

基于改进BP神经网络的微裂纹漏磁定量识别

邱忠超^{1,2}, 张卫民¹, 张瑞蕾³, 马春红³

(1. 北京理工大学机械与车辆学院, 北京 100081; 2. 机械科学研究总院先进制造技术研究中心, 北京 100083;

3. 河北环境工程有限公司, 河北 承德 067000)

摘 要: 漏磁检测是铁磁材料常用的无损检测方法之一, 定量识别是指通过检测到的漏磁信号识别裂纹的尺寸. 采用主成分分析和优化神经网络相结合的建模方法, 建立了微裂纹宽度与深度的预测模型. 主成分分析去除了数据相关性, 减小了输入样本维数, 显著简化了网络结构; 遗传算法优化的BP神经网络(GA-BP神经网络)可以有效地防止搜索过程中陷入局部最优解. 通过基于磁偶极子模型的理论计算与人工刻槽微裂纹漏磁检测实验两种途径验证了该算法在微裂纹定量识别中的应用, 为裂纹发展阶段的早期定量识别技术奠定了一定的基础.

关 键 词: 漏磁检测; 主成分分析; GA-BP神经网络; 微裂纹; 定量识别

中图分类号: TG 115.28

文献标志码: A

文章编号: 1005-3026(2016)12-1759-05

Quantitative Identification of Microcracks Through Magnetic Flux Leakage Based on Improved BP Neural Network

QIU Zhong-chao^{1,2}, ZHANG Wei-min¹, ZHANG Rui-lei³, MA Chun-hong³

(1. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China; 2. Advanced Manufacture Technology Center, China Academy of Machinery Science & Technology, Beijing 100083, China; 3. Hebei Aerospace Environmental Engineering Co., Ltd, Chengde 067000, China. Corresponding author: ZHANG Wei-min, E-mail: zhangwm@bit.edu.cn)

Abstract: Magnetic flux leakage detection is one of NDT methods for ferromagnetic materials. Quantitative identification is to identify the crack size through obtaining magnetic flux leakage signals. By combining principal component analysis (PCA) and neural network, a model was established to predict width and depth of the micro crack. The principal component analysis removed the data correlation and reduced the dimension of the input samples, so it can significantly simplify the network structure. BP neural network optimized by genetic algorithm (GA-BP neural network) can prevent the search process from running into the local optimal solution. Based on the theoretical calculation of magnetic dipole model and experiment on the artificial cracks, the algorithm applied in the quantitative recognition of microcracks was verified, which may lay the foundation for the early quantitative recognition technique of crack development stage.

Key words: magnetic flux leakage detection; principal component analysis (PCA); GA-BP neural network; microcrack; quantitative identification

钢铁是工业中最常用的材料, 广泛应用于工业生产的各个领域. 由于疲劳、冲击等因素, 钢铁在生产和使用中会产生裂纹等缺陷, 使机械零部件的安全可靠性降低, 甚至导致恶性事故发生. 漏磁检测是一种常用的磁性无损检测方法, 由于其

灵敏度高、不需添加耦合剂及易实现自动化等优点, 受到人们的欢迎^[1]. 但是, 随着磁传感器的发展和漏磁检测技术的推广, 目前不仅要求对缺陷定性检测, 而且要求对缺陷进行轮廓重构, 即定量识别. 从理论上讲, 用有限个离散方位的观测数据

来重构缺陷轮廓属于不适定性问题,不具备唯一解,重构难度较大.因此,缺陷定量识别目前已成为漏磁检测技术的研究热点和工程应用瓶颈^[2].

目前针对漏磁检测定量识别的研究工作主要集中在大尺寸裂纹与仿真分析. Carvalhoa 等采用 BP 神经网络实现了管道焊接缺陷类型的识别^[3]; Hwang 等提出了用径向基神经网络与径向小波基函数神经网络对人工凹坑缺陷形状重构^[4]; Ramuhalli 等提出了一种基于神经网络和模拟退火梯度下降相结合的技术来求解反演问题^[5];王平等通过有限元仿真与实验方法实现了基于脉冲漏磁检测技术的钢轨裂纹的定量识别^[6];张勇等提出了一种基于磁偶极子模型的矩形裂纹的快速重构方法^[7].

