

小波分解和 BDLTM-GRU 混合模型相融合的 桥梁耦合极值应力高精度预测

杨 渡¹, 樊学平^{1,2}, 刘月飞^{1,2}

(1. 兰州大学土木工程与力学学院, 甘肃 兰州 730000; 2. 兰州大学西部灾害与环境力学教育部重点实验室, 甘肃 兰州 730000)

摘要: 为实现桥梁耦合极值应力的高精度预测, 采用小波多分辨率分析法对监测极值应力进行分解, 取分解后的低频数据为趋势项信息, 高频数据为车辆荷载效应信息, 趋势项减去其均值为温度荷载效应信息, 通过以上步骤实现桥梁极值应力的解耦。建立双变量(引入随时间变化的趋势项)贝叶斯动态线性趋势性模型(BDLTM)对低频极值应力进行预测分析; 采用 GRU 神经网络模型对高频极值应力进行预测分析; 实现耦合极值应力的叠加预测。利用天津富民桥的监测耦合数据验证 BDLTM-GRU 模型的可行性, 同时与耦合极值应力的单 BDLTM 和单 GRU 模型进行精度比较, 验证 BDLTM-GRU 模型预测的高精度。

关键词: 耦合极值应力; 小波多分辨率分析法; BDLTM-GRU 模型; BDLTM; GRU 神经网络

中图分类号: U441⁺.2; TU392.5 **文献标志码:** A **文章编号:** 1004-4523(2025)05-1026-10

DOI: 10.16385/j.cnki.issn.1004-4523.2025.05.014

High precision prediction of bridge coupled extreme stresses with the fusion of wavelet decomposition and BDLTM-GRU mixture model

YANG Du¹, FAN Xueping^{1,2}, LIU Yuefei^{1,2}

(1. School of Civil Engineering and Mechanics, Lanzhou University, Lanzhou 730000, China; 2. Key Laboratory of Mechanics on Disaster and Environment in Western China of the Ministry of Education, Lanzhou University, Lanzhou 730000, China)

Abstract: To achieve high-precision prediction of bridge-coupled extreme stresses, the wavelet multi-resolution analysis method is adopted to decouple the coupled extreme stresses. The decoupled low-frequency data is taken as the trend item information, where the high-frequency data is considered as the vehicle load effect information. The trend item, after subtracting its mean, is the temperature load effect information. A bivariate Bayesian dynamic linear trend model (BDLTM), which introduces a time-varying trend term, is built to predict and analyze low-frequency extreme stress. GRU neural network model is provided to predict and analyze high-frequency extreme stresses. The dynamic coupled extreme stresses are predicted. The monitoring coupled data from Tianjin Fumin Bridge is provided to illustrate the feasibility and application of the proposed BDLTM-GRU model, the accuracy of which is compared with the single BDLTM model and single GRU model for verifying the high precision of the BDLTM-GRU model.

Keywords: coupled extreme stresses; wavelet multi-resolution analysis method; BDLTM-GRU model; BDLTM; GRU neural network

桥梁健康监测的研究可大致分为两个阶段^[1]。目前, 第一阶段关于桥梁结构健康监测(SHM)系统的研究已相当成熟, 而第二阶段对于健康监测数据的处理逐渐成为了当前的研究热点。桥梁监测系统在运行阶段会记录数量极多的随时间变化的监测数据, 现在对于监测数据的处理研究主要在结构的模态参数识别^[2]、桥梁结构损伤识别^[3]以及桥梁模型修正^[4]等领域, 而基于无有限元模型的动态预测和可靠性评估^[5]方面的研究则相对较少。由于桥梁结

构的监测数据具有随机性和趋势性等, 导致高精度预测桥梁的极值应力比较困难, 因此研究荷载效应极值的高精度动态预测方法也是桥梁结构健康监测研究的关键问题。

小波多分辨率分析^[6]能够有效地提取信号中的低频信息, 对多种作用耦合情况下的监测数据进行分解。在进行服役桥梁状态评估时, 就成功使用小波多分辨率分析法从长期应变响应数据中提取趋势项信息, 得到温度效应信息, 并基于此进行桥梁可靠

收稿日期: 2023-07-14; 修订日期: 2023-08-22

基金项目: 国家自然科学基金资助项目(51608243); 中央高校基金面上项目(lzujbky-2022-43)

性分析^[7]。

目前在役桥梁结构的可靠性研究大多基于无有限元模型,通过建立数学模型,构建监测数据与模型参数之间的动态关系,最终实现桥梁结构可靠性的动态预测^[8-10]。至今已发展出了一些基于无有限元模型的桥梁动力响应的预测方法,比如通过引入以状态变化趋势为变量的双变量贝叶斯动态模型来对监测数据进行高精度预测^[11],在分析过程中对解耦后的极值数据进行预测,对于高频极值数据的非线性性和波动性未加考虑。

