到
一个准确反映桥梁预期状态的理想输出。以这段时
间中监测极值最大的 PT20 截面为例,其前 760h 的
监测数据如图 3 所示。

首先利用传感器收集到的小时极值挠度数据建立
了预测模型,之后利用滑动窗口 LSTM 方法对该组传
感器监测数据进行动态预测,由于监测信息中包含温
度荷载效应引起的周期趋势,而本文分析对象为每小
时的挠度极大值,不需要考虑长期的周期例如季节变
化,因此将 LSTM 窗口长度和 SSA 参数设置为 $L=24$
对应每天 24h 的周期,并且为了捕捉环境的变化,对 SSA




图3 主梁PT20处变形监测数据

Fig. 3 Deformation monitoring data at main girder PT20

方法增加了一个窗口长度,即将分解的序列长度设置为360。这一窗口长度是为了捕捉桥梁结构在15d周期内的挠度变化特性。这个周期长度是基于对过往监测数据的时间序列分析得出的,发现15d内的数据能够较好地反映结构的周期性变化和长期趋势。该周期的选择既能保证数据窗口具有足够的数据点来精确捕捉这些结构行为特征,又能避免因窗口过大而可能引入的数据冗余。预测过程中,对当前 t 时刻的已知历史数据与最新预测数据 $\tilde{Z}_t$ 进行SSA分解,残差由LSTM的最新预测减去分解结果得到。以时刻1000h处为例,基于已知的监测结果与此时的LSTM预测结果,数据可以分解为图4的形式。利用BDLM对残差数据进行修正后,得到输出结果(图5)。从图5可以看出,预测结果与实测数据基本保持一致。

为了进一步说明LSTM-SSA-BDLM的预测性能,基于PT20,PT19和PT1三处的挠度监测数据,将提出方法与滑动窗口LSTM及BDLM的预测结果进行对比分析,结果如图6~图8所示。

以预测均方根误差RMSE为预测精度指标,计算




图4 1000h时刻预测过程的SSA分解结果

Fig. 4 SSA decomposition results at 1000h






图5 PT20处LSTM-SSA-BDLM的预测结果

Fig. 5 The prediction result of LSTM-SSA-BDLM at PT20

结果如表1所示。其中RMSE越小,给出的预测精确越高。从PT20,PT19和PT1监测点处的挠度数据预测结果来看,与滑动窗口LSTM和BDLM相比,提出的LSTM-SSA-BDLM方法展现出了明显的预测精度提升。RMSE的计算结果显示,提出的方法在PT20、PT19和PT1监测点处的挠度数据预测平均精度提升了约15%,而与BDLM相比,平均精度提升了约23%。



a 提出方法与LSTM



b 提出方法与BDLM

图6 PT20处挠度预测结果对比

Fig. 6 Comparison of deflection predictions at PT20




图 7 PT19处挠度预测结果对比

Fig. 7 Comparison of deflection predictions at PT19




图 8 PT1处挠度预测结果对比

Fig. 8 Comparison of deflection predictions at PT1

表 1 预测结果 RMSE 对比

Tab.1 Comparison of RMSE in prediction results

方法	PT20	PT19	PT1
LSTM-SSA-BDLM	0.110 9	0.119 7	0.179 0
LSTM	0.143 2	0.140 9	0.193 5
BDLM	0.215 7	0.133 2	0.201 2

之后,为了提供更多的性能评估参考,根据第二节中的阈值设置方法,结合预测挠度数据对结构的黄色预警阈值实时更新。对PT1处的监测数据进行Weibull分布拟合,并将前800h数据的经验分布与Weibull分布拟合结果进行比较,如图9所示,能够清晰地看出实际监测数据的经验分布与Weibull分布的累积分布曲线较为吻合,因此将监测数据的分布视为Weibull分布是合理的。并且这一假定也通过了KS检验。

将预测结果结合Weibull分布来设定动态阈值,结果如图10所示。并且利用前800h的历史极值数据计算基于正态分布假设的静态预警指标,将结果也会绘制在图中。




图 9 主梁PT20处挠度累积分布图

Fig. 9 Cumulative distribution of deflection at main girder PT20




图10 主梁PT20处挠度实测、预测及两种预警指标

Fig. 10 Measurement, prediction, and two types of warning indicators of midspan deflection at PT20 of the main girder

