

引用本文:游颖,王建,刘学刚,等.改进BP神经网络的钢结构应力缺失数据重构[J].建筑科学与工程学报,2022,39(4):166-173.
YOU Ying, WANG Jian, LIU Xue-gang, et al. Reconstruction of Missing Stress Data for Steel Structure Based on Improved BP Neural Network[J]. Journal of Architecture and Civil Engineering, 2022, 39(4): 166-173.

DOI:10.19815/j.jace.2021.11130

改进BP神经网络的钢结构应力缺失数据重构

游颖¹,王建¹,刘学刚²,彭宁¹,周敏峰²,邓志扬¹

(1. 湖北工业大学机械工程学院,湖北武汉430064; 2. 武汉中科科创工程检测有限公司,湖北武汉430077)

摘要:钢结构健康监测过程中的应力数据缺失会干扰监测各环节的运行状态,无法保障施工阶段的安全,因此解决数据缺失问题至关重要。钢结构在施工阶段应力应变监测中,由于受到外界诸多复杂因素的影响,导致监测数据不准确、缺失以及局部应力数据的重构值与真实值偏差较大等问题。采用改进BP神经网络分别对300组和30组钢结构应力应变监测数据进行重构,并对改进BP神经网络的数据重构方法进行适用性分析。结果表明:相比线性回归法,改进BP神经网络法进行离散型缺失数据的重构平均误差降低0.7%,特别是对于局部缺失数据,改进BP神经网络法的数据重构精度更高,平均局部误差降低2.2%;为达到较好的重构精度,使用改进BP神经网络对缺失数据重构时,数据的缺失率不宜超过20%;改进BP神经网络法可为钢结构应力缺失数据重构以及结构健康监测提供技术支持,具有较好的实用性。

关键词:钢结构;数据重构;改进BP神经网络;结构健康监测;粒子群算法;附加动量法

中图分类号:TU391

文献标志码:A

文章编号:1673-2049(2022)04-0166-08

Reconstruction of Missing Stress Data for Steel Structure Based on Improved BP Neural Network

YOU Ying¹, WANG Jian¹, LIU Xue-gang², PENG Ning¹, ZHOU Min-feng², DENG Zhi-yang¹

(1. School of Mechanical Engineering, Hubei University of Technology, Wuhan 430064, Hubei, China;

2. Wuhan Zhongke Kechuang Engineering Inspection Co., Ltd., Wuhan 430077, Hubei, China)

Abstract: The lack of stress data in the process of steel structure health monitoring will interfere with the operation status of each link of monitoring, and cannot guarantee the safety of the construction stage. Therefore, it is very important to solve the problem of data missing. In the stress and strain monitoring of the steel structure during the construction stage, due to the influence of many complex external factors, the monitoring data is inaccurate and missing, and large deviation is between the structural value and the real value. The improved BP neural network was used to reconstruct the monitoring data of the stress and strain of the steel structure of the 300 groups and 30 groups respectively. The applicability of the data reconstruction method of the improved BP neural network was analyzed. The results show that compared with the linear regression method, the improved BP neural network method reduces the average error of discrete

收稿日期:2021-11-16

基金项目:国家自然科学基金项目(52105550);湖北省自然科学基金项目(2013CFB025)

作者简介:游颖(1969-),女,湖北赤壁人,副教授,工学博士,E-mail:774085476@qq.com。

missing data reconstruction by 0.7%. Especially for locally missing data, the reconstruction accuracy of the neural network method is higher, and the average local error is reduced by 2.2%. In order to achieve better reconstruction accuracy, when using the improved BP neural network to reconstruct missing data, the missing rate of data should not exceed 20%. The improved BP neural network method can provide technical support for the reconstruction of missing stress data of steel structures and structural health monitoring, which has good practicability.

