

基于 RBF 神经网络的钢框架梁端节点损伤识别

薛 强^{1,2}, 郝际平¹, 郑 粤²

(1. 西安建筑科技大学土木工程学院, 陕西 西安 710055; 2. 西安建筑科技大学建筑设计研究院, 陕西 西安 710055)

摘 要: 为有效识别钢框架梁端节点损伤程度及半刚性节点刚度参数, 提出采用钢梁位移模态和曲率模态指标作为神经网络的输入参数, 基于 RBF 神经网络对刚框架梁端节点损伤程度进行参数识别研究. 结果证明, 位移模态识别损伤位置的准确度高于曲率模态, 对损伤程度的识别曲率模态优于位移模态. 其中位移模态损伤识别误差小于 10%, 曲率模态识别误差小于 5%, 得出基于 RBF 神经网络可以较好的识别节点损伤及半刚性刚度参数.

关键词: RBF 神经网络; 钢框架; 节点损伤识别

中图分类号: TU375

文献标志码: A

文章编号: 1006-7930(2011)02-0192-06

1 引 言

结构损伤识别是土木工程中一个重要的研究课题, 近年来采用人工神经网络 ANN(Artificial Neural Network)方法对结构进行损伤识别取得了长足的进步. 国内外学者针对钢框架结构损伤识别进行了许多探索性的研究, 多数采用 BP 神经网络以结构整体振动参数为指标进行损伤识别研究. 在实际工程中, 整体结构刚度的影响因素很多, 识别精度不宜控制. 单根钢梁的模态参数较结构整体更易实测, 本文采用 RBF 神经网络以单根钢梁为研究对象进行识别, 分别采用位移模态和曲率模态指标作为神经网络的输入参数对钢梁梁端进行损伤程度识别^[1-3].

同时与 BP 网络相比较, RBF 神经网络是一种局部逼近网路, 问题有唯一解, 不存在 BP 网络中所遇的局部极小值问题, 肯定能获得全局最小点, 另外, 与 BP 网收敛速度慢的缺点相反, RBF 神经网络学习速度很快, 比 BP 网络快 103 ~ 104 倍, 适于在线实时控制. 此外由于 RBF 神经网络采用高斯核函数, 除使得网络训练速度加快, 还能更好的处理学习数据以外的测试实例, 因而泛化能力得到进一步加强.

2 网络结构及识别方法

2.1 RBF 神经网络结构

径向基函数 RBF 神经网络(简称径向基网络)是由 J. Moody 和 C. Darken 于 20 世纪 80 年代末提出的一种神经网络结构, 它是具有单隐层的三层前馈网络. 目前已经证明, 径向基网络能够模拟逼近任意连续函数. 径向基网络的神经元模型结构如图 1 所示, 由图可见, 径向基网络的传递函数 $radbas$ 是以权值向量和阈值向量之间的距离 $\|dist\|$ 通过输入向量和加权矩阵的行向量的乘积得到的, 其中径向基网络传递函数的原型函数如式 1 所示.

$$radbas(n) = e^{-n^2} \quad (1)$$

RBF 神经网络结构如图 2 所示, 图 2 虽然与传统单隐层 BP 网络相似, 但其构造与算法本质上是不同的. 从输入空间到隐层空间的变换是线性的, 隐层单元的作用相当于对输入模式进行一次变换, 将降低维数的输入数据变换到高维空间内, 以利于分类识别, 隐单元的这种变换作用也可以看作是对输入数据进行特征提取.

收稿日期: 2010-03-10 修改稿日期: 2011-03-26

基金项目: 国家自然科学基金资助项目(50878181)

作者简介: 薛 强 (1982-), 男, 陕西延安人, 博士研究生, 工程师, 主要从事钢结构稳定设计及损伤识别方法研究.

