

8-20-2020

Fault Diagnosis for Automobile Coating Equipments Based on Extension Neural Network

Yongwei Ye

College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China;

Shedong Ren

College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China;

Lianqiang Ye

College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China;

Shenhao Ge

College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Fault Diagnosis for Automobile Coating Equipments Based on Extension Neural Network

Abstract

Abstract: Aiming at the difficulty in discovering and eliminating the system faults of automobile coating equipments in time, a new method of fault diagnosis based on extension neural network was proposed. The feature of extension theory was used in managing the structured information through qualitative and quantitative description, and it was also combined by the characteristic of parallel construct in neural network. So the extension reasoning process was completed by means of the parallel distributed processing construct of the network. Matter-element input and output models were established according to the equipment monitoring parameters and fault types for the heating system. And parameter samples were taken into training, and a comparative simulation experiment was made for the result. The experiment reveals that the extension neural network has a simpler construct and can respond faster compared with the traditional neural network.

Keywords

fault diagnosis, neural networks, extenics, heating system

Authors

Yongwei Ye, Shedong Ren, Lianqiang Ye, Shenhao Ge, and Zhiqin Qian

Recommended Citation

Ye Yongwei, Ren Shedong, Ye Lianqiang, Ge Shenhao, Qian Zhiqin. Fault Diagnosis for Automobile Coating Equipments Based on Extension Neural Network[J]. Journal of System Simulation, 2015, 27(3): 542-548.

基于可拓神经网络的汽车涂装线设备故障诊断

叶永伟, 任设东, 叶连强, 葛沈浩, 钱志勤

(浙江工业大学机械工程学院, 杭州 310014)

摘要: 针对汽车涂装线设备故障无法及时发现和排除的困难, 提出基于可拓神经网络的故障诊断方法。该方法利用可拓学定性和定量描述方式处理结构化知识的特性并结合神经网络并行结构的特点, 使可拓神经网络借助并行分布处理结构完成可拓推理过程。依据烘房燃烧加热系统设备监测参数和故障类型, 建立基于可拓神经网络的物元输入、输出模型。将参数样本进行训练, 对训练结果进行仿真对比实验, 实验结果显示该方法相对传统神经网络具有结构简单、反应速度快等优点。

关键词: 故障诊断; 神经网络; 可拓学; 加热系统

中图分类号: TP391

文献标识码: A

文章编号: 1004-731X (2015) 03-0542-07

Fault Diagnosis for Automobile Coating Equipments Based on Extension Neural Network

Ye Yongwei, Ren Shedong, Ye Lianqiang, Ge Shenhao, Qian Zhiqin

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China)

Abstract: Aiming at the difficulty in discovering and eliminating the system faults of automobile coating equipments in time, a new method of fault diagnosis based on extension neural network was proposed. The feature of extension theory was used in managing the structured information through qualitative and quantitative description, and it was also combined by the characteristic of parallel construct in neural network. So the extension reasoning process was completed by means of the parallel distributed processing construct of the network. Matter-element input and output models were established according to the equipment monitoring parameters and fault types for the heating system. And parameter samples were taken into training, and a comparative simulation experiment was made for the result. The experiment reveals that the extension neural network has a simpler construct and can respond faster compared with the traditional neural network.

Keywords: fault diagnosis; neural networks; extenics; heating system

引言

汽车涂装线由前处理系统、电泳系统、烘房系统组成, 是一个具有不确定性、繁杂多变的研究对象。对涂装线进行可靠、准确地监测和潜在故障的

及时预警和诊断是保证各系统设备稳定运行的基本条件。因此, 提高汽车涂装线各系统设备的故障诊断效率是企业急需解决的问题。

在可拓神经网络(Extension Neural Network, ENN)^[1]基础上, 设计一种基于ENN的汽车涂装线设备故障诊断方法。可拓神经网络是继遗传神经网络、模糊神经网络之后的一种新的网络类型, 它集成可拓学和神经网络的优点, 对基于区间特征量值的聚类 and 识别有显著效果。基于该方法, 本文研究分析了涂装线烘房系统设备故障频发的问题。首先