鉴于桥梁监测数据的随机性、动态性、耦合性等特性,采用小波多分辨率分析法对桥梁监测数据进行解耦,引入随时间变化的趋势项 β_{t-1} 的贝叶斯动态线性趋势性模型(BDLTM)对低频极值数据进行预测分析。由于高频极值数据的非线性和波动性,BDLTM可能不是最优模型,所以采用GRU模型对高频极值数据进行预测分析,将高频极值应力预测值和低频极值应力预测值进行叠加得到桥梁耦合极值应力的预测值,并与单一BDLTM和单一GRU神经网络模型的耦合极值应力预测值进行比较,通过天津富民桥的实时监测数据,对本文所建立的模型进行验证。

1 桥梁监测数据的解耦处理

桥梁所受到的应力是由桥梁在工作期间桥面上的车辆流动、温度的变化、风的作用以及桥梁自重等引起的,由于风荷载作用与其他三种作用相对桥梁的影响很小,可忽略不计,所以本文认为监测应力是车辆、温度、桥梁自重耦合产生的结果。经过前期验证,用小波多分辨率分析法和一次移动平均法^[12-13]对桥梁极值应力进行分解的结果非常相近,但是小波多分辨率法具有比移动平均法更优秀的频率和时间分析能力,能够自适应地选择不同尺度进行分析,而移动平均法只能人为选择窗口长度;对于序列数据中的一些局部特征(如尖峰等),移动平均法可能会将其平滑掉。所以本文采用小波多分辨率分析法对极值应力数据进行分解处理。为了确定所需的小波函数和分解层数,将小波多分辨率法的分解结果和移动平均法的分解结果进行一一比对,按相对误差选出最优的小波函数和分解层数,Symlet小波函数在第二次分解时的效果最好。将小波多分辨率分解后的近似部分(低频极值应力)的均值作为桥梁自身引起的应力,细节部分(高频极值应力)作为车辆荷载引起的应力,然后将近似部分与其均值的差作为温度荷载引起的应力,通过以上步骤实现对桥梁极值应力的解耦操作。

1.1 小波多分辨率分析法

小波变换通常选择一个函数作为母函数,然后通过对母函数伸缩和平移变换来定义一组子小波函数,这些子小波构成一个完整的基函数,小波变换则是利用这组基函数将信号分解成不同尺度和频域的成分,从而对信号实现在时间和频率域上的特征分析;使用多分辨率分析方法,可以在不同时间尺度上观察和分析信号,以获取信号在不同尺度下的变化趋势和特征。在基于小波的多分辨率分析中,可以通过使用同一函数并调整尺度和位移参数对信号进行重复分解。

小波变换可用于对非平稳信号进行分解,并提取局部特征信息,在时域和频域上都能较好地表征信号的特征信息,具有多分辨率的特点。实现小波变换的过程是通过多次尺度和位移变换,将原始信号进行细分,并使用选定的小波基函数,得到一组不同的信号。通过选择性地叠加这些信号,可以逼近原始信号。在重构效果方面,小波变换比傅里叶变换更具优势。小波多分辨率分析实际上是将信号分解成不同的分辨率尺度:粗分辨率(近似)的数据包含低频分量的信息,而精细分辨率(细节)的数据包含高频分量的信息。

选定一个母小波函数 $\Psi(t)$,连续信号的小波变换就可以被定义为:

$$W_{\Psi}f(a,b) = \frac{1}{|a|^{\frac{1}{2}}} \int_{-\infty}^{+\infty} f(t) \overline{\Psi}\left(\frac{t-b}{a}\right) dt, a > 0 \quad (1)$$

式中, $W_{\Psi}f(a,b)$ 为小波变换后的结果, a 为尺度参数, b 为时间参数; t 为自变量; $\Psi(t)$ 被称为母小波; $\overline{\Psi}$ 表示复共轭。

已知函数 $f(t)$ 可以由 $W_{\Psi}f(a,b)$ 用二重积分表示重构,定义为:

$$f(t) = \frac{1}{C_{\Psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_{\Psi}f(a,b) \Psi\left(\frac{t-b}{a}\right) \frac{1}{a^2} da db \quad (2)$$

