

# 基于AGA优化RBF神经网络的 矿井通风机故障诊断

余发山 高勇

(河南理工大学电气工程与自动化学院 焦作 454000)

**摘要:** 针对径向基神经网络(RBF)用于故障诊断时存在收敛速度慢、诊断结果准确率低等问题,提出了一种基于自适应遗传算法(AGA)优化RBF神经网络的矿井通风机故障诊断方法。采用AGA对RBF神经网络的隐层节点数、隐层基函数的中心和宽度进行优化,以此提高RBF网络的泛化能力。通过大量收集和整理工作形成样本集,使用训练样本训练RBF网络,根据网络输出结果对通风机故障进行诊断。仿真结果表明,相较于RBF神经网络,AGA优化的RBF神经网络收敛速度更快,迭代次数更少,能够有效识别通风机故障类型,诊断结果准确率更高。

**关键词:** 矿井通风机;故障诊断;自适应遗传算法;神经网络

**中图分类号:** TP183; TN707 **文献标识码:** A **国家标准学科分类代码:** 510.80

## Fault diagnosis of mine ventilator based on AGA optimized RBF neural network

Yu Fashan Gao Yong

(School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China)

**Abstract:** Aiming at the problem that RBF neural network have a slow convergence speed and the diagnostic accuracy is low when applied to fault diagnosis, a fault diagnosis method of mine ventilator based on Adaptive genetic algorithm optimized RBF neural network is proposed. Using adaptive genetic algorithm to optimize the number of hidden layer nodes, the center and width of hidden layer function, and the generalization ability of network is improved. Through a large number of collection and finishing work to form a sample set, using the training sample set to train the network, make fault diagnosis of mine ventilator according to the network output results. The simulation reveals that compared with RBF neural network, the RBF neural network optimized by adaptive genetic algorithm has a faster convergence speed and less number of iterations. It can effectively identify the type of failure, and it has a higher accuracy of fault diagnosis.

**Keywords:** mine ventilator; fault diagnosis; adaptive genetic algorithm; neural network

## 0 引言

作为煤矿生产中的关键设备,矿井通风机具有向矿井输送新鲜空气、稀释瓦斯等危险物质浓度、保障井下矿工生命安全的重要作用,与煤矿安全生产息息相关。因此,通风机的稳定运行和故障监测对煤矿的安全生产具有重要意义。

在矿井通风机故障诊断领域,国内外学者都做了大量的探索与研究。近年来反向传输神经网络(BP)、支持向量机(SVM)等方法被用于通风机的故障诊断。建立BP神经网络通风机故障诊断模型<sup>[1]</sup>,并在此基础上利用蚁群算法

优化BP神经网络的权值和阈值<sup>[2]</sup>,两者都实现了通风机不同故障状态的识别。采用支持向量机学习通风机样本数据形成故障分类器,利用该分类器对通风机故障样本进行检测,从而得出通风机的故障诊断结果<sup>[3]</sup>。

径向基神经网络(RBF)的分类能力和学习速度均优于BP神经网络<sup>[4]</sup>,遗传算法(genetic algorithm, GA)具有良好的搜索效率和全局优化性能。为了进一步提高通风机故障诊断准确率,本文提出了一种基于自适应遗传算法(adaptive genetic algorithm, AGA)优化RBF神经网络的故障诊断方法,并将其应用于矿井通风机的故障诊断。仿真结果表明,AGA优化的RBF神经网络应用于矿井通风

机故障诊断时取得了良好的诊断效果,表明该方法可行。

### 1 RBF 神经网络

RBF 神经网络是一种 3 层前向神经网络,包括输入层、隐含层和输出层。通常选取高斯函数作为径向基函数<sup>[5]</sup>,其解析性好,且任意阶次可微分;隐含层输出依靠输入向量与高斯函数中心的距离,此距离用欧几里德范数表示。当网络输入为  $\mathbf{x}$  时,隐含层输出如式(1)所示。

$$u_i = \exp\left(-\frac{1}{2\sigma_i^2} \|\mathbf{x} - \mathbf{c}_i\|^2\right) \quad i = 1, 2, \dots, m \quad (1)$$