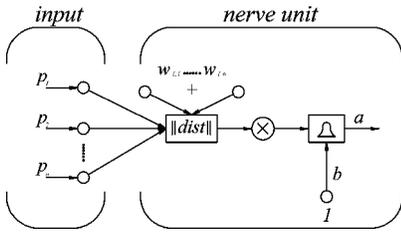


图 1 径向基神经单元模型结构

Fig. 1 Radial basis function neural cell model structure

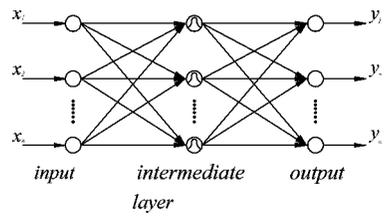


图 2 RBF 神经网络结构

Fig. 2 RBF neural network

2.2 位移模态与曲率模态

位移模态法也称位移模态或振型模态差法, 该方法以损伤前后振型的差值作为损伤定位参数, 当发生破损时, 受到影响的自由度差值在损伤域内就会出现比较大的值, 可以利用振型差值识别损伤的位置. 损伤前后位移模态差为:

$$E = \Phi_0 - \Phi \tag{2}$$

实际应用中, 将激励点设置在各阶振型的峰值点上, 分别利用每一阶模态频率激励, 将每一阶的最大可能振幅激励出来, 再将每一阶振幅向量归一化合并为矩阵 Φ_0 , 同理得出损伤情况下的 Φ , 求出振型模态差 E .

曲率模态法也称曲率模态差法, 这种方法是梁在损伤前后曲率模态差为损伤定位参数. 如结构出现破损, 破损处的刚度会降低, 则曲率模态差便会增大, 振型曲率的变化随着曲率模态差增大而增大, 因此, 可以根据振型曲率的变化确定损伤的位置. 曲率 $1/\rho$ 由梁弯曲变形近似方程可得:

$$1/\rho = \frac{d^2 y}{d^2 x} \tag{3}$$

式中: ρ 为梁的曲率半径; x 为梁长度方向坐标; y 为梁弯曲挠度;

对式(3)差分计算可得曲率模态:

$$c_{i,j} = 1/\rho_j = \frac{z^{(i-1),j} - 2z_{i,j} + z^{(i+1),j}}{l_{i-1} l_i} \tag{4}$$

式中: $c_{i,j}$ 、 $z_{i,j}$ 分别为梁的曲率值和位移模态位移值; i 为梁节点号; j 为模态阶次; l_{i-1} 、 l_i 分别为第 $i-1$ 和 i 个梁单元长度.

需要注意的是, 求曲率模态依赖于位移模态, 对测量值有很高的精度要求, 除模态测量的精度问题外, 不足之处还有求曲率模态时需要非常邻近的测点, 以便利用中心差分法求取曲率模态, 这样就要求有足够密的测点, 否则将增大曲率模态振型的误差.

2.3 损伤指标

在钢框架结构的计算分析中, 梁柱连接节点常被看作刚性连接, 事实上, 节点在荷载作用下如果有损伤, 节点的工作特性表现并非为完全刚性, 而是介于刚性连接和铰接之间的状态^[3-4]. 节点的工作特性是节点的转动刚度, 即节点转动单位角所能抵抗的弯矩值, 刚性连接时的转动刚度为无限大, 而铰接时转动刚度为零, 如图 3 所示.

图中 θ_1^* 为梁左端转角, 包括梁自身弯曲引起的转角及弹簧转动引起的转角, θ_1 为梁自身弯曲引起的左端转角, 由图可知, 弹簧转角 $\Phi = \theta_1^* - \theta_1$. 定义节点抗转动刚度为^[5]:

$$k_{r1} = M_1 / \Phi_1; k_{r2} = M_2 / \Phi_2 \tag{5}$$

式中: M_1 、 M_2 分别为杆件两端所承受的弯矩. 分别定义杆件两端的节点损伤系数为^[6]:

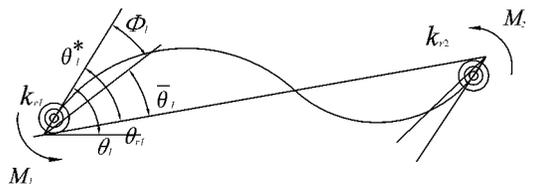


图 3 端部半刚性连接的杆件单元模型

Fig. 3 Column-beam element with elastic spring

表 1 NET1 网络部分训练样本输入: Y 代表样本序号
Tab. 1 Part of the NET1 training samples; Y as sample number

