

考虑时空相关性的桥梁监测数据 多通道联合恢复方法

辛景舟^{1,2}, 杨伟彤^{1,2}, 周建庭^{1,2}, 唐启智^{1,2}, 周朝营^{1,2}, 张洪^{1,2}

(1. 重庆交通大学省部共建山区桥梁及隧道工程国家重点实验室, 重庆 400074;

2. 重庆交通大学土木工程学院, 重庆 400074)

摘要: 桥梁健康监测数据由于受到传感器故障等因素的影响, 易发生数据缺失的情况。然而, 现有监测数据恢复方法尚未有效利用数据的时间与空间相关性。为此, 本文提出了一种考虑时空相关性的桥梁监测数据多通道联合恢复方法。采用卡尔曼滤波归一化处理原始数据, 消除随机误差的影响; 将预处理后的数据划分为训练集和测试集, 通过滑窗方式构造训练样本, 并对样本进行掩码处理, 将数据恢复问题转化为时间序列预测问题; 利用传感器自身历史数据的时空相关性, 构建端到端的长短期记忆神经网络进行训练, 从而实现缺失数据的恢复; 基于某悬索桥主梁挠度和吊索索力监测数据验证所提方法的有效性, 讨论该方法恢复单通道及多通道数据的性能。结果表明, 与传统循环神经网络相比, 在数据缺失率为 60% 时, 所提方法可以实现 22% 的精度提升; 此外, 该方法能充分利用数据通道间的时空相关性, 实现多个通道数据的同时恢复。

关键词: 桥梁健康监测; 桥梁工程; 数据恢复; 长短期记忆神经网络; 时空相关性

中图分类号: U446 **文献标志码:** A **文章编号:** 1004-4523(2025)03-0558-09

DOI: 10.16385/j.cnki.issn.1004-4523.2025.03.012

Joint recovery method for multi-channel bridge monitoring data considering spatiotemporal correlation

XIN Jingzhou^{1,2}, YANG Weitong^{1,2}, ZHOU Jianting^{1,2}, TANG Qizhi^{1,2}, ZHOU Chaoying^{1,2},
ZHANG Hong^{1,2}

(1. State Key Laboratory of Mountain Bridge and Tunnel Engineering, Chongqing Jiaotong University, Chongqing 400074,
China; 2. School of Civil Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: Bridge health monitoring data often encounter missing values due to sensor failures and other factors. Existing data recovery methods have not effectively utilized the temporal and spatial correlations in the data. In this paper, a multi-channel recovery method for bridge monitoring data based on temporal and spatial correlations is proposed. The original data is preprocessed using a Kalman filter to eliminate random errors. The preprocessed data is divided into training and testing sets, and training samples are constructed using a sliding window approach with masking. The data recovery issue is formulated as a time series prediction issue. Besides, an end-to-end LSTM network architecture is trained to leverage the temporal and spatial correlations in the historical data of the sensors which enables the recovery of missing data. The proposed method is validated using the measured deflection and cable force data from a suspension bridge, and the performance of single-channel and multi-channel data recovery is discussed. Compared to the traditional RNN models, results show that the proposed method achieves a 22% improvement in accuracy when the data missing rate is 60%. Moreover, the method effectively utilizes the temporal and spatial correlations among different channels, enabling simultaneous recovery of data from multiple channels.

Keywords: bridge health monitoring; bridge engineering; data recovery; long short-term memory neural network; spatiotemporal correlation

随着交通强国战略的深入实施, 桥梁健康监测
系统得到广泛建立^[1-4], 为桥梁安全保障提供了重要

手段。桥梁健康监测数据的完整性是发挥健康监测
系统预期功能的关键所在。然而, 由于监测设备、数

收稿日期: 2023-08-26; 修订日期: 2024-01-23

基金项目: 国家自然科学基金资助项目(52278292, 52208264); 重庆市杰出青年科学基金资助项目
(CSTB2023NSCQ-JQX0029); 贵州省交通运输厅科技项目(2023-122-001)

据传输故障等因素的干扰,监测数据缺失时有发生,这严重影响了结构损伤识别和安全评估的准确性。因此,恢复缺失监测数据,对于保障监测数据的可靠性,准确把握桥梁的健康状态具有重要研究意义与工程应用价值^[5-6]。

近年来,数据驱动的监测数据恢复方法得到了快速发展^[7],大致可分为3类,即基于压缩感知的恢复方法、基于统计插值的恢复方法以及基于深度学习的恢复方法。其中,基于压缩感知的恢复方法是根据欠采样信号重构理论,利用观测矩阵将信号投影到低维空间得到观测向量,最后通过求解最优化问题实现原信号的恢复。比如,胡辽林等^[8]提出了阈值收缩迭代算法,实现了含噪信号的恢复;HUANG等^[9]提出了一种贝叶斯压缩感知算法来恢复健康监测数据;CAO等^[10]利用压缩感知技术,实现了无线传感器网络的数据恢复。但是此类方法需要较多的先验知识,耗时较长,无法实现实时恢复,并且该方法在很大程度上依赖数据在特定特征空间的稀疏性,不适用于数据高缺失率情况^[11]。