式中, C_{Ψ} 代表归一化常数。在实际情况中,小波变换通常使用的是离散形式,是通过将尺度参数 a 和时间参数 b 离散化来实现的,即

$$a = 2^j, b = 2^j k; j, k \in \mathbf{Z} \quad (3)$$

式中, \mathbf{Z} 代表正整数的集合。离散小波函数 Ψ_{jk} 可表示为:

$$\Psi_{jk}(t) = 2^{\frac{j}{2}} \Psi(2^j t - k) \quad (4)$$

上式构成平方可积函数空间 $L^2(\mathbf{R})$ 的一个标准正交基,利用这个标准正交基, $f(t)$ 可表示为:

$$f(t) = \sum_j \sum_k \alpha_{jk} \Psi_{jk}(t) \quad (5)$$

其中:

$$\alpha_{jk} = \int_{-\infty}^{\infty} f(t) \Psi_{jk}(t) dt \quad (6)$$

分解到 J 级的细节信号:

$$D_J = \sum_{k \in \mathbf{Z}} \alpha_{j,k} \Psi_{j,k}(t) \quad (7)$$

分解到 J 级的近似信号:

$$A_J = \sum_{j>J} D_j \quad (8)$$

$$f(t) = A_J + \sum_{j \leq J} D_j \quad (9)$$

式(1)~(9)展现了对信号进行分解和重建的过程,在选定层数的情况下,信号被分解为低频(近似)和低频(细节)。

1.2 低频极值应力的贝叶斯线性动态模型

贝叶斯动态线性模型(BDLM)可以用于时间序列数据的建模和预测。BDLM将动态线性模型中的参数估计问题转化为贝叶斯推断问题,是一种利用贝叶斯方法来估计模型参数和状态变量的技术,同时也能通过贝叶斯模型对未来观测数据进行预测。这种方法将已知监测信息和掌握的先验信息相结合,建立动态线性模型并持续修正相关参数,以达到更精确的预测效果。

由于解耦后的低频极值应力是一个时间序列,并且桥梁在监测期间存在许多不可观测的误差,导致低频极值应力状态的值也是不可观测的。因此,采用动态线性模型来描述极值应力的状态变化是合适的。动态线性模型通常基于以下三个假设:

(1) 状态变量 $(\theta_t, \beta_t, t = 1, 2, 3, \dots, T)$: 呈现马尔科夫链^[12-13]的变化; θ_t 和 θ_{t-1} 呈线性变化; T 为监测总时间;

(2) 监测变量 y_t 之间相互独立,且只与 θ_t 有关, y_t 与 θ_t 存在线性关系;

(3) 状态变量和它的误差服从正态分布,监测变量和它的相关误差也服从正态分布。

为了更好地描述极值应力状态变量的变化过程,考虑其具有随机性,因此引入了随时间变化的状态变量趋势项 β_{t-1} 。使用双状态变量来建立状态方程,所建立的动态线性模型(DLTM)可以表示为:

(1) 监测方程:

$$y_t = \theta_t + v_t; \quad v_t \sim N(0, V_t) \quad (10)$$

(2) 状态方程:

$$\begin{cases} \theta_t = \theta_{t-1} + \beta_{t-1} + \omega_t; & \omega_t \sim N(0, W_t) \\ \beta_{t-1} = \theta_{t-1} - \theta_{t-2} \end{cases} \quad (11)$$

(3) 初始信息:

$$\theta_{t-1} | D_{t-1} \sim N(m_{t-1}, C_{t-1}) \quad (12)$$

式中, y_t 为在 t 时刻的桥梁监测值; θ_t 为由前一刻的状态变量和它的相对误差还有变化趋势组成的状态值; v_t 为 y_t 所对应的监测误差; $N(\cdot)$ 为高斯分布的概

率密度函数; β_{t-1} 为状态变量在 $t-1$ 时刻的变化趋势,由此时刻和前一时刻的状态变量确定; ω_t 为 t 时刻 θ_t 对应的误差; V_t 为 v_t 的方差; W_t 为 ω_t 的方差; D_{t-1} 为 $t-1$ 时刻及之前所有有效信息的集合; m_{t-1} 为 θ_{t-1} 的点估计; C_{t-1} 为 $t-1$ 时刻 θ_{t-1} 的方差。

动态线性模型中的关键参数有 V_t 、 W_t 、 β_{t-1} 、 m_{t-1} 、 C_{t-1} 。 V_t 可以通过使用原始监测数据进行方差估计; W_t 通过引入折扣因子结合初始状态信息近似确定:

$$W_t = C_{t-1} + \frac{C_{t-1}}{\delta} \quad (13)$$

式中, δ 为折扣因子,在本文中取为 0.98。

1.3 高频极值应力的 GRU 模型

高频极值应力相比较于低频极值应力有较强的非线性和波动性,因此采用 GRU(gated recurrent unit)神经网络模型来对其进行预测分析。GRU^[14]也被称为门控单元循环结构,属于深度神经网络的一种,是长短期记忆(LSTM)神经网络的一种变体。图1即为 GRU 模型单元结构示意图,在一个完整的 GRU 模型中,通常由数个这种单元结构层组成。GRU 模型在一定程度上解决了 LSTM 神经网络梯度爆炸的情况。目前广泛应用于时间序列数据的预测和修复^[15]。相比于其他的神经网络模型,GRU 模型的优势在于输入的参数较少,拥有较快的训练速度,而且还能降低数据过拟合的风险。




