

基于 L-M 神经网络的齿轮故障诊断

毛明明¹, 柳益君², 汤嘉立²

(1. 华为技术有限公司业务与软件产品线, 广东 深圳 518129;

2. 江苏技术师范学院 计算机工程学院, 江苏 常州 213001)

摘要: 齿轮传动工况的复杂性使得其特征参量与故障形式呈非线性映射关系。提出基于 Levenberg-Marquardt 算法的前向多层神经网络的齿轮故障诊断方法, 该方法通过利用二阶导数信息, 可以提高收敛速度和增强网络的泛化性能。并以一种齿轮箱故障信号采集实验系统为例, 通过 MATLAB 软件及其神经网络工具建模和仿真研究。结果表明, Levenberg-Marquardt 神经网络对齿轮常见故障有良好的识别能力, 能稳定、准确地识别各类故障, 与标准 BP 网络相比, 收敛速度快且诊断更为准确。

关键词: 神经网络; 麦夸特算法; 齿轮故障诊断

中图分类号: TP183

文献标识码: A

文章编号: 1673-629X(2011)01-0210-04

Gear Fault Diagnosis Based on Levenberg-Marquardt Neural Network

MAO Ming-ming¹, LIU Yi-jun², TANG Jia-li²

(1. Business and Software Product Line, Huawei Technologies Co., Ltd., Shenzhen 518129, China;

2. College of Computer Engineering, Jiangsu Teachers University of Technology, Changzhou 213001, China)

Abstract: Because of the complexity of gear working condition, there are non-linear relationship between characteristic parameters and fault types. Proposes to apply the feed forward artificial neural network with Levenberg-Marquardt training algorithm, to the problem of gear fault diagnosis. By using second derivative information, the network convergence speed is promoted and the generalization performance is enhanced. Taking a certain gearbox fault signal acquisition experimental system for an example, MATLAB software and its neural network toolbox are used to model and simulate. The experiment result shows that Levenberg-Marquardt neural network has good performance for the common gear fault diagnosis and it can identify various types of faults stably and accurately. Furthermore, compared with conventional BP neural network, the Levenberg-Marquardt neural network reduces training epochs and promotes prediction accuracy.

Key words: neural network; Levenberg-Marquardt algorithm; gear fault diagnosis

0 引言

齿轮箱是机械设备的一个重要组成部分, 其传动比固定、传动转矩大、结构紧凑, 是用于改变转速和传递动力的常用传动部件, 也是易于发生故障的部件。因此, 齿轮故障诊断得到了研究人员的广泛重视和关注。

齿轮传动工况的复杂性使得它的故障形式与特征的关系呈非线性映射关系。因此建立系统的解析模型存在一定的困难^[1]。神经网络具有强大的非线性映射能力, 用它作为工具不需要建立系统的解析模型就可以对系统的故障模式进行分类, 进而对系统进行故障诊断。

作为故障识别的一种有效方法, 神经网络已在许多实际系统中得到了成功应用^[2-5]。主要原因是它具有如下特点: ①非线性映射特性; ②信息的分布存储特性; ③并行处理和全局优化能力; ④高度的自学习和自组织能力。在各种各样的神经网络中, BP 神经网络是一种多层前向神经网络, 它结构简单, 而且具有最佳逼近性能。多年来, BP 神经网络得到了国内外学者的很多关注和研究, 并在故障诊断与模式识别领域得到成功应用。尽管在故障诊断领域 BP 神经网络表现出的性能较为优秀, 但是也存在一些缺点: ①不易调和泛化性和过拟合之间的矛盾; ②学习训练的收敛速度较慢; ③容易收敛到局部极小点。这些不足之处对于它的实用化和工程化均是不利的。麦夸特 (Levenberg-Marquardt, L-M) 算法, 在学习精度和速度方面比标准 BP 算法更具优势^[6], 因此将基于 L-M 学习算法的前向多层神经网络用于齿轮常见故障诊断, 以满足故障诊断对神经网络训练次数和准确度的要求, 仿真实验结

收稿日期: 2010-05-16; 修回日期: 2010-08-02

基金项目: 江苏省自然科学基金基础研究基金 (07KJD20040)