针对目前所识别的对象为较大尺寸裂纹(1~10 mm)与自然裂纹相差较大的问题,并结合现有的裂纹检测标准(0.12 mm),本文所研究的微裂纹是指宽度、深度都小于 0.5 mm 的槽型裂纹.微裂纹的定量识别对铁磁性构件的早期损伤检测与寿命评估具有重要意义,但由于微细裂纹尺寸较小,检测信号的信噪比较差,使定量识别的难度显著增加.

本文采用主成分分析和优化神经网络相结合的建模方法,建立了微裂纹宽度与深度的预测模型.主成分分析去除了数据相关性,减小了输入样本维数,显著简化了网络结构;遗传算法优化的 BP 神经网络(GA-BP 神经网络)可以有效地防止搜索过程中陷入局部最优解.通过基于磁偶极子模型的理论计算与人工刻槽微裂纹漏磁检测实验两种途径对该算法在微裂纹定量识别中的应用进行验证,为裂纹发展阶段的早期定量识别技术奠定一定的基础.

1 主成分分析方法与特征量的提取

1.1 主成分分析

主成分分析(principal component analysis, PCA)在方差分析的基础上,将数据投影到方差最大的正交主成分上,使得多维数据的互相关最小,进而实现多维数据的降维^[8].设 m 维数据 $\boldsymbol{X} = \{\boldsymbol{x}_1, \boldsymbol{x}_2, \cdots, \boldsymbol{x}_m\}$ ($\boldsymbol{x}_i = \{x_i^1, x_i^2, \cdots, x_i^j, \cdots, x_i^n\}$),令 $\bar{x}_i = x_i - E(x_i)$, $E(x_i)$ 为 x_i 的数学期望;计算数据 \boldsymbol{X} 的协方差并进行奇异值分解得

$$\boldsymbol{C} = E(\boldsymbol{X}\boldsymbol{X}^T) = \boldsymbol{U}_{m \times m} \boldsymbol{\Lambda}_{m \times m} \boldsymbol{U}_{m \times m}^T. \quad (1)$$

式中: $\boldsymbol{\Lambda}$ 为协方差矩阵特征值的对角矩阵, $\boldsymbol{\Lambda} = \text{diag}(\lambda_1, \lambda_2, \cdots, \lambda_m)$, 且 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_m$; \boldsymbol{U} 为特

征向量组成的正交矩阵.

\boldsymbol{X} 在主成分方向上的投影即为 \boldsymbol{X} 按贡献率大小排序的主成分 $\boldsymbol{P} = \{p_1, p_2, \cdots, p_i, \cdots, p_m\}$.

$$\boldsymbol{P} = E(\boldsymbol{X}\boldsymbol{X}^T) = \boldsymbol{U}_{m \times m}^T \boldsymbol{X}_{m \times n}. \quad (2)$$

p_i 对应的特征值 λ_i 定义为该主成分的贡献率:

$$\varphi_i = \frac{\lambda_i}{\sum_{i=1}^m \lambda_i}. \quad (3)$$

前 l 个主成分的累计贡献率 ψ_l 定义为

$$\psi_l = \frac{\sum_{i=1}^l \lambda_i}{\sum_{i=1}^m \lambda_i}. \quad (4)$$

在实际应用时,确定累计贡献率的阈值后,即可确定主成分的选择数量.

1.2 特征量的提取

对裂纹漏磁信号进行定量分析的关键在于信号特征量的提取.特征提取就是利用已有的特征参数构造一个较低维数的特征空间,将原始特征中蕴含的有用信息映射到少数几个特征上,忽略多余的不相干信息.

