

文章编号:1673-2049(2009)01-0101-06

基于 BP 神经网络的大跨高空连廊 应变监测数据恢复

赵 昕¹, 贾 京², 郑毅敏¹

(1. 同济大学 建筑设计研究院, 上海 200092; 2. 同济大学 土木工程学院, 上海 200092)

摘要:为了解决大跨高空连廊吊装阶段性态监测中应变监测数据存在缺失的问题,利用 BP 神经网络进行数据恢复。首先基于相关性分析,选择与数据缺失监测点应变值相关性最强的 5 个监测点作为参考点;然后利用未缺失时间段内待恢复监测点和参考点的应变数据进行建模和检验,一半数据用来建立 BP 神经网络模型,一半数据用来进行模型的检验;最后利用建立的模型对缺失的数据进行恢复,得到了完整的应变监测数据。利用得到的恢复数据与参考点数据在缺失段内的相关系数对数据恢复的效果进行了评价。结果表明:该方法可有效地恢复缺失的应变监测数据。

关键词:性态监测;相关性分析;BP 神经网络;数据恢复;数据缺失;参考点;高空连廊

中图分类号: TU317 **文献标志码:** A

Strain Monitoring Data Restoring of Large-span Steel Skybridge Based on BP Neural Network

ZHAO Xin¹, JIA Jing², ZHENG Yi-min¹

(1. Architectural Design & Research Institute, Tongji University, Shanghai 200092, China;

2. School of Civil Engineering, Tongji University, Shanghai 200092, China)

Abstract: In order to solve the problem of strain monitoring data absence in performance monitoring of large-span steel skybridge, the data restoring was carried out by using BP neural networks. Firstly, based on correlation analysis, five reference points which were most correlative with the data missing points were obtained, then the data of both reference points and data missing point in the stage were simulated and verified. All data were separated into two subsets: one for training the BP neural network model, and the other for validating the model. The missing data were restored by using the trained BP neural networks. Finally, the integrated strain monitoring data were gained, and the correlation coefficients of the data missing point and each reference point were calculated; comparing the correlation coefficients, the performance of data restoring was evaluated. The results show that this method can restore the missing strain monitoring data effectively.

Key words: performance monitoring; correlation analysis; BP neural network; data restoring; data missing; reference point; steel skybridge

收稿日期:2009-01-05

基金项目:上海青年科技启明星计划项目(07QB14044)

作者简介:赵 昕(1975-),男,江苏应县人,高级工程师,工学博士,E-mail:kenkien@gmail.com。

0 引言

20 世纪 80 年代开始,结构的性态监测受到越来越多的关注^[1-8]。结构的性态监测始于桥梁结构,近几年对建筑结构的性态监测逐渐增多,如深圳市民中心和深圳地王大厦等复杂超高的结构都进行了性态监测^[9]。结构的性态监测分为 2 种:一种是在结构使用期间对结构进行长期的性态监测,了解结构正常使用阶段的性态;另一种是在结构施工的重要阶段或是遭遇恶劣的外部荷载(如台风和地震)对结构进行有针对性的短期性态监测,以了解结构在特殊危险时期的真实工作状态。应变反映的是结构的局部特性,是结构局部性态的一个重要指标,对结构的性态评估起着关键的作用。第 1 种监测是在结构的正常使用阶段进行监测的,受到的影响较小,数据相对稳定和准确;但第 2 种监测经常会受到施工因素和设备因素的影响,造成某些监测数据的缺失或者误差较大。应变监测是静力监测,采样频率较低,对于异常数据和缺失的数据,一般是采用线性回归法、平均法(取其前后数据的平均值),或是用前后的某个数据来代替,这些方法恢复的数据误差较大、实用性较差^[10]。

本文中发展了一种基于 BP 神经网络的方法对异常和缺失的监测数据进行恢复。该方法由 2 个部分组成,即基于相关性分析的训练样本选择和以 BP 神经网络为基础的数据恢复。笔者应用该方法对大跨高空钢结构连廊的性态监测数据进行了数据恢复分析,结果表明,该方法可有效地恢复缺失的应变监测数据。