收稿日期: 2014-08-24 修回日期: 2014-11-25;
基金项目: 浙江省自然科学基金(LY12E05025);
作者简介: 叶永伟(1964-), 男, 浙江义乌人, 博士, 副教授, 研究方向为机电系统智能控制, 制造业信息化等; 任设东(1989-), 男, 浙江金华人, 硕士生, 研究方向为机电系统故障诊断与决策。

<http://www.china-simulation.com>

分析ENN模型结构和算法原理,并以烘房燃烧加热系统为例,通过实验验证该方法的有效性。最后将可拓神经网络与BP网络进行对比仿真实验,显示该方法具备的优点,拓展了可拓神经网络的实用性。

1 设备故障诊断方法

目前智能故障诊断技术涉及的学科领域广,主要有基于数学模型的方法、基于知识的方法和基于信号处理的方法3大类^[2]。故障树诊断法是一种由果到因的分析过程,从系统故障状态出发,逐级进行推理分析,最终确定故障发生的基本原因。Cacers等最早研究了基于故障树的故障诊断问题,提出由系统结构框架图建立故障树方法^[3]。刘世前等通过建立操纵控制系统故障树及故障树传播矩阵,研究分析了无人直升机尾部传动轴不对中故障引起的振动与作动器效能降低问题^[4]。基于神经网络的诊断方法,诊断实质是建立从征兆到故障部件的映射过程。BP神经网络广泛用于解决复杂、高度非线性问题,但存在收敛速度慢,易陷入局部极值的缺点。Thukaram等在辐射型配电系统的故障诊断中,通过主成分分析法精简测量数据,并结合神经网络和支持向量机实现故障分类^[5]。基于专家系统的故障诊断方法是利用领域专家在长期实践中积累起来的经验建立知识库,并设计一套计算机程序模拟人类专家的推理和决策过程进行故障诊断。李增芳等实现了以神经网络推理为主的多种人工智能技术集成的发动机故障诊断测试专家系统^[6]。周明等开发了基于模糊推理的分布式电力系统故障诊断专家系统^[7]。基于信号处理的故障诊断是利用各种信号处理方法进行分析处理,提取相关故障信号的时域与频域特征用于故障诊断,主要包括小波变换方法和谱分析方法^[8]。王承等结合小波变换的时频局部化、多尺度分析特性和神经网络非线性映射、学习推理优点,提出基于小波-神经网络的模拟电路故障诊断方法^[9]。林勇等提出了基于形态小波包和双谱分析算法,通过对滚动轴承故障诊断试验,区分出不同类型、不同程度的故障序列^[10]。

基于数学模型的故障树法、神经网络法和基于知识的专家系统以及基于信号处理的小波变换、谱分析等故障诊断方法,在实际应用中都存在着不足的地方。基于数学模型的方法因其建模困难以及模型本身的误差很大程度上影响诊断的准确率;基于专家系统诊断方法无需建立复杂的数学模型,但诊断的准确程度依赖于知识库中专家经验的丰富程度和知识水平的高低,并且当规则过多,推理过程容易出现匹配冲突、组合混乱等问题,降低诊断效率;基于信号处理方法是诊断的基础,但是不具备推理能力,适用于故障监测和简单场合的故障诊断。

基于以上讨论,在可拓神经网络基础上设计一种设备故障诊断方法。可拓理论通过对事物的定性和定量分析来化解不相容问题,为解决故障诊断问题提供了新的工具和算法。杨春燕等利用可拓学理论,建立了系统故障诊断的定性定量分析相结合方法,为计算机进行故障诊断提供可行的物元模型^[11]。Wang等人提出了一种双连接权值的可拓神经网络结构,用于解决基于区间的分类与聚类问题^[1]。张俊彩,周玉等人实现了可拓神经网络方法在变压器故障中的诊断^[12-13]。向长城等结合遗传算法和可拓神经网络开发了励磁系统的故障诊断系统^[14]。

2 可拓神经网络

可拓神经网络(Extension Neural Network, ENN)是将可拓学中的基元理论、可拓距、关联函数等概念引入到神经网络中,使网络具备可拓学定性和定量描述事物的能力及神经网络自学习、并行处理问题的能力。

2.1 可拓学基本概念^[15]