式中:  $u_i$  表示第  $i$  个隐含层节点的输出;  $\mathbf{x}$  为输入样本,  $\mathbf{x} = [x_1, x_2, x_3, x_4, x_5, \dots, x_n]^T$ ;  $\mathbf{c}_i$  为第  $i$  个隐含层节点高斯函数的中心;  $\|\mathbf{x} - \mathbf{c}_i\|$  为欧几里德范数;  $\sigma_i$  为宽度;  $m$  为隐含层节点数。

RBF 神经网络隐含层节点输出的线性叠加构成网络的输出,网络输出如式(2)所示。

$$y_j = \sum_{i=1}^m w_{ij} u_i, \quad j = 1, 2, \dots, p \quad (2)$$

式中:  $y_j$  是第  $j$  个输出层节点的输出,  $w_{ij}$  是第  $i$  个隐含层到第  $j$  个输出层之间的权值,  $p$  为输出层节点数。

RBF 神经网络是局部逼近网络,其模式识别和分类能力强,而且学习速度快<sup>[6]</sup>,因此被广泛应用于故障诊断领域。

### 2 AGA 优化 RBF 神经网络

GA 主要实现过程有染色体编码、创建适应度函数以及遗传操作中的选择、交叉和变异操作<sup>[7]</sup>。其中,交叉概率  $P_c$  和变异概率  $P_m$  严重影响 GA 性能,如果二者选择不当,将会降低 GA 的收敛速度,并且导致早熟收敛。因此,本文采用 Srinivas 等人提出的 AGA,它根据解群体对环境的适应能力,自适应的改变  $P_c$  和  $P_m$ 。通过对  $P_c$  和  $P_m$  的调整,可以保持种群多样性,并且确保 GA 的收敛性<sup>[8]</sup>。

通过分析 RBF 神经网络结构得出,网络隐含层节点数  $m$ 、隐层基函数的中心  $c_i$  和宽度  $\sigma_i$  严重影响 RBF 神经网络的性能,如果选择不当,将会降低 RBF 神经网络解的有效性和准确性<sup>[9]</sup>。因此,本文使用 AGA 优化这 3 个参数,提高 RBF 神经网络样本学习率,保证其全局寻优能力。AGA 优化 RBF 神经网络的主要步骤如下。

#### 1) 确定编码方式

本文采用实数编码,把隐含层节点数  $m$ 、隐层基函数的中心  $c_i$  和宽度  $\sigma_i$  编成染色体,将这 3 个参数的集合看成一个个体,采用随机方式在初始化阶段产生初始群体<sup>[10]</sup>。

#### 2) 选择适应度函数

对网络进行优化是为找到一组最优参数,使训练样本的均方误差和最小<sup>[11]</sup>,因此适应度函数选为:

$$F = \frac{1}{N} \sum_{j=1}^p \sum_{i=1}^N (y_{ji}^d - y_{ji})^2 \quad (3)$$

式中:  $N$  为训练样本总数,  $y_{ji}^d$  和  $y_{ji}$  分别为为第  $i$  个样本的第  $j$  个网络输出节点的期望输出和实际输出。

#### 3) 选择操作

选择操作采用轮盘赌法,个体被选中的概率与其相对适应度有关。设个体  $i$  适应度为  $F_i$ ,种群大小为  $M$ ,则个体  $i$  被选中的概率  $P_i$  为<sup>[12]</sup>:

$$P_i = \frac{F_i}{\sum_{i=1}^M F_i} \quad i = 1, 2, \dots, M \quad (4)$$

#### 4) 确定交叉概率和变异概率

在 AGA 中,当种群个体适应度趋向一致或局部最优时,增加  $P_c$  和  $P_m$ ;当种群适应度较分散时,减少  $P_c$  和  $P_m$ <sup>[13]</sup>。因此,自适应的  $P_c$  和  $P_m$  能够提供相对某个解的最佳  $P_c$  和  $P_m$ 。 $P_c$  和  $P_m$  的计算式分别如式(5)、(6)所示。

$$P_c = \begin{cases} P_{c1} - \frac{(P_{c1} - P_{c2})(f' - f_{avg})}{f_{max} - f_{avg}}, & (f' \geq f_{avg}) \\ P_{c1}, & (f' < f_{avg}) \end{cases} \quad (5)$$

$$P_m = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f_{max} - f)}{f_{max} - f_{avg}}, & (f \geq f_{avg}) \\ P_{m1}, & (f < f_{avg}) \end{cases} \quad (6)$$

