

# 基于 BP 神经网络的多传感器信息融合研究

夏菽兰<sup>1</sup>, 赵力<sup>2</sup>

(1. 盐城工学院 电气工程学院, 江苏 盐城 224051;

2. 东南大学 信息科学与工程学院, 南京 210096)

**摘要:** BP 网络是应用最广的一种人工神经网络, 将 BP 神经网络应用到压力检测领域的温度等非线性补偿, 具有重要的实用价值, 对压力检测精度的改进效果显著; 从传感器信息融合的角度看, 神经网络就是一个融合系统; 通过对神经网络基本理论的阐述, 针对研究对象将 BP 神经网络原理与多传感器信息融合技术有机集合起来, 提出了基于 BP 神经网络的二传感器信息融合模型及改进算法, 建立了 BP 神经网络训练标准样本库, 并对该网络模型进行主要技术指标的测试和仿真工作, 测试结果表明构建的模型及其改进算法能很好地满足了高精度压力检测仪的指标要求。

**关键词:** 压力检测; 信息融合; 多传感器信息融合; BP 神经网络

## Research of Multi-sensor Information Fusion Based on BP Neural Networks

Xia Shulan<sup>1</sup>, Zhao Li<sup>2</sup>

(1. School of Electrical Engineering, Yancheng Institute of Technology, Yancheng 224051, China;

2. College of Information Science and Engineering, Southeast University, Nanjing 210096, China)

**Abstract:** BP network is a kind of the most widely used artificial neural network, it is applied to temperature nonlinear compensation of pressure detecting, has important practical value, and significantly on the improvement of detection accuracy. From the point of view of the sensor information fusion, neural network is a fusion system. Through the exposition of the basic theory of neural network, and based on the principle of BP neural network and multi sensor information fusion technology, the model and the improved algorithm of two sensor information fusion based on BP neural network have been proposed, and training sample database of BP neural network has been established. The main technical parameters of the network model have been tested and simulated, and the results show that the constructed model and its improved algorithm can well meet the requirement of high accuracy pressure detector index.

**Keywords:** pressure detecting; information fusion; multi-sensor information fusion; BP neural networks

## 0 引言

BP (back propagation) 网络, 全称误差逆传播神经网络, 是应用最广的一种人工神经网络。在人工神经网络的 3 种主要分类模型 (分层前向网络、反馈网络和自组织网络) 中, BP 网络属于分层前向网络。它的主要作用是用于函数逼近、模式识别、分类及数据压缩等方面。在压力检测中的作用可以认为是一种函数逼近功能。BP 神经网络是一种具有三层或三层以层次结构的神经网络, 层与层之间, 每个单元都实现权值连接<sup>[1]</sup>, 但是每层各神经元之间不连接。BP 网络是通过信息的正向传播和误差的反向传播构成的。输入大量样本进行有导师学习, 不断减小网络实际输出与期望输出的距离以逼近实际需求。BP 神经网络实现了多层网络学习的设想, 其学习训练过程可归结为: 信息前向传播→误差后向传播→记忆训练→趋向收敛。BP 神经网络有具体的学习规则、明确的数学意义和清晰的算法步骤, 同时还增设了隐含层次, 它对非线性模式有很强的识别能力, 更具有广泛的应用前景。

## 1 基于 BP 网络的二传感器融合模型

高精度压力检测系统的主要目标是最大程度消除温度对压力检测结果的影响。若采用 BP 神经网络对压力传感器和温度传感器进行信息融合, BP 网络的输入参量应该是压力传感器的输出电压值  $U$  和温度传感器测量的温度  $T$ 。而输出参量应该只有一个, 即经过融合以后的压力值  $\hat{P}$ 。关于 BP 网络隐含层的选择, 考虑到网络训练好以后, 需要移植到 ARM 中实现, 因此隐含层结构应尽量简单。本文设定隐含层为单层, 隐含层神经元个数则要根据具体的训练来确定。构建的 BP 神经网络的二传感器信息融合模型如图 1 所示。