作者简介: 毛明明 (1979-), 女, 浙江奉化人, 工程师, 研究方向为计算机系统工程和计算机应用。

果表明了该方法的有效性。

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1} J^T(w)e(w) \quad (2)$$

1 L-M 神经网络原理

1.1 BP 算法

多层前向神经网络是目前使用较多的一种神经网络模型,在理论上对于非线性连续映射可以任意逼近,因而在非线性系统的建模及控制方面非常适用^[7]。

在神经网络中,下一层输入对上一层节点刺激脉冲强度由传递函数反映,通常取 sigmoid 函数,因为其在(0,1)内取值连续:

$$f(x) = \frac{1}{1 + e^{-x}}$$

提供训练样本 (X_p, Y_p) ($p = 1, 2, \dots, P$), P 为样本数目, $X_p = (x_{p1}, x_{p2}, \dots, x_{pM})$, M 是输入向量的维数。设 Y_p 为样本 X_p 期望的网络输出向量, \hat{Y}_p 是网络的实际输出向量, $Y_p = (y_{p1}, y_{p2}, \dots, y_{pN})$, N 为输出向量维数。误差指标函数为:

$$E(w) = \frac{1}{2} \sum_{p=1}^P \|Y_p - \hat{Y}_p\|^2 = \frac{1}{2} \sum_{p=1}^P e_p^2(w) \quad (1)$$

式(1)中 w 是一个向量,由网络的全部权值和阈值组成, $e_i(w)$ 是误差。

标准 BP 学习算法是梯度下降法,算法学习过程可描述如下^[8,9]:

Step1. 对权值 w_{ij} 及阈值向量进行初始化,并给出学习误差的允许值 ε ;

Step2. 由式(1)计算 E ,若 $E \leq \varepsilon$,转步骤 3,否则对每个样本 (X_p, Y_p) :

a) 计算网络输出 o : ①对每一个输出单元 k ,计算 $\delta_k = o_k(1 - o_k)(t_k - o_k)$; ②对每一个隐含单元 h ,计算 $\delta_h = o_h(1 - o_h) \sum_k w_{hk} \delta_k$;

b) 更新网络连接权值 w_{ij} , $w_{ij} = w_{ij} + \Delta w_{ij}$, $\Delta w_{ij} = \mu \delta_j x_{ij}$, x_{ij} 为单元 i 到 j 的输出, μ 是学习速率;

Step3. 结束。

1.2 Levenberg-Marquardt 学习算法

BP 算法中,参数沿误差梯度的相反方向移动,从而使误差逐步减小,最终取得极小值。这种基于梯度下降方法的线性收敛速度很慢,偏导数的计算是引起其计算复杂度的主要原因。而 L-M 算法由 Gauss-Newton 法改进得到,兼具梯度法之全局特性与 Gauss-Newton 法局部特性。对于二阶导数信息的利用提高了 L-M 算法的速度^[10]。

设 w^k 表示第 k 次迭代的权值和阈值所组成的向量,新的权值和阈值所组成的向量 w^{k+1} 为 $w^{k+1} = w^k + \Delta w$ 。L-M 算法中的权值增量 Δw 由式(2)计算:

式中 I 为单位矩阵, $J(w)$ 为 Jacobian 矩阵,即

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix}$$

在速度上 L-M 算法要比梯度法快很多。且式(2)的解一定存在,因为 $J^T(w)J(w) + \mu I$ 是正定的。L-M 算法学习过程如下:

Step1. 对权值和阈值向量进行初始化;给出学习误差的允许值 ε ,常数 μ_0 和 β ($0 < \beta < 1$),令 $k = 0$, $\mu = \mu_0$;

Step2. 对输出及误差函数 $E(w^k)$ 进行计算;

Step3. 对 Jacobian 矩阵 $J(w^k)$ 进行计算;

Step4. 计算权值增量 Δw ;

Step5. 如果 $E(w^k) < \varepsilon$,则转至步骤 8;

Step6. 计算新权值和阈值向量 w^{k+1} : $w^{k+1} = w^k + \Delta w$;

Step7. 计算 $E(w^{k+1})$,若 $E(w^{k+1}) < E(w^k)$,则令 $k = k + 1$, $\mu = \mu\beta$,转到步骤 2,否则令 $\mu = \mu/\beta$,转到步骤 4;

Step8. 结束。

2 故障诊断模型构建

2.1 特征参量选择

文中以文献[11,12]介绍的一种齿轮箱故障诊断方法为例进行研究。齿轮箱故障信号采集实验系统装置如图 1 所示。系统由三相异步电动机驱动,由联轴器输入动力于齿轮箱,再通过齿轮箱传动,将动力传递于负载轮,最后由抱紧装置卡住。主要通过检测振动加速度信号获得数据。

