

基于 BP 神经网络的天平校准数据处理方法研究

车兵辉, 尹欣繁, 彭先敏, 章贵川

(中国空气动力研究与发展中心, 四川 绵阳 621000)

摘要: 针对基于最小二乘法的多项式天平校准公式拟合方法无法消除天平非线性引起的误差, 提出了基于 BP 神经网络的公式拟合方法; 理论分析了典型的 3 层 BP 神经网络的结构和学习原理, 介绍了常规多项式公式拟合和 BP 神经网络公式拟合步骤和方法, 建立了具有 6 个输入节点和 6 个输出节点的三层 BP 神经网络, 采用 C 语言实现了 BP 神经网络的训练过程和自动学习, 并保存训练结果; 采用某六分量天平校准数据, 将天平输出电压值作为 BP 神经网络的输入, 将天平加载载荷作为网络输出对网络进行训练, 并给出了多项式和神经网络方法的计算误差对比结果; 结果表明, 采用神经网络方法拟合精度平均提高了 67%, 可有效消除系统非线性引起的误差, 天平公式拟合精度显著提高。

关键词: BP 神经网络; 天平公式; 拟合

Research on Data Processing Method of Balance Calibration Based on BP Neural Network

Che Binghui, Yin Xinfan, Peng Xianmin, Zhang Guichuan

(China Aerodynamics Research and Development Center, Mianyang 621000, China)

Abstract: In view of the fact that the fitting method of the calibration formula of the polynomial balance based on the least square method cannot eliminate the error caused by the balance nonlinearity, a formula fitting method based on the BP neural network is proposed. The structure and learning principle of typical 3-layer BP neural network are analyzed theoretically, the steps and methods of conventional polynomial formula fitting and BP neural network formula fitting are introduced, and a three-layer BP neural network with 6 input nodes and 6 output nodes is established, the training process and automatic learning of BP neural network are realized by using C language, and save the training results. The calibration data of a six-component balance were used, the output voltage value of the balance was used as the input of BP neural network, the load of the balance was used as the output of the network to train the network, and the comparison results of the calculation error between the polynomial and the neural network method were given. The results show that the error caused by the system nonlinearity can be eliminated effectively by using the neural network method, and the fitting accuracy of the balance formula is improved six-seven percent.

Keywords: BP neural network; balance formula; fitting

0 引言

天平是用于风洞试验中的具有多分量的力传感器, 在使用之前必须对其进行校准和标定, 获取其计算公式。天平的静校是在实验室内模拟天平使用时的受力状态, 通过在各分量上单独加载或组合加载不同的载荷, 获取天平的对应输出电压值, 然后通过插值拟合、解方程等方法获取输入和输出量之间的对应函数。目前普遍采用线性插值拟合的方法获取天平公式^[1], 然而多分量天平各分量之间存在干扰, 在拟合公式是要考虑干扰项, 通常二次干扰和组合干扰会出现非线性特性, 采用线性拟合方法会产生较大误差。

神经网络具有很强的非线性映射和泛化功能, 能够较

好地描述非线性系统和不确定系统。目前神经网络在多领域获得了极其广泛的应用, 尤其是 BP 网络, 即反向传播网络, 使用最为广泛。BP 网络是利用非线性可微分函数进行权值训练的多层网络, 在函数逼近、多维插值、模式识别等领域得到广泛应用^[2]。在系统辨识、传感器非线性修正、传感器校准等方面也有广泛应用。多分量天平是一个典型的多变量传感器, 输入输出关系是一个典型的多输入多输出系统, 因此本文针对多分量天平的特点, 采用 BP 神经网络算法对多分量天平公式拟合方法进行研究, 通过算例验证此方法的应用效果。

1 BP 神经网络

1.1 BP 网络结构

BP 网络 (Back-Propagation Network) 又称反向传播神经网络, 是一种多层的前馈神经网络, 他是一种具有 3 层或 3 层以上的神经网络, 由输入层、中间层、输出层组