可拓学是以蔡文教授为首的我国学者们创立的新学科,它以形式化的模型,研究事物拓展的可能性和开拓创新的规律与方法。可拓学主要包括可拓论、可拓方法、可拓工程3大部分,其逻辑细胞为物元分析、可拓集合、关联函数。为后续论述方

便，下面介绍可拓学的基本概念。

定义1 以物Nm为对象，cm为特征，Nm关于cm的量值vm构成有序三元组

$$M = (Nm, cm, vm) \quad (1)$$

作为描述物的基本元，称为一维物元。Nm, cm, vm三者为物元M的三要素，其中cm和vm构成的二元组称为物元Nm的特征元。

例如，M=(烘房，温度，110°C)表示汽车涂装线烘房的温度为110°C。当一物有多个特征，则可以定义多维物元。

定义2 设经典域 $X_0 = \langle a, b \rangle$ ，可行域 $X = \langle c, d \rangle$ ， $X_0 \subset X$ ，且两者无公共端点，则对任意的x，令

$$k(x) = \rho(x, X_0) / D(x, X_0, X) \quad (2)$$

称k(x)为点x关于 X_0 和X在 X_0 中点时取最大值的关联函数。

定义中， $X_0 = \langle a, b \rangle$ ， $X = \langle c, d \rangle$ 既可以表示闭区间，也可以表示开区间或半开半闭区间。式中， $\rho(x, X_0)$ 表示点x与区间 $X_0 = \langle a, b \rangle$ 之距，称为可拓距，其计算式为：

$$\rho(x, X_0) = |x - (a+b)/2| - (b-a)/2 \quad (3)$$

$D(x, X_0, X)$ 表示点与两个区间 X_0, X 的位置关系，称为位值，其计算式：

$$D(x, X_0, X) = \begin{cases} \rho(x, X) - \rho(x, X_0) & x \notin X_0 \\ \rho(x, X) - \rho(x, X_0) + a - b & x \in X_0 \end{cases} \quad (4)$$

可拓学中通过关联函数值区分点与区间的隶属程度：当 $k(x) \geq 0$ ，表示x属于 X_0 的程度； $k(x) < 0$ ，表示x不属于 X_0 的程度。正是因为可拓学将“类内即为同”的定性表述发展到类内也有程度区别的定量描述，使特征分类更加准确。

2.2 ENN结构模型

可拓神经网络结构如图1所示，由两层神经元组成，包括输入层和输出层，以及连接两层神经元的连接权值。输入层神经元表示多维物元的特征量值，输出神经元表示特征系统可能发生的故障类型。区别传统神经网络，ENN中每两个输入、输出

神经元间用两个连接权值来调整，两个连接权值分别为某一特征经典域的上下限值。用 w^L 表示经典域下限， w^U 为上限，则连接输入层第j个节点和输出层第k个节点的两个权值可表示为 w_{kj}^L 和 w_{kj}^U 。




图1 可拓神经网络结构

2.3 ENN算法

可拓神经网络通过可拓理论中改进的可拓距作为测度工具，如式(5)所示，用来判别样本特征与距离中心z的相似程度。

$$ED = \frac{|x - z| - (w^U - w^L) / 2}{|(w^U - w^L) / 2|} + 1 \quad (5)$$

特征值在经典域内， $0 \leq ED \leq 1$ ；在经典域外， $ED > 1$ ；图2表示不同特征值在经典域内外的可拓距。从图中可看出，不同经典域区间由于不同的灵敏度，得到不同的可拓距，这在基于区间的分类识别应用中有突出优势。




图2 可拓距离

可拓神经网络采用监督式学习机制，学习系统根据已知输入和实际输出的差值来调整系统参数，从而重新组织已有的知识结构使其不断改善自身性能。可拓神经网络监督学习算法描述如下：

假设样本集 $X = \{X_1, X_2, \dots, X_N\}$, 其中 N 表示样本总数。第 i 个样本表示为 $X_i^p = \{X_{i1}^p, X_{i2}^p, \dots, X_{in}^p\}$, n 表示样本特征总数, P 表示训练样本所属类型。

