

文章编号:1671-251X(2013)03-0061-03 DOI:

张飞,何雅琴,张珂.改进 BP 网络在煤矿通风系统故障检测中的应用[J].工矿自动化,2013,39(3):61-63.

# 改进 BP 网络在煤矿通风系统故障检测中的应用

张飞<sup>1</sup>, 何雅琴<sup>2</sup>, 张珂<sup>3</sup>

(1.常州机电职业技术学院 电气工程系,江苏 常州 213164; 2.常州机电职业技术学院 信息工程系,江苏 常州 213164; 3.天地(常州)自动化股份有限公司,江苏 常州 213015)

**摘要:**针对 BP 神经网络传统学习算法步长难以确定的问题,提出了采用基于 RLS 算法的 BP 神经网络检测煤矿通风系统故障的方法;简要介绍了 BP 神经网络的结构,详细介绍了 RLS 学习算法和仿真过程。仿真结果表明,采用 RLS 算法的 BP 神经网络能够满足煤矿通风系统故障检测的要求。

**关键词:**煤矿通风;故障检测;BP 神经网络;RLS 学习算法

中图分类号:TD635 文献标志码:A 网络出版时间:

网络出版地址:

Application of improved BP neural network in fault detection of  
mine ventilation system

ZHANG Fei<sup>1</sup>, HE Ya-qin<sup>2</sup>, ZHANG Ke<sup>3</sup>

(1.Department of Electrical Engineering, Changzhou Institute of Mechatronic Technology, Changzhou 213164, China; 2.Department of Information Engineering, Changzhou Institute of Mechatronic Technology, Changzhou 213164, China; 3.Tiandi (Changzhou) Automation Co., Ltd., Changzhou 213015, China)

**Abstract:**For problem that step of traditional learning algorithm of BP neural network is difficult to determine, the paper proposed a method of using BP neural network based on RLS algorithm to detect fault of mine ventilation system. It introduced structure of the BP neural network briefly, and introduced RLS learning algorithm and simulation process in details. The simulation results show that the BP neural network with RLS algorithm can meet the requirements of fault detection of mine ventilation system.

**Key words:**coal mine ventilation; fault detection; BP neural network; RLS learning algorithm

## 0 引言

瓦斯体积分数超标一直是引发煤矿安全事故的主要原因。《煤矿安全规程》第 136 条规定:采区回风巷、采掘工作面回风巷风流中瓦斯体积分数超过 1.0%或 CO<sub>2</sub> 体积分数超过 1.5%时,必须停止工作,撤出人员,采取措施,进行处理。通风系统的正常运转可以有效降低矿井内的瓦斯体积分数。因此,在通风系统发生故障时,快速有效地定位并修复故障点,可以有效地挽回经济损失,保障矿工生命安全

全。本文针对 BP 神经网络传统学习算法步长难以确定的问题,采用 RLS(Recursive Least Square, 递推最小二乘法)作为网络的学习算法,并将其应用到煤矿通风系统故障检测中。

## 1 BP 神经网络

BP 神经网络由输入层、隐层和输出层组成<sup>[1]</sup>,前后层节点之间采用全连接方式,输出和输入之间没有反馈回路。BP 神经网络模型如图 1 所示<sup>[2]</sup>。

任一神经元的输入和输出之间的关系可用




图1 BP神经网络模型

式(1)表示:

$$Y_k = g\left(\sum_{i=1}^N net(k) + \theta_k\right) \quad (1)$$

式中:  $Y_k$  代表第  $k$  个神经元的输出;  $N$  为输入个数;  $g(\cdot)$  为激活函数;  $net(k) = \omega_{k,i}x_i$ ,  $x_i$  代表神经元的第  $i$  个输入,  $\omega_{k,i}$  为第  $k$  个神经元和第  $i$  个输入之间的权值;  $\theta_k$  为第  $k$  个神经元的阈值。

隐层的激活函数一般选择非线性 S 型函数, 输出层可根据需要选择 S 型函数或线性函数。S 型函数的表达式<sup>[3]</sup>:

$$f(u) = 1/(1 + e^{-u}) \quad (2)$$

神经网络在正式应用之前首先要进行学习, 这是一个信息正向传播、误差反向传播、各层权值不断调整的过程。权值和阈值的调整方法:  $w(k+1) = w(k) + \eta\Delta w$ ,  $\theta(k+1) = \theta(k) + \eta\Delta\theta$ , 其中  $\eta$  为学习率。  $\eta$  越小, 越有利于控制误差, 但学习时间长;  $\eta$  越大, 学习速率加快, 但容易产生震荡, 不利于收敛。