收稿日期:2020-03-01; 修回日期:2020-04-02。

作者简介:车兵辉(1982-),男,陕西眉县人,硕士,工程师,主要从事低速风洞测控技术方向的研究。

成, 中间层可以是 1 个也可以是多个, 典型的 3 层网络结构如图 1 所示, 信号从输入层进入顺序经过中间层节点处理, 最后传到输出节点, 同一层内节点互不相连, 且每一层节点都与相邻层所有节点相连, 因此每一层节点只对下一层节点产生影响^[3-6]。其主要的优点是: 信号是前向传播的, 而误差是反向传播的。




图 1 典型的 3 层网络结构

BP 网络采用的传递函数是非线性变换函数——Sigmoid 函数 (又称 S 函数), 即:

$$f(S_j) = \frac{1}{1 + e^{-S_j}}, S_j = \sum_{i=0}^N x_i \omega_{ij} \quad (1)$$

式中, x_i 为神经网络中第 i 个输入, ω_{ij} 为前一层节点 i 至该层节点 j 之间的权值, 输出层传递函数为线性传递函数。

由于 BP 网络采用误差梯度最快下降法, 在计算误差梯度时需要传递函数求偏导, S 函数本身及其导数都是连续的, 因而在处理上十分方便。

1.2 BP 网络算法原理

BP 网络学习算法的基本原理是梯度最速下降法, 他的主要思想是调整网络连接权值, 使网络总误差最小, 也就是采用梯度搜索原理, 寻找合适的连接权值, 使网络的实际输出值与期望输出至误差均方差最小。网络的学习过程是一种误差不断向后传播不断修正权系数的过程。这种学习过程以训练过程, 是网络各神经元连接方式、连接权值和阈值的调整寻优过程, 更是参数辨识过程。学习的方法是使误差达到设定值, 从而获得输入输出数据之间的关系。

BP 网络所有的连接权值和阈值都可以通过学习调节。多层网络学习过程包含正向和反向传播两个阶段, 第一阶段是信号的前向传播, 输入信息从输入层经过中间层逐层处理, 并传到输出层, 每层神经元的输出只影响下一层神经元的状态。如果输出层不能得到期望输出, 则进入第二阶段反向传播, 误差信号从输出层到中间层, 最后到输入层, 依次调节中间层到输出层的权重和阈值, 输入层到中间层的权重和阈值。重复以上两个阶段, 直到系统整体误差最小。

根据以上分析, 多层 BP 网络学习的具体过程和步骤如下:

1) 初始化参数, 给权值和阈值赋予 (0, 1) 区间的随机数。

2) 选取一组输入和目标样本。

3) 用输入样本、权值、阈值逐层计算输出值, 并与期望目标比较, 当误差满足时结束, 否则进行下一步。

4) 根据误差修正权值和阈值, 公式如下:

$$\begin{aligned} v_{ji}(n+1) &= v_{ji}(n) + \lambda d_i^k b_j \\ \gamma_i(n+1) &= \gamma_i(n) + \lambda d_i^k \\ \omega_{ij}(n+1) &= \omega_{ij}(n) + \beta e_j^k x_i^k \\ \theta_j(n+1) &= \theta_j(n) + \beta e_j^k \end{aligned} \quad (2)$$

其中: v 为中间层至输出层连接权值, ω 为输入层至中间层的连接权值, γ 和 θ 分别是输出层阈值和中间层阈值, d 为输出层各节点误差, b 为中间层节点输出, e 为中间层各节点误差, x 为输入层节点输入, λ 和 β 为学习参数, 取之范围为 (0, 1) 区间。

5) 返回步骤 2) 重复, 直到所有样本学习完为止。

网络训练完成后可以获得 v , ω , γ , θ 参数的值, 则网络可表示为:

$$F_i = g \left[\sum_{m=1}^N v_{im} \left[f \left[\sum_{n=1}^N \left(\sum_{m=1}^6 \omega_{nm} S_m + \theta_n \right) \right] \right] + \gamma_i \right] \quad (3)$$

式中, N 为中间层节点数, F_i ($i=1, \dots, 6$) 为输出信号, g 为输出层节点传递函数, f 为中间层节点传递函数, S_m ($m=1, \dots, 6$) 为输入信号。根据上式即可计算出给定输入值对应的输出值。