图 1 GRU 模型单元结构示意图

Fig. 1 GRU model unit structure diagram

图1中, z_t 代表更新门,该门主要决定当前需要传递多少信息到未来,更新门的计算公式如下:

$$z_t = \sigma(W_z * x_t + U_z * h_{t-1}) \quad (14)$$

式中, x_t 表示时间步 t 的输入向量,代表时间序列 x 的第 t 个分量; h_{t-1} 表示前一个时间步的输出信息; “*”代表两矩阵相乘,即通过使用权重矩阵 W_z 和 U_z 对 h_{t-1} 和 x_t 进行线性变换,然后将这两个信息相加。更新门 z_t 通过一个激活函数 σ (Sigmoid) 将结果限制在 0~1 之间。

r_t 代表重置门,主要决定有多少来自过去的消息

需要遗忘,其计算公式如下:

$$r_t = \sigma(\mathbf{W}_r * \mathbf{x}_t + \mathbf{U}_r * \mathbf{h}_{t-1}) \quad (15)$$

式(15)中的主要参数介绍见更新门,需要注意的是线性变换的参数变了(权重矩阵)。重置门与更新门的计算结果一样会被压缩到0~1之间;重置门可以衡量门控开启的大小,如果值为0,则代表该信息被完全遗忘。

$\tilde{\mathbf{h}}_t$ 代表的是当前的记忆内容,将用到上一步提出的重置门,在进行计算后使用双曲正切函数(tanh)作为激活函数,将值限制到-1~1之间。计算公式如下:

$$\tilde{\mathbf{h}}_t = \tanh[\mathbf{W}_h * \mathbf{x}_t + \mathbf{U}_h * (r_t * \mathbf{h}_{t-1})] \quad (16)$$

式中, \mathbf{h}_t 表示当前门的最终输出结果,它保存了当前单元的信息,并将其输入到下一个单元中; \mathbf{W}_h 和 \mathbf{U}_h 为权重矩阵。此计算中还使用了更新门的输出结果,计算公式如下:

$$\mathbf{h}_t = (1 - z_t) * \mathbf{h}_{t-1} + z_t * \tilde{\mathbf{h}}_t \quad (17)$$

在式(15)~(17)中, \mathbf{W}_z 、 \mathbf{U}_z 、 \mathbf{W}_r 、 \mathbf{U}_r 、 \mathbf{W}_h 、 \mathbf{U}_h 都是GRU神经网络的参数,是在训练的过程中学习得出的。

2 解耦极值应力与耦合极值应力的预测

2.1 低频极值应力的BDLTM预测

基于DLTM模型,结合解耦后的动态监测数据,可以利用贝叶斯方法对其进行概率递推得到BDLTM。

(1) $t-1$ 时刻的状态后验分布:

$$\theta_{t-1} | D_{t-1} \sim N(m_{t-1}, C_{t-1}) \quad (18)$$

(2) t 时刻的状态先验分布:

$$\theta_t | D_{t-1} \sim N(a_t, R_t) \quad (19)$$

式中, $a_t = m_{t-1} + \beta_{t-1} + \lambda$, $R_t = C_{t-1} + W_t$, 其中 λ 为状态的一阶回归系数, β_{t-1} 为 $t-1$ 时刻状态变量的变化趋势,可以使用一阶差分法来计算。

(3) t 时刻观测变量一步预测分布:

$$y_t | D_{t-1} \sim N(\mu_t, \sigma_t^2) \quad (20)$$

式中, $\sigma_t^2 = \text{var}(y_t | D_{t-1}) = R_t + V_t$, $\mu_t = E(y_t | D_{t-1})$, 其中 $\text{var}(\cdot)$ 和 $E(\cdot)$ 分别代表方差和均值。定义 $P_t = (\sigma_t^2)^{-1}$ 为贝叶斯动态模型的精度。

(4) t 时刻的状态后验分布:

$$\theta_t | D_t \sim N(m_t, C_t) \quad (21)$$

式中, $C_t = \text{var}(\theta_t | D_t) = R_t - \mathbf{A}_t \mathbf{A}_t^T \sigma_t^2$, $m_t = E(\theta_t | D_t) = a_t + \mathbf{A}_t \mathbf{e}_t$, $\mathbf{A}_t = R_t (\sigma_t^2)^{-1}$, $\mathbf{e}_t = y_t - f_t$ 表示更新向量。

根据HPD区域的定义^[13],第 k 步观测值的预测区间(95%的保证率)为:

$$[f_t(k) - 1.645 \sqrt{Q_t(k)}, f_t(k) + 1.645 \sqrt{Q_t(k)}] \quad (22)$$

式中, $f_t(k)$ 和 $Q_t(k)$ 分别为预测值和预测方差。

2.2 高频极值应力的GRU模型预测

首先利用解耦后的高频极值应力数据开始训练GRU模型,得到式(15)~(17)中的模型参数,然后利用已知参数的GRU模型开始对高频极值应力进行预测,步骤如下:

(1) 输入层:输入初始数据 $\mathbf{X}(t)$,也就是解耦后的高频极值应力。

(2) 门控单元:包括在1.3节提到的更新门和重置门。

(3) 隐藏状态:即图1中的 $\mathbf{h}(t)$,代表了模型在时间步 t 对序列数据的内部记忆。

(4) 更新门:用于决定隐藏状态 $\mathbf{h}(t)$ 的更新程度,通过式(15)进行计算。

(5) 重置门:决定了隐藏状态 $\mathbf{h}(t)$ 对于先前一步的隐藏状态 \mathbf{h}_{t-1} 进行重置的程度,通过式(16)进行计算。

(6) 候选隐藏状态: $\tilde{\mathbf{h}}_t$ 是根据重置门和输入的序列数据计算得出的,通过式(17)进行计算。

(7) 更新隐藏状态:隐藏状态的更新是根据更新门和候选隐藏状态进行的,通过式(17)进行计算。

(8) 输出层:根据隐藏状态来进行相应的预测工作。

对(3)~(8)步进行重复分析直到处理完所输入的序列数据即可完成对序列数据的预测工作。

2.3 耦合极值应力的预测模型

为了能够验证出本文提出的(BDLTM-GRU)预测模型的可行性,对于耦合极值应力的预测分为以下三种情况进行分析比较:

情形一:低频极值应力的BDLTM预测值叠加高频极值应力的GRU模型预测值;

情形二:直接对耦合极值应力建立BDLTM进行预测;

情形三:直接对耦合极值应力建立GRU模型进行预测;

对于以上三种情形分别进行预测,然后引入均方误差值 R 来验证三种情形的精度。均方误差值 R 越小,则该模型的精度越高。

$$R = \sqrt{\frac{\sum_{i=1}^n (y_{\text{obs},i} - y_{\text{model},i})^2}{n}} \quad (23)$$

式中, y_{obs} 为真实观测值; y_{model} 为耦合极值应力预测模型的预测值; n 为观测值的个数。

3 监测应力实例分析

富民桥的总体结构如图2所示,主梁的监测截

面如图3所示。富民桥总长为340.3 m,宽度为40 m,设有双向6车道的机动车道,并且人行道设置在主梁下方。桥的主跨为157 m,属于单塔空间索面自锚式悬索桥。



图2 天津富民桥
Fig. 2 Tianjin Fumin Bridge

该桥的主要结构特点是桥塔高58 m,采用独柱设计。为了保证桥梁的稳定,以主跨和边跨的主缆来支撑桥梁结构。主跨主缆锚定于主梁的两侧,呈现三维抛物线形状,这种形状既在立体空间上又在平面上呈现。而边跨主缆则采用一组缆索构成,并且不使用垂直的吊索。




图4 截面变化段光纤应变传感器布置图(A截面)

Fig. 4 Fiber optic strain sensor layout in section change (Section A)

图5为3个监测点的极值应力曲线图,可以看出A断面的底板内侧和中间所承受的应力较大且变化趋势也基本一致。这是由于底板内侧和中间通常距离桥墩比较近,受到桥墩的反作用力较大,所以承受较大的应力。




图5 监测极值应力曲线

Fig. 5 Monitoring extreme stress curves

3.1 桥梁构件极值应力的解耦

利用小波多分辨率分析法对天津富民桥A截面




图3 主梁的监测截面

Fig. 3 Monitoring section of the main beam

本文对该桥梁A面的3个传感器FBG01074(底板内侧)、FBG01078(底板中间)、FBG01081(底板外侧)所分别监测的120 h的应力数据进行分析,取每小时的绝对值最大值为极值应力进行研究,这些数据均是在20 Hz的采样频率下采集的。A断面的传感器布置图如图4所示,其中,测点1、3、5、7、8、10、12、13为顺桥向测点,2、4、6、9、11、14为温度补偿测点。本文传感器FBG01074、FBG01078和FBG01081分别对应测点1、3、5。

底板内侧、中间和外侧的极值应力时程曲线进行趋势项(低频)提取。

趋势项曲线与其均值的差作为温度荷载引起的极值应力,所对应曲线为温度荷载效应的极值应力时程曲线,如图6所示;极值应力曲线减去低频曲线可得到车辆荷载所引起的应力时程曲线,如图7所示。图8为温度荷载效应和车辆荷载效应耦合后的极值应力时程曲线。