首先根据可拓理论物元模型确定连接输入、输出神经元的初始权值 W_{kj}^L 和 W_{kj}^U , 并计算相应的中心点 Z_{kj} 。然后, 输入第 i 个样本特征参数及该样本对应类型 P , 通过改进可拓距分别计算样本 X_i^p 和第 K 类的距离, 如式(6):

$$ED_{ik} = \sum_{j=1}^n \left[\frac{|x_{ij}^p - z_{kj}| - (w_{kj}^U - w_{kj}^L) / 2}{|(w_{kj}^U - w_{kj}^L) / 2|} + 1 \right],$$

$$k = 1, 2, \dots, n_c \quad (6)$$

确定 K^* , 使得 $ED_{ik^*} = \text{Min}\{ED_{ik}\}$, 如果 $K^* = P$, 即改进可拓距最小值确实是在 P 类取得, 则计算下一个样本的可拓距, 否则对第 P 类和第 K^* 类所对应的连接权和类中心值进行调整, 如式(7)~(10)。

(1) 连接权调整:

$$\begin{cases} w_{pj}^{L(new)} = w_{pj}^{L(old)} + \eta(x_{ij}^p - z_{pj}^{old}) \\ w_{pj}^{U(new)} = w_{pj}^{U(old)} + \eta(x_{ij}^p - z_{pj}^{old}) \end{cases} \quad (7)$$

$$\begin{cases} w_{k^*j}^{L(new)} = w_{k^*j}^{L(old)} + \eta(x_{ij}^p - z_{k^*j}^{old}) \\ w_{k^*j}^{U(new)} = w_{k^*j}^{U(old)} + \eta(x_{ij}^p - z_{k^*j}^{old}) \end{cases} \quad (8)$$

(2) 类中心值调整:

$$z_{pj}^{new} = z_{pj}^{old} + \eta(x_{ij}^p - z_{pj}^{old}) \quad (9)$$

$$z_{k^*j}^{new} = z_{k^*j}^{old} + \eta(x_{ij}^p - z_{k^*j}^{old}) \quad (10)$$

式中: η 表示学习速度。从算法调整公式中可以发现, 可拓神经网络的学习过程只是调整 P 类和 k^* 类的连接权值, 因此相对于采用其他监督学习算法的传统神经网络具有速度优势, 能够更快地适应新的信息。

3 基于 ENN 的烘房加热系统故障诊断

3.1 燃烧加热系统的 ENN 结构设计

汽车涂装线烘房系统由燃烧加热、热风循环以

及废气处理三个子系统组成, 本文以烘房燃烧加热系统为例, 用基于可拓神经网络结构的设计方法对其进行建模分析, 该系统设备监测结构图如图3所示。根据结构图, 建立输入层维数为12维的输入向量模型, 分别是: F1.1, 风机振动烈度小于0.4f(f 表示风机基频), F1.2(0.4f~0.49f), F1.3(0.5f), F1.4(0.51f~0.99f), F1.5(f), F1.7(3f~4f), 助燃风机出口压力PS3、助燃风机转速n1、助燃风机轴瓦温度T1、调节阀压力PS1、加热温度TW、电机电流A。

通过对烘房加热系统故障经验分析, 该系统的故障包括: 调节阀阻塞Q1、输送管道堵塞Q2、燃气水分含量过多Q3、燃油压力不足Q4、原油含水Q5、电机转子故障Q6。构建输出层维数为6维的输出向量模型。

因此, 烘房加热系统故障诊断 ENN 结构模型中, 网络输入层12个神经元, 输出层6个神经元, 连接权个数144。




图 3 烘房加热系统参数监测

3.2 算法描述

基于 ENN 的烘房加热系统故障诊断算法描述如下:

步骤1 确定 ENN 输入层样本特征及对应输出层故障类型;

步骤2 根据可拓学理论物元模型, 确定连接权上下限值。由式(1), c_j 表示物元对象 N_k 第 j 个特征, $V_{kj} = \langle w_{kj}^L, w_{kj}^U \rangle$ 表示第 k 类故障关于特征 c_j 的经典域。其中:

$$w_{kj}^L = \text{Min}_{i \in N} \{x_{ij}^k\} \quad (11)$$

$$w_{kj}^U = \text{Max}_{i \in N} \{x_{ij}^k\} \quad (12)$$

步骤3 计算每类故障初始中心点:

$$z_k = \{z_{k1}, z_{k2}, \dots, z_{kn}\} \quad (13)$$

$$z_{kj} = (w_{kj}^L + w_{kj}^U) / 2 \quad (14)$$

式中: $j=1,2,\dots,n$; $k=1,2,\dots,n_c$; $n=12, n_c=6$ 。

步骤4 输入第 i 个训练样本特征参数及对应故障类型 P : $X_i^P = \{X_{i1}^P, X_{i2}^P, \dots, X_{im}^P\}$, $P \in n_c$;