对于压力检测仪来说, 输入信号只有一个, 即外界输入的实际压力  $P_{\text{实际}}$ , 该信号作用于压力传感器以后的响应为一个电压值  $U$ , 由于该电压值的大小会受到温度的影响, 需要温度传感器测出工作的实际温度。对于 BP 网络来说, 它的输入信号则是上述压力传感器输出的电压值  $U$  和温度传感器测出的温度  $T$ 。通过一个二输入、单输出的三层 BP 网络不断训练, 得到一个在系统可接受误差范围内的输出值  $P_{\text{融合}}$ 。根据上述分析可知:

$$U = f(P_{\text{实际}}, T) \quad (1)$$

因为  $U$  和  $T$  均为  $P_{\text{实际}}$  的单值函数, 故式 (1) 的反函数存在, 即:

$$P_{\text{实际}} = f^{-1}(U, T) \quad (2)$$

设定训练误差, 对模型中的三层 BP 网络进行训练, 使其

收稿日期: 2014-09-11; 修回日期: 2014-10-13。

基金项目: 国家自然科学基金项目资助(60472058)。

作者简介: 夏菽兰(1969-), 女, 江苏盐城人, 副教授, 硕士, 主要从事电子技术与信息检测技术方向的研究。

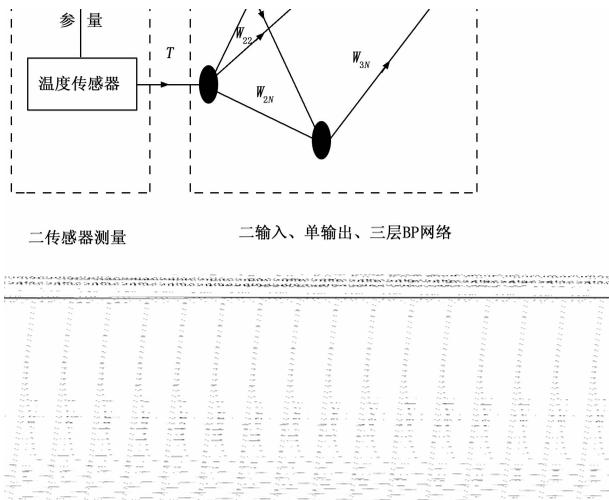


图 1 基于 BP 神经网络的二传感器信息融合模型

逼近式 (2)，这样得到的输出值  $P_{融合}$  可较好地近似于  $P_{实际}$ 。

## 2 BP 神经网络学习算法

根据前述分析本文所用 BP 网络模型的输入层有两个处理单元，输出层有一个单元。隐含层神经元个数未定，设为  $N$ 。对于隐含层的第  $n$  个神经元，设其输入为  $I_{1n}$ ，输出为  $O_{1n}$ 。对于输出层，由于只有一个神经元，设其输入为  $I_2$ ，输出为  $O_2$ 。设定输入层的第一个输入与隐含层的第  $n$  个神经元的连接权值为  $w_{1n}$ ，输入层的第二个输入与隐含层的第  $n$  个神经元的连接权值为  $w_{2n}$ ，隐含层的第  $n$  个神经元与输出神经元的连接权值为  $w_{3n}$ 。

设定输入层神经元为线性，其传递函数为  $f(x) = x$ ，故输入层神经元的输入和输出是相等的。对于隐含层和输出层神经元，选用 S 型传递函数，即  $f(x) = 1/(1 + e^{-x})$ 。

本文 BP 算法的步骤可归纳如下：

1) 设置变量与参量： $X_k = [u_k, t_k]$ , ( $k = 1, 2, \dots, M$ )，为输入训练样本， $M$  为训练样本的个数； $W_a(n) = \begin{bmatrix} w_{11}(n) & w_{12}(n) & \dots & w_{1N}(n) \\ w_{21}(n) & w_{22}(n) & \dots & w_{2N}(n) \end{bmatrix}$  为第  $n$  次迭代时输入层与隐含层之间的权值向量； $W_b(n) = [w_{31}(n) \ w_{32}(n) \ \dots \ w_{3N}(n)]$  为第  $n$  次迭代时隐含层与输出层之间的权值向量； $Y_k(n)$ , ( $k = 1, 2, \dots, M$ ) 为第  $n$  次迭代时网络的实际输出； $P_k$ , ( $k = 1, 2, \dots, M$ ) 为期望输出； $\eta$  为学习速率， $n$  为迭代次数。

2) 初始化，给  $W_a(n)$  和  $W_b(n)$  各赋一个较小的非零值，此时， $n = 0$ 。

3) 随机输入样本  $X_k$ 。

4) 对输入样本  $X_k$ ，前向计算 BP 网络隐含层和输出层的输入、输出信号。

5) 由期望  $P_k$  和上一步求得的  $Y_k(n)$  计算误差  $E(n)$ ，判断其是否满足，若满足转至 7)，若不满足，接着 6)。

6) 判断  $n+1$  是否大于最大迭代次数，若大于转至 7)；否则，反向计算权值修正量  $\Delta w$ ，修正权值， $n = n+1$ ，转到第四步；

