

# 粗糙集 - 遗传算法 - 神经网络集成分类器及其在转子故障诊断中的应用研究

陈 果

南京航空航天大学, 南京, 210016

**摘要:**针对转子故障诊断问题,在综合粗糙集理论、遗传算法及神经网络学习算法各自优点的基础上,提出了一种新的粗糙集 - 遗传算法 - 神经网络(RS - GA - NN)集成分类器模型。在该模型中,利用粗糙集理论的离散和约简算法实现对样本数据的特征选取;利用神经网络实现样本特征向量与故障之间的非线性映射;利用遗传算法实现对神经网络的结构优化以使神经网络的泛化能力达到最优。利用转子故障实验台模拟了不平衡、不对中、碰摩及油膜涡动4种故障的127个样本,构建了多故障识别的RS - GA - NN集成分类器,进行了转子故障的智能诊断实验,获得了很好的效果。

**关键词:**粗糙集理论;遗传算法;神经网络;转子;故障诊断

**中图分类号:**TH165.3      **文章编号:**1004 - 132X(2008)01 - 0085 - 06

## Rough Set - genetic Algorithm - neural Network Compositive Classifier and Its Application in Rotor Faults Diagnosis

Chen Guo

Nanjing University of Aeronautics and Astronautics Nanjing, 210016

**Abstract:** The fault diagnosis problem of rotor system was aimed at, on the basis of synthesizing the advantages of Rough Set (RS) theory, Genetic Algorithm (GA) and Neural Network (NN), a new RS - GA - NN compositive classifier was put forward. In the model, the RS was used to carry out selection of sample features; the NN was used to realize the mapping between features and fault type of sample; the GA was used to optimize the structure of NN model in order to make it to reach the best generalization. The rotor fault experimental rig was used to simulate unbalance, misalignment, rubbing and oil whirling faults, and 127 faults samples are obtained. Finally, the RS - GA - NN compositive classifier of multi - faults recognition was established, and the intelligent fault diagnosis experiment was finished, and a very satisfied result is obtained.

**Key words:** rough set (RS); genetic algorithm (GA); neural network (NN); rotor; fault diagnosis

## 0 引言

旋转机械转子系统通常存在不平衡、不对中、碰摩以及油膜涡动等故障<sup>[1]</sup>,故障特征与故障模式之间的非线性不确定映射关系,导致了传统的基于信号分析的转子系统故障诊断存在很大的难度。神经网络具有超强的非线性映射能力和容错性,被广泛应用于转子系统的故障诊断,形成了基于神经网络的智能诊断<sup>[2-4]</sup>。然而,神经网络的智能诊断中目前普遍存在两方面问题:一方面是面对由信号分析得到的大量特征信息,如何选取最具有价值、分类能力最强的特征;另一方面是神经网络应该如何优化,方可保证其最大的泛化能力。针对这两个问题,有许多学者进行了研究。虞和济等<sup>[4]</sup>介绍了基于遗传算法(GA)的神经网络

(NN)结构优化的方法,郝丽娜等<sup>[5]</sup>建立了粗糙集(RS) - 神经网络模型,利用粗糙集理论进行了特征选取。但这些研究并未将上述两问题作为一个整体来研究,因此,诊断过程的自动化程度和自适应能力较低。本文在这些研究基础上,结合神经网络<sup>[4]</sup>、粗糙集理论<sup>[6]</sup>和遗传算法<sup>[7]</sup>各自优点,提出了粗糙集 - 遗传算法 - 神经网络(RS - GA - NN)集成分类器,以期提高诊断过程的自动化程度和自适应能力。

## 1 粗糙集 - 遗传算法 - 神经网络集成分类器模型学习流程及关键技术

结合粗糙集理论、遗传算法及神经网络模型,本文构造了RS - GA - NN集成分类器模型,其学习流程如图1所示,该学习过程包括基于粗糙集理论的特征选取、基于BP算法的神经网络的内部参数学习及基于遗传算法的神经网络外部参

