

电子科技大学
UNIVERSITY OF ELECTRONIC SCIENCE AND TECHNOLOGY OF CHINA

博士学位论文

DOCTORAL DISSERTATION

(电子科技大学图标)

论文题目

基于粒子群优化算法的航空发动机

故障诊断与性能参数预测研究

学科专业

机械工程

学号

201411080101

作者姓名

郑波

指导教师

黄洪钟 教授

分类号 TP177

密级

UDC 注1

学位论文

基于粒子群优化算法的航空发动机

故障诊断与性能参数预测研究

(题名和副题名)

郑波

(作者姓名)

指导教师

黄洪钟

教授

电子科技大学

成都

(姓名、职称、单位名称)

申请学位级别 博士

学科专业 机械工程

提交论文日期 2018.04.27

论文答辩日期 2018.06.06

学位授予单位和日期

电子科技大学

2018年06月

答辩委员会主席

评阅人

注1: 注明《国际十进分类法 UDC》的类号。

**Research on Aeroengine Fault Diagnosis and
Performance Parameters Prediction Based on
Particle Swarm Optimization**

**A Doctoral Dissertation Submitted to
University of Electronic Science and Technology of China**

Discipline: Mechanical Engineering

Author: Bo Zheng

Supervisor: Prof. Hong-Zhong Huang

School: School of Mechanical and Electrical Engineering

独创性声明

本人声明所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。据我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得电子科技大学或其它教育机构的学位或证书而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示谢意。

作者签名：郑波

日期：2018年6月28日

论文使用授权

本学位论文作者完全了解电子科技大学有关保留、使用学位论文的规定，有权保留并向国家有关部门或机构送交论文的复印件和磁盘，允许论文被查阅和借阅。本人授权电子科技大学可以将学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。

(保密的学位论文在解密后应遵守此规定)

作者签名：郑波

导师签名：黄浩钟

日期：2018年6月28日

摘 要

航空发动机作为保障飞行安全运行的核心部件，由于其运行环境的不确定性、严苛性，本身系统构成的复杂性，使得对航空发动机的故障诊断与预测成为一项复杂而又关键的任务，不仅影响航空公司等运营团体的经济利益，更与人员生命财产安全直接相关。随着现代传感器技术、通信技术的快速发展，使得对航空发动机的状态监控和趋势分析成为现实，基于智能算法的诊断与预测技术被广泛采用，使航空发动机的维修保养思想得到根本改变。针对航发发动机故障诊断、预测、及数据处理等问题，本文提出基于粒子群优化（Particle Swarm optimization, PSO）算法的诊断与预测方法，拓展 PSO 算法应用范围，利用粒度计算进行相似性数据压缩，降低算法时间开销。将优化领域的 PSO 算法作为故障诊断与预测工具，对本文是一项挑战。本文主要工作与创新点如下：

（1）PSO 算法作为经典群体智能算法，在优化领域具有广泛的应用，但因容易陷入局部最优区域而导致早熟收敛。实质上，缺乏种群多样性和有效交互模式，以及搜索过程的不平衡、更新策略的单一化，都是导致早熟收敛的原因。受人类学习行为的启发，围绕导致早熟收敛的原因，对 PSO 算法进行有效改进，通过将粒子群划分为导师和学生，模拟人类的集体学习行为，私人辅导行为，以及研究行为，提出了多极值学习型 PSO（Multiple Extremum Learning PSO, MELPSO）算法，使得 PSO 算法具备人类学习过程中的适应性、交互性、动态性、多样性等特点，提升了算法获得全局最优解的概率，增强了算法运行的稳定性和鲁棒性，拓展了算法的应用空间。

（2）根据航空发动机故障模式分布特点，提出基于距离判断的识别方法，利用 MELPSO 算法的寻优性能，为各类别寻找满足最大类间距离、最小类内距离、以及最大训练样本识别准确率的单最优分类点，依靠到不同最优分类点的距离进行故障模式识别。但基于单最优分类点的识别原理存在不能够准确识别具有线性不可分数据集的缺陷，因此需要为数据集中各个类别寻优合适的最优分类点，而不是仅确定唯一的最优分类点，进而在单最优分类点识别原理的基础上，提出基于自适应最优分类点的改进识别原理，利用优先度的概念组织多目标优化，确保了优化目标按照重要程度依次被实现，以此提高对线性不可分数据的识别准确率。

（3）海量的状态监控数据能够准确清晰地描述机械设备的运行状态特征，但其中大量重复或者相似性的数据在故障识别时起着基本类似的作用，因而变相地增加了样本规模，影响了计算效率。因此，提出基于图形割裂的粒度计算方法，

并应用到故障数据压缩当中，粒度通过提取和割裂平凡子图和完整子图生成。同时，考虑到监控数据间各属性不同量纲对相似度的影响，提出无量纲相似度的计算方法，克服了量纲的影响。将满足相似指标的数据进行压缩，减少了数据样本，降低了算法的时间开销，同时，保障了压缩样本对原始样本空间分布的维持，避免了因样本减少，信息损失后，对故障模式识别准确率的影响。

(4) 航空发动机主要性能参数是判断发动机健康状态的一个主要指标，容易受到如：运行环境、机械因素、飞行状态等因素影响，具有非线性、非封闭性和不确定性等特点。利用 MELPSO 的全局寻优能力，求解出具有非线性映射功能的函数，构造出基于时间序列的预测方式，利用前序数据预测后续数据。同时为克服时间序列预测方式输出偏差较大的缺陷，根据性能参数的影响因素，结合预测逻辑和主要影响因素，进一步构造出基于影响因素的预测方式，提高了预测准确率和输出的稳定性。

关键词：粒子群优化算法，故障诊断与预测，粒度计算，多目标优化，最优分类点

ABSTRACT

Aeroengine is the core component of aircrafts. It is a difficult task to diagnose and prevent the faults of aeroengine due to the uncertainty and harsh of its operation environment, as well as its complex structure. With the rapid development of modern sensing and signal processing technology, condition monitoring and fault trend analysis of aeroengines become feasible. The diagnosis and prognostics technology based on intelligent algorithm has been widely adopted, and they has fundamentally changed the maintenance paradigm of aeroengine. Aiming at the diagnosis, prognostics, and data processing of aeroengines, the diagnosis and prognostics methods based particle swarm optimization (PSO) are proposed in this dissertation. The granular computing (GrC) is adopted to compress the similar data for reducing the time overhead of algorithms. It is a challenge to use PSO as a diagnosis and prognostics method. The main contributions of this dissertation are summarized as follows.

(1) As a classical swarm intelligence algorithm, the PSO has been widely used in the optimization field, but it may easily trap into local suboptimal areas due to the premature convergence. Actually, the premature convergence is caused easily due to the lack of population diversity, inefficient interactive model, unbalance of search process, simplification of update strategy. Inspired by human learning behavior, the PSO is modified to overcome the premature convergence. By dividing the particles into tutors and students, a novel multiple extremum learning PSO (MELPSO) is proposed, which can imitate the strategies of collective learning, private tutoring, and research behavior, so that it has the characteristics of adaptability, interaction, dynamic and diversity in the learning process, consequence. The global optimal solution can be found with a higher probability, the stability and robustness are also enhanced.

(2) According to the fault mode distribution of aeroengines, the recognition method based on distance is designed, and the optimization performance of MELPSO can find a single optimized classification point for each class. The optimized classification point meet the three-optimization objectives, including the shorter intra-class distance, longer inter-class distance, and maximum classification accuracy of training samples, by which the unknown fault modes can be recognized by the nearest distance to the optimized classification points. However, the recognition principle based on single optimized

points cannot recognize the data sets with nonlinear separatrix accurately, some appropriate points for each class need to be determined rather than only finding a single optimized point, thus, and an adaptive optimized classification strategy is proposed. Meanwhile, the concept of priority levels is proposed for the multi-objective optimizations, and it can ensure that the prime objective is achieved firstly. The improved recognition strategy has a better performance for recognizing the sets with nonlinear separatrix.

(3) Massive monitoring data can accurately describe the operation states of the mechanical equipment, but a large number of data are the same or alike, which reflect the same fault model. However, with the increase of the sample size, the computational efficiency can be reduced. Accordingly, the granular computing based graph partition is proposed into compress fault data, the granularities are generated by extracting and partitioning the trivial subgraph set and complete subgraph set. Meanwhile, in order to overcome the influence of attributes with different dimensions, the dimensionless similarity is proposed. This method can compress the data to meet the similarity threshold, and it can also reduce the sample size and computational demand. Moreover, this method can guarantee the spatial distribution of compressed data is closer to that of original data, so that the influence of data information loss on the accuracy of fault diagnosis can be decreased

(4) The main performance parameters of aero-engine are main indexes to judge the health state, and they are easy to be influenced by factors such as operation environment, mechanical factors, and flight condition and so on. They always have the characteristics of non-linearity, non-closure, and uncertainty. By the means of the global optimization capability of MELPSO, a function with nonlinear mapping can be worked out, and then the prognostics method based on time series is constructed to predict the known data. Furthermore, in order to the defect of the time series with output deviation, the impact factors on the performance parameters are determined, and a prognostics method based on impact factor is further constructed, it can improve the accuracy of prediction and the stability of output.

Keywords: particle swarm optimization, diagnosis and prognostics, granular computing, multiple objective optimizations, optimized classification point

目 录

第一章 绪 论	1
1.1 研究工作的背景与意义	1
1.2 航空发动机故障诊断与预测技术研究历史与现状	2
1.3 粒子群优化算法研究历史与现状	7
1.4 粒度计算研究历史与现状	9
1.5 本文的结构安排	11
第二章 基于人类学习行为的粒子群优化算法	14
2.1 多极值学习型 PSO 算法原理	14
2.1.1 集体学习策略原理	15
2.1.2 私人辅导策略原理	17
2.1.3 研究行为策略原理	18
2.2 MELPSO 算法流程及性能改进分析	18
2.2.1 MELPSO 算法实施流程	18
2.2.2 MELPSO 算法性能改进分析	20
2.3 算法寻优性能验证及比较	21
2.3.1 各优化算法性能比较及分析	24
2.3.2 算法参数对优化性能影响及分析	27
2.4 本章小结	38
第三章 基于 MELPSO 算法的故障模式识别方法	39
3.1 基于距离的故障模式识别方法	40
3.2 基于单最优分类点的故障模式识别原理	43
3.2.1 基于分类的适应度函数设计	43
3.2.2 算法性能验证及分析	45
3.3 基于自适应最优分类点的故障模式识别原理	48
3.3.1 单最优分类点的缺陷分析	48
3.3.2 自适应最优分类点的识别原理	50
3.4 故障模式识别应用及分析	59
3.4.1 在轴承故障识别中的应用	59
3.4.2 在航空发动机小样本故障状态识别中的应用	62
3.4.3 在航空发动机气路状态识别中的应用	64

3.5 本章小结	67
第四章 基于图形割裂的粒度计算及其应用	68
4.1 相似度的定义及图形的生成	69
4.1.1 无量纲相似度的定义	69
4.1.2 图形的生成	70
4.2 基于无量纲相似度的图形割裂	74
4.2.1 平凡子图集和完全子图集的提取	74
4.2.2 图形割裂的原则和粒度的生成	75
4.3 粒度的应用及样本空间分布变化的评价	78
4.3.1 粒度在故障诊断中的应用	78
4.3.2 空间分布变化的评价	79
4.4 算法应用及其性能评价	85
4.4.1 相似度阈值 s 、空间变化评价指标 EI 和样本数量 $ X $ 间关系	88
4.4.2 基于图形割裂的粒度计算对分类性能的影响	95
4.5 本章小结	97
第五章 基于 MELPSO 算法的航空发动机性能参数预测	99
5.1 基于预测的适应度函数设计	100
5.2 历史数据的组织结构形式	103
5.3 航空发动机性能参数预测	106
5.3.1 基于 MELPSO 算法的预测性能验证	106
5.3.2 预测性能比较	109
5.4 基于影响因素的 EGTM 预测	111
5.5 本章小结	116
第六章 全文总结与展望	118
6.1 全文总结	118
6.2 后续工作展望	119
致 谢	120
参考文献	121
攻读博士学位期间取得的成果	133

第一章 绪论

1.1 研究工作的背景与意义

进入 21 世纪以来,随着现代科学技术的进步与发展,机械装备及生产系统日益向着精密化、集成化、智能化、高效化方向发展。作为现代技术应用密度高度集中的产业,航空业取得了快速发展,随之而来的是对于航空器的安全性、保障性、可靠性、经济性,甚至环保性等问题提出了更苛刻的要求,一旦航空器发生故障,特别是作为航空器核心系统的航空发动机发生故障,就会直接影响飞行安全,轻则造成事故症候,降低运行效率,重则危及人员生命财产安全,引起严重经济损失,造成灾难性后果。据统计,在全球众多的飞行事故中,由航空发动机故障所引起的占到约 50%,同时,在全球飞机维修产业中,对航空发动机的维护支出成本最高,基本上占到所有维修成本的 40%^[1]。因此,如何提高航空发动机的系统可靠性,可维护性,增强维修决策的科学性,保障航空发动机安全可靠运行,对航空运营组织降低运行成本,缩短维修周期,保障生命财产安全都具有十分重要的意义。加强航空发动机的故障诊断与预测技术研究,已成为各发动机厂商提高产品核心竞争力的重要保障。

传统的航空发动机维修方式主要以定时维修为主,即以发动机主要部件工作时限确定维修、更换周期,按照厂商所确定的工作寿命中断作业进行维修。至今,这一维修方式依然是我国所采用的主要维修手段,这一方式的主要缺点在于仅按照统计规律,将运行时间作为维修依据,而不能有效预防那些与使用时间没有直接关系的故障,同时,也忽略造成航空发动机运行环境和条件的个体差异,从而造成了相应的过度维修。航空发动机的运行实践和理论均已表明:发动机在飞行过程中产生故障具有随机不确定性。因此,20 世纪 90 年代,美国针对军用飞机战备完好性率先提出了故障预测与健康管理的(Prognostics and Health Management, PHM)的概念^[2,3],并迅速引入民用领域,从而使航空发动机由原来的定时维修转变为基于状态的视情维修(Condition-Based Maintenance, CBM)。该维修方式借助于先进的传感器技术,将发动机的健康状态量化,通过长期的技术状态监控,对因性能衰退,或者故障征兆引起的数量变化进行分析判断,从而确定合适的维修时间以及维修深度。在相应的工程机械领域的实践已表明:视情维修的方式有效延长了机械设备平均无故障工作时间,减少了不必要的维修作业,降低了维修成本,成为提高和保障设备运行可靠性的主要技术手段。例如,波音公司发展的飞机健康管理(Aircraft Health Management, AHM)系统已广泛应用到全球各家主要

航空公司中,据不完全统计,通过使用 AHM 系统,各航空公司平均节省了约 25% 的因航班故障而导致的额外费用。在直升机领域使用的健康与使用管理系统 (Helicopter and Usage Monitoring System, HUMS),使得美国陆军直升机任务完备率提高了 10%。美国等西方国家联合开发的联合攻击战斗机 (Joint Strike Fighter, JSF) 项目,通过 PHM 技术使得飞机维护保障智能化水平显著提高,使得 JSF 与 F16 相比,在人力费用方面降低约 30%,设备保障费用方面较低约 50%,而架次生成率却提高了约 25%^[4, 5]。因此,PHM 技术已成为实现基于性能自主保障和智能维修保障等新型保障手段的主要支撑技术,通过采用先进智能算法和推理技术,对设备关键部件进行状态监控、性能趋势分析、故障快速隔离诊断、维修保养科学决策,已成为 PHM 技术发展的主要方向。

由于航空发动机复杂的结构状态和严苛的工况环境,导致航空发动机的健康状态往往具有强烈的非线性、不确定性等特征,基于数据驱动的航空发动机故障诊断与预测算法成为发展的主流,基于神经网络、演化计算、支持向量机、模糊逻辑、时间序列、群体智能、证据理论、统计分析等方法被广泛应用于航空发动机 PHM 中,增强了 PHM 应用能力^[6]。而智能计算因对自然界中人、动物、自然现象等的数学描述,使得各算法具备自学习、自交互、自适应、自联想等特征,成为解决故障诊断与预测的主要技术方法。但各类智能算法也普遍存在一些共同的缺陷,如:算法可调参数缺乏相应理论依据,迭代过程中易陷入局部最优区域,对知识的表达性及解释性差等^[7, 8]。粒子群优化 (Particle Swarm Optimization, PSO) 算法作为经典的群体智能算法,因对自然现象的深刻描述,数学含义的精准定义,以及快速简洁的状态更新过程,灵活多变的应用形式,已成为应用最广泛的群体智能算法之一。

本文在国家自然科学基金“基于混合不确定性信息处理的复杂分层系统健康评估”等项目的资助下,开展基于 PSO 算法的故障诊断与预测技术研究,着力改进 PSO 算法的全局寻优性能,合理设计满足应用需求的优化目标函数,对进一步强化 PSO 算法应用性能,拓宽 PSO 算法应用范围,增强故障诊断与预测的技术基础有重要意义。因此,本文将在提高 PSO 应用能力的基础上,围绕故障诊断、性能预测、数据处理等 PHM 的核心技术进行深入研究,为航空发动机的故障诊断与预测技术开辟新的技术方法。

1.2 航空发动机故障诊断与预测技术研究历史与现状

故障诊断 (Fault Diagnosis, FD),通俗讲就是对设备的运行状态进行判断。在

设备状态正常时，能对设备未来状态作出评估和预警；而在设备状态异常时，能够对异常原因、部位、类型、程度等作出判断，并提出维修决策方案^[9]。而故障预测既是根据设备运行的规律，如惯性规律、相似性规律、统计规律等，对设备的一个或多个状态特征参数的变化趋势进行建模，预先估计和确定设备故障的时间、位置和可能性大小^[7]。在航空飞行中，发动机的安全可靠运行是一个至关重要的问题，航空发动机是一个多耦合、非线性、多因素影响的复杂机械设备，故障成因，特别是性能衰退，是各部件物理化学状态改变而引起的，有简单的、不确定的故障成因，例如阀门故障，叶片击伤，空气导管断裂、转子卡滞等；也有复杂的、多耦合的、渐进的故障成因，积碳、部件磨损、磨损剥落、疲劳损伤、排气温度升高等。但两者有一个共同特点，即都会引起状态监控参数的改变。从 20 世纪 60 年代以来，航空发动机生成和使用厂商对发动机的故障监测、诊断方法进行了大量研究，形成了基于以下技术途径的状态监控方法：

(1) 依靠发动机气路性能参数监控与分析

依靠从飞行状态数据中解码、整理的气路性能参数，如温度、压力、燃油流量、高低压转子转速等，通过转换成标准状态下的数值，与发动机生产厂商给定的该型发动机标准性能参数进行比较，发现数值偏差，判断偏差变化的趋势。通过分析引起性能参数变化的原因，以及预测性能参数变化情况，判断发动机健康状况，定位故障部件，制定维修计划。世界主流发动机都有相应的监控系统，例如 GE (General Electric) 公司开发的 SAGE (System for the Analysis of Gas Turbine Engines)，RR (Rolls-Royce) 公司开发的 COMPASS (Condition Monitoring and Performance Analysis Software System)，以及 PW (Pratt & Whitney) 公司开发的 EHM (Engine Health Management)，这些软件都已记录了各型发动机运行过程中的大量重要的实时性能数据^[10]。根据这些性能趋势数据，并结合发动机特定的运行环境，使得对状态监控和预测成为可能。

1972 年，Urban 等提出了故障影响系数矩阵方法，利用带有噪声或者偏置的气路性能参数进行航空发动机故障诊断，开启了气路诊断序幕，该方法要求测量参数大于等于故障种类^[11]。进入 20 世纪 90 年代后，随着传感器技术以及人工智能计算的发展，进一步推动了气路故障诊断的快速发展，美国空军研究实验室 (Air Force Research Laboratory) 在 90 年代后期开发的具有实时诊断功能的发动机健康管理 (Engine Health Management, EHM) 样机系统，主要就采用了基于神经网络的诊断技术^[12]。而我国在民用航空领域，1988 年北京飞机维修工程公司等四家单位联合研制了发动机监控和诊断 (Engine Monitoring and Diagnosis, EMD) 系统，实现了趋势预测和故障诊断的功能^[13]。

(2) 依靠润滑油系统对发动机机械状态进行监控

一般监控内容包括润滑油系统工作状态，润滑油中的金属屑含量，滑油品质等。滑油的温度、压力等都是监控的主要参数，滑油压力直接影响润滑油量的大小，进而影响到对关键部件的润滑效果和冷却效果，通常滑油压力降低，可能是滑油管路漏油或者油泵故障，而滑油温度直接反应了发动机的轴承、齿轮等部件的工作状态，过高的温度会改变滑油品质，降低轴承使用寿命。通过对滑油中的金属屑进行监控分析，包括光谱分析、铁谱分析、磁性屑探测等，不仅可以判断发动机的磨损严重程度，还能根据磨损状态的趋势分析，合理制定维修保障计划。

从20世纪50年代起，美国海军率先将滑油光谱分析技术应用到飞机发动机上^[14]，1976年美国海陆空三军正式建立联合油液分析计划的技术支持中心，在发动机磨损预测方面取得了明显的应用效果^[15]。2006年，Wang利用回归预测模型对滑油监控数据进行处理，通过对滑油中的金属屑含量进行预测，从而确定系统的磨损状况^[16]。2008年，Panda等利用不同神经网络模型实现了对钻头磨损的预测^[17]。国内学者针对滑油当中金属屑含量变化，做了大量的监控与预测分析。尉询楷等利用支持向量机对航空发动机滑油进行监控与分析^[18]。姜旭峰等利用遗传算法来优化BP神经网络的权值，对航空发动机磨损状况进行预测，算法取得了较高的预测精度^[19]。左洪福等出版了关于发动机磨损状态监控和诊断技术的专著，系统总结了磨损状态监控与诊断的技术方法^[20]。