另外,部分学者利用监测数据的相关性特征,开展了基于统计插值的监测数据恢复研究。比如,马帜等^[12]引入概率主成分分析方法来恢复缺失监测数据;陈帅等^[13]将监测数据转换为高维矩阵,利用奇异值分解理论插补缺失数据;CHEN等^[14]开发了一种概率分布回归方法,利用来自其他传感器的完整数据恢复缺失数据;YANG等^[15]利用数据结构的先验知识恢复随机缺失的结构振动响应时程。然而,此类方法只能恢复缓慢变化的信号,不适用于高频信号的恢复。

随着人工智能技术的发展,深度学习方法也在不断应用于数据恢复研究^[16]。由于深度学习可以从数据中提取更复杂的非线性相关性,因此其具有更高的恢复精度^[17]。比如,LEI等^[18]为了重构缺失监测数据,提出了一种深度卷积生成对抗网络;孟宏宇等^[19]构建了无监督残差网络用于地震监测数据的重构;OH等^[20]利用完整应变监测数据,构建了卷积神经网络(convolutional neural network, CNN)数据恢复模型,以此恢复缺失的应变响应;郭旭等^[21]结合CNN和深度卷积生成对抗网络来恢复故障信号。虽然基于深度学习的监测数据恢复方法已取得长足发展,但现有方法大多是利用传感器之间的空间相关性,没有挖掘出数据自身的时间相关性,未能实现两者的融合统一。

针对现有研究的不足,本文充分利用监测数据的时间与空间相关性,提出考虑时空相关性的桥梁监测数据多通道联合恢复方法,通过桥梁挠度和吊索索力监测数据恢复的实例分析验证方法的有效性。

1 长短期记忆神经网络

1.1 基本原理

针对传统循环神经网络(recurrent neural network, RNN)的梯度消失和长期依赖问题^[22],长短期记忆神经网络(long short-term memory neural network, LSTM)通过定义一个特殊的“门”来控制信息的流动,降低了梯度消失的概率,增强长时记忆,内部结构更加复杂,具有更强的表现力。

LSTM包含3种类型的门,即遗忘门、输入门和输出门,如图1所示。遗忘门的第一层决定了信息能否通过细胞状态^[23]:

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

式中, f_t 为 t 时刻的遗忘门; $\sigma(\cdot)$ 为sigmoid激活函数; W_f 表示权重; x_t 为输入值; h_{t-1} 为 $t-1$ 时刻的输出值; b_f 为偏差项。

第二个输入门从当前输入向量中决定哪些信息应该存储在细胞状态中:

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

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

式中, i_t 表示 t 时刻的输入门; \hat{C}_t 表示临时记忆单元状态; W_i 、 W_c 表示权重; $\tanh(\cdot)$ 为激活函数; b_i 、 b_c 表示偏差项。通过下式更新细胞状态:

$$C_t = f_t \odot C_{t-1} + i_t \odot \hat{C}_t \quad (4)$$

式中, C_t 为 t 时刻的记忆单元状态; \odot 表示逐元素乘法。

第三层可以提供当前时间步内的输出信息。具体表达式如下:

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

式中, o_t 为 t 时刻的输出门; W_o 表示权重; b_o 表示偏差项。于是,细胞的输出值为:

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$

$$y_t = f(W_y h_t + b_y) \quad (7)$$

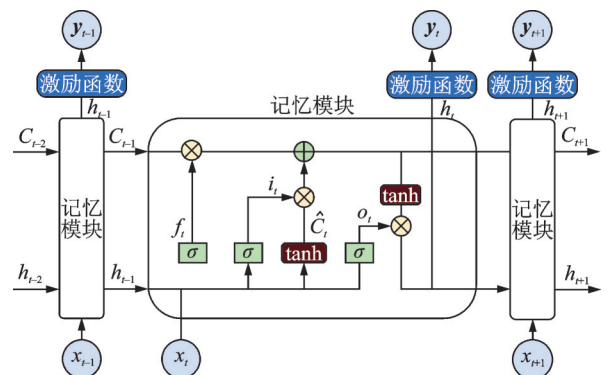


图1 长短期记忆神经网络模型

Fig. 1 The model of LSTM

式中, y_t 为输出层的输出向量; W_y 为隐藏层与输出层权重矩阵; b_y 为偏置; $f(\cdot)$ 为输出层的激活函数。

1.2 训练机制

LSTM在网络结构和损失函数 L 确定后,其训练过程为:首先初始化网络参数,然后通过前向传播将信息传递到输出层,再通过误差反向传播更新网络参数,如图2所示。图中, h_0 表示初始隐藏状态(一般为零向量)。正向传播按照图2中黑色箭头方向进行,误差反向传播按照绿色箭头方向进行。权重和偏置项通过最小化目标函数的损失进行更新。通过不断循环更新参数,直至梯度达到所需精度为止,此时模型参数达到最优,并可将其参数应用于后续的预测中。