收稿日期:2006 - 11 - 09

基金项目:国家自然科学基金资助项目(50705042);航空科学基金资助项目(2007ZB52022)

数学学习三部分。在图 1 中,单点划线为基于粗糙集理论的特征选取,虚线框为神经网络内部参数学习,双点划线框中为外部参数的学习。RS - GA - NN 集成分类器的学习流程可以描述如下:

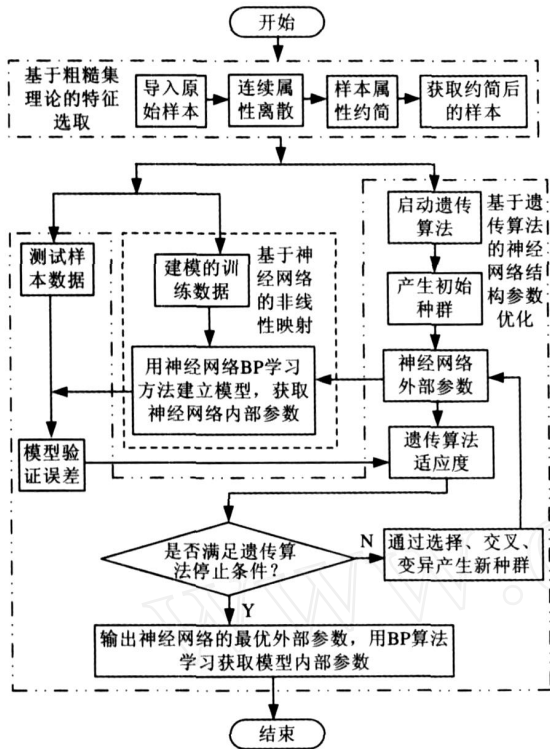


图 1 RS - GA - NN 集成分类器学习训练流程

(1) 算法开始后,读取样本数据,利用粗糙集理论的离散与约简算法,对样本数据中的连续属性进行离散,然后用约简算法约去样本中的冗余属性,从而得到最具分类能力的特征集,并利用所获取的最优特征集形成新的样本集。

(2) 将特征选取后得到的新样本集中的一部分数据作为训练样本,其余数据作为测试样本。

(3) 获取了神经网络初始外部参数(结构参数)和训练样本后,启动神经网络 BP 算法训练样本学习后得到模型的内部参数(神经网络的连接权值)。对所得到的神经网络模型,用测试样本进行验证,用得到的识别率来衡量模型的泛化能力,并转化为遗传算法的适应度函数值。

(4) 依据种群中各染色体的适应度值,对种群中的个体进行选择、交叉和变异以获得新一代的种群,对新一代的种群中的染色体解码,可以获取模型新的外部参数,运用新外部参数下的神经网络模型,对训练样本学习又可以得到新的内部参数。再用测试样本对模型进行验证,获取不同外部参数下的学习机器适应度,并进行下轮的外部参数学习,直到满足遗传算法停止条件。

(5) 输出最优的神经网络结构参数(模型外部

参数),同时在给定的训练样本下,通过 BP 算法学习得到神经网络的连接权值(模型内部参数)。

显然,整个参数选择过程均为自动完成,不需要人工干预,因此具有很强的自适应能力。

### 1.1 基于粗糙集理论的样本特征选取

#### 1.1.1 连续属性的离散

粗糙集理论只能对离散数据进行处理,而转子振动数据通常为连续量,因此,需要作离散处理。

定义 1 决策表:决策表是一个通过信息表来进行知识表达的系统,表的列表示属性,表的行表示实例对象。一般来讲,决策表由四部分构成,  $S = U, R, V, f$ 。其中,  $U$  是论域;  $R = C \cup D$  是属性集合,子集  $C$  和  $D$  分别称为条件属性和决策属性;  $V$  为属性值域;  $f: U \times R \rightarrow V$  为一个信息函数,指定了  $U$  中每一个对象的属性值。