7) 判断是否完成所有的训练样本，是则结束，否则转至

3)。

## 3 BP 神经网络算法改进

BP 学习中，学习步长  $\eta$  的选择比较重要，其值越大权值的变化就越大，则 BP 的收敛速度就快，但可能导致网络不稳定； $\eta$  值较小可使网络稳定，但收敛速度会变慢。可见标准 BP 算法有一些明显的缺点，诸如因网络不稳而导致无法训练、网络训练时间长以及可能会陷入局部极小值等。为了克服标准 BP 算法的缺点，可对原有算法进行一些改进。

1) 步长选择对 BP 学习影响很大，过大过小都不好。如果能够是自适应调整学习步长<sup>[2]</sup>，不但能够缩短学习时间，而且可使网络保持稳定。定义可变学习步长为  $\eta(n)$ ，当迭代次数为  $n$  时，误差对权值系数的负梯度为  $-\frac{\partial E(n)}{\partial w(n)} = D(n)$ ，可以得到：

$$w(n+1) = w(n) + \Delta w = w(n) - \eta(n) \frac{\partial E(n)}{\partial w(n)} =$$

$$w(n) + \eta(n) D(n) \quad (3)$$

$\eta(n)$  值的设定规则为：当连续两次迭代的梯度方向相同即  $D(n)D(n-1) > 0$  时，表明梯度下降过慢，可使学习步长加倍，即  $\eta(n) = 2\eta(n-1)$ ；当连续两次迭代的梯度方向相反即  $D(n)D(n-1) < 0$  时，表明梯度下降过快，可使学习步长减半，即  $\eta(n) = 0.5\eta(n-1)$ 。

该方法改变了学习步长设定的盲目性，科学的自适应改变学习步长，提高了学习速度，也减小了收敛时间。

2) 由前文可知，学习步长  $\eta$  选择较大值时，网络的收敛速度加快，但也会导致网络振荡甚至发散。如能在学习步长较大时，找到一种方法来阻止网络振荡，也可以提高 BP 学习的性能。这里考虑加入一个动量项：

$$w(n+1) = w(n) + \eta[(1-\alpha)D(n) + \alpha D(n-1)] \quad (4)$$

这里  $0 \leq \alpha < 1$ ，当  $\alpha = 0$  时即为标准的 BP 学习算法。可见改进后的算法在修正权值  $w(n)$  时，不仅考虑了  $n$  时刻的负梯度  $D(n)$ ，还注重前一次训练的经验积累 ( $n-1$  时刻的经验积累)。加入这样一个阻尼项<sup>[3]</sup>，是对网络振荡的一种平滑，可提高收敛效果。

3) 将以上两种思路相结合可得到一种结合步长调整和阻尼项的新的改进方法，它的算法权值调整表达式如下：

$$w(n+1) = w(n) + 2^{\theta} \eta(n-1)[(1-\alpha)D(n) + \alpha D(n-1)] \quad (5)$$

$D(n)D(n-1) > 0$  时， $\theta = 1$ ； $D(n)D(n-1) < 0$  时， $\theta = -1$ 。

LM 算法即 Levenberg-Marguardt 优化算法，用以最小化那些作为其他非线性函数平方和的函数，这非常适合性能指数是均方误差的神经网络训练。基于 LM 算法的 BP 改进算法使学习时间更短、精度更高。它的权值调整值为： $\Delta w = (J^T J + \mu I)^{-1} J^T e$ ，其中： $e$  为误差向量， $I$  为单位阵， $\mu$  为一个标量， $J$  为关于  $e$  的 Jacobian 矩阵。关于 LM 算法的推导，可参考文献 [4]。本文采用 LM 算法对神经网络进行训练，效果令人满意。基于 MATLAB 的强大功能，选择 MATLAB 神经网络工具箱中 trainlm 函数来实现。

### 4 网络模型及改进算法仿真

#### 4.1 训练样本库的建立

本文 BP 网络的传递函数选择为前述的 S 型函数, 它的值为 (0, 1), 即 BP 网络的期望输出只能趋于 0 和 1, 而不能达到 0 和 1。为了避免网络迅速进入饱和状态而无法继续学习, 网络的输入和输出应该是归一化的数值<sup>[5]</sup>。本文网络的输入是压力检测仪测得的电压  $U$  及温度传感器测得的温度  $T$ , 网络的输出为压力值  $P$ 。对压力检测仪标定数据进行归一化得到 BP 神经网络输入输出的样本库。