(3) 依靠振动分析判断航空发动机故障

振动问题是航空发动机生产和使用过程中的主要故障表现之一。随着发动机推力、转速等不断提高，使得整机所承受的振动载荷也随之不断增加，振动破坏力所引起的故障越来越严重，统计资料表明，由振动所引起的航空发动机故障，占到发动机故障的60%以上，另一方面，用振动分析方法可以发现约20%的航空发动机故障^[21]。从而形成了以信号处理技术为手段的振动分析方法，如小波分析、快速傅里叶变换、盲源信号分析等信号处理技术，为发现和诊断转子轴承等相关部件的故障提供了技术支撑。国内外都已制造出种类繁多的振动诊断仪器，使振动检测实现了自动化、集成化和遥测化，在航空发动机在线诊断、工况监测、故障预报方面发挥着重要作用。

(4) 利用无损检测技术进行发动机内部损失监控

由于航空发动机在高温、高压等复杂工况下工作，发动机的燃烧室、涡轮、叶片等部件表面容易出现烧伤、裂纹、叶尖卷边、腐蚀、撕裂等损伤，严重危害飞行安全。利用孔探、超声波、声发射等无损检测手段，能够及时发现发动机内部结构损伤的大小、形状和分布情况等，对航空发动机关键部件的损伤、失效进

行检测、评估和监控，保障发动机的运行安全。董务江等在长期的航线维护实践中，探讨和总结了孔探技术在核心机探伤方面的技术要求，进一步分析了内窥镜检测与无损检测在航空发动机探伤方面的差异^[22, 23]。张海兵等从原位探伤的角度着手，根据合适的检测频率，设计了对某型发动机 2 级压气机叶片的涡流探伤检测方法^[24]。张传明、崔宗辉等深入分析影响超声波探伤仪检测的相关因素，并分别对压气机叶片以及叶片榫头进行了超声波检测^[25, 26]。

围绕着航空发动机的状态监控手段，各国研究人员相继提出了处理和分析状态监控数据，进行故障诊断与预测的数学方法。自 20 世纪 60 年代开始，美、英等发达国家相继成立专门机构对故障诊断技术进行专项研究，同时在宣传、培训、咨询，以及诊断技术开发方面做了卓有成效的工作^[8]。目前，美国经过几十年积累，PHM 技术处于世界领先地位，为航空航天、核能等尖端领域发展提供有力的保障支持，而英国、俄罗斯等国在状态监控和预测、故障诊断、摩擦磨损检测等方面积累了技术优势。在 1981 年，随着《航空发动机状态监测指南》的发布，航空发动机故障诊断技术在世界范围内的研究进入起步阶段。经过几十年的发展，形成了一些具有代表性的数学方法。

(1) 基于数学模型的诊断方法

基于数学模型的方法是早期故障诊断采用的主要方法，需要对诊断对象建立起比较精确的数学模型，往往数学模型对诊断对象的精确描述程度直接影响着诊断效果。在数学模型容易建立，比较精确时，采用数学模型方法是首选^[27-29]。因为这种方法的优点在于通过系统动态过程来掌握系统状态，使得诊断结果具有可解释性，但缺点是在实际当中，往往难以获得诊断对象的精确数学描述，因此这样限制了基于数学模型的诊断方法的使用范围和效果。基于数学模型的方法主要有两种方式：一是形成残差序列，即当前系统状态输出和正常系统输出之间的差值；二是分析引起残差序列的故障成因，从而实现故障诊断。Kobayashi 等将多 Kalman 滤波器方法应用到航空发动机的传感器故障诊断中，提高了传感器故障检测精度^[30]。Yang 等将传统的定量数值融合技术与定性推力分析相结合，提出了一种基于多源信息融合技术的故障监测与诊断方法，提高了工业过程中设备的状态监控质量^[31]。陈伟等提出了一种基于线性参数变化自适应观测器的故障估计算法来估计故障信息，应用到直升机线性参数变化飞控系统执行器的故障诊断^[32]。陈煜提出了基于非线性模型的涡喷发动机气路故障诊断方法^[33]。范作民等在总结航空燃气涡轮发动机故障诊断中的各类数学模型方法的基础上，出版了航空燃气涡轮发动机故障诊断理论专著《航空发动机故障诊断导论》^[34]。

(2) 基于信号处理的方法

信号处理在许多重要工程应用领域得到广泛应用，其主要内容包括变换、滤波、调制、解调、检测以及谱分析和估计等。在航空业中，主要用于检测发动机的传动特性以及磨损情况等，而振动问题是航空发动机生产和使用过程中的主要故障表现之一。国外原创性成果很丰富，1984年 Morlet 首次提出小波分析的概念，直到 1989 年，Mallat 提出了多分辨分析的概念，才使得小波变换完全走向实用化，小波变换对非平稳信号、奇异信号的分析能力和奇点检测的时域定位和频域定位特性使其在机械振动信号处理的分析中得到迅速应用^[35, 36]。Huang 在 1998 年提出了经验模式分解（Empirical Mode Decomposition, EMD）方法，这种方法从根本上摆脱了基于傅里叶变换方法的局限性，在机械振动信号的处理中得到了广泛应用^[37, 38]。Gelle 等将盲源分离应用到旋转机械的振动分析和监控中^[39]。丹麦 B&K 公司为提高航空发动机机械故障检测能力，开发了适用于航空发动机的振动检测系统^[40]。国内基于振动信号处理的研究取得了较丰富的成果，李国鸿等从航空发动机非平稳状态整机振动数据处理应用需求出发，提出了应用于航空发动机非平稳状态整机振动信号分析的短时傅里叶变换技术，反映振动信号频谱随时间的变化情况，并应用到故障诊断当中^[41]。肖蕾等通过小波分解信号，对能量进行合理化分解，来表征不同故障的目标，通过能量特征向量提取来构建故障模式和类别标签的联系，建立故障样本标准状态数据库，通过与标准状态数据的相似性比较，从而进行故障诊断，并将其应用到飞机电力传动系统的故障诊断当中^[42]。殷彬彬对航空发动机控制系统振动信号处理进行了研究，提出了一种改进的快速傅里叶变换（Fast Fourier Transform, FFT）频域分析方法，为发动机控制系统振动信号处理进一步研究奠定了基础^[43]。屈梁生、何正嘉等长期致力于全息谱、小波变换等先进故障诊断技术的底层研究^[44-47]。哈尔滨工业大学、西安交通大学等国内著名高校相继开发基于机组和旋转机械振动的微机监测和故障诊断系统，提高了我国的大型机械状态监控与诊断水平^[48]。

（3）基于智能诊断的方法

智能算法及计算机计算的快速发展，为故障诊断技术的发展提供了新的理论基础。基于智能诊断的方法不需要对诊断对象有精确的数学描述，而能根据反映诊断对象运行状态的监控数据进行学习，从而实现对未知状态的自动识别，表现了自学习、自交互、自适应、自联想等智能特征^[49]。如神经网络诊断法、支持向量机诊断法、进化智能诊断法、专家系统诊断法、模糊故障诊断法、信息融合诊断法等^[50-54]。国内外学者在这方面都进行了大量研究。Arkov 等将人工神经网络算法用于发动机故障识别中^[55]，提高了发动机状态监控质量。Mustapha 等采用 if-then 规则，通过知识系统来模拟专家进行故障诊断，开发了基于知识系统的喷气

发动机智能故障诊断系统^[56]。Mast 等采用 Bayesian 置信网络进行航空发动机故障识别^[57]。侯胜利等提出基于免疫聚类分析的特征提取及其在发动机故障诊断中的应用^[58]。在美国自成立的“智能维护系统中心 (Intelligent Maintenance Systems, IMS)”，将智能方法大量成功应用于机械设备性能衰退分析和预测性维护方法研究^[59]。吴海桥等基于案例推理和模糊逻辑，开发了用于发动机故障诊断的专家系统^[60]。朱家元等采用支持向量机和多元分类算法进行故障诊断^[61]，提高了诊断精度。Joly 等利用人工神经网络对高涵道比军用涡扇发动机进行了故障诊断^[62]。因此，基于学习的各类智能算法已成为航空发动机等复杂机械设备故障诊断的主要工具。

(4) 基于混合算法的诊断方法

各类算法由于数学原理的差异，在实际问题处理当中，总是表现出不同的性能水平。混合算法即是针对特定问题，结合不同算法的优势，提高故障诊断精度的一种方法，例如：将进化算法或者群体智能算法与神经网络、支持向量机等结合；将基于模糊推理和基于案例推理的方法相结合；将模糊算法、粗糙集与神经网络相结合等。根据实际需要，将不同算法进行集成，充分避免单一算法固有缺陷所造成的性能下降。Koboyashi 等利用神经网络和遗传算法对航空发动机性能进行诊断^[63]。Yang 等利用 PSO 优化极限学习机 (Extreme Learning Machine, ELM)，提高了 ELM 对航空发动机的故障诊断能力^[64]。Lee 等利用支持向量机和神经网络混合的方法对燃气轮机进行故障诊断，提高故障探测效率^[65]。钱政等提出了一种在范例推理框架上集成模糊数据的故障诊断方法，提高了对电力变压器的故障诊断性能^[66]。赵文涛等提出了一种基于 PSO 算法的组合优化模型，通过确定各预测算法的加权系数，提高了模型输出的稳定性^[67]。郑波等将 PSO 算法用于优化支持向量机的相关参数，并分别用于航空发动机的送修等级确定和磨损预测中，提高了支持向量机的应用性能^[68, 69]。张爱国等将模糊数学与神经网络集成，并应用于微光电视故障诊断中，提高了神经网络的应用效果^[70]。

1.3 粒子群优化算法研究历史与现状

近年来，随着工程优化问题，如非线性过程控制、机械结构设计、文本挖掘、系统优化、路径规划、数据聚类等，变得越来越复杂，传统解析算法难以求解复杂优化问题，而基于群体智能的优化算法为复杂优化问题求解提供了有效的解决途径。在众多群体智能算法中，PSO 是一种经典的算法，它由 Kennedy 和 Eberhart 于 1995 年提出^[71]，该算法模拟自然界中鸟群捕食行为，由于简洁的数学描述、较少的参数设置、清晰的生物含义，使其成为求解优化问题的最流行方法之一。

PSO 算法本质上是一种启发式的群体随机搜索算法，群体当中的个体代表对

特定问题的可行解，而每个个体依据自身及群体经验不断进行位置更新，从而获得趋于最优解空间的解。但几乎所有群体智能算法都面临同一固有问题，即因易陷入局部最优区域而导致早熟收敛^[72-74]。实质上，缺乏种群多样性和有效交互模式，以及搜索过程的不平衡、更新策略的单一化，都是导致早熟收敛的原因。近年来，围绕着克服这一缺陷，提出了很多改进型算法，按照算法改进原理大致可分为如下四类，即：

（1）基于参数调节

对惯性权重、学习因子等控制参数恰当调节，对加速收敛，避免早熟具有重要作用^[72]。对于惯性权重的调节，产生出了线性递减权重^[75]、线性递增权重^[76]、高斯分布随机权重^[77]、模糊自适应权重等调节方式^[78, 79]。近年的研究表明线性递减权重能更加显著提升算法性能^[80]。同时，基于学习因子的改进算法平衡着对个体认知和群体认知的依赖，对优化性能有显著影响，主要有收缩因子、可变因子等调节方式^[81, 82]。而针对惯性权重和加速因子的自适应调节方法综合考虑了两类参数的影响^[83]，对一些工程问题起到了良好的优化效果。参数调节因其简便性、可操作性，成为改进群体智能算法的重要突破口。

（2）基于邻域拓扑结构

为了加强个体间的信息流通，增强种群多样性，以邻域内的粒子作为研究对象，提出了大量新颖的改进算法^[84-86]。为加强个体的全局搜索能力，一种基于信息流过程的 FIPS (Fully Informed Particle Swarm) 算法利用邻域内所有粒子的加权和来更新指定粒子的位置，该算法的优点在于粒子的新位置能够被邻域其它粒子有效评估，从而获得更优的全局信息^[87]。不同于固定邻域拓扑结构，一种基于动态变化的邻域拓扑结构被用来更新粒子，产生了 DMSPSO (Dynamic Multi-Swarm PSO) 算法^[88]，该算法在搜索初期，随机选择具有较小邻域的子种群来探索解空间，而后期通过动态重组后，形成较大邻域的子种群，利用社会交换策略，增加子种群间信息传递，提高了局部开发能力。除此之外，文献^[89-91]也提出了相应的基于邻域拓扑的改进算法。

（3）基于算法集成

为了进一步改进 PSO 性能，研究人员通过算法之间的融合，根据与其他进化算法（如：遗传算法、蜂群算法等）搜索特性的分析、对比，利用其他算法搜索过程中的优势来克服 PSO 的缺陷。如遗传算法当中的选择、交叉、变异算子已被引入 PSO，以增强种群多样性^[92, 93]。而差分进化^[94]、模拟退火^[95]、免疫算法^[96]等也与 PSO 产生了有效结合，取得了良好的应用效果。同时，基于量子行为^[97]、混沌行为^[98]、牛顿运动定律的 PSO 也得到快速发展^[99]，有效改进了 PSO 算法寻优性

能。

(4) 基于人类行为

近年来,根据对人类诸多行为的探索和模范,衍生出很多基于人类行为的 PSO 改进算法,为算法性能的提高开启了新的研究途径。主要有对人类教学与学习行为的模仿^[100, 101]、对人类衰老生理机制的模仿^[102]、对人类认知心理行为的模仿^[103]、对人类组织领导行为的模仿^[104]、对人类随机游走行为的模仿^[105]、对人类竞争合作行为的模仿^[106]。因人类行为具有良好的多样性、交互性、动态性、适应性等特点,使得传统 PSO 继承了许多人类行为的有益特征,有效增强了 PSO 的种群多样性,提高了获得全局最优解的概率,加快了算法收敛速度,各类改进算法在工程应用领域取得了良好的应用效果。

对 PSO 早熟收敛改进方式主要的从四个方面开展。而实质上,上述四类改进原理也是围绕着其中一个或者多个方面对算法进行改进。在整个搜索过程中,始终保持全局探索与局部开发的动态平衡,维持适当的种群多样性,增强优势个体与劣势个体间的相互交换,设计合理有效的更新策略,对增加获得全局最优解的概率和增强算法稳定性有决定作用。

1.4 粒度计算研究历史与现状

20 世纪 60 年代,著名控制论专家 Zadeh 教授提出了模糊集合论,并在此基础上进一步提出了模糊信息粒化问题,进而演化出“词计算理论”。他认为人类认知的三个主要特征分别为:粒化(granulation),即将全体分解为部分;组织(organization),即将部分集成为整体;因果(causation),即因果的关联^[107-109]。他强调语言是人类进行思考、认知、推理、表达、判断的主要工具,因而语言表达本身就是对问题认知的粒化过程。Hobbs 于 1985 年首次提出了粒度(granularity)的概念,但没有给出粒度的计算准则^[110]。而 Yager 和 Filev 进一步阐明“人们已形成了一个关于世界的粒度观点”,基于此观点,“人类的观察、度量、概念化和推理都是在粒度意义下进行的”^[111]。而粒度计算(Granular Computing, GrC)作为一个专业学术概念是由 Lin 于 1997 年首次提出的,他认为 GrC 是处理所有关于粒度的理论、方法、技术和工具^[112]。我国学者张钹和张铃在有关问题的独自研究过程中,特别强调“人类智能的一个公认特点,就是人们能从极不相同的粒度观察和分析同一问题。人们不仅能在不同粒度的世界进行问题的求解,而且能够很快地从一个粒度世界跳到另一个粒度世界,往返自如,毫无困难。这种处理不同粒度世界的能力,正是人类问题求解的强有力的表现”^[113]。这段话深刻阐释了粒度计算的特征,为商空间理论提出奠定了基础。因此信息的粒化是人类对复杂问题

认知的主要反映形式，代表着人类的认知过程。

GrC 有三种经典的计算理论，即 Zadeh 提出的词计算（Computing with Words）理论^[108, 109]，Pawlak 提出的粗糙集（Rough Set）理论^[114, 115]，以及我国学者张钊、张铃提出的商空间（Quotient Space）理论^[116, 117]。词计算主要从模糊的角度研究词义表达及推理，粗糙集主要通过对属性分析和约简实现信息粒化，而商空间主要从人类认知的宏观角度研究粒度间的相互转换，尽管三者从不同的角度进行粒度计算，但都考虑到了人类智能中信息粒化的特点。

词计算理论是对模糊集理论的继承和发展，克服了模糊集理论存在一系列重要问题^[109]。它主要研究词的表示及推理，用模糊集理论中对象关于集合的隶属程度进行词的度量，用 If-Then 规则进行逻辑推理。因此词计算理论通常采用形容词或者副词所表达的程度来表示不同的粒度概念。Zadeh 提出的词计算模型描述了在论域 U 上，语言粒度 X 和 Y 的前后关联关系，如果 R 对 X 进行约束，则 Y 会被 B 约束，可用 If-Then 规则表示为：If X is R , then Y is B 。粒度定义为 $G = \{X | X \text{ is } r R\}$ ， $\text{is } r$ 表明了 R 对 X 的约束方式， r 是离散变量，表示约束的类型，例如： $r = e$ 为等式约束， $r = c$ 为交约束， $r = d$ 为并约束， $r = p$ 为概率约束等，不同的约束类型可构造出不同的信息粒度。一般而言，词计算都是从粒度的粗划分开始的，通常利用约束间不同组合来构建笛卡儿积，并且对粒度进行自然语言的程度注释，以此建立词计算的理论基础。因此，从本质上讲，词计算理论就是根据专家主观先验经验，构造出一个相应粒度空间，并给出各粒度的度量值，从而在问题求解时降低问题复杂性的过程^[118]。

粗糙集理论是处理模糊、不精确和不完备问题的数学方法，它不依靠先验信息，主要通过论域中元素间关系来实现对数据的客观处理^[114]。它利用等价关系 R 实现对论域 U 中的元素进行分类，记为： $U/R = \{[x]_R | x \in U\}$ 。粗糙集理论通过一个集合关于某个知识库的上、下近似来描述粒度，一个等价关系对应一个粒度，强调的是分类，其粒度定义为： $G = U/R$ 。粗糙集理论中的不确定性概念是通过上、下近似从所研究的数据库中直接定义，所以能够比较客观地反映知识表达的不确定性和模糊性。同时，粗糙集理论通过属性约减，保留对象的关键属性，达到降低问题复杂性的目的。尽管粗糙集理论在数据挖掘中取得了巨大的成就，但它局限于集合运算，缺乏有效处理现实问题的代数运算体系，并且研究的只是论域点集，而缺乏元素间的拓扑结构关系^[119]。

商空间理论主要通过三元组 (X, F, T) 来阐述所研究的具体问题， X 表示问题的论域， F 表示由属性构成的集合，而 T 表示在 X 上的拓扑结构。通过在论域中引入一个等价关系 R ，将论域的粒度化等同于 R 的一个划分，与 R 相对应的商集为 $[X]$ ，

若将 $[X]$ 作为一个论域,则其对应的三元组 $([X], [F], [T])$ 称为对应于 R 的商空间。一个商空间就是关于问题的一个信息粒,因此,商空间理论主要研究各粒度之间的相互转换关系,包括粒度间的合成、分解、综合和推理等关系。商空间的重要性质是由保真原理和保假原理所构成的同态原则。根据同态原则,对于复杂问题求解,通过对不同粒度间的合成,可实现粒度由细到粗的转换,增加对问题的总体认知和把握,从而减小计算开销;另一方面,通过粒度间的分解,同样可实现由粗到细的转换,从细节方面更深层把握问题,从而实现对问题内涵的深刻挖掘。商空间理论为在粗细不同的粒度下观察、研究问题提供了支撑,根据问题求解的需要,能主观地把握对问题理解的深浅。因此,商空间理论更侧重于从宏观上分析粒度的转换规律,但缺乏对粒度本身的度量研究。

三种理论从不同的研究角度分析了人类的认知习惯,刻画了人类的智能行为,阐述了 GrC 的核心思想。在对复杂问题求解的过程中,人类首先倾向于从复杂问题的全貌出发,层层分解,有粗到细,不断将复杂问题转换为易理解的子问题,渐进地参透问题本质,简化人类认知过程。同时,由于受限于对实际问题的认知情况,人们很难获得精确的、完整的信息,所获得的信息通常具有不确定性、不完整性,或是模糊性。因此,人类在实际问题求解时,通常在满足实际求解需求的前提下,更侧重于对问题的近似求解,通过粒度间的相互转换,实现从宏观层面把握问题,有效避开精确认知的不确定性、不完整性、模糊性等,从而增强人类的认知能力,提高问题求解效率。

除了词计算、粗糙集、商空间等经典粒度计算模型外,关联规则、决策树、聚类、神经网络等常用的机器学习方法也用于建立 GrC 模型,进行粒度划分,以减小数据规模。Tang 等于 2004 年就将 GrC 与经典分类器 SVM 融合起来,提出了 GSVM (Granular Support Vector Machine) 的概念,进而提出了基于关联规则的粒度划分方法,它在保持较好泛化性基础上,有效克服传统 SVM 对大数据训练效率低下的问题^[120, 121]。Zhang 等一些学者从不同角度将聚类方法,结合相应的评价准则来进行粒度划分,提高了分类器在大规模数据集训练中的计算效率和泛化能力^[122]。Yu 提出基于树形层次结构的 GSVM 学习模型,通过构造不同类别的粒度树来满足分类器训练精度要求^[123]。郭虎升等提出了利用 ART (Adaptive Resonance Theory) 和 SOM (Self-Organizing Maps) 神经网络来进行粒度划分,进而实现数据压缩,通过对分类器的训练,获得了较满意的泛化能力^[124]。

