

硕 士 学 位 论 文

论文题目 粒子群 RBF 网络在飞
机燃油系统故障诊断
中的应用研究

申请学位专业： 导航、制导与控制

申请学位类别： 工学硕士

分类号：_____ 密 级： 公开

UDC：_____ 学 号： 080212

中国民航大学

硕 士 学 位 论 文

粒子群 RBF 网络在飞机燃油系统故障诊断中的应用研究

研究生姓名： 俞利明

导 师 姓 名： 张 鹏 教授

学位类别： 工学硕士 学科专业名称： 导航、制导与控制

所在院系： 航空自动化学院 论文答辩日期： 2011 年 3 月 11 日

2011 年 3 月 日

Studies On Fault Diagnosis Of Aircraft Fuel System Based On Particle Swarm RBF Network

A Dissertation Submitted to
Civil Aviation University of China
For the Academic Degree of Master of Science

BY
Yu Li-ming

Supervised by
Prof. ZHANG Peng

Aeronautical Automation College
Civil Aviation University of China

March.2011

摘 要

飞机是典型的复杂系统，由于人为失误、材料缺陷、制造误差及使用环境波动等因素的影响以及疲劳、磨损和老化等效应的存在，使飞机在使用过程中不可避免地会发生各种故障，而飞机故障可能会带来灾难性的后果，因此及时准确地对飞机系统故障进行诊断，给出排故策略，提高维修效率，保证其安全正常地运营十分重要。

本文针对飞机故障类型复杂的特点，以波音737飞机的燃油系统作为研究对象，对其故障诊断过程进行分析，运用改进的粒子群算法优化RBF神经网络方法对飞机燃油系统进行故障诊断，以实现飞机设备故障的快速与精确诊断，从而缩短飞机排除故障停场时间，提高航空公司的经济效益。本文主要的研究内容包括：以民航飞机维修手册、维修大纲以及可靠性报告作为故障诊断的知识来源，将三种信息综合考虑，建立民航飞机故障诊断知识复合模型，对飞机燃油系统进行故障分析，整理得到神经网络的训练样本；设计基于粒子群RBF网络的故障诊断模型，采用减聚类算法确定RBF网络隐单元中心的数量，利用粒子群算法优化RBF网络，再以最小二乘法得到相应的中心宽度值，并在Matlab上实现模型仿真，对基于粒子群RBF网络的故障诊断方法进行验证。结果表明该方法可有效地提高故障诊断效率，从而减少因排故导致的航班延误，具有实际应用价值。

关键词：粒子群优化算法；径向基神经网络；故障诊断；飞机燃油系统

Abstract

As a typically complex system, aircraft may inevitably encounter various failures in the course of using because of human error, material defects, manufacturing errors, environmental fluctuations and other factors as fatigue, wear and aging. Therefore, timely and accurately fault diagnosis of aircraft systems and given troubleshooting strategies to improve maintenance efficiency are very important to ensure the safety of normal operations.

For the complex characteristics of the aircraft failure type, this paper takes aircraft fuel system of Boeing 737 as the research object, analyzed the process of fault diagnosis, using particle swarm optimization on RBF neural network fault diagnosis of aircraft fuel systems in order to achieve rapid and accurate diagnosis. This method can reduce the time of aircraft troubleshooting and improve the economic efficiency of airlines. Specifically: taking the civil aircraft maintenance manual, maintenance program and the reliability of the report as fault diagnosis knowledge sources to build a knowledge composite model of civil aviation fault diagnosis, then analysis the aircraft fuel system fault to get neural network training sample. Design RBF network based on particle swarm optimization model for fault diagnosis, by this step, this paper uses the subtractive clustering algorithm to determine the number of hidden units of RBF networks, uses particle swarm algorithm to optimize RBF network, then calculate the center's width value with the least square method, in the last part, implement model simulation on Matlab to verify the fault diagnosis method based on particle swarm RBF network. The results show that with this method can effectively improve the efficiency of fault diagnosis and reduce the flight schedule due to flight delays, it has practical value.

Keywords: particle swarm optimization; RBF neural network; fault diagnosis; aircraft fuel system

目 录

摘 要.....	I
Abstract.....	II
第一章 绪论.....	1
1.1 选题背景及意义.....	1
1.2 民航飞机的故障诊断特点及要求.....	2
1.2.1 故障诊断概述.....	2
1.2.2 飞机故障来源及特点.....	3
1.2.3 飞机故障诊断的特点.....	3
1.2.4 民航飞机一般排故流程.....	4
1.3 国内外的研究现状.....	5
1.3.1 飞机智能故障诊断技术研究现状.....	5
1.3.2 神经网络应用于故障诊断的优势与不足.....	6
1.3.3 神经网络优化研究现状.....	7
1.4 本文的所做的工作及内容安排.....	9
第二章 飞机燃油系统与故障分析.....	10
2.1 飞机燃油系统概述.....	10
2.2 飞机燃油系统的部件.....	11
2.3 飞机燃油系统的子系统.....	12
2.3.1 燃油储存系统.....	12
2.3.2 压力加油系统.....	13
2.3.3 发动机供油系统.....	14
2.3.4 APU 供油系统.....	15
2.3.5 抽油系统.....	16
2.3.6 燃油量指示系统.....	17
2.3.7 燃油温度指示系统.....	17
2.4 飞机燃油系统故障分析.....	17
2.5 本章小结.....	19
第三章 基本粒子群优化算法及其改进.....	20
3.1 基本粒子群优化算法.....	21
3.1.1 算法的基本原理.....	21
3.1.2 算法流程.....	22
3.2 粒子群优化算法的改进.....	24
3.2.1 惯性权重的引入.....	24

3.2.2 收缩因子的引入.....	26
3.2.3 扰动因子的引入.....	26
3.2.4 粒子群算法的综合改进.....	27
3.3 改进前后粒子群算法的比较.....	28
3.4 本章小结.....	28
第四章 基于粒子群算法的 RBF 网络.....	30
4.1 径向基神经网络.....	30
4.1.1 径向基网络的结构及数学模型.....	30
4.1.2 RBF 网络的参数分析.....	32
4.1.3 RBF 神经网络的泛化能力分析.....	32
4.2 进化算法在神经网络优化中的应用.....	33
4.3 PSO 算法应用于 RBF 神经网络的详细设计.....	34
4.3.1 粒子编码.....	34
4.3.2 减聚类算法确定网络中心个数.....	35
4.3.3 粒子群 RBF 网络的参数设置.....	36
4.3.4 最小二乘法确定网络权值.....	38
4.3.5 PSO 算法优化 RBF 神经网络的流程.....	39
4.4 粒子群 RBF 网络的性能评价指标.....	40
4.5 本章小结.....	41
第五章 粒子群 RBF 神经网络在飞机燃油系统故障诊断中的应用.....	42
5.1 飞机燃油系统故障诊断的知识来源.....	42
5.2 故障诊断的知识复合模型设计.....	43
5.3 飞机燃油系统故障特征向量设计.....	43
5.4 故障诊断流程框图设计.....	44
5.5 粒子群优化 RBF 神经网络故障诊断算法的 Matlab 实现.....	45
5.5.1 粒子群优化 RBF 神经网络的初始化.....	45
5.5.2 粒子群优化 RBF 神经网络的适应度值.....	46
5.5.3 粒子群优化 RBF 神经网络的粒子速度和位置计算.....	47
5.5.4 粒子群优化 RBF 神经网络的粒子适应度值更新.....	47
5.5.5 粒子群优化 RBF 神经网络的速度和位置更新.....	48
5.6 基于粒子群 RBF 网络的燃油系统故障诊断实现.....	48
5.6.1 粒子群优化 RBF 神经网络设计.....	48
5.6.2 RBF 网络的训练及诊断结果分析.....	49
5.7 本章小结.....	52

结论.....	53
致谢.....	55
参考文献.....	56
作者简介.....	59

第一章 绪论

1.1 选题背景及意义

飞机是典型的复杂系统，由于人为失误、材料缺陷、制造误差及使用环境波动等因素的影响以及疲劳、磨损和老化等效应的存在，在飞行过程中不可避免地会发生各种故障，而飞机故障可能会带来灾难性的后果，因此故障诊断对保证其安全正常地运营十分重要。

现代飞机综合应用了机械、电子、计算机及自动控制等多学科的先进技术，而且结构层次很多，它的故障诊断具有涉及专业领域多、诊断难度大、要求时间短等特点，对诊断人员要求较高，往往需要多位专家的参与。此外，随着我国民航业的迅速发展，各个航空公司机队的规模不断扩大，使飞机维修工作量增长很快。而且随着我国航空公司机队部分飞机的老龄化，维修任务进一步增加，使维修专家缺乏的问题更加突出，在一定程度上影响到了飞机安全正常地营运。

飞机系统故障常是偶然地发生于飞行、周期性维护工作和各种机务准备的过程中。一般情况下，根据外观征兆不能直接得出哪一个部件有故障或需要加以调整、修理、更换的结论，有的飞行中发生的故障，地面检查时往往还难以再现。目前，飞机外场的故障诊断基本上是靠人工完成，维修人员依据故障信息和各种外观征兆，通过查阅排故手册，按相应故障隔离程序，用替换法逐步隔离出故障件。排故手册涵盖了几乎所有可能引起该故障的组件，并给出了组件的拆换次序，这虽然能够解决绝大部分飞机维护中遇到的故障问题，但排故过程烦琐，排故效率低。尤其在飞机过站短停遇到故障时，经常由于无法及时维修导致航班延误，造成航空公司的巨大损失。

飞机维修工作量快速增长而专业维修人员数量不足、航线排故时间有限与飞机排故、维修效率较低这个矛盾已成为制约中国民航业发展非常突出的因素。研究开发对大型飞机的快速有效的故障诊断技术可以有效地了解设备的运行状况，及时发现设备的潜伏性故障，避免突发事件的发生，这不仅对提高飞机的可靠性以及提高航空公司的经济效益有着十分重要的作用，而且对民航事业的科技进步有着举足轻重的科学价值。

本论文针对飞机故障诊断中的这些问题，以波音737飞机的燃油系统作为研究对象，对其故障诊断过程进行分析研究，将粒子群RBF神经网络引入飞机的故障诊断中，以提高民航飞机的故障诊断能力，实现对故障的快速准确的定位，从而缩短飞机排除故障停场时间，提高航空公司的经济效益。

1.2 民航飞机的故障诊断特点及要求

1.2.1 故障诊断概述

故障诊断技术自有工业生产以来就已存在，但故障诊断技术作为一门学科是20世纪60年代以后发展起来的，它是适应工程实际需要而形成的。所谓故障诊断是指系统在一定工作环境下查明导致系统某种功能失调的原因或性质，判断劣化状态发生的部位或部件，提出排除故障相应措施以及预测状态劣化的发展趋势等^[1]。

故障诊断技术的发展大体经历了三个阶段^[2]：第一阶段故障诊断主要依靠人类的感官器官、个人经验以及简单仪表等，对诊断信息只是做简单的数据处理；传感器技术、动态测试技术和信号分析技术的发展促使故障诊断技术进入了第二阶段，并且在维修工程以及可靠性工程中得到了广泛的应用；自上世纪80年代以来，由于机器设备日趋复杂化、智能化以及光电一体化，传统的诊断技术已经不能适应这种发展形势，随着计算机技术、人工智能技术特别是专家系统的迅速发展，诊断技术进入了第三个发展阶段——智能化阶段。

故障诊断的基本思想一般可以这样表述：设备全部可能发生的状态，包括正常状态和故障状态，组成的状态空间为 X ，它的可测特征的取值范围全体构成特征空间为 Y ，当系统处于某一状态 S 时，系统就具有确定的特征 Y ，即存在映射 g ：

$$g: X \rightarrow Y \quad (1.1)$$

反之，一定的特征也对应确定的状态，即存在映射 f ：

$$f: Y \rightarrow X \quad (1.2)$$

如果 g 和 f 是双射函数，即特征空间和状态空间存在一对一的单满射，则由特征向量可唯一确定系统的状态，反之亦然。故障诊断的目的在于根据可测量的特征向量来判断系统处于何种状态，也就是找出映射 f 。若系统可能发生的状态是有限的，例如可能发生 n 种故障，这时把正常系统所处的状态称为 x_0 ，把存在不同故障的系统所处的不同状态称为 $x_1, x_2, \dots, x_n$ 。当系统处于状态 x_i 时，对应的可测量特征向量为 $Y_i = (y_{i1}, y_{i2}, \dots, y_{im})$ 。故障诊断是由向量 $Y = (y_1, y_2, \dots, y_m)$ 求出它所对应的状态 X 的过程。因为一般故障状态并非是绝对清晰的，而是具有一定的模糊性，所以它对应的特征值也在一定范围内变动。在这种情况下，故障诊断就成为按特征向量对被测系统进行分类的问题或对特征向量进行状态的模式识别问题。因此故障诊断实质上也是一类模式分类问题。

故障诊断的过程有三个主要步骤：第一是检测设备状态的特征信号；第二是从所检测的特征信号中提取征兆；第三是根据征兆和其它诊断信息来识别设备的状态，从而完成故障诊断。

1.2.2 飞机故障来源及特点

飞机在经历设计、制造、装配、使用和维护的全过程中，存在各种各样的复杂因素，其故障可能的来源有：

1、设计问题，飞机设计是一项十分复杂的工作，在设计过程中难免出现个别小错误。例如，飞机数字式综合电子系统由数字式硬件和控制软件构成，其中就包括对一些控制软件缺陷的修正；

2、制造问题，包括飞机零部件在整个制造过程中所产生的缺陷，诸如材料缺陷、制造误差等；

3、使用环境，飞机每次飞行，其零部件经历从地面到近万米高空激烈的环境变化，并长期承受机械振动、超温、潮湿和辐射等恶劣的使用环境，这些都可能会导致故障；

4、意外事件，在各种文献上经常报道飞机在飞行过程中发生雷击、鸟撞等意外事件。在上述来源中，由于现代工业制造水平的飞速发展，制造问题引发的故障在全部故障来源中所占的比例不断下降，而环境和人为因素所占的比例有所上升。

民用飞机是个大型复杂系统，其故障的特点可以概括为以下四个方面：

1、大多数飞机零部件所发生的故障是随机的。不存在固有失效率，由于大部分故障来自环境和人为因素，而这些因素本身就是随机的，所以大多数飞机失效零部件在正常的使用寿命内不存在确定的固有失效率。

2、飞机总的故障率遵循“浴盆曲线”。在飞机使用初期，其各个零部件的性能参数处于调试和工艺磨合阶段，性能参数变化较大，工作不稳定，总故障率相对较高；随着飞机飞行时间的增加，其各个零部件完成调试和工艺磨合后，其性能逐渐稳定，总故障率有所下降，发生的故障主要是机载电子设备的可靠性故障，随机性较大；当飞机使用时间超过经济寿命的75%以后，由环境因素导致的磨损、腐蚀和疲劳等效应日趋严重，损耗性故障越来越多，总失效率又开始上升。

3、故障机理复杂。现代飞机综合应用了机械、电子、计算机、自控、检测技术等多学科的先进技术，是一种大型复杂机电设备，各系统工作原理的多样性导致了其故障机理的复杂性，例如ATA23章为通讯系统，以电子设备为主，而ATA32章为起落架系统，以机械设备为主，这两个系统发生故障的机理肯定不同。

4、并发故障发生可能性大。飞机系统的复杂性决定了其故障的综合性特点，任何一个原发性故障的发生都存在多条潜在的引发故障，所以它是个多故障并发系统。

1.2.3 飞机故障诊断的特点

1、故障诊断必须满足适航规章要求

民用航空，包括民用航空器的设计、制造、使用和维修，始终处于有关国际组织和各国法规的严格控制之下。例如，我国管辖民用航空维修的适航规章主要有CCAR-121AA《民用航空器运行适航管理规定》和CCAR-145《民用航空器维修许可审