#### 4.2 标准 BP 网络及其改进算法仿真与比较

有了输入输出样本库, 就可以完成神经网络的建立和训练等功能, 并将训练好的网络应用到实际的压力检测系统中去。

##### 4.2.1 网络的建立与训练

MATLAB 神经网络工具箱是神经网络应用领域的一款非常便捷的工具。本文用到的算法函数有 `traingd` (标准 bp 算法)、`traindm` (附加阻尼项算法)、`trainlm` (LM 算法) 等。输入 `nntool`, 启动神经网络工具箱管理器。通过执行 `NewNetwork` 建立神经网络, 通过设定 `Inputs` 和 `Targets` 指定网络的输入和期望输出, 进而可以对网络进行初始化 (Initialize)、仿真 (Simulate)、训练 (Train&Adapt)。

1) 建立网络输入输出样本。点击 `NewData`, 按照建立的样本库设定网络的输入和输出;

2) 建立 BP 神经网络。点击 `NewNetwork`, 创建一个新的神经网络, 设定网络类型为 BP 网络 (Feed-forward backprop), 并设定训练函数和传递函数等参数。按照前文的分析, BP 网络设为三层, 输入层的神经元个数为 2, 中间层的神经元个数待定, 输出层的神经元个数为 1;

- 3) 打开建立好的神经网络, 对其初始化, 并进行训练;
- 4) 保存训练好的网络参数, 并移植到压力检测系统。

##### 4.2.2 算法性能比较

前文对标准 BP 算法进行了推导和分析, 并针对该算法的不足进行了改进, 提出了可变学习步长算法、加入动量项算法以及二者相结合算法。另外, 参考相关数学文献, 给出了基于 LM 算法的 BP 神经网络学习算法, 并将其运用到多传感器信息融合领域。

这里对标准 BP 算法、结合可变学习步长及动量项算法和 LM 算法进行仿真。为方便性能比较, 设定网络输出与期望输出的均方误差  $MSE=0.01$ , 仿真结果如图 2~4 所示。

由图 2~4 可见, 标准 BP 算法用了 6 147 次迭代才使得均方误差达到 0.01, 结合可变学习步长及动量项算法则将训练迭代次数大大减少到 86 次, 而基于 LM 的 BP 学习算法仅仅只需要 13 次迭代学习就可以达到设定的训练目标。经过上述性能比较和分析, 本文选用基于 LM 的 BP 学习算法来完成最终的多传感器信息融合。

### 5 融合结果分析

对于高精度压力检测系统, 要求其满量程误差为 0.02%, 这里满量程范围已被归一化为 [0.05, 0.95], 因而, 系统的最大误差不能超过  $\Delta p = 0.02\% * (0.95 - 0.05) = 0.00018$ 。