可以看出常用的正态分布假设的静态预警指标由于不能反应实际监测极值数据的分布,并且受到历史样本的限制,因此随着环境变化容易出现误报。而考虑极值分布的动态预警指标一方面充分考虑到了监测极值信息的分布特征,一方面也会随着时间不断更新,这样更能很大程度降低预警误报,并且能更准确的反应在役桥梁结构的安全状态,符合实际工程需求。预测与监测值均落在动态预警指标以下,可以看出PT20处主梁断面在这段时间的运营安全状态良好。并且可以利用预测区间的上限来提前估计超过阈值的可能,从而实现结构的提前预警。

4 结论

本文提出了一种新的基于在役桥梁变形监测数据的结构性能预测方法。本研究采用Block Maxima (BM)方法选取的每小时挠度极值数据,作为评估桥梁安全性能的关键指标。研究中建立的LSTM-SSA-BDLM预测框架旨在精准估计桥梁结构的预期行为。通过SSA方法从滑动窗口LSTM输出中提取长期趋势与周期项,可以有效识别温度引起的挠度变化,同时使用BDLM方法动态修正分解后的车辆荷载效应与噪声。该方法不仅保留了车辆荷载效应的关键信息,同时降低了噪声的影响。应用本文提出的方法于实际工程的一座在役斜拉桥的主梁监测断面,对三处测点的小时挠度极值数据能进行了预测,预测结果与实测结果吻合良好。对比分析表明,与滑动窗口LSTM和BDLM方法相比,LSTM-SSA-BDLM方法在预测精度上有较大提升。以均方根误差(RMSE)为评价标准,三个测点处的

结果表明,与滑动窗口LSTM相比,平均精度提升约15%,而与BDLM相比,则提升约23%。

最终,结合实时预测数据,并考虑到极值序列的分布特征,本文提出了一种结合极值理论的在线更新超限阈值设定方法。这种方法有效克服了静态预警指标的局限性,并利用预测结果的置信区间实现提前预警,从而为在役桥梁的运营维护和决策提供了科学依据。

作者贡献声明:

屈广:负责数据整理与管理、实验数据的分析、论文初稿的撰写以及实验结果的可视化并负责论文审阅与修订;

孙利民:负责研究资金的获取,对研究课题进行监管与指导,并参与论文审阅与修订;

辛公锋:参与论文审阅与修订。

参考文献:

- [1] DEVENDIRAN D K, BANERJEE S. Influence of combined corrosion-fatigue deterioration on life-cycle resilience of RC bridges [J]. *Journal of Bridge Engineering*, 2023, 28 (5) : 04023014.
- [2] SUN L, SHANG Z, XIA Y, *et al.* Review of bridge structural health monitoring aided by big data and artificial intelligence: from condition assessment to damage detection [J]. *Journal of Structural Engineering*, 2020, 146(5): 04020073.
- [3] QU G, XIA Y, SUN L, *et al.* Behavior expectation-based anomaly detection in bridge deflection using AOA-BILSTM-TPA: considering temperature and traffic-induced temporal patterns [J]. *Structural Control and Health Monitoring*, 2024 (1):2337057.
- [4] ALAMPALLI S, FRANGOPOL D M, GRIMSON J, *et al.* Bridge load testing: state-of-the-practice [J]. *Journal of Bridge Engineering*, 2021, 26(3):03120002.
- [5] GONG C, DAN M F. Reliability of steel girder bridges with dependent corrosion growth [J]. *Engineering Structures*, 2020, 224:1.
- [6] 张翼飞, 刘洪涛, 王佳瑀, 等. 基于极大似然异方差高斯过程的桥梁纵向变形数据回归与预测分析 [J]. *土木工程与管理学报*, 2023, 40(3):57.
ZHANG Y, LIU H, WANG J, *et al.* Regression and forecasting analysis of bridge longitudinal deformation data based on most likely heteroscedastic gaussian process. [J]. *Journal of Civil Engineering and Management*, 2023, 40(3):57.
- [7] LI Y, ASTROZA R, CONTE J P, *et al.* Nonlinear FE model updating and reconstruction of the response of an instrumented seismic isolated bridge to the 2010 Maule Chile Earthquake [J]. *Earthquake Engineering & Structural Dynamics*, 2017, 46 (15):2699.