式中:  $P_{c1} = 0.9, P_{c2} = 0.6, P_{m1} = 0.1, P_{m2} = 0.001, f'$  为要交叉的两个个体中较大的适应度值,  $f$  为要变异的个体适应度值,  $f_{avg}$  为每代群体的平均适应度值,  $f_{max}$  为群体中的最大适应度值。AGA 优化 RBF 神经网络的流程如图 1 所示。

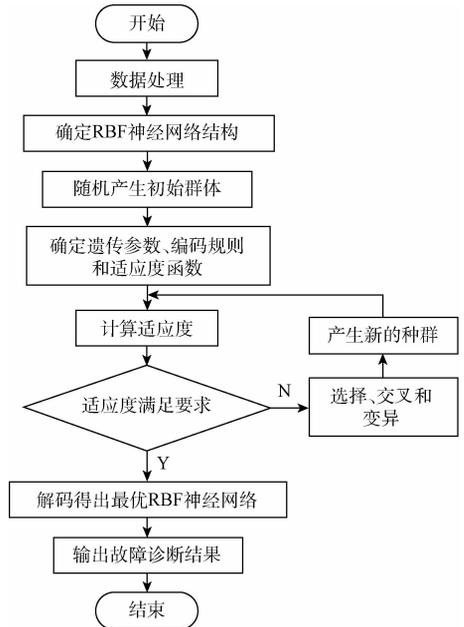


图 1 AGA 优化 RBF 神经网络流程

### 3 通风机故障诊断

作为一种旋转类机械系统,矿井通风机在运行过程中

常常伴有各种频率的机械振动。根据相关研究,矿井通风机的故障信息通常蕴含在振动信号中。当通风机发生故障时,其振动信号的频谱图会发生突变,所以本文将通风机振动信号在不同频段的频谱幅值作为故障信号的特征并将它提取出来,利用通风机不同故障类型对应其振动信号在不同频段内频谱幅值不同的性质,通过分析不同频段的振动信号来判断通风机的故障类型。

故障诊断对象为矿井通风机,诊断过程如下:首先通过振动传感器采集矿井通风机的振动信号,然后对振动信号进行小波包分解和故障特征信息提取,并建立样本集,接下来利用训练样本训练自适应遗传算法优化的RBF神经网络,最后输出训练结果并根据训练结果进行故障诊断。故障诊断流程如图2所示。

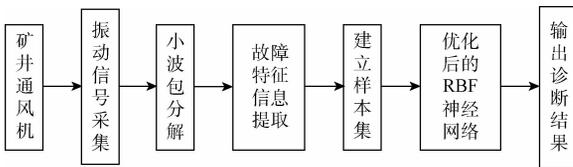


图2 故障诊断流程

### 3.1 确定输入向量和输出向量

由于通风机不同故障类型时其振动信号在不同频段内频谱幅值不同,因此本文以每一种故障振动信号在不同频段的频谱幅值作为RBF神经网络的输入向量。将振动信号划分成8个频段,分别用 $x_1 \sim x_8$ 表示。其中 $x_1$ 表示 $0.01f \sim 0.39f$ , $x_2$ 表示 $0.40f \sim 0.49f$ , $x_3$ 表示 $0.50f$ , $x_4$ 表示 $0.51f \sim 0.99f$ , $x_5$ 表示 $1f$ , $x_6$ 表示 $2f$ , $x_7$ 表示 $3f \sim 5f$ , $x_8$ 表示 $> 5f$ , $f$ 为工频。RBF神经网络的输出对应矿井通风机的故障类型。矿井通风机故障类型有很多,综合考虑通风机自身以及矿井环境等因素,本文选择转子不平衡、转子不对中、机械松动、喘振、动静件碰摩和油膜振荡这6种类型进行通风机的故障诊断。因此,网络输入层节点数为8,对应8个频段 $x_1 \sim x_8$ ;输出层节点数为6,对应6个输出 $y_1 \sim y_6$ 。设定网络的期望输出为“1”时表示通风机有故障,当期望输出为“0”时表示通风机无故障。设定网络的实际输出以0~1的数值表示对应故障发生的概率<sup>[14]</sup>。