在总结常见的漏磁信号特征量基础上,并考虑到试验采集到的漏磁信号含有较多噪声,本文定义漏磁信号的主要波形特征量如下:1)切向信号波形的峰-峰值,记为 X_1 ;2)切向信号波形的半波宽,记为 X_2 ;3)切向信号半波波面积,记为 X_3 ;4)切向信号波形的短时能量,记为 X_4 .5)切向信号波形的一次微分信号的峰谷长值,记为 X_5 ;6)法向信号波形的峰谷值,记为 X_6 ;7)法向信号波形的峰谷间距 X_7 ;8)法向信号波形下面积,记为 X_8 ;9)法向信号波形的波形能量,记为 X_9 ;10)法向信号波形的一次微分信号的峰谷值,记为 X_{10} .上面给出了漏磁信号的 10 个主要特征量,但这些特征量对缺陷的尺寸参数的反映并不一致.

2 遗传算法优化的 BP 神经网络

BP 神经网络是神经网络中应用最广的一种多层前馈神经网络,它既是前向网络的核心部分,也是神经网络的精华. BP 神经网络学习算法的本质是通过神经网络各层之间连接权值、阈值的调节,从而实现网络的实际输出向期望输出的逼近.而 BP 神经网络在训练之初,各层的连接权值和阈值被初始化为 $[0, 1]$ 间的随机值,这种未经优化的随机值会使 BP 神经网络的收敛速度慢,并且容易陷入局部极小值.

GA-BP 神经网络是用遗传算法优化 BP 神经网络的初始权值和阈值,其基本思想就是用个体代表网络的初始权值和阈值,个体值初始化的 BP 神经网络的预测误差作为该个体的适应度值,通过选择、交叉、变异操作寻找最优个体,即最优的 BP 神经网络初始权值和阈值. 由于该算法从许多点开始并行操作,而非局限于特定一点,在解空间应用概率法则进行高效启发式搜索,因而可以有效地防止搜索过程中陷入局部最优解. 将遗传算法得到的最优个体对 BP 神经网络初始权值和阈值赋值,GA-BP 神经网络具体算法流程如图 1 所示^[9].

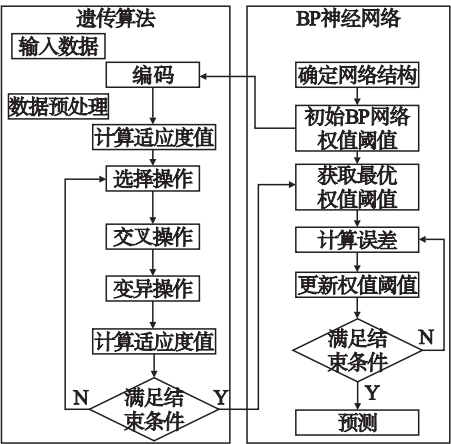


图 1 GA-BP 神经网络流程图
Fig. 1 Flow chart of GA-BP neural network

$$H_x = 2\delta_s \left[\arctan \frac{h(x+b)}{(x+b)^2 + y(y+b)} - \arctan \frac{h(x-b)}{(x-b)^2 + y(y+b)} \right],$$
$$H_y = \delta_s \ln \frac{[(x+b)^2 + (y+h)^2][(x-b)^2 + y^2]}{[(x-b)^2 + (y+h)^2][(x+b)^2 + y^2]}.$$

其中: $\delta_s = \frac{2.65}{2\pi} (\frac{h/b+1}{h/(\mu b)+1}) H_a$, H_a 为施加场强度.

缺陷样本库由 25 个槽型裂纹缺陷组成,缺陷

3 基于磁偶极子模型的理论计算

3.1 磁偶极子模型

矩形槽裂纹的磁偶极带二维模型如图 2 所示,用无限长磁偶极带模拟矩形槽裂纹. 其中,槽宽为 $2b$,槽深为 h , P 为空间中的任意一个点. 磁偶极子模型认为,磁化使矩形槽的两侧壁均匀分布着面密度 σ_s 相等,而极性相反的两条磁荷带,并假设槽的其他部位均无磁荷分布,如图 2 所示.