由于压力检测系统对精度的要求很高, 需要通过不断修改

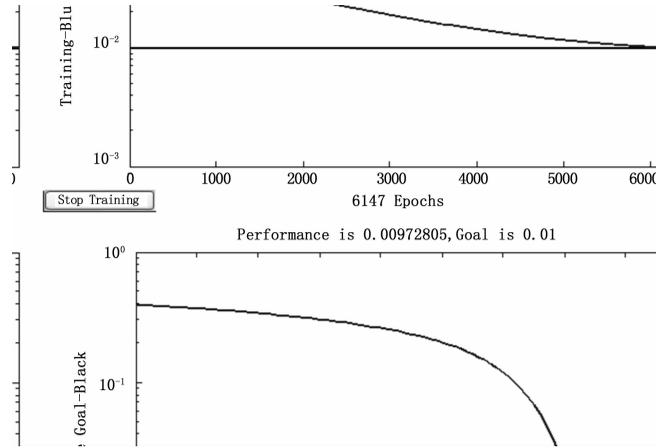


图 2 标准 BP 算法

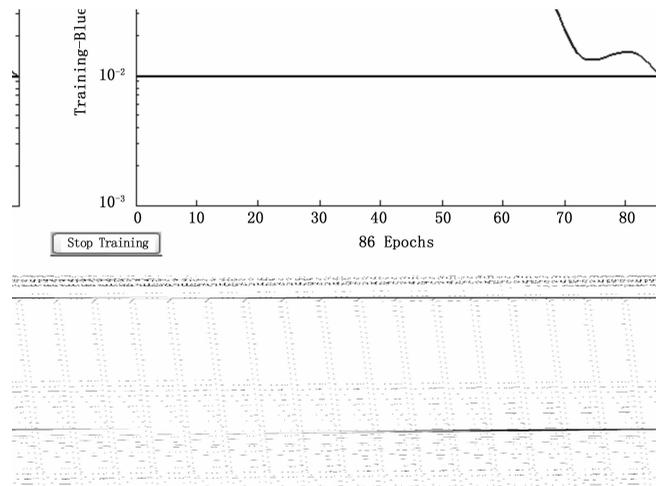


图 3 结合可变学习步长及动量项算法

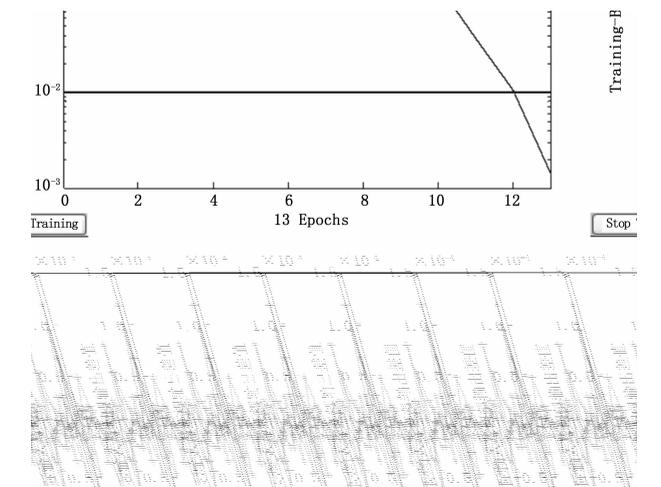


图 4 基于 LM 的 BP 学习算法

隐含层神经元个数获得满足系统精度要求的 BP 网络。隐含层神经元个数的选择过程比较麻烦, 它没有既定的规则, 可借鉴他人经验并经过不断地尝试获得理想的结果。表 1 给出隐含层神经元个数改变时 BP 网络不同的训练效果 (固定迭代次数为

2 000)。BP 网络训练的目标量是均方误差 MSE，它虽然可以反映训练的效果，但不等同于最大误差这个概念。表 1 中记录了训练的最大误差值。由表中数据可以看出，当隐含层神经元个数为 6 时，其归一化后的最大输出误差为 0.00154，相对于满量程来说，误差约为 0.1%，精度比较低。当隐含层神经元个数为 22 时，系统的满量程误差小于 0.02%，满足高精度压力检测系统的要求。

当然隐含层神经元个数的增加伴随而来的一个问题是当该网络移植到 ARM 中时会带来系统复杂度的增加和计算时间的延长，为此需要在精度和运算速度之间取得平衡。

表 1 隐含层神经元个数对训练效果的影响

神经元个数 $N$	6	10	14	18	22
均方误差	$9.7 \times 10^{-8}$	$4.3 \times 10^{-8}$	$8.4 \times 10^{-9}$	$4.7 \times 10^{-9}$	$1.2 \times 10^{-9}$
最大误差	0.00154	0.00083	0.00056	0.00037	0.00013

值得注意的是对于单隐含层 BP 网络，虽然网络训练的效果主要由隐含层神经元的个数决定，但是训练步长的选择以及初始网络权值的设定对结果也有一定的影响。由于神经网络工具箱中对网络权值的初始化是随机的，即使网络结构完全相同，每次训练的结果也不完全一样，有时候网络的性能可以相差一个数量级。以隐含层神经元个数为 12 的网络为例，固定迭代次数为 1 500 次，固定学习步长为 0.1，随机做了 5 次测试，结果如表 2 所示。

表 2 初始权值对训练效果的影响

测试次数	1	2	3	4	5
均方误差	$2.13 \times 10^{-9}$	$1.56 \times 10^{-8}$	$9.23 \times 10^{-10}$	$8.41 \times 10^{-10}$	$2.32 \times 10^{-9}$