Node number	Y1	Y2	Y3	Node number	Y1	Y2	Y3
2	0.286 843	-0.286 866	-0.286 465	28	0.288 280	-0.288 260	-0.287 817
23	0.287 382	-0.287 388	-0.286 970	29	0.288 100	-0.288 086	-0.287 649
24	0.287 801	-0.287 795	-0.287 364	30	0.287 801	-0.287 795	-0.287 369
25	0.288 100	-0.288 086	-0.287 646	31	0.287 382	-0.287 388	-0.286 977
26	0.288 280	-0.288 260	-0.287 815	4	0.286 843	-0.286 862	-0.286 468
27	0.288 340	-0.288 319	-0.287 872				

表 2 NET2 网络训练样本输入: Y 代表样本序号
Tab. 2 Part of the NET2 training samples; Y as sample number

Node number	Y1	Y2	Y3	Node number	Y1	Y2	Y3
23	0.965 79	0.951 43	0.934 94	28	0.995 02	0.979 83	0.962 42
24	0.993 44	0.978 30	0.960 93	29	0.994 87	0.979 69	0.962 29
25	0.994 16	0.979 00	0.961 60	30	0.994 50	0.979 35	0.961 97
26	0.994 67	0.979 49	0.962 07	31	0.969 34	0.967 63	0.956 80
27	0.994 95	0.979 76	0.962 35				

当网络输入变量确定后, 需要进行归一化处理, 这里将其变换在[-1, 1] 的范围内, 因为结果归一化处理的数据对于网络的学习更加容易训练和学习, 因为原始数据幅值大小不一, 有时相差比较悬殊, 如果直接投入使用, 测量大的波动就垄断了神经网络的学习过程, 使其不能反映小的测量变化. 归一化后的数据是通过计算测量值与相应情况下基准的偏差值, 再除以最大偏差值的绝对值得到输入变量的. RBF 神经网络收敛速度快, 迭代次数少, 训练时间短, 仅用几秒时间就训练成功.

将单节点的理想输出值与仿真输出值的差值百分比作为识别是否准确的指标, 如式 8, 为便于比较, 将理想输出与仿真输出误差制成曲线, 见图 5、6.

$$\gamma = \frac{|t_f - t_l|}{t_l} \tag{8}$$

式中: t_f 、 t_l 分别代表仿真输出和理想输出; γ 为识别误差

2、4 节点总体识别效果和为 9 式, 将其绘制成曲线如图 7 和 8, 式中各符号含义同 8 式.

$$\gamma = \frac{||t_{f2} + t_{f4}| - |t_{l2} + t_{l4}||}{|t_{l2} + t_{l4}|} \tag{9}$$

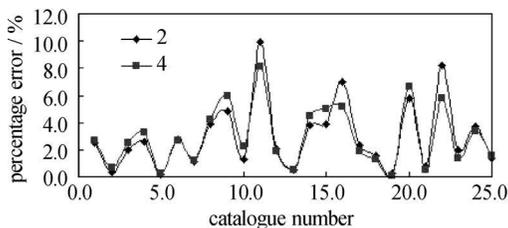


图 5 NET1 网络训练误差分布曲线
Fig. 5 NET1 network training error distribution curve

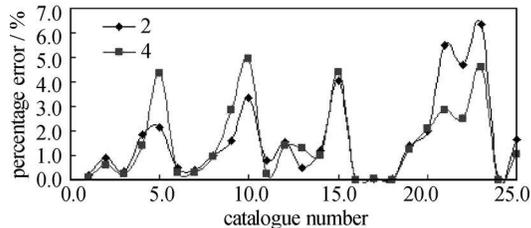


图 6 NET2 网络训练误差分布曲线
Fig. 6 NET2 network training error distribution curve

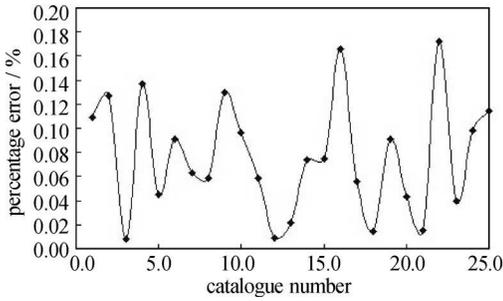


图 7 NET1 网络训练分布曲线
(2 节点、4 节点误差和)