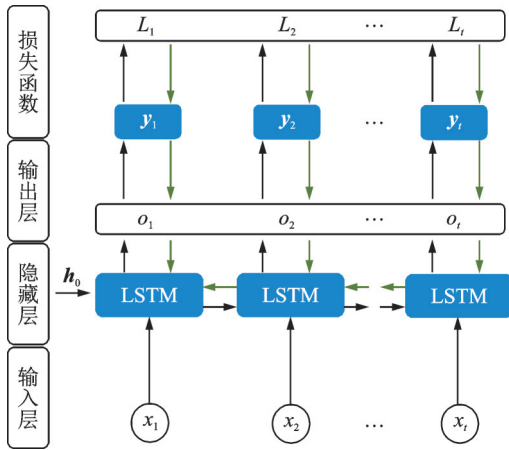


图2 LSTM训练机制

Fig. 2 The training mechanism of LSTM

2 桥梁监测数据恢复方法

2.1 方法流程

桥梁监测数据具有非稳定性、非线性、海量性等特点。针对桥梁监测数据多通道缺失情况,本文利用监测数据的时空相关性,提出桥梁监测数据多通道联合恢复方法如图3所示,恢复流程如下:

(1)采用卡尔曼滤波处理时间序列数据,并对滤波后的数据进行归一化处理;

(2)将经过预处理的时序数据划分为训练集与测试集,其中训练集用于建立模型,测试集用于验证模型的泛化能力;

(3)采用时间窗滑动裁剪时序数据,构造训练样本;

(4)对构造完成的样本进行掩码处理,标记缺失数据,以便在模型训练和数据恢复中充分利用数据间时空相关性;

(5)搭建多通道联合恢复神经网络模型,通过训练学习多通道数据间的时空相关性;

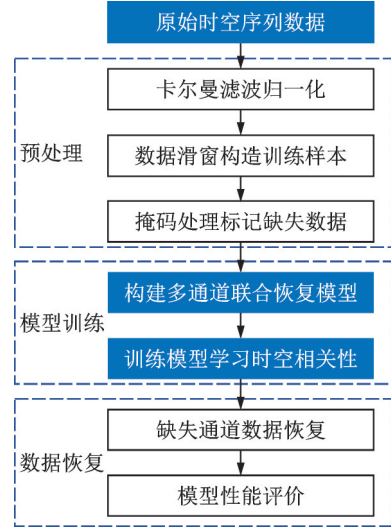


图3 基于时空相关性的桥梁监测数据多通道联合恢复方法
Fig. 3 Multi-channel joint recovery method of bridge monitoring data based on spatiotemporal correlation

(6)将测试集送入训练好的数据恢复模型中,进行缺失数据的恢复,验证模型的泛化能力;

(7)恢复模型评价。

2.2 掩码处理

在桥梁健康监测系统中,数据缺失是随机发生的,缺失位置与模式对恢复性能有显著影响。为此,本文通过掩码处理标记缺失数据,使模型在训练过程中能够充分利用数据的时空相关性实现传感器数据的多通道联合恢复,提高数据恢复的准确性和可靠性。针对多维时间序列 $X = [x_1, x_2, \dots, x_T] \in \mathbf{R}^{T \times D}$, $x_t \in \mathbf{R}^D$, $T \geq 1$, 其中, T 为通道个数, D 为数据长度, \mathbf{R} 为实数集,利用一个二进制掩码矩阵 $mask_t^d \in \{0, 1\}^D$ 来表示数据是否缺失:

$$mask_t^d = \begin{cases} 0, & x_t^d \text{ 缺失} \\ 1, & x_t^d \text{ 未缺失} \end{cases} \quad (8)$$

式中, x_t^d 表示第 t 个通道的第 d 个值。

对 X 进行掩码处理得到 X_R , 即 X_R 中的缺失数据为 0, 未缺失数据为原始值:

$$X_R = X \odot mask \quad (9)$$

将 X_R 作为后续网络模型输入,模型输出定义为 Y , Y 维度与 X_R 一致,则缺失数据的预测值为:

$$\hat{X}_m = Y \odot (1 - mask) \quad (10)$$

那么,最终的预测结果为:

$$\hat{X} = X_R \oplus \hat{X}_m \quad (11)$$

式中, \oplus 为矩阵对应元素相加。

2.3 模型评价指标

为了评价模型的恢复性能,选取了4个评价指标,分别为均方误差 MSE 、均方根误差 $RMSE$ 、平均绝对误差 MAE 和决定系数 R^2 ,其计算公式如下^[24]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

式中, n 为缺失数据的个数; \hat{y}_i 为第 i 个预测数据; y_i 为第 i 个原始数据; \bar{y} 为第 i 个原始数据均值。MSE、RMSE、MAE 的数值越小, 表明该模型的恢复精度越高; R^2 的值越大, 说明模型的拟合能力越强。

3 实例分析

3.1 桥梁概况

以某大跨轨道专用悬索桥为依托工程。该桥全长 1650.5 m, 主桥长 1120 m, 桥面宽 22 m。主梁为钢梁-混凝土梁混合结构。该桥健康监测系统主要监测挠度、温湿度、索力等指标。主桥钢箱梁竖向变形测点布置于两边跨 1/4、1/2、3/4 跨截面及中跨 1/8、1/4、3/8、1/2、5/8、3/4、7/8 跨截面, 全桥共 13 个截面, 每个截面均布设两个测点(均位于上/下游侧腹板位置), 共计 30 个测点(含 2 个基准点和 2 个转点)。具体监测测点布置如图 4 所示。