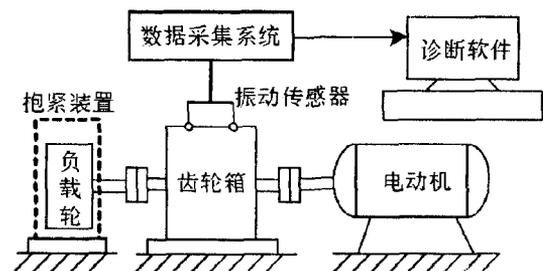


图 1 齿轮箱故障信号采集实验系统

齿轮箱中的 5 类典型故障是在齿轮箱相同型号的零件上人为设置的,其分别是:①滚动轴承内圈划伤;

②轴承外圈有剥落坑;③轴承保持架损坏;④齿轮齿面磨损;⑤齿轮崩齿。对上述 5 类故障分别在典型转速下进行实验测试。实验中,采样频率为 8kHz,连续采样 2048 点得到时域波形。由于采集到的原始振动信号包括大量的噪声干扰,因此需要对信号进行预处理以提高信号的信噪比。预处理中采用的降噪方法包括高通滤波、均值化、选择 db4 紧支集小波基和三层小波浮动阈值。然后选用 4 个时域特征参量和 3 个频域特征参量作为故障样本特征。时域参量包括:①峰值指标(F1);②峭度指标(F2);③裕度指标(F3);④偏态指标(F4)。频域参量包括:①频谱重心(F5);②频率方差(F6);③谐波因子(F7)^[11]。

由于这些时频域参量存在着量纲差别,故而在神经网络训练之前必须进行数据归一化处理。具体实验过程参考文献[11]。已归一化的五种典型齿轮箱故障训练样本的特征参量值 F1~F7 见表 1。

表 1 训练样本

组别	F1	F2	F3	F4
1	0.0468	0.0287	0.0371	0.0928
2	0.7281	0.3886	0.5426	0.4224
3	0.4472	0.2873	0.3812	0.3871
4	0.9079	0.3501	0.6515	0.3487
5	1.0000	0.5430	0.7723	0.5339
6	0.7858	0.3973	0.6176	0.4558
7	0.4132	0.0658	0.2997	0.1273
8	0.1735	0.1260	0.1451	0.2188
9	0.4073	0.1293	0.3217	0.2290
10	0.2899	0.0000	0.1205	0.0000
11	0.6029	0.2359	0.4465	0.3133
12	0.5199	0.2600	0.4122	0.3433
13	0.6188	0.2327	0.4529	0.2889
14	0.9574	1.0000	1.0000	1.0000
15	0.5857	0.6005	0.5769	0.6759
组别	F5	F6	F7	故障类型
1	0.0000	0.0000	1.0000	第 1 类(轴承内圈划伤)
2	0.6281	0.9423	0.3221	第 2 类(轴承外圈剥落坑)
3	0.6425	0.9269	0.1677	第 3 类(轴承保持架损坏)
4	0.8396	0.5554	0.4868	第 4 类(齿面磨损)
5	0.6775	0.8825	0.2200	第 5 类(崩齿)
6	0.5705	0.9857	0.0000	
7	0.8872	0.4222	0.4286	
8	0.5373	0.9987	0.1593	
9	0.5342	0.9996	0.2743	
10	1.0000	0.0298	0.4940	
11	0.5920	0.9724	0.1180	
12	0.5489	0.9952	0.1874	
13	0.8734	0.4637	0.5434	
14	0.7344	0.7916	0.0024	
15	0.7147	0.8274	0.3881	

2.2 模型的建立

将神经网络用于故障模式识别的方法原理如下:故障特征参量作为神经网络的输入,对应于每个输入结点,故障原因作为神经网络的输出,对应于输出结

点。利用一组故障样本训练网络,网络充分学习后其结构和参数得以确定。网络训练完毕后,便可进行故障的模式分类:根据给定的一组特征参量,实现特征参量到故障集的非线性映射。

文中采用 7-15-1 的 3 层神经网络结构,如图 2 所示。输入向量包含 7 项参量,因此这里的输入层包含 7 个结点。隐含层的结点数 15 根据 Kolmogorov 定理确定:设 n 为输入层的结点数,则隐含层结点数为 $2n + 1$ 。输出层包含 1 个结点,输出故障类型(数字 1-5 分别对应 5 类故障)。