3.2 温度荷载效应极值应力的预测

图6所得的温度荷载效应即为所需要的初始数据,然后对初始数据进行柯尔莫戈洛夫-斯米诺夫检验,得到其服从正态分布。

根据监测数据,结合式(11)~(13),即可对温度荷载效应建立线性动态模型(DLTM):

(1)监测方程:

$$y_t = \theta_t + v_t; \quad v_t \sim N(0, V_t) \quad (24)$$

(2)状态方程:

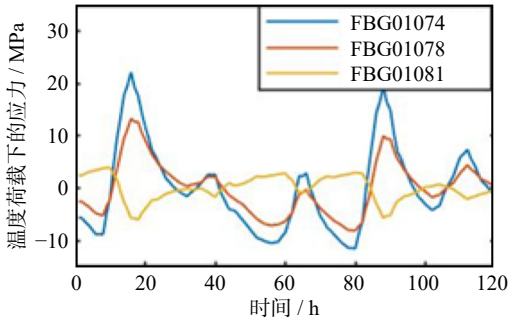


图 6 解耦后的温度荷载效应曲线

Fig. 6 Temperature load effect curves after decoupling

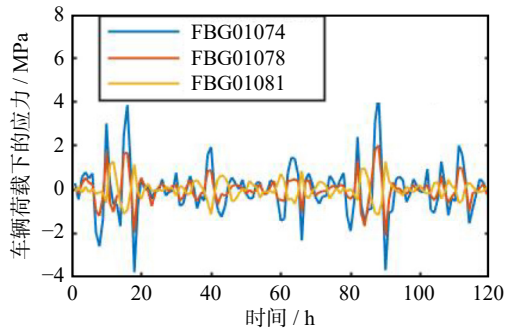


图 7 解耦后的车辆荷载效应曲线

Fig. 7 Vehicle load effect covers after decoupling

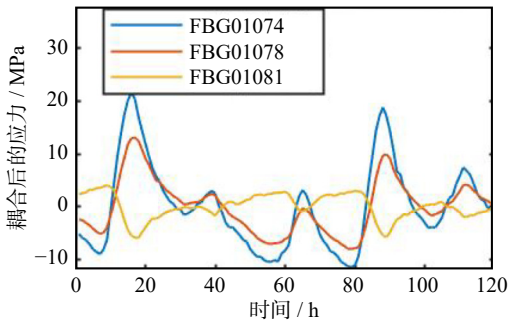


图 8 耦合后的荷载效应曲线

Fig. 8 The load effect curves after coupling

$$\begin{cases} \theta_t = \theta_{t-1} + \beta_{t-1} + \omega_t; \omega_t \sim N(0, W_t) \\ \beta_{t-1} = \theta_{t-1} - \theta_{t-2} \end{cases} \quad (25)$$

(3) 初始信息:

$$\theta_{t-1}|D_{t-1} \sim N(0, 8.02^2) \quad (26)$$

$$\theta_{t-1}|D_{t-1} \sim N(0, 5.1^2) \quad (27)$$

$$\theta_{t-1}|D_{t-1} \sim N(0, 2.34^2) \quad (28)$$

其中, 式 (26) 为 FBG01074 的初始信息, 式 (27) 为 FBG01078 的初始信息, 式 (28) 为 FBG01081 的初始信息。 V_t 为温度荷载数据线性动态模型的监测误差的方差, 可由对平滑处理后的监测数据的方差求得 $V_t = 64.46$ (FBG01074), $V_t = 26.04$ (FBG01078), $V_t = 5.46$ (FBG01081); W_t 可由式 (13) 计算得到。

由式 (26)~(28) 可知解耦后的温度效应的初始状态服从正态分布, 结合 2.1 节的 BDLTM 概率递推可对解耦后温度荷载作用下的极值应力进行预测评估, 图 9~11 即为温度荷载效应的预测曲线。




图 9 FBG01074 的温度荷载效应的预测曲线

Fig. 9 Prediction curves of temperature load effect for FBG01074




图 10 FBG01078 的温度荷载效应的预测曲线

Fig. 10 Prediction curve of temperature load effect for FBG01078




图 11 FBG01081 的温度荷载效应的预测曲线

Fig. 11 Prediction curves of temperature load effect for FBG01081

由图 9~11 可知贝叶斯动态线性模型的预测结果变化趋势都非常贴近原始数据, 且在温度荷载效应波动较大的情况下, 所有的监测值仍处于预测区间之内; 由图 12~14 可知预测精度也呈缓慢上升趋势, 代表后续的预测值会越来越贴近温度荷载效应的监测值。

车辆荷载效应由于非线性和波动性较强, 所以采用 GRU 神经网络模型对其进行预测, 在进行预测之前先输入原始数据对 GRU 模型进行训练, 随着训练次数的增多, 预测值也逐渐逼近原始数据。