1 大跨高空连廊吊装应变监测

浙江杭州市民中心 R1 连廊为 2 层高的 大跨 钢 桁 架 结 构 (图 1),跨 度 52 m,高 度 7.2 m,质量 660 t。连廊吊装采用地面整体组装成型、整体吊装就位的方法。为了解高空钢结构连廊在提升和就位过程中结构的真实性态,对连廊的吊装进行了 72 h 全程无线监测。在整个监测过程中每隔 10 min 自动采集 1 次数据,在起吊的关键时间段每隔 2 min 采集 1 次数据。数据采集采用 24 个应变传感器,传感器布置主要依据有限元软件的分析结果,并考虑以下 3 个因素:①施工阶段监测的传感器要作为日后正常使用阶段的长期健康监测的传感器,综合考虑施工监测和长期监测的因素;②利用有限元分析软件得到每根杆件的应变,选出局部区域中应变大的杆件,

起到控制作用;③利用结构的对称性,在对称位置只布置一侧。传感器布置如图 2 所示。






图 1 连廊结构


Fig. 1 Structure of Skybridge



(a) 底层传感器



(b) 二层传感器



(c) 顶层传感器

图 2 传感器布置

Fig. 2 Arrangements of Sensors

应变 ϵ 按式(1)进行计算,即

$$\epsilon = 0.000\ 951\ 06 \times 0.939\ 7 f^2 \quad (1)$$

式中: f 为频率。

由于施工和设备本身的原因,设备置于起吊的连廊上,个别传感器某一段时间的应变数据无法得到,5 号监测点的传感器应变值共缺失 381 条数据,缺失率为 73%。由于数据缺失率如此之大,所以无法实现用简单的线性插值恢复数据。

2 基于 BP 神经网络的数据恢复原理

在连廊的整体起吊过程中,结构构件的应变受温度、自重和起吊不平衡的影响,因此在时域上应变监测数据带有非线性特征,监测数据不可能用某个函数表达,根据现有的研究成果,可以用神经网络来

描述应变和其他影响因素之间的非线性关系。应变监测数据恢复思想就是在对应变监测点相关性分析的基础上,利用 BP 神经网络强大的模型训练能力和数据预测能力来保证恢复数据的精度。取时域上待恢复监测点附近的有效数据作为训练样本,以待恢复的监测点为输出,和它相关性强的监测点为输入,进行 BP 神经网络样本训练,最后,将待恢复时间段上关联监测点数据作为已训练完毕的 BP 神经网络模型输入,对应的输出作为恢复的数据。

2.1 相关性分析

从监测系统所有监测点的整体角度出发,所有监测点之间都是具有相关性的,但是却存在强弱之分,相关性的强弱受到很多因素的影响^[11]。从统计学角度出发,反映监测点应变数据相关性强弱的指标定义为相关系数。设有 n 个不同的应变传感器,取其中任意 2 个传感器采集的采样数据值分别为 X_i 和 X_j ,且 $1 < i, j < n$,在采样时间 T 内,每个传感器有 M 次采样数据值, X_i 记为 $x_i(1), \dots, x_i(k), \dots, x_i(M)$, X_j 记为 $x_j(1), \dots, x_j(k), \dots, x_j(M)$,则定义二者在采样时间 T 内的相关系数为 $G(X_i, X_j)$,即

$$G(X_i, X_j) = \frac{\sum_{k=1}^M [x_i(k) - E_{x_i}][x_j(k) - E_{x_j}]}{\left\{ \sum_{k=1}^M [x_i(k) - E_{x_i}]^2 \sum_{k=1}^M [x_j(k) - E_{x_j}]^2 \right\}^{1/2}} \quad (2)$$

式中: $x_i(k)$ 、 $x_j(k)$ 分别为不同传感器的某一时刻的监测值; $-1 \leq G(X_i, X_j) \leq 1$; E_{x_i} 、 E_{x_j} 为不同传感器应变的期望值。

根据以上相关系数的定义,分子表示的是不同传感器应变在时间段内的协方差,其值越大表明二者在采样时间 T 内越相似,而分母是对该值的单位化,所以相关系数 $G(X_i, X_j)$ 的定义可以反映出不同传感器应变相关联的程度:数值越大且为正,说明不同传感器的应变正相关,即变化趋势越趋于一致;数值越小且为负,说明不同传感器的应变负相关,即变化趋势越趋于相反。

2.2 BP 神经网络数据预测

BP 神经网络是一种无反馈的前向网络,网络中的神经元分层排列,分为输入层、隐含层和输出层,层与层之间靠权值和阈值进行连接,带有很强的数学基础,并且可以精确设计神经网络的结构^[12-13]。BP 神经网络拓扑结构如图 3 所示。