针对矿井通风机的故障类型,并结合AGA优化RBF神经网络的故障诊断方法,建立如图3所示的矿井通风机RBF神经网络故障诊断模型。图3中,RBF神经网络的输入为通风机振动信号在 $x_1 \sim x_8$ 这8个频段内的频谱幅值,RBF神经网络的输出为通风机待诊断故障类型 $y_1 \sim y_6$ 。

### 3.2 确定样本集

通过大量的收集和整理工作,得到矿井通风机的学习样本集。在通风机6种故障类型下,每种故障类型分别选取3组数据作为神经网络的训练样本,用来对网络进行训练;然后从样本集中按故障类型再分别选出2组数据作为

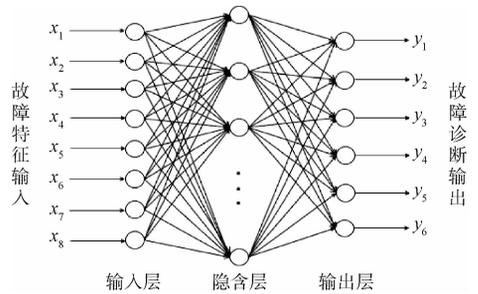


图3 通风机RBF神经网络故障诊断模型

网络的测试样本,用来对网络进行检测。为了便于后期对通风机故障类型进行分析,对不同故障类型设定不同的期望输出。不同故障类型对应的期望输出如表1所示;样本集如表2所示,表2中前18组数据作为训练样本,后12组数据作为测试样本。

表1 故障类型对应的期望输出

故障类型	期望输出					
	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$
转子不平衡	1	0	0	0	0	0
转子不对中	0	1	0	0	0	0
机械松动	0	0	1	0	0	0
喘振	0	0	0	1	0	0
动静件碰摩	0	0	0	0	1	0
油膜振荡	0	0	0	0	0	1

### 3.3 仿真分析

经过MATLAB软件仿真,适应度值变化曲线如图4所示。由图4可以看出,经过16次迭代之后,适应度值无明显变化,达到稳定值0.00094。曲线收敛迅速,收敛效果好。

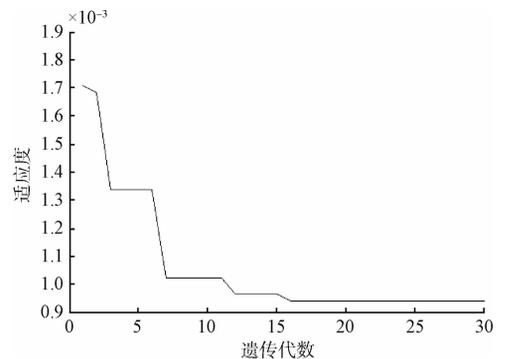


图4 适应度值曲线

RBF网络与AGA-RBF网络训练误差曲线如图5所示。设置目标均方误差值为0.001,当网络误差小于目标误差时,训练停止。

由图5可以看出,基本RBF神经网络收敛速度缓慢,

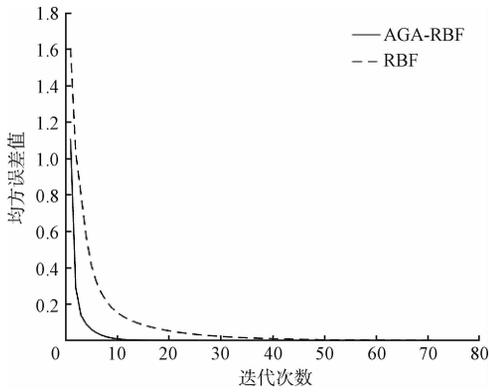


图 5 训练误差曲线对比

在 73 代时迭代结束,网络完成训练,收敛至目标误差值;而 AGA-RBF 网络收敛迅速,仅需 26 次迭代,网络就完成了训练。由图 5 可知,相较于基本 RBF 神经网络,AGA-RBF 神经网络收敛速度更快,迭代次数更少。

接下来利用表 2 中的测试样本作为训练好的神经网络的输入进行通风机故障识别,并通过网络期望输出与实际输出的对比分析来判断通风机故障类型。通过选择适当的判定区间,判定仿真结果归于 1 或 0。当结果  $> 0.9$ , 则判定其为 1;当结果  $< 0.1$ , 则判定其为 0;当结果处于  $0.1 \sim 0.9$  判定为无效分类<sup>[15]</sup>。基本 RBF 网络输出及诊断结果如表 3 所示,AGA-RBF 网络输出及诊断结果如表 4 所示。