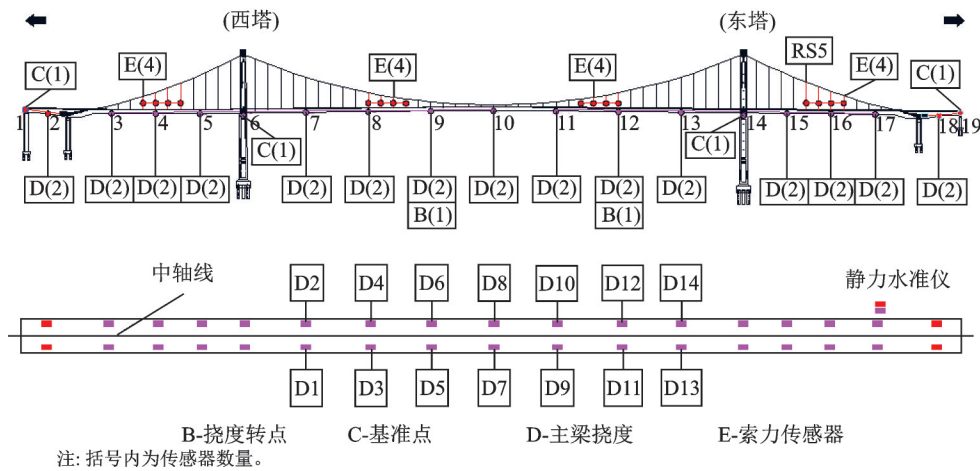


图 4 依托工程挠度与索力的监测测点布置

Fig. 4 Arrangement of the deflection and cable force monitoring point of the background bridge

选取该桥中跨 1/8、1/4、3/8、1/2、5/8、3/4、7/8 截面上/下游挠度作为分析对象, 将中跨 1/8 上游命名为 D1, 下游为 D2, 依次向右侧类推, 直至中跨 7/8 下游为 D14。采集该桥于 2021 年 10 月 1 日至 11 月 1 日的监测数据, 取其半小时均值作为挠度荷载响应数据, 构成了共 4230 个数据点的主梁挠度数据集。

3.2 缺失数据恢复

首先以挠度监测数据为例, 仅利用数据的时序相关性, 考察所提方法在不同缺失率和缺失模式下的恢复性能; 然后以桥梁吊索索力为例, 进一步验证方法的适用性。

3.2.1 数据预处理

为了更好地消除噪声等因素的干扰, 同时提高数据利用率, 首先采用卡尔曼滤波算法进行数据预处理^[25], 初始误差协方差、系统状态转移矩阵、观测状态转移矩阵均设置为 1, 并在算法迭代过程中不断更新。D7 和 D8 的滤波结果如图 5 所示。从图 5 中可以看出, 滤波后数据波动均小于未滤波前的波

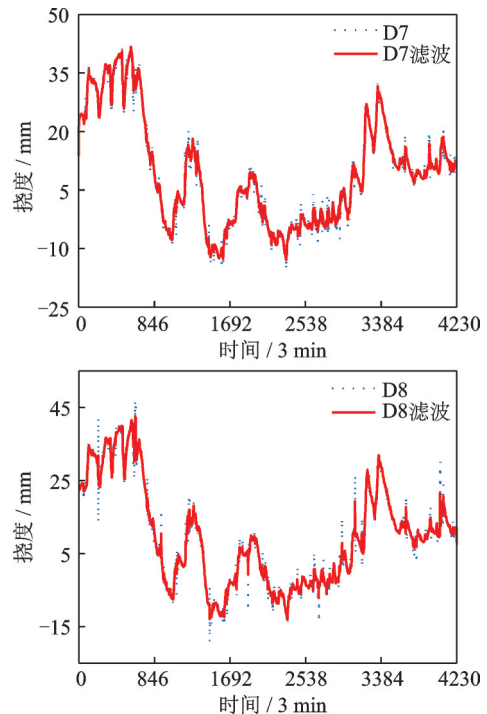


图 5 卡尔曼滤波后的挠度数据

Fig. 5 The deflection data after Kalman filtering

动情况,说明消除数据中的随机误差影响有利于后续的数据处理与分析。

3.2.2 划分训练集和测试集

选取D7作为数据集,对D7数据集进行归一化处理,并将归一化后的数据按照8:2的比例划分为训练集与测试集。

3.2.3 构造训练样本

采用数据滑窗^[26]的方式裁剪与扩充时序数据,滑窗划分方式如图6所示。滑窗步长为1,滑窗长度为10。在滑动窗口裁剪增强的数据集中,训练集有3375个样本,测试集有84个样本,每个样本的长度为10。

3.2.4 搭建数据恢复模型

模型网络一般由输入层、隐藏层和输出层组成,网络层数与网络参数的选取决定网络容量的大小,并且影响恢复模型的泛化能力和准确度。考虑到问

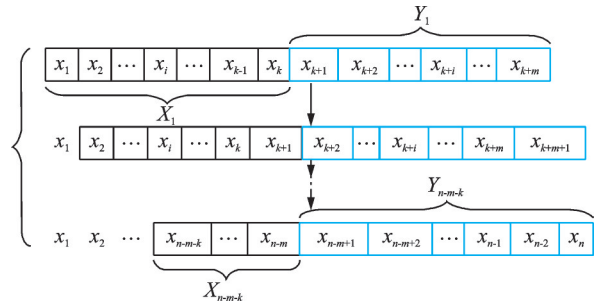


图6 滑动时间窗构造训练样本
Fig.6 The training sample constructed by sliding time window

题的复杂性及训练样本的规模,并且为了使模型能够学习到更高级别的时间特征,本文采用了如图7所示的网络结构。此外,使用Adam优化器进行参数更新,利用MSE损失函数计算真实值与预测值之间的误差。