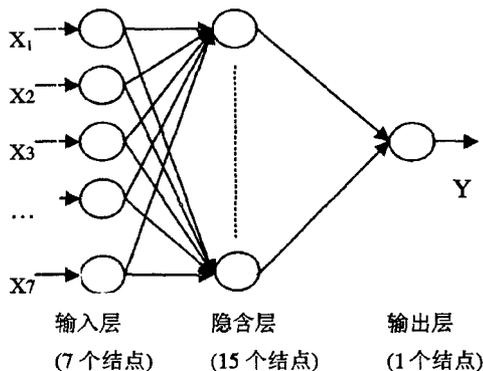


图 2 用于齿轮故障诊断的神经网络结构

文中建立、训练和测试神经网络所采用的软件为 MATLAB 7。将表 1 中样本的三分之二作为训练集,三分之一作为验证集。参数设置如下:①输入层与隐含层的传递函数采用正切 Sigmoid 函数 $tansig()$;②隐含层和输出层之间的传递函数采用线性函数 $purelin()$;③学习率 lr 设为 0.01;④最大训练步数 $epoch$ 设为 2000;⑤ $show$ 为 50;⑥以输出的均方误差 MSE 为目标,设 $goal$ 为 0.001;⑦采用实现 L-M 算法的函数 $trainlm$ 训练网络。MATLAB 关键代码如下:

```
net=newff(minmax(P),[15,1],{'tansig','purelin'},'trainlm');%设置各层节点数,传递函数和学习函数
net=init(net);%神经网络初始化
net.trainparam.epochs=2000;%最大训练次数
net.trainparam.lr=0.01;%设置学习率
net.trainparam.show=50;%显示训练迭代过程
net.trainparam.goal=1e-3;%设置训练要求精度
[net,tr]=train(net,P,t,[],[],val);
figure(2);
plot(tr.epoch,tr.perf,'-',tr.epoch,tr.vperf,'--');
```

L-M 神经网络训练过程中误差变化曲线见图 3。由图 3 可见,经过 23 步训练后 L-M 神经网络均方误差 MSE 达到了误差标准目标 0.001;另外,图中验证集与训练集的误差曲线变化一致,验证集的验证误差随着网络训练误差的减小而减小,这说明网络没有发生过拟合现象。

为了比较研究,文中也对标准 BP 神经网络进行

训练和测试。实现代码与 L-M 神经网络一样,但是需将学习算法函数改为 'traingd'。BP 网络的误差变化曲线如图 4 所示;训练集和验证集的误差曲线也始终一致,说明网络没有过度训练;BP 网络 1694 步后收敛到预定精度。与 BP 网络相比,L-M 网络收敛速度得到了大幅提高。