### 2 RLS 学习算法

RLS 学习算法解决了传统 BP 网络的步长选取问题, 算法描述如下<sup>[4]</sup>:

假设期望输出  $d(k)$  和期望输入  $r(k)$  满足关系  $f: r(k) \rightarrow d(k)$ , 则可以推出  $f^{-1}: d(k) \rightarrow r(k)$ 。

定义性能指标为

$$J = 0.5 \sum_{k=1}^N \lambda^{N-k} [d(k) - net(k)]^2 \quad (3)$$

式中:  $\lambda$  为遗忘因子。

神经元的输入输出可用式(4)~(7)表示:

$$net(k) = \mathbf{X}_{t-1}^T \mathbf{W}_u \quad (4)$$

$$x_u(k) = f[net_u(k)] \quad (5)$$

$$\mathbf{X}_{t-1}^T(k) = [x_{1,t-1}(k), x_{2,t-1}(k), \dots, x_{n,t-1}(k)] \quad (6)$$

$$\mathbf{W}_u^T = [w_{u1}^t, w_{u2}^t, \dots, w_{um}^t] \quad (7)$$

$J$  对于  $\mathbf{W}$  的偏微分为 0, 令  $\Phi^T(k) = [\sqrt{\lambda^{N-1}} \cdot \mathbf{X}(1), \dots, \sqrt{\lambda^{N-k}} \mathbf{X}(k)]$ , 则  $\mathbf{W}$  的 LS 估计为

$$\mathbf{W}(k) = [\Phi^T(k)\Phi(k)]^{-1}\Phi^T(k)\mathbf{R}(k) \quad (8)$$

式中:  $\mathbf{R}(k)$  为网络输出。

相应的 RLS 估计为

$$\mathbf{W}_L(k) = \mathbf{W}_{L-1}(k) + \mathbf{M}_{L-1}(k)[\mathbf{r}_L(k) - \mathbf{X}_{L-1}^T(k)\mathbf{W}_{L-1}(k-1)] \quad (9)$$

式中:  $\mathbf{M}_{L-1}(k) = \frac{\mathbf{P}_{L-1}(k)\mathbf{X}_{L-1}(k)}{\lambda + \mathbf{X}_{L-1}^T\mathbf{P}_{L-1}(k)\mathbf{X}_{L-1}(k)}$ ,

$\mathbf{P}_{L-1}(k) = \frac{1}{\lambda[\mathbf{I} - \mathbf{M}_{L-1}(k)]\mathbf{X}_{L-1}^T(k)\mathbf{P}_{L-1}(k-1)}$ , 递推时取  $\mathbf{P}_{L-1}(0) = (10^3 \sim 10^6)\mathbf{I}$ ,  $\mathbf{I}$  为单位矩阵。

对于中间层神经元, 定义期望输入和输出满足关系  $d(k) = f(r(k))$ 。定义反向传播误差为

$$\delta_u(k) = f[net_u(k)][r_u(k) - net_u(k)] \quad (10)$$

相应的神经元期望输入为

$$r_u(k) = f^{-1}[d_u(k)] \quad (11)$$

当  $t=L-1$  时 ( $L$  为神经元所处的层), 对于第  $i$  个神经元, 由于  $\frac{\partial J_u}{\partial \mathbf{W}_{L-1}^T} = 0$ , 令  $\delta_L(k) = r_L(k) - net_L(k)$ , 可得

$$\frac{\partial J_{L-1}}{\partial \mathbf{W}_{L-1}^T} = - \sum \lambda^{N-k}(k)\delta_{L-1}(k)\mathbf{X}_{L-2}(k) = 0 \quad (12)$$

求解式(12)可得到第  $i$  个神经元的连接权系数的 RLS 估计为

$$\mathbf{W}_{L-1}(k) = \mathbf{W}_{L-1}(k-1) + \Delta\mathbf{W}_{L-1} \quad (13)$$

由此递推至  $t=1$ , 可得到 RLS 估计为

$$\mathbf{W}_u(k) = \mathbf{W}_u(k-1) + \mathbf{M}_{L-1}(k)[r_u(k) - net_u(k)] \quad (14)$$

### 3 仿真分析

针对煤矿通风系统中常见的轴不对中、转子不平衡和基础松动这 3 类故障进行仿真。仿真测试采用了参考文献[5]中的数据。训练样本见表 1, 测试样本见表 2, 其中  $C_1 \sim C_8$  代表在不同频段测得的输出值。表中的数据是采用式(15)进行归一化处理<sup>[6]</sup>后的数据。

$$\hat{x} = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (15)$$

由于测试系统有 8 个参数输入网络, 所以 BP 神经网络的输入节点为 8; 隐层的神经元数可依据经验公式  $m=2n+1$  ( $n$  为输入节点数) 计算得到, 这里取 17; 输出神经元的数量依据输出类别决定, 这里取为 4。故障类别和网络输出对应关系见表 3。