3.3 车辆荷载效应极值应力的预测

图 15~17 是使用 GRU 模型对车辆荷载进行预测的结果, 图 18~20 是预测值与车辆荷载效应之间的




图12 FBG01074的温度荷载效应的预测精度

Fig. 12 Prediction accuracy of temperature load effect for FBG01074




图13 FBG01078的温度荷载效应的预测精度

Fig. 13 Prediction accuracy of temperature load effect for FBG01078




图14 FBG01081温度荷载效应的预测精度

Fig. 14 Prediction accuracy of temperature load effect for FBG01081

误差图(车辆荷载效应-预测值), 可以看到 GRU 模型对于预测车辆荷载效应表现较好, 预测结果的波




图15 FBG01074的车辆荷载效应的预测值

Fig. 15 The predicted value of vehicle load effect for FBG01074

动趋势与车辆荷载的波动趋势基本吻合, 数值误差也较小, 基本符合预测要求。




图16 FBG01078的车辆荷载效应的预测值

Fig. 16 The predicted value of vehicle load effect for FBG01078




图17 FBG01081的车辆荷载效应的预测值

Fig. 17 The predicted value of vehicle load effect for FBG01081




图18 FBG01074的车辆荷载效应的预测误差图

Fig. 18 Prediction error diagram of vehicle load effect for FBG01074

3.4 耦合极值应力的预测

将图9~11和图15~17分别得到的温度荷载效应预测值和车辆荷载效应预测值进行叠加, 即可实现耦合极值应力的预测, 将预测后的耦合极值应力与耦合极值应力的原始数据进行对比来验证BDLTM-GRU模型的可行性。

从图21~23可以看出耦合极值应力的预测值与实测值基本一致, 预测效果良好且比较稳定, 变化趋势方面基本吻合, 预测值处于置信区间之内, 因此本文所提模型具有可行性, 且效果较好。




图 19 FBG01078 的车辆荷载效应的预测误差图

Fig. 19 Prediction error diagram of vehicle load effect for FBG01078




图 20 FBG01081 的车辆荷载效应的预测误差图

Fig. 20 Prediction error diagram of vehicle load effect for FBG01081




图 21 FBG01074 的 BDLTM-GRU 模型预测的耦合数据

Fig. 21 Coupling data predicted by the BDLTM-GRU model for FBG01074




图 22 FBG01078 的 BDLTM-GRU 模型预测的耦合数据

Fig. 22 Coupling data predicted by the BDLTM-GRU model for FBG01078




图 23 FBG01081 的 BDLTM-GRU 模型预测的耦合数据

Fig. 23 Coupling data predicted by the BDLTM-GRU model for FBG01081

为了继续验证 BDLTM-GRU 模型的精度, 对 2.3 节中所提出的三种情形进行建模分析:

(1) 情形一: 耦合极值应力预测值如图 21~23 所示。

(2) 情形二: 耦合极值应力的数据如图 8 所示, 根据 1.2 节和 2.1 节所提出的 BDLTM 对其进行建模预测。结果如图 24~26 所示。




图 24 FBG01074 的 BDLTM 预测的耦合数据

Fig. 24 Coupling data predicted by the BDLTM model for FBG01074




图 25 FBG01078 的 BDLTM 预测的耦合数据

Fig. 25 Coupling data predicted by the BDLTM model for FBG01078

(3) 情形三: 根据耦合极值应力的数据建立 GRU 模型对其进行预测分析, 结果如图 27~29 所示。

从预测结果图来看三种预测模型都能够较好地 对耦合极值应力进行实时预测, 不管是趋势走向还是峰值数据都比较符合耦合极值应力的监测数据。




图 26 FBG01081 的 BDLTM 预测的耦合数据

Fig. 26 Coupling data predicted by the BDLTM model for FBG01081




图 27 FBG01074 的 GRU 模型预测的耦合数据

Fig. 27 Coupling data predicted by the GRU model for FBG01074




图 28 FBG01078 的 GRU 模型预测的耦合数据

Fig. 28 Coupling data predicted by the GRU model for FBG01078




图 29 FBG01081 的 GRU 模型预测的耦合数据

Fig. 29 Coupling data predicted by the GRU model for FBG01081

为了对比三种预测模型的精度,采用三种模型的均方误差来判断哪种模型的精度最高。

FBG01074:

$$R(1) = 0.5966; R(2) = 0.6261; R(3) = 0.7259$$

FBG01078:

$$R(1) = 0.3320; R(2) = 0.3848; R(3) = 0.4562$$

FBG01081:

$$R(1) = 0.3169; R(2) = 0.3397; R(3) = 0.3760$$

通过以上三个监测点的三种模型可以得到 $R(1) < R(2) < R(3)$, 因此 BDLTM-GRU 的模型精度要略大于 BDLTM 和 GRU 模型的精度。