Key words: steel structure; data reconstruction; improved BP neural network; structural health monitoring; particle swarm algorithm; additional momentum method

0 引 言

大跨度空间钢结构以其强度高、质量轻、抗震性好等优点,越来越多地应用于地标建筑、体育场馆、火车站等重要的大型建筑中^[1]。由于大跨度钢结构规模庞大,钢结构构件交错,设计者往往重点考虑结构在成型后的性能状态,缺少对构件安装施工阶段的受力状态监测,从而引发结构破坏。利用先进的传感技术对空间钢结构施工阶段和服役整个生命周期进行健康实时监测,有利于降低钢结构预防性维护和管理成本^[2-3]。

结构健康监测中由于一些不确定因素造成部分数据缺失,使整个监测过程无法获得准确的、可靠的测量数据。为了应对这样的情况,中国许多学者对于数据重构已展开相关研究和讨论。罗尧治等^[4]利用自研的无线传感系统对杭州铁路的钢结构施工阶段实施应力监测和研究分析。赵昕等^[5]利用 BP 神经网络对大跨高空连廊吊装监测中应变缺失数据进行数据恢复,并使用缺失数据段的相关系数对数据恢复效果进行评价,证明方法的有效性。杨渊等^[6]针对立体桁架结构健康监测中结构振动信号缺失的情况,利用卷积自编码器模型进行缺失数据重构,该模型能在较高缺失率下保证重构数据的准确性。孟欣^[7]采用基于 MCMC(Markov Chain Monte Carlo)算法的贝叶斯数据重构方法,对智能化能源监测系统中传感器缺失数据进行重构,取得较好的效果。

BP 神经网络(Back Propagation Neural Network)以其非线性映射能力、较高的稳定性和精度,已经在相关领域得到广泛应用,常常被用来进行非线性函数的逼近与拟合和数据重构^[8]。本文基于改进 BP 神经网络,研究通过多个测点对目标监测点的钢结构应力缺失数据进行重构,以及重构方法在不同数据类型和不同缺失率下的适应性,解决监测数据丢失的问题,提高监测信息的可靠性。

1 改进 BP 神经网络

1.1 BP 神经网络

BP 神经网络是一种无反馈前向网络,由输入层、隐藏层和输出层 3 个部分组成的分层网络模型,如图 1 所示^[9],其中, x_i 为输入层第 i 节点输入值, y_l 为输出层第 l 节点输出值, W_{ij} 为连接第 i 节点和第 j 节点的连接权重, W_{jl} 为连接第 j 节点和第 l 节点的连接权重, i 为输入层神经元个数, j 为隐藏层神经元个数, l 为输出层神经元个数。各层之间可以通过网络连接权值和阈值来确定接受信息的程度^[9-10]。




图 1 BP 神经网络的结构模型

Fig. 1 Structural Model of BP Neural Network

1.2 粒子群优化算法和附加动量因子法

粒子群算法在优化网络的初始条件方面效果显著^[11-13],因此可以采用粒子群算法对 BP 神经网络学习初始条件中的权值和阈值进行优化,从而避免 BP 神经网络陷入局部极小化^[14]。

在每次迭代中,粒子的位置和速度分别用公式(1)、(2)更新,即

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id}^k - x_{id}^k) + c_2 r_2 (p_{gd}^k - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

式中: ω 为惯性权重; v_{id} 为粒子的速度; x_{id} 为粒子的位置; p_{id} 为粒子到当前迭代为止自身发现的最优位置; p_{gd} 为所有粒子迭代后的最优位置; c_1 、 c_2 为算法

的学习因子; r_1 和 r_2 为 $[0,1]$ 范围内的随机数; k 为迭代次数; v 为粒子位置的变化率。

附加动量因子法是在权值和学习率 η 阈值的变化上,增加一个正比于上一次权值的值,来产生新的权值和阈值的变化,通过附加动量因子法能使网络跳出局部最小值,从而加快网络的收敛^[15-16]。新的权值和阈值分别用式(3)、(4)表示。

$$\Delta w_{ij}(k+1)=(1-D_1)\eta\delta_i u_j + D_1\Delta w_{ij}(k)$$

(3)

$$\Delta \theta_j(k+1)=(1-D_1)\eta\delta_i + D_1\Delta \theta_j(k)$$

(4)