图 2 等效磁偶极子模型
Fig. 2 Magnetic dipole model

在测点 $P(x,y)$ 处,漏磁场的水平分量 H_x 与法向分量 H_y 可表示为^[2]

宽度、深度尺寸组合形式为 $(2b,h)_i$,其中 i 为样本编号,如表 1 所示.

表 1 裂纹尺寸参数

Table 1 Crack size parameters					mm
深度 h	宽度 $2b$				
	0.10	0.15	0.20	0.25	0.30
0.10	(0.10,0.10) ₁	(0.15,0.10) ₆	(0.20,0.10) ₁₁	(0.25,0.10) ₁₆	(0.30,0.10) ₂₁
0.15	(0.10,0.15) ₂	(0.15,0.15) ₇	(0.20,0.15) ₁₂	(0.25,0.15) ₁₇	(0.30,0.15) ₂₂
0.20	(0.10,0.20) ₃	(0.15,0.20) ₈	(0.20,0.20) ₁₃	(0.25,0.20) ₁₈	(0.30,0.20) ₂₃
0.25	(0.10,0.25) ₄	(0.15,0.25) ₉	(0.20,0.25) ₁₄	(0.25,0.25) ₁₉	(0.30,0.25) ₂₄

3.2 主成分分析特征提取

主成分分析方法是多个与缺陷外形参数有关的特征变量简化为少数几个不相关的综合变量,简化统计数据,揭示特征变量内部的关系,每个主成分是初始变量的线性组合,所有主成分间相互正交,没有冗余信息,构成空间的正交基,它

的根本思想在于降维.

根据裂纹磁荷模型计算 25 组槽型裂纹的漏磁分布,然后提取漏磁信号的 10 个主要波形特征量,构成一个 25×10 的特征值样本矩阵. 用主成分分析方法对该矩阵降维,各主成分的特征值及累计贡献率如表 2 所示.

表 2 各主成分的特征值及累计贡献率
Table 2 Feature and cumulative contribution ratio of the principal components

主成分	特征值	贡献率/%	累计贡献率/%
PC1	7.892 4	78.92	78.92
PC2	1.953 7	19.54	98.46
PC3	0.105 7	1.06	99.52
PC4	0.031 5	0.32	99.84
PC5	0.014 6	0.14	99.98
PC6	0.002	0.02	100
PC7	3.399e-05	0.000 4	100
PC8	6.95e-06	7.846e-05	100
PC9	8.700e-08	2.673e-06	100
PC10	5.746e-09	8.551e-08	100

由表 2 可知,前 2 项主成分的方差占总方差的 98.46%,按照主成分的选取标准,即主成分累

表 3 主成分各因子载荷
Table 3 Factor loading of the principal components

主成分	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}
PC1	0.354 3	0.059	0.355 5	0.348 9	0.011 5	0.355 4	0.348 0	0.355 6	0.350 4	0.355 1
PC2	-0.060 5	0.699 8	-0.031 1	-0.045 0	0.709 5	-0.003 7	0.015 6	-0.008 1	-0.002 2	-0.004 7




图 3 3 层 BP 神经网络结构图

Fig. 3 Structure of three layer BP neural network

3.4 定量识别结果与讨论

对表 1 中的 25 个缺陷模型样本,选择 20 个作为训练数据,其余 5 个作为测试数据.采用图 3 所示 GA-BP 神经网络对理论计算数据进行预测,预测结果如表 4 所示.

表 4 理论计算数据预测结果

Table 4 Predictive results of the theoretical calculation data

序号	实际值/mm		预测值/mm		误差/%	
	宽度	深度	宽度	深度	宽度	深度
1	0.10	0.30	0.097 4	0.297 1	2.60	0.95
2	0.15	0.20	0.172 0	0.197 8	14.67	1.12
3	0.20	0.10	0.174 8	0.107 8	12.62	7.82
4	0.25	0.25	0.247 0	0.248 7	1.18	0.50
5	0.30	0.20	0.298 4	0.204 7	0.55	2.34

计贡献率达 85%^[8],说明这 2 项主成分可以代替原来的 10 个漏磁信号特征值.表 3 为主成分线性变换系数.由表 3 可知,第一主成分中 $X_1, X_3, X_4, X_6, X_7, X_8, X_9, X_{10}$ 占较大载荷,第二主成分中 X_2, X_5 占有较大载荷.用 2 项主成分的值作为神经网络预测模型的输入样本.