神经网络输入层输入训练样本,经过隐含层学习训练网络,调整和修正权值和阈值,输入层和隐含




图 3 BP 神经网络拓扑结构

Fig. 3 Topology Structure of BP Neural Network

层之间的不同层通过传递函数来实现层与层之间的前向学习,传递函数选择 S 型传递函数,即^[14]

$$f(x) = \frac{1}{1 + e^{-x}} \quad x \in (0, 1) \quad (3)$$

误差 R_{MSE} 计算公式为

$$R_{MSE} = \sqrt{\frac{\sum_i (t_i - O_i)^2}{N}} \quad (4)$$

式中: t_i 、 O_i 分别为期望输出和网络的计算输出; N 为样本容量。

网络的计算输出公式为

$$O_i = f\left(\sum_{i=1}^n \omega_{ij} x_i + b_j\right) \quad (5)$$

式中: ω_{ij} 为权重; b_j 为阈值。

利用 BP 神经网络将预测数据分为 2 个阶段:第 1 阶段是利用已有的数据进行模型训练,主要是学习权值和阈值,并与目标值进行比较,按照最小平方准则得到误差值,直到满足设定的误差;第 2 阶段是数据预测阶段,通过已有的输入层,利用训练好的神经网络模型对数据进行预测。

3 监测数据恢复

3.1 不同监测点应变值相关性分析

通过对连廊进行 72 h 的监测,得到了 24 个监测点的应变数据。由于 5 号监测点应变数据存在缺失,在对 5 号监测点的应变数据进行数据恢复之前,先要分析 5 号监测点应变值和其他监测点应变值之间的相关性。按照式(2)中定义的相关性系数,5 号监测点缺失应变与同时刻其他监测点应变的相关系数统计如表 1 所示。

从表 1 中可以看出,5 号监测点应变与 4 号监测点应变的相关系数最大,达到 0.989。图 4 为 5 号和 4 号监测点未缺失时间段应变。

表 1 5 号监测点与其他监测点的应变相关系数

Tab. 1 Strain Correlation Coefficients Between Monitoring Point 5 and Other Monitoring Points

监测点 编号	相关 系数	监测点 编号	相关 系数	监测点 编号	相关 系数	监测点 编号	相关 系数
1	0.678	8	0.755	14	0.638	20	0.710
3	0.953	9	0.976	15	0.863	21	0.637
4	0.989	10	0.787	16	-0.830	22	0.635
6	0.917	12	0.294	17	0.825	23	0.297
7	0.953	13	0.726	18	0.864	24	0.857




图 4 5 号监测点和 4 号监测点未缺失段应变

Fig. 4 Strains of Monitoring Point 5, 4 in Unabridged Data Stage

3.2 基于 BP 神经网络的数据预测

通过相关性分析,对于 5 号监测点应变的预测各选择 5 个监测点应变作为神经网络模型的训练样本,为预测 5 号监测点应变的监测点,选择 3 号、4 号、6 号、7 号、9 号 5 个监测点的应变作为神经网络训练的输入样本。对于已有的正确的数据,将数据分为 2 个部分,一半数据用来训练模型,一半数据用来验证训练模型的正确性,然后用验证过的正确的模型对缺失的数据进行数据恢复。

神经网络的组成中,隐含层的层数和每层中的神经元是决定神经网络效能的关键参数,对于非线性的不连续函数,采用双层隐含层为宜^[15]。最常用的方法就是通过经验公式确定隐含层的神经元,再通过试算的方法逐渐增加神经元个数,直到满足训练精度的要求。经验公式主要有 $N=\sqrt{m+n}+c$ 和 $N=\sqrt{mn}$,其中, m 为输入层神经元个数, n 为输出

层神经元个数, c 为 1~10 的常数,一般通过试算得到。通常选择第一隐含层神经元稍多,第二隐含层神经元稍少,这样有利于改善多层前馈网络的性能。神经元个数太少,从样本获取信息的能力差,不足以概括体现样本规律;神经元个数太多,会把样本中非规律性如噪声也牢记,形成“过度吻合”,降低泛化能力。

根据式(6)并对 c 进行试算分析,选择隐含层层数为 2 的 5-20-10-1 结构的 BP 神经网络,第一隐含层选择线性传递函数,第二隐含层选择 S 型对数传递函数,用带动量自适应学习速率的梯度下降法进行训练,学习函数选择梯度下降动量学习函数。应变是衡量结构局部性态的参数,应变差能更直接有效地体现结构构件应力的变化,对结构性态监测的意义大于应变本身。对于承受静力荷载的结构,结构构件应变的变化比较平缓,因此结构构件的应变差变化很小,以应变差作为学习数据来控制神经网络的学习效果,神经网络对输入样本和神经网络结构参数就变得非常敏感。如果训练的数据过少,这样训练得到的神经网络的预测能力有限并且误差较大,无法体现真实的样本规律,造成欠训练;若训练的数据量过大,模型得到的样本信息中包含大量的噪声信号,泛化能力差,不具有普遍性,造成训练过度。通过计算,误差均方根为 0.032。用前一半数据训练的模型预测后一半验证数据,并且与实测应变差进行对比,见图 5。