至此,齿轮故障的神经网络诊断模型构建完成。在应用过程中,只需输入检测样本的标准化指标数据,便可以识别研究。

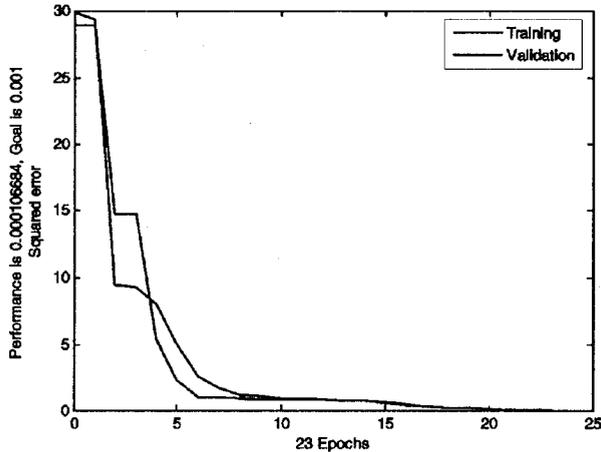


图 3 L-M 网络误差变化曲线

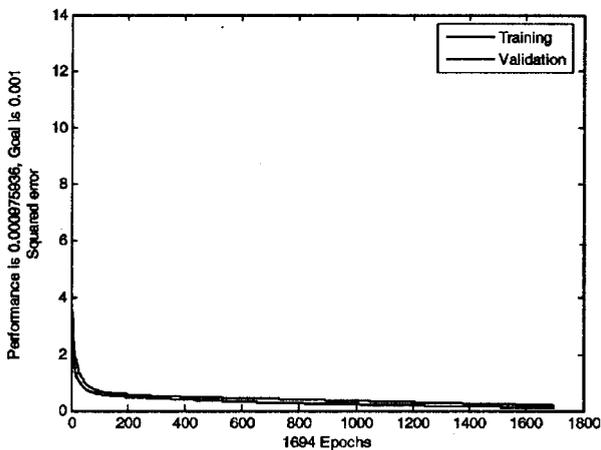


图 4 BP 网络误差变化曲线

3 诊断仿真

为了验证模型的有效性,选用如表 2 所示的 5 组齿轮箱故障测试样本进行分类识别^[11]。

检测结果如表 3 所示,结果比较见表 4。由表 4 中可见,L-M 网络输出的最大、最小和平均相对误差分别为 5.190%、0.022% 和 1.810%,均小于 BP 网络输出的相应相对误差 14.555%、0.076% 和 7.083%。同时,BP 网络模型对第 4 组有误判,准确率为 80%,而 L-M 网络模型对 5 组测试样本均能准确识别,即对测试样本的诊断准确率达到 100%。这说明 L-M 神经网络在齿轮故障诊断方面具有很好的性能,比 BP 网络

提高了分析精度。

表 2 检测样本

组别	F1	F2	F3	F4	F5
1	1.0000	0.6001	0.7791	0.5778	0.5735
2	0.6208	0.2622	0.4557	0.3210	0.4817
3	0.2269	0.1710	0.1759	0.2476	0.4585
4	0.7128	0.3986	0.5230	0.4224	0.5270
5	0.9769	1.0000	1.0000	1.0000	0.6140

组别	F6	F7	实际故障类型	期望输出
1	0.9175	0.1390	轴承内圈划伤	1
2	0.9842	0.0000	轴承外圈划伤	2
3	0.9940	0.0586	轴承外圈剥落坑	3
4	0.9585	0.1931	齿面磨损	4
5	0.8732	0.0819	齿面崩齿	5

表 3 检测结果

组别	L-M 网络		BP 网络	
	输出	识别类型	输出	识别类型
1	1.0519	第 1 类	0.9071	第 1 类
2	2.0466	第 2 类	1.7738	第 2 类
3	3.0273	第 3 类	2.9945	第 3 类
4	3.9760	第 4 类	3.4178	第 3 类
5	5.0011	第 5 类	5.0038	第 5 类

表 4 结果比较

	L-M 网络	BP 网络
最大相对误差	5.190%	14.555%
最小相对误差	0.022%	0.076%
平均相对误差	1.810%	7.083%
诊断准确率	100%	80%

4 结束语

文中提出将基于 Levenberg-Marquardt 算法的神经网络用于齿轮故障诊断是一种新的尝试。该算法不仅提高了神经网络的学习速度和稳定性,而且具有良好的收敛性质,不像常规网络那样的易陷入局部极小点。以一种齿轮箱故障信号采集实验系统为例,并使用 MATLAB 7 软件及其神经网络工具箱编程实现,进行建模和测试。仿真结果表明,用 L-M 神经网络进行齿轮故障诊断具有如下优点:泛化性强、收敛快、诊断准确等,与传统的 BP 网络比较,显著提高了识别故障的能力,具有很好的推广应用价值。

参考文献:

- [1] 刘军,王萍.基于粗糙集理论的故障诊断系统知识库设计[J].计算机技术与发展,2008,18(9):95-97.
- [2] 李斌,章卫国,宁东方,等.基于神经网络信息融合的智能故障诊断方法[J].计算机仿真,2008,25(6):35-37.
- [3] 龙伯华,谭阳红,许慧,等.基于新小波神经网络的电力电子电路故障诊断[J].计算机仿真,2009,26(5):266-270.
- [4] 贾玉玲,邱惠清.BP 神经网络齿轮故障诊断的仿真[J].

随着救援工作的不断深入,需要准确了解地震灾区的救援需求。应急系统主要参考目前已有地震应急及震害预测研究中已有的需求分析模型,并适当补充、完善,初步建立一个可满足目前地震应急指挥工作要求的技术系统^[10]。

4.2 系统建设中 GIS 新技术的应用

(1) 网络空间数据库建设。

地震应急基础数据是实施地震应急指挥的基础和必要条件,数据库建设中采用大量新技术:包括集中与分布式相结合的数据库群建设、海量数据仓库、空间数据引擎、高可用数据库系统、分布式数据库的数据同步和存储、数据库系统的自动备份。地震应急数据包括:人口、经济、建筑、基础地理、城市地图、公路、铁路、气象、地震灾害、地质、生命线工程、医疗、消防、水库、应急预案、应急联络等 47 大类数百个小类,这些数据以区、市、县、乡、村为单位开展收集和建库工作,建成后的数据库在统一的数据规范指导下,实行应急数据共享。