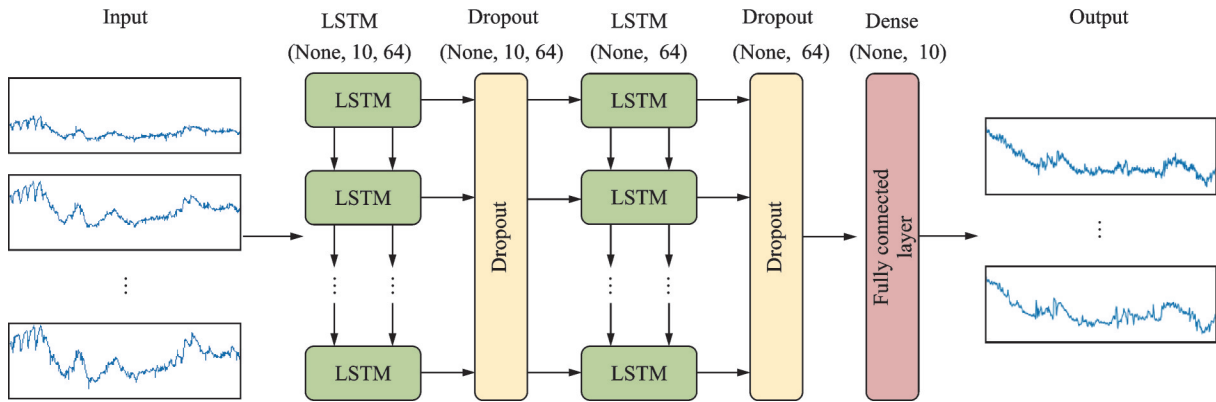


图7 所用LSTM结构

Fig.7 The structure of LSTM

3.2.5 数据恢复

(1)不同缺失率下的恢复性能

在数据随机缺失模式下设置了不同的缺失率(10%~90%)工况,并与传统RNN模型进行比较,部分结果如图8~10及表1所示。由结果可知,当数据缺失率达到60%时,两种模型均能恢复缺失数

据,但得到的恢复值与真实值之间存在一定的差异,其原因可能是在数据缺失率大于60%时,数据恢复机制已经发生了改变。随着缺失率的增加,模型恢复误差也随之增加,但LSTM恢复模型比RNN恢复模型更加准确。

进一步,表1展示了两种模型在不同缺失率下

表1 数据恢复误差对比

Tab.1 Comparison of data recovery error

恢复方法	评价指标	缺失率								
		10%	20%	30%	40%	50%	60%	70%	80%	90%
LSTM	RMSE	0.43	0.49	0.50	0.51	0.52	0.53	0.55	0.57	0.83
	MSE	0.18	0.24	0.25	0.26	0.27	0.28	0.30	0.33	0.69
	MAE	0.26	0.31	0.33	0.33	0.35	0.34	0.40	0.39	0.59
	R ²	0.99	0.99	0.99	0.99	0.99	0.98	0.98	0.98	0.96
RNN	RMSE	0.44	0.50	0.59	0.61	0.66	0.68	0.69	0.70	1.03
	MSE	0.19	0.25	0.35	0.37	0.44	0.46	0.47	0.49	1.06
	MAE	0.29	0.34	0.44	0.38	0.44	0.42	0.48	0.43	0.80
	R ²	0.99	0.99	0.98	0.98	0.98	0.97	0.97	0.97	0.95




图 8 数据缺失率为 30%

Fig. 8 Data missing rate of 30%




图 9 数据缺失率为 60%

Fig. 9 Data missing rate of 60%




图 10 数据缺失率为 90%

Fig. 10 Data missing rate of 90%

恢复结果的评价指标。从表 1 中可以看出,LSTM 模型的各项评价指标均优于传统 RNN 模型。比如,在缺失率为 90% 时,LSTM 模型恢复结果的 RMSE 为 0.83,而传统 RNN 模型的 RMSE 为 1.03。其原因在于 LSTM 模型更能记住时序数据的长时相关性,并能捕捉时序数据中隐藏的特征,从而使得模型能够有效地恢复缺失数据。此外,LSTM 模型恢复结果的 R^2 值都在 0.95 以上,高于 RNN 模型,说明了 LSTM 对所有的真实值预测准确,基本没有偏差。

(2)不同缺失模式下的恢复性能

在缺失率为 40% 的随机缺失数据恢复(缺失模式为 [0,1,0,1,1,1,0,1,0,1])的基础上,进行了数据缺失率为 40% 的连续缺失数据恢复(缺失模式为 [1,1,0,0,0,0,1,1,1,1]),恢复结果与恢复误差如图 11、12 及表 2 所示。从中可以看出,连续缺失模式下 LSTM 模型的 RMSE 为 0.50,小于 RNN 模型的 0.65;且连续缺失模式下 LSTM 与 RNN 模型的 RMSE、MSE、MAE 均大于随机缺失情况下的结果,说明对于连续缺失模型,两种模型的数据恢复能力均有所下降,但总体而言,所提方法在恢复结果上优于传统 RNN 模型。