2 天平校准数据处理方法

2.1 多项式拟合方法

天平的静校是在实验室内模拟天平使用时的受力状态, 对天平施加静态载荷, 通过静校求出天平使用公式、精度和准确度^[7]。

天平加载得到一组施加载荷和相应的电压值输出, 设 F_i ($i=1, \dots, 6$ 表示 6 个分量) 为加载的载荷, S_i ($i=1, \dots, 6$ 表示 6 个分量) 为输出电压值, 则天平公式可表示为:

$$\begin{bmatrix} F_1 \\ F_2 \\ F_3 \\ F_4 \\ F_5 \\ F_6 \end{bmatrix}_{6 \times 1} = \begin{bmatrix} a_1 & a_2 & \dots & a_{27} \\ b_1 & b_2 & \dots & b_{27} \\ \vdots & \vdots & \ddots & \vdots \\ f_1 & f_2 & \dots & f_{27} \end{bmatrix}_{27 \times 6} \begin{bmatrix} S_1 \\ \vdots \\ S_6 \\ S_1^2 \\ S_1 S_2 \\ \vdots \\ S_5 S_6 \\ S_6^2 \end{bmatrix}_{27 \times 1} \quad (4)$$

式中, a_i, b_i, \dots, f_i ($i=1 \dots 27$) 分别为 F_i ($i=1 \dots 6$) 分量的 27 个校准参数。以上关系建立在参数 a_i, b_i, \dots, f_i ($i=1 \dots 27$) 为线性条件下, 加载载荷 F_i 和电压输出值 S_i ($i=1 \dots 6$) 为已知量, 参数 a_i, b_i, \dots, f_i 通过曲线拟合获得^[8-9]。

将上式简写为:

$$[F] = [K][S] \quad (5)$$

则系数矩阵 $[K]$ 可表示为:

$$[K] = [[S]^T[S]]^{-1}[S]^T[F] \quad (6)$$

根据上式可计算出天平公式中的系数矩阵, 从而获得天平计算公式。

以上分析是建立在系数矩阵为线性的, 如果系数矩阵具有非线性特性, 通过上述方法拟合出的计算公式会有较大的误差。

2.2 BP 神经网络拟合方法

天平校准是根据加载已知载荷作为天平系统的输入, 获得的各分量应变计输出电压为输出。天平系统模型是载荷到电压值之间的映射关系, 然而在使用时天平所加载的载荷是未知数, 可获取的是各分量应变计电压值, 需要根据电压值求取载荷值, 因此需要获取电压值到载荷值之间的映射关系, 是天平系统模型的反函数, 天平公式的拟合就是求取天平系统模型的反函数, 图 2 给出了天平公式拟合原理。




图 2 天平公式拟合原理

根据 BP 神经网络具有极强的输入—输出非线性映射能力的特点, 以天平校准获得的各分量应变计输出电压值数据集 $S_i (i=1 \dots 6)$ 为输入样本, 对应的加载载荷 $F_i (i=1 \dots 6)$ 为输出样本, 对神经网络进行训练, 逐层计算输出, 并与目标值比较, 获取误差 e , 根据误差修正各层权重矩阵, 使得拟合误差满足要求, 完成训练过程, 得到各层的连接权重矩阵。在使用时, 根据获得的天平各分量的电压值, 采用式 (3) 即可计算出对应的载荷值。

BP 神经网络中间层节点数可自由设定, 研究表明一个三层网络可实现以任意精度近似任何连续函数。因此采用 BP 神经网络作为天平公式模型是可行的。神经网络训练时加载输入端的数据太大, 会使参数收敛速度慢。此外, 由于在神经网络中采用 S 型函数, 输出范围为 $[0, 1]$, 因此在神经网络训练前对数据进行变换, 使其在区间 $[0, 1]$, 变换公式如下:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

式中, x_i 为输入或输出数据, x_{\min} 为数据样本中的最小值, x_{\max} 为数据样本中的最大值。

建立神经网络天平公式模型的步骤如下:

1) 获取天平校准原始数据。表 1 给出了天平校准时的部分加载载荷数据 (各分量的最大、最小值和零载荷), 每个分量的加载载荷在量程范围内等间隔选取, 六各分量共