设决策种类的个数为  $r(d)$ 。属性  $a$  的值域  $V_a$  上的一个断点可以记为  $(a, c)$ ,其中  $a \in R, c$  为实数。在值域  $V_a = [l_a, r_a]$  上的任意一个断点集合  $\{(a, c_1^a), (a, c_2^a), \dots, (a, c_{k_a}^a)\}$  定义了  $V_a$  上的一个分类  $P_a = \{[c_0^a, c_1^a], [c_1^a, c_2^a], \dots, [c_{k_a}^a, c_{k_a+1}^a]\}$ 。因此,任意的  $P = \prod_{a \in R} P_a$  定义了一个新的决策表  $S^p = U, R, V^p, f^p, f^p(x_a) = i \Leftrightarrow f(x_a) \in [c_i^a, c_{i+1}^a)$ ,对于  $x \in U, i \in \{0, 1, \dots, k_a\}$ ,即经过离散后,原来的信息系统被一个新的信息系统所代替。

转子故障样本集可以看作一个决策表,其特征量为决策表中的条件属性,而故障模式为决策表的决策属性。本文从数据本身出发,利用粗糙集理论的离散方法进行连续属性离散处理。目前, Nguyen 等<sup>[8]</sup>提出的布尔逻辑与粗糙集理论相结合的离散方法是粗糙集理论中离散化思想的重大突破,其基本思想是,在保持信息系统的不可分辨关系不变的前提下,尽量以最小数目的断点把所有实例的分辨关系区分开。Nguyen 等<sup>[9]</sup>在此基础上提出了贪心算法,大大降低了计算的空间和时间复杂度,因此,本文利用贪心算法来实现属性离散。

#### 1.1.2 属性约简

定义 2 不可分辨关系:对于每个属性子集  $B \subseteq R$ ,定义不可分辨二元关系  $IND(B)$ ,即  $IND(B) = \{(x, y) \mid (x, y) \in U^2, \forall b \in B (b(x) = b(y))\}$ 。在粗糙集理论中,不可分辨关系是定义其他概念的基础。

定义 3 基本集:由论域中相互间不可分辨的对象组成的集合,是组成论域知识的颗粒。

定义 4 属性约简:如果  $B \subseteq A$ ,属性集  $A$  和

属性集  $B$  相对于决策属性的分类一致,也就是具有相同的分类能力,这就称  $B$  为  $A$  的相对约简。对于论域  $U$ ,  $P$  和  $Q$  为定义在  $U$  上的两个等价关系簇,且  $Q \subseteq P$ 。如果  $IND(Q) = IND(P)$  且  $Q$  是独立的,则称  $Q$  是  $P$  的一个绝对约简。对于论域  $U$ ,  $P$  和  $Q$  为定义在  $U$  上的两个等价关系簇,  $P$  的所有  $Q$  不可省略的原始关系簇称为  $P$  的  $Q$  核,记为  $CORE_Q(P)$ 。如果记  $P$  的所有  $Q$  约简关系簇为  $RED_Q(P)$ ,则有  $CORE_Q(P) = RED_Q(P)$ 。

通常,在转子故障样本集所形成的决策表信息系统中的知识并不是同等重要的,有些条件属性是冗余的,而冗余属性的存在势必会造成资源的浪费,也对决策判断带来干扰。属性约简的目的就是保留重要的属性,消除这些冗余属性,因此,属性重要程度是对信息决策表进行约简的重要依据。在粗糙集理论中,对于一个属性重要程度的评判完全依赖于论域中的样本,不依赖于先验知识。由于获取所有的属性约简被证明是一个  $N - P$  完全问题,因此,属性约简需要用启发性算法来实现。本文采用基于辨识矩阵的约简方法<sup>[10]</sup>。