3.3 GA-BP 神经网络

BP 神经网络结构包括输入层、隐含层和输出层,其中隐含层可以是一层或多层,本文所建立的 BP 神经网络结构为 2-8-2,即输入层有 2 个节点,隐含层有 8 个节点,输出层有 2 个节点,如图 3 所示.隐含层和输出层函数的选择对 BP 神经网络预测精度有较大影响,本文中隐含层节点转移函数选择 tansig 函数,输出层节点选择 purelin 函数.遗传算法(GA)由遗传算法工具箱(GAOT)实现.

由表 4 可以看出,预测结果精度均达到 85% 以上,其中,深度的预测结果误差小于 10%,宽度的预测误差稍大,最大为 14.67%.由此可知,理论计算数据的预测结果是比较成功的.

4 微裂纹漏磁定量识别实验

为了构建真实信号样本库,研制了一套漏磁检测系统,如图 4 所示.该系统由阵列传感器、励磁装置、信号调理、采集卡、扫描控制台等组成.




图 4 漏磁检测系统图

Fig. 4 Photo of the MFL test system

采用电火花加工方法,在 16MnR 钢板上制作了与表 1 具有相同尺寸的 25 个人工槽型微裂纹缺陷样本.采用检测系统采集微裂纹缺陷表面的漏磁信号,并通过形态滤波法对信号进行预处理.最后,采用 PCA 和 GA-BP 神经网络相结合的建

模方法,建立了微裂纹的参数识别模型,识别结果如表 5 所示.

表 5 漏磁实验数据预测结果

Table 5 Predictive results of the MFL experimental data

序号	实际值/mm		预测值/mm		误差/%	
	宽度	深度	宽度	深度	宽度	深度
1	0.10	0.30	0.133 3	0.267 5	33.30	10.84
2	0.15	0.20	0.162 9	0.208 6	8.60	4.28
3	0.20	0.10	0.135 5	0.116 6	32.24	16.64
4	0.25	0.25	0.274 8	0.221 1	9.90	11.55
5	0.30	0.20	0.229 1	0.230 7	23.62	15.36

由表 5 可知,实验数据的预测结果误差比仿真数据预测结果偏大,最大为 33.3%. 尽管存在不容忽视的预测误差,但从现有研究结果看,尚属正常. 因为从宏观裂纹(裂纹宽深尺度大于1 mm)预测结果看,一般预测误差都在 20% 左右^[5-7],对微细裂纹(裂纹宽深小于 0.5 mm)的预测缺乏可靠资料,但比照宏观裂纹,这一结果还有其合理性,能够基本反映缺陷的尺寸大小.

5 结 论

本文采用 PCA 和 GA-BP 神经网络的方法,开展了尺度 0.5 mm 以下的微裂纹漏磁定量识别研究. 结果表明,PCA 减小了输入样本维数,显著简化了网络结构;GA-BP 神经网络可有效防止搜索过程中陷入局部最优解. 最终,通过磁偶极子

模型数值计算与人工微裂纹检测实验两种途径验证了该技术路径的有效性.

参考文献:

[1] Wang Z D,Gu Y, Wang Y S. A review of three magnetic NDT technologies [J]. *Journal of Magnetism and Magnetic Materials*,2012,324:382-388.

[2] 王长龙,陈自立,马晓琳,等. 漏磁检测的缺陷可视化技术[M]. 北京:国防工业出版社,2014.
(Wang Chang-long, Chen Zi-li, Ma Xiao-lin, et al. Visualization technology of detect in magnetic flux leakage testing [M]. Beijing :National Defense Industry Press,2014.)