步骤5 用改进的可拓距计算式(5)计算样本 X_i^P 与第 k 类之间的可拓距;

步骤6 确定 k^* , 使得 $ED_{ik^*} = \text{Min}\{ED_{ik}\}$, 如果 $k^*=P$, 则转到步骤8, 否则转到步骤7对 P 类和 k^* 类的连接权和类中心值进行调整;

步骤7 按照公式(7)-(10)对第 P 类和第 k^* 类的

连接权和类中心值进行调整;

步骤8 重复步骤4-7, 如果所有样本均训练完, 则完成一个学习步长。

4 实验仿真与讨论

4.1 网络训练

对样本数据进行 ENN 训练, 样本数据来源于文献[16]附录表 A 烘房加热系统的原始监测参数, 通过 PCA^[17] 约简后得到 12 维监测参数, 即输入层的 12 维神经元, 输出神经元为 6 维的故障类型。选取原始数据中的 24 组样本数据, 并对其进行归一化处理以消除不同量纲带来的影响, 数据处理后样本参数如表 1 所示。通过表 1 中的样本数据构造烘房加热系统的故障物元模型, 如表 2 所示。

表 1 数据处理后的训练样本参数

编号	F _{1.1}	F _{1.2}	F _{1.3}	F _{1.4}	F _{1.5}	F _{1.7}	PS3	n1	T1	PS1	TW	A	故障类型
1	0.461 5	0.090 9	0.285 7	0.584 6	0.966 9	0.470 6	1.000 0	1.000 0	0.000 0	1.000 0	0.500 0	1.000 0	Q1
2	0.307 7	0.384 6	0.500 0	0.540 5	0.913 9	0.176 5	1.000 0	1.000 0	0.000 0	1.000 0	0.500 0	1.000 0	Q1
3	0.000 0	0.636 4	1.000 0	0.927 9	0.781 4	0.558 8	0.639 6	1.000 0	0.000 0	0.533 3	0.500 0	1.000 0	Q1
4	0.153 8	0.181 8	0.357 1	0.261 3	0.821 2	0.794 1	0.522 5	0.869 5	0.714 3	0.666 7	1.000 0	0.500 0	Q1
5	0.615 4	0.272 7	0.857 1	0.126 1	0.900 7	0.529 4	0.639 6	1.000 0	0.714 3	0.533 3	0.500 0	0.500 0	Q2
6	0.307 7	0.363 6	0.785 7	0.666 7	0.887 4	0.323 5	0.522 5	0.869 5	0.714 3	0.666 7	1.000 0	0.200 0	Q2
7	0.615 4	1.000 0	0.500 0	0.504 5	0.847 6	0.882 3	0.270 3	0.869 5	1.000 0	0.666 7	1.000 0	0.200 0	Q2
8	0.923 1	0.909 1	0.142 8	0.774 8	0.668 9	0.470 6	0.144 1	0.000 0	1.000 0	0.333 3	0.000 0	0.000 0	Q2
9	0.615 4	0.818 2	0.285 7	0.837 8	0.966 9	0.382 3	1.000 0	1.000 0	0.000 0	1.000 0	0.500 0	1.000 0	Q3
10	0.461 5	0.545 4	0.428 6	0.315 3	0.781 4	0.617 6	1.000 0	1.000 0	0.000 0	1.000 0	0.500 0	1.000 0	Q3
11	0.461 5	1.000 0	0.285 7	0.387 4	0.549 7	0.558 8	0.405 4	0.869 5	1.000 0	0.666 7	1.000 0	0.200 0	Q3
12	0.153 8	0.272 7	0.285 7	0.036 0	0.562 9	0.500 0	0.000 0	0.000 0	1.000 0	0.333 3	0.000 0	0.000 0	Q3
13	0.384 6	0.272 7	0.642 9	0.405 4	0.913 9	0.470 6	1.000 0	1.000 0	0.000 0	1.000 0	0.500 0	1.000 0	Q4
14	0.923 1	0.090 9	0.857 1	0.000 0	0.774 8	0.705 9	0.639 6	0.869 5	0.714 3	0.533 3	1.000 0	0.500 0	Q4
15	0.615 4	0.727 3	0.642 9	0.333 3	0.033 1	0.764 7	0.270 3	0.000 0	1.000 0	0.666 7	0.000 0	0.200 0	Q4
16	0.076 9	0.272 7	0.642 9	0.036 0	0.589 4	0.588 2	0.000 0	0.000 0	1.000 0	0.333 3	0.000 0	0.000 0	Q4
17	0.769 2	0.727 3	0.857 1	0.707 2	0.781 4	0.088 2	0.639 6	1.000 0	0.714 3	0.533 3	0.500 0	0.500 0	Q5
18	0.615 4	1.000 0	0.142 8	0.036 0	0.000 0	0.058 8	0.405 4	0.869 5	0.714 3	0.666 7	1.000 0	0.200 0	Q5
19	1.000 0	0.636 4	0.071 4	0.396 4	1.000 0	0.764 7	0.144 1	0.000 0	1.000 0	0.000 0	0.000 0	0.000 0	Q5
20	0.461 5	0.909 1	0.285 7	0.756 8	0.582 7	0.735 3	0.000 0	0.000 0	1.000 0	0.333 3	0.000 0	0.000 0	Q5
21	0.384 6	0.363 6	0.714 3	0.675 8	0.940 4	0.588 2	1.000 0	1.000 0	0.000 0	1.000 0	0.500 0	1.000 0	Q6
22	0.923 1	0.000 0	0.357 1	0.486 5	0.774 8	0.705 9	0.639 6	0.869 5	0.714 3	0.533 3	1.000 0	0.500 0	Q6
23	0.846 2	0.727 3	0.642 9	0.837 8	0.033 1	0.852 9	0.270 3	0.869 5	1.000 0	0.666 7	0.000 0	0.200 0	Q6
24	0.538 5	0.909 1	0.214 3	0.982 0	0.622 5	0.588 2	0.144 1	0.000 0	1.000 0	0.333 3	0.000 0	0.000 0	Q6