1.5 本论文的技术路线和结构安排

本文的主要技术路线如图 1-1 所示。对发动机故障模式与监控参数间关系的分

析，是前期工作的主要内容，并在第 3 章和第 5 章进行阐述。对 PSO 算法的改进是第 2 章的主要研究内容，提出基于人类学习行为的改进方法。故障诊断方法是第 3 章的主要研究内容，设计包括基于单最优点和自适应最优点的诊断原理。粒度计算是第 4 章的主要研究内容，提出基于图形割裂的粒度计算方法。故障预测是第 5 章的主要研究内容，分别用时间序列和影响因素两种预测原理对主要性能参数进行预测。最后对全文内容作总结，并对下一步需要继续研究的内容进行展望。

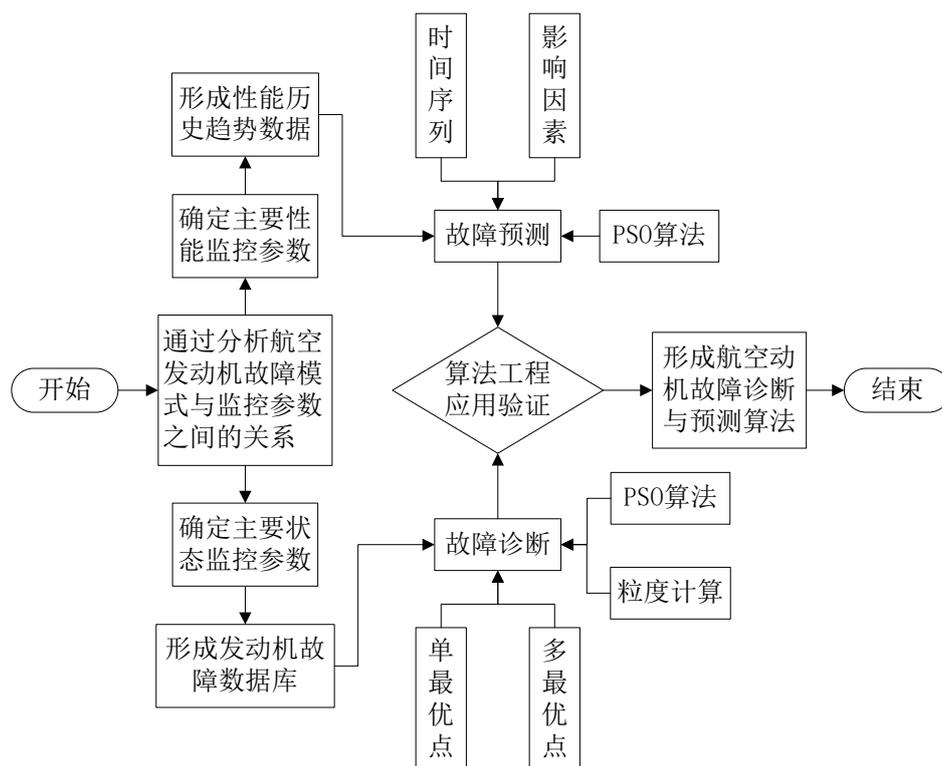


图 1-1 论文研究技术路线

论文主要研究内容如下：

第一章：绪论。详细阐述论文的研究背景及意义；深入分析航空发动机故障诊断与预测技术的发展现状，以及主要技术手段等；总结 PSO 算法的改进方式，并探讨算法因陷入局部最优区域而导致早熟收敛的原因；对 GrC 发展进行概述；最后给出论文的主要研究内容和结构安排。

第二章：对基于人类学习行为的 PSO 算法进行研究。PSO 算法存在易陷入局部最优区域而导致早熟收敛的固有缺陷，在深入分析引起 PSO 算分陷入局部最优区域的基础上，提出模拟人类学习行为的多极值学习型 PSO (Multiple Extremum Learning PSO, MELPSO) 算法。

第三章：开展基于 MELPSO 算法的故障模式识别研究。设计出满足相应寻优

条件的多目标优化问题，优化出单最优分类点，依靠到最优分类点的距离进行未知模式识别，提高故障模式识别准确率。同时，针对数据间具有非线性间隔的特点，提出基于自适应最优分类点的识别策略，利用优先度的概念组织多目标优化，进一步拓展识别算法的应用范围。

第四章：依靠数据间的无量纲相似度指标，利用图形割裂的粒度计算方法，对满足相似性条件的样本进行压缩，减少数据样本，降低算法的时间开销，同时，保障压缩样本对原始样本空间分布的维持，避免因样本减少，信息损失后，对故障模式识别准确率的影响。

第五章：开展基于 MELPSO 算法的航空发动机性能参数预测研究。针对航空发动机性能参数的非线性等特点，提出基于 MELPSO 算法求解的非线性映射函数，通过时间序列的预测方式实现对未知数据的预测。同时，发动机运行衰退受多种因素影响，又表现出不确定等特点，因此，设计出基于影响因素的预测方式，以提高预测算法输出的稳定性和准确率。

第六章：结束语和未来工作展望。对全文进行总结，概括本文的主要工作和创新点，并提出未来的研究方向。

第二章 基于人类学习行为的粒子群优化算法

受鸟类群聚行为启发，在 PSO 算法中，每个种群有 N 个粒子，而粒子表示为 D 维的位置向量和速度向量，且在整个解空间中被随机初始化。位置向量代表对求解问题的潜在可行解，而速度向量代表粒子的运动轨迹。在整个搜索过程中，所有粒子相互合作，彼此分享信息，依靠自身和群体的经验更新位置，进行全局寻优。PSO 算法的迭代公式如下所示：

$$\begin{cases} \mathbf{v}_i^{k+1} = \mathbf{v}_i^k + c_1 \cdot r_1 \cdot (\mathbf{p}_{id}^k - \mathbf{p}_i^k) + c_2 \cdot r_2 \cdot (\mathbf{p}_{gd}^k - \mathbf{p}_i^k) \\ \mathbf{p}_i^{k+1} = \mathbf{p}_i^k + \mathbf{v}_i^{k+1} \end{cases} \quad (2-1)$$

其中， k 为当前迭代次数； \mathbf{p}_i 为第 i 个粒子； \mathbf{p}_{id} 为单个粒子所经历的历史最优位置； \mathbf{p}_{gd} 为群体最优位置； \mathbf{v}_i 为粒子的速度向量； c_1 和 c_2 为正常数，称为学习因子，一般在 0-2 之间取值；而 r_1 和 r_2 为 $[0, 1]$ 之间两个相互独立的随机数^[125]。粒子的速度更新分别由 3 项构成，第一项是前一次迭代计算的速度，代表粒子对解空间的探索，第二项为依靠自身能力对解空间进行开发，而第三项则是依靠社会能力的开发。为了进一步提升算法性能，惯性权重 ω 被引入到速度更新公式当中，表示为 $\omega \cdot \mathbf{v}_i^k$ ，以平衡开发和探索的能力^[126]。在整个搜索过程中， ω 是线性递减的，维持了搜索初期的探索能力和后期的开发能力。而且相关文献已经证明了线性递减惯性权重更有利于获得全局最优解^[80]。

PSO 算法因易陷入局部最优区域而导致早熟收敛。实质上，如图 2-1 所示，缺乏种群多样性和有效交互模式，以及搜索过程的不平衡、更新策略的单一化，是导致早熟收敛的原因。本章将围绕导致早熟收敛的原因，对 PSO 算法进行有效改进，以提高算法的全局搜索能力，增强 PSO 算法的应用性能。

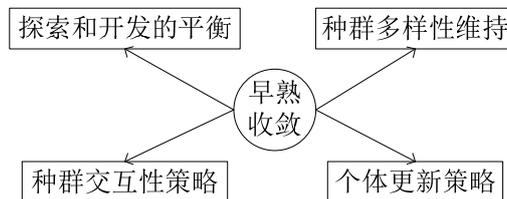


图 2-1 算法性能改进的主要研究方向

2.1 多极值学习型 PSO 算法原理

为了降低 PSO 算法固有缺陷对全局寻优的影响，受人类集体学习行为启发，在本章中将提出一种新型 PSO 算法。根据人类的集体学习行为，在一个学习集体

里面，存在学生和导师，学生当中有学习能力强弱之分，因此会产生不同的学习指导策略，而导师除了指导学生以外，还担负着对应用知识的研究与拓展。通过学生和导师的共同探索和开发，达到对特定问题的求解。这一描述简要概括了人类的集体学习行为。

根据集体学习行为，在算法执行过程当中，种群当中所有粒子将根据实际问题认知能力进行排序，排名前 n_t 位的粒子被定义为导师，余下的粒子将被归为学生，搜索的过程中，所有学生将被随机赋予一个导师，并在导师指导下进行集体学习，而对于学习能力差的学生，将在导师的帮助下进行私人辅导，以期获得更好的学习效果，导师在担负教学指导任务的同时，也承担着对应用问题的研究。实质上，学生的学习行为和导师的研究行为都是为了求解实际问题，其中定义的导师是种群当中的前 n_t 个极值，因此，此种改进型算法也被称为 MELPSO 算法。在 MELPSO 算法中，大多数的粒子将追从前 n_t 个极值，而不是传统的单极值，这使得找到位于全局最优区域或者接近全局最优区域的解的概率增大。图 2-2 给出了 MELPSO 算法的学习结构原理。

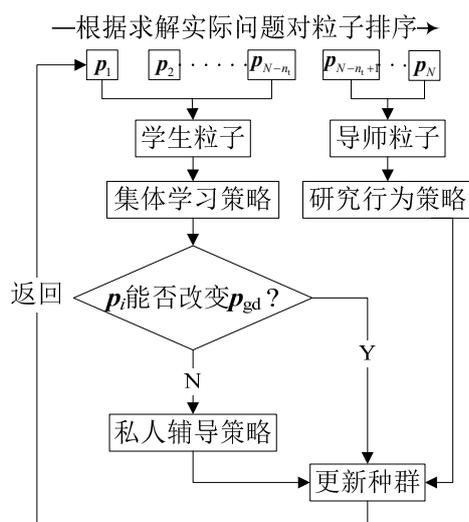


图 2-2 MELPSO 算法学习结构原理图

MELPSO 算法的学习原理使其能够维持种群多样性，较好平衡探索和开发能力，降低固有缺陷影响，提高全局收敛速度，因其遵从了人类集体学习行为的多样性、交互性、动态性、适应性等优势。根据各学习行为的特点，算法的学习策略原理设计如下。

2.1.1 集体学习策略原理

正如人类在班级里学习一样，集体学习是大多数学生知识获取的最主要方

式，学生粒子随机确定一个导师，在导师指导下，依照自身知识累积进行学习。集体学习的数学表达描述如下：

$$\mathbf{v}_s^{k+1} = \omega_s^k \mathbf{v}_s^k + c_1 r_1 \mathbf{a}_1 (\mathbf{p}_{s-id} - \mathbf{p}_s^k) + c_2 r_2 (\mathbf{p}_t^k - \mathbf{p}_s^k) \quad (2-2)$$

$$\mathbf{p}_s^{k+1} = \mathbf{p}_s^k + \mathbf{v}_s^{k+1} \quad (2-3)$$

其中， c_1 和 c_2 取值分别为 1.5 和 1.7； r_1 和 r_2 为控制参数，在每次迭代时随机设置在 $[0, 1]$ 区间； \mathbf{p}_s 为学生粒子， \mathbf{p}_{s-id} 为学生粒子的个体极值； \mathbf{p}_t 作为导师粒子，由学生粒子随机选择其中一个作为导师； \mathbf{a}_1 设计的目的是用于对已有知识进行批判继承，称为修正向量； ω_s 是学生粒子的惯性权重，可以根据式(2-4)计算：

$$\omega_s^{k+1} = \omega_s^k - (\omega_{\max} - \omega_{\min}) / k_{\max} \quad (2-4)$$

其中， k_{\max} 为最大迭代数； ω_{\max} 和 ω_{\min} 分别是惯性权重的最大值和最小值，取值分别为 0.9 和 0.2，而 ω_s 的初始值设为 ω_{\max} 。因此，学生粒子采用的是线性递减的惯性权重，这是专门针对学生粒子设计的方案，因为学生粒子是拥有适应度值相对较差的粒子，采用线性递减权重有利于加速粒子的收敛，增强局部开发能力。

根据集体学习策略的理念，可以对式(2-2)和(2-3)进行合理的、拟人化的全新定义，这一定义与算法表达的思想是切合的。

(1) 速度 \mathbf{v}_s^{k+1} 可定义为学习过程中的知识增量。

(2) $\omega_s^k \mathbf{v}_s^k$ 代表着前次学习中知识的累积。实质上，知识累积就是对特定优化问题求解的渐进过程，代表着对特定问题认知由简单初级到全面深入的过程。

(3) \mathbf{p}_{s-id} 是学生粒子为求解特定优化问题所取得的已有最优知识，因此 $\mathbf{p}_{s-id} - \mathbf{p}_s^k$ 可定义为依靠自身认知进行的知识获取。

(4) $\mathbf{p}_t - \mathbf{p}_s^k$ 代表依靠导师指导而获取的知识。因学生粒子可接受 n_t 个导师粒子的指导，而导师粒子却不是固定不变的，随着迭代的进行，依据适应度值进行更换。因此，依靠导师指导能增加学生粒子搜寻更多潜在最优区域，避免陷入局部最优区域的概率。

对学生粒子而言，修正向量 \mathbf{a}_1 仅作用于自我学习项，而不是导师指导项，实质上，完全依靠学生粒子的个体极值 \mathbf{p}_{s-id} 是不利于求解最优问题的。因此，批判地继承学生粒子个体极值是有必要的。修正向量的引入能增加学生粒子的多样性，同时，始终维持着有效的收敛速度。而 \mathbf{a}_1 是与粒子具有相同维度的二进制向量， $\mathbf{a}_1 = [a_{11}, a_{12}, \dots, a_{1D}]$ ，可以根据式(2-5)计算：

$$\mathbf{a}_1 = \text{bin}(a_{1d} \in \{0, 1\}, d = 1, 2, \dots, D) \quad (2-5)$$

a_{1d} 是修正向量 \mathbf{a}_1 的元素； D 是粒子的维度； $\text{bin}(\cdot)$ 是用于产生 D 维二进制随机向量的函数。因此，如果 $a_{1d} = 1$ ，则学生粒子个体极值的第 d 维将被有效继承，否则，对第 d 维的继承将被拒绝，这一个过程即所谓批判继承。

式(2-2)和(2-3)描述了集体学习行为。在这一策略中，知识增量来自于长期的知识积累，基于自身认知的自我学习和导师的指导，而已有的知识和知识增量构成了新的知识，这一过程完全与人类学习过程相一致。同时，控制参数 r_1 和 r_2 也模拟了学生粒子的学习习惯，不同值间的组合使得学生粒子或依赖于自我学习，或依赖于导师指导，或依赖于两者间的折中。

2.1.2 私人辅导策略原理

正如人类学习一样，集体学习是一种普适策略，所有学生粒子都要参与。通过集体学习，有些学生粒子能够获取知识，改进对特定问题的认知，而有些学生粒子却不能改进认知。对于这些相对较差的学生粒子，私人辅导策略可有助于其进行知识更新，改进认知。为了能够适应处理各类复杂优化问题，设计了 3 种来自于导师粒子的私人辅导策略，包括整体继承（Holistic Inheritance, HI），片段继承（Fragment Inheritance, FI），随机继承（Random Inheritance, RI），这 3 种私人辅导策略描述如下：

$$\text{整体继承: } \mathbf{p}_{s(\text{HI})}^{k+1} = \mathbf{p}_t^k \quad (2-6)$$

$$\text{片段继承: } \mathbf{p}_{s(\text{FI})}^{k+1}(s_1:s_2) = \mathbf{p}_t^k(s_1:s_2) \quad (2-7)$$

$$\text{随机继承: } \mathbf{p}_{s(\text{RI})}^{k+1} = (1-\alpha) \cdot \mathbf{p}_t^k + \alpha \cdot (\mathbf{p}_s^k - \mathbf{p}_t^k) \quad (2-9)$$

其中，整体继承表示较差学生粒子习得导师粒子的所有知识，即用导师粒子知识完全替换自身知识；片段继承表示较差学生粒子习得部分导师粒子的知识，即用导师粒子的连续片段替代相应位置的学生粒子， s_1 和 s_2 代表元素在粒子向量中的序号，通常 $1 < s_1 < s_2 < D$ ；而随机继承表示较差学生粒子习得来自于导师粒子随机位置的知识，即随机抽取导师粒子的元素替代相应位置的学生粒子，而 α 是一个随机产生的 D 维二进制向量。

根据私人辅导策略，较差粒子的位置更新是通过比较 3 种策略所得的适应度值优劣情况，使较差粒子获得更优适应度值的学习策略将用来更新较差粒子，这就增加了较差粒子获得更优适应度值的概率，改进了粒子的知识质量。因此，私人辅导策略的数学表达如式(2-10)所示：

$$\mathbf{p}_s^{k+1} = \left\{ \mathbf{p}_{s(\text{method})}^{k+1} \mid \max / \min \left(\text{fit} \left(\mathbf{p}_{s(\text{method})}^{k+1} \right) \right), \text{method} = \text{'HI', 'FI', 'RI'} \right\} \quad (2-10)$$

私人辅导的进化策略能够帮助不能改进自身个体极值的粒子收敛到一个相对较优的区域，而且，避免了学生粒子的过度聚集，维持了种群的多样性。

2.1.3 研究行为策略原理

与学生粒子不同，导师粒子主要是对未知问题的研究和探索，而非对已有知识的学习。所以导师粒子要肩负找到全局最优区域而探索更多解空间的责任。因此，导师粒子的进化策略定义为研究行为，其更新过程如下所示：

$$\mathbf{v}_t^{k+1} = \omega_t^k \mathbf{v}_t^k + c_1 r_1 \mathbf{a}_1 (\mathbf{p}_{t\text{-ic}}^k - \mathbf{p}_t^k) + c_2 r_2 \mathbf{a}_2 (\mathbf{p}_{\text{ge}}^k - \mathbf{p}_t^k) \quad (2-11)$$

$$\mathbf{p}_t^{k+1} = \mathbf{p}_t^k + \mathbf{v}_t^{k+1} \quad (2-12)$$

而导师粒子的惯性权重 ω_t 由下式计算可得：

$$\omega_t^{k+1} = \omega_t^k + (\omega_{\max} - \omega_{\min}) / k_{\max} \quad (2-13)$$

在导师粒子的更新过程中，对于式(2-11)前两项的解释与式(2-2)对应的项是相似的，但是第3项的解释与表达却完全不一致。实质上，全局极值 \mathbf{p}_{gd} 在本研究中被赋予了新的概念，定义为针对特定问题的最终应用知识，它是由学生粒子的学习开发和导师粒子的研究探索共同产生的对特定问题求解的认知。导师粒子根据自身的知识累积及认知来研究特定优化问题，所以，不同于学生粒子，导师粒子始终跟随全局极值 \mathbf{p}_{gd} ，这意味着研究行为在执行过程中始终构架于求解实际优化问题的基础之上，显然，这是有助于改进全局极值的。此外，修正向量也被应用到式(2-11)当中，进行批判继承个体极值和全局极值，修正向量 \mathbf{a}_2 使得导师粒子能够降低对全局极值的过度依赖，避免在迭代后期因追寻单一全局极值而陷入局部最优区域。相较于学生粒子，导师粒子的惯性权重 ω_t 采用的却是线性递增的策略，原因在于这些已取得相当较优适应度值的导师粒子有责任为了获得全局最优解而探索更多的解空间。

实质上， ω_s 和 ω_t 共同作用于不同类型的粒子，起到了平衡粒子群开发和探索的能力，从而增强了获得全局最优解的概率。

2.2 MELPSO 算法流程及性能改进分析

2.2.1 MELPSO 算法实施流程

MELPSO 算法流程如图 2-3 所示，算法按照如下步骤组织实施：

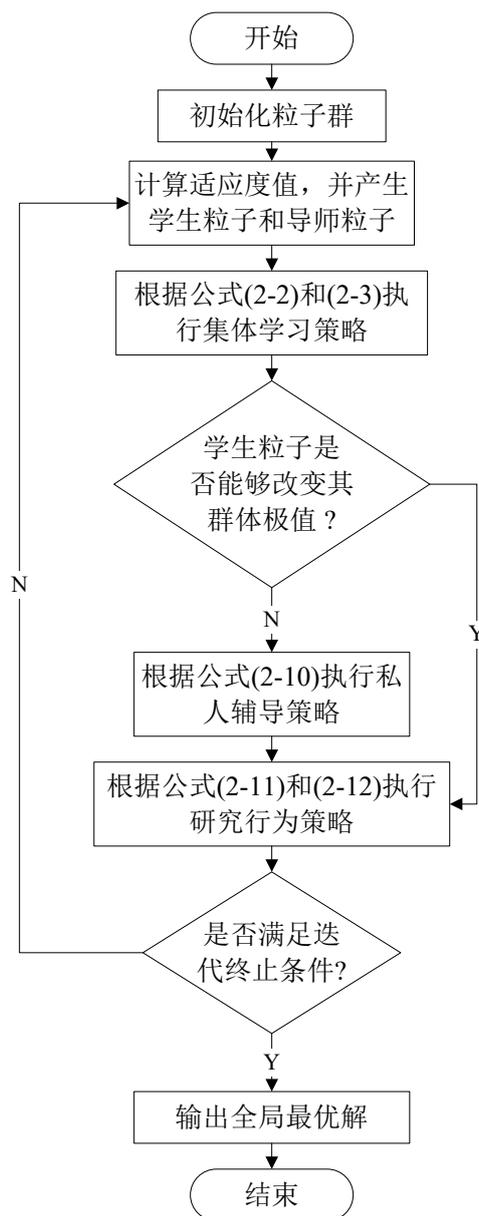


图 2-3 MELPSO 算法流程图

步骤 1: 初始化每个粒子的速度和位置。本质上, 每个粒子的位置可被视为代表着一个潜在解的知识。采用随机随时化可使得粒子群具有更高的概率尽量散布于整个解空间, 从而确保种群的多样性。