定规定》。飞机故障诊断时,适航要求主要体现于飞机制造商提供飞机维修手册(Aircraft Maintenance Manual, AMM)和排故手册之中,Boeing等美国公司将排故手册称为故障隔离手册(Fault Isolation Manual, FIM),Airbus称为故障排除手册(Trouble Shooting Manual, TSM)。

2、故障征兆和故障原因间对应关系复杂,排故难度大

民航飞机属复杂系统,由发动机、空调系统、电源系统、燃油系统、液压系统、通讯导航系统、飞行控制系统等许多子系统组成,每个子系统又由更低级的子系统构成,系统结构层次多,在子系统内、层次之间的联系极为复杂。

由于故障具有纵向传播性,较高层次系统的故障可来源于低层次系统故障;飞机在同一层次上不同系统间在构造和功能上还存在众多的联系或耦合作用,所以故障亦存在横向传播性,例如B737飞机的无线电导航系统、大气数据惯性基准系统(ADIRS)、飞行管理计算机系统(FMCS)、电子飞行仪表系统(EFIS)等都与数字式飞行控制系统(DFCS)存在着数据通信。而DFCS的飞行指引(F/D)、自动驾驶(A/P)、偏航阻尼(Y/D)、自动油门(A/T)、马赫配平、速度配平等分系统之间又存在相互交联信号。

3、故障诊断往往需要多学科知识

民航飞机中机电一体化设备越来越多,设备中的机械和电气系统不仅在控制方面,而且在功能、能量利用和物理方面都趋于综合,因此对其进行故障诊断需要机械、自控、计算机等多学科知识。例如,飞行控制系统中自动驾驶仪的故障,就涉及到飞机管理计算机、惯性基准系统、自动油门等不同的子系统。

4、故障诊断涉及的结构层次有所提高

民航飞机的模块化、集成化程度越来越高,故障诊断涉及的结构层次也随之提高,一般当故障源查到某一部件层,需要整体更换此部件或调整此部件的参数才能排除故障时,故障源查到此一层次已满足要求,不一定需要查到元件级。这类部件一般称为航线可更换件LRU(Line Replace Unit)。

5、诊断时间要求紧

大部分故障是发生在飞机正常营运过程中,航空公司为了减少因航班延误或取消带来的损失,要求诊断工作尽量在短停、航前或航后维修时间内完成,时间要求紧。

6、诊断工作的难点集中于故障诊断学的诊断逻辑部分

对于民航飞机故障诊断而言,故障诊断的三个主要步骤中,检测系统特征信号及故障征兆的提取,随着飞机故障信息学的发展可由设备自动完成,大多数情况下无需维修人员的参与。因此,民航飞机故障诊断难点集中于故障诊断学的诊断逻辑部分,即如何根据故障征兆确定故障原因。

1.2.4 民航飞机一般排故流程

目前维修人员对飞机进行故障诊断的具体步骤如下:

- 1、在短停、航后阶段查阅机组人员的飞行记录。并对相关设备进行检查;
- 2、如果发现故障,根据机型号和故障信息查阅MEL(最低设备清单)和CDL(外形缺省清单),判断该故障是否在放行的范围内。如果飞机在故障未被排除的情况下被放行,其推迟维修的项目必须是MEL和CDL中规定的内容,并满足规定的条件;
- 3、在排除故障的过程中,对于经常发生的、简单故障,维修人员根据经验可直接实施故障隔离过程。而一些不常发生的、比较复杂的故障,则参照FIM实施故障隔离程序;
- 4、查找FIM的流程如下:
 - (1) 根据FIM中的故障信息索引(Fault Code Index),由记录的故障征兆可找到FIM Fault Code(故障码)和FIMTASK(任务号);
 - (2) 飞行控制系统中,如果任务号为22-11TASK801/802/803,则要根据任务中的内容做相关BITE,然后根据CDU上显示的结果,通过维护索引(Maintenance Message Index)找到相应的任务号;
 - (3) 根据任务号找到对应的故障隔离程序。它提供了导致该故障信息发生的几乎所有可能原因(Possible Cause)及排除故障的步骤,同时需要参考AMM和WDM手册中对应的内容。
- 5、根据排除故障需要参考的AMM和WDM手册中对应内容,例如AMM中对应的TASK号,生成排故工作单,根据它实施;
- 6、根据排故结果填写故障历史记录。

1.3 国内外的研究现状

1.3.1 飞机智能故障诊断技术研究现状

近年来,人工智能及计算机技术的飞速发展,为故障诊断技术提供了新的理论基础,产生了许多智能故障诊断方法。由于不需要对象的精确数学模型,而且具有智能特性,因此智能故障诊断技术在具有很好的应用前景。

目前智能故障诊断研究主要集中在以下几个方面:

- 1、将一些新的理论引入故障诊断之中,如信息融合故障诊断、基于进化算法的故障诊断、基于Agent故障诊断、基于图论的模型推理方法、基于神经网络的故障诊断等,随着新理论不断发展,这方面的工作仍是故障诊断的重要内容之一。
- 2、诊断系统集成化,将几种诊断方法融合到一起的集成故障诊断研究,实现多种诊断方法的融合。如将小波变换、模糊数学、神经网络综合到一起的故障诊断方法^[3,4]。由于每种方法都有其优点和不足,这种集成故障诊断方法必然有其独特的优点,这也是有待深入研究的内容之一。

3、诊断系统综合化，由过去单纯的监测和诊断，向今后集监控、测试、诊断、管理、预测和训练于一体的综合系统化方向发展。

4、随着人工智能的发展，人们越来越意识到操作人员的常识及人的自然智能的优越性，在故障诊断系统中适当考虑人的作用会降低故障误报率和漏报率。

当前运用于飞机故障诊断的智能技术主要有：专家系统故障诊断方法、神经网络故障诊断方法、模糊故障诊断方法、遗传算法故障诊断方法、粗糙集故障诊断方法、人工免疫算法故障诊断方法、故障树故障诊断方法和支持向量机故障诊断方法等。

智能故障诊断技术在民航领域已经取得了许多的研究成果，文献[5]建立基于故障树的图形化专家知识录入及维护系统，实现可视化的录入和编辑专家知识，解决了飞机故障诊断中获取专家知识的瓶颈制约的问题，文献[6]在航空公司机务维护信息库的基础上，提出了一种民航飞机排故专家系统解决方案，解决了查询任一故障描述的排故方法。文献[7]以基于径向基函数的概率神经网络对飞行控制系统的作动筒进行故障诊断，仿真结果显示概率神经网络更适合于大步长采样下的网络辨识，且有较好的泛化能力，所得检测结果符合预期要求。文献[8]给出了基于径向基函数神经网络的飞机自动驾驶仪故障诊断方法，径向基神经网络克服了BP神经网络的训练收敛速度慢，容易产生局部极小值的缺点，应用于自动驾驶仪故障诊断训练收敛速度快，且具有较高的故障诊断正确率。文献[9]把支持向量机应用在机载设备故障诊断及预报中，有效地解决了机载设备故障诊断中典型故障样本缺乏、先验知识不足等问题。

1.3.2 神经网络应用于故障诊断的优势与不足

与其它的故障诊断方法相比，神经网络故障诊断方法的优势主要体现在以下几个方面：

1、非线性映射能力

神经网络中大量神经元的集体并行行为并不是各神经元行为的简单叠加，而是表现了一种复杂非线性系统的特性，这对于高维空间模式识别和非线性模式识别问题的分类精度高，具有分辨故障原因及类型的能力，这为故障诊断的实现提供了前提条件。

2、并行处理能力。

神经网络的并行处理决定了它的处理过程相对较快。

3、联想记忆

神经网络具有滤出噪声及在有噪声情况下得出正确结论的能力，因此，可以训练人工神经网络来识别故障信息，使其能在噪声环境中有效地工作，这特别适合在线故障诊断。

4、自组织和自学习能力

可以根据研究对象的历史数据训练神经网络，然后将此信息与当前测量数据进行比较，以确定故障。

5、分布式存贮与容错性

信息在神经网络中分布于众多神经元存贮,每个神经元存贮部分信息,部分信息丢失对网络输出结果影响较小,网络具有很好的容错性。

虽然以神经网络进行故障诊断的优势显而易见,但目前一般的神经网络模型相当于一个“黑匣子”,仅能做到故障征兆特征空间之间的非线性映射,无法表达故障诊断的技术内容和内在实质。具体而言人工神经网络存在以下几方面的缺点:

1、训练样本获取的困难性。神经网络故障诊断是建立在大量的故障样本训练基础之上的,系统性能受到所选训练的样本的数量及其分布情况的限制。如果样本选择不当,特别在训练样本少、样本分布不均匀的情况下,很难有良好的诊断能力。然而在设备诊断中,往往很难得到大量的故障样本,且在所能得到的有效故障样本中,其分布也是很不均匀的。

2、忽视了领域专家的诊断经验知识。神经网络利用知识和表达知识的方式单一,通常的神经网络仅仅通过典型的实例来获取诊断知识,忽视了领域专家在长期实践中所积累的宝贵经验。而设备故障诊断尤其是大型设备的故障诊断是一项经验性技术,忽视了专家经验,基于单一的典型实例必将导致神经网络故障诊断能力的下降。

3、权重形式的知识表达方式难以理解。由于神经网络所学习到的知识是以权重形式分布在网络之中,这种隐式的数值表示不易为人们理解,且对诊断结果缺乏解释能力。对用户来说,整个诊断系统是一个“黑箱”,不具备透明性,因而在工程实际中用户是很难接受的。

1.3.3 神经网络优化研究现状

与人脑的作用机制类似,神经网络完成任务的过程首先包括学习训练过程,然后才是使用(回忆或创新联想)过程,只有经过充分学习的神经网络才能使人们放心使用。为了提高神经网络在实用中的学习和诊断性能,神经网络的学习能力研究,即确定最优的网络结构和训练算法,是神经网络优化研究领域的重点^[10]。

1、网络结构设计优化的研究现状

网络结构设计优化是通过设计满足精度要求的结构尽可能小的网络,来保证网络的应用性能。训练算法优化则是在确定了的网络结构框架下,通过网络训练而得到优化的网络参数,达到满意的学习效果。

由于神经网络潜在和固有的并行性、非线性性,很难用数学模型对其结构进行精确的分析。目前,网络结构设计尚无确定可循的理论方法,一个公认的指导原则是:在没有其它先验知识时,能与给定样本相符合的最简单的网络就是最佳选择。传统的方法有逐步增长法、逐步修剪法以及正规化约束法(regularization),以及几何方法和顺序构造法。

逐步增长法是先从一个较简单的网络开始,逐步增加隐单元数目直到满足要求为止。逐步修剪法则相反,从一个较复杂的网络开始,逐步删除隐单元数目直至满足要求

为止。正规化约束法是在目标函数中, 增加对模型复杂性的约束。

Gray 与 Michel 于 1993 年首先提出了二进制映射二分问题的前馈网络结构学习算法。所谓二进制映射即所有样本模式的输入和输出向量均为二进制向量, 由于所有模式只分两类, 因此网络的输出只取单一数值 0 或 1。可以认为所有样本组成一个 Boolean 函数的真值表, 由此二进制映射学习问题就转化为由真值表求得 Boolean 函数表达式的问题。可以用卡诺图法由真值表得到 Boolean 函数的标准合取或析取表达式, 而逻辑或和逻辑与运算都是线性可分的函数映射, 因此由 Boolean 表达式就可构造出两层的感知器网络。该算法根据 Boolean 表达式即可确定中间层的神经元个数, 但由卡诺图法获得 Boolean 表达式的计算往往使学习效果时好时坏, 且产生的中间层神经元较多。

1995 年, J.H.Kim 和 Sung-Kwon Park 又给出了二进制映射二分问题的几何学习算法, 这种方法构造一个两层的前馈网络实现样本模式所描述的二分问题, 直接根据样本模式求解超平面将不同类别的模式分割在多个区域中, 求解超平面的过程即构造网络中间层的过程。实践表明, 几何方法要好于卡诺图法。

上述两种方法都是根据学习问题的样本模式直接构造了前馈网络, 算法在构造过程中确定了中间层神经元个数。算法肯定结束, 因而是收敛的。但上述两种方法均不能直接有效地推广到一般二进制映射学习问题。

几何方法存在另一个缺陷, 即算法构造的网络输出层的连接权值有很快的指数增长, 这种指数增长虽然可以在理论上保证网络结果的正确性, 但在实际应用中是不能接受的。

2、训练算法优化的研究现状

误差修正学习法目前常被用于多层前馈神经网络的训练过程, 最典型的误差修正学习算法是 BP 算法。BP 算法首先设计一个误差函数, 赋予每个连接权值一个随机初始值, 然后利用梯度下降法计算连接权值的修正量, 直到误差函数取值达到所要求的范围。但这类算法最明显的缺陷是算法的收敛速度太慢, 有时甚至不收敛。由于算法的连接权值计算是利用梯度下降法寻找局部最优的过程, 即使找到局部最优点, 也未必能够满足要求而结束, 因此算法必须多次选择初始点重新开始计算, 这种方法在最坏情况下需要网络连接权值遍历整个搜索空间, 才能找到合适的解, 显然算法学习速度慢是必然的。

综上所述, 针对实际工程问题设计和优化神经网络的过程, 实际上可以归结为网络权值参数的训练与合理的网络结构设计这两类典型的优化问题。由于神经网络的训练学习是一个极其复杂的过程, 传统的学习算法往往需要很长时间, 才能在一定精度范围内找到符合要求的网络结构与参数。

现有的神经网络模型并没有攻克组合爆炸问题, 只是把计算量转交给了学习算法来完成。也就是说, 增加处理机数目一般不能明显增加近似求解的规模, 尽管采用大规模并行处理机是神经网络计算的重要特征, 还应寻找其它有效方法, 建立具有计算复杂性、网络容错性和坚韧性的计算理论。因此, 为提高网络的设计速度及泛化能力, 各种全局优化算法越来越受到相关研究人员的青睐。

1.4 本文的所做的工作及内容安排

本文综合研究了RBF神经网络理论、粒子群算法、故障诊断等多方面知识。在此基础上,运用粒子群算法优化RBF神经网络方法对民航飞机进行故障诊断,以实现飞机设备故障的快速与精确诊断,从而缩短飞机排除故障停场时间,提高航空公司的经济效益。具体做法是:以民航飞机维修手册、维修大纲以及可靠性报告作为故障诊断知识来源,将三种信息综合考虑建立民航飞机故障诊断知识复合模型,以飞机燃油系统为例,整理得到神经网络的训练样本;设计基于PSO-RBF网络的故障诊断优化模型,并在Matlab上实现模型仿真,进而以训练样本对该神经网络进行训练,最终对基于粒子群优化算法的RBF神经网络故障诊断方法的实验性初步验证,使飞机尽可能地提高效率(减少维修时间),达到系统能快速找到故障发生的部位,快速维修的目的。

本文的主要内容包括:

第一章“绪论”,介绍课题的来源并简要分析了课题的研究意义,概述民航飞机故障的来源和特性,给出了民航飞机故障诊断的特点,以及民航机务维修的方法和流程。总结智能故障诊断技术在民航领域的应用现状,在此基础上介绍神经网络在故障诊断领域的优势与现存问题,并概述了提高神经网络的学习和诊断性能的策略。最后简要介绍论文研究的主要内容以及工作安排。

第二章“B737燃油系统分析”,本章在介绍了B737的燃油系统的组成以及系统框图的基础上,对其各子系统做了详细的阐述。在此基础上分析了飞机燃油系统的故障,对燃油系统进行了系统级和部件级的故障分析。

第三章“粒子群优化算法”,本章首先介绍了粒子群优化算法的基本原理、算法流程、在此基础上分析了PSO算法的优势与不足。针对基本粒子群算法的不足,综合引入惯性权重、收缩因子以及扰动因子三个参数,提高了算法的寻优能力,保证了算法的收敛,并且能够避免迭代后期因粒子多样性缺失而陷入局部极小值。