计 81 个样本, 表 2 给出了对应的天平输出电压值。

表 1 部分典型加载载荷 $\text{kg}, \text{kg} \cdot \text{m}$

	F1	F2	F3	F4	F5	F6
1	-800	0	0	0	0	0
2	-80	0	0	0	0	0
3	0	20	0	0	0	0
4	0	200	0	0	0	0
5	0	0	-144	0	0	0
6	0	0	144	0	0	0
7	0	0	0	-200	0	0
8	0	0	0	200	0	0
9	0	0	0	0	-122	0
10	0	0	0	0	122	0
11	0	0	0	0	0	-72
12	0	0	0	0	0	72
13	0	0	0	0	0	0

2) 由式 (7) 将原始数据进行归一化, 得到训练神经网络的输入输出样本。

3) 确定神经网络输入输出端数量、各层节点数、 λ 和 β 的值。网络输入端数量与输入层节点数量相同, 输出端数量与输出层节点数相同, 均等于天平的份量个数 (一般为 6)。中间层节点数根据拟合精度确定, 精度要求高时, 取较大值, 反之亦然。中间层数量、 λ 和 β 的值的确定需要结合精度要求、训练效果等确定。根据所确定的输入输出数量建立的网络结构如图 1 所示。

4) 将训练样本输入构建好的网络进行训练, 直到达到要求的精度为止, 保存获得的连接权重和阈值。

5) 将获得的连接权重和阈值带入式 (3) 即可获得天平载荷计算公式。

3 神经网络方法实现及应用

采用 c 语言实现 BP 神经网络的训练, 将训练样本读入程序, 实现自动学习, 并保存训练后的结果。

3.1 神经网络算法实现

根据第 1 节中描述的 BP 神经网络训练步骤编写程序, 图 3 给出了软件实现的流程图。

首先建立网络数据结构并初始化变量, 网络数据结构如下:

```
typedef struct BPNet{
    int LayerNum;//中间层数量
    double ** v;//中间层权矩阵
    double ** w;//输出层权矩阵
    double StudyRate;//学习率
    double * bi;//中间层阈值
    double * bo;//输出层阈值
    double Accuracy;//精度控制参数
    int MaxLoop;//最大循环次数
}BPNet;
```

表 2 对应的天平输出电压值(单位:10 μV)

	S1	S2	S3	S4	S5	S6
1	-9 143.717 29	-126.421 79	-298.521 81	102.053 39	-3.626 95	238.586 91
2	-914.569 01	-12.226 81	-31.510 25	10.290 36	-0.658 37	28.230 31
3	6.548 18	942.791 67	-14.889 81	3.988 12	-6.064 78	3.985 35
4	65.614 58	9437.131 75	-151.149 58	40.200 03	-35.760 09	43.236 98
5	-10.486 65	-0.536 78	-4372.353 35	2.983 24	-6.053 55	46.086 75
6	10.408 20	0.933 43	4 366.841 72	-2.415 04	5.583 01	-70.326 17
7	3.419 27	62.536 78	-23.081 71	-7 831.829 92	164.673 01	-43.285 16
8	-1.693 36	-47.529 87	29.343 26	7 806.208 01	-172.224 77	-8.678 22
9	-0.721 68	-58.134 68	65.726 73	-0.806 32	-6 369.831 05	88.991 37
10	-0.828 45	64.023 44	-61.625 00	1.348 47	6 338.760 91	-59.855 14
11	-2.432 94	2.726 73	-18.991 70	1.193 69	9.110 03	-3 936.089 68
12	1.596 35	-1.153 24	21.266 60	-0.840 66	-17.216 31	3 929.506 84
13	0	0	0	0	0	0