表 2 烘房加热系统故障物元模型

故障类型	物元模型
Q1: 调节阀阻塞	$M_1 = (N_1, C, X_1) = \begin{bmatrix} N_1 & c_1 & <0.0000, 0.4615> \\ & c_2 & <0.0909, 0.6364> \\ & c_3 & <0.2857, 1.0000> \\ & c_4 & <0.2613, 0.9279> \\ & c_5 & <0.7814, 0.9669> \\ & c_6 & <0.1765, 0.7941> \end{bmatrix} + \begin{bmatrix} N_1 & c_7 & <0.5225, 1.0000> \\ & c_8 & <0.8695, 1.0000> \\ & c_9 & <0.0000, 0.7143> \\ & c_{10} & <0.5333, 1.0000> \\ & c_{11} & <0.5000, 1.0000> \\ & c_{12} & <0.5000, 1.0000> \end{bmatrix}$
Q2: 输送管道堵塞	$M_2 = (N_2, C, X_2) = \begin{bmatrix} N_2 & c_1 & <0.3077, 0.9231> \\ & c_2 & <0.2727, 1.0000> \\ & c_3 & <0.1428, 0.8571> \\ & c_4 & <0.1261, 0.7748> \\ & c_5 & <0.6689, 0.9007> \\ & c_6 & <0.3235, 0.8823> \end{bmatrix} + \begin{bmatrix} N_2 & c_7 & <0.1441, 0.6396> \\ & c_8 & <0.0000, 1.0000> \\ & c_9 & <0.7143, 1.0000> \\ & c_{10} & <0.3333, 0.6667> \\ & c_{11} & <0.0000, 1.0000> \\ & c_{12} & <0.0000, 0.5000> \end{bmatrix}$
Q3: 燃气水分含量过多	$M_3 = (N_3, C, X_3) = \begin{bmatrix} N_3 & c_1 & <0.1538, 0.6154> \\ & c_2 & <0.2727, 1.0000> \\ & c_3 & <0.2857, 0.4286> \\ & c_4 & <0.0360, 0.8378> \\ & c_5 & <0.5497, 0.9669> \\ & c_6 & <0.3823, 0.6176> \end{bmatrix} + \begin{bmatrix} N_3 & c_7 & <0.0000, 1.0000> \\ & c_8 & <0.0000, 1.0000> \\ & c_9 & <0.0000, 1.0000> \\ & c_{10} & <0.3333, 1.0000> \\ & c_{11} & <0.0000, 1.0000> \\ & c_{12} & <0.0000, 1.0000> \end{bmatrix}$
Q4: 燃油压力不足	$M_4 = (N_4, C, X_4) = \begin{bmatrix} N_4 & c_1 & <0.0769, 0.9231> \\ & c_2 & <0.0909, 0.7273> \\ & c_3 & <0.6429, 0.8571> \\ & c_4 & <0.0000, 0.4054> \\ & c_5 & <0.0331, 0.9139> \\ & c_6 & <0.4706, 0.7647> \end{bmatrix} + \begin{bmatrix} N_4 & c_7 & <0.0000, 1.0000> \\ & c_8 & <0.0000, 1.0000> \\ & c_9 & <0.0000, 1.0000> \\ & c_{10} & <0.3333, 1.0000> \\ & c_{11} & <0.0000, 1.0000> \\ & c_{12} & <0.0000, 1.0000> \end{bmatrix}$