第四章“粒子群算法在RBF神经网络中的应用”,本章首先介绍RBF神经网络,在讨论了RBF网络的参数设置和泛化能力之后,重点介绍了粒子群算法对RBF神经网络的优化。

第五章“基于粒子群 RBF 神经网络的故障诊断”,本章以飞机燃油系统为研究对象,通过分析,提出基于维修手册、维修大纲、可靠性报告的民航飞机故障诊断知识复合模型,以此建立 RBF 神经网络的故障诊断训练样本。以 Matlab 为平台,编写粒子群 RBF 神经网络故障诊断程序,对飞机燃油系统进行故障诊断,并与 BP 和 RBF 网络进行对比,进行结果分析。

第二章 飞机燃油系统与故障分析

由于飞机综合性能的需要,飞机燃油系统在近十几年中得到了迅速发展。飞机燃油系统已不再仅仅是保证飞机的配平和向发动机供油,而是要完成更多的功能。而功能的增强、综合性能的提高也使飞机燃油系统越来越复杂,这使得飞机燃油系统的故障模式更为复杂,本章对燃油系统进行了深入的分析。

2.1 飞机燃油系统概述

飞机燃油系统的主要功用是储存一定量的燃油,根据需要将燃油供应到发动机和辅助动力装置(APU),并在飞机允许的各种飞行状态和工作条件下,按下定的顺序向发动机可靠地供给规定压力和流量的燃油,以满足飞机各工作状态的燃油需求。此外燃油系统还具有给飞机上其他设备(或系统)冷却和保持飞机重心于规定范围内等附加功能。

波音 737 飞机的燃油系统装有压力加油和放油设备以及燃油测量设备。两个主油箱和中央油箱为发动机和 APU 储存燃油,各翼尖处的通气油箱为主油箱提供外溢空间和通气。通气油箱内侧有一个单向活门,通气油箱内积存的燃油可以通过该活门返回主油箱,但主油箱内的燃油无法进入通气油箱。机翼上加油口可以为主油箱人工加油。机翼下表面的维护口盖用作燃油检查或部件修理的入口。在燃油箱底部有一个排放活门,用来放掉燃油箱里的杂质、凝聚物和燃油。图 2-1 为波音 737 飞机燃油系统的概述图。




图 2-1 飞机燃油系统概况




图2-3 燃油系统右后梁上的部件分布

2.3 飞机燃油系统的子系统

早期飞机的燃油系统是由油箱和一些简单的导管组成，而现代飞机是由大量的相互联系的子系统组成。具体而言，波音 737 飞机燃油系统包括下列子系统：燃油贮存系统；压力加油系统；发动机燃油供给；APU 燃油供给；抽油系统；燃油指示系统。




图 2-4 波音 737 飞机燃油系统组成框图

2.3.1 燃油储存系统

燃油储存系统由 2 个主油箱和 1 个中央油箱组成，主油箱在机翼里，1 号主油箱在左机翼，2 号主油箱在右机翼，中央油箱位于机身和每个机翼的内侧段。通气油箱只用来收集溢流的燃油。

1、沉淀槽放油活门

沉淀槽放油活门在每个油箱的最低点，用来从油箱排出燃油、水和杂质。

2、燃油通气系统

通气系统保持油箱内的压力接近外界的大气压力。系统由一个带火焰抑制器的通气斗和油箱内的通气通道和管子组成。释压活门安装在通气油箱接近门内侧。

3、中央油箱抽油系统

中央油箱抽油系统利用一个引射泵将中央油箱的燃油导入1号主油箱从而增加其可用燃油量。

2.3.2 压力加油系统

压力加油系统给各油箱加油，并给油箱间串油。三个油箱通过右翼的加油站来加油。油箱加油是通过四个加油活门完成的，每个主油箱有一个加油活门，中央油箱有两个加油活门。加油活门由控制电门和燃油量处理器控制。加油接头处的最大燃油压力约为 $3.5 \times 10^5 Pa$ 。压力加油的加油速度快，加油点集中，燃油不易受污染，且能自动控制加油量。

- 1、油箱加油站在右翼，它包括：加油面板、加油总管、加油接头、加油关断活门。
- 2、加油站有可自动或人工控制的加油关断活门。
- 3、当控制电门在打开位时，加油关断活门线圈通电。油压正常时活门打开。当油箱加满时，浮子电门给加油关断活门断电。把控制活门放到关位时也要断电。没电时，活门关闭。
- 4、每个燃油关断活门上有人工超控柱塞。当线圈失效时，柱塞和油压可以帮助打开活门。




图2-5 压力加油系统

2.3.3 发动机供油系统

发动机供油系统从 1、2 号主油箱和中央油箱给发动机供油。可以用 P5 燃油控制面板和 P10 发动机起动手柄操纵发动机供油系统。




图2-6 发动机供油系统

1、中央油箱增压泵

中央油箱增压泵在轮舱的后梁，它从中央油箱向供油总管提供燃油。燃油控制面板上的电门控制每个中央油箱增压泵，左中央油箱增压泵压力电门在左轮舱后梁上，右中央油箱增压泵压力电门在右轮舱后梁上。

2、主油箱前后增压泵

主油箱前增压泵在大翼前梁，主油箱后增压泵在大翼后梁上，从主油箱提供燃油到发动机供油总管。燃油控制面板上的电门控制每个主油箱前后增压泵。前增压泵压力电门在前梁上，通过大翼顶部的接近盖板接近。后增压泵压力电门在后梁上，通过轮舱接近。

3、燃油交输活门

燃油交输活门让燃油在左右发动机供油总管之间流动。通过连接两台发动机供油总管，一个油箱可以为双发供油。燃油交输活门由燃油控制面板的燃油交输活门电门控制。

4、发动机燃油梁活门

发动机燃油梁活门控制燃油从发动机供油总管流向发动机供油管。发动机起动手柄和发动机火警电门控制发动机燃油梁活门。

5、燃油关断活门电瓶

燃油关断活门电瓶保证燃油系统始终有电用来关闭发动机燃油梁活门和 APU 燃油关断活门。

6、除水引射泵

除水引射泵利用增压泵出口压力作为引射源，靠其产生的吸力不断将水份从每个油箱的底部引至增压泵进口，继而进入发动机燃烧，防止油箱腐蚀。除水引射泵在后梁上，主油箱各一个，中央油箱有 2 个。

7、旁通活门

旁通活门连接供油总管，提供燃油到发动机的第二条通道。1、2 号主油箱各有一个旁通活门，它是自动操作的。

8、发动机供油

在飞行开始的时候通常所有的泵电门在接通位，中央油箱提供燃油给发动机。当中央油箱空了以后，可以将中央油箱增压泵关断。当中央油箱空了而增压泵接通，燃油从主油箱提供给发动机。燃油通过交输活门保证主油箱的平衡。当一个油箱的所有增压泵都关断且交输活门也关闭，主油箱的旁通活门打开从主油箱吸油供给发动机。

2.3.4 APU 供油系统

APU 供油系统可从任何油箱给 APU 供油。中央油箱增压泵或主油箱增压泵给 APU 供油，如果泵关断，则 APU 从 1 号主油箱吸油。电子控制组件(ECU)控制燃油流向 APU，它从 APU 总电门、防火系统和 APU 传感器接受信号控制 APU 燃油关断活门。燃油关断活门电瓶保证燃油系统一直有电用来关闭 APU 燃油关断活门。APU 供油管经过 APU 燃油关断活门供油到 APU 控制组件，外罩收集从 APU 供油管渗漏的燃油再通过排放口排出机外。




图2-7 APU供油系统

2.3.5 抽油系统

抽油系统是将飞机燃油安全抽出机外的整套装置。抽油系统可倒油到加油口，它允许对每个油箱压力抽油。只允许对 1、2 号主油箱吸力放油，1 号主油箱吸力抽油时必须与 2 号主油箱同时抽油，当 2 号主油箱排空，空气进入总管则油停止流动。在地面还可以进行油箱之间的串油。




图2-8 抽油系统

2.3.6 燃油量指示系统

燃油指示系统计算每个燃油箱燃油量，它包括：油箱组件，补偿器，比重计，一个处理器组件，驾驶舱指示器，负载选择指示器，一个负载选择控制组件。燃油量指示显示在驾驶舱和加油面板。燃油量指示系统允许在地面加油时允许关断预设的燃油重量。当油箱加满时，自动中止加油。燃油量指示系统对故障隔离有强大的自检功能。来自油箱的组件，补偿器和比重计的信号输入到处理器来收集燃油重量。处理器将信息发送至驾驶舱燃油量指示器，加油面板的负载选择指示器，飞行管理计算机，EICAS，飞机状态监控系统或数字飞行数据采集组件。系统有容错功能，因此一个单独故障只能引起一个油箱的显示丢失。如果油箱数据不精确，则这个单独的油箱油量和总油量显示空白。

2.3.7 燃油温度指示系统

燃油感温棒在 1 号主油箱后梁上，燃油温度指示器在 P5 燃油系统面板上，燃油温度指示系统显示 1 号主油箱燃油温度。

2.4 飞机燃油系统故障分析

根据目前波音 737 飞机燃油系统在实际应用中所发生的故障来分析，燃油系统的故障一般表现在两个方面：一是飞机燃油部件的故障，即故障发生在当飞机进行加油、输

油或耗油过程中, 由于操作性机件(主要是供油泵、阀门、调节器和传感器)发生机械故障所导致的; 二是子系统的故障, 即由于子系统的多个附件发生故障, 造成子系统的功能下降或丧失。

燃油系统中出现的常见部件级故障有:

1、压力加油控制活门故障。其故障模式有压力加油控制活门无法关闭或者无法打开。当活门无法打开时, 系统无法正常压力加油, 油箱中油位不变; 当活门无法关闭时, 油箱内的油位达到设定值仍然继续增加。结合压力加油过程中油箱内油位的变化判断对应活门状态。

2、插板开关故障。故障模式有插板开关无法关闭或无法打开。系统中采用的插板开关有外接的开反馈和关反馈信号; 管理机发出“开”的指令时, 开反馈信号为高; 发出关指令时, 关反馈信号为高。结合反馈信号是否正常判断插板开关是否保障。

3、油位传感器故障。油位传感器几种常见的故障模式为: 冲击故障; 漂移故障; 偏置故障; 短路故障; 开路故障。

4、燃油泵压力低故障。飞行中当油箱油量低而飞机又处于颠簸气流中, 在爬升、下降期间, 燃油泵出口压力可能降低, 驾驶舱中相应的“油泵低压灯”闪亮。因为有抽吸供油方式, 一般可正常飞行; 但如果一个油箱中的全部增压泵都处于低压状态, 这在高空可能出现发动机功率下降的现象, 应采取相应措施。

5、油量表指示误差大故障。因油面振动、信号机械传递机构摩擦等原因, 会产生油量表的指示误差较大的故障。飞机的燃油量不能以油量表指示为唯一依据, 在计算续航时间和航程时一般以“时间基准算法”, 即根据加油量、平均耗油量和飞行时间进行计算。

由于飞机燃油系统是一个复杂的非线性系统, 某个燃油部件或测量元件的故障将直接或间接影响到其它部件或测量元件的故障诊断, 这使得燃油系统系统级的故障诊断尤为麻烦。

飞机燃油系统的系统级故障诊断主要是为了解决油箱及加油、输油管路的故障诊断问题。下面将对油箱及加油、输油管路的故障进行分析。

1、油箱故障

油箱的故障诊断非常复杂, 牵涉到了泵、油位传感器、加油活门、隐射泵等的状态, 输油、加油管路的故障同样是非常复杂的, 没有办法单独判断, 必须进行系统级的分析与判断。

燃油渗漏是油箱故障中常见的一个, 燃油渗透指燃油从油箱、油泵底座、管路或管接头处向外渗出的现象, 飞行前应认真检查。出现渗漏时, 飞机是否适航要根据使用手册的规定结合渗漏的严重程度而定, 但如果存在连续滴滴情况, 无论出现在飞机什么部位, 都应停止飞行。

燃油渗漏的判故可分为以下三个步骤: 首先检查与该油箱相连的各交流泵、直流泵、引射泵正常; 其次判断该油箱的加油控制活门正常; 最后核实该油箱中的油位传感器正

常；

2、输油管路

将加油管路上的油管分段，输油管路上按备份油箱到消耗油箱、辅助油箱到消耗油箱、预消耗油箱到消耗油箱分为三段。故障模式为：堵塞、泄露。

此外，燃油含水量过大也会导致燃油系统故障。水可以溶解于燃油中以游离形式混在燃油中，其来源是空气中所含的水蒸气、加油时混入的水、油箱中冷凝水等。游离水易于燃油结合形成一种类似胶冻的物质，温度低时可引起燃油系统结冰(冰晶)，可能堵塞增压泵滤网和燃油滤；大量的水分会引起发动机功率下降甚至停车；水会使油箱中的电气优良传感器短路，影响油量表的指示，还可以滋生微生物。

2.5 本章小结

本章在介绍了 B737 的燃油系统的组成以及系统框图的基础上，对其各子系统做了详细的阐述，包括燃油贮存系统；压力加油系统；发动机燃油供给；APU 燃油供给；抽油系统；燃油指示系统。在此基础上分析了飞机燃油系统的故障表现，对燃油系统进行了系统级和部件级的故障分析。

第三章 基本粒子群优化算法及其改进

粒子群优化算法(Particle Swarm Optimization, PSO)是由 Eberhart 和 Kennedy^[11]在 1995 年提出的一种基于群体智能方法的演化计算技术,是演化计算领域中的一个新的分支。算法最初受到飞鸟和鱼类集群活动规律的启发,利用群体智能建立了一个简化模型,用组织社会行为代替了进化算法的自然选择机制,通过种群间个体协作来实现对问题最优解的搜索。

PSO 算法同遗传算法(GA)类似^[12],是一种基于群体优化的工具。系统初始化为一组随机解,通过迭代搜寻最优值。但是并没有遗传算法用的交叉以及变异操作,而是粒子(潜在的解)在解空间追随最优的粒子进行搜索。与遗传算法比较,PSO 的优势在于简单、容易实现和更强的全局优化能力,既适合科学研究,又特别适合工程应用。

具体而言,PSO 算法有如下几个显著的优点:

- 1、无集中控制约束,不会因个别个体的故障影响整个问题的求解,确保了系统具备更强的鲁棒性,对算法稍加改动可以适应不同的应用环境;
- 2、有记忆性,粒子和群体的历史最好位置可以记忆并传递给其他粒子;
- 3、收敛速度快,在迭代进化中只有最优的粒子把信息传递给其他粒子,属于单向信息流动;
- 4、采用实数编码,直接由问题的解决定,问题解的变量数直接作为粒子的维数;
- 5、适合并行分布式算法处理,可充分利用多处理器。从粒子群算法的工作过程可以看出,可以在搜索空间上进行并行操作,同时各个个体的搜索过程也是可以并行进行的,在解决运算量非常大的优化问题时,利用并行计算的优势可以大大减少求解问题的时间;
- 6、对问题定义的连续性无特殊要求,这是粒子群算法区别于传统优化算法的一个非常好的性质,使得其应用的范围得以拓展;
- 7、算法简单、所需调整的参数较少、易于实现,在工程上针对具体问题可以通过调节较少的参数来配置与其相适应的具体优化算法;
- 8、易于与其他算法混合以提高算法性能。

已有的粒子群算法和应用方法研究证明粒子群优化方法是一种能够有效解决大多数全局优化问题的新方法。无论是从理论研究还是应用研究的角度分析来说,粒子群算法及应用研究都是具有重要学术意义和现实价值。