### 1.2 神经网络分类器模型

由于在模式识别中,多类问题往往可以转化为两类问题来处理,而且这样做往往会使网络结构简化,训练样本要求减少,训练时间大大缩短等,因此本文神经网络模型为两类模式识别的三层多输入单输出 BP 网络模型。

模型中,用  $(x_1, x_2, \dots, x_n)$  表示输入  $n$  维输入向量,输入向量需要归一化处理,将数值变换到 0 和 1 之间; $y$  为输出,训练样本的取值为“+1”或“-1”,分别代表不同的两类。神经元激活函数均为双极性 Sigmoid 函数,即

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

设神经网络模型的隐层节点数为  $q$ ,隐层节点的激活函数为  $f_H$ 、阈值为  $J_j (j = 1, 2, \dots, q)$ ;输出层节点数为 1,输出层节点的激活函数为  $f_O$ 、阈值为  $J$ 。第  $i$  个隐节点与第  $j$  个输入节点的连接权为  $w_{ij}$ ,第  $i$  个隐节点与输出节点的连接权为  $W_i$ ,则

$$y = f_O \left[ \sum_{i=1}^q W_i f_H \left( \sum_{j=1}^n w_{ij} x_j + J_j \right) + J \right] \quad (2)$$

由两类分类器原理,根据输出  $y$  的值来对样本进行判别分类: $y > 0$ ,判断为是“+1”类; $y < 0$ ,判断为“-1”类; $y = 0$ ,则无法判断。

基于神经网络模型,本文将网络连接权值定义为内部参数,在神经网络学习成功后自动产生。而将网络的结构参数定义为外部参数,包括:

初始权值(影响网络的收敛位置); 隐层节点数(直接影响到所逼近的非线性函数复杂程度和模型的泛化能力); 训练步数(对网络泛化能力具有很大的影响,网络训练步数越多,网络结构越复杂,泛化能力往往将变得很差)。网络的结构参数(外部参数)对其分类性能具有很大的影响,因此需要优化设计。

### 1.3 基于遗传算法的神经网络结构参数优化

在遗传算法中,采用二进制编码,对神经网络中间隐层节点数  $N_M$  和网络训练步数  $N_S$  以及产生初始随机种群的随机种子  $N_R$  进行二进制编码,根据优化参数的取值范围,将其量化值(用二进制串表示)编码成基因串  $a = \{ 0, 1, \dots, B_M - 1; B_M, B_M + 1, \dots, B_M + B_S - 1; B_M + B_S, B_M + B_S + 1, \dots, B_M + B_S + B_R - 1 \}$ ,其中  $a$  中的前  $B_M$  个量化值代表中间隐层节点数  $M$ ,中间的  $B_S$  个量化值代表网络训练步数,后  $B_R$  个量化值代表产生初始随机种群的随机种子  $N_R$ 。所以每个基因串长度为  $B_M + B_S + B_R$  个 bits,此时的搜索空间有  $2^{B_M + B_S + B_R}$  个点。规定解码后,中间隐层节点数加 1 而得到  $M$ ,网络训练步数加 1 而得到  $K$ ,随机种子乘以 10 而得到  $N_R$ 。

由于网络对测试样本的识别结果在一定程度上反映了神经网络泛化能力,因此,定义遗传算法的适应度函数为网络对测试样本的识别率。

另外,遗传算法采用赌轮选择法、均匀交叉法和基本位变异法,其中交叉率一般取 0.5 ~ 0.9,变异率一般取为 0.01 ~ 0.1。

## 2 转子故障诊断实例

### 2.1 转子故障模拟实验台及信号测试

ZT-3 型转子试验台是一个综合性试验台架,由电机、转子、转速控制系统等组成,上面可以灵活地安装振动、位移、转速、加速度等机械参量测量的传感器,进行综合性的工程测试。转子故障测试试验装置如图 2 所示,由电动机带动,通过转速传感器(反射式光电传感器)获知转速,利用电涡流位移传感器采集转子振动模拟信号,利用 DH5922 动态