式中: Δw_{ij} 为权值变化量; D_1 为动量因子; δ_i 为误差项; u_j 为输入变量; $\Delta \theta_j$ 为阈值变化量。

1.3 改进 BP 神经网络模型流程

利用粒子群算法确定 BP 神经网络初始权值和阈值,通过附加动量法更新权值和阈值,克服 BP 神经网络算法易局部极小化、收敛速度慢等缺点。改进 BP 神经网络模型流程如图 2 所示。

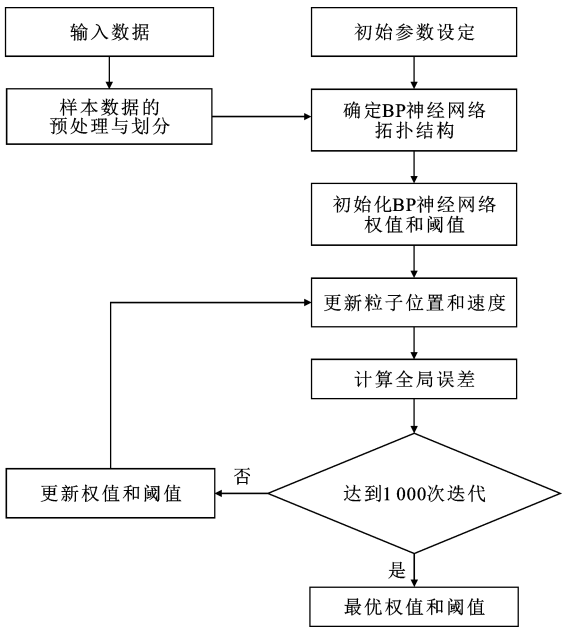


图 2 改进 BP 神经网络模型流程图

Fig. 2 Flow Chart of Improved BP Neural Network Model

2 基于改进 BP 神经网络的钢结构应力缺失数据重构方法

本文节选了 2018 年 2 月 1 日~2018 年 6 月 30 日时间段内的网安中心钢结构中某顶部弦杆目标监测点 A 的 300 组应力数据。选择屋盖网壳结构拱形截面上与该顶部弦杆监测点 A 相邻的 3 个相关测点。网安中心结构示意图如图 3 所示,3 个相关测点的位置关系如图 4 所示,监测点 A 的应力数据






图 3 网安中心结构示意图


Fig. 3 Schematic Diagram of Network Security Center Structure



(a) 监测点 A 位置分布



(b) 相关测点位置分布



(c) 测点 1、测点 2、测点 3 位置分布

图 4 监测点 A 及相关测点的位置分布

Fig. 4 Location Distribution of Monitoring Point A and Related Measuring Points

如图 5 所示。

图 4 中虚线内的 50 组监测数据假定成缺失数据,用作网络的测试数据,来检验数据重构的精度,剩余的 250 组数据用于训练,构建改进 BP 神经网络重构模型。

测点 1 与目标监测点 A 位于同一杆件,测点 2 位于与目标测点 A 相连的杆件上,测点 3 位于目标




图 5 监测点 A 在 2018 年 2 月 1 日~2018 年 6 月 30 日的应力变化曲线

Fig. 5 Stress Change Curve of Monitoring Point A from February 1, 2018 to June 30, 2018

测点 A 较远区域的杆件上,各相邻监测点与顶部弦架监测点 A 在同一时间段内所监测的应力数据之间的相关系数如表 1 所示。

表 1 各监测点与顶部弦架监测点 A 应力数据的关系
Table 1 Relationship Between Stress Data of Each Monitoring Point and Monitoring Point A at Top String Frame