4 结 论

(1) 采用小波多分辨率分析法对桥梁监测极值应力进行了分解处理, 然后进行解耦操作, 使用 BDLTM 和 GRU 模型对解耦后的极值应力进行预测分析, 最终通过 BDLTM-GRU 模型来预测耦合极值应力, 通过对天津富民桥的实例验证, 证明本文所建立的 BDLTM-GRU 模型能够较为准确地预测耦合极值应力。

(2) 通过建立的 BDLTM-GRU 模型实现了对耦合极值应力的预测, 分别与 BDLTM 和 GRU 模型进行了精度比较, 验证了本文所提出的 BDLTM-GRU 模型具有高精度的特性。

参考文献:

- [1] 樊学平, 吕大刚. 基于 BDNM 的桥梁结构可靠度预测 [J]. 哈尔滨工业大学学报, 2014, 46(2): 1-5.
FAN Xueping, LYU Dagang. Reliability prediction of bridge structures based on BDNM[J]. *Journal of Harbin Institute of Technology*, 2014, 46(2): 1-5.
- [2] 李顺龙. 基于健康监测技术的桥梁结构状态评估和预警方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2009.
LI Shunlong. Approaches of condition assessment and damage alarming of bridges based on structural health monitoring[D]. Harbin: Harbin Institute of Technology, 2009.
- [3] AN Y H, CHATZI E, SIM S H, et al. Recent progress and future trends on damage identification methods for bridge structures[J]. *Structural Control and Health Monitoring*, 2019, 26(10): e2416.
- [4] WAN H P, REN W X. Stochastic model updating utilizing Bayesian approach and Gaussian process model[J]. *Mechanical Systems and Signal Processing*, 2016, 70: 245-268.
- [5] FAN X P, LIU Y F. Use of monitored daily extreme stress data for performance prediction of steel bridges: dynamic linear models and Gaussian mixed particle filter[J]. *Mechanical Systems and Signal Processing*, 2019, 121: 841-855.
- [6] BURRUS C S, GOPINATH R A, GUO H T. Introduction to

- Wavelets and Wavelet Transforms: A primer[M]. Upper Saddle River, USA: Prentice Hall, 1998.
- [7] NI Y Q, XIA H W, WONG K Y, et al. In-service condition assessment of bridge deck using long-term monitoring data of strain response[J]. *Journal of Bridge Engineering*, 2012, 17(6): 876-885.
- [8] NI Y Q, CHEN R. Strain monitoring based bridge reliability assessment using parametric Bayesian mixture model[J]. *Engineering Structures*, 2021, 226: 111406.
- [9] 樊学平, 吕大刚. 基于贝叶斯 DLM 的桥梁结构可靠度预测 [J]. *铁道学报*, 2014, 36(6): 93-98.
- FAN Xueping, LYU Dagang. Reliability prediction of aging bridges based on Bayesian dynamic linear model[J]. *Journal of the China Railway Society*, 2014, 36(6): 93-98.
- [10] 樊学平, 刘月飞, 吕大刚. 桥梁监测数据的动态线性建模与可靠性预测 [J]. *同济大学学报(自然科学版)*, 2016, 44(7): 1002-1009.
- FAN Xueping, LIU Yuefei, LYU Dagang. Dynamic linear modeling of bridge monitored data and reliability prediction[J]. *Journal of Tongji University (Natural Science)*, 2016, 44(7): 1002-1009.
- [11] 樊学平, 杨光红, 刘月飞. 大跨混凝土桥梁耦合极值应变的混合粒子预测 [J]. *哈尔滨工程大学学报*, 2021, 42(8): 1167-1175.
- FAN Xueping, YANG Guanghong, LIU Yuefei. Hybrid particle prediction of coupling extreme strain data of long-span concrete bridges[J]. *Journal of Harbin Engineering University*, 2021, 42(8): 1167-1175.
- [12] PETRIS G, PETRONE S, CAMPAGNOLI P. Dynamic Linear Models with R[M]. New York, USA: Springer, 2009.
- [13] WEST M, HARRISON J. Bayesian Forecasting and Dynamic Models[M]. New York, USA: Springer, 1989.
- [14] CHO K, VAN MERRIËNBOER B, BAHDANAU D, et al. On the properties of neural machine translation: encoder-decoder approaches[C]//Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation. Stroudsburg, PA, USA: ACL, 2014: 103-111.
- [15] 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 Hanwen, DENG Yang, LI Aiqun. Restoring method of structural abnormal monitoring data based on GRU neural network[J]. *Journal of Vibration and Shock*, 2023, 42(9): 328-338.

第一作者:杨 渡(2001—),男,硕士研究生。

E-mail: yangdu18@lzu.edu.cn

通信作者:樊学平(1983—),男,博士,副教授。

E-mail: fanxp@lzu.edu.cn