(2) 空间技术支持下的震害动态评估。

系统设计采用基于 PDA 的震害调查终端,这样指挥系统建设在空间数据的基础上,可以实现动态获取空间数据并进行震害评估,震害动态评估技术可根据灾区现场情况不断跟踪、评估灾情发展的软件,用于为指挥人员制订救灾决策提供基本的地震损失信息。

(3) GIS 决策分析。

抗震救灾指挥部各类软件、数据库、显示模块等均须运行在 GIS 平台上。通过 GIS 的相关操作,对各类信息进行计算,对救援分布力量、灾害分布、次生灾损通过专业模型进行空间计算并生成专题图件。指挥系统还借用 Google 平台,利用 Google 高分辨率影像辅助空间分析决策。

5 结束语

GIS 新技术应用于数字地震应急救灾,可以将地

震基础数据库中无法看到的数据之间的关系模式,借助 GIS 的空间分析、网络分析、数学模型分析和可视化功能清晰直观地表现出来。GIS 新技术可以为指挥者提供更丰富和更直观的救援信息,提供更科学的决策模型^[11,12]。建设一个具有智能应急功能的地震应急平台必将涉及大量的空间信息与属性信息,也必须借助 GIS 新技术的支持。

参考文献:

- [1] 成小平,帅向华,杨亚莉,等.地震应急响应系统中的数据分发[J].地震,2001,21(4):88-93.
- [2] 李东平,赵锦慧,沈晓健,等.基于 GIS 技术的浙江省地震应急指挥演练系统[J].地震研究,2006(3):45-51.
- [3] 孙芹芹,陈少沛,谭建军.基于 MDA 的城市地质灾害应急 GIS 模型研究[J].计算机技术与发展,2008,18(7):184-186.
- [4] 赵军,李东平,朱瑜馨.可视化语言实现 GIS 软件的二次开发[J].测绘通报,2002(S1):25-27.
- [5] Heath J R, Yakutis P J. High Speed Storage Area Networks Using a Fibre Channel Arbitrated Loop Interconnect [J]. Network, IEEE, 2000, 14(2): 2-3.
- [6] Lawmn G. New Ways to Build Rich Internet Applications [J]. IEEE Computer Society, 2008, 41(8): 10-12.
- [7] Xilinx Inc. Logic CORE Fibre Channel User Guide [J]. [s. l.]: Xilinx Inc, 2004.
- [8] 刘维中.基于 AJAX 及其框架技术开发 WEB 应用[J].中国科技信息,2009(1):69-70.
- [9] 李军利,查良松.数据挖掘在人口 GIS 中的应用研究[J].计算机技术与发展,2009,19(12):213-216.
- [10] 汤胤,彭宏,郑启伦.基于数据挖掘和范例推理的智能分析决策支持技术综述[J].计算机工程与应用,2004,(9):184-187.
- [11] 李向,宋涛. MAS 技术在土壤重金属污染评价及预警中的应用[J].计算机技术与发展,2010,20(1):217-220.
- [12] 王结臣,沈定涛,陈焱明,等.一种有效的复杂多边形裁剪算法[J].武汉大学学报:信息科学版,2010(3):369-372.

(上接第 213 页)

机床与液压,2008,36(7):229-231.

- [5] 李佳,礼宾,王梦卿.基于神经网络的齿轮故障诊断专家系统[J].机械传动,2007,32(5):81-83.
- [6] Suratgar A A. Modified Levenberg-Marquardt Method for Neural Networks Training [J]. Proceedings of World Academy of Science, Engineering and Technology, 2005, 6:46-48.
- [7] Fidele B, Cheenebash J. Artificial Neural Network as a Clinical Decision-Supporting Tool to Predict Cardiovascular Disease [J]. Trends in Applied Sciences Research, 2009, 4(1): 36-46.

- [8] Alpaydin E. Introduction to Machine Learning [M]. [s. l.]: MIT Press, 2004.
- [9] 夏玫,陈立潮,王新波.一种提高 BP 神经网络泛化能力的改进算法[J].计算机技术与发展,2009,19(9):62-64.
- [10] 刘鹏.一类基于 Levenberg-Marquardt 算法的神经 PID 控制研究[J].重庆工商大学学报(自然科学版),2008,25(2):139-142.
- [11] 王晓红.基于概率投票策略的多类支持向量机及应用[J].计算机工程,2009,35(2):180-183.
- [12] 孟浩东.基于神经网络和灰色理论的传动箱故障诊断研究[D].太原:中北大学,2005.