因此,PSO 算法一提出,立刻引起了演化计算等领域的学者们的广泛关注,并在短短的几年时间里出现大量的研究成果,形成了一个研究热点,在函数优化^[13]、神经网络训练^[14]、多目标优化^[15]和模糊系统控制等领域得到了广泛的应用。

3.1 基本粒子群优化算法

3.1.1 算法的基本原理

粒子群优化是模拟鸟群的捕食行为，一群鸟在随机搜索食物，在这个区域里只有一块食物。所有的鸟都不知道食物在那里。但是他们知道当前的位置离食物还有多远，最简单有效的就是搜寻目前离食物最近的鸟的周围区域。粒子群优化算法从这种模型中得到启示并用于解决优化问题^[16]。

在 PSO 算法中，每个优化问题的潜在解都可以想象成 D 维搜索空间上的一个点，我们称之为“粒子”(Particle)。粒子在搜索空间中以一定的速度飞行，这个速度根据它本身的飞行经验和同伴的飞行经验来动态调整。所有的粒子都有一个被目标函数决定的适应值(fitness value)，并且记录了自己到目前为止发现的最好位置(particle best, 记为 $pbest$)和当前的位置，这个可以看作是粒子自己的飞行经验。除此之外，每个粒子还知道到目前为止整个群体中所有粒子发现的最好位置(global best, 记为 $gbest$ ，它是在 $pbest$ 中的最好值)，这个可以看作是粒子的同伴的经验。

每个粒子使用下列信息改变自己的当前位置：

- 1、当前位置；
- 2、当前速度；
- 3、当前位置与自己最好位置之间的距离；
- 4、当前位置与群体最好位置之间的距离。

优化搜索正是在由这样一群随机初始化形成的粒子而组成的一个种群中，以迭代的方式进行。由此可知，粒子群优化算法也是基于个体的合作与竞争来完成复杂搜索空间中最优解的搜索，是一种基于群智能方法的演化计算技术。

假设在一个 D 维的目标搜索空间中，有 m 个粒子组成一个群体。其中第 i 个粒子的位置表示为向量 $\vec{x}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, $i = 1, 2, \dots, m$ ；其速度也是一个 D 维的向量，记 $\vec{v}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ；第 i 个粒子迄今为止搜索到的最优位置为 $\vec{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ ；整个粒子群搜索到的最优位置为 $\vec{p}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。每个粒子的位置按如下公式进行变化：

$$v_{id}(t+1) = v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (3.1)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (3.2)$$

其中， $i = 1, 2, \dots, m$ ； $d = 1, 2, \dots, D$ ；加速因子 c_1 和 c_2 为非负常数； r_1 和 r_2 是服从 $[0, 1]$ 上均匀分布的随机数； $x_{id}(t)$ 是第 i 个粒子的当前位置； p_{id} 是第 i 个粒子迄今为止搜索到的最优位置； p_{gd} 是整个粒子群搜索到的最优位置； v_{id} 是第 i 个粒子的当前速度；

$x_{id}(t) \in [-x_{\max}, x_{\max}]$, $v_{id} \in [-v_{\max}, v_{\max}]$, $x_{\max}$ 、 $v_{\max}$ 是非负数。在迭代过程中当 $v_{id} > v_{\max}$ 时, 取 $v_{id} = v_{\max}$; 当 $v_{id} < -v_{\max}$ 时, 取 $v_{id} = -v_{\max}$; 当 $x_{id}(t) > x_{\max}$ 时, 取 $x_{id}(t) = x_{\max}$; 当 $x_{id}(t) < -x_{\max}$ 时, 取 $x_{id}(t) = -x_{\max}$ 。

加速因子 c_1 , c_2 是使粒子向最优位置 p_{id} 和 p_{gd} 飞行的权重因子。较小的 c_1 , c_2 会使粒子以较小速率向目标区域游动, 较大则可能会使粒子很快飞越目标。 $v_{\max}$ 是一个很重要的参量, 它决定了粒子的搜索空间。若 $v_{\max}$ 太大, 则粒子可能很快就飞出最优点, 若其太小, 则粒子很可能无法越过局部最优点, 从而陷入局部最优。




图 3-1 粒子迭代示意图

每一代中任意粒子迭代的过程见图 3-1 所示。从社会学的角度来看速度迭代公式 3.1, 粒子的当前飞行速度由三部分组成:

第一部分 $x_{id}(t)$ 称为记忆项, 表示上次速度大小和方向的影响;

第二部分 $c_1 r_1 (p_{id} - x_{id}(t))$ 称为自身认知项, 是从当前点指向此粒子自身最好点的一个矢量, 表示粒子的动作来源于自己经验的部分;

第三部分 $c_2 r_2 (p_{gd} - x_{id}(t))$ 称为群体认知项。是一个从当前点指向种群最好点的一个矢量, 反映了粒子间的信息的共享和协同合作。

第一部分由于具有随机性, 有扩大搜索空间的趋势, 因此具有全局优化的能力。第二部分和第三部分由于体现了粒子的“个体经验”和“社会认知”, 使得粒子逐渐向当前最好位置收缩。粒子就是通过综合自身已有的信息和从外界得到的信息来决定下一步的运动, 从而实现算法的全局和局部搜索。

3.1.2 算法流程

算法实现的流程可描述为:

1、粒子初始化。初始搜索点的位置 $X_i(0)$ 及其速度 $V_i(0)$ 通常是在允许的范围内随机产生的, 每一个粒子的 $pbest$ 坐标设置为其当前位置, 且计算出其相应的个体极值(即

全局极值点的适应值)就是个体极值中最好的,记录该最好值的粒子序号,并将 $pbest$ 设置为该最好粒子的当前位置;

2、评价每一个粒子。计算粒子的适应值,如果好于该粒子当前的个体极值,则将 $pbest$ 设置为该粒子的位置,且更新个体极值。如果所有粒子的个体极值中最好的好于当前的全局极值,则将 $gbest$ 设置为该粒子的位置,记录该粒子的序号,且更新全局极值;

3、粒子的更新。用式 3.1 和式 3.2 对每一个粒子的速度和位置进行更新;

4、检验是否符合结束条件。如果当前的迭代次数达到了预先设定的最大次数或达到最小偏差要求,则停止迭代,输出寻优结果,否则转到 2。

算法的流程图如图 3-2 所示




图 3-2 基本粒子群优化算法流程图

3.2 粒子群优化算法的改进

粒子群优化算法概念简单容易实现,其代码只有短短的几行,和其他优化算法相比,这也是它的优点之一。但是粒子群基本算法在实际运用中也存在一些缺点^[17],主要有:

1、对于有多个局部极值点的函数,容易陷入到局部极值点中,得不到正确的结果。造成这种现象的原因有两种,其一是由于待优化函数的性质;其二是由于粒子群算法中粒子的多样性迅速消失,造成早熟收敛。这两个因素通常密不可分地纠缠在一起。

2、由于缺乏精密搜索方法的配合,PSO 算法往往不能得到精确的结果。造成这种问题的原因是 PSO 算法并没有很充分地利用计算过程中获得的信息,在每一步迭代中,仅仅利用了群体最优和个体最优的信息。

3、PSO 算法虽然提供了全局搜索的可能,但是并不能保证收敛到全局最优点上。

4、PSO 算法是一种启发式的仿生优化算法,目前还没有严格的理论基础,仅仅是通过对某种群体搜索现象的简化模拟而设计的,但并没有从原理上说明这种算法为什么有效,以及它适用的范围。因此,PSO 算法一般适用于一类高维的、存在多个局部极值点而并不需要得到很高精度解的优化问题。

因此研究者们对其作了各种各样的改进,现在已经从基本粒子群优化算法发展出许多不同的版本,如:引入惯性权重形成标准粒子群算法;引入收缩因子,从而确保粒子群算法能够收敛;针对粒子易于陷入局部极小值问题,引入扰动因子,强迫粒子跳出局部极小值,进而引发新一轮的搜索过程。

3.2.1 惯性权重的引入

探测是指粒子在较大程度上离开原先的寻优轨迹,偏到新的方向进行探索;开发则指粒子在较大程度上继续原先的寻优轨迹进行局部搜索。为了更好的控制算法的探测和开发能力,Shi 与 Eberhart 于 1998 年发表了名为“A Modified Particle Swarm Optimizer”的论文,将惯性权重 ω 引入到式 3.1 中,形成标准的粒子群优化算法:

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (3.3)$$

这样标准粒子群优化算法中有三个权重因子:惯性权重 ω , 加速因子 c_1 和 c_2 。通过实验研究惯性权重 ω 对算法性能的影响,发现较大的 ω 有利于跳出局部最优,进行全局寻优;而较小的 ω 有利于局部最优,加速算法收敛。惯性权重的大小决定了对粒子当前速度继承的多少,较大的惯性权重将使粒子具有较大的速度,从而有较强的探索能力;较小的惯性权重将使粒子具有较强的开发能力,为了保持粒子具有均衡的探索和开发能力,惯性权重必须进行合理的选择。

惯性权重的选择主要分为固定权重和时变权重两类。因定权重的选择就是选择某一常数作为权重值,在优化过程中不变;而时变权重则是选定某一个变化范围,在迭代过

程中按照某一规律变化。

最初应用中惯性权重为常数，而基本的 PSO 算法可以看作 $\omega=1$ ，因此在迭代后期缺少局部搜索能力。文献[18]认为当 $\omega=0.6$, $c_1=c_2=1.7$ 时粒子群优化算法的性能最佳；文献[19]得出的结论为 $\omega=0.729$, $c_1=c_2=1.494$ 。

后来的试验发现，动态惯性权值能够获得比固定值更好的寻优结果。目前，动态惯性权值的调整方法主要有两种，一种是线性调整策略： ω 随着优化时间线性减小；另一种是非线性自适应调整策略：随着迭代的进行逐步减小 ω 。文献[20]综合分析了常数和可变 ω 对算法性能的影响并提出了 ω 的设置原则。

采用较多的惯性权重调整方法是 Shi 建议的线性递减权值(Linearly decreasing weight, 简称 LDW)策略，惯性权重 ω 线性递减公式如下：

$$\omega = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T_{\max}} T \quad (3.4)$$

其中， $\omega_{\max}, \omega_{\min}$ 分别是 ω 的最大最小值，典型的取值是 $\omega_{\max}=0.9$, $\omega_{\min}=0.4$ ； $T, T_{\max}$ 分别是当前迭代步数和最大迭代步数。线性递减的惯性权值函数保证了粒子群算法前期阶段具有较好的全局搜索能力，在迭代后期也保证了算法的局部搜索能力，弥补了基本 PSO 算法的一些不足。

但是线性调整策略中权重 ω 的值仅与迭代的次数有关，不能适应算法运行中复杂、非线性变化的特性。当待解问题很复杂时，该方法使得 PSO 迭代的时间较长，在迭代后期全局搜索能力不足，导致不能找到要求的最优解，这可以用自适应改变惯性权重的方法来克服。

自适应改变惯性权重的方法根据群体早熟收敛程度和个体适应值自适应的调整粒子的惯性权重，使粒子群在进化过程中始终保持惯性权重的多样性，在算法的全局收敛性和收敛速度之间做了一个折中，即惯性权重按照下式动态调整：

$$\omega(k+1) = \begin{cases} \omega(k) - (\omega(k) - \omega_{\min}) \left| \frac{f_i - f'_{avg}}{f_i - f_{avg}} \right|, & f_i > f_{avg} \\ \omega(k), & f_{avg} < f_i < f'_{avg} \\ 1.5 - \frac{1}{1 + k_1 \exp(-k_2 \Delta)}, & f_i < f_{avg} \end{cases} \quad (3.5)$$

式中， f_i 为第 k 次迭代中第 i 个粒子的适应值， f_{avg} 为粒子的平均适应值，

$f_{avg} = \frac{1}{m} \sum_{i=1}^m f_i$ ； m 为粒子如的大小； f'_{avg} 为适应值优于 f_{avg} 的适应值求平均得到的值；

$\Delta = |f_m - f'_{avg}|$ ， f_m 为最优粒子的适应值， Δ 用于评价粒子群的早熟收敛程度，且 Δ 越小，说明粒子群越趋于早熟收敛。 k_1, k_2 两个参数的选择对算法性能的影响较大，文献[21]中

通过论证, 认为取 $k_1 = 1.5, k_2 = 0.3$ 值较好。

3.2.2 收缩因子的引入

在 Clerc 等^[22]的研究中提出了收缩因子的概念, 它描述了一种选择惯性权重 ω 、加速常数 c_1 和 c_2 的的方法, 以确保 PSO 算法收敛。通过正确地选择这些控制参数, 就没有必要将 v_{id} 限制在 $[-v_{\max}, v_{\max}]$ 。带有收缩因子 χ 的速度项方程如下:

$$v_{id}(t+1) = \chi(v_{id}(t) + \varphi_1 r_1(p_{id} - x_{id}(t)) + \varphi_2 r_2(p_{gd} - x_{id}(t))) \quad (3.6)$$

$$\chi = \frac{2}{2 - \varphi - \sqrt{\varphi^2 - 4\varphi}} \quad (3.7)$$

其中 $\varphi = \varphi_1 + \varphi_2, \varphi > 4$ 。这对应于 3.1 式中的一种特殊的参数组合, 其中, χ 即是一种受 c_1 和 c_2 限制的 ω , 而 $c_1 = \chi\varphi_1$ 和 $c_2 = \chi\varphi_2$ 。

设 $\varphi_1 = \varphi_2 = 2.05$, 将 $\varphi = \varphi_1 + \varphi_2 = 4.1$ 代入 3.7, 得出 $\chi = 0.7298$, 并代入方程 3.6 得到

$$v_{id}(t+1) = 0.7298(v_{id}(t) + 2.05r_1(p_{id} - x_{id}(t)) + 2.05r_2(p_{gd} - x_{id}(t))) \quad (3.8)$$

因为 $2.05 \times 0.7298 = 1.4926$, 所以, 这个方程式同式 3.1 使用 $c_1 = c_2 = 1.4926$ 和 $\omega = 0.7298$ 所得到的方程式是等价的。

Eberhart 和 Shi 对利用 $v_{\max}$ 和收缩因子 χ 的算法做了比较, 结果表明, 后者比前者通常具有更好的收敛率, 但在一些测试函数的求解过程中, 收缩因子的粒子群优化算法在给定的迭代次数内无法达到全局极值点, 这是由于粒子偏离所期望的搜索空间太远而造成的。为了降低这种影响, 他们认为用收缩因子时首先对算法进行限定, 比如设参数 $v_{\max} = x_{\max}$, 或预先设置搜索空间的大小。这样可以改进算法对所有测试函数的求解性能。从数学上分析, 惯性权值 ω 和收缩因子 χ 这两个参数是等价的。

3.2.3 扰动因子的引入

当所有粒子都向最优解的方向飞行时, 越接近最优, 粒子速度越小, 当粒子的速度小于某一极小值时, 它的变化已经无法更新粒子的位置。因而粒子群趋向同一, 失去粒子解的分散性, 优化过程停滞不前, 易陷入局部极小值, 同时延长了迭代时间。

当粒子陷入局部极小值时, 其速度几乎为零, 因此本文提出一种速度极限扰动策略, 即当粒子速度小于某一极小值(如 0.001)时, 不遵循原来的速度更新策略, 而是随机产生速度值, 强迫粒子跳出局部极小值, 从而引发新一轮的搜索过程。扰动策略可表示为

$$\text{IF } v_{id} < v_{\min} \quad \text{THEN } v_{id} = v_{id} + \text{rand}() \quad (3.9)$$

该方法只需设定一个速度极小值, 操作方便, 效率高, 并且在应用中具有普适性。

3.2.4 粒子群算法的综合改进

由上述分析可知,在粒子群算法中引入适当的惯性权重可以保证算法在前期具有较强的全局寻优能力,在搜索后期具有较强的局部寻优能力;引入适当的收缩因子能确保粒子群算法能够收敛,而引入扰动因子,采用本文中的速度扰动策略则能够有效避免粒子在寻优过程中陷入局部极小值。这三个因子对于粒子群性能的改善都可以起到重要的作用,因此本文综合三个优化因子,设计改进的粒子群算法流程如图所示:




图 3-3 改进的粒子群算法流程图

3.3 改进前后粒子群算法的比较

为了检测标准粒子群优化算法与改进后的粒子群优化算法的性能,取测试目标函数为:

$$f(X) = (x_1 - 0.2577)^2 + (x_2 - 0.1575)^2 + (x_3 - 0.4854)^2 + (x_4 - 0.1034)^2 - 2 \quad (3.10)$$

其中 $X = [x_1, x_2, x_3, x_4]$, $x_1, x_2, x_3, x_4 \in [0, 1]$, 算法中粒子种群规模为 20, 最大迭代次数取 100, 在达到最大迭代次数的情况下停止搜索, 其中取学习因子 $c_1 = 2.8$, $c_2 = 1.3$, 于是收敛因子 $\chi = 0.7298$, 惯性权重的最大值 $\omega_{\max} = 0.9$, 最小值 $\omega_{\min} = 0.3$, 以公式 3.4 使惯性权重 ω 线性递减, 适应度阈值 $\xi = 0.001$, 联接权值在 $[-20, 20]$ 区间变化, 引入扰动因子, 设粒子速度小于 0.001 时, 强迫粒子跳出极小值, 目标误差设为 $e < 1 \times 10^{-5}$ 。




图 3-4 最优适应度进化曲线

图 3-4 最优适应度进化曲线为基本 PSO 算法和综合惯性权重、收缩因子和扰动因子后的 PSO 算法两种情况的比较结果。从图可以看出, 改进 PSO 从刚开始收敛速度就比基本 PSO 快, 而且速度明显优于基本 PSO 算法。基本 PSO 算法收敛速度主要呈线性结构, 而改进 PSO 在前 50 代收敛速度是逐渐增加的, 50 代到 100 代收敛速度是逐渐减少, 从而很好的反映了线性递减的惯性权重对于粒子群寻优的作用。为检测粒子群算法的收敛性, 对测试目标函数进行二十次测试, 结果为基本粒子群算法收敛 16 次, 收敛率为 80%, 改进后的粒子群算法的收敛次数为 19 次, 收敛率为 95%。

3.4 本章小结

本章首先介绍了粒子群优化算法的基本原理、算法流程、在此基础上分析了 PSO

算法的优势与不足。针对基本粒子群算法的不足，引入惯性权重、引入收缩因子以及引入扰动因子三个参数，提高了算法的寻优能力，保证了算法的收敛性，并且能够避免迭代后期因粒子多样性缺失而陷入局部极小值，最后对改进后的粒子群算法与基本粒子群算法进行了对比。

第四章 基于粒子群算法的 RBF 网络

4.1 径向基神经网络

近年来,随着智能技术的发展,神经网络理论已得到广泛的应用,其中前馈和反馈神经网络是两种典型的网络模型,从学习的观点看,前馈网络(包括 BP 网络、RBF 网络等)是一种较强的学习系统,具有复杂的非线性处理能力。实现映射和函数逼近是前馈网络的共同特点。

1985 年, Powell 提出了多变量插值的径向基函数(Radial Basis Function—RBF)方法。1988 年, Broomhead 和 Lowe 首先将 RBF 应用于神经网络的设计,从而构成了径向基函数神经网络,即 RBF 神经网络^[24]。

4.1.1 径向基网络的结构及数学模型

结构上看,径向基(RBF)神经网络^[25-26]属于多层前向网络。它是一种三层前向网络,如图 4-1 所示。输入层由信号源节点组成;第二层为隐含层,隐单元的个数由所描述的问题而定,隐单元节点的变换函数是对中心点径向对称且衰减的非负非线性函数;第三层为输出层,它对输入模式做出响应。




图 4-1 RBF 神经网络结构图

RBF 神经网络利用了这样的数学基础:分类问题在高维空间(某种特殊意义下的)比在低维空间中更可能是线性可分的^[27]。构成 RBF 网络的基本思想是:用径向基函数(RBF)作为隐单元的“基”,构成隐含层空间,隐含层对输入矢量进行变换,将低维的模式输入数据变换到高维空间内,使得在低维空间内线性不可分的问题在高维空间内线性可分。隐含层空间到输出层空间的映射是线性的,即网络的输出是隐层神经元输出的线性加权和,此处的权为网络的可调参数。由此可见,从总体上来说,网络由输入到输出的映射是非线性的,而网络对可调参数而言是线性的。

图 4-1 中, RBF 神经网络结构为 $n-h-m$, 即网络具有 n 个输入, h 个隐节点, m 个

输出，其中， $X_k = (x_{k1}, x_{k2}, \dots, x_{kn})^T \in R^n$ 为网络输入矢量， $\omega \in R^{h \times m}$ 为输出权矩阵， $b = [b_1, b_2, \dots, b_m]^T$ 为输出单元偏移， $Y_k = [y_{k1}, y_{k2}, \dots, y_{km}]^T$ 为网络输出， $\phi_i(\bullet)$ 为第 i 个隐节点的激活函数，也称为基函数， C_i 为网络中第 i 个隐节点的数据中心值， $\|\bullet\|$ 则表示欧氏距离，输出层节点中的 Σ 表示输出层神经元采用的线性激活函数。

设训练样本集由 S 个训练样本组成，于是有

$$X_k = [x_{k1}, x_{k2}, \dots, x_{kn}], (k=1, 2, \dots, S)$$

任一训练样本，对应的输出

$$Y_k = [y_{k1}, y_{k2}, \dots, y_{km}], (k=1, 2, \dots, S)$$

期望输出为

$$d_k = [d_{k1}, d_{k2}, \dots, d_{km}], (k=1, 2, \dots, S)$$

当网络输入训练样本 X_k 时，RBF 神经网络的第 j 个输出就可表示为

$$y_{kj} = \sum_{i=1}^h \omega_{ij} \phi_i(\|X_k - C_i\|), \quad j=1, 2, \dots, m. \quad (4.1)$$

其中，RBF 的基函数 $\phi(\bullet)$ 一般选用关于中心点对称的非线性函数，可以取多种形式，高斯函数是常用的径向基函数，其具体形式为：

$$\phi_i(x) = e^{-\frac{\|x - c_i\|^2}{2\delta_i^2}}, i=1, 2, \dots, m \quad (4.2)$$

其中的 $\delta > 0$ 称为该基函数的扩展常数或宽度。显然， δ 越小，RBF 的宽度就越小，基函数就越具有选择性。

则对应网络隐单元的高斯函数为：

$$\begin{aligned} \phi(X_k, C_i) &= \phi(\|X_k - C_i\|) \\ &= \exp\left(-\frac{1}{2\sigma_i^2} \|X_k - C_i\|^2\right) \\ &= \exp\left(-\frac{1}{2\sigma_i^2} \sum_{j=1}^n (x_{kj} - c_{ij})^2\right) \end{aligned} \quad (4.3)$$

其中 $C_i = [c_{i1}, c_{i2}, \dots, c_{in}]$ 为高斯函数的中心，代表了类的典型模式； σ_i 为高斯函数的扩展常数(spread)或宽度，决定高斯函数的形状，也决定了该中心点对应的基函数的作用范围。 $0 \leq \|X_k - C_i\| \leq 1$ ，输入 X_k 与中心距离越近，隐层节点响应输出越大，从 4.3 式可以看出，只要输入模式离中心的距离相同，节点输出就相等，因此，基函数是径向对称的，故名径向基函数。

由于 $\phi(\bullet)$ 取为高斯函数，因而对任意 X_k 均有 $\phi(X_k) > 0$ ，从而失去局部调整权值的

优点。而事实上,当 X 远离 C_i 时, $\phi(X_k)$ 已经很小,因此可以作为0对待。实际上只当 $\phi(X_k)$ 大于某一数值(例如0.05)时才对相应的权值 ω_k 进行修改。经这样处理后的RBF网络也同样具备局部逼近网络学习收敛快的优点。同时这样近似处理,可在一定程度上克服高斯函数不具备紧密性的缺点。

4.1.2 RBF 网络的参数分析

RBF神经网络的性能很大程度上受自身的网络拓扑结构影响,而决定网络性能与结构的因素主要有四个:径向基函数(RBF)的中心矢量、方差、隐层神经元数目以及隐含层到输出层神经元之间的连接权值。RBF神经网络学习训练过程主要围绕这四个因素进行,从而建立起了一个从输入到输出的映射模型。径向基函数的方差参数决定了隐神经元对外部输入信号的响应范围,每个隐神经元的中心点位置和响应宽度范围可以是不同的,分别负责各自的局部映射动作^[28]。当输入信号靠近某个隐神经元中心时,则该神经元被激活,并产生较大输出;当输入信号远离这个中心时,则该神经元的输出趋于零^[29]。径向基函数只对输入信号产生局部响应,隐含层神经元的输出在输出层进行进一步的线性加权求和,实现从输入空间到输出空间的映射,从而使整个网络达到分类或函数逼近的目的^[30]。隐层神经元数目也影响到神经网络的性能:数目太少会使网络缺乏学习与逼近能力;而数目太多又会带来网络过拟合、训练时间增加和神经网络反应速度降低等问题^[31]。

基于上述分析,RBF神经网络中待定的参数可归纳为两类:一类是基函数的中心 c_i 和宽度 σ_i 以及中心数目 n ,另一类为输出层与隐层之间的连接权重 ω 。当基函数中心 c_i 和宽度 σ_i 以及数目 n 确定之后,网络输出对输出层权参数是线性的,可由线性方程组解出或采用最小二乘法求得。因此 c_i , σ_i , n 的确定是建立RBF神经网络的关键。

4.1.3 RBF 神经网络的泛化能力分析

对于RBF网络而言,中心点的确定是个关键问题,其很大程度上决定了RBF网络泛化能力的好坏。在实际应用中,使用者最关心的也是训练后的神经网络是否具有较强的泛化能力。所谓泛化能力,是指经训练后的网络对未在训练集中出现的样本作出正确反应的能力。也就是说,网络的学习和训练不仅是对先前输入单纯的记忆,而是从大量样本中获取到隐含的内在规律,从而对其他输入也能做出正确地反应。网络的泛化能力主要由以下几个因素所影响:

- 1、待求解问题的复杂程度。它取决于问题本身,因而无法控制。
- 2、样本的质量和数量。样本集应该包含能够反映环境变化的各种信息。当网络结构一定时,样本数量应当比可调参数大几倍,这样学习结果才可靠。

3、网络结构、网络初始权值的设定和网络的学习算法。网络的结构因素主要指网络的隐含层数以及各隐含层中节点的个数对泛化能力的影响。有研究表明,网络隐含层节点数目过多会导致“过拟合”现象,从而降低网络的泛化能力。“过拟合”现象是由于训练样本有限,而在学习过程中过分追求训练集内误差最小,而对于集外的样本则无法正确处理。在神经网络结构设计中,只要能满足精度要求,RBF网络隐含层的节点不宜过多。

如果构造的 RBF 网络规模冗余,势必会造成训练、测试时的软硬件开销过大,有可能导致网络的过适应,即在训练中可以取得很好的效果,但是在测试时却没有很好的泛化能力。如果网络结构过小,RBF 神经网络无法代表数据的全局信息,因此在训练时同样得不到理想的结果^[32]。

4.2 进化算法在神经网络优化中的应用

随着进化算法研究的发展,人们逐渐将进化算法与人工神经网络相结合,利用各种进化方法来训练神经网络。由于进化算法具有较强的全局收敛能力和较强的鲁棒性,且不需要借助问题的特征信息,如导数的梯度信息。因此,将两者相结合,不仅能发挥神经网络的泛化映射能力;而且能够提高神经网络的收敛速度与学习能力。进化算法用于神经网络优化主要有两方面:一是用于神经网络的训练,即优化神经网络各层之间的连接权值及阈值;二是优化神经网络的拓扑结构。具体研究方法有如下三种^[33]:

1、通过优化连接权值来训练神经网络

针对给定的神经网络,列出所有的神经元,并将所有神经元可能存在的连接权值编码成二进制或是实数码串表示的个体,随机生成这些码串的群体,按照常规的方法执行进化操作。将新形成的码串解码构成神经网络,计算所有训练样本通过此神经网络产生的均方误差,以此来确定每一个个体的适应度值。这种方法思路简单,但用于优化的计算量较大,尤其是在优化解决复杂问题的大规模神经网络时,随着神经元数量的增多,连接权值的数目也随之增多,从而造成进化算法的搜索空间急剧增大。

2、优化神经网络的结构和学习规则

利用进化算法优化设计神经网络的结构,同时包括神经网络的学习规则以及与之关联的参数。这种方法直接将未训练的神经网络结构模式和学习规则编码成码串表示的个体,再进行操作。与前一种方法相比,其搜索空间相对较小,但是也存在着一一定的缺陷。在优化过程中,每一个被选择的个体都必须解码成未经过训练的神经网络,再经过传统的训练以确定其连接权值,因此收敛速度慢。

3、同时优化神经网络的结构和连接权值

同时对神经网络的结构和连接权值进行编码以进行优化。Vittorio 曾经提出粒度编码方法来提高连接权值的优化精度,但是这同时会加剧个体适应度值的不连续变化,从而影响到算法的收敛速度。

采用进化算法去优化神经网络，比基于梯度的神经网络学习算法，无论精度还是速度上，均有了很大的提高。然而，作为一种仿生的随机算法，进化算法本身又具有不可克服的缺陷。比如进化算法中研究最为充分的遗传算法，虽然它可以用来求解各类复杂问题，但总是难以克服过早收敛的缺点，同时在采用遗传操作进化时，需要的控制参数过多，尤其是在优化神经网络的时候，优化过程总难以控制。

4.3 PSO 算法应用于 RBF 神经网络的详细设计

4.3.1 粒子编码

在粒子群算法中，一个粒子对应于一个 RBF 神经网络的可行解。因此，以粒子群算法对 RBF 神经网络进行优化时，每个粒子中应包含 RBF 神经网络所需优化的参数，也就是基函数中心值、宽度和权值。首先将粒子比较均匀地散布在整个解空间中，有助于粒子群尽快找到全局最优解，进而将每个初始隐单元分配一个宽度值，使宽度值随隐单元位置的变化而变化，从而使隐单元在非线性映射过程中发挥最大作用，对于粒子位置和相应宽度的初始化编码的具体步骤如下：

第一步，隐单元位置的初始值由训练样本产生，假设训练样本矩阵如图 4-2 所示：

$$\begin{bmatrix} x_{11} & x_{12} & \bullet & \bullet & x_{1m} \\ x_{21} & x_{22} & \bullet & \bullet & x_{2m} \\ \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet \\ x_{n1} & x_{n2} & \bullet & \bullet & x_{nm} \end{bmatrix}$$

图 4-2 RBF 神经网络训练样本矩阵

其中 m 是输入样本的维数，也就是输入层中的神经元数目。 n 是训练样本的个数。假设 $x_{i\min}$ 是训练样本中第 i 列的最小值， Δi 是第 i 列的最大值和最小值之差， M 是一个常数。那么第 j 个隐单元的第 i 个值可以表示为：

$$hid_{ji} = x_{i\min} + rand(0, M)(\Delta i / M) \quad (4.4)$$

第二步，可以把宽度值的选取范围限定在一个比较大的范围内进行搜索，我们设定上限 $\sigma_{\max}$ 为初始化所有中心值最大欧几里德距离的两倍，下限 $\sigma_{\min}$ 为初始化所有中心值最小欧几里德距离的 0.5 倍， $\Delta\sigma$ 是 $\sigma_{\max}$ 与 $\sigma_{\min}$ 之差，那么第 i 个隐单元的宽度值可以表示为：

$$\sigma_i = \sigma_{\min} + rand(0, M)(\Delta\sigma / M) \quad (4.5)$$

第三步，对粒子速度的初始化比较简单，只需在 $[0, v_{\max}]$ 内随机得到隐单元每一维的速度即可。

通过如上三步对隐层节点中心值、宽度值以及对粒子速度的初始化，可以使粒子群较为均匀地分布在解空间中。

假设隐单元的数量为 m ，为了使计算方便简洁，每个粒子可用 $2 \times m \times n + 2 \times m + 1$ 维表示。其中，前 $m \times n$ 维表示每个隐层单元的位置，其后 m 维表示每个隐单元的宽度，因为在粒子寻优的过程中每个隐层单元的宽度都要随其位置做出自适应调整，因此每个粒子要用 $m \times n + m$ 维的长度表示速度，粒子的最后一维数据表示其适应度值。整体结构如图 4-3 所示。