相邻监测点	与测点 A 位置关系	相关系数
测点 1	同一杆件	0.79
测点 2	相连杆件	0.68
测点 3	较远杆件	0.45

2.1 钢结构应力数据重构方法步骤

改进 BP 神经网络重构应力缺失数据的过程为:

(1)样本划分。将相关测点同时段的 300 组数据分为 250 组训练数据和 50 组检验数据。

(2)构建模型。模型的输入层采用测点 1 的训练数据,输出层采用目标测点 A 的训练数据,通过模型训练构建 3 层 BP 神经网络模型。

(3)输出重构值。将每个测点假定的 50 组检验数据输入到构建好的神经网络模型中,即可得到测点 A 中 50 组缺失数据的重构值。

(4)分析数据。采用应力数据重构值与真实值之间的最大绝对误差 A [式(5)]、均方差 M [式(6)]和相关系数 R [式(7)]作为重构精度的指标,其中 A 用于考察局部重构值的误差, A 和 M 的值越小、相关系数 R 越趋近 1,表示重构精度越高。

$$A = \max(|\hat{y}_i - y_i|) \tag{5}$$


$$M = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{n}} \tag{6}$$

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \tag{7}$$


式中: \hat{y}_i 为第 i 个重构的应力数据(实际输出); y_i 为第 i 个真实的应力数据(期望输出); $\bar{\hat{y}}$ 为重构应力数据的均值; \bar{y} 真实应力数据的均值。

2.2 基于多测点相关性的应力数据重构


首先使用单测点的应力数据作为样本,使用改进 BP 神经网络对目标测点 A 的缺失数据重构。之后使用测点 1 和 2 的应力数据作为样本,使用改进 BP 神经网络对目标测点 A 缺失数据重构。基于单测点 1、2、3 得到的目标测点 A 缺失数据重构曲线如图 6 所示,基于多测点 1 和 2 得到的目标测点 A 缺失数据重构曲线如图 7 所示,重构精度如表 2 所示。



(a) 基于监测点1的缺失数据重构值与真实值变化曲线



(b) 基于监测点2的缺失数据重构值与真实值变化曲线



(c) 基于监测点3的缺失数据重构值与真实值变化曲线

图 6 基于单测点相关性的缺失数据重构曲线
Fig. 6 Reconstruction Curves of Missing Data Based on Single-point Correlation

由表 2 可知,测点 1 和 2 重构的应力值与真实应力值的偏差较小,测点 3 重构的应力值与真实应力值的偏差较大,这主要是因为相距较远的测点间没有明显的相关性。

相对于采用单测点 1、2 而言,采用 2 个测点数




图 7 基于多测点相关性的缺失数据重建曲线

Fig. 7 Reconstruction Curves of Missing Data Based on Multi-point Correlation

表 2 不同测点下缺失数据的重构精度

Table 2 Reconstruction Accuracy of Missing Data at Different Measurement Points

监测点	单测点重构精度			多测点重构精度
	1	2	3	1, 2
M/MPa	1.85	2.11	2.56	1.98
R	0.81	0.80	0.55	0.81
A/MPa	3.2	3.7	3.8	3.6

据进行重构时,对缺失数据的重构精度并没有得到提高。因为在同一杆件或者相邻杆件之间测点所提供的相关性信息存在高度重复,也表明测点与相同杆件或邻近杆件间测点之间的相关关系已经足够强。因此,当某监测点数据缺失时,优先选择单个高相关性相邻监测点对缺失的数据进行重构,重构过程简单且重构精度很高。

在实际情况下,不一定都有高相关性的相邻测点,或是相邻测点也同样存在监测数据缺失。这种情况下,只能取一些相关性稍弱的相邻测点,或者距离更远的测点当成相关点,来重构缺失数据,不同的位置与参与模型输入的测点个数对应的重构精度如图 8、9 所示。




图 8 相邻区域相关测点数量的数据重构精度

Fig. 8 Data Reconstruction Accuracy of Number of Related Measuring Points in Adjacent Area