在 Matlab7.0 中分别采用传统 BP 神经网络学习算法——trainlm 算法和 RLS 算法进行仿真。在 trainlm 算法中设置最大训练次数为 1 000, 训练精度要求为  $1e-3$ , 学习率为 0.01, 训练迭代过程参数为 10。trainlm 算法和 RLS 算法训练过程如图 2 所示。

表1 训练样本

故障类型	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	C <sub>6</sub>	C <sub>7</sub>	C <sub>8</sub>
正常	0.886 5	0.096 5	0.003 3	0.004 1	0.002 4	0.002 4	0.002 6	0.002 0
正常	0.886 3	0.110 5	0.002 3	0.003 3	0.001 7	0.002 7	0.002 1	0.001 9
轴不对中	0.575 7	0.335 8	0.007 6	0.055 3	0.005 5	0.007 1	0.006 5	0.006 6
轴不对中	0.537 8	0.351 8	0.007 7	0.060 1	0.005 3	0.006 9	0.006 0	0.006 9
转子不平衡	0.795 5	0.173 7	0.002 9	0.019 5	0.001 9	0.002 0	0.002 2	0.002 3
转子不平衡	0.791 5	0.161 2	0.005 2	0.019 4	0.004 5	0.006 3	0.007 1	0.006 4
基础松动	0.072 4	0.076 5	0.527 3	0.219 3	0.111 9	0.114 3	0.738 9	0.302 3
基础松动	0.068 5	0.081 1	0.536 7	0.221 3	0.100 8	0.114 9	0.742 2	0.296 7

表2 测试样本

故障类型	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	C <sub>6</sub>	C <sub>7</sub>	C <sub>8</sub>
正常	0.886 5	0.111 6	0.001 6	0.003 2	0.000 7	0.000 7	0.000 7	0.000 7
轴不对中	0.533 3	0.365 4	0.007 8	0.069 0	0.005 8	0.006 7	0.005 0	0.007 1
转子不平衡	0.781 5	0.151 1	0.009 3	0.021 4	0.008 5	0.008 6	0.009 8	0.009 9
基础松动	0.065 6	0.082 0	0.548 6	0.222 4	0.100 5	0.115 6	0.742 3	0.295 3

表3 故障类别和期望输出的对应关系

状态	期望输出
正常	1,0,0,0
轴不对中	0,1,0,0
转子不平衡	0,0,1,0
基础松动	0,0,0,1

可见,4组输出对应的通风系统状态分别为正常、轴不对中、转子不平衡和基础松动,输出完全正确。

#### 4 结语

瓦斯体积分数超标是诱发煤矿事故的主要原因之一,而通风系统的好坏直接影响瓦斯体积分数。针对传统BP神经网络训练算法的缺点,采用RLS算法作为网络的学习算法,并对所提出的方法进行了仿真验证。仿真结果表明,该算法的效率要优于传统的学习算法,而且经过训练后的网络输出完全能够满足系统的要求。

#### 参考文献:

- [1] 刘超,程国华.基于BP神经网络饲料配料误差补偿模型[J].制造业自动化,2011,33(13):44-47.
- [2] 蒋伟,王小岑.基于BP神经网络的煤矿水泵系统控制方法研究[J].工矿自动化,2011,37(11):10-13.
- [3] 许永建.变压器故障诊断技术研究[D].南京:南京理工大学,2010:9.
- [4] 喻宗泉,喻晗.神经网络控制[M].西安:西安电子科技大学出版社,2009:107-109.
- [5] 朱全,付胜.基于小波包和神经网络的矿用通风机故障预警研究[J].中国矿业,2008,17(3):51-54.
- [6] 柳小桐.BP神经网络输入层数据归一化研究[J].机械工程与自动化,2010(3):122-123,126.




图2 trainlm算法和RLS算法训练过程

从图2可看出,trainlm算法经过19次迭代训练,网络输出误差达到了系统设定要求,而RLS算法只经过6次迭代训练就达到了设定的误差要求。RLS算法的工作效率明显优于trainlm算法。

采用RLS算法训练BP神经网络后,再用表2的测试样本作为输入,实际输出结果见表4。

表4 RLS算法训练后的测试输出数据

实际输出				期望输出
0.995 1	0.001 4	0.003 2	-0.002 5	1000
0.025 5	1.056 2	-0.019 7	0.007 8	0100
-0.000 5	-0.003 5	0.965 4	0.034 1	0010
-0.001 4	0.024 3	-0.009 2	0.984 0	0001