Fig. 7 NET1 network training error distribution curve(2,4 sum error)

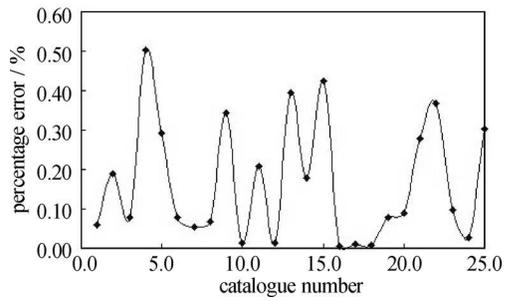


图 8 NET2 网络训练分布曲线
(2 节点、4 节点误差和)

Fig. 8 NET2 network training error distribution curve(2,4 sum error)

3.3 神经网络样本测试

测试样本选取损伤系数为 1.0、0.85、0.64、0.96、0.72, 具体组合见表 4, 测试时, 将各节点位移和曲率模式输入, 看计算得出的节点损伤系数是否与表中理想输出一致, 输出值见表 5 与 6.

表 4 NET1、NET2 网络测试样本理想输出; C 为样本序号

Tab. 4 Part of the NET1、NET2 training samples; C as sample number

Node number	C1	C2	C3	C4	C5
2	1.0	0.8	0.8	0.6	0.7
4	0.75	0.64	0.96	0.64	0.85

表 5 NET1 网络测试样本仿真输出; C 为样本序号

Tab. 5 Part of the NET1 training samples; C as sample number

Node number	C1	C2	C3	C4	C5
2	0.993 55	0.822 43	0.785 66	0.592 6	0.725 52
4	0.753 39	0.618 24	0.919 44	0.645 56	0.842 74

表 6 NET2 网络测试样本仿真输出; C 为样本序号

Tab. 6 Part of the NET1 training samples; C as sample number

Node number	C1	C2	C3	C4	C5
2	1.011 60	0.778 20	0.766 48	0.619 52	0.743 57
4	0.744 63	0.659 15	0.955 94	0.625 41	0.826 99

3.4 不同识别指标对比

识别的效果含有两个方面, 节点位置的识别和节点损伤系数数值大小的识别. 就研究例题来看, 位置的识是指该系数是 2 节点的还是 4 节点, 就节点识别精确度是指识别出的数值与理想输出的误差百分比. 在样本群中有些样本位置的识别精度都有所下降, 因为当节点损伤系数相近时, 梁左端和右端位移响应值相差不大, 导致此时识别误差较大, 网络对位移相差值没有足够的敏感度. 位移模式 2 和 4 节点识别的误差和很小, 其原因是虽然梁左端和梁右端相对位移差值很小, 整个梁的位移和在不同的样本值之间有较大的差异, 所以位移识别误差和相对误差很小, 均在 0.2% 以下.

就单个节点识别而言, 由表可知, 曲率模式较位移模式更为敏感, 而识别的误差和位移模式优于曲率模式. 因为曲率模式反映的是梁曲率模式的变化, 该指标相对于位移指标更能反映梁端部损伤系数的变化, 例如若梁左右端损伤系数分别为 0.8、0.8 和 0.9、0.9 时位移模式响应并不明显, 但是曲率模式却有较大的变化. 相反, 整个梁的位移和值在固结系数分别为 0.9、0.9 时明显大于 0.8、0.8 时, 而曲率模式和值此时变化却较小, 这也就解释了误差和值的误差百分比——位移模式(0.2%)小于曲率模式(0.5%).

测试样本中也反映了以上规律. 就工程应用来说, 更重视对单个节点参数的识别, 曲率模式比位移模式更为敏感, 优先选用曲率模式. 由此可见曲率模式和位移模式反映了结构的两个不同的力学特性, 位移模式反映整体变化, 曲率模式反映局部变化. 因此, 根据不同的识别指标, 采用合理的识别输入量是关键之一. 识别损伤系数用曲率模式较好, 识别周期用位移模式较好.