由图 8、9 可知,随着测点数量的增多,缺失数据的重构精度越来越高。此外,相邻区域测点中,当参与重构的相关测点数量超过 2 个以后,重构精度提




图 9 较远区域相关测点数量的数据重构精度

Fig. 9 Data Reconstruction Accuracy of Number of Related Measuring Points in Far Area

升不再明显,此时 M 和 R 分别约为 2.30 MPa 和 0.70。对于较远区域测点,当参与重构的相关测点数量达到 3 个以后,重构精度基本不变,此时 M 和 R 分别约为 2.70 MPa 和 0.60,说明并不是相关测点越多,缺失数据的重构精度越高。当测点距离越远,想要达到一定重构精度所需要的相关测点数量也越多,同时也可以看出,与缺失测点距离越近,重构的精度也越高。相对于采用同一杆件相邻测点或者相邻杆件测点对缺失数据重构精度而言,均相差较大。当某监测点数据发生缺失时,优先选择距离最近的、相关性高的测点对缺失数据进行重构。

3 改进 BP 神经网络法钢结构缺失应力数据重构的适用性分析

在研究不同缺失类型对重构效果的影响时,采用中顶部弦杆监测点在 2018 年 3 月 1 日~3 月 15 日半个月采集的应力数据。该测点与高相关性相邻测点的应力数据如表 3 所示。监测点 1 为有缺失数据的待重构监测点,监测点 2 为与其高相关性的相邻监测点。

3.1 不同缺失类型对重构效果的影响

从 2018 年 3 月 1 日~3 月 15 日的监测数据中选取序号为 1、4、7、10、12、14、17、19 离散的 8 个数据假定为离散型缺失数据;选取序号为 23~30 连续的 8 个应力数据假定为连续型缺失数据。

在结构监测领域中,线性回归模型常应用于各类变形监测数据处理。接下来选取 2018 年 2 月~6 月中除去缺失数据外的所有应力数据对上述缺失的应力数据分别采用改进 BP 神经网络法和线性回归法进行重构。缺失数据的重构值与真实值的变化曲线如图 10 所示,重构误差如表 4 所示。

由图 10 和表 4 可知:对离散型缺失数据重构时,线性回归的重构相对误差最大为 8.4%,最小为

表 3 待重构监测点与相邻监测点应力

Table 3 Stresses of Monitoring Points to Be Reconstructed and Adjacent Monitoring Points

序号	监测时间	应力 /MPa	
		监测点 1	监测点 2
1	2018/3/1 01:00	17.4	14.4
2	2018/3/1 13:00	18.5	14.3
3	2018/3/2 01:00	17.5	13.9
4	2018/3/2 13:00	19.2	14.2
5	2018/3/3 01:00	18.8	13.6
6	2018/3/3 13:00	26.9	14.1
7	2018/3/4 01:00	19.1	15.2
8	2018/3/4 13:00	26.8	13.1
9	2018/3/5 01:00	19.1	16.8
10	2018/3/5 13:00	20.2	13.7
11	2018/3/6 01:00	21.7	17.7
12	2018/3/6 13:00	22.8	17.5
13	2018/3/7 01:00	19.7	14.1
14	2018/3/7 13:00	25.5	18.3
15	2018/3/8 01:00	21.4	14.3
16	2018/3/8 13:00	20.7	13.9
17	2018/3/9 01:00	20.2	13.9
18	2018/3/9 13:00	26.0	17.2
19	2018/3/10 01:00	19.9	13.5
20	2018/3/10 13:00	27.0	19.7
21	2018/3/11 01:00	20.6	13.2
22	2018/3/11 13:00	29.2	18.3
23	2018/3/12 01:00	19.7	13.7
24	2018/3/12 13:00	26.4	19.2
25	2018/3/13 01:00	19.4	13.8
26	2018/3/13 13:00	24.9	19.4
27	2018/3/14 01:00	18.4	12.9
28	2018/3/14 13:00	25.6	18.8
29	2018/3/15 01:00	19.6	14.2
30	2018/3/15 13:00	26.4	18.6