步骤 2: 利用适应度函数 $\text{fit}(\cdot)$ 来计算粒子群的适应度值, 再根据适应度值将粒子群按照升序或者降序排列, 而前 n_t 个粒子将作为导师粒子, 剩余的粒子将作为学生粒子。

步骤 3: 利用集体学习策略来更新学生粒子的速度和位置。学生粒子随机选择导师粒子, 如果 $\text{fit}(p_s^{k+1})$ 优于 $\text{fit}(p_{s\text{-ie}})$, 则令 $p_{s\text{-ie}} = p_s$; 同时, 如果 $\text{fit}(p_s^{k+1})$ 优于

$\text{fit}(p_{ge})$ ，则令 $p_{ge} = p_s$ ，这意味着集体学习策略对该学生粒子是有效的，然后转入步骤 5。如果 $\text{fit}(p_s^{k+1})$ 不能优于 $\text{fit}(p_{ge})$ ，意味着集体学习策略无效，要采用私人辅导策略，故转入步骤 4。

步骤 4: 私人辅导策略将帮助这些不能改进自身个体极值的学生粒子获得较优的适应度值。学生粒子需重新随机选择导师粒子，如果 $\text{fit}(p_s^{k+1})$ 优于 $\text{fit}(p_{s-ic})$ ，则令 $p_{s-ic} = p_s$ ；同时，如果 $\text{fit}(p_s^{k+1})$ 不弱于 $\text{fit}(p_{ge})$ ，则令 $p_{ge} = p_s$ 。

步骤 5: 利用研究行为策略来更新导师粒子的知识。同样地，如果 $\text{fit}(p_t^{k+1})$ 优于 $\text{fit}(p_{s-ic})$ ，则令 $p_{t-ic} = p_t$ ；如果 $\text{fit}(p_t^{k+1})$ 优于 $\text{fit}(p_{ge})$ ，则令 $p_{ge} = p_t$ 。

步骤 6: 重复上述步骤 2 至步骤 5，直到迭代终止条件被满足，最后输出所寻最优解。迭代终止条件有不同的形式，而在本研究中，统一设置迭代终止条件为达到最大迭代数，即 $k = k_{max}$ 。

2.2.2 MELPSO 算法性能改进分析

由图 2-1 分析所示，对 PSO 算法而言，要想提高全局寻优能力，必然要从四个方面入手对算法进行改进，而 MELPSO 算法通过对人类学习行为的仿真，充分模拟人类学习过程中的适应性、交互性、动态性、多样性等特点，极大提升算法的优化性能。因此，如图 2-4 所示，根据 MELPSO 算法采用的技术方法来分析该算法是如何从不同方面改进寻优性能的。

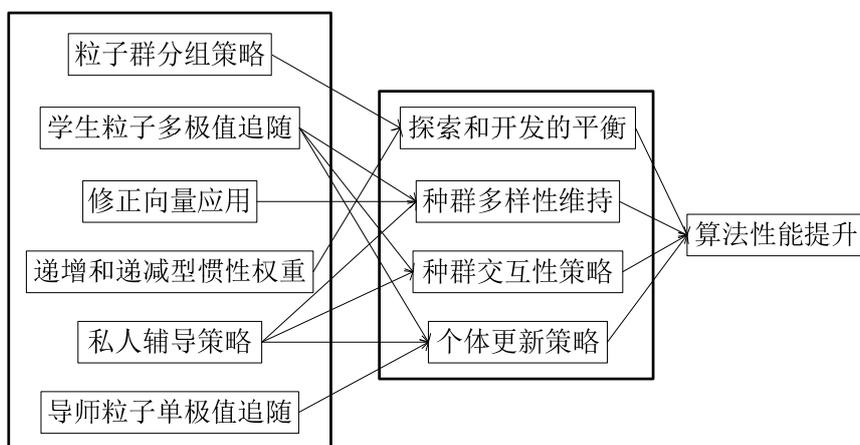


图 2-4 MELPSO 算法性能改进分析图

(1) 采用分组策略，将粒子群分成学生粒子和导师粒子，同时递减型的学生粒子惯性权重 ω_s 和递增型的导师粒子惯性权重 ω_t 使得不同的粒子始终兼顾探索和开发，使两者在整个迭代过程中达到相对平衡。

(2) 修正向量，私人辅导策略，以及对多极值的追随，保证了整个迭代过程中绝大部分粒子具有随机变异性，从而维持着种群多样性。

(3) 种群交互性采用多极值追随策略, 而不再完全单一地追随全局极值, 同时私人辅导策略的加入, 都增强了学生粒子同导师粒子的交互, 保持了粒子群间的信息传递。

(4) 5 种不同的个体更新策略为更新赋予了更丰富的内涵, 在更新过程中, 不仅只是粒子位置发生变化, 同时也维持着种群的多样性, 提供了种群间信息传递的渠道。

综合考虑造成 PSO 算法早熟收敛, 陷入局部最优区域的原因, 在算法执行过程中, 针对性地进行改进克服, 提升了算法获得全局最优解的概率, 增强了算法运行的稳定性和鲁棒性, 拓展了算法的应用空间。

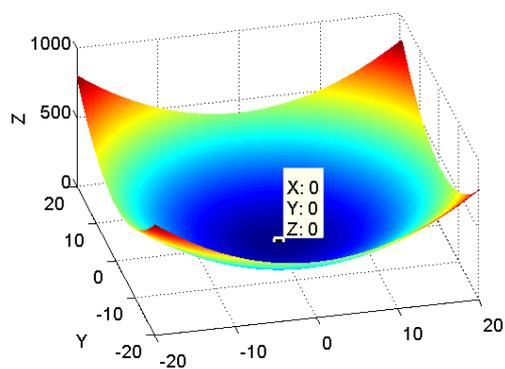
2.3 算法寻优性能验证及比较

PSO 算法本质上是一种启发式的群体随机搜索算法。而随机性像双刃剑一样, 既是维持种群多样性的必然保证, 又是导致求解结果差异性的本质原因^[127]。因位置、速度等大量参数随机初始化, 同时受不同进化策略的影响, 即便同一优化算法, 最终所求得的全局最优解都可能存在差异, 有些算法甚至会导致解的较大差异, 这些解或者处于不同的局部最优区域, 或者从不同的空间方向靠近全局最优区域。因此, 对于这一最优解的差异性现象, 文献[128]将其解释为解的不唯一性, 特别对于复杂的多模态问题, 解的差异将异常明显, 严重影响了算法的应用效果。解的差异性将自然引起适应度值的波动, 所以, 算法的性能, 包括寻优性能, 稳定性等都可以通过适应度值的波动程度来衡量。在本研究当中, 重复 100 次实验所求全局极值的最小值 (Min)、均值 (Mean)、最大值 (Max) 和均方差 (Standard Deviation, STD) 被用来对算法性能进行验证。

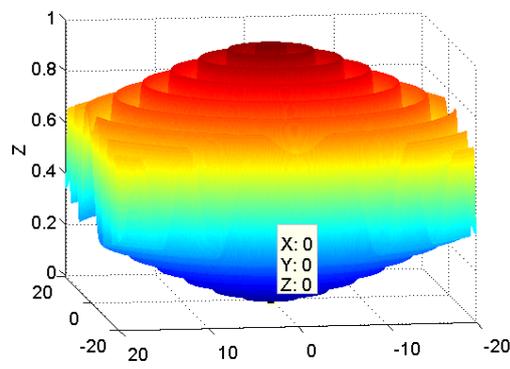
一些经典的测试函数将用来检验各类 PSO 改进算法的整体性能, 而表 2-1 显示了 8 类测试函数的相关特征。对这 8 类函数而言, 全局最优区域隐藏于宽度从 -100 到 100 的 50 维的多维空间中, 除了巨大的搜索空间外, 这些函数都具有相应特点, Schaffer, Griewank, Ackley 和 Rastrigin 都是典型的非线性多模态函数, 它们都是公认的复杂优化问题, 因为在解空间存在无数的局部最优极值的干扰。而对于 Sphere, SDPF (Sum of Different Power Function), RHEF (Rotated Hyper Ellipsoid Function) 和 Rosenbrock, 它们的极值几乎位于相对平缓、狭窄的区域, 此类区域就类似于抛物线般的峡谷, 所以, 函数所提供的关于全局极值的信息是难于发掘的, 使得很多优化函数在处理这 3 类函数时都具有明显困难。图 2-5 显示了 8 类函数的 3 维图像特征。所以, 这 8 类函数对 PSO 改进算法是巨大的挑战, 对算法性能也是一个显著检验。

表 2-1 典型测试函数特征

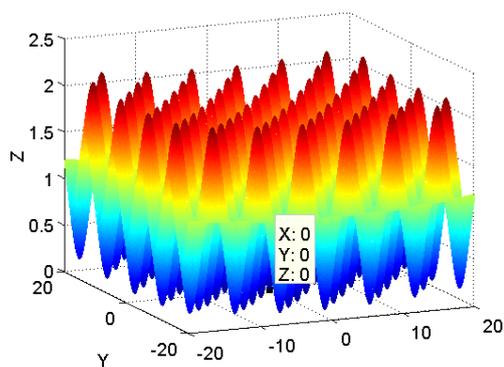
测试函数	搜索范围	维数	最优解	全局极值
Sphere: $f_{\text{Sphere}} = \sum_{i=1}^n x_i^2$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0
Schaffer: $f_{\text{Sch}} = 0.5 + \frac{\left(\sin \sqrt{\sum_{i=1}^n x_i^2}\right)^2 - 0.5}{\left[1 + 0.001 \left(\sum_{i=1}^n x_i^2\right)\right]^2}$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0
Griewank: $f_{\text{Gri}} = \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0
Ackley: $f_{\text{Ack}} = -20 \cdot e^{-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}} - e^{\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)} + 20 + e$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0
Rastrigin: $f_{\text{Ras}} = \sum_{i=1}^n [x_i^2 - 10 \cdot \cos(2\pi x_i) + 10]$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0
Rosenbrock: $f_{\text{Ros}} = \sum_{i=1}^{n-1} [100(x_i^2 - x_{i+1})^2 + (x_i - 1)^2]$	[-100, 100]	50	$(1, 1, \dots, 1)_{50}$	0
SDPF: $f_{\text{SDPF}} = \sum_{i=1}^n x_i ^{i+1}$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0
RHEF: $f_{\text{RHEF}} = \sum_{i=1}^n \left(\sum_{j=1}^i x_j\right)^2$	[-100, 100]	50	$(0, 0, \dots, 0)_{50}$	0



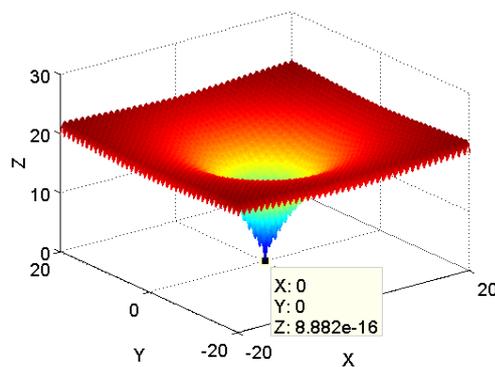
(a)



(b)



(c)



(d)

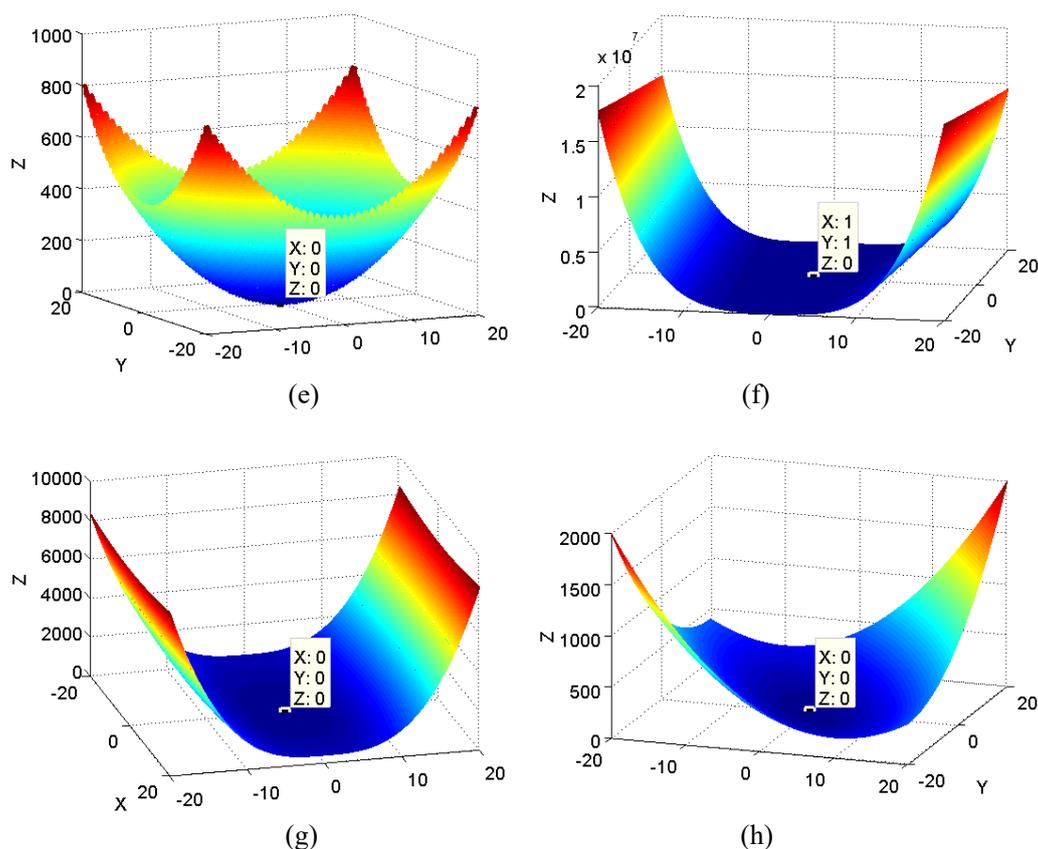


图 2-5 各测试函数空间三维图像。(a) Sphere 函数图像；(b) Schaffer 函数图像；(c) Griewank 函数图像；(d) Ackley 函数图像；(e) Rastrigin 函数图像；(f) Rosenbrock 函数图像；(g) SDPF 函数图像；(h) RHEF 函数图像

在最近关于 PSO 算法的一系列研究当中，基于人类行为的改进得到了广泛关注，如模仿人类认知行为的 SRPSO (Self Regulating PSO) 算法^[103]；模仿人类社会进化机制的 ALCPSO (Aging Leader and Challengers PSO) 算法^[102]；模仿人类的社会学习行为的 SLPSO (Social Learning PSO) 算法^[129]；和模仿人类智能搜索行为的 SOA (Seeker Optimization Algorithm) 算法^[105]。这些基于人类行为的改进型算法已证明在全局寻优能力方面具有优良的性能。同时，一些经典的基于参数调节的 PSO 改进算法，包括带惯性权重 (Inertia Weight, IW) 的改进算法^[125]，带压缩因子 (Shrinkage Factor, SF) 的改进算法^[130]，都解决了很多实际工程应用问题。除此之外，基于动态邻域 (Dynamic Neighborhood, DN) 拓扑结构的 PSO 改进算法也已广泛应用到各类优化问题当中^[131]；基于模拟退火 (Simulated Annealing, SA) 与 PSO 集成的 SAPSO 算法^[95]，多 Agent (Multiple Agent) 与 PSO 集成的 MAPSO 算^[132]，也极大提高了单一 PSO 算法的寻优性能。因此，SRPSO、ALCPSO、SLPSO、SOA、IWPSO、SFPSO、DNPSO、SAPSO 和 MAPSO 算法将与 MELPSO 算法进

行综合比较，验证所提算法的性能。

2.3.1 各优化算法性能比较及分析

8类测试函数为各算法提供了非常严苛的优化条件，使得各算法性能能够得以充分而有效验证。同时为了验证算法运行的稳定性，对同一优化问题，每个算法将连续计算100次，以获得适应度值的统计参数。对所有算法而言，种群数量设置为60，最大迭代数设置为400，粒子位置为[-100, 100]，速度限制为[-2, 2]，粒子维度为50，MELPSO算法的导师粒子数设置为3，而其它算法的具体参数设置在之前相关引用文献中已有具体讨论，请参见引用文献。各算法计算结果的统计如表2-2至表2-9所示。

表 2-2 各优化算法对 Sphere 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{Sph}	SRPSO	2.2043e-05	2.5242e-04	0.0027	4.2361e-04
	ALCPSO	3.1508	8.4617	23.2152	3.5402
	SLPSO	2.1907e+03	4.1728e+03	7.5936e+03	1.0768e+03
	SOA	0.1055	0.3556	2.8734	0.4243
	IWPSO	157.5616	474.2775	1.1510e+03	170.3416
	SFPSO	1.0749e+03	1.9491e+03	3.1651e+03	487.0422
	DNPSO	8.7476e-04	0.1176	1.5174	0.2309
	SAPSO	44.9451	132.2141	323.4580	53.1313
	MAPSO	2.4162e-04	0.0042	0.0373	0.0073
	MELPSO	8.9132e-106	5.4995e-93	4.7113e-91	4.7304e-92

表 2-3 各优化算法对 Schaffer 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{Sch}	SRPSO	0.3961	0.4481	0.4760	0.0159
	ALCPSO	0.4147	0.4548	0.4825	0.0143
	SLPSO	0.4760	0.4928	0.4974	0.0034
	SOA	0.1270	0.1856	0.2727	0.0397
	IWPSO	0.3733	0.4451	0.4796	0.0176
	SFPSO	0.4663	0.4886	0.4959	0.0048
	DNPSO	0.4964	0.4995	0.4999	4.4917e-04
	SAPSO	0.3733	0.4455	0.4760	0.0182
	MAPSO	0.2727	0.3816	0.4663	0.0410
	MELPSO	0	0	0	0

表 2-4 各优化算法对 Griewank 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{Gri}	SRPSO	6.5566e-07	0.0055	0.0271	0.0066
	ALCPSO	0.1362	0.3550	0.6089	0.1003
	SLPSO	1.4347	2.0718	2.9030	0.2967
	SOA	0.0183	0.0682	0.1837	0.0390
	IWPSO	1.0381	1.1099	1.2333	0.0337
	SFPSO	1.2522	1.4751	1.7843	0.1139
	DNPSO	1.1532e-04	0.0105	0.1050	0.0154
	SAPSO	0.8031	0.9869	1.0605	0.0593
	MAPSO	7.5990e-04	0.0041	0.0247	0.0060
	MELPSO	0	0	0	0

表 2-5 各优化算法对 Ackley 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{Ack}	SRPSO	20.9769	21.1626	21.2718	0.0591
	ALCPSO	11.1611	19.2621	20.3429	1.7590
	SLPSO	16.8872	18.6374	20.3589	0.7229
	SOA	0.8516	2.9511	6.7027	0.9149
	IWPSO	15.9496	19.7884	20.9801	1.2198
	SFPSO	18.5238	20.6655	21.0528	0.3983
	DNPSO	19.9981	20.0057	20.0702	0.0103
	SAPSO	13.5620	19.4486	20.6969	1.7836
	MAPSO	2.1466	18.8497	21.0427	4.7275
	DELPSO	0	0	0	0

表 2-6 各优化算法对 Rastrigin 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{Ras}	SRPSO	100.4994	193.3532	316.4255	47.8580
	ALCPSO	384.3389	950.8462	1.8720e+03	247.1140
	SLPSO	2.4599e+03	4.5667e+03	7.1415e+03	1.1390e+03
	SOA	154.2016	283.5588	460.7673	60.7549
	IWPSO	668.0716	1.1198e+03	2.0499e+03	253.8437
	SFPSO	1.6033e+03	2.6131e+03	3.9525e+03	493.3263
	DNPSO	263.7042	471.2133	877.0716	123.0914
	SAPSO	751.8557	1.1760e+03	2.0357e+03	212.5357
	MAPSO	111.4675	204.6464	316.7379	42.7844
	MELPSO	0	0	0	0

表 2-7 各优化算法对 Rosenbrock 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{Ros}	SRPSO	41.4845	155.0830	577.2163	99.5176
	ALCPSO	993.8711	5.2190e+03	4.0914e+03	5.2917e+03
	SLPSO	2.5045e+07	8.8191e+07	2.8155e+08	4.8067e+07
	SOA	116.8974	1.3262e+03	7.9966e+03	1.4619e+03
	IWPSO	8.8031e+04	5.8911e+05	2.2943e+06	4.2853e+05
	SFPSO	6.3937e+06	2.0591e+07	5.2896e+07	8.9704e+06
	DNPSO	46.9572	168.5542	359.9697	65.6856
	SAPSO	4.9509e+04	2.6430e+05	1.2654e+06	1.8261e+05
	MAPSO	42.0773	148.8532	477.8643	78.9878
	MELPSO	39.7651	42.6252	45.5219	1.1505