表 2 样本集

编号	样本数据								期望输出					
	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$
1	0.000	0.003	0.007	0.001	0.923	0.051	0.004	0.003	1	0	0	0	0	0
2	0.002	0.001	0.004	0.010	0.356	0.619	0.102	0.009	0	1	0	0	0	0
3	0.002	0.002	0.276	0.000	0.630	0.103	0.110	0.000	0	0	1	0	0	0
4	0.912	0.000	0.000	0.008	0.136	0.002	0.011	0.000	0	0	0	1	0	0
5	0.112	0.102	0.000	0.163	0.278	0.164	0.200	0.200	0	0	0	0	1	0
6	0.108	0.836	0.000	0.000	0.000	0.002	0.006	0.003	0	0	0	0	0	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
25	0.006	0.002	0.003	0.000	0.946	0.062	0.001	0.009	1	0	0	0	0	0
26	0.002	0.000	0.008	0.011	0.421	0.634	0.098	0.008	0	1	0	0	0	0
27	0.000	0.001	0.298	0.006	0.688	0.124	0.132	0.004	0	0	1	0	0	0
28	0.924	0.002	0.000	0.009	0.127	0.000	0.018	0.005	0	0	0	1	0	0
29	0.119	0.125	0.000	0.178	0.296	0.187	0.215	0.223	0	0	0	0	1	0
30	0.114	0.845	0.002	0.006	0.000	0.000	0.007	0.010	0	0	0	0	0	1

表 3 RBF 网络输出与诊断结果

编号	期望输出						RBF 网络输出						诊断结果
	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	
19	1	0	0	0	0	0	0.924	0.032	0.021	0.019	0.013	0.006	转子不平衡
20	0	1	0	0	0	0	0.027	0.933	0.021	0.003	0.025	0.012	转子不对中
21	0	0	1	0	0	0	0.038	0.019	0.941	0.046	0.015	0.005	机械松动
22	0	0	0	1	0	0	0.022	0.015	0.008	0.946	0.018	0.023	喘振
23	0	0	0	0	1	0	0.036	0.024	0.016	0.029	0.885	0.012	X
24	0	0	0	0	0	1	0.018	0.027	0.006	0.031	0.015	0.954	油膜振荡
25	1	0	0	0	0	0	0.938	0.042	0.031	0.012	0.026	0.004	转子不平衡
26	0	1	0	0	0	0	0.025	0.964	0.004	0.038	0.029	0.014	转子不对中
27	0	0	1	0	0	0	0.014	0.032	0.945	0.023	0.054	0.002	机械松动
28	0	0	0	1	0	0	0.028	0.017	0.012	0.962	0.025	0.004	喘振
29	0	0	0	0	1	0	0.019	0.018	0.023	0.035	0.916	0.029	动静件碰摩
30	0	0	0	0	0	1	0.052	0.008	0.037	0.029	0.046	0.945	油膜振荡

表4 AGA-RBF网络输出与诊断结果

编号	期望输出						AGA-RBF网络输出						诊断结果
	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	
19	1	0	0	0	0	0	0.984	0.012	0.006	0.011	0.010	0.003	转子不平衡
20	0	1	0	0	0	0	0.014	0.979	0.010	0.006	0.013	0.002	转子不对中
21	0	0	1	0	0	0	0.018	0.009	0.994	0.019	0.005	0.001	机械松动
22	0	0	0	1	0	0	0.011	0.002	0.024	0.995	0.011	0.007	喘振
23	0	0	0	0	1	0	0.015	0.013	0.006	0.014	0.925	0.012	动静件碰摩
24	0	0	0	0	0	1	0.007	0.016	0.003	0.011	0.008	0.969	油膜振荡
25	1	0	0	0	0	0	0.992	0.018	0.017	0.011	0.006	0.015	转子不平衡
26	0	1	0	0	0	0	0.013	0.981	0.021	0.018	0.009	0.011	转子不对中
27	0	0	1	0	0	0	0.007	0.019	0.982	0.013	0.015	0.006	机械松动
28	0	0	0	1	0	0	0.014	0.007	0.012	0.978	0.015	0.005	喘振
29	0	0	0	0	1	0	0.010	0.008	0.015	0.012	0.952	0.018	动静件碰摩
30	0	0	0	0	0	1	0.024	0.004	0.016	0.009	0.021	0.989	油膜振荡