0.4%，平均相对误差为 4.7%；改进 BP 神经网络的重构相对误差最大为 5.8%，最小为 2.6%，平均相对误差为 4%。对连续型缺失数据重构时，线性回归的重构误差最大为 8.7%，最小为 2.5%，平均相对误差为 6.8%；改进 BP 神经网络的重构相对误差最大为 5.5%，最小为 1.2%，平均相对误差为 4.6%。通过分析可以看出，采用改进 BP 神经网络对离散型和连续型的数据缺失重构效果均更好。

3.2 不同缺失率对重构效果的影响

改进 BP 神经网络重构模型的构建需要将数据划分成训练数据和测试数据，训练数据的样本占总体数据比例不能低于 70%，且测试样本数据越多，

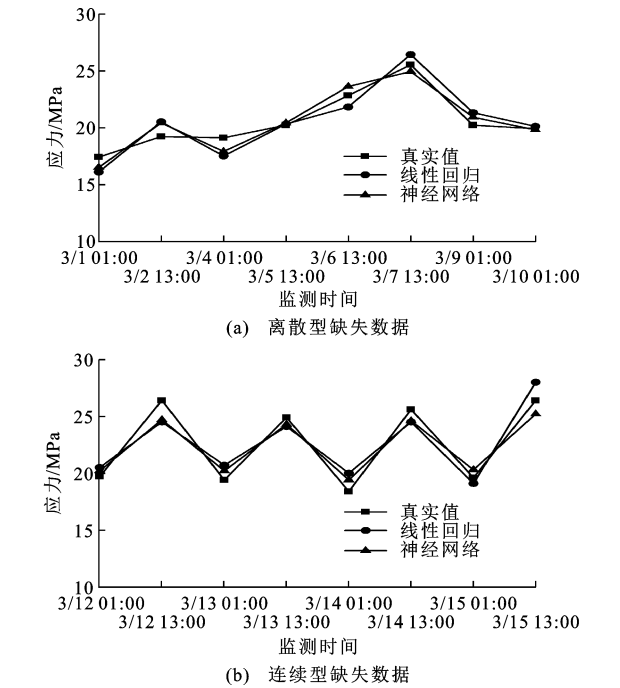


图 10 不同缺失类型的重构值与真实值变化曲线

Fig. 10 Change Curves of Reconstructed Values and True Values for Different Missing Types

缺失率就越大，缺失率过高会导致重构效果较差，因此需要分析神经网络重构法在不同缺失率下的重构效果。

选取钢结构中顶部弦杆某监测点在一段时间内连续采集的 200 个数据，按照 5%~30% 六个不同缺失比例随机节选数据，随机节选的数据假定为缺失值。节选数据的缺失类型包括离散型与连续型，采用改进 BP 神经网络进行重构。不同缺失率下重构的平均相对误差与误差大于平均误差值的比例如图 11 所示，部分数据真实值与重构值变化曲线如图 12 所示。

由图 11、12 可知，采用改进 BP 神经网络对缺失数据进行重构时，数据缺失率的增长会导致重构的效果变差，符合神经网络训练样本占比越少、模型精度越低的特点。当数据的缺失率低于 10% 时，重构值与真实值平均相对误差约为 3.5%，重构精度很高；当缺失率为 20% 时，平均相对误差约为 5%，重构精度较好；当缺失率超过 25% 时，平均相对误差接近 10%，真实值与重构值的误差较大，重构精度较差。为达到较好的重构精度，使用改进 BP 神经网络对缺失数据重构时，数据的缺失率不宜超过 20%。