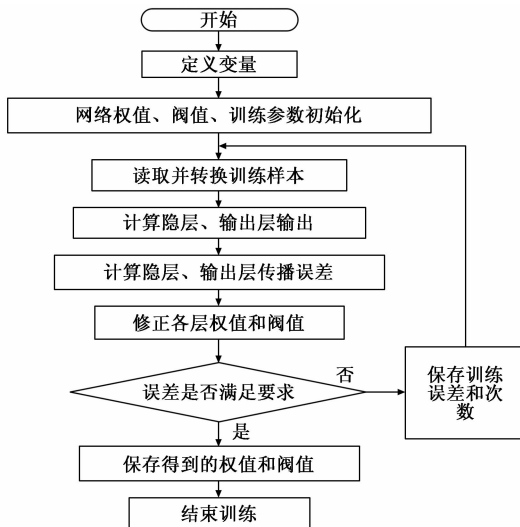


图 3 软件实现的流程图

变量主要有中间层权重矩阵 V 和阈值 bi 、输出层权重矩阵 W 和阈值 bo ，其中 V 为 $m \times n$ 的二维数组， W 为 $n \times r$ 的二维数组， bi 为 n 个元素的一维数组， bo 为 r 个元素一维数组， m 为输入层个数， n 为中间层个数， r 为输出层个数。将这些变量初始化为 (0, 1) 范围内的随机数。

训练过程实现如下：

读取样本并根据式(7)归一化样本数据，初始化学习率 StudyRate、精度 Accuracy 等参数；

```

E=0;//初始化误差
While E>Accuracy do
{
For i=1 to SamplesNumber
{
For k=1 to n//计算中间层输出
{

```

$$S_k = \sum_{j=1}^m x_{ij} v_{jk} + bi_k$$

$$O1_k = \frac{1}{1 + e^{-S_k}}$$

}

For t=1 to r//计算输出层输出

{

$$S_t = \sum_{k=1}^n O1_k w_{kt} + bo_t$$

$$O2_t = \frac{1}{1 + e^{-S_t}}$$

}

计算输出误差 e;

按照式(2)修正权重矩阵和阈值;

}

E=E+e;

}

保存得到的权值矩阵和阈值向量;

训练结束。

3.2 神经网络方法应用

采用某天平的校准数据，共 81 个样本。选用以下参数对网络进行训练：输入层节点数 6，分别为天平 6 个分量（3 个力和 3 个力矩）的电压值，中间层节点数为 10，输出层节点数 6，分别为天平 6 个分量的载荷，学习率 λ 和 β 取 0.001，目标精度 0.001。将样本归一化后输入网络，神经网络学习 16 700 次达到精度要求，图 4 给出了训练收敛特性。

从图中可以看出训练过程能够很好地收敛，训练次数越多精度越高，增加训练次数可进一步提高训练精度。中间层的节点数关系到网络的训练性能，图中也给出了中间层节点数为 15、20、30 时的收敛特性，节点数增加时收敛速度会加快，当节点数为 30 时过程中出现波动，收敛速度




图 4 训练收敛特性

的没有明显变化, 因此节点数的选择不是越大越好, 对于输入向量数较少的网络中间层数量不宜选择过大, 需根据训练结果综合考虑。

为了检验神经网络的训练效果, 选取训练样本中的一部分作为检验样本, 将输入值进行归一化后, 根据式 (3) 计算电压值对应的载荷值, 通过网络计算出的载荷值为归一化后的数据, 要获取实际载荷值, 需要采用训练时的归一化参数进行反归一化, 反归一化公式如下:

$$y_i = y'_i(y_{\max} - y_{\min}) + y_{\min} \quad (i = 1, 2 \dots 6) \quad (8)$$

y_i 为载荷, y'_i 为神经网络计算出的输出值, y_{\max} 为训练样本中输出值的最大值, y_{\min} 为训练样本中输出值的最小值分别采用多项式拟合方法和神经网络方法进行载荷计算, 然后用计算的载荷和实际载荷比较计算误差, 图 5 给出了两种方法计算的误差。图中分别给出了 3 个力 F_y 、 F_x 、