由表3可以看出,基本RBF网络第23组数据输出的一个结果为无效分类,其诊断结果在表3中使用“X”标记,剩余的其他11组数据分类有效,诊断结果正确;表4中的AGA-RBF网络所有的故障样本输出都得到了有效分类,故障诊断结果全部正确。

综合表3和4可以看出,分别采用基本RBF神经网络和AGA-RBF神经网络对矿井通风机进行故障诊断,基本RBF神经网络有错误诊断现象发生,且诊断精度低;而AGA-RBF神经网络诊断结果全部正确,并且相较于基本RBF神经网络具有更高的诊断精度。

## 4 结 论

本文提出了一种基于AGA优化RBF神经网络的矿井通风机故障诊断方法,利用AGA优化RBF神经网络的隐含层节点数、隐层基函数的中心和宽度,提高RBF神经网络的泛化能力,然后将优化后的RBF神经网络应用于矿井通风机的故障诊断。经过仿真验证,相较于RBF神经网络,AGA优化后的RBF神经网络迭代次数更少,收敛速度更快,诊断结果准确率高,诊断结果精度高,满足矿井通风机故障诊断的要求。

## 参考文献

- [1] 江泽标. 人工神经网络在煤矿通风机故障诊断中的应用[J]. 煤矿机械, 2011, 32(7):266-268.
- [2] 黄明, 郭立楠, 朱伟, 等. 基于蚁群算法和BP神经网络的矿井通风机故障诊断[J]. 煤矿机械, 2012, 32(7):258-259.
- [3] 石瑶, 任清阳. 基于支持向量机的矿井通风机故障诊断系统的研究[J]. 自动化与仪器仪表, 2013(5):18-20.
- [4] 林剑锋, 戚金清, 王兢, 等. 几种神经网络在混合气体预测中的比较[J]. 传感器与微系统, 2010, 29(6):25-27.
- [5] 林海军, 滕召胜, 杨进宝, 等. 基于RBF神经网络集

成-模糊加权输出的数字温度传感器误差补偿[J]. 仪器仪表学报, 2011, 32(7):1675-1680.

- [6] 邵婷婷, 张博超, 周美丽, 等. 基于RBF神经网络的测斜仪方位角校正研究[J]. 国外电子测量技术, 2016, 35(2):77-79.
- [7] 仲云飞, 梅一韬, 吴邦彬, 等. 遗传算法优化BP神经网络在大坝扬压力预测中的应用[J]. 水电能源科学, 2012(6):98-101.
- [8] 韩琳, 薛静, 张通. 基于粗糙集神经网络的旋转机械故障诊断[J]. 计算机测量与控制, 2010, 18(1):64-66.
- [9] 刘景艳, 王福忠, 杨占山. 基于RBF神经网络和自适应遗传算法的变压器故障诊断[J]. 武汉大学学报:工学版, 2016, 49(1):88-93.
- [10] 张文广, 徐宇茹, 姜鹏, 等. 基于IGA算法优化的RBF神经网络应用[J]. 海军航空工程学院学报, 2010, 25(3):271-275.
- [11] 余发山, 康洪, 张宏伟. 基于PSO优化BP神经网络的液压钻机故障诊断[J]. 自动化仪表, 2016, 37(4):42-46.
- [12] 郑东耀, 陈曦. 基于小波神经网络的自动调焦方法研究[J]. 电子测量与仪器学报, 2012, 26(5):398-403.
- [13] 刘春, 马颖. 遗传算法和神经网络结合的PSD非线性校正[J]. 电子测量与仪器学报, 2015, 29(8):1157-1163.
- [14] 任静, 黄家栋. 基于免疫RBF神经网络的变压器故障诊断[J]. 电力系统保护与控制, 2010, 38(11):6-9.
- [15] 余发山, 康洪. 基于GA优化BP神经网络的液压钻机故障诊断[J]. 电子测量技术, 2016, 39(2):134-137.

## 作者简介

余发山, 教授, 博士, 硕士生导师, 主要研究方向工业过程控制与电气传动自动化方面。

高勇, 硕士研究生, 主要研究方向电力系统及其自动化。

E-mail: 815919211@qq.com