图 4-3 粒子编码结构图

可以看出，利用本文的编码方式，使每个隐层中心对应各自的宽度值，每个宽度值都在粒子结构中设定各自的运行速度，因此在隐层中心位置做出改变的时候，相应的宽度值都能随之做出自适应调整，因此每个对应宽度值都能在粒子全局寻优的过程中发挥出最大的作用。

4.3.2 减聚类算法确定网络中心个数

K-means 聚类算法是确定 RBF 网络基函数中心的常用方法，但必须事先确定径向基函数中心个数。由于同一种输入样本模式可能对应于多个聚类，K-means 聚类算法得到的隐节点数目仍很大，从而产生由于隐节点数目过大而出现的过学习问题^[34]。文献[35]引入减聚类算法用于指导聚类学习，并通过一个聚类自动终止判断聚类个数。

减聚类算法^[36]是依据样本点密度来选取隐层节点的方法，避免了 K-means 算法确定隐单元个数的盲目性，是一种相对有效的确定基函数中心个数的聚类算法。考虑将数据归一化到一个单位超立体中的 n 维空间 p 个数据点 $(x_1, x_2, \dots, x_p)$ ，对数据进行归一化，定义数据点 x_i 处的密度指标为：

$$D_i = \sum_{j=1}^p \exp \left[-\frac{\|x_i - x_j\|^2}{(r_a/2)^2} \right] \quad (4.6)$$

式 4.6 中正数 r_a 定义了该点的一个邻域，半径以外的数据点对该点的密度指标贡献

甚微。显然，如果一个数据点的密度指标高，则该数据点一定有多个邻近的数据点。

在计算每个数据点密度指标后，将 D_i 保存在集合 $A(c)$ 中，供下次迭代使用，选择具有最高密度指标的点作为第一个聚类中心，令 x_{c1} 为选中的点，其密度指标记为 D_{c1} ，按照式 4.7，用 x_{c1} 取代 x_{cm} ，修正每个数据点 x_i 的密度指标。

$$D_i = D_i - D_{c_m} \exp \left[-\frac{\|x_i - x_{c_m}\|^2}{(r_b/2)^2} \right] \quad (4.7)$$

式 4.7 中，常数 r_b 定义了一个密度指标显著减小的邻域，通常大于 r_a ，这样可以避免出现相距很近的聚类中心。显然，靠近第一个聚类中心 x_{c1} 的数据点的密度指标将显著减小，这样使得这些点不太可能成为下一个聚类中心。

修正了每个数据点的密度指标后，选定下一个聚类中心 x_{c2} 再次修正数据点的所有密度指标。该过程不断重复，直到如下聚类终止判据 $D_{\max}/D_{c1} < r$ 成立。终止判据的物理意义是当前最高密度值同初始最高密度值相比非常小，也即当前聚类中心包含极少数据点时，则可忽略该聚类中心，结束聚类。

具体聚类学习步骤如下：

- 1、按式 4.6 计算每个数据点的密度指标，并将 D_i 保存在集合 $A(n_c)$ 中，供下次迭代使用，选择具有最高密度指标 D_{c1} 的数据点 x_{c1} 为第一个聚类中心，记 $m=1$ ；
- 2、确定第 m 个聚类中心，利用式 4.7 修正每个数据点的密度指标，寻找 $D_{\max}$ ；
- 3、将 $D_{\max}$ 代入终止判据，判据如果成立，则拒绝接受该点为聚类中心，到步骤 4；否则，接受具有最高密度指标的数据点 x_{cm} 为第 m 个聚类中，并将 D_i 保存到集合 $A(n_c)$ 中，且执行赋值命令 $D_{cm} = D_{\max}$ 、 $m = m + 1$ ，返回步骤 2；
- 4、聚类结束，共确定 $m-1$ 个聚类中心 $x_{c1}, x_{c1}, \dots, x_{c(m-1)}$ ，记 $n_c = m-1$ ，从而确定了 RBF 网络的隐层节点数。

4.3.3 粒子群 RBF 网络的参数设置

粒子群优化算法参数是影响算法性能和效率的关键，如何确定最优参数使算法性能最佳本身就是一个极其复杂的优化问题。

粒子群优化算法需调整参数主要包括，种群大小 m ，加速因子 c_1 、 c_2 ，惯性权重 ω ，收缩因子 χ ，扰动因子，最大速度限制 $v_{\max}$ ，最大迭代步数 $T_{\max}$ ，计算精度 ε 。其中最大迭代步数 $T_{\max}$ ，计算精度 ε 通常为算法的终止条件，由具体的问题兼顾算法的优化质量和搜索效率等多方面性能具体确定。

1、群体规模

一般取值 20-40。研究表明,对于大多数问题来说,30 个粒子就可以取得很好的结果,不过对于比较难的问题或者特殊类别的问题,粒子数目可以取到 100 或 200。另外粒子数目越多,算法搜索的空间范围就越大,也就更容易发现全局最优解。当然,算法运行的时间也较长。

2、加速因子

加速因子 c_1 和 c_2 分别代表粒子飞向个体最优解和全局最优解的加速权重,分别调节向全局最好粒子和个体最好粒子方向飞行的最大步长,若太小,则粒子可能远离目标区域,若太大则会导致突然向目标区域飞去,或飞过目标区域。

关于加速因子 c_1 、 c_2 的具体取值,大量的实验结果表明 c_1 、 c_2 之和最好接近于 4 时,算法性能较好^[37],通常 $c_1 = c_2 = 2.05$ 。也有研究者认为 c_1 、 c_2 应不相等,并由试验得出 $c_1 = 2.8, c_2 = 1.3$ 。

3、最大速度

粒子最大速度决定粒子在一次飞行中可以移动的最大距离,同惯性权重一样,它也起着平衡全局和局部搜索能力的作用。必须限制粒子最大的速度,否则,粒子就可能跑出搜索空间。粒子最大的速率通常设定为粒子范围的宽度。一般可以考虑 $v_{\max} = kx_{\max}$, 其中 $k = 0.5$ 。

4、最大位置

粒子的位置可以受最大位置 $X_{\max}$ 的限制,避免粒子飞出有物理意义的解空间之外。Robinson 提出了三种控制技术,分别为吸引墙、反射墙和不可见墙。一旦粒子的某一维碰到解空间的边界,则吸引墙方法将速度设为零,反射墙方法改变速度方向,由此这两种方法最终都可以将粒子拉回到允许的解空间范围内。而不可见墙方法对飞出边界的粒子不计算适应值,以节约计算时间并避免影响其它粒子的运动。

5、惯性权重系数

惯性权重 ω 控制着粒子的先前速度对当前速度的影响程度。惯性权重系数。取值较大时,全局寻优能力强,局部寻优能力弱。反之,则局部寻优能力增强,而全局寻优能力减弱。执行过程中可使 ω 从较大的初始值逐渐减小来提高算法的搜索性能,但搜索后期,较小的 ω 值一定程度上限制了算法的全局搜索能力。

6、扰动因子

扰动因子即为一个速度阈值。当粒子陷入局部极小值时,其速度几乎为零,速度极限扰动策略可有效解决这一问题,也就是当粒子速度小于某一极小值(如 0.001)时,不遵循原来的速度更新策略,而是随机产生速度值,强迫粒子跳出局部极小值,从而引发新一轮的搜索过程。

7、收缩因子

收缩因子描述了一种选择惯性权重 ω 、加速常数 c_1 和 c_2 的值的方法,以确保 PSO 算法收敛。带有收缩因子 χ 的速度项方程如下:

$$v_{id}(t+1) = \chi(v_{id}(t) + \varphi_1 r_1(p_{id} - x_{id}(t)) + \varphi_2 r_2(p_{gd} - x_{id}(t))), \text{ 其中 } \chi = \frac{2}{2 - \varphi - \sqrt{\varphi^2 - 4\varphi}}。$$

8、适应度函数

神经网络训练的目的在于寻找一些参数使其均方误差和最小，为了直观地表示每个粒子所表示的 RBF 神经网络参数性能，我们选择每个粒子所代表可行解的均方误差的倒数作为适应度值，其中第 i 个粒子的适应度值可表示为：

$$f(i) = 1/E(i) = 1/\sum_{k=1}^N \sum_{j=1}^M |d_{kj} - y_{kj}| \quad (4.8)$$

其中， N 代表输入样本的个数， M 代表输出结点的个数。 d_{kj} 和 y_{kj} 分别代表第 k 个样本输入时第 j 个输出节点的期望输出和实际输出。 y_{kj} 的计算需要首先计算隐层到输出层权值，权值可由下节介绍的最小二乘法得到。

9、算法终止条件

粒子群优化算法的终止条件一般可以设置为达到最大迭代次数或者满足一定的误差准则。

4.3.4 最小二乘法确定网络权值

假定当输入为 $X_j (j=1,2,...,N)$ 时，第 i 个隐节点的输出为

$$h_{ji} = \phi_i(\|X_j - c_i\|) \quad (4.9)$$

则隐输出矩阵为

$$\hat{H} = [h_{ji}] \quad (4.10)$$

其中， $\hat{H} \in R^{N \times h}$ ，如果 RBF 神经网络的当前权值为 $\omega = [\omega_1, \omega_2, ..., \omega_h]^T$ (待定)，则对所有样本，网络输出矢量为

$$\hat{y} = \hat{H} \omega \quad (4.11)$$

令 $\varepsilon = \|y - \hat{y}\|$ 为逼近误差，则如果给定了教师信号 $y = [y_1, y_2, ..., y_n]^T$ 并确定了 $\hat{H}$ ，便可通过最小化下式求出网络的输出权值：

$$\varepsilon = \|y - \hat{y}\| = \|y - \hat{H} \omega\| \quad (4.12)$$

通常， ω 可用最小二乘法求得

$$\omega = \hat{H}^+ y \quad (4.13)$$

式中， $\hat{H}^+$ 为 $\hat{H}$ 的伪逆，即

$$\hat{H}^+ = (\hat{H}^T \hat{H})^{-1} \hat{H}^T \quad (4.14)$$

4.3.5 PSO 算法优化 RBF 神经网络的流程

改进的 PSO 算法优化 RBF 网络的步骤如下：

- 1、确定适当的粒子数量，利用减聚类算法对训练样本集进行聚类分析，确定基函数的中心个数；
- 2、初始化粒子群，依据本节所述的编码方式初始化粒子群；
- 3、设定算法初始参数和停止条件；
- 4、判断算法是否符合停止条件，符合执行步骤 9，不符合执行步骤 5；
- 5、利用 PSO 算法得出此次迭代后每个粒子的新位置；
- 6、判断每个粒子的速度是否小于某一极小值(如 0.001)，是则根据前述章节中关于扰动因子的叙述，随机产生速度值，强近粒子跳出局部极小值，引发新一轮搜索过程，并执行步骤 4；
- 7、对每个粒子，比较它的适应度与它经历最好位置的适应度，如果更好，更新此粒子的所代表的局部极小点 *pbest*；
- 8、对每个粒子，比较它的适应度与群体所经历最好位置的适应度，如果更好，更新粒子群搜索到的当前全局极大值 *gbest*。执行步骤 4；
- 9、判断算法终止的条件。泛化误差是否达到一定精度，粒子迭代是否到达限定的最大步数。
- 10、将群体所经历最好位置解码后的值作为 RBF 神经网络的结构参数，结合最小二乘算法得到隐层和输出层之间的权值，对 RBF 神经网络进行训练，算法结束。

图 4-4 是 PSO 算法优化 RBF 网络的流程图。




图 4-4 改进的粒子群算法训练 RBF 网络流程图

4.4 粒子群 RBF 网络的性能评价指标

对于前馈型神经网络,在网络训练中对学习算法进行测试而得到的性能指标通常有以下四种:

- 1、错误率 ε_T , 它的值是由训练集中分类错误的样本数目除以训练集的总样本数目

而得到的。

$$\varepsilon_T = \frac{n_T}{N_T} \times 100\% \quad (4.15)$$

n_T 是训练集中分类错误的样本数目， N_T 是训练集的总样本数目。

2、测试集的分类错误率 ε_G ，它的值是由测试集中分类错误的样本数目除以测试集的总样本数目而得到的。任何测试集中的样本在训练阶段是不允许出现在训练集中的。

$$\varepsilon_G = \frac{n_G}{N_G} \times 100\% \quad (4.16)$$

n_G 是由测试集中分类错误的样本数目， N_G 是测试集的总样本数目。

3、训练集上的均方误差 MSE_T

$$MSE_T = \frac{1}{2N_T} \sum_{i=1}^{N_T} \sum_{j=1}^C (y_{ji}^d - y_{ji})^2 \quad (4.17)$$

其中， N_T 是训练集中的样本总数， C 是训练集样本的维数。

4、测试集上的均方误差 MSE_G ，也称泛化均方误差

$$MSE_G = \frac{1}{2N_G} \sum_{i=1}^{N_G} \sum_{j=1}^C (y_{ji}^d - y_{ji})^2 \quad (4.18)$$

其中， N_G 是测试集中的样本总数， C 是测试集样本的维数。

4.5 本章小结

本章首先介绍了径向基神经网络(RBF)的基本原理，网络结构及数学模型，分析了RBF网络的参数及影响RBF网络泛化能力的因素。简要说明了进化算法在神经网络中的应用，然后重点介绍了粒子群算法优化RBF神经网络的设计，首先利用减聚类算法确定RBF神经网络隐单元中心的数量，利用粒子群算法优化RBF神经网络的隐单元中心的位置宽度值，结合最小二乘法确定隐层与输出层之间的连接权值，在此基础上给出了粒子群算法优化RBF网络的流程图。最后介绍了粒子群算法优化神经网络的性能评价指标。

第五章 粒子群 RBF 神经网络在飞机燃油系统故障诊断中的应用

5.1 飞机燃油系统故障诊断的知识来源

民航飞机故障诊断所依据的知识多种多样。如徐荣红等利用神经网络和专家系统对飞机电传动系统进行故障诊断^[38]，该文中所提出的生成规则只能针对飞机的某一系统。而已有民航飞机的知识来源主要是维修手册，金林等提出从维修手册中提取故障与规则可能的映射，但是从维修手册中提取可能的故障信息，这与实际存在着差别^[39]；董健康等依据维修手册提出了对使用历史记录进行决策的方法进行故障诊断，但历史数据的统计过程繁琐，所以方法不能普遍适用^[40]。

传统的民航故障诊断依据的信息主要有维修手册和维修大纲。适航规定民航飞机故障诊断时依据维修手册^[41]，维修手册中包含了民航飞机的结构简图、故障诊断步骤等信息，故障诊断人员在使用中按自己的理解形成推理规则。维修手册内容主要包括传统的故障隔离和排除的全过程^[42]。由于维修手册是标准文件，未体现出飞机使用后的个体特征和环境差异，同时从维修手册中获取的规则往往比实际情况复杂。

维修大纲是民航故障诊断依据的计划性文件，主要包含了部件的计划维修信息。维修大纲内容包括故障发生的维修间隔、维修等级、计划维修项目、零部件的重要度等信息^[43]。通过维修大纲可以估计故障出现的时间，用这一时间与实际的工作时间比较，可以指导故障诊断。