Q5: 原油含水	$M_5 = (N_5, C, X_5) = \begin{bmatrix} N_5 & c_1 & <0.4615, 1.0000> \\ & c_2 & <0.6364, 1.0000> \\ & c_3 & <0.0714, 0.8571> \\ & c_4 & <0.0360, 0.7568> \\ & c_5 & <0.0000, 1.0000> \\ & c_6 & <0.0588, 0.7647> \end{bmatrix} + \begin{bmatrix} N_5 & c_7 & <0.0000, 0.6936> \\ & c_8 & <0.0000, 1.0000> \\ & c_9 & <0.7143, 1.0000> \\ & c_{10} & <0.0000, 0.6667> \\ & c_{11} & <0.0000, 1.0000> \\ & c_{12} & <0.0000, 0.5000> \end{bmatrix}$
Q6: 电机转子故障	$M_6 = (N_6, C, X_6) = \begin{bmatrix} N_6 & c_1 & <0.3846, 0.9231> \\ & c_2 & <0.0000, 0.9091> \\ & c_3 & <0.2143, 0.7143> \\ & c_4 & <0.4865, 0.9820> \\ & c_5 & <0.0331, 0.9404> \\ & c_6 & <0.5882, 0.8529> \end{bmatrix} + \begin{bmatrix} N_6 & c_7 & <0.1441, 1.0000> \\ & c_8 & <0.0000, 1.0000> \\ & c_9 & <0.0000, 1.0000> \\ & c_{10} & <0.3333, 1.0000> \\ & c_{11} & <0.0000, 1.0000> \\ & c_{12} & <0.0000, 1.0000> \end{bmatrix}$

通过物元模型初始化连接权值, 并按照可拓神经网络的算法步骤对网络进行训练, 其中学习效率 $\eta=0.1$, 训练曲线如图4所示。从ENN对样本数据训练曲线可以看出, 当迭代次数为140次时, 训练精度达到 10^{-6} , 符合训练的精度要求。

4.2 对比分析

为验证可拓神经网络的优越性, 采用相同的样

本数据在传统BP神经网络中进行训练。设定BP神经网络初始参数:

目标误差: $g=10^{-6}$; 隐层节点数 $m=10$;

初始权更新值 $\Delta^{(0)}=0.1$;

增加因子 $\eta_+=1.2$, 减小因子 $\eta_-=0.5$;

最大循环次数: $e=2000$; 最大权更新值

$\Delta_{max}=50.0$ 。




图4 可拓神经网络训练曲线




图5 BP神经网络训练曲线

图5为BP神经网络训练曲线，表3列出了可拓神经网络与BP神经网络的实验仿真比较。

表3 实验对比结果

网络模型	BP神经网络	可拓神经网络
网络结构	12-10-6(3层)	12-6(2层)
学习效率	变学习速率	0.1
连接权个数	180	144
训练步长	250	140
训练精度	10^{-6}	10^{-6}