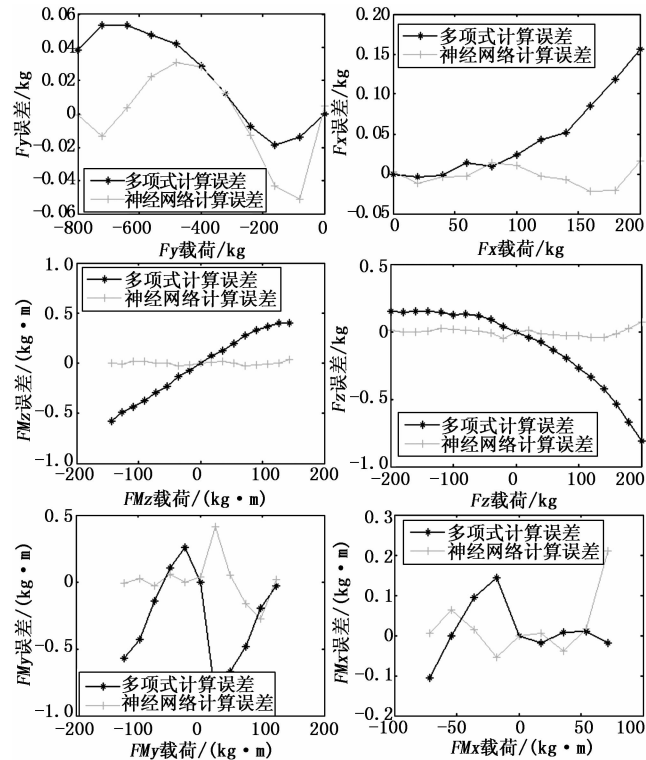


图 5 两种方法计算的误差

F_z , 3 个力矩 FM_z 、 FM_y 、 FM_x 的计算误差, 采用多项式拟合的公式计算误差随着载荷的变化而变化, 误差与载荷相关, 这种误差是由于系统的非线性造成的, 很难通过线性公式修正。采用神经网络方法拟合的公式计算出的载荷平均误差减小 67%, 而且误差基本与载荷无关, 可见神经网络方法可以有效地逼近系统的非线性特性, 消除了由于多项式无法表述系统的非线性特性而带来的误差。

4 结束语

本文通过对天平校准数据的处理和公式拟合方法进行了研究, 提出了 BP 神经网络的拟合方法, 建立了基于神经网络的天平输入输出模型, 通过校准数据对模型进行训练。这种方法充分利用了神经网络的非线性特性、学习能力, 通过样本训练逼近系统的输入输出特性, 有效地克服了系统的非线性误差。结果表明, 采用神经网络模型的天平公式拟合和采用多项式拟合方法相比, 天平公式的计算精度平均提高了 67%, 取得了很好的效果。该方法为天平或其他多变量传感器的校准提供了新的思路。

参考文献:

- [1] 武家驹. 应变天平多元校中几种数据处理方法的比较 [J]. 气动实验与测量控制, 1994, 8 (3): 55-58.
- [2] 郭利辉, 周雅. 基于 MATLAB 神经网络工具箱的 BP 网络设计 [J]. 信息技术与信息化, 2009 (3): 20-22.
- [3] 汪晓东, 万旭, 赵鹏程, 等. 基于神经网络的传感器静态误差综合修正法 [J]. 仪器仪表学报, 1997, 18 (3): 310-313.
- [4] 许弘毅, 郝建, 邓思宇, 等. 基于 BP 神经网络的某防空导弹发射机构故障分析 [J]. 计算机测量与控制, 2019, 27 (12): 124-128.
- [5] 宋廷强, 齐艳丽. 基于 BP 神经网络的智能轮胎标签仿真研究 [J]. 计算机测量与控制, 2017, 25 (8): 170-174.
- [6] 刘鑫, 贾云献, 孙磊, 等. 基于 BP 神经网络的变速箱故障诊断方法研究 [J]. 计算机测量与控制, 2017, 25 (1): 12-15.
- [7] 田力伟. 风洞天平采集校准系统 [D]. 西安: 西北工业大学, 2003.
- [8] Reis M L C C, Vieira W J, Barbosa I M, et al. Validation of an external six-component wind tunnel balance calibration [A]. 24th AIAA Aerodynamic Measurement Technology and Ground Testing Conference [C]. 2004.
- [9] Barbosa I M, et al. External balance calibration curve prediction using polynomial and MLP artificial neural network [A]. 26th AIAA Aerodynamic Measurement Technology and Ground Testing Conference [C]. 2008.