由上可知，因为维修手册和维修大纲是设计人员制订的，所以它们与实际存在着一定差别。而故障诊断是一种使用后的行为，所以本文从可靠性报告中提取历史数据，提出应用可靠性报告作为故障诊断重要依据的思想。

可靠性报告是由飞机制造商和航空公司定时发布^[44]，主要包括零部件的故障次数统计、零部件的拆换统计(包括计划拆换和非计划拆换)、飞机的飞行和签派数据等。可靠性报告是故障统计历史信息的记录，其实质是故障的经验统计，是一种使用后的行为，也是智能故障诊断方法应用的主要领域。

所以将故障的历史记录与传统的故障诊断规则相结合，综合维修手册、维修大纲和可靠性报告可以全面考虑民航飞机的故障诊断信息。它们构成了民航飞机故障诊断的知识来源，见图5-1：




图5-1 民航飞机故障诊断的知识来源

5.2 故障诊断的知识复合模型设计

通过分析民航飞机故障诊断所能依据的信息，可以看出，从维修手册、维修大纲、可靠性报告中提取故障诊断规则，包括了维修手册中的故障推理知识、维修大纲中的经验知识和可靠性报告中的统计知识。将三种信息综合考虑建立民航飞机故障诊断知识复合模型的规则获取流程，如图5-2所示。




图5-2 知识复合模型的规则获取流程图

飞机故障诊断传统方法所依据的维修手册和维修大纲在飞机投入运营后基本不变，从中提出的规则可以归属为传统规则；可靠性报告是定期发布的、某时段内的飞机使用统计信息，与实际故障诊断过程接近。复合的方法是将三类知识来源进行分析，将知识进行推理，得到的规则进行统一处理。

5.3 飞机燃油系统故障特征向量设计

根据知识复合方法，本文以维修手册、维修大纲、可靠性报告为知识来源，整理得到飞机燃油系统故障诊断规则，对飞机燃油系统进行分析之后所得到的故障征兆与故障类型之间的关系图如下所示：




图5-3 飞机燃油系统故障征兆与故障类型对应关系图

由上图可知,引起飞机燃油系统故障的征兆有 6 个,分别是 K_1 : 机身副油箱信号灯不灭; K_2 : 一组油尽灯提前亮; K_3 : 机身副油箱不输油或输油慢; K_4 : 副油箱增压压力小; K_5 : 油箱冲压活门处漏油; K_6 : 机翼油箱不输油。而对应的故障类型有 9 个,分别是 1: 机身副油箱压力信号故障; 2: 增压管路漏油; 3: 5 号油箱浮子信号传感器故障; 4: 7 号油箱浮子活门故障; 5: 机身副油箱增压安全活门故障; 6: 机身副油箱活门卡滞故障; 7: 副油箱油盖不封密; 8: 单向活门组被堵; 9: 油量耗量表传感器故障。

故障征兆与故障类型的对应关系图中,我们可以看出故障类型 1 对应故障征兆 K_1 ; 故障类型 2 对应故障征兆 K_1, K_2, K_3, K_4, K_6 ; 故障类型 3 对应故障征兆 K_2 ; 故障类型 4 对应故障征兆 K_2, K_3, K_5, K_6 ; 故障类型 5 对应故障征兆 K_2, K_4 ; 故障类型 6 对应故障征兆 K_5 ; 故障类型 7 对应故障征兆 K_1, K_2, K_3, K_4 ; 故障类型 8 对应故障征兆 K_2, K_3 ; 故障类型 9 对应故障征兆 K_2 。

于是,基于 RBF 神经网络的飞机燃油系统故障诊断的特征向量可表示为表 5.1:

表 5.1 飞机燃油系统故障诊断特征向量表

故障原因	特征向量					
	K_1	K_2	K_3	K_4	K_5	K_6
1	1	0	0	0	0	0
2	1	1	1	1	0	1
3	0	1	0	0	0	0
4	0	1	1	0	1	1
5	0	1	0	1	0	0
6	0	0	0	0	1	0
7	1	1	1	1	0	0
8	0	1	1	0	0	0
9	0	1	0	0	0	0

5.4 故障诊断流程框图设计

基于神经网络的飞机燃油系统的故障诊断仿真步骤是:首先以知识复合模型对飞机维修手册、维修大纲和可靠性报告进行综合分析,得到飞机燃油系统故障征兆与故障原因之间的关系,经预处理提取征兆集数据,归一化为网络输入模式;第二步样本集训练神经网络,使神经网络获取诊断飞机燃油系统故障所需要的知识。对于粒子群优化的 RBF 神经网络而言,这些知识是由分布在网络内部的隐节点数据中心及连接权值隐性表达的。之后再输入以征兆向量进行测试,获得粒子群 RBF 网络的输出,然后对网络输出进行处理后获得诊断结果,获取故障发生的位置和性质。图 5-4 为故障诊断流程框图:




图5-4 基于粒子群RBF网络的故障诊断框图

5.5 粒子群优化 RBF 神经网络故障诊断算法的 Matlab 实现

快速发展的Matlab软件为神经网络理论的实现提供了一种便利的仿真手段。Matlab神经网络工具箱的出现，更加拓展了神经网络的应用空间。神经网络工具箱将很多原本需要手动计算的工作交给计算机，一方面提高了工作效率，另一方面，还提高了计算机的准确度和精度，减轻了工作人员的负担。

Matlab的神经网络工具箱，它为人工神经网络编程提供了很大的便利。它以人工神经网络理论为基础，利用MATLAB编程语言构造出许多典型神经网络的激活函数，如S型、线性、竞争层、饱和线性等激活函数，使设计者对所选定网络输出的计算，转变为对激活函数的调用。另外，可以根据各种典型的修正网络权值的规则，加上网络的训练过程，利用Matlab语言编写各种网络权值训练的子程序。这样一来，网络的设计者可以根据自己的需要调用工具箱中有关神经网络的设计与训练的程序，使自己能从繁琐的编程中解脱出来，集中精力思考和解决问题，从而提高效率和质量。

5.5.1 粒子群优化 RBF 神经网络的初始化

```

AllSamIn=;
AllSamout=;
前向通道数据预设的最大值和最小值，可以用其它函数实现：
global minAllSamout;           %最小总样本输出
global maxAllSamout;
[] =premnmx();
TestSamIn=[];
TestSamout=[];
TargetOfTestSam=[];           %测试样本目标
TrainSamIn=AllSamInn;
TrainSamOut=AllSamOutn;
样本评估：
EvaSamIn=[];                   %样本评估输入
  
```

```

EvaSamInn=tramnmx(EvaSamIn,minAllSamIn,maxAllSamIn); %归一化处理
global Ptrain;
Ptrain=TrainSamIn;
global Ttrain;
Ttrain=TrainSamOut;
Ptest=TestSamIn;
Ttest=TestSamOut;
Spread=1.2; % 分布常数
vmax=0.5; % 最大速率
minerr=0.001; % 适应度阈值
wmax=0.90; % 惯性权重的最大值
wmin=0.30; % 惯性权重的最小值
global itmax;
itmax=300; %最大允许迭代步数
c1=2.8; %学习因子
c2=1.3; %学习因子
for iter=1:itmax
W(iter)=wmx-((wmax-wmin)/itmax)*iter; %惯性权重线性下降
end
粒子在a,b之间随机初始化:
a=-1;
b=1;
m=-1;
n=1;
global N; %粒子群数目
N=40;
global D; %粒子群长度
D=(indim+1)*hiddennum+(hiddennum+1)*outdim;
粒子群位置初始化:
rand('state',sum(100*clock)); %产生0-1之间的随机数，粒子在a,b即-1和1
之间随机初始化
X=a+(b-a)*rand(N,D,1); %产生N行D列由0-1之间的数组成的矩阵
V=m+(n-m)*rand(N,D,1); %粒子群速度在m,n即-1和1之间初始化

```

5.5.2 粒子群优化 RBF 神经网络的适应度值

```

global fvrec;
MinFit=[]; %最小适应度

```

```

BestFit=[]; %最大适应度
global net; %net—待初始化的神经网络
net=newrbe(P,T,spread); %创建一个RBF网络
调用fitcal函数:
fitness=fitcal();
fvrec(:,1,1)=fitness(:,1,1);
[C,I]=min(fitness(:,1,1));
MinFit=[MinFit C];
BestFit=[BestFit C];
L(:,1,1)=fitness(:,1,1); %记录每次反复的粒子的适应函数
B(1,1,1)=C; %记录粒子的最小适应函数
gbest(1,:,1)=X(I,:,1); %全局极值

```

5.5.3 粒子群优化 RBF 神经网络的粒子速度和位置计算

```

V(:,2)=W(1)*V(:,1)+c1*rand*(pbest(:,1)-X(:,1))+c2*rand*(G(:,1)-X(:,1));
用vmax限制粒子的速度, 如果V>vmax则V=vmax,如果V<-vmax则V=-vmax;
for ni=1:N
for di=1:D
if v(ni,di,2)>vmax
V(ni,di,2)=vmax;
elseif V(ni,di,2)<-vmax
V(ni,di,2)= -vmax;
else
V(ni,di,2)= V(ni,di,2);
end
end
end
X(:,2)= X(:,1)+ V(:,2);

```

5.5.4 粒子群优化 RBF 神经网络的粒子适应度值更新

适应度值的更新就是粒子群优化神经网络的过程, 当神经网络的均方误差指标满足要求时, 粒子群根据均方误差来判断好位置, 并将其保存在最优粒子位置数据内。

新位置的计算:

```

fitness=fitcal(X,net,indim,hiddennum,outdim,D,Ptrain,Ttrain,minAllSamOut,maxAllSamOut)
;
fvrec(:,1,j)=fitness(:,1,j);
[C,I]=min(fitness(:,1,j));
MinFit=[ MinFit C];
BestFit=[ BestFit min(MinFit)];

```

```

L(:,1,j)=fitness(:,1,j);
B(1,1,j)=C;
gbest(1,:,j)=X(1,:,j);
[C,I]=min(B(1,1,:));
保持gbest是已出现的最好粒子:
if B(1,1,j)<=C
gbest(1,:,j)= gbest(1,:,j);
else
gbest(1,:,j)= gbest(1,:,I);
end

```

5.5.5 粒子群优化 RBF 神经网络的速度和位置更新

$$V(:,j+1)=W(j)*V(:,j)+c1*rand*(pbest(:,j)-X(:,j))+c2*rand*(G(:,j)-X(:,j));$$

5.6 基于粒子群 RBF 网络的燃油系统故障诊断实现

以表 5.1 所示的飞机燃油系统故障诊断特征值作为 RBF 网络的输入，选择单位矩阵作为对应的期望输出，便构成 RBF 网络的训练样本，如表 5.2 所示：

表 5.2 飞机燃油系统故障诊断的训练样本

故障 类型	特征向量						期望输出								
	K ₁	K ₂	K ₃	K ₄	K ₅	K ₆									
1	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0
2	1	1	1	1	0	1	0	1	0	0	0	0	0	0	0
3	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0
4	0	1	1	0	1	1	0	0	0	1	0	0	0	0	0
5	0	1	0	1	0	0	0	0	0	0	1	0	0	0	0
6	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0
7	1	1	1	1	0	0	0	0	0	0	0	0	1	0	0
8	0	1	1	0	0	0	0	0	0	0	0	0	0	1	0
9	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1

5.6.1 粒子群优化 RBF 神经网络设计

采用的粒子群RBF神经网络有输入节点6个，输出节点9个，取 $\gamma_a = 0.5$ ， $\gamma_b = 0.55$ ，运用减聚类算法确定基函数中心个数为10个。经过多次试验比较后，粒子群的粒子个数取 $N = 40$ ，设 $V_{\max} = X_{\max}$ ，为保证算法收敛，根据第三章收敛因子部分的分析，取学习

因子 $c_1 = 2.8$, $c_2 = 1.3$, 这等同于取收敛因子 $\chi = 0.7298$, 惯性权重的最大值 $\omega_{\max} = 0.9$, 最小值 $\omega_{\min} = 0.3$, 以公式(3.4)使惯性权重 ω 线性递减, 适应度阈值 $\xi = 0.001$, 联接权值在 $[-20, 20]$ 区间变化, 迭代终止条件为使目标误差 $e < 1 \times 10^{-5}$ 且设最大允许迭代步数 $T_{\max} = 300$, 以此构建起粒子群优化神经网络的算法所需要的基本参数。

为便于比较, 采用构造具有相同网络结构的RBF神经网络(输入节点6个, 隐单元个数为10个, 输出节点9个), 同样设置训练误差精度达到 $e < 1 \times 10^{-5}$ 满足学习要求, 径向基函数的扩展常数设为0.5。同时构造BP神经网络, 网络结构为 $6 \times 7 \times 9$, 目标误差 $e < 1 \times 10^{-5}$ 。

5.6.2 RBF 网络的训练及诊断结果分析

以表 5.2 所示的样本训练粒子群 RBF 神经网络, RBF 神经网络和 BP 神经网络。训练结果如下所示:




图 5-5 粒子群 RBF 神经网络的训练结果




图 5-6 RBF 神经网络的训练结果




图 5-7 BP 神经网络的训练网络

由图5-5，图5-6，图5-7，我们可对BP、RBF神经网络和粒子群RBF神经网络的简单的比较，表5.3为三种神经网络在设定误差下的样本学习收敛所需步数，所用时间和实际训练误差。

表5.3 神经网络的比较

神经网络算法	设定误差	实际训练误差	实际学习步数	学习时间(s)
BP神经网络	1×10^{-5}	1.44×10^{-10}	112	11.43
RBF神经网络		3.85×10^{-31}	8	1.21
粒子群RBF神经网络		2.11×10^{-31}	6	0.095

可以看出经粒子群优化的RBF网络在给定误差 1×10^{-5} 下，仅需要6步，耗时0.095s，实际训练误差达到 2.11×10^{-31} 。RBF神经网络需要8步，耗时1.21s，而BP网络需要112步，耗时11.83s才能达到精度要求。此外在实际训练误差方面，PSO-RBF和RBF具有同一数量级的训练误差，略小于RBF，但远远小于BP网络，可见粒子群优化后的RBF神经网络具有更好的性能。

为验证BP、RBF和粒子群RBF网络已达到训练要求，以7号油箱浮子活门故障为例对它们分别进行测试，所对应的故障征兆有 K_2 一组油尽灯提前亮， K_3 机身副油箱不输油或输油慢， K_5 油箱冲压活门处漏油， K_6 机翼油箱不输油，即输入样本(0, 1, 1, 0, 1, 1)，网络正确的输出应是(0, 0, 0, 1, 0, 0, 0, 0, 0)。所得到的测试结果如表5.4所示：

表5.4 网络测试结果

故障	1	2	3	4	5	6	7	8	9
理想输出	0	0	0	1	0	0	0	0	0
BP	0.023	0.171	0.216	0.852	0.106	0.221	0.107	0.318	0.091
RBF	0.153	0.069	0.173	0.913	0.109	0.073	0.108	0.042	0.071
PSO-RBF	0.079	0.058	0.142	0.968	0.082	0.059	0.037	0.106	0.047

由上表可知, BP网络, RBF网络和PSO-RBF网络的输出与理想输出接近, 测试诊断结果都是7号油箱浮子活门故障, 说明网络都达到了训练要求。

下面以训练集上的均方误差 MSE_T 作为网络评价标准对三种神经网络进行评价, 评价公式为 $MSE_T = \frac{1}{2N_T} \sum_{i=1}^{N_T} \sum_{j=1}^C (y_{ji}^d - y_{ji})^2$, 为简单起见, 只以 7 号油箱浮子活门故障来评价, 计算得到 BP 神经网络的 MSE_T 等于 0.1396, RBF 网络的 MSE_T 等于 0.0507, PSO-RBF 网络的 MSE_T 等于 0.0341。由此看来与同为前馈网络 BP 神经网络相比, RBF 网络在训练样本上有很大的提高, 从 MSE_T 评价标准来看, 本文中所述的粒子群 RBF 网络, 对 RBF 网络作了改进, 得到了更好的训练结果, 验证了该方法是可行的。