图 2 转子试验装置信号采集原理图

信号测试分析系统进行模/数变换,将数字信号送给计算机(或数字信号处理器)进行处理。

本文利用 ZL-3 多功能转子故障模拟试验台和 DHDAS 信号测试分析系统获取了不同转速下的不平衡故障样本 25 个、不对中样本 32 个、碰摩样本 30 个及油膜涡动样本 40 个。为了验证本文提出的粗糙集-遗传算法神经网络集成分类器算法的有效性,将故障样本随机分为训练样本集(46 个样本)、测试样本集(43 个样本)及未知样本集(38 个),每个样本集中均包含了不平衡、不对中、碰摩以及油膜涡动 4 种故障。其中,训练样本直接参与神经网络训练;测试样本参与对每次

训练好的神经网络的测试,其识别率作为遗传算法的适应度函数;未知样本参与对优化好的神经网络的识别率的测试,作为最佳神经网络的分类性能评价依据。

### 2.2 转子系统多故障诊断的集成神经网络方法

由于多分类问题可以转化为两分类问题来考虑,且两类问题具有的网络结构简单、训练样本要求少、训练时间短等优点,本文将四分类问题转化为两分类问题,由各子网络分别负责诊断一种故障,最后根据 4 个神经网络的输出来判断最终故障类型。转子故障诊断的集成神经网络模型如图 3 所示。