表 2-8 各优化算法对 SDFP 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{SDFP}	SRPSO	2.0020	3.1507e+08	2.2388e+10	2.2950e+09
	ALCPSO	1.2845e+14	1.2248e+24	4.0634e+25	6.2171e+24
	SLPSO	1.0338e+35	6.1211e+52	6.1031e+54	6.1029e+53
	SOA	3.6939e+10	2.1513e+29	1.8180e+31	1.8296e+30
	IWPSO	3.1191e+21	1.4861e+38	1.3550e+40	1.3597e+39
	SFPSO	3.2660e+33	1.4339e+49	1.4305e+51	1.4305e+50
	DNPSO	9.8549e-11	0.1565	5.4823	0.6774
	SAPSO	7.1250e+20	9.6887e+35	7/8243e+37	7.9557e+36
	MAPSO	16.4958	7.8390e+07	3.0258e+09	3.5420e+08
	MELPSO	1.7180e-213	7.3065e-187	7.1776e-185	0

表 2-9 各优化算法对 RHEF 函数计算结果的统计比较表

测试函数	算法	Min	Mean	Max	STD
f_{RHEF}	SRPSO	378.6979	917.4161	1.9263e+03	325.5636
	ALCPSO	417.5442	1.0312e+03	2.9371e+03	400.3505
	SLPSO	4.2404e+03	9.5979e+03	1.9661e+04	3.0536e+03
	SOA	156.2746	2.0296e+03	4.5913e+03	845.3182
	IWPSO	2.6973e+03	1.0436e+04	2.6980e+04	4.5818e+03
	SFPSO	3.8656e+03	6.8552e+03	1.4529e+04	1.9304e+03
	DNPSO	33.8847	675.4832	1.0108e+04	1.7240e+03
	SAPSO	908.7697	2.5067e+03	1.1545e+04	1.2099e+03
	MAPSO	224.2853	560.1683	1.2585e+03	215.6727
	MELPSO	7.3321e-96	2.7666e-79	2.2507e-77	2.2974e-78

表 2-2 至表 2-9 表明：对所有测试函数，MELPSO 算法都能获得比其它改进算法更优的解，除了 Rosenbrock 函数，MELPSO 算法都获得了全局最优解，而其它改进算法在处理如此复杂的多模态优化问题时，基本不能获得全局最优解，由于改进原理的单一性，这些算法基本不可能处理所有测试函数，只能对某一些测试函数敏感。且 MELPSO 算法在寻优过程表现出了非常优异的稳定性和可靠性，随机性对算法的影响被极大抑制，“解的不唯一性”得到有效克服。比较结果有效证明了本文对 PSO 算法改进的可行性，MELPSO 算法能够以更高概率获得全局最优解，为拓展 PSO 应用提供了坚实理论支撑。

为验证各算法的收敛特性，分别采用各算法在 100 次计算结果中最优值的全局极值变化曲线作性能比较，比较结果如图 2-6 至图 2-13 所示。

图 2-6 至图 2-13 也直观有力地证明了 MELPSO 算法的寻优能力强于其它改进算法。在应对各类复杂、大参数优化问题时，能够快速收敛到一个相对最优的解区域，提高优化问题的求解质量，从而满足实际工程应用要求。造成 MELPSO 算法与其它改进算法性能巨大差异的原因，在于其它改进算法没有能够针对引起 PSO 算法易陷入局部最优的所有主要因素进行修正，而只侧重于部分因素进行改进。基于人类行为的算法，如：SRPSO、ALCPSO、SLPSO、SOA 算法，多侧重于种群多样性和交互性的改进；基于参数调节的算法，如：IWPSO 和 SFPSO 算法，多侧重于个体更新策略、探索开发平衡的改进；基于领域拓扑结构的算法，如：DNPSO 算法，多侧重于种群交互性、探索开发平衡的改进；而基于算法集成的算法，如：SAPSO 和 MAPSO 算法，则多侧重于个体更新策略、探索开发平衡和种群多样性的改进。如前分析，在深入研究 PSO 算法固有缺陷的基础上，MELPSO 算法的各类改进策略分别针对了探索开发平衡、种群多样性、交互性维持，个体更新策略进行了有效改进，从而增强 MELPSO 算法为全局寻优能力。

2.3.2 算法参数对优化性能影响及分析

在深入研究 PSO 算法固有缺陷的基础上，MELPSO 算法对各类起因作了针对性改进，从而提高了算法优化性能。而如同其他很多算法一样，一些参数都需要人为调节，其对算法性能影响明显^[133]。MELPSO 算法也具有相应调节的参数，主要的不确定参数是导师粒子数 n_t ，之前的算法验证中，导师粒子数设置为 3。因此，为了验证不同的导师粒子数对算法的影响，分别取 $n_t = 1-15$ 来验证对算法性能的影响，测试函数也利用表 2-1 当中的函数。算法设置与 2.4.1 节一致，且连续运行 100 次所得统计参数来验证算法性能。图 2-14 至图 2-21 显示了对于不同的测试函数，导师粒子数 n_t 变化对算法性能的影响。