从实验对比表中可以看出，相对于传统BP神经网络，可拓神经网络在网络结构、学习效率等方面更具有优越性。在网络结构上，BP网络结构为3层，输入层、隐层和输出层，神经元个数分别为12，10，6，连接权个数为180；可拓神经网络结构包含输入、输出层，神经元个数分别为12，6，连接权个数为144。在学习效率上，可拓神经网络迭代140次即可达到精度要求，BP神经网络则需要迭代250次。

5 结论

采用可拓神经网络方法实现对汽车涂装线设备故障诊断，通过对涂装线烘房加热系统的实际数据进行实验仿真，验证了该方法的有效性和可行性。通过对比分析实验，看出可拓神经网络相对于传统神经网络拥有结构简单，能更快达到精度要求等优点。该方法的应用提高了设备故障诊断效率，为汽车涂装线设备故障诊断提供一种新的思路和方法。

参考文献:

- [1] Wang M H, Hung C P. Extension neural network and its applications [J]. Neural Networks (S0893-6080), 2003, 16(5): 779-784.
- [2] 周东华, 胡艳艳. 动态系统的故障诊断技术 [J]. 自动化学报, 2009, 35(6): 748-758.
- [3] Caceres S, Henley E J. Process Failure Analysis by Block Diagrams and Fault Trees [J]. Industrial and Engineering Chemistry Fundamentals (S0888-5885), 1976, 15(2): 128-134.
- [4] 刘世前, 施维, 沈勇, 等. 基于信息熵的纵列式无人直升机故障树诊断 [J]. 系统仿真学报, 2009, 21(14): 4424-4428.
- [5] Thukaram D, Khincha H P, Vijaynarasimha H P. Artificial Neural Network and Support Vector Machine Approach for Locating Faults in Radial Distribution Systems [J]. IEEE Transaction on Power Delivery (S0885-8977), 2005, 20(2): 710-721.
- [6] 李增芳. 基于人工智能和虚拟仪器技术的发动机故障诊断专家系统研究 [D]. 杭州: 浙江大学, 2004.
- [7] 周明, 任建文, 李庚银, 等. 基于模糊推理的分布式电力系统故障诊断专家系统 [J]. 电力系统自动化, 2001, 25(24): 33-36.
- [8] 张萍, 王桂增, 周东华. 动态系统的故障诊断方法 [J]. 控制理论与应用, 2000, 17(2): 153-158.
- [9] 王承, 陈光祚, 谢永乐. 小波-神经网络在模拟电路故障诊断中的应用 [J]. 系统仿真学报, 2005, 17(8): 1936-1938.
- [10] 林勇, 周晓军, 张文斌, 等. 基于形态小波理论和双谱分析的滚动轴承故障诊断 [J]. 浙江大学学报(工学版), 2010, 44(3): 432-439.
- [11] 杨春燕, 何斌. 系统故障的可拓诊断方法 [J]. 广东工业大学学报, 1998, 15(1): 100-105.
- [12] 周玉, 钱旭, 张俊彩, 等. 可拓神经网络研究综述 [J]. 计算机应用研究, 2010, 27(1): 1-5.
- [13] 张俊彩, 钱旭, 周玉. 可拓神经网络在变压器故障诊断中的应用 [J]. 计算机工程与应用, 2011, 47(7): 8-11.
- [14] 向长城, 黄席樾, 殷礼胜, 等. 基于遗传算法与可拓神经网络的故障诊断 [J]. 计算机仿真, 2008, 25(4): 249-252, 266.
- [15] Yang Chunyan, Cai Wen. Extensics: Theory, Method and Application [M]. Beijing, China: Science Press, 2013.
- [16] 刘志浩. 基于PCA和SVM的汽车涂装线机电设备智能诊断 [D]. 杭州: 浙江工业大学, 2012.
- [17] 叶永伟, 刘志浩, 黄利群. 基于PCA的汽车涂装线设备信号特征提取 [J]. 仪器仪表学报, 2011, 32(10): 2363-2370.