4 结 语

引入损伤系数定义节点的损伤程度, 通过例题分析证明得出, 采用 RBF 神经网络对钢框架的节点识别是可行的. 位移模态识别误差一般在 5% 左右, 曲率模态识别误差在 3% 左右, 总体识别效果较好, 识别损伤系数, 曲率模态识别效果优于位移模态. 采用神经网络识别损伤程度缺点也是明显的, 需要准备的数据量较大, 所识别的输入量试验较难测量.

参考文献 References

- [1] 姜绍飞. 基于神经网络的结构优化与损伤检测[M]. 北京: 科学出版社, 2002.
JIANG Shao-fei. Structural Optimization and Damage Detection Based on Neural Network[M]. Beijing: Science Press, 2002.
- [2] 陈 伟, 瞿伟廉, 姜正国. 人工神经网络技术在结构损伤诊断中的应用[J]. 世界地震工程, 2002, 18(1): 146-149.
CHEN Wei, QU Wei-lian, JIANG Zheng-gou. The application of artificial neural networks to structural damage detection. [J]. World earthquake engineering, 2002, 18(1): 146-149.
- [3] 陈绍蕃. 钢结构设计原理[M]. 3 版. 北京: 科学出版社, 2005: 180-214.
CHEN Shao-fan. Principles of steel structure design[M]. 3rd ed. Beijing: Science Press, 2005: 180-214.
- [4] 陈惠发, 周绥平, 译. 钢框架稳定设计[M]. 上海: 世界图书出版公司, 1999: 161-221
CHEN Hui-fa, ZHOU Sui-ping. Translated Stability Design of Steel Frame[M]. Shanghai: World Book Publishing Company, 1999.
- [5] 沈祖炎. 钢结构学[M]. 北京: 中国建筑工业出版社, 2006: 55-80.
SHEN Zu-yan. Research on steel structure[M]. Beijing: China Architecture and Building Press, 2006: 55-80.
- [6] 瞿伟廉, 陈 伟, 李秋胜. 基于神经网络技术的复杂框架结构节点损伤的两步诊断法[J]. 土木工程学报, 2003, 36(5): 37-42.
QU Wei-lian, CHEN Wei, LI Qiu-sheng. Two-step approach for joints damage diagnosis of framed structures by artificial neural networks[J]. China Civil Engineering Journal, 2003, 36(5): 37-45.
- [7] 周建中, 赵鸿铁, 薛建阳. 粘弹性阻尼结构的递归神经网络优化[J]. 西安建筑科技大学学报: 自然科学版, 2005, 37(1): 35-39.
ZHOU Jian-zhong, ZHAO Hong-tie, XUE Jian-yang. Optimum of the viscoelastic structure based on recurrent neural network[J]. J. Xi'an Univ. of Arch. & Tech.; Natural Science Edition, 2005, 37(1): 35-39
- [8] 陈 骥. 钢结构稳定与理论设计[M]. 2 版. 北京: 科学出版社, 2003: 188-201.
CHEN Ji. Stability of steel structures theory and design[M]. 2nd ed. Beijing: Science Press, 2003: 180-214.

Research on steel frame parameters identification based on RBF neural networks

XUE Qiang^{1,2}, HAO Ji-ping¹, ZHENG Yue²

(1. School of Civil Eng., Xi'an Univ. of Arch. & Tech., Xi'an 710055, China;
2. Institute of Architecture., Xi'an Univ. of Arch. & Tech., Xi'an 710055, China)

Abstract: To effectively identify the post-earthquake level of steel frame joint damage and semi-rigid joint stiffness parameters, and mode shapes curvature mode are used as RBF neural networks import vector to identify steel portal frame construction. Curvature mode is more sensitive than mode shapes for structural parameters identification. Modal identification results show that the displacement damage location accuracy is higher than curvature mode and the damage degree identification curvature mode is superior to displacement mode. Modal displacement damage identification error is less than 10% and the curvature modal identification error is less than 5%. Based on RBF neural networks joint damage and semi-rigid parameters can be better identified.

Key words: RBF neural networks; steel frame; frame detection