此外,图 13 给出了连续缺失模式下恢复值与真实值的散点图。从图 13 中可以看出,LSTM 模型的




图 11 数据随机缺失恢复结果(缺失率为 40%)

Fig. 11 Recovery results of data of random missing (missing rate of 40%)




图 12 数据连续缺失恢复结果(缺失率为 40%)

Fig. 12 Recovery results of data of continuous missing (missing rate of 40%)

表 2 两种模型在不同数据缺失模式(缺失率为 40%)下的恢复误差

Tab.2 The recovery error of the two models under different data missing modes (missing rate of 40%)

缺失模式	恢复方法	评价指标			
		RMSE	MSE	MAE	R^2
随机缺失	LSTM	0.51	0.26	0.32	0.98
	RNN	0.61	0.37	0.42	0.98
连续缺失	LSTM	0.50	0.25	0.32	0.98
	RNN	0.65	0.42	0.42	0.98

R^2 为 0.986,而 RNN 模型的 R^2 为 0.979,说明 LSTM 模型的数据拟合度高于 RNN 模型,恢复数据更加接近真实值。

3.2.6 方法适用性

为进一步验证所提方法的普适性,选取东岸主桥边跨 RS5 号吊索索力进行验证分析,数据时间跨度为 2023 年 1 月 1 日至 1 月 15 日,时间间隔为 1 min,共 5000 个数据。索力原始数据以及卡尔曼滤波处理后的结果如图 14 所示。

按照 40% 的数据缺失率对数据进行掩码处理,并划分为训练集和测试集。使用训练集对 LSTM 模型进行训练,并在测试集上进行验证,恢复结果如图 15 所示。

为了更直观地展示 LSTM 模型恢复数据的差异,表 3 展示了不同模型在索力数据集上的恢复误差。从表 3 及图 15 中可以看出,LSTM 模型与 RNN 模型恢复值与真实值的差异均较小。此外,从恢复误差来看,LSTM 模型的 RMSE 为 2.64,远小于 RNN 模型的 3.53,其原因在于 LSTM 模型优异的数

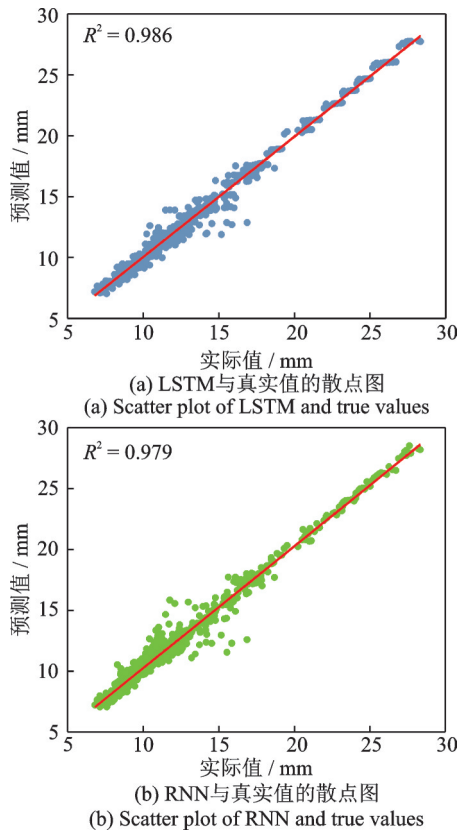


图13 连续缺失模式下恢复值与真实值的散点图

Fig. 13 Scatter plots of the recovered values and the true values under continuous missing mode




图14 滤波前/后索力对比

Fig. 14 Comparison of cable forces before and after filtering




图15 LSTM恢复结果

Fig. 15 Recovery results using LSTM

表3 索力数据恢复误差对比

Tab. 3 Comparison of recovery error of cable force data

恢复方法	评价指标			
	RMSE	MSE	MAE	R^2
LSTM	2.64	6.97	1.70	0.75
RNN	3.53	12.49	2.40	0.63

据特征提取能力。因此,本文所提方法能有效恢复索力缺失数据,并在恢复桥梁监测数据上具有一定的普适性。

3.3 讨论分析

在验证了所提方法利用时序相关性恢复缺失通道自身数据的基础上,本节针对实际工程中长期存在的单通道与多通道数据缺失情况,进一步探究所提方法利用时空相关性的恢复性能。

3.3.1 单通道恢复

针对单通道数据缺失情况,将D1设置为缺失对象(即模型输出),选取D2、D10、D4、D3、D7、D9、D8共7个通道数据作为模型输入,进行通道D1挠度信号的恢复。两种模型在测试集上的恢复结果如图16所示,而表4列出了恢复误差对比。从图16及表4中可以看出,就整体数据恢复情况而言,虽然LSTM模型与RNN模型的恢复结果均较原始曲线有一定的偏移,但基于监测数据的时空相关性来恢复丢失数据的方法具有可行性。LSTM模型与RNN模型之所以和实际值之间存在一定差异,其原因可能是本文数据均来自实际桥梁监测数据,而该数据存在一定的非平稳性与非线性。另外,从图16中可以看出,基于LSTM模型的恢复值与真实值曲线的重合度高于RNN模型。