图 5 预测应变差与实测应变差比较

Fig. 5 Comparisons of Forecasting Strain Variations and Measured Strain Variations

通过已有数据训练神经网络模型并且验证该模型,用得到的模型来预测应变数据,得到缺失部分的应变差曲线如图 6 所示。用训练的模型对缺失部分的应变数据进行预测,得到缺失部分的应变曲线如图 7 所示。与未缺失时间段的应变数据分析结果类似,未缺失时间段 5 号监测点和 4 号监测点的应变数据的相关系数为 0.989,并且图 4 中 2 个监测点的应变曲线变化规律相同;5 号监测点对应的缺失




图 6 缺失段预测应变差

Fig. 6 Forecasting Strain Variations in Data Missing Stage




图 7 5 号监测点和 4 号监测点缺失段应变

Fig. 7 Strains of Monitoring Point 5,4 in Data Missing Stage

时间段的预测应变变化曲线与相同时间段内 4 号监测点应变变化曲线如图 7 所示,此时间段内 2 个监测点的应变的相关系数为 0.992。图 8 为数据缺失时间段内 5 号监测点恢复的应变差和 4 号监测点实测应变差的比较,在应变差这个层面也存在极强的相关性。

从应变差和应变 2 个方面的比较可知:由于应变差对于数据和网络结构十分敏感,所以预测的结果误差相对较大,应变差误差最大值对应的应力为 0.4 MPa,对结构性态监测的影响较小;用训练得到的模型预测缺失时间段的应变,得到的应变与其他监测点同时间段应变的相关系数与未缺失时间段对应的系数十分接近。

表 2 为缺失段和未缺失段应变相关系数的对比。由表 2 可知,通过神经网络模型预测很好地保持了不同监测点之间的相关关系。




图 8 5 号监测点和 4 号监测点缺失段应变差

Fig. 8 Strain Variations of Monitoring Point 5,4 in Data Missing Stage

表 2 缺失段和未缺失段应变相关系数的对比

Tab. 2 Comparisons of Strain Correlation Coefficients Between Missing Data Stage and Unabridged Data Stage

监测点编号		3	4	6	7	9
相关系数	未缺失段	0.953	0.989	0.917	0.953	0.976
	缺失段	0.976	0.992	0.946	0.949	0.978

4 结 语

以相关性分析为基础,利用神经网络的方法对监测数据进行恢复,在以往的研究中大多是局限于试验阶段,很少在实际监测中运用神经网络的方法进行数据恢复。本文中通过对大跨高空连廊的应变监测数据进行恢复,证明在实际的监测数据恢复中,可以通过已有的数据建立神经网络模型,对未知数据进行预测;虽然对于数据的预测已满足工程要求,但是通过建立神经网络模型可知,对于同一监测数据,从不同角度建立网络模型的方法和难度是不一样的,因此要合理地选择和应用神经网络来进行数据的预测;在结构性态监测领域,神经网络可以建立起荷载和响应以及不同响应之间的复杂非线性关系。

参考文献:

References:

[1] 张刚刚,王春生,徐 岳. 基于径向基函数神经网络的斜拉桥损伤识别[J]. 长安大学学报:自然科学版,

- 2006, 26(1): 49-53.
- ZHANG Gang-gang, WANG Chun-sheng, XU Yue. Damage Detection of Cable-stayed Bridge Based on RBF Neural Networks[J]. Journal of Chang'an University: Natural Science Edition, 2006, 26(1): 49-53.
- [2] 谭冬莲, 肖汝诚. 基于改进 Gauss-Newton 法的在役桥梁结构参数识别[J]. 长安大学学报: 自然科学版, 2007, 27(4): 57-60.
- TAN Dong-lian, XIAO Ru-cheng. Parameter Identification of Existing Bridge Structure Based on Improved Gauss-Newton Algorithm[J]. Journal of Chang'an University: Natural Science Edition, 2007, 27(4): 57-60.
- [3] 谭冬莲, 肖汝诚. 桥梁监测系统中梁桥静力应变传感器的优化配置[J]. 长安大学学报: 自然科学版, 2007, 27(5): 66-69.
- TAN Dong-lian, XIAO Ru-cheng. Optimal Placement of Static Strain Sensors of Beam Bridge Structure in Bridge Monitoring System[J]. Journal of Chang'an University: Natural Science Edition, 2007, 27(5): 66-69.
- [4] 郭琦, 贺拴海, 白云. 基于神经网络的简支梁桥预应力衰减评估模型[J]. 长安大学学报: 自然科学版, 2007, 27(6): 53-57.
- GUO Qi, HE Shuan-hai, BAI Yun. Evaluation Model on Prestress Attenuation of Simple Span Bridges Based on Neural Networks[J]. Journal of Chang'an University: Natural Science Edition, 2007, 27(6): 53-57.
- [5] 叶爱文, 谢慧才. 混凝土中钢筋直径雷达检测的神经网络方法[J]. 建筑科学与工程学报, 2008, 25(4): 105-110.
- YE Ai-wen, XIE Hui-cai. Neural Network Method of Diameter Detection of Rebar in Concrete by Using GPR[J]. Journal of Architecture and Civil Engineering, 2008, 25(4): 105-110.
- [6] 张杨, 李国强. 通用频率指纹库在固接梁损伤定位中的应用[J]. 建筑科学与工程学报, 2005, 22(4): 40-44.
- ZHANG Yang, LI Guo-qiang. Application of Universal Bank of Natural Frequency Indexes in Damage Location of Beams with Fixed Ends[J]. Journal of Architecture and Civil Engineering, 2005, 22(4): 40-44.
- [7] 常军. 基于曲率模态的钢筋混凝土梁多点损伤位置识别[J]. 建筑科学与工程学报, 2006, 23(4): 24-27.
- CHANG Jun. Curvature Model Based Many Damage Locations Identification of Reinforced Concrete Beam [J]. Journal of Architecture and Civil Engineering, 2006, 23(4): 24-27.
- [8] 叶见曙, 张剑, 赵新铭. 基于 Novozhilov-柔度理论的连续弯箱梁桥位移参数 Kalman 滤波识别[J]. 中国公路学报, 2007, 20(5): 65-70.
- YE Jian-shu, ZHANG Jian, ZHAO Xin-ming. Kalman Filtering Identification for Displacement Parameters of Continuous Curved Box Girder Bridge Based on Novozhilov-flexibility Theory[J]. China Journal of Highway and Transport, 2007, 20(5): 65-70.
- [9] 瞿伟廉, 滕军, 项海帆, 等. 风力作用下深圳市民中心屋顶网架结构的智能健康监测[J]. 建筑结构学报, 2006, 27(1): 1-8.
- QU Wei-lian, TENG Jun, XIANG Hai-fan, et al. Intelligent Health Monitoring for Roof Space Truss Structure of the Shenzhen Citizen Center Under Wind Load[J]. Journal of Building Structures, 2006, 27(1): 1-8.
- [10] 胡顺仁, 陈伟民, 章鹏, 等. 基于 RBF 神经网络的桥梁挠度数据恢复研究[J]. 仪器仪表学报, 2006, 27(12): 1605-1608.
- HU Shun-ren, CHEN Wei-min, ZHANG Peng, et al. Research of Bridge Deflection Restoring Based on RBF Neural Networks[J]. Chinese Journal of Scientific Instrument, 2006, 27(12): 1605-1608.
- [11] FU J Y, LIANG S G, LI Q S. Prediction of Wind-induced Pressures on a Large Gymnasium Roof Using Artificial Neural Networks[J]. Computers and Structures, 2007, 85(3/4): 179-192.
- [12] AGRAWAL R, IMIELINSKI T, SWAMI A N. Mining Association Rules Between Sets of Items in Large Databases[C]//BUNEMAN P, JAJODIA S. Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data. New York: ACM Press, 1993: 207-216.
- [13] 田景文, 高美娟. 人工神经网络算法研究及应用[M]. 北京: 北京理工大学出版社, 2006.
- TIAN Jing-wen, GAO Mei-juan. Algorithms and Applications of Artificial Neural Networks[M]. Beijing: Beijing Institute of Technology Press, 2006.
- [14] DEMUTH H, BEALE M. Neural Network Toolbox for Use with Matlab[M]. Natick: The Mathworks Inc, 1994.
- [15] 闻新. MATLAB 神经网络仿真与应用[M]. 北京: 科学出版社, 2003.
- WEN Xin. Simulation and Application of MATLAB Neural Networks[M]. Beijing: Science Press, 2003.