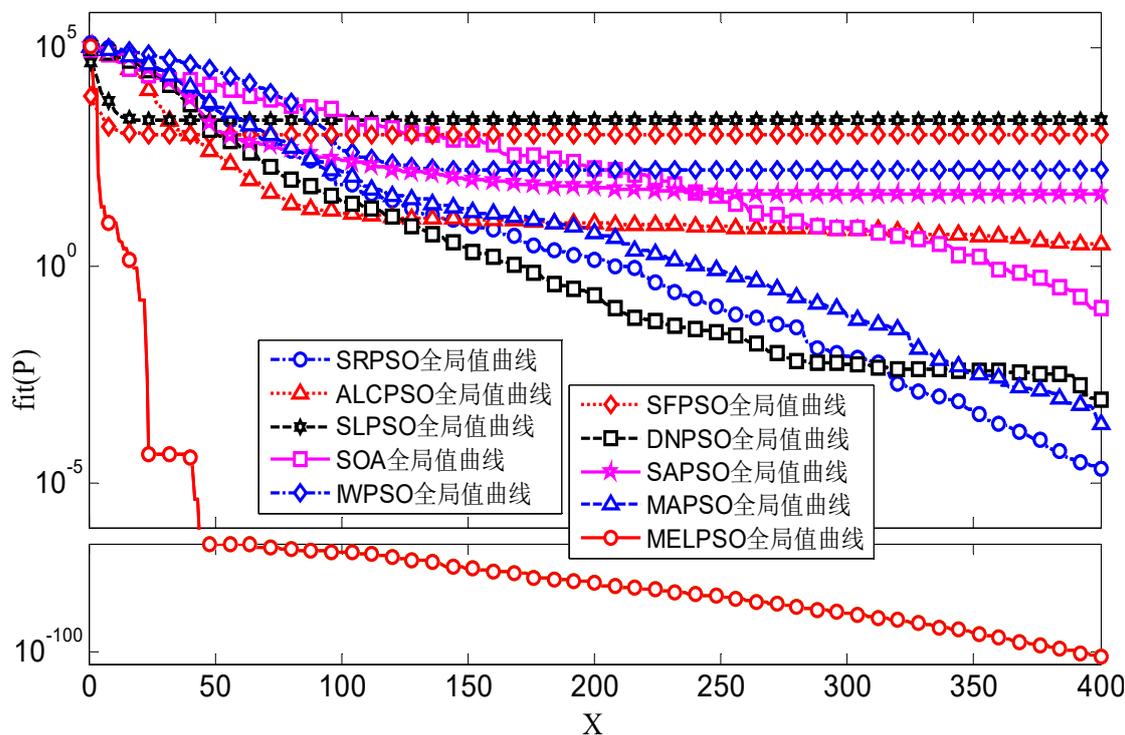


图 2-6 Sphere 函数寻优的全局极值曲线比较

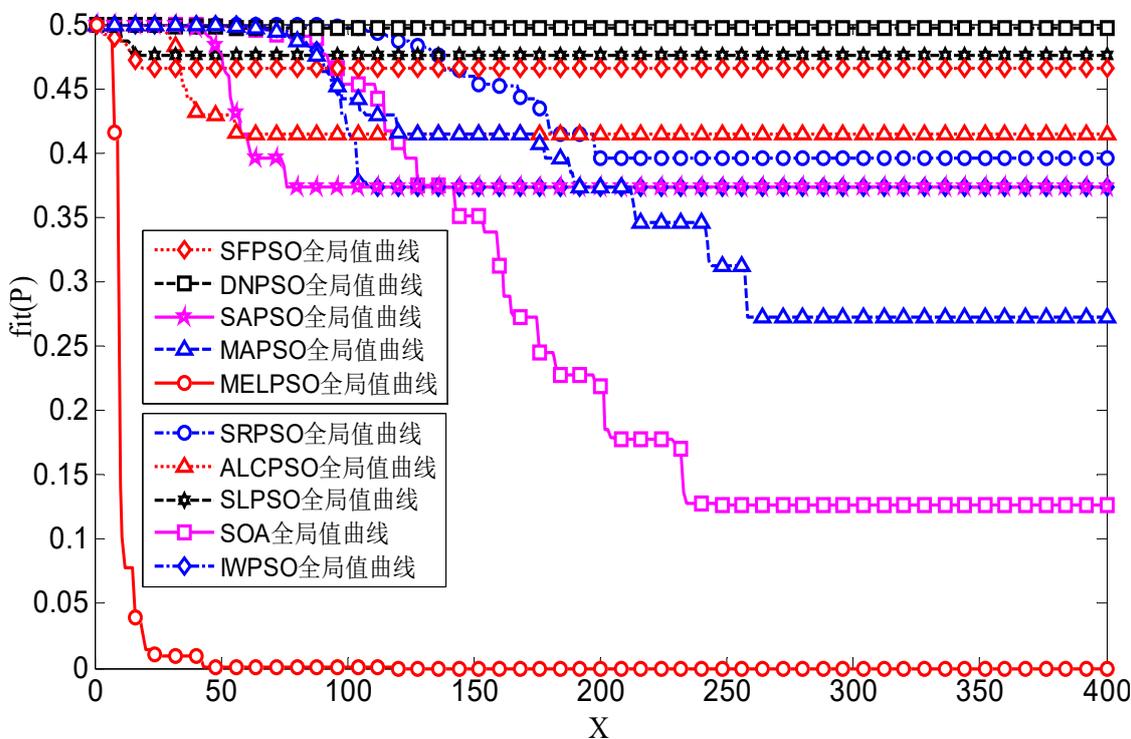


图 2-7 Schaffer 函数寻优的全局极值曲线比较

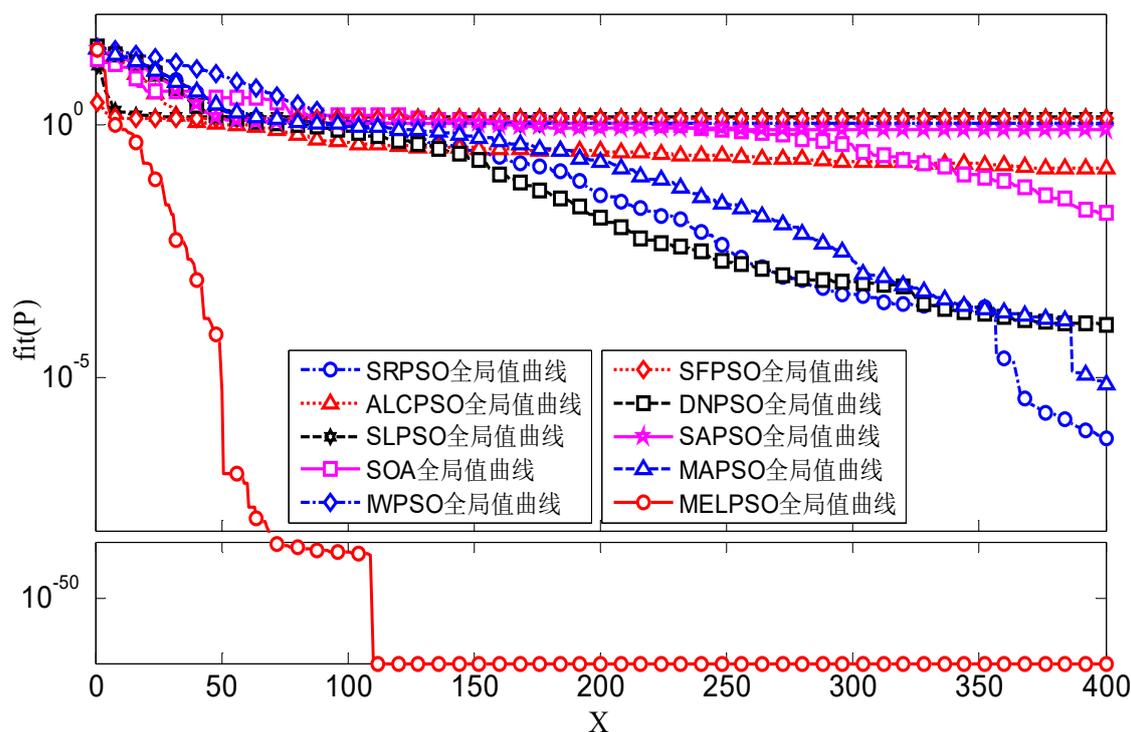


图 2-8 Griewank 函数寻优的全局极值曲线比较

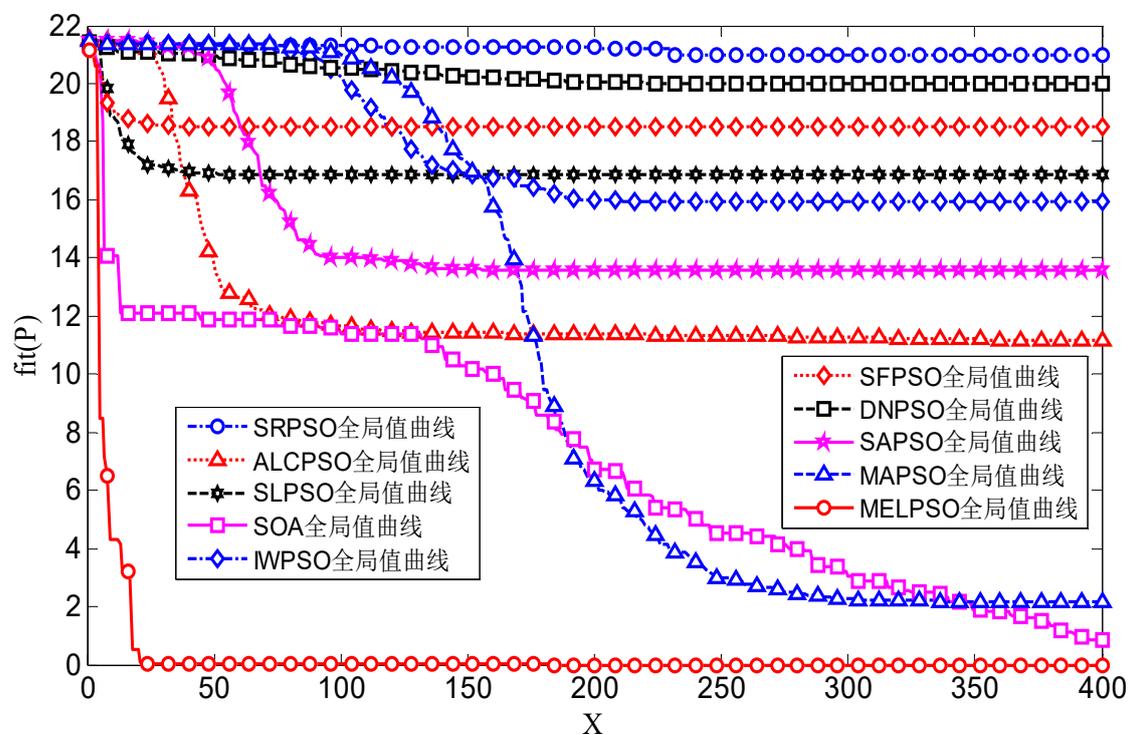


图 2-9 Ackley 函数寻优的全局极值曲线比较

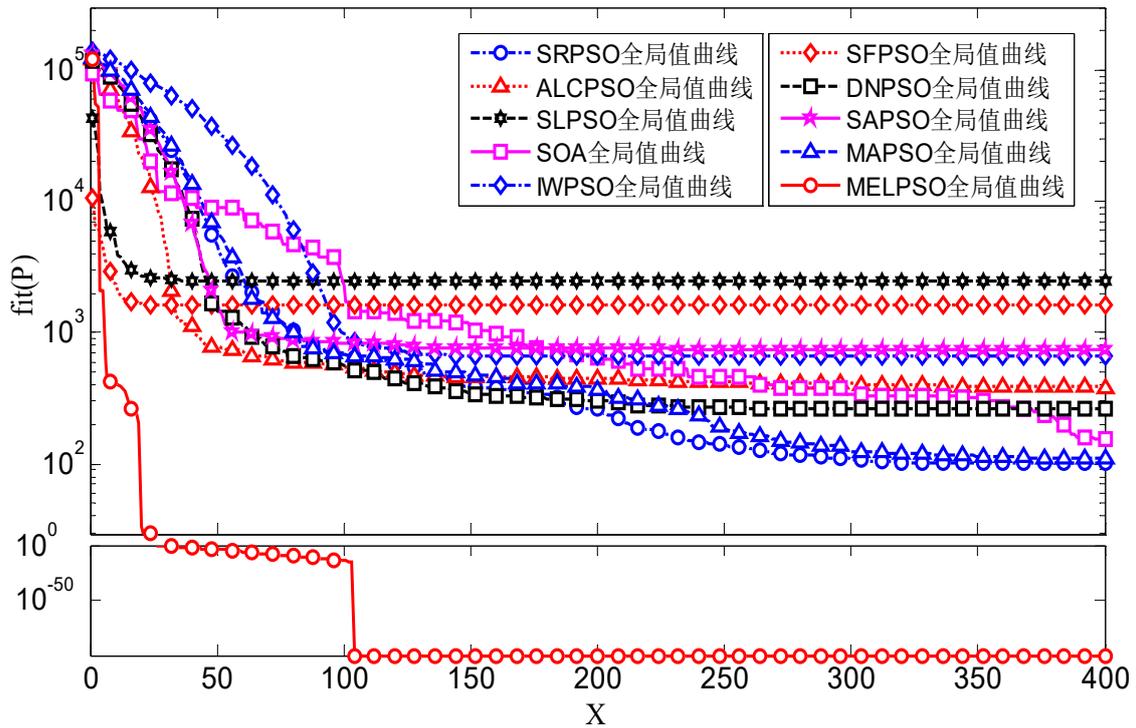


图 2-10 Rastrigin 函数寻优的全局极值曲线比较

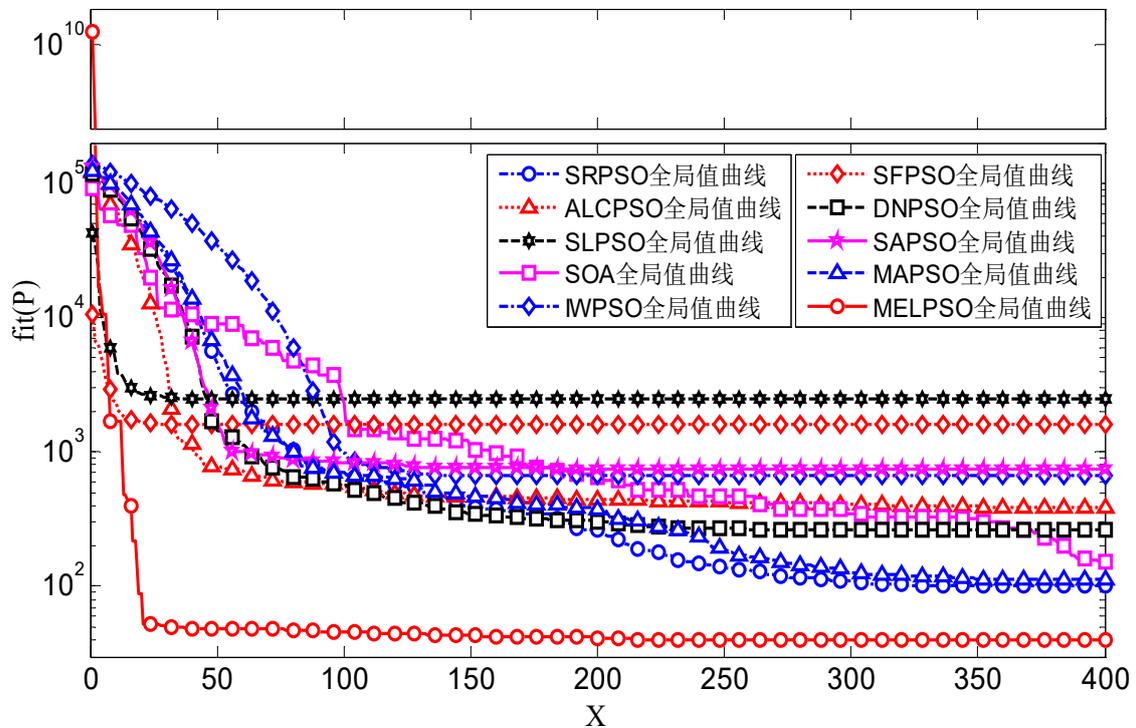


图 2-11 Rosenbrock 函数寻优的全局极值曲线比较

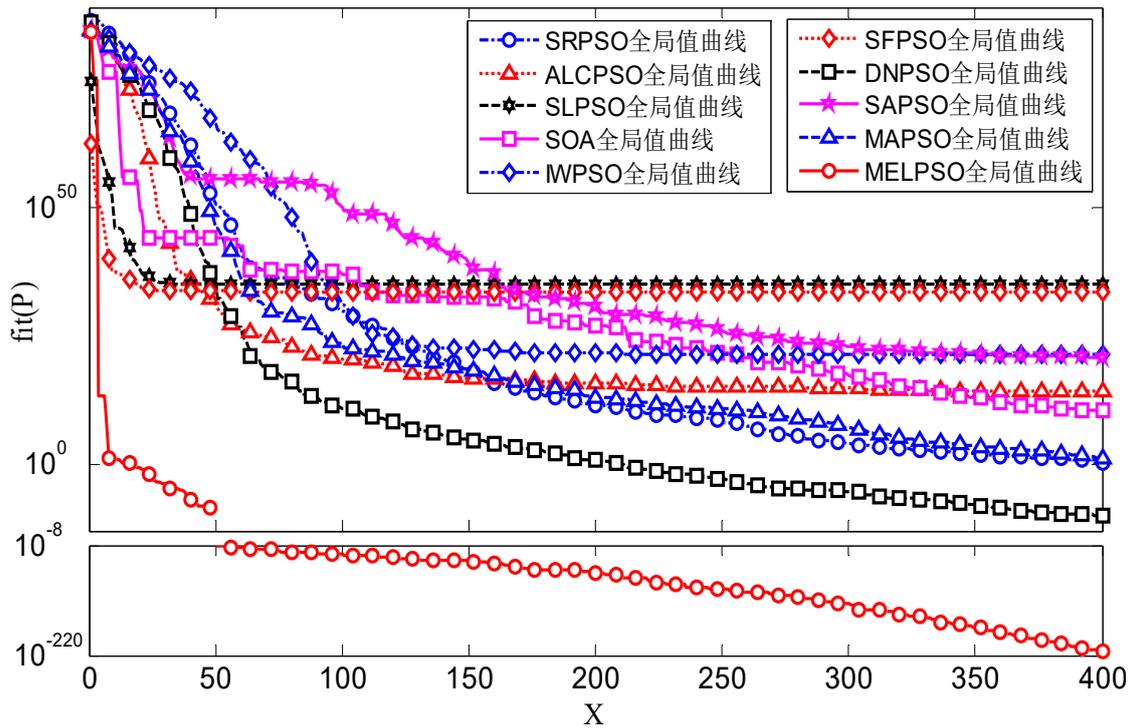


图 2-12 SDFP 函数寻优的全局极值曲线比较

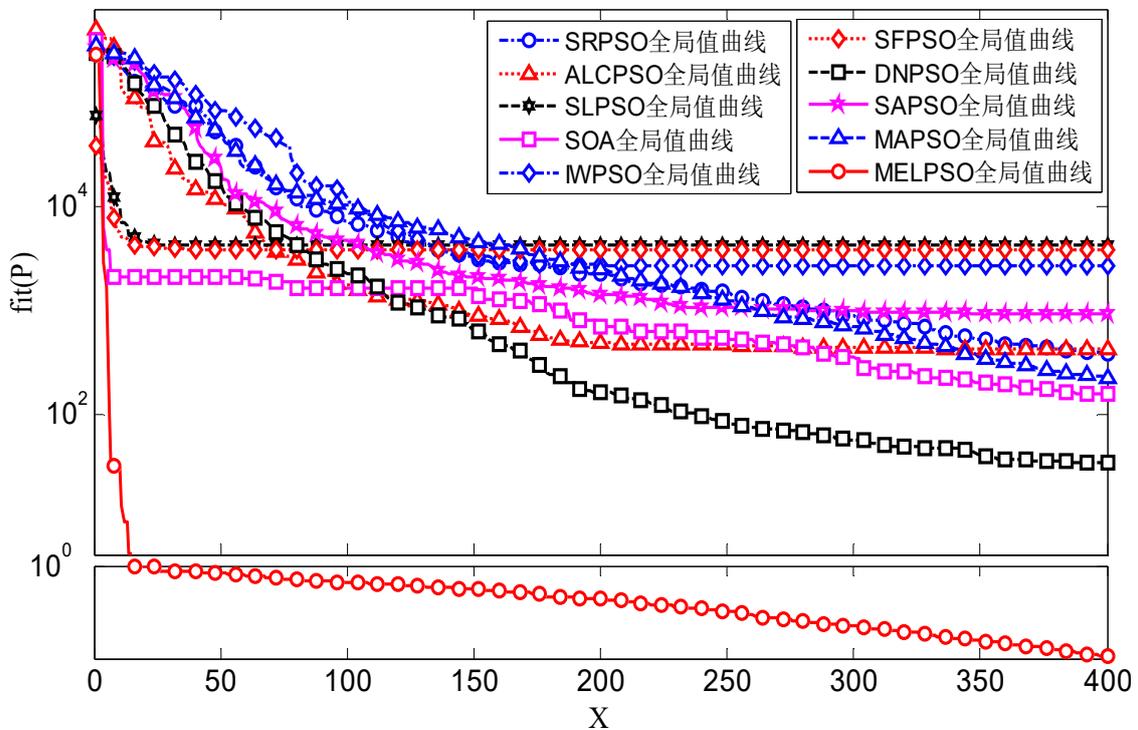


图 2-13 RHEF 函数寻优的全局极值曲线比较

图 2-14 至图 2-21 表明：对 Sphere、Ackley、SDPF、RHEF 函数，当 $n_t=1$ 时，算法寻优性能最佳，且随着 n_t 的增大，算法寻优性能逐渐降低；对 Schaffer、Griewank、Rastrigin 函数， n_t 的变化对算法寻优性能几乎没有造成影响；而对 Rosenbrock 函数，随着 n_t 的增大，算法寻优性能却呈现出逐渐增强的趋势。因此，对于不同的目标函数， n_t 呈现出不确定的作用，所以在设定 n_t 时，需要根据具体的函数进行确定。同时，尽管 n_t 的变化对算法的性能造成了影响，但总体而言，与其它改进型算法相比，算法性能的变化都在一个可接受的水平范围内，从而再次证明 MELPSO 算法运行的稳定性。

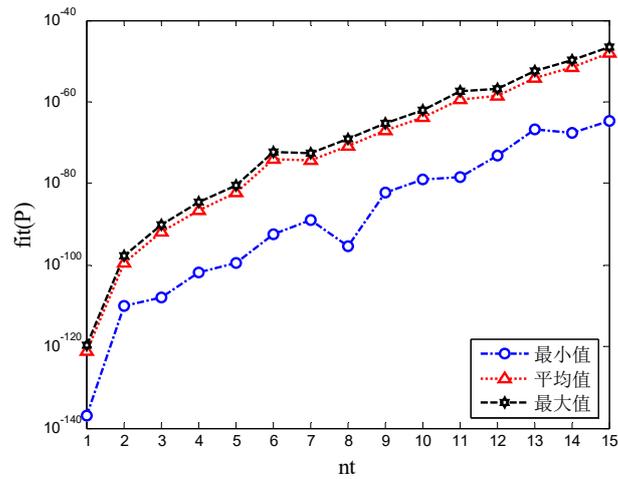


图 2-14 n_t 变化对 Sphere 函数寻优性能的影响

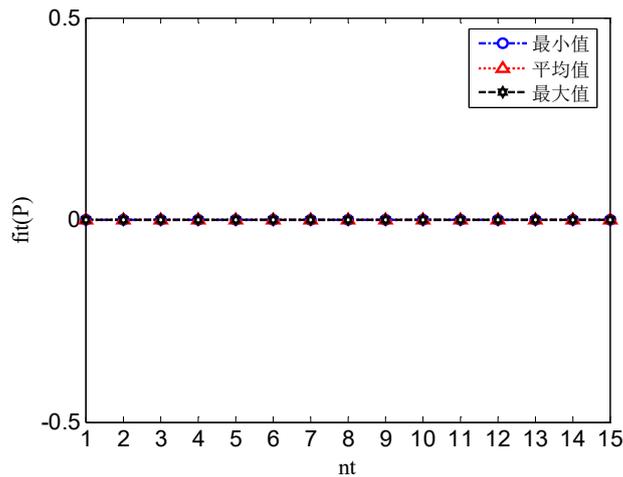


图 2-15 n_t 变化对 Schaffer 函数寻优性能的影响

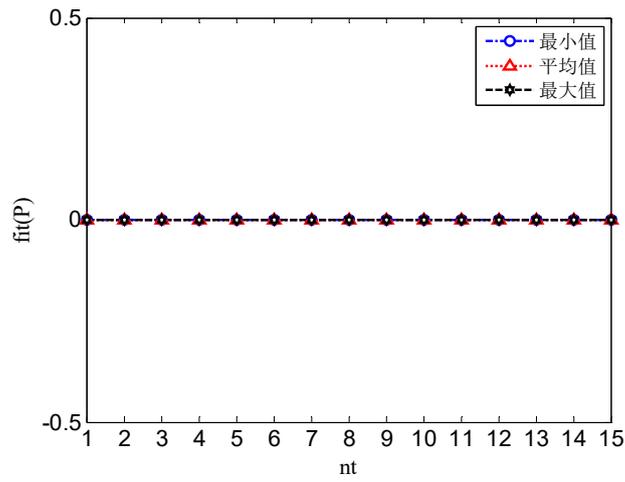


图 2-16 n_t 变化对 Griewank 函数寻优性能的影响

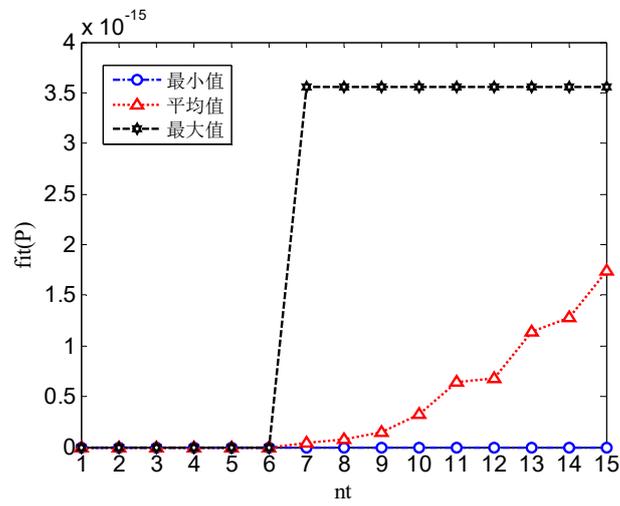


图 2-17 n_t 变化对 Ackley 函数寻优性能的影响

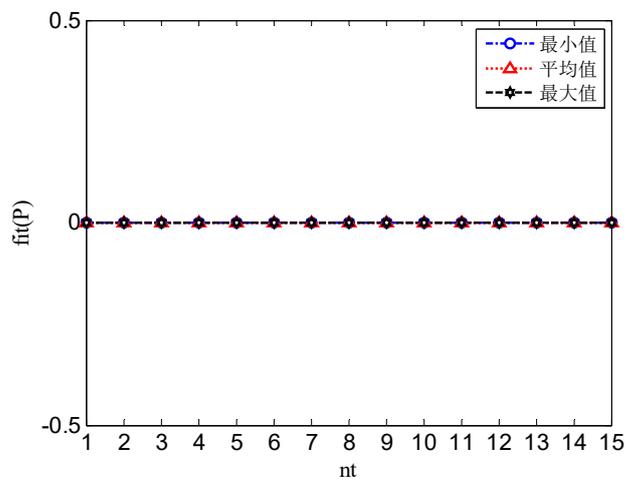


图 2-18 n_t 变化对 Rastrigin 函数寻优性能的影响

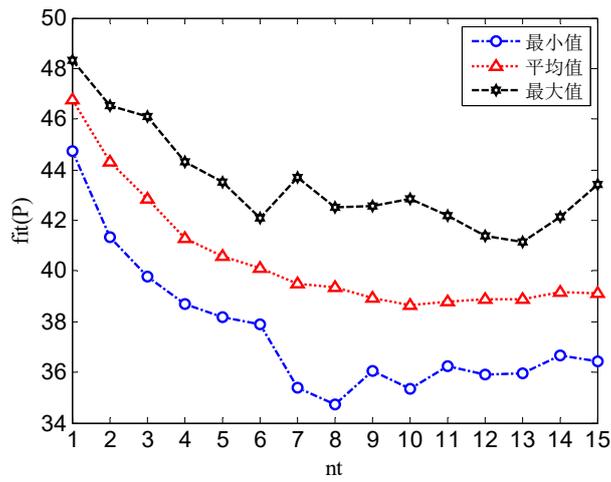


图 2-19 n_t 变化对 Rosenbrock 函数寻优性能的影响

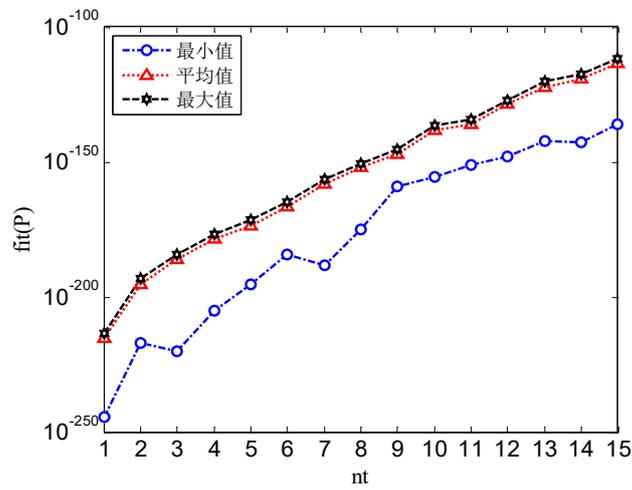


图 2-20 n_t 变化对 SDPF 函数寻优性能的影响

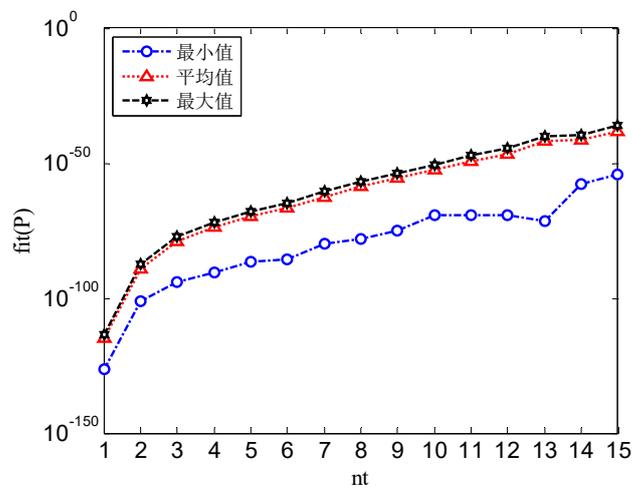


图 2-21 n_t 变化对 RHEFF 函数寻优性能的影响

另一方面，MELSPO 算法的更新方式有 5 种，对学生粒子而言：有集体学习策略和 3 个私人辅导策略，对导师粒子而言有研究行为。能够起到全局极值更新的只有集体学习策略、片段继承策略、随机继承策略和研究行为策略，为了验证这 4 种更新策略在寻优过程中所起的作用，统计全局极值在改变时所依靠的更新策略次数，直观体现出算法更新策略在种群进化过程中所起的作用，从而验证算法设计的合理性和有效性。

导师粒子数 n_t 依然取从 1 到 15 的变化区间，每次连续运行 100 次，优化目标函数如表 2-1 所示，算法设置如 2.4.1 节所示。用 4 种更新策略分别改变全局极值的次数与全局极值改变总次数的百分比来表征不同更新策略优化不同目标函数时所起作用。图 2-22 至图 2-29 显示了各更新策略在优化过程中改变全局极值次数所占百分比。

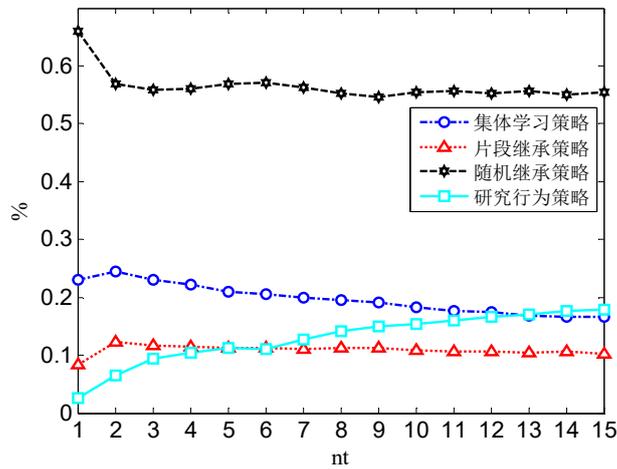


图 2-22 不同更新策略在优化 Sphere 函数的作用

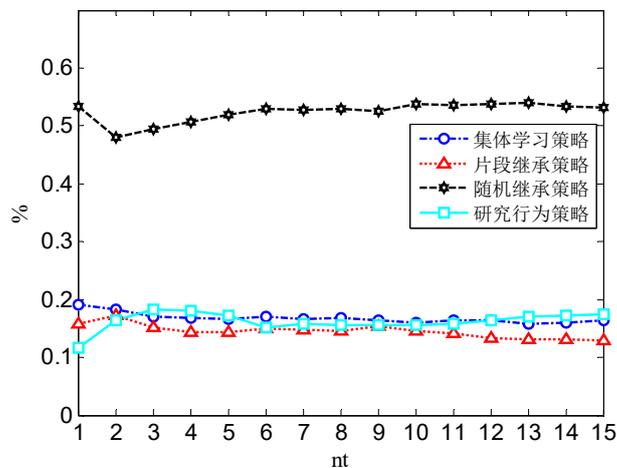


图 2-23 不同更新策略在优化 Schaffer 函数的作用

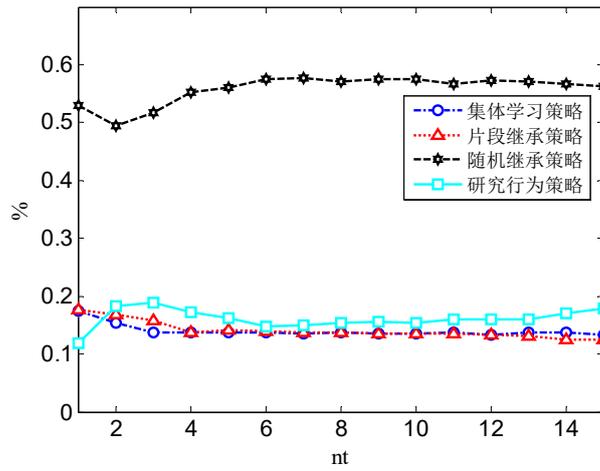


图 2-24 不同更新策略在优化 Griewank 函数的作用

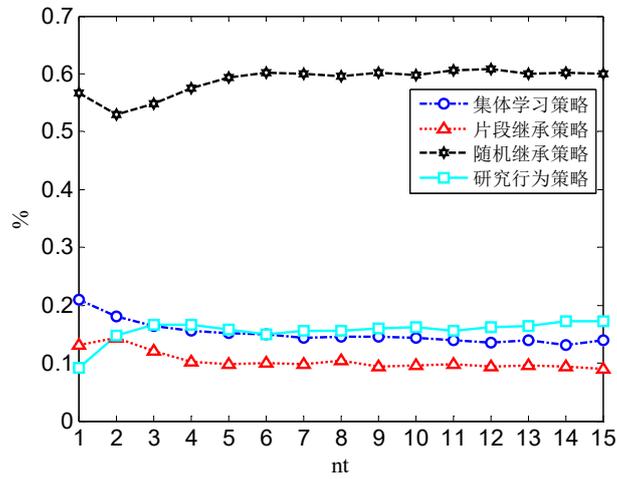


图 2-25 不同更新策略在优化 Ackley 函数的作用

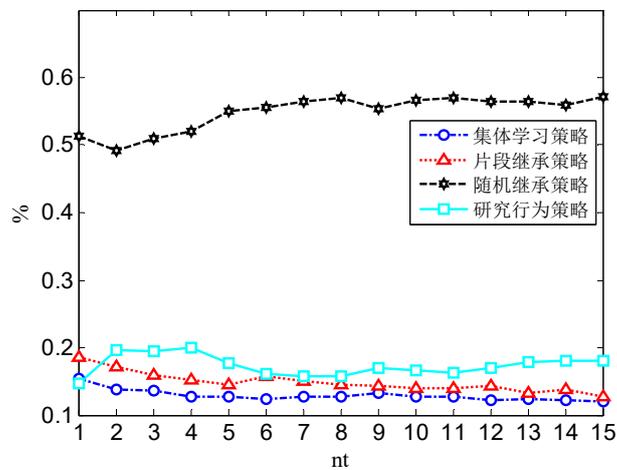


图 2-26 不同更新策略在优化 Rastrigin 函数的作用

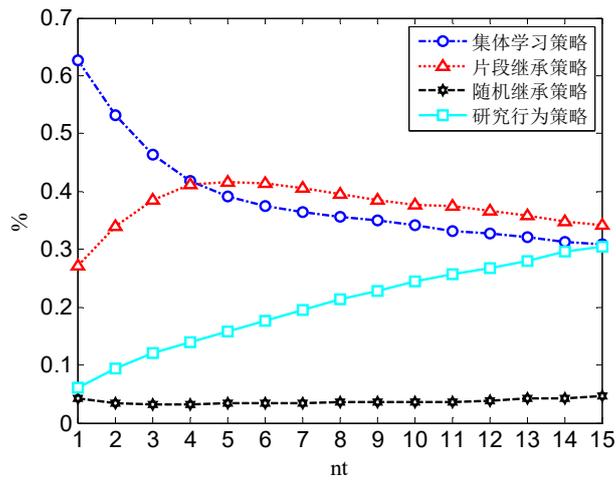


图 2-27 不同更新策略在优化 Rosenbrock 函数的作用

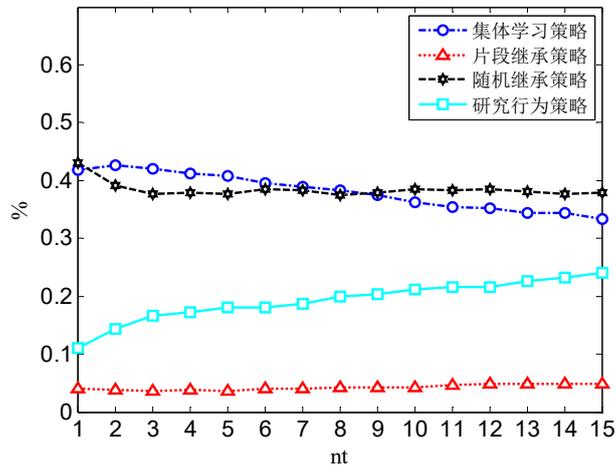


图 2-28 不同更新策略在优化 SDPF 函数的作用

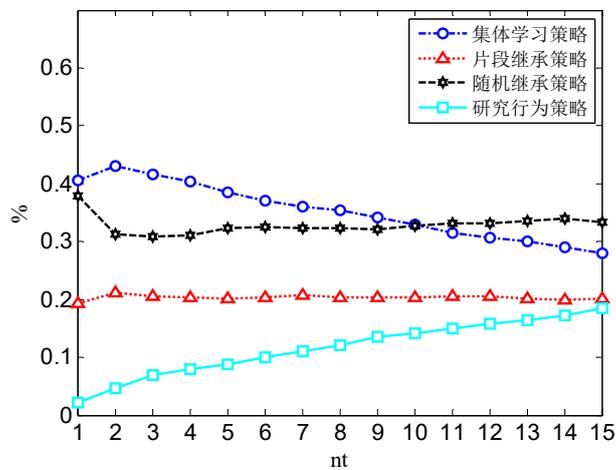


图 2-29 不同更新策略在优化 RHEF 函数的作用

由图 2-22 至图 2-29 可知：对 Sphere、Schaffer、Griewank、Ackley、Rastrigin 函数，私人辅导中的随机继承策略起到了更新全局极值的主要作用，对 SDPF、RHEF 函数，集体学习和随机继承基本起到同样重要的作用，而对 Rosenbrock 函数，集体学习和片段继承几乎起到相同的作用，因此，各更新策略能够根据目标函数的不同特点有侧重的发挥作用，改进全局极值，确保了在面对高维的、复杂的、多参数的优化难题，有效而稳定获得全局极值，进而证明了算法设计的合理性。