[3] Carvalho A A,Rebelloa J M A,Sagrilo L V S. MFL signals and artificial neural networks applied to detection and classification of pipe weld defects[J]. *NDT&E International*, 2006,39:661-667.

[4] Hwang K,Mandaym S,Udpa S S. Characterization of gas pipeline inspection signals using wavelet basis function neural networks[J]. *NDT&E International*,2000,33:531-545.

[5] Ramuhalli P,Udpa L. Electromagnetic NDE signal inversion by function-approximation neural networks [J]. *IEEE Transaction on Magnetics*,2002,38:3633-3641.

[6] Wang P,Xiong L H,Sun Y C, et al. Features extraction of sensor array based PMFL technology for detection of rail cracks [J]. *Measurement*,2014,47:613-626.

[7] Zhang Y,Ye Z F,Wang C. A fast method for rectangular crack sizes reconstruction in magnetic flux leakage testing [J]. *NDT&E International*,2009,42:369-375.

[8] Yang C Y,Wu T Y. Diagnostics of gear deterioration using EEMD approach and PCA process [J]. *Measurement*,2015, 61:75-87.

[9] Zhang Y X, Gao X D, Katayama S. Weld appearance prediction with BP neural network improved by genetic algorithm during disk laser welding [J]. *Journal of Manufacture System*,2015,34:53-59.



(上接第 1754 页)

参考文献:

[1] Al-Alawi B M, Bradley T H. Review of hybrid, plug-in hybrid, and electric vehicle market modeling studies [J]. *Renewable & Sustainable Energy Reviews*, 2013, 21 (5): 190-203.

[2] Chen Z Y, Xiong R, Wang K Y, et al. Optimal energy management strategy of a plug-in hybrid electric vehicle based on a particle swarm optimization algorithm [J]. *Energies*,2015,8(5):3661-3678.

[3] 陈清泉,孙逢春,祝嘉光. 现代电动汽车技术[M]. 北京:北京理工大学出版社,2002:38-60.
(Chen Qing-quan, Sun Feng-chun, Zhu Jia-guang. Modern electric car technology [M]. Beijing: Beijing Institute of Technology Press,2002:38-60.)

[4] Chau K T, Wong Y S. Overview of power management in hybrid electric vehicles [J]. *Energy Conversion and Management*,2002,43:1953-1968.

[5] Ahn J K, Jung K H, Kim D H, et al. Analysis of a regenerative braking system for hybrid electric vehicles using an electro-mechanical brake [J]. *International Journal of Automotive Technology*,2009,10(2):229-234.

[6] Oleksowicz S A,Burnham K J,Barber P,et al. Investigation of regenerative and anti-lock braking interaction [J]. *International Journal of Automotive Technology*, 2013, 14 (4):641-650.

[7] 杨亚娟,赵韩,朱茂飞. 电动汽车最大能量回收再生制动控制策略的研究[J]. 汽车工程,2013,35(2):105-110.
(Yang Ya-juan, Zhao Han, Zhu Mao-fei. A study on the control strategy for maximum energy recovery by regenerative braking in electric vehicles [J]. *Automotive Engineering*,2013,35(2):105-110.)

[8] 叶敏,郭金刚. 电动汽车再生制动及其控制技术[M]. 北京:人民交通出版社,2013:8-22.
(Ye Min,Guo Jin-gang. Regenerative brikng and its control technology on electric vehicle [M]. Beijing: China Communications Press,2013:8-22.)

[9] Chen Z Y,Xiong R,Cao J Y. Particle swarm optimization-based optimal power management of plug-in hybrid electric vehicles considering uncertain driving conditions [J]. *Energy*,2016,96:197-208.

[10] Schoutena N J, Salmanb M A, Kheir N A. Energy management strategies for parallel hybrid vehicles using fuzzy logic[J]. *Control Engineering Practice*, 2003, 11 (2): 171-177.