图16 单通道数据恢复结果

Fig. 16 Recovery results of single-channel data

表4 不同模型的恢复误差对比

Tab. 4 Comparison of recovery error of different models

恢复方法	评价指标			
	RMSE	MSE	MAE	R^2
LSTM	0.49	0.24	0.38	0.82
RNN	0.61	0.38	0.49	0.76

3.3.2 多通道恢复

针对多通道数据缺失情况,利用8个通道间的时空相关性,以8个通道数据同时作为输入和输出,进行8个通道的挠度信号恢复,数据缺失率设置为10%~90%。表5列出了在数据缺失率为10%下的数据恢复误差对比。从表5中可以看出,在数据缺失率为10%的情况下,8个通道的恢复误差RMSE均在1.5以下,D10数据集恢复结果的 R^2 值为0.49,其原因可能是D10数据集与其余数据集的时空相关性较弱,但从整体上看,D1、D3、D4、D7、D8数据集

恢复结果的 R^2 值均在0.8以上,说明利用监测数据的时空相关性恢复缺失数据具有可行性。

表5 数据缺失率为10%下的恢复误差

Tab. 5 Recovery error with data missing rate of 10%

恢复方法	评价指标			
	RMSE	MSE	MAE	R^2
D1	0.47	0.22	0.35	0.87
D2	0.64	0.41	0.42	0.65
D9	1.34	1.80	0.84	0.53
D10	1.49	2.22	0.94	0.49
D3	0.86	0.75	0.58	0.85
D4	0.87	0.75	0.59	0.82
D7	1.03	1.06	0.77	0.94
D8	1.16	1.35	0.82	0.93

为了探究基于时空相关性的多通道数据恢复方法在不同数据缺失率下的恢复性能,图17直观展示了每个通道在不同缺失率下模型恢复性能变化情况。从图17中可以看出,数据缺失率越大,模型恢复性能越差,但也存在部分数据集在缺失率增加时,模型性能反而更好的情况,其原因在于本文所提出的数据缺失率为数据集整体缺失率,而整体缺失率的增加,并不代表每个单一数据集缺失率的增加。




图17 各通道数据在不同数据缺失率下的RMSE

Fig. 17 RMSE of each channel data under different data missing rates

4 结论

(1)所提方法利用时序相关性恢复挠度监测数据的精度和拟合能力优于其他模型,并且能够很好地捕捉样本特征,实现较理想的监测数据恢复。比如,在数据缺失率为60%的情况下,所提方法的RMSE为0.53,而RNN模型为0.68,精度提升达22%。

(2)所提方法除了实现挠度监测数据的恢复,还能够准确恢复索力监测数据,具有良好的适用性。比如,在索力监测数据缺失40%的情况下,所提方法恢复结果的RMSE为2.64,较传统RNN模型下降了25%。

(3)所提方法能充分利用数据的时空相关性恢复单通道数据与多通道数据,取得较好的效果。比如,单通道数据恢复时所提方法的恢复值更加贴近真实值,相比标准RNN模型更具准确性;在多通道数据恢复时,所提方法的拟合度均在0.8以上,证明了利用监测数据的时空相关性恢复缺失数据的可行性。

尽管所提方法在桥梁监测数据多通道联合恢复方面取得了较好的效果,但是在高缺失率情况下仍需进一步提升恢复精度。

参考文献:

- [1] XIN J Z, JIANG Y, ZHOU J T, et al. Bridge deformation prediction based on SHM data using improved VMD and conditional KDE[J]. Engineering Structures, 2022, 261: 114285.
- [2] XIN J Z, ZHOU C Y, JIANG Y, et al. A signal recovery method for bridge monitoring system using TV-FEMD and encoder-decoder aided LSTM[J]. Measurement, 2023, 214: 112797.
- [3] TANG Q Z, XIN J Z, JIANG Y, et al. Fast identification of random loads using the transmissibility of power spectral density and improved adaptive multiplicative regularization[J]. Journal of Sound and Vibration, 2022, 534: 117033.
- [4] 唐启智, 辛景舟, 周建庭, 等. 基于AR-GP模型的结构损伤识别方法[J]. 振动与冲击, 2021, 40(9): 102-109.
TANG Qizhi, XIN Jingzhou, ZHOU Jianting, et al. Structural damage identification method based on AR-GP model[J]. Journal of Vibration and Shock, 2021, 40(9): 102-109.
- [5] 王凌波, 王秋玲, 朱钊, 等. 桥梁健康监测技术研究现状及展望[J]. 中国公路学报, 2021, 34(12): 25-45.
WANG Lingbo, WANG Qiuling, ZHU Zhao, et al. Current status and prospects of research on bridge health monitoring technology[J]. China Journal of Highway and Transport, 2021, 34(12): 25-45.
- [6] 张笑华, 肖兴勇, 方圣恩. 面向桥梁结构健康监测的压缩感知动力响应信号重构[J]. 振动工程学报, 2022, 35(3): 699-706.
ZHANG Xiaohua, XIAO Xingyong, FANG Shengen. Dynamic response reconstruction for bridge structural health monitoring based on compressed sensing[J]. Journal of Vibration Engineering, 2022, 35(3): 699-706.
- [7] JIANG K J, HAN Q, DU X L, et al. Structural dynamic response reconstruction and virtual sensing using a sequence to sequence modeling with attention mechanism[J]. Automation in Construction, 2021, 131: 103895.
- [8] 胡辽林, 王斌, 薛瑞洋. 压缩感知后引入噪声的信号