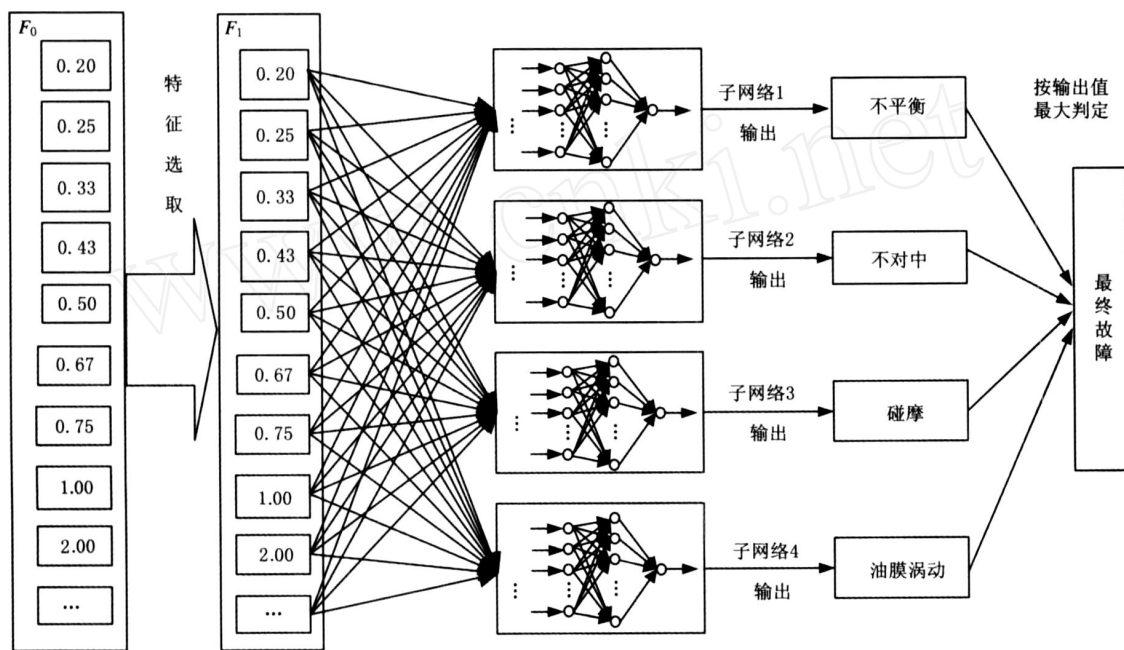


图 3 转子故障诊断的集成神经网络模型

(1) 在每个子网络中,  $(x_1, x_2, \dots, x_m)$  表示  $m$  维输入向量, 分别代表  $m$  个频率特征参数。本文通过频谱分析提取了样本的  $m = 17$  个频谱特征, 它们为 0.2、0.25、0.33、0.43、0.5、0.67、0.75、1、2、3、4、5、6、7、8、9、10 共 17 个, 构成原始特征集合  $F_0$ 。输入向量需要归一化处理, 将数值变换到 0 和 1 之间。

(2) 利用粗糙集理论中的离散和约简算法对 17 个频率特征进行选取, 获取最具有分类能力的特征量, 得到缩减后的样本特征集  $F_1$ 。

(3) 训练样本的构成。对某故障子网络, 属于该故障的样本网络输出为 +1, 属于其他故障的样本则输出为 -1。如对于不平衡故障样本, 不平衡子网络的期望输出为 +1, 而属于其他故障的样本, 不平衡子网络期望输出为 -1。

(4) 子网络识别率计算。对于子神经网络, 由两类分类器原理, 根据输出  $y$  的值来对样本进行

判别分类。 $y > 0$ , 判断为是该损伤类型;  $y < 0$ , 判断为不是该故障;  $y = 0$ , 则无法判断是否为该故障。子网络识别率正确识别样本数与参与测试的样本数目之比。

(5) 集成神经网络总识别率计算。相同的样本特征参数输入到每个子网络后, 每个子网络将产生一个输出  $y_i (i = 1, 2, 3, 4)$ , 对最终的故障类型判别方法为: 如果  $y_i = \max_{k=1,2,3,4} (y_k), y_i > 0$ ,  $N(y_i) = 1$ , 则将最终损伤判别为第  $i$  类损伤, 否则, 该样本作拒识处理。这里,  $N(y_i)$  为满足条件的  $y_i$  的个数。总识别率为正确识别数与参与测试的样本数之比。

### 2.3 粗糙集-遗传算法-神经网络集成分类器对转子系统多故障诊断的诊断结果

利用本文提出的 RS-GS-NN 集成分类器算法以及所构建的集成神经网络诊断模型, 对转

子实验台模拟的包含不平衡、不对中、碰摩以及油膜涡动的 127 个样本进行了诊断实验,结果如表 1~表 4 所示。其中,表 1 所示为不进行特征选取的训练与识别结果;表 2 所示为各子网络外部结构参数的优化结果;表 3 所示为利用通过粗糙集约简后得到的 9 个特征量 (0.2 x、0.43 x、0.5 x、0.75 x、2 x、4 x、5 x、8 x、9 x),对转子故障样本的训练及测试结果;表 4 所示为相应的各子网络外部结构参数的优化结果。

表 1 在所有频谱特征下的训练和识别结果

子网络	样本数据数	训练样本数	测试样本数	未知样本数	对测试样本的识别率 (%)	对测试样本的总识别率 (%)	对未知样本的总识别率 (%)
不平衡	127	46	43	38	93.02	76.74	76.32
不对中	127	46	43	38	90.80		
碰摩	127	46	43	38	88.37		
油膜涡动	127	46	43	38	97.67		

表 2 在所有频谱特征下的经过遗传算法优化后得到的最优子神经网络外部参数

子网络	输入层节点数	中间层节点数	最大训练步数	权值随机种子	训练误差
不平衡	17	12	24	450	0.001
不对中	17	17	13	190	0.001
碰摩	17	6	25	620	0.001
油膜涡动	17	4	17	260	0.001

表 3 通过粗糙集理论约简后的频谱特征下的训练和识别结果

子网络	样本数据数	训练样本数	测试样本数	未知样本数	对测试样本的识别率 (%)	对测试样本的总识别率 (%)	对未知样本的总识别率 (%)
不平衡	127	46	43	38	93.02	88.37	86.84
不对中	127	46	43	38	95.35		
碰摩	127	46	43	38	93.02		
油膜涡动	127	46	43	38	97.67		