4 结 语

利用粒子群算法全局寻优的特点，优化BP神

表 4 缺失数据的重构值误差

Table 4 Reconstruction Value Error of Missing Data

序号	监测时间	真实应力值/MPa	线性回归		改进 BP 神经网络	
			重构值/MPa	相对误差/%	重构值/MPa	相对误差/%
1	2018/3/1 01:00	17.4	16.1	7.2	16.4	5.8
4	2018/3/2 13:00	19.2	20.5	6.7	19.7	2.6
7	2018/3/4 01:00	19.1	17.5	8.4	19.9	4.1
10	2018/3/5 13:00	20.2	20.3	0.4	21.2	4.8
12	2018/3/6 13:00	22.8	21.8	4.6	23.9	4.9
14	2018/3/7 13:00	25.5	26.4	3.5	24.8	2.7
17	2018/3/9 01:00	20.2	21.3	5.2	20.9	3.5
19	2018/3/10 01:00	19.9	20.1	1.2	20.6	3.6
23	2018/3/12 01:00	19.7	20.5	4.3	20.4	3.5
24	2018/3/12 13:00	26.4	24.5	7.1	25.0	5.2
25	2018/3/13 01:00	19.4	20.7	6.5	20.4	4.9
26	2018/3/13 13:00	24.9	24.1	3.3	26.3	5.5
27	2018/3/14 01:00	18.4	20.0	8.7	19.4	5.2
28	2018/3/14 13:00	25.6	24.5	4.2	24.8	3.2
29	2018/3/15 01:00	19.6	19.1	2.5	19.4	1.2
30	2018/3/15 13:00	26.4	28.0	6.1	27.9	5.5




图 11 不同缺失率下的拟合优度

Fig. 11 Fit Goodness Under Different Missing Rates




图 12 缺失数据的真实值曲线与不同缺失率下的
重构数据点

Fig. 12 True Value Curve of Missing Data and
Reconstructed Data Points Under Different
Missing Rates

经网络的初始权值和阈值,采用改进 BP 神经网络对多测点的缺失应力数据进行重构。对于某些监测

点缺失数据,可优先选择距离最近的、相关性高的测点对缺失数据进行重构。通过对离散型和连续型的缺失数据重构方法进行适用性分析,可以发现改进 BP 神经网络对离散型和连续型的数据缺失重构效果均更好。分析了不同缺失率对数据重构精度的影响,为了达到较好的重构精度,数据的缺失率不宜超过 20%。

参考文献:

References:

[1] 罗尧治,梅宇佳,沈雁彬,等. 国家体育场钢结构温度与应力实测及分析[J]. 建筑结构学报,2013,34(11): 24-32.
LUO Yao-zhi,MEI Yu-jia,SHEN Yan-bin,et al. Field Measurement of Temperature and Stress on Steel Structure of the National Stadium and Analysis of Temperature Action[J]. Journal of Building Structures,2013,34(11):24-32.

[2] LUO Y Z,YANG P C,SHEN Y B,et al. Development of a Dynamic Sensing System for Civil Revolving Structures and Its Field Tests in a Large Revolving Auditorium[J]. Smart Structures and Systems,2014, 13(6):993-1014.

[3] 鲜勇,杨子成,郭玮林,等. 基于 BP 神经网络的惯导初始对准误差辨识方法[J]. 飞行力学,2021, 39(2):77-82,94.
XIAN Yong,YANG Zi-cheng,GUO Wei-lin,et al. In-