- 恢复[J]. 光学精密工程, 2014, 22(10): 2840-2846.
- HU Liaolin, WANG Bin, XUE Ruiyang. Signal recovery of noise introduced after compressed sensing[J]. Optics and Precision Engineering, 2014, 22(10): 2840-2846.
- [9] HUANG Y, BECK J L, WU S, et al. Bayesian compressive sensing for approximately sparse signals and application to structural health monitoring signals for data loss recovery[J]. Probabilistic Engineering Mechanics, 2016, 46: 62-79.
- [10] CAO G M, JUNG P, STAŃCZAK S, et al. Data aggregation and recovery in wireless sensor networks using compressed sensing[J]. International Journal of Sensor Networks, 2016, 22(4): 209-219.
- [11] JIANG K J, HAN Q, DU X L. Lost data neural semantic recovery framework for structural health monitoring based on deep learning[J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(9): 1160-1187.
- [12] 马帆, 罗尧治, 万华平, 等. 基于概率主成分分析的结构健康监测数据修复方法研究[J]. 振动与冲击, 2021, 40(21): 135-141.
- MA Zhi, LUO Yaozhi, WAN Huaping, et al. Repair method of structural health monitoring data based on probabilistic principal component analysis[J]. Journal of Vibration and Shock, 2021, 40(21): 135-141.
- [13] 陈帅, 赵明, 郭栋, 等. 基于SVD-KDR算法的工业监测数据插补技术[J]. 机械工程学报, 2021, 57(2): 30-38.
- CHEN Shuai, ZHAO Ming, GUO Dong, et al. Missing data imputation using SVD-KDR algorithm in industrial monitoring data[J]. Journal of Mechanical Engineering, 2021, 57(2): 30-38.
- [14] CHEN Z C, BAO Y Q, LI H, et al. LQD-RKHS-based distribution-to-distribution regression methodology for restoring the probability distributions of missing SHM data[J]. Mechanical Systems and Signal Processing, 2019, 121: 655-674.
- [15] YANG Y C, NAGARAJAIAH S. Harnessing data structure for recovery of randomly missing structural vibration responses time history: sparse representation versus low-rank structure[J]. Mechanical Systems and Signal Processing, 2016, 74: 165-182.
- [16] FAN G, LI J, HAO H. Lost data recovery for structural health monitoring based on convolutional neural networks[J]. Structural Control & Health Monitoring, 2019, 26(10): e2433.
- [17] WANG Z W, LU X F, ZHANG W M, et al. Deep learning-based reconstruction of missing long-term girder-end displacement data for suspension bridge health monitoring[J]. Computers & Structures, 2023, 284: 107070.
- [18] LEI X M, SUN L M, XIA Y. Lost data reconstruction for structural health monitoring using deep convolutional generative adversarial networks[J]. Structural Health Monitoring, 2021, 20(4): 2069-2087.
- [19] 孟宏宇, 杨华臣, 张建中. 无监督残差网络的地震数据重构方法[J]. 石油地球物理勘探, 2022, 57(4): 789-799.
- MENG Hongyu, YANG Huachen, ZHANG Jianzhong. Seismic data reconstruction method based on unsupervised residual network[J]. Oil Geophysical Prospecting, 2022, 57(4): 789-799.
- [20] OH B K, GLISIC B, KIM Y, et al. Convolutional neural network-based data recovery method for structural health monitoring[J]. Structural Health Monitoring, 2020, 19(6): 1821-1838.
- [21] 郭旭, 骆勇鹏, 王林堃, 等. 基于CNN与DCGAN的结构振动监测传感器故障诊断及监测数据恢复[J]. 铁道科学与工程学报, 2022, 19(11): 3383-3395.
- GUO Xu, LUO Yongpeng, WANG Linkun, et al. Fault self-diagnosis of structural vibration monitoring sensor and monitoring data recovery based on CNN and DCGAN[J]. Journal of Railway Science and Engineering, 2022, 19(11): 3383-3395.
- [22] SANTRA A S, LIN J L. Integrating long short-term memory and genetic algorithm for short-term load forecasting[J]. Energies, 2019, 12(11): 2040.
- [23] GUO A P, JIANG A J, LIN J, et al. Data mining algorithms for bridge health monitoring: Kohonen clustering and LSTM prediction approaches[J]. The Journal of Supercomputing, 2020, 76(2): 932-947.
- [24] UDDIN M G, NASH S, DIGANTA M T M, et al. Robust machine learning algorithms for predicting coastal water quality index[J]. Journal of Environmental Management, 2022, 321: 115923.
- [25] LIM C K R, MBA D. Switching Kalman filter for failure prognostic[J]. Mechanical Systems and Signal Processing, 2015, 52-53: 426-435.
- [26] DAI Q, LIU J W, YANG J P. SWSEL: sliding window-based selective ensemble learning for class-imbalance problems[J]. Engineering Applications of Artificial Intelligence, 2023, 121: 105959.

第一作者: 辛景舟(1989—),男,博士,教授。

E-mail: xinjz@cqjtu.edu.cn

通信作者: 张洪(1987—),男,博士,教授。

E-mail: hongzhang@cqjtu.edu.cn