- [8] QU G, SONG M, XIN G, *et al.* Time-convolutional network with joint time-frequency domain loss based on arithmetic optimization algorithm for dynamic response reconstruction[J]. *Engineering Structures*, 2024, 321:119001.
- [9] ZHAO H, TAN C, OBRIEN E J, *et al.* Developing digital twins to characterize bridge behavior using measurements taken under random traffic[J]. *Journal of Bridge Engineering*, 2022, 27(1):04021101.
- [10] CHEN J, JIANG X, YAN Y, *et al.* Dynamic warning method for structural health monitoring data based on ARIMA: case study of Hong Kong – Zhuhai – Macao Bridge immersed tunnel [J]. *Sensors*, 2022, 22(16): 6185.
- [11] WANG Q A, ZHANG C, MA Z G, *et al.* Modelling and forecasting of SHM strain measurement for a large-scale suspension bridge during typhoon events using variational heteroscedastic Gaussian process [J]. *Engineering Structures*, 2022, 251: 113554.
- [12] LI S, WANG W, LU B, *et al.* Long-term structural health monitoring for bridge based on back propagation neural network and long and short-term memory [J]. *Structural Health Monitoring*, 2023, 22(4): 2325.
- [13] HACKETT BL, SUDHARSHAN PHANI P, WALKER CC, *et al.* Advances in the measurement of hardness at high strain rates by nanoindentation [J]. *Journal of Materials Research*, 2023, 38(5):1163.
- [14] QU G, SUN L, HUANG H. Bridge performance prediction based on a novel SHM-data assimilation approach considering cyclicity[J]. *Structural Control and Health Monitoring*, 2023, 2023(1):2259575.
- [15] CAKMAK F, MENKULASI F, EAMON C. Time-dependent flexural deformations in composite prestressed concrete and steel bridge beams. I: prediction methodology[J]. *Journal of Bridge Engineering*, 2022, 27(5): 04022016.
- [16] LI K, ZHANG Z, GUO H, *et al.* Prediction method of pipe joint opening-closing deformation of immersed tunnel based on singular spectrum analysis and SSA-SVR [J]. *Applied Ocean Research*, 2023, 135: 103526.
- [17] GE B, WANG Z C, XIN Y, *et al.* Dynamic real-time reliability prediction of bridge structures based on Copula – BHDLM and measured stress data [J]. *Measurement*, 2022, 203: 112006.
- [18] HUANG Z, LI T, HUANG K, *et al.* Predictions of flow and temperature fields in a T-junction based on dynamic mode decomposition and deep learning [J]. *Energy*, 2022, 261: 125228.
- [19] STAUEMEYER R C, MORRIS E R. Understanding LSTM--a tutorial into long short-term memory recurrent neural networks [DB/OL]. (2019-9-12) [2024-11-11]. <https://arxiv.org/abs/1909.09586>.
- [20] REYAD M, SARHAN AM, ARAFA M. A modified Adam algorithm for deep neural network optimization [J]. *Neural Computing and Applications*. 2023, 35(23):17095.
- [21] HASSANI H. Singular spectrum analysis: methodology and comparison[J]. *Journal of Data Science*, 2007, 5(2):239.
- [22] QU G, SONG M, SUN L. Bayesian dynamic noise model for online bridge deflection prediction considering stochastic modeling error [J]. *Journal of Civil Structural Health Monitoring*, 2024, 18:1.
- [23] 屈广. 基于监测数据同化的桥梁极值应力动态预测方法研究 [D]. 兰州: 兰州大学, 2019.
QU G. Research on dynamic prediction methods of bridge extreme stresses based on monitoring data assimilation [D]. Lanzhou: Lanzhou University, 2019.
- [24] LI Y, PENG K, HE J, *et al.* Maintenance management research of a large-span continuous rigid frame bridge based on reliability assessment by using strain monitored data[J]. *Journal of Architectural Environment & Structural Engineering Research*, 2021, 4(2): 20.
- [25] HUSSAIN F, ALI Y, LI Y, *et al.* Revisiting the hybrid approach of anomaly detection and extreme value theory for estimating pedestrian crashes using traffic conflicts obtained from artificial intelligence-based video analytics [J]. *Accident Analysis & Prevention*, 2024, 199:107517.
- [26] FASANO G, FRANCESCHINI A. A multidimensional version of the Kolmogorov – Smirnov test[J]. *Monthly Notices of the Royal Astronomical Society*, 1987, 225(1):155.
- [27] PHOOPHIWFA T, LAOSUWAN T, VOLODIN A, *et al.* Adaptive parameter estimation of the generalized extreme value distribution using artificial neural network approach [J]. *Atmosphere*, 2023, 14(8):1197.