- initial Alignment Error Identification Method of SINS Based on BP Neural Network[J]. Flight Dynamics, 2021,39(2):77-82,94.
- [4] 罗尧治,刘 钝,沈雁彬,等. 杭州铁路东站站房钢结构施工监测[J]. 空间结构,2013,19(3):3-8,26.
LUO Yao-zhi, LIU Dun, SHEN Yan-bin, et al. Steel Structure Construction Monitoring of Hangzhou East Railway Station Building[J]. Spatial Structure, 2013, 19(3):3-8,26.
- [5] 赵 昕,贾 京,郑毅敏. 基于BP神经网络的大跨高空连廊应变监测数据恢复[J]. 建筑科学与工程学报, 2009,26(1):101-106.
ZHAO Xin, JIA Jing, ZHENG Yi-min. Strain Monitoring Data Restoring of Large-span Steel Skybridge Based on BP Neural Network[J]. Journal of Architecture and Civil Engineering, 2009,26(1):101-106.
- [6] 杨 渊,练继建,周观根,等. 基于深度学习的随机缺失数据重构和结构损伤识别[J]. 工业建筑, 2021, 51(增):401-405.
YANG Yuan, LIAN Ji-jian, ZHOU Guan-gen, et al. Random Missing Data Reconstruction and Structural Damage Identification Based on Deep Learning[J]. Industrial Construction, 2021,51(S):401-405.
- [7] 孟 欣. 建筑能源监测系统中缺失数据的重构与修补方法研究[D]. 大连:大连理工大学,2021.
MENG Xin. Research on Reconstruction and Repair of Missing Data in Building Energy Monitoring System [D]. Dalian: Dalian University of Technology, 2021.
- [8] 金 浏,赵 瑞,杜修力. 混凝土抗压强度尺寸效应的神经网络预测模型[J]. 北京工业大学学报, 2021, 47(3):260-268.
JIN Liu, ZHAO Rui, DU Xiu-li. Neural Network Prediction Model of Concrete Compressive Strength Size Effect[J]. Journal of Beijing University of Technology, 2021,47(3):260-268.
- [9] MANO RAJA PAUL M, KANNAN R, LEEBAN MOSES M, et al. Fault Identification in a Grid Connected Solar PV System Using Back Propagation Neural Network[J]. IOP Conference Series: Materials Science and Engineering, 2021,1084(1):012109.
- [10] ROSA SUSILA J K, AFIT M, LAKSONO P. Implementation of Back Propagation Artificial Neural Network for Heart Disease Abnormality Diagnosis[J]. Journal of Physics:Conference Series, 2021,1764(1):012165.
- [11] PENG H, WU H, WANG J W. Research on the Prediction of the Water Demand of Construction Engineering Based on the BP Neural Network[J]. Advances in Civil Engineering, 2020,2020:8868817.
- [12] NANGLIA P. Lung Cancer Classification Using Feed Forward Back Propagation Neural Network for CT Images[J]. International Journal of Medical Engineering and Informatics, 2021,13(2):1.
- [13] 欧青立,张 磊,邓 鹏,等. 粒子群优化BP神经网络PID控制注塑机液压系统[J]. 应用科技, 2018, 45(4):50-55.
OU Qing-li, ZHANG Lei, DENG Peng, et al. Particle Swarm Optimization BP Neural Network PID Control Hydraulic System of Injection Molding Machine[J]. Applied Science and Technology, 2018,45(4):50-55.
- [14] 黄 璇,郭立红,李 姜,等. 改进粒子群优化BP神经网络的目标威胁估计[J]. 吉林大学学报(工学版), 2017,47(3):996-1002.
HUANG Xuan, GUO Li-hong, LI Jiang, et al. Target Threat Assessment Based on BP Neural Network Optimized by Modified Particle Swarm Optimization[J]. Journal of Jilin University (Engineering and Technology Edition), 2017,47(3):996-1002.
- [15] 王雪松,许爱德,赵中林,等. 粒子群优化递归神经网络的SRM磁链观测器[J]. 电气工程学报, 2017, 12(10):1-8.
WANG Xue-song, XU Ai-de, ZHAO Zhong-lin, et al. Stator Flux Observer of SRM Based on Particle Swarm Optimized Recurrent Neural Network [J]. Journal of Electrical Engineering, 2017,12(10):1-8.
- [16] KENNEDY J, EBERHART R. Particle Swarm Optimization[C]//IEEE. Proceedings of ICNN'95 — International Conference on Neural Networks. Perth: IEEE, 1995:1942-1948.