2.4 本章小结

PSO 算法具有因易陷入局部最优区域而导致早熟收敛的固有缺陷，从而限制了在高维、复杂、多参数的优化问题中的应用，本章从种群多样性的维持、种群间有效交互模式的增强、搜索过程中开发与探索的平衡，以及更新过程的改进等方面增强算法的全局寻优能力，提出了基于模仿人类学习的 MELPSO 算法。因该算法较好地模仿了人类多样性、交互性、动态性、适应性等行为特点，在面对各类复杂优化难题时，表现了出较佳的全局优化性能，有效克服了早熟收敛的固有缺陷。经过性能的分析与比较，证明了 MELPSO 算法稳定、可靠的全局优化能力，进一步拓展了 PSO 算法的应用空间，为后续实际工程应用提供了坚实的技术支撑。

第三章 基于 MELPSO 算法的故障模式识别方法

由于现代工业水平不断提高，工业设备不断改进，对设备故障机理、故障模式进行准确分析和判断已变得非常复杂。同时，故障对生产活动造成的影响也日益严重，特别是一些关键部件，与安全生产有着直接的联系。在现代工业发展过程中，非计划停机和重大损失是完全不可接受的，而关键部件的失效是造成机器停机，甚至灾难性事故的主要原因^[134]。因此，自 20 世纪 60 年代以来，故障诊断技术得到了快速发展，已经成一门独立的、交叉性的重要学科，成为预防重大事故、保障运营安全、获得最大生产利益的关键手段，在现代工业发展过程中起到了至关重要的作用^[8, 135]。基于此，开展故障诊断研究，对改善排故效率，缩短维修时间、降低维修成本和确保安全生产具有重要意义。

图 3-1 给出了一般的设备状态监控、信息处理、故障诊断，及健康预测的实施流程图。

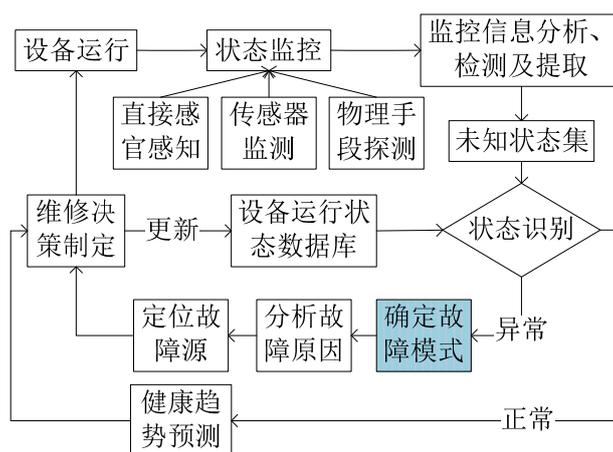


图 3-1 设备状态监控、故障诊断，及健康预测的实施流程图

如图 3-1 所示，现代工业社会当中，对于设备的健康管理，主要是建立在大量传感器监测数据的基础之上。由于设备各子系统、各部件运行特征、工作环境、载荷强度等不一致，通过信息处理后，设备不同的运行状态特征能够通过监控数据的差异性体现出来。依据设备状态运行数据库的特征数据来分析监控数据的状态。通常状态分为“正常”和“异常”，同时，设备运行状态数据库主要来自于设备生产制造过程中的大量测试试验，以及大量实际使用过程中所收集的各类特征数据。对于“正常”的状态监控数据，能够反映出设备运转的状态衰退特征，用于对设备的健康状态趋势预测，制定相应的维修检测计划。而对于“异常”的状

态监控数据，则需要明确从运行状态数据库中识别出相应的故障模式，确定引起故障的原因，进而定位故障源，最终制定相应的维修决策方案。这一系列健康管理方案，也为预防维修（preventive maintenance, PM）的实施提供了保障，有效提升了维修效率，降低了维修成本，确保了运行安全。

故障模式识别是故障诊断的关键环节，其定义为：准确确定设备未知故障模式所属的真实状态^[136]。实质上，故障模式识别已被广泛地成功应用于许多复杂设备的未知运行状态识别中，例如：航空发动机、旋转机械、电力电子系统等。按照国际故障诊断惯例，确定未知故障状态的常用方法有：基于解析模型的方法、基于信号处理的方法，以及基于机器学习的方法^[137]。一般来说，当诊断对象的动态模型已知时，基于解析模式的方法是适用的；当无法清晰地描述系统的状态模型时，而输入/输出信号可知时，可采用基于信号处理的方法；当很难甚至无法建立诊断对象的定量数学模型时，采用基于机器学习的方法较为简便^[138]。随着工业设备发展的复杂化、集成化、智能化，传统的解析模型方法几乎难以准确描述设备的运行特征，基于机器学习的方法，如人工智能算法、统计模式识别、群体智能算法、基于核函数的算法等，因主要处理设备运行过程中的状态监控数据，而非关注设备运行过程中的物理化学变化特性，从而避免了对诊断对象运行过程中的复杂数学描述，已被广泛应用于解决各种实际问题，尤其是在故障诊断领域中，极大促进了故障诊断技术进步^[139]。

3.1 基于距离的故障模式识别方法

反映设备运行状态的监控数据在多维特征空间中总是呈现出一定的分布特性，如呈现出团状分布、带状分布、甚至不规则分布等特征，而且通常不同类别的数据分布间没有明确清晰的边界。基于距离的模式识别方法主要是依靠判别到点、线或者面的距离长短来确定未知样本的所属类别。该方法主要优点在于识别原理简单、直观，易于实现；缺点是难以处理非线性分布明显的的数据，且训练过程中大量距离计算导致算法运行效率不高。

样本间的相似度关系通常可以用很多种距离定义来测量，如明可夫斯基距离、马氏距离、曼哈顿距离、切比雪夫距离、皮尔逊相关系数和余弦相似度等^[140-143]。当然，这些距离定义都是从不同理论层面来表征样本相似度的。通常，欧几里得距离是一种应用广泛的相似度测量公式，很多经典算法都采用欧式距离来表征样本相似度^[128, 131, 144]。欧式距离计算公式如下：

$$\begin{aligned}
 dis_{ij} &= \|\mathbf{x}_i - \mathbf{x}_j\| = \sqrt{\|\mathbf{x}_i - \mathbf{x}_j\|^2} \\
 &= \sqrt{\langle \mathbf{x}_i - \mathbf{x}_j, \mathbf{x}_i - \mathbf{x}_j \rangle} = \sqrt{\sum_{d=1}^D (x_{id} - x_{jd})^2}
 \end{aligned} \tag{3-1}$$

式中： \mathbf{x}_i 表示第*i*个样本。欧式距离取值在 $[0, +\infty)$ ，“0”表示 \mathbf{x}_i 和 \mathbf{x}_j 是完全一致的，两者相似度为1；而如果 \mathbf{x}_i 和 \mathbf{x}_j 的欧式距离趋于无穷大，则两者的相似度将趋于0。因其简单、直观的特点，本文也将采用欧式距离来度量样本间的相似度。

常见的基于距离的模式识别算法有：基于“点”的算法：*k*-NN (*k*-Nearest Neighborhood) 算法^[145]、LVQ (Learning Vector Quantization) 算法^[146]；基于“线”或者“面”的经典算法：SVM (Support Vector Machine) 算法^[147]。

k-NN 算法分类原理如图 3-2 所示。*k*-NN 算法主要构造一个距离度量准则，为每一个测试样本寻找 *k* 个近邻，通常利用欧式距离来评判样本间的相似程度，相似度大的即为最近邻。如图 3-2 所示，基于统计法则，若 *k* = 3，测试样本应归为样本 1，若 *k* = 5，测试样本应归为样本 2。因此，*k*-NN 算法对 *k* 值敏感，且易受不平衡样本容量影响。

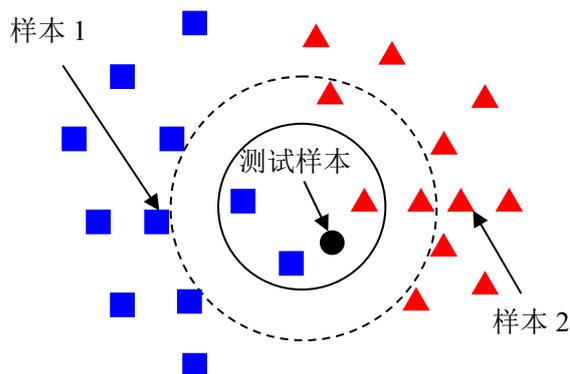


图 3-2 *k*-NN 算法分类原理

LVQ 网络结构如图 3-3 所示，由输入层，竞争层和输出层组成。算法的基本原理为：不同特征的输入样本输入网络后，通过距离公式来描述输入样本与竞争层神经元的相似度，从而在竞争层的二维平面上形成相应区域的获胜神经元群，分别反映与输入样本相似的特征。当未知样本输入时，根据其与竞争层不同神经元群的相似程度来实现模式识别。LVQ 网络结构简单，算法描述清晰，通过获胜神经元分布，直观地揭示样本的分布特性，是一种适用于模式识别的神经网络模型^[30]。

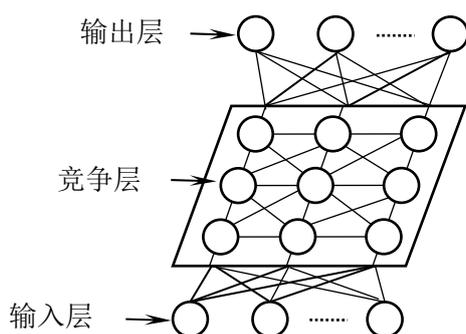


图 3-3 LVQ 算法的网络结构

SVM 是在统计学习理论上发展起来应用广泛的机器学习方法，以统计学习理论的 VC 维理论和结构风险最小化原则为基础，将学习训练过程转化为一个二次规划（Quadratic Programming）问题，有效克服了“维数灾难”，避免了局部最优，在解决小样本、非线性及高维模式识别问题中表现出了特有优势^[148]。其线性分类原理是：确定了一个分类平面来无误地分开两类样本，并且离分类平面最近的样本到分类平面的距离，即分类间隔，应是最大的，该分类平面被称为最优分类平面。对于非线性分类问题，则通过核函数将低维空间中线性不可分的样本映射到高维空间，转换为线性可分的样本，从而实现非线性分布的样本分类。其分类原理如图 3-4 所示。

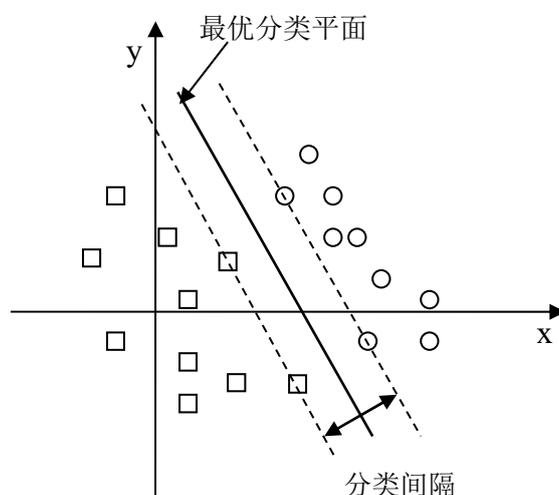


图 3-4 SVM 算法分类原理图

本文将提出一种直观、简单的基于单最优分类点的思路，所谓单最优分类点，是指通过样本的训练，为每一类样本确定一个分类点 c_i ，其中 $i = 1, 2, \dots, n_c$ ， n_c 表示样本的类别数，通过未知样本到最优分类点的距离来判断其所属类别，分类原理如图 3-5 所示。若未知样本到最优点 1 的距离较到最优点 2 的距离短，则当划属

样本 1 的类别，反之则当划属样本 2 的类别。基于单最优分类点的分类判别式如下所示：

$$CL(\mathbf{y}_j) = \left\langle i \mid dis_{ji} = \min \left(dis_{j1} \cdots dis_{ji} \cdots dis_{jn_c} \right) \right\rangle \quad (3-2)$$

其中： \mathbf{y}_i 表示未知样本， $CL(\cdot)$ 用于显示未知样本的类别标签（Class Label, CL）。

所以， \mathbf{y}_i 属于第 i 类，意味着 \mathbf{y}_i 到最优点 \mathbf{c}_i 的距离是最短的。

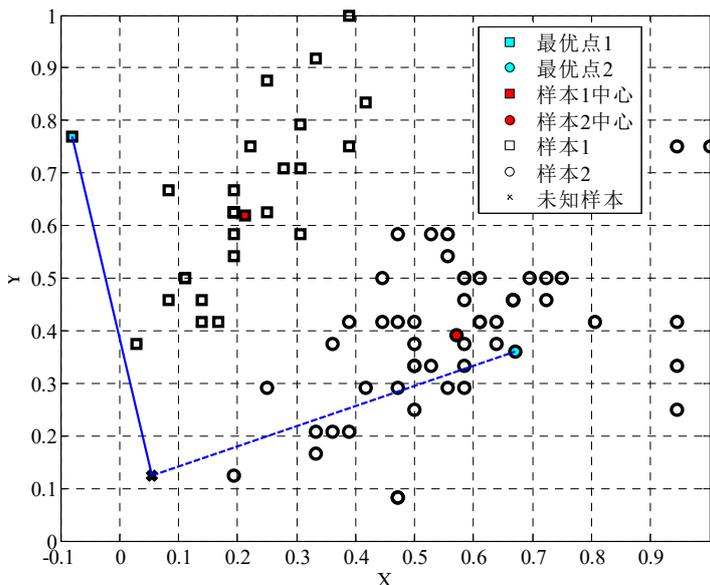


图 3-5 基于单优化点的分类原理

基于单最优分类点的方法，不同于 SVM，每次只能处理两类的分类问题，而可一次处理多类的分类问题。但关键是怎样确定一个合适的优化点来满足准确分开所有样本的要求，MELPSO 算法已被证明具有优良的寻优能力，能够处理高维的、复杂的、多参数的优化问题，能够为确定最优分类点提供有力的优化技术支持。

3.2 基于单最优分类点的故障模式识别原理

3.2.1 基于分类的适应度函数设计

在 PSO 算法中，对实际优化问题的数学描述，主要是依靠适应度函数来完成的，不同的适应度函数体现了不同的具体优化问题^[127]。通过 PSO 算法不断改变粒子位置，调整适应度函数值，从而实现对实际问题的优化。MELPSO 算法的优化体系已经设计完成，并已证明了其全局优化能力，关键是怎样来描述满足分类要求的最优分类点，从而实现对不同类别的模式识别。如前所述，基于单最优分类

点的分类原理，即为各类别数据分别寻找一个最优点，使得依靠到这些最优点欧式距离的长度来判别出未知样本所属类别。

为了使得最优分类点能够区分不同类别的样本，最优分类点应该满足自身间的最大可分性，即各最优分类点间的距离尽可能最大，这一距离被定义为类间距离 $dis_{inter-class}$ 。同时，各分类点应与所属样本具有较大的相似度，即各分类点与所属样本间的距离尽可能最小，而这一距离被定义为类内距离 $dis_{intra-class}$ 。文献[149]将最小化类内距离作为优化目标，实现分类点的寻优。而文献[150]又将最大化类间距离增为优化目标，从而实现了分类点的多目标寻优，其对未知样本的识别准确率也得到了明显提高。

除此之外，训练样本在确定最优分类点时也起着重要作用，对训练样本的识别准确率同样体现了最优分类点空间分布的合理性，因此，将对训练样本的识别准确率新增为一个优化目标，能够保证确定最优分类点的基本细节，提高对未知样本的识别准确率。因此，基于单最优分类点的寻优是一个三目标的优化问题，三目标表示如下：

$$\begin{cases} \max \text{fit}_1(\mathbf{p}_i) = n_{\text{trc}}/n_{\text{ts}} \\ \min \text{fit}_2(\mathbf{p}_i) = dis_{\text{intra-class}} \\ \max \text{fit}_3(\mathbf{p}_i) = dis_{\text{inter-class}} \end{cases} \quad (3-3)$$

式中， \mathbf{p}_i 表示第 i 个粒子， $\text{fit}_1(\cdot)$ 代表着对训练样本的识别准确率，而 n_{trc} 是被正确识别的样本数， n_{ts} 是训练样本总数； $\text{fit}_2(\cdot)$ 和 $\text{fit}_3(\cdot)$ 分别表示类内距离和类间距离。

n_{trc} 计算如下：

$$n_{\text{trc}} = \sum_{i=1}^{n_{\text{ts}}} \begin{cases} n_{\text{trc}} + 1, \left(\text{cl}(\mathbf{x}_i) = j \mid \min \left[\|\mathbf{x}_i - \mathbf{c}_j\|_2, j = 1, \dots, n_c \right] \right) \\ n_{\text{trc}} + 0, \text{otherwise} \end{cases} \quad (3-4)$$

而 $dis_{intra-class}$ 和 $dis_{inter-class}$ 计算如下：

$$dis_{\text{intra-class}} = \sum_{i=1}^{n_c} \sum_{j=1}^{ns_i} \sqrt{\sum_{d=1}^D (c_{id} - x_{jd})^2} \quad (3-5)$$

$$dis_{\text{inter-class}} = \sum_{i=1}^{n_c-1} \sum_{j=i+1}^{n_c} \sqrt{\sum_{d=1}^D (c_{id} - c_{jd})^2} \quad (3-6)$$

式中， ns_i 表示属于第 i 类的样本数量。

基于单最优分类点应满足尽可能大的训练样本识别准确率，较大的类间距离和较小的类内距离，增加了分类点的约束，提高了分类点的容错能力。同时，为

考虑避免计算的复杂性，降低计算开销，将三优化目标转化成单优化目标，既充分满足三个优化目标要求，又达到降低多目优化复杂性的目的。因此，基于 MELPSO 算法的单最优分类点适应度函数表示如下：

$$\text{fit}(\mathbf{p}_i) = \text{fit}_1(\mathbf{p}_i) + \frac{\text{fit}_3(\mathbf{p}_i)}{\text{fit}_2(\mathbf{p}_i)} \quad (3-7)$$

实质上，式(3-7)将多目标优化转换成了最大化单目标优化问题，综合考虑了样本类间距离最大、类内距离最小，以及训练样本分类准确率最高，为单最优分类点寻优提供了明确的指导， $\text{fit}(\mathbf{p}_i)$ 值越大，越能获得满足三个因素的最优分类中心。

基于 MELPSO 算法的单最优分类点寻优如下：

步骤 1：将训练样本和测试样本集归一化到[0, 1]区间，其必要性在于消除不同量纲的影响，降低粒子搜索空间，提高算法计算效率。

步骤 2：利用随机初始化的方式在整个解空间为粒子的位置和速度赋值，而粒子的位置代表着各类的分类点。而随机方式的优势在于可充分增加种群多样性。分类点 \mathbf{c}_i 的初始值可由下式完成：

$$\begin{cases} \mathbf{c}_i = [c_{i1}, c_{i2}, \dots, c_{ik}, \dots, c_{iD}] \\ c_{ik} = \text{unifrnd}(\min(x_{1k}, x_{2k}, \dots, x_{ns,k}), \max(x_{1k}, x_{2k}, \dots, x_{ns,k}), 1, 1) \end{cases} \quad (3-8)$$

式中：函数 $\text{unifrnd}(\alpha, \beta, a, b)$ 产生 a 行 b 列在 $[\alpha, \beta]$ 区间服从均匀分布的实矩阵。