由表 2 可知，网络权值的初始值对 BP 网络学习速度和性能有一定的影响。同时经过试验可以发现，改变学习步长也会对 BP 网络的训练速度和学习效果造成影响

综上所述选择 BP 网络结构及对其进行训练时，主要应该考虑隐含层神经元的个数，它对神经网络的性能影响最大。同时还必须考虑学习步长及权值初始值的影响以使训练效果达到最好。一般情况下为了在三者之间取得平衡，需要通过做大量的实验积累经验，并得出一个最终的方案，尚无捷径可走。本文确定使用的 BP 网络具有两个输入、一个输出，中间的隐含层含有 12 个神经元。对该网络进行训练，不断改变初始权值和学习步长以选取一个较好的训练结果。当迭代次数  $N=1\ 628$  时即可获得一次理想的训练，此时系统的均方误差达到  $10^{-9}$ 。训练完成以后，可以得到网络的相关参数： $w\{1, 1\}$ 、 $b(1)$ 、 $w\{2, 1\}$ 、 $b(2)$ 。将上述参数和图 1 所示模型对应起来即为一个训练好的达到高精度性能要求的多传感器信息融合网络。

将该网络移植到 ARM 中去，即可完成压力检测系统消除温度影响的功能。在 ARM 中进行该 BP 网络运算的复杂度量：共需  $22 \times 3=66$  次乘法运算，23 次加法运算，并执行 23 次 S 型传递函数。LPC2478 可以较快地完成上述运算。

将测试数据送入该训练好的网络进行前向计算，得到的误差分布如图 5 所示。从图中可以看出，110 个组测试数据中，最大误差为  $1.3 \times 10^{-4}$ ，其中近 100 组分布在误差小于

0.005% 的范围之内。这说明，将本设计的 BP 神经网络应用到传感器信息融合领域，不仅可以使压力检测系统的满量程误差控制在 0.02% 以内，而且能使系统的泛化能力得以提升，将大多数测量点精度控制在 0.01% 左右。

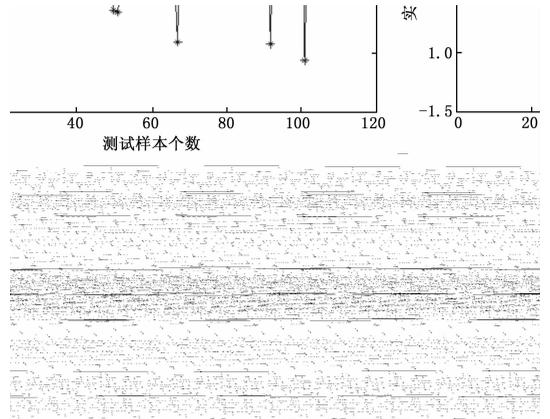


图 5 BP 网络训练误差

对仿真结果进行反归一化运算，反归一化公式如下：

$$P = \frac{(P - 0.05)(P_{\max} - P_{\min})}{0.9} + P_{\min} \quad (6)$$

将网络的输出代入反归一化公式，得到经过 BP 神经网络融合以后的压力值，由测试结果可以得到系统满量程综合误差：

$$\xi = \frac{0.008 \text{ mPa}}{60 \text{ mPa}} \times 100\% = 0.013\% \quad (7)$$

该结果说明采用基于 BP 神经网络的改进算法来融合电压信息和温度信息后，系统的精度提高到 0.02% 之内，性能获得显著提升。

## 6 结束语

本文结合压力检测中的二传感器信息融合技术，提出了基于 BP 神经网络二传感器信息融合模型和改进算法。对该模型进行了详细的仿真，确定了一个具有两输入、单输出、隐含层含有 22 个神经元的 BP 网络结构，得到了网络的各项参数，便于移植到 ARM 平台上。将 BP 神经网络应用到压力检测领域的温度等非线性补偿，具有重要的实用价值，对压力检测精度的改进效果显著。

### 参考文献：

- [1] 张妮, 田学民. LMBP 神经网络改进算法的研究 [J]. 计算机与应用化学, 2010, 27 (8): 1111-1114.
- [2] Zhang Y L. Research on multi-sensor data fusion based on improved BP algorithm [J]. Journal of Southeast University (Natural Science Edition), 2008, 38 (1): 258-261.
- [3] Ishigaki, Tsukasa. An information fusion-based multiobjective security system with a multiple-input/single-output sensor [J]. IEEE Sensors Journal, 2007, 7 (5): 734-742.
- [4] 赵辉, 王秀峰. LM 算法在传感器数据融合中的应用 [J]. 传感器技术, 2005, 24 (5): 77-79.
- [5] Xian Z W, Tao Z, Lei H. Application of fuzzy adaptive back-propagation neural network in thermal conductivity gas analyzer [J]. Neurocomputing, 2010, 7 (3): 579-583.