最后, 本文以可靠性报告中的记录作为测试样本, 对神经网络的泛化能力和故障诊断能力进行测试。

某一次燃油系统出现以下故障征兆: 一组油尽灯提前亮, 副油箱增压压力小, 油箱冲压活门处漏油, 也就是对应的征兆 K_2 、 K_4 和 K_5 , 而实际的故障原因是机身副油箱增压安全活门故障, 即故障 5。结合该事例, 对 BP、RBF 和 PSO-RBF 网络分别进行 Matlab 仿真测试, 对故障征兆进行特征提取并编码后得到故障特征向量为(0, 1, 0, 1, 1, 0), 输入神经网络后, 所得的诊断结果如表 5.5 所示。

表5.5 测试样本网络输出结果比较

故障	1	2	3	4	5	6	7	8	9
理想输出	0	0	0	0	1	0	0	0	0
BP	0.172	0.313	0.210	0.579	0.552	0.004	0.302	0.106	0.221
RBF	0.103	0.226	0.265	0.298	0.834	0.142	0.272	0.195	0.117
PSO-RBF	0.132	0.170	0.089	0.091	0.927	0.102	0.164	0.025	0.087

测试结果显示, 故障4和故障5数值上比较接近, BP神经网络在该事例中可能出现误诊, 而RBF和PSO-RBF网络均给出了正确的诊断结果。

以测试集上的均方误差 MSE_G 作为评价指标对该诊断结果进行比较。评价方程为 $MSE_G = \frac{1}{2N_G} \sum_{i=1}^{N_G} \sum_{j=1}^C (y_{ji}^d - y_{ji})^2$, 经计算得到 BP 神经网络的 MSE_T 等于 0.6024, RBF 网络的 MSE_T 等于 0.1853, PSO-RBF 网络的 MSE_T 等于 0.1047。由此可知, PSO-RBF 网络的故障诊断能力要优于 RBF 网络, 并且远远优于 BP 网络。

结果表明, 粒子群算法优化的RBF网络无论从训练误差、训练次数和训练时间, 还是从故障诊断能力和网络性能上来看都优于BP网络和RBF网络, 利用粒子群RBF网络对飞机系统进行故障诊断是精确高效的。

5.7 本章小结

本章介绍了粒子群算法优化的RBF网络对飞机燃油系统的故障诊断。首先分析了飞机燃油系统故障诊断的知识来源，在此基础上提出了结合维修手册、维修大纲和可靠性报告的复合知识获取模型，进而给出燃油系统的故障征兆和故障类型关系图，以此设计燃油系统的故障特征向量，作为神经网络的训练样本。以Matlab为平台，编写基于粒子群优化RBF网络的故障诊断程序，并利用之前得到的训练样本对其进行训练，实现故障诊断。最后本文对BP网络，RBF网络和粒子群改进的RBF网络进行了故障诊断对比，证明了粒子群RBF网络在飞机系统的故障诊断应用的可行性以及优越性。

结论

粒子群算法具有较快的收敛速度和较强的全局收敛能力,且不需要借助问题的特征信息,如导数等梯度信息,实现起来非常容易。因此,随着粒子群等群体智能算法的迅速发展,将粒子群算法用于神经网络的优化过程已经成为了国际上一个非常热门的研究领域,而径向基(RBF)网络具有结构简单、训练速度快、诊断精度高等优点。因此将粒子群算法与RBF神经网络优化相结合,不仅能发挥神经网络的泛化映射能力,而且能够提高神经网络的收敛速度及学习能力。针对这些特点,本文在分析神经网络的学习方式和泛化能力的基础上,对粒子群算法和RBF神经网络进行了深入研究,设计并实现了基于PSO的神经网络优化算法,提高了RBF神经网络的性能。最后以B737飞机燃油系统为对象,利用粒子群RBF网络对其进行故障诊断,并与BP和RBF网络进行对比,验证了粒子群RBF网络进行故障诊断的优越性。本文所做的研究工作总结如下:

1、传统的民航故障诊断依据的信息主要有维修手册和维修大纲,维修手册和维修大纲是设计人员制订的,所以它们与实际排故存在着一定差别。而故障诊断是一种使用后的行为,本文从可靠性报告中提取历史数据,提出应用可靠性报告作为故障诊断依据的思想,并结合维修手册和维修大纲给出了飞机故障诊断知识复合模型。

2、粒子群优化算法的参数是影响算法性能和效率的关键,而确定最优参数使算法的运行达到最佳效果本身又是一个极其复杂的优化问题。由于参数空间的大小不同,且各参数间的相关性,在实际的应用中,尚无确定最优参数的通用方法,只能凭用户的经验选取。本文参阅了大量粒子群优化算法参数选择分析方面的论文,并根据各个控制参数值的意义和关系,给出了参数选择的一些经验值,为算法的实际应用打下坚实的基础。

3、RBF网络是一种性能优良,有着巨大潜力的神经网络。本文在介绍RBF网络基本原理、网络结构及数学模型的基础上,对RBF网络中的参数以及影响RBF网络泛化性能的因素进行了分析总结。

4、本文在粒子群算法中同时引入惯性权重、收缩因子和扰动因子,从而解决了粒子群算法容易陷入局部最优解的问题,确保了算法的收敛性并且提高了粒子群算法的寻优能力。把改进粒子群算法用于对RBF神经网络参数的优化,克服了PSO算法局部搜索能力差的问题,同时提高了RBF网络的全局寻优能力。

5、为了验证粒子群优化神经网络的飞机燃油系统故障诊断方法的可行性,本文首先设计了故障诊断方案,然后以维修手册,维修大纲和可靠性报告为故障诊断知识来源,建立RBF神经网络的训练样本,并应用Matlab语言编制了改进的粒子优化RBF神经网络算法程序,最后以粒子群RBF网络对飞机燃油系统进行故障诊断,得到故障诊断结果与BP和RBF网络对比,实验结果表明诊断结果更好,验证了粒子群RBF神经网络的优越性。

此外,本文还存在一些不足和有待改进的地方,仍有许多值得深入研究的问题和方向:

1、民航飞机是大型复杂的机电系统，其故障发生时，故障现象复杂，而且很多时候是多故障同时出现，本文只针对单故障的诊断，与实际飞机系统故障诊断尚存在着一定差别。

2、完善粒子群算法的理论：虽然粒子群算法在很多领域得到了应用，但是其理论基础相当薄弱，一些学者采用简化模型对其粒子轨迹、收敛条件进行了分析，但实际粒子轨迹的运动是一个随机事件，在这方面的研究还比较少见，这也关系到算法的收敛性、参数的选择等问题。

3、基于粒子群算法的RBF神经网络优化是一个有监督的学习过程，因此对于训练数据的选择和预处理显得十分重要，本文中的数据预处理只是粗浅地处理，可以预计这样的处理并不适用于较大的数据，因此需要对数据的预处理工作进行一定的改进。这样可以间接的提高网络的训练效果。

4、基本粒子群算法在收敛性能上的缺陷，学习算法有可能收敛于局部最优解，从而影响优化网络的性能。本文虽然在算法上引入了惯性权重、收缩因子和扰动因子这三个控制参数，但实际仿真过程中，算法仍然存在粒子的早熟问题，存在收敛到局部最优解的可能性，需要在今后的研究中从算法的模型以及参数的控制入手来进一步提高算法的收敛性。

致谢

值此论文即将完成之际，谨向所有关心、帮助、支持我的老师、同学和朋友们致以最诚挚的谢意。

攻读硕士学位期间，自始至终得到了导师张鹏教授的悉心指导和无微不至的关怀。张老师渊博的学识、活跃的学术思想、敏捷的思维、严谨求实的治学作风、锐意创新的科研精神和平易近人的师长风范，无一不令我肃然起敬。他不仅在学术研究方面对我倾注了很大的心血和努力，更为重要的是，我从他身上学到了很多待人接物、为人处世的道理，这将使我受益终生。在此谨向恩师表达最衷心的感谢和最诚挚的敬意。

感谢华克强教授在这两年多的学习生涯中对我的关爱与提携。华老师兢兢业业的敬业精神和对学术理论的通透掌握给了我很大的启发。我向华老师表示深深的感谢，衷心祝愿华老师身体健康，幸福平安。

研究生学业生涯中，有幸认识了很多朋友，他们在学习、生活等方面都给了我无私的帮助。在此衷心感谢王婷、谈斌、付晶、皮博浩、李荣松、纪雪松等硕士，祝愿他们在将来的学习和工作中前程似锦。

特别感谢我的父母和陈捷晨，感谢他们对我学业的支持。正是他们的殷切期望、鼓励和帮助，才使我能安心学习、完成自己的论文。

最后，感谢所有给予我关心、教诲和帮助的师长、亲人、同学和朋友们！

参考文献

- [1] 杨军等. 装备智能故障诊断技术[M]. 国防工业出版社, 2004
- [2] 董健康, 樊建梅. 波音 777 飞控系统故障模型研究与实现[D]: [硕士学位论文]. 天津: 中国民用航空学院, 2006
- [3] Saunterd, Hamelinf. Frequency-domain optimization for robust fault detection and isolation in dynamic systems. IEEE on Automatic Control, 1999, 44(4): 878-882
- [4] 张宝珍. 国外综合诊断、预测与健康管理工作的发展及应用[J]. 计算机测量与控制, 2008, 16(5): 15-18
- [5] 李建伟, 汪成亮, 周亚鑫. 专家系统在飞机故障诊断与维护指导系统中的实际应用[J]. 计算机应用与软件, 2009, 5
- [6] 董健康, 耿宏. 民航飞机排故专家系统研究[J]. 航空维修与工程, 2004, 2
- [7] 孙健, 章卫国, 宁东方. 基于神经网络的飞控系统故障诊断[J], 测控技术, 2008
- [8] 张阔等. 基于 RBF 神经网络的自动驾驶仪故障诊断[J], 数据采集与处理, 2006, 12
- [9] 邸亚洲, 李宝亭, 袁涛. 支持向量机在机载设备故障诊断及预测中的应用研究[J], 科技信息, 2008, 2
- [10] 包方. 基于智能算法的神经网络优化及其应用[D]: [硕士学位论文]. 江苏: 江南大学, 2008
- [11] J.Kemredy, R. C. Ebehart. Swarm Intelligence. Morgan Kaufmann Publihers, Inc. San Francisco, CA, 2001
- [12] 熊凌, 赵明旺. 基于遗传算法的 BP 网络全局收敛的混合智能算法. 武汉科技大学学报. 2000, 23(3): 183-186
- [13] 寇晓丽, 刘三阳. 基于模拟退火的粒子群算法求解约束优化问题[J]. 吉林大学学报(工学版). 2007, 31(1): 136-140
- [14] 柴长松, 张欣, 牛奔等. 基于粒子群神经网络的发动机故障诊断[J]. 微计算机信息, 2007: 23(8-1): 186-187
- [15] 张学良, 温淑花, 李海楠等. PSO 算法在多目标优化问题中的仿真应用[J]. 农业机械学报, 2007, 38(7): 112-115
- [16] Eberhart, R. Kennedy, J. A New Optimizer Using Particle Swarm Theory [C]. In: Proc of the Sixth International Symposium on Micro Machine and Human Science. Nagoya. Japan. 1995: 39-43
- [17] 李建勇. 粒子群优化算法研究[D]: [硕士学位论文], 浙江: 浙江大学. 2004
- [18] Trelea I. The particle swarm optimization algorithm: Convergence analysis and parameter selection. Information Processing Letters, 2003, 85(6): 317-325
- [19] Eberhart R, Shi Y. Comparing inertia weights and constriction factors in particle swarm

- optimization. IEEE Congress on Evolutionary Computation, 2000: 84-88
- [20] 王俊伟, 汪定伟. 粒子群算法中惯性权重的实验与分析[J]. 系统工程学报, 2005, 20(2): 194-198
- [21] 韩江洪, 李正荣, 魏振春. 一种自适应粒子群优化算法及其仿真研究[J]. 系统仿真学报, 2006, 18(10): 2969-2971
- [22] Clerc M, Kennedy J. The Particle Swarm- explosion, Stability, and Convergence in A Multidimensional Complex Space[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(1): 58-73
- [23] Boeringer, D. W. and Werner, D. H. Particle swarm optimization versus genetic algorithms for phased array synthesis. IEEE Transactions on Antennas and Propagation, 2004, 52(3): 771-779
- [24] 高隽. 人工神经网络原理及仿真实例[M]. 机械工业出版社, 2003, 7
- [25] 魏海坤. 神经网络结果设计的理论与方法[M]. 北京: 国防工业出版社, 2005
- [26] 周志华, 彻云霄, 曹存根. 神经网络及其应用[M]. 北京: 清华大学出版社, 2004
- [27] Simon Haykin 著. 神经网络原理[M]. 叶世伟, 史忠植译. 机械工业出版社, 2004
- [28] 宋保强, 付琼, 宋彤. 改进的 RBF 神经网络及其应用[J]. 计算技术与自动化, 2001, 20(3): 66-69
- [39] 汪小帆, 宋文忠. 径向基函数神经网络的一种构造算法[J]. 控制与决策, 1997, 12(2): 150-155
- [30] 姜显扬. 基于遗传算法优化神经网络的混沌控制方法[D]: [硕士学位论文]. 郑州: 郑州大学, 2004
- [31] 张雨浓. 人工神经网络的面向对象软件实现[D]: [硕士学位论文]. 广州: 华南理工大学, 1999
- [32] 张顶学, 关治洪, 刘新芝. 基于 PSO 的 RBF 神经网络学习算法及其应用[J]. 计算机工程与应用, 2006, 20(5): 362-368
- [33] 李博. 粒子群优化算法及其在神经网络中的应用[D]: [硕士学位论文]. 大连: 大连理工大学, 2005: 3
- [34] 张友民, 李庆国, 戴冠中等. 一种 RBF 网络结构优化方法[J]. 控制与决策, 1996, 11(6): 667-671
- [35] Haralambos Sarimveis . A Fast Training Algorithm for RBF Networks Based on Subtractive Clustering. Neurocomputing, 2003, (51): 501-505
- [36] 张顶学, 关治洪, 刘新芝. 基于 PSO 的 RBF 神经网络学习算法及其应用[J]. 计算机工程与应用, 2006, 20(5): 362-368
- [37] Kennedy, J. Thinking is Social: Experiments with the Adaptive Culture Model. Journal of Conflict Resolution. 1998, 42(1): 56-76
- [38] 徐荣红, 孙金标. 基于神经网络和专家系统的电传动操纵系统故障诊断[J]. 航空学

- 报, 2005, 26(2): 195-198
- [39] 金林, 张洪才. 一种基于模糊神经网络的故障诊断方法[J]. 西北工业大学学报, 2004, 22(5): 657-661
- [40] 董健康, 耿宏. 飞机排故方法模糊与统计综合评估算法的研究[J]. 航空学报, 2004, 25(3): 258-262
- [41] Air Transport Association of America, Inc. 2000, 4-1707 ATA2200[S]. Washington DC ATA Inc, 2003
- [42] Bombardier. CSP A-001 CRJ200/440 Aircraft Maintenance Manual[Z]. Canada, 2002: 1053-1064
- [43] Bombardier . CSP B-053 CRJ700/CRJ900 Maintenance Review Board Report [Z]. Canada, 2001: 58-70
- [44] Bombardier. CSP A-113 CRJ100/200 Quarterly/Monthly FRACAS report[Z]. Canada, 2004: 88-89, 135-136