表 4 在所有频谱特征下的经过遗传算法优化后得到的最优子神经网络外部参数

子网络	输入层节点数	中间层节点数	最大训练步数	权值随机种子	训练误差
不平衡	9	31	19	380	0.001
不对中	9	17	8	0	0.001
碰摩	9	25	12	450	0.001
油膜涡动	9	28	24	450	0.001

对比表 1 和表 3 可以看出:不经过特征选取,利用 17 个特征一起进行神经网络训练,由于网络输入节点数很大,因此导致神经网络的训练时间很长,然而,通过遗传算法获取的最优网络仍然达到了很高的识别率,各子网络识别率基本上在 85% 左右,对包含 4 种故障的测试样本和未知样本的总识别率分别为 76.74% 和 76.32%;经过特征选取

后,样本的部分冗余信息被消除,神经网络输入节点数大大减少,因此网络不仅训练速度更快,收敛更好,而且其识别率也明显提高了,子网络的识别率均达到了 93% 以上,对包含 4 种故障的测试样本和未知样本的总识别率分别达到了 88.37% 和 86.84%。由此可见,特征选取对转子故障诊断的重要性,尤其在特征量众多的情况下更是如此。

通过计算分析可以看出,本文提出的 RS - GA - NN 集成分类器算法以及转子多故障识别的集成神经网络方案是正确有效的,对于有效识别转子多特征下的多故障具有重要意义。同时,RS - GA - NN 集成分类器的计算具有很强的自适应性,整个计算过程自动完成,无需人工干涉。

### 3 结论

(1) 提出了粗糙集 - 遗传算法 - 神经网络集成分类器模型及其计算流程,并且给出了其关键技术。

(2) 将 RS - GA - NN 集成分类器模型运用于转子故障诊断,构造了实现转子多故障诊断的集成神经网络模型,并对故障诊断流程进行了解释。

(3) 利用 ZL - 3 多功能转子模拟实验台进行了不平衡、不对中、碰摩及油膜涡动故障模拟,获取了包含 4 种故障的 127 个故障样本。利用故障样本,对本文所提出的 RS - GA - NN 集成分类器算法及多故障诊断的集成神经网络模型进行了诊断实验,实验结果充分表明了本文提出的 RS - GA - NN 集成分类器模型和转子多故障诊断的集成神经网络模型的有效性。同时表明了,在转子多特征下的多故障诊断中,特征选取至关重要。

(4) 本文的 RS - GA - NN 集成分类器模型能够有效地实现故障样本的特征选取、神经网络模型的结构自动优化,整个过程自动完成,有效地提高了转子故障诊断的效率。

#### 参考文献:

[1] 陈予恕,田家玉,金宗武,等. 非线性动力学理论与大型火电机组振动故障综合治理技术[J]. 中国机械工程, 1999, 10(9): 1063-1067.

[2] Kalkat M, Yildirim S, Uzmay I. Design of Artificial Neural Networks for Rotor Dynamics Analysis of Rotating Machine Systems [J]. Mechatronics, 2005, 15: 573-588.

[3] Nalinaksh S, Vyas D. Satishkumar. Artificial Neural Network Design for Fault Identification in a Rotor-bearing System[J]. Mechanism and Machine Theory, 2001, 36: 157-175.

# 超声辅助多介质电火花铣削加工机床的研究

苏树朋 张勤河 张建华 霍孟友 艾 兴

山东大学, 济南, 250061

**摘要:**通过分析新型放电介质自身及其与超声复合的电火花加工的独特特点, 得出了超声辅助多介质电火花铣削加工工艺对加工机床的要求。依此提出了机床的整体系统框架, 并详述了该加工机床的机体结构以及控制系统的软硬件结构。初步实验证明, 该加工机床运行稳定, 加工效果明显。

**关键词:**电火花加工; 铣削; 介质; 超声振动; 开放式结构; PMAC

**中图分类号:** TG661 **文章编号:** 1004-132X(2008)01-0090-05

## Research on Ultrasonic Vibration Multi-dielectrics Electrical Discharge Milling Machine Tool

Su Shupeng Zhang Qinhe Zhang Jianhua Huo Mengyou Ai Xing

Shandong University, Jinan, 250061

**Abstract:** Through the analysis of unique machining characteristics of electrical discharge milling (ED - Milling) in distinctive dielectrics with the aid of ultrasonic vibration, the requirements for machine tool were brought forward. On the basis of these requirements, the overall architecture of the new - type EDM machine tool was designed herein. The main machine body, CNC hardware system and CNC software system were described in detail. The initial experiments show that the machine tool works well and has satisfied to the requirements of the new - type EDM process.

**Key words:** EDM; milling; dielectric; ultrasonic vibration; open architecture; PMAC (program multiple axes controller)

## 0 引言

电火花加工 (electrical discharge machining, EDM) 技术已广泛应用于工业生产中<sup>[1]</sup>, 然而, 传统电火花加工多采用油基工作液作为工作介质, 存在着安全隐患和污染问题, 不符合绿色制造理念, 从而制约了电火花加工技术的发展<sup>[2,3]</sup>。为此, 科研人员开始尝试采用新型介质进行电火花

加工, 并取得了可喜的成果。

日本东京农工大学 Masanori 等<sup>[4,5]</sup>打破禁锢人们达半个世纪之久的传统观念, 即工作液是电火花加工中必不可少的要求之一, 创造性地提出了气中电火花加工技术。研究发现, 气中电火花加工技术不仅具有电极损耗率极低、环保安全等优点, 而且在适当条件下, 气中电火花加工的材料去除率并不低于采用煤油基工作液的材料去除率, 因而, 气中电火花加工技术被认为是 21 世纪有可能取得重大突破的绿色加工技术之一<sup>[6]</sup>。

收稿日期: 2007-05-21

基金项目: 国家自然科学基金资助项目 (50575128); 山东省中青年科学家奖励基金资助项目 (2005BS05004)

- [4] 虞和济, 陈长征, 张省, 等. 基于神经网络的智能诊断 [M]. 北京: 冶金工业出版社, 2000.
- [5] 郝丽娜, 王伟, 吴光宇, 等. 粗糙集 - 神经网络故障诊断方法研究 [J]. 东北大学学报, 2003, 24 (3): 252-255.
- [6] Pawlak Z. Rough Set [J]. International Journal of Information and Computer Science, 1982, 11 (5): 341-356.
- [7] Goldberg D. Genetic Algorithms in Search, Optimization and Machine Learning [M]. Reading, MA: Addison - Wesley, 1989.
- [8] Nguyen H S, Skowron A. Quantization of Real Values Attributes, Rough Set and Boolean Reasoning Approaches [C]// Proceeding of the 2nd Joint Annual Conference on Information Science.

Wrightsville Beach, NC, USA, 1995: 34-37.

- [9] Nguyen S H, Nguyen H S. Some Efficient Algorithms for Rough Set Methods [C]// Proc. of the Conference of Information Processing and Management of Uncertainty in Knowledge - Based Systems. Granada, Spain, 1996: 1451-1456.
- [10] 王国胤. 粗糙集理论与知识获取 [M]. 西安: 西安交通大学出版社, 2001.

(编辑 郭伟)

**作者简介:** 陈果, 男, 1972 年生。南京航空航天大学民航学院副教授。主要研究方向为航空发动机状态监测与故障诊断、智能诊断与专家系统、机器学习与知识获取、图像处理及模式识别、非线性转子动力学等。获国家科技进步一等奖 1 项。发表论文 60 余篇。