步骤 3：按照 MELPSO 算法更新粒子的速度、位置，并计算粒子适应度值。

步骤 4：按照种群适应度值变化情况更新群体极值和个体极值。

步骤 5：检测是否达到寻优要求，若达到要求则退出迭代，输出最优分类中心；否则返回步骤 3。

3.2.2 算法性能验证及分析

为验证基于 MELPSO 的分类算法的分类性能，一些常用数据集将作为测试对象来评估算法的分类性能，而这些数据集均来自于 UCI (University of California Irvine) 数据库。数据集的相关信息显示于表 3-1 中，训练样本和测试样本均是随机确定。而且，一些经典的分类算法，如：SVM^[68]、BP (Back Propagation) 网络^[151]、LVQ 网络^[152]、基于期望最大化 (expectation maximization, EM) 算法和混合高斯 (mixture normal) 分布的贝叶斯 (Bayesian) 分类器^[153]、以及 k -NN 算法^[145]，将与基于 MELPSO 的分类算法进行性能比较，证明所设计分类原理的合理性和有效性。

表3-1 测试数据集信息表

名称	维数	类别	训练样本	测试样本
Wine	13	3	98 (34+38+26)	80 (25+33+22)
Indian Liver Patients (ILP)	10	2	213 (106+107)	120 (60+60)
Wisconsin Diagnostic Breast Cancer (WDBC)	9	2	503 (324+179)	180 (120+60)
Seeds	7	3	120 (40+40+40)	80 (30+30+30)
Haberman's Survival (HS)	3	2	121 (80+41)	105 (65+40)

因 PSO 算法是启发式群体随机搜索算法, 随机性是影响算法性能的主要因素, 因此导致最优解具有不确定性, 往往从不同空间方向趋近于最优区域。同时, BP 网络和 LVQ 网络连接权值的随机设定容易导致输出结果的不确定性, 此外, 利用文献[68]所提方法对 SVM 核参数进行优化, 以及基于 EM 的参数估计方法依然是存在不确定性的。为比较算法性能, 在相同运行环境下, 连续对各数据集做 50 次分类实验, 从而获得分类准确率的统计参数, 这些统计参数包括最小值、均值、最大值, 以及标准差, 利用统计特性来验证算法性能的优劣。 k -NN 算法对参数 k 敏感, 不同 k 取值会造成相差较大分类结果, 因此我们将验证不同 k 取值的影响。

MELPSO 算法参数设置如下: 种群数量设置为 60, 最大迭代数设置为 200, 导师粒子数设置为 5, 需要优化的参数个数为 $n_c \cdot D$ 。BP 和 LVQ 网络中间层神经元设置分别为: $n = \text{round}(\sqrt{D + n_c^2} + r_1)$ 和 $n = \text{round}((n_c - r_2)^2 \cdot n_c + D)$, 其中 r_1 和 r_2 分别为 [1, 10] 和 [0, n_c] 之间的随机数, $\text{round}(\cdot)$ 为四舍五入函数, 确保 n 为整数。特别地, BP 网络和 LVQ 网络的误差目标均设置为 0.001, 而迭代次数分别设置为 500 次和 200 次; 混合高斯分布数设置为 3, 误差目标为 10^{-6} , 而 EM 的迭代数设置为 3000。所有分类实验的结果统计如表 3-2 至表 3-6 所示。对于 k -NN 算法, 不再以统计结果来衡量算法性能, 而是仅列出当 $k = 1$ 时, 算法分类准确率, 以及使算法分类准确率最大时所对应的 k 取值。

尽管各算法的分类原理不尽相同, SVM 利用非线性分类超平面进行分类; BP 网络利用非线性映射关系确定数据和类别标签的关系; LVQ 网络依靠到获胜神经元的距离来判别未知数据状态; Bayesian 将训练样本的混合正态分布作为先验概率分布; k -NN 算法依靠距离, 但需要事先确定最邻近样本的数量。如表 3-2 至表 3-6 所示, 基于 MELPSO 算法的单最优分类点的分类性能相对于其它算法, 综合来看,

整体具有较高的分类准确率。这表明单最优分类点原理对不同维度、不同分布特性的数据集，具有良好的分类能力，适合于更多数据分布类型的识别；由于 MELPSO 算法优良的全局寻优性能，随机性对分类结果的影响是有限的。显然，基于 MELPSO 算法的单最优分类点能够为故障模式准确识别提供理论支撑。

表 3-2 对 Wine 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Wine	Single point	0.9625	0.9737	0.9875	0.0040
	BP	0.8625	0.9306	0.9875	0.0310
	LVQ	0.9000	0.9275	0.9500	0.0132
	SVM	0.9625	0.9748	0.9875	0.0031
	Bayesian	0.9625	0.9735	0.9875	0.0071
	k -NN	0.9625 ($k=1$)		0.9625 ($k=1$)	

表 3-3 对 ILP 的分类性能比较

数据集	算法	Min	Mean	Max	STD
ILP	Single point	0.6667	0.7100	0.7500	0.0232
	BP	0.2667	0.4165	0.5417	0.0621
	LVQ	0.5417	0.6700	0.7250	0.0451
	SVM	0.4250	0.4393	0.4583	0.0106
	Bayesian	0.4333	0.6051	0.7000	0.0531
	k -NN	0.5250 ($k=1$)		0.6750 ($k=34$)	

表 3-4 对 WDBC 的分类性能比较

数据集	算法	Min	Mean	Max	STD
WDBC	Single point	0.9611	0.9611	0.9611	0
	BP	0.8667	0.9214	0.9500	0.0157
	LVQ	0.9000	0.9181	0.9389	0.0114
	SVM	0.9611	0.9611	0.9611	0
	Bayesian	0.9444	0.9464	0.9611	0.0045
	k -NN	0.9556 ($k=1$)		0.9667 ($k=7$)	

表 3-5 对 Seeds 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Seeds	Single point	0.9556	0.9627	0.9778	0.0080
	BP	0.9333	0.9531	0.9667	0.0115
	LVQ	0.9444	0.9656	0.9778	0.0088
	SVM	0.9556	0.9556	0.9556	0
	Bayesian	0.9333	0.9484	0.9667	0.0118
	k -NN	0.9556 ($k=1$)		0.9778 ($k=4$)	

表 3-6 对 HS 的分类性能比较

数据集	算法	Min	Mean	Max	STD
HS	Single point	0.6667	0.6857	0.6952	0.0076
	BP	0.3238	0.5008	0.7048	0.1096
	LVQ	0.4381	0.5862	0.6857	0.0736
	SVM	0.3619	0.4426	0.4952	0.0517
	Bayesian	0.3333	0.5121	0.7046	0.1162
	k -NN	0.5333($k=1$)		0.6762 ($k=10$)	

3.3 基于自适应最优分类点的故障模式识别原理

3.3.1 单最优分类点的缺陷分析

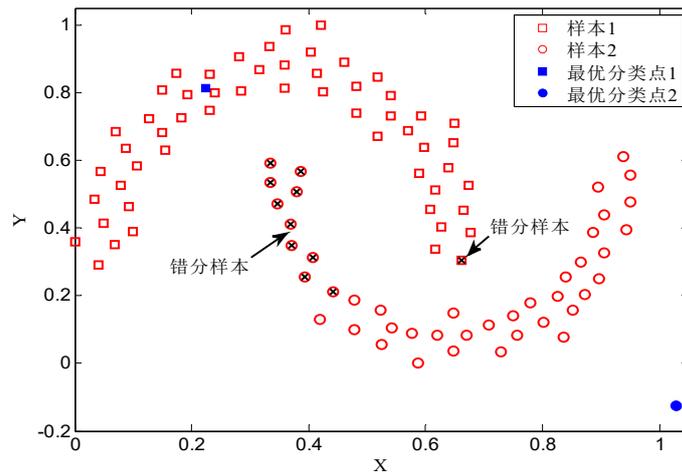
借助于 MELPSO 算法寻优的基于单最优分类点的识别原理，实质上是为每类样本寻找一个使式(3-7)获得最大值的分类点，而未知样本依靠到各个分类点的距离长短进行识别。然而，由于仅依靠到单个点的距离进行未知模式识别，对于一些数据集而言，找到一个合适的分类点来准确进行未知模式判别是存在困难的，或者说是不可行的。考虑到数据的可视化问题，将二维数据集作为示例来证明单最优分类点存在的问题。图 3-6 展示了 3 组二维数据集的空间分布情况，并演示了基于单最优分类点的识别效果。表 3-7 给出了 3 组数据集的相关信息。

尽管这 3 组数据集不同类别的样本之间存在相对较明显的空间间隔，正如图 3-6 所示，对这 3 组数据集而言，单最优分类点显然是存在缺陷的，仅依靠一个点几乎是不能实现对未知样本的准确判别。而这 3 组数据集存在相同的分布特点：具有明显的线性不可分性，因此，基于单最优分类点的识别原理几乎不能够处理

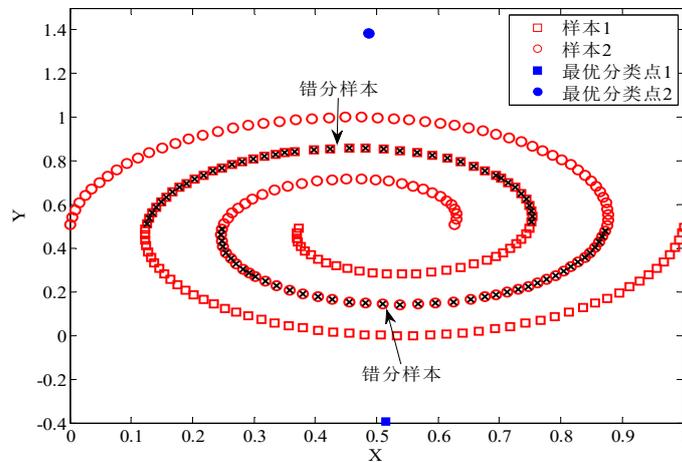
类似的具有线性不可分性的数据集。没有免费的午餐(No Free Lunch, NFL)定理已经证明：任何一种模式分类器都不可能对所有问题有效，总是存在一定程度上的分类器偏差^[154]。因此，算法识别原理已决定了算法适用范围，而基于单最优分类点的识别原理的缺陷在于不能够准确识别具有线性不可分性的数据集。这无疑限制了它的应用。

表3-7 二维数据集信息表

名称	维数	类别	训练样本	测试样本
Two moons	2	2	98 (55+43)	500 (333+167)
Spiral	2	2	244 (123+121)	314 (157+157)
Three circles	2	3	263 (77+88+98)	901 (150+251+500)



(a)



(b)

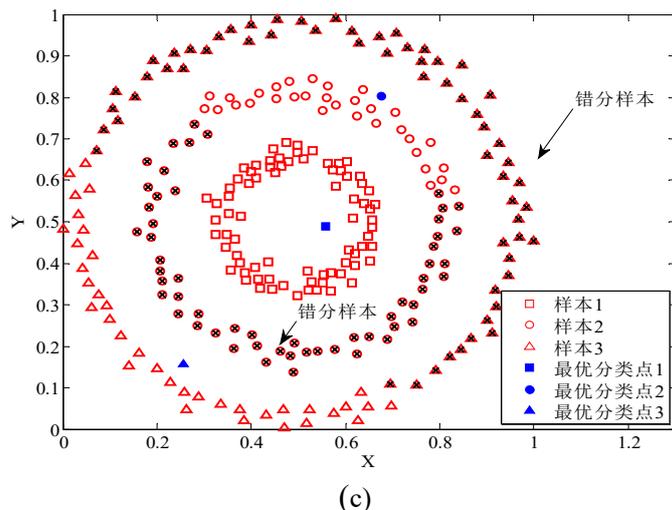


图 3-6 基于单最优分类点的数据识别演示。(a) “Two moons” 数据集识别演示图形；
(b) “Spiral” 数据集识别演示图形；(c) “Three circles” 数据集识别演示图形

针对基于单最优分类点的识别原理存在的缺陷，有必要对其实行进一步改进，从而拓展算法应用范围，增强故障模式识别能力。因此，将继续利用 MELPSO 算法的寻优性能，为数据集中各个类别寻优合适的最优分类点，而不是仅确定唯一的最优分类点，进而提出基于自适应最优分类点的改进识别原理，以提高对线性不可分数据的识别准确率。

3.3.2 自适应最优分类点的识别原理

为了克服上节所讨论的对具有线性不可分性数据的识别缺陷，在基于单最优分类点的基础上将提出一种新的识别原理，并重新设计算法的适应度函数和优化目标。新的识别原理依然是通过未知样本到最优点的距离长短来实现判别，但是不同之处在于：不再是为数据集中每一类别样本寻找单个最优点，最优点的数量是算法根据数据集分布特点自适应确定的，因此，这一识别原理是基于自适应最优分类点的。为了保证识别准确率，借助于 MELPSO 算法的寻优性能，需要优化三个目标，这是一个多目标优化问题，三个优化目标表示如下：

$$\begin{cases} \max \text{fit}_1(\mathbf{p}) = \frac{n_{\text{trc}}}{n_{\text{ts}}} \\ \min \text{fit}_2(\mathbf{p}) = n_{\text{toc}}, n_{\text{toc}} = \sum_{l=1}^{n_c} n_{\text{oc}}(l) \\ \max \text{fit}_3(\mathbf{p}) = \frac{\text{dis}_{\text{inter-points}} + \text{dis}_{\text{intra-points}}}{\text{dis}_{\text{samples-points}}} \end{cases} \quad (3-9)$$

式中： $\text{fit}_1(\cdot)$ 代表着对训练样本的识别准确率，与之前描述是一致的，而 n_{trc} 计算如下：

$$n_{\text{trc}} = \sum_{i=1}^{n_s} \begin{cases} n_{\text{trc}} + 1, & \left(\text{cl}(\mathbf{x}_i) = j \mid \min \begin{cases} \|\mathbf{x}_i - \mathbf{c}_j\|_2 + \varepsilon, \exists \text{cl}(\mathbf{x}_i) = j \\ \|\mathbf{x}_i - \mathbf{c}_j\|_2, \exists \text{cl}(\mathbf{x}_i) \neq j \end{cases}, j = 1, \dots, n_c \right) \\ n_{\text{trc}} + 0, & \text{otherwise} \end{cases} \quad (3-10)$$

对训练样本而言，若与最优分类点的类别一致，则加一个容错系数 ε ，在训练过程中设计容错系数的目的是：保证在相对较大的距离上识别训练样本，从而为未知样本识别提供一定距离裕度。由于数据都被归一化到 $[0, 1]$ 区间，因此 ε 设置为较小的数，一般在 $[0, 0.01]$ 区间； n_{toc} 是最优分类点数量， $n_{\text{oc}}(l)$ 表示属于第 l 类的最优分类点个数，而 $l=1, \dots, n_c$ ； $\text{fit}_3(\mathbf{p})$ 显示了最优分类点和训练样本间的距离关系，类间距离 $dis_{\text{inter-points}}$ 则表示不同类别间最优分类点间的距离，类内距离 $dis_{\text{intra-points}}$ 则表示属于相同类别的最优分类点间的距离，样本-点距离 $dis_{\text{samples-points}}$ 表示同类别的训练样本到同类别的最优分类点间的距离。显然， $dis_{\text{inter-points}}$ 的定义类似于单最优点的 $dis_{\text{inter-class}}$ ， $dis_{\text{samples-points}}$ 的定义类似于单最优点的 $dis_{\text{intra-class}}$ ，而 $dis_{\text{intra-points}}$ 是自适应最优点独有的距离。因此，对于自适应最优点而言， $\text{fit}_3(\mathbf{p})$ 描述的是这样一种约束：不同类别的最优点应尽可能散开，表现出不同类别间的差异性；同一类别的最优分类点也要尽可能分散，避免最优分类点作用域间相互重叠；而同一类的样本和最优分类点的距离应尽可能小，从而体现出最优分类点和样本间的相似性。因此， $\text{fit}_3(\mathbf{p})$ 不仅保持了所有最优分类点间的差异性，同时也维持了训练样本的可辨识性，为模式识别提供了准确而清晰的指导。

正是这三种距离间的相互制约，保障了最优分类点的容错能力，三种距离的计算公式如下：

$$dis_{\text{inter-points}} = \sum_{l=1}^{n_c-1} \sum_{k=l+1}^{n_c} \left(\left\| \text{mean}(\mathbf{c}_{l_i}) - \text{mean}(\mathbf{c}_{k_j}) \right\|_2 \mid i = 1, 2, \dots, n_{\text{oc}}(l), j = 1, 2, \dots, n_{\text{oc}}(k) \right) \quad (3-11)$$

$$dis_{\text{intra-points}} = \sum_{l=1}^{n_c} \left(\min \left\{ \left\| \mathbf{c}_{l_i} - \mathbf{c}_{l_j} \right\|_2 \mid i = 1, 2, \dots, n_{\text{oc}}(l) - 1, j = i + 1, \dots, n_{\text{oc}}(l) \right\} \right) \quad (3-12)$$

$$dis_{\text{samples-points}} = \sum_{i=1}^{n_s} \left(\min \left[\left\| \mathbf{x}_i - \mathbf{c}_{l_j} \right\|_2 \mid j = 1, 2, \dots, n_{\text{oc}}(l), \text{cl}(\mathbf{x}_i) = l \right] \right) \quad (3-13)$$

式中， \mathbf{c}_{l_j} 表示属于第 l 类的第 j 个最优分类点。因此，这样的三目标优化问题，满足了最大化的识别准确率、最小化的最优分类点数量、以及最大化的距离关系。

对多目标优化问题的求解是一个关键环节，现较为流行的求解方法是基于非劣解（Noninferior Solution）的，基本思想是求得多目标问题的非劣解集，然后在非劣解集中进行协调和选择，确定出最优解^[155]。而在本研究中，专门针对 PSO 算法迭代寻优的特点，提出一种定性优先级的概念，优先级仅有“高”和“低”两种定性描述，即根据问题求解的实际需求，确定各个目标的优先级，优先级高的目标首先被满足，余下的目标再逐次被满足。为了方便描述最优化当中的最大化 and 最小化，定义两种符号：“ \succ ”表示“优于”，“ \preccurlyeq ”表示“不劣于”。

设有 m 个目标， $F(\mathbf{p}) = [\text{fit}_1(\mathbf{p}), \text{fit}_2(\mathbf{p}), \dots, \text{fit}_m(\mathbf{p})]$ ， \mathbf{p} 是一个粒子，也是问题的可行解， $P(\cdot)$ 表示单目标的优先级，若存在 $P(\text{fit}_1(\mathbf{p})) \succ P(\text{fit}_2(\mathbf{p})) \succ \dots \succ P(\text{fit}_m(\mathbf{p}))$ ，则个体极值 \mathbf{p}_{id} 和群体极值 \mathbf{p}_{gd} 按如下 m 个条件进行更新：

$$\left\{ \begin{array}{l} 1. \left\{ \begin{array}{l} \text{fit}_1(\mathbf{p}) \succ \text{fit}_1(\mathbf{p}_{id}) \\ \text{fit}_1(\mathbf{p}) \succ \text{fit}_1(\mathbf{p}_{gd}) \end{array} \right. \\ \vdots \\ m. \left\{ \begin{array}{l} \text{fit}_1(\mathbf{p}) \preccurlyeq \text{fit}_1(\mathbf{p}_{id}) \text{ and } \dots \text{ and } \text{fit}_{m-1}(\mathbf{p}) \preccurlyeq \text{fit}_{m-1}(\mathbf{p}_{id}) \text{ and } \text{fit}_m(\mathbf{p}) \succ \text{fit}_m(\mathbf{p}_{id}) \\ \text{fit}_1(\mathbf{p}) \preccurlyeq \text{fit}_1(\mathbf{p}_{gd}) \text{ and } \dots \text{ and } \text{fit}_{m-1}(\mathbf{p}) \preccurlyeq \text{fit}_{m-1}(\mathbf{p}_{gd}) \text{ and } \text{fit}_m(\mathbf{p}) \succ \text{fit}_m(\mathbf{p}_{gd}) \end{array} \right. \end{array} \right. \quad (3-14)$$

如果其中任意一条件满足，则令 $\mathbf{p}_{id} = \mathbf{p}$ ， $\mathbf{p}_{gd} = \mathbf{p}$ ，从而实现极值更新。对于自适应最优分类点而言，三个优化目标的优先级为： $P(\text{fit}_1(\mathbf{p})) \succ P(\text{fit}_2(\mathbf{p})) \succ P(\text{fit}_3(\mathbf{p}))$ ，根据式(3-14)，个体极值和群体极值按如下条件更新：

$$\left\{ \begin{array}{l} 1. \left\{ \begin{array}{l} \text{fit}_1(\mathbf{p}) \succ \text{fit}_1(\mathbf{p}_{id}) \\ \text{fit}_1(\mathbf{p}) \succ \text{fit}_1(\mathbf{p}_{gd}) \end{array} \right. \\ 2. \left\{ \begin{array}{l} \text{fit}_1(\mathbf{p}) \geq \text{fit}_1(\mathbf{p}_{id}) \text{ and } \text{fit}_2(\mathbf{p}) < \text{fit}_2(\mathbf{p}_{id}) \\ \text{fit}_1(\mathbf{p}) \geq \text{fit}_1(\mathbf{p}_{gd}) \text{ and } \text{fit}_2(\mathbf{p}) < \text{fit}_2(\mathbf{p}_{gd}) \end{array} \right. \\ 3. \left\{ \begin{array}{l} \text{fit}_1(\mathbf{p}) \geq \text{fit}_1(\mathbf{p}_{id}) \text{ and } \text{fit}_2(\mathbf{p}) \leq \text{fit}_2(\mathbf{p}_{id}) \text{ and } \text{fit}_3(\mathbf{p}) \succ \text{fit}_3(\mathbf{p}_{id}) \\ \text{fit}_1(\mathbf{p}) \geq \text{fit}_1(\mathbf{p}_{gd}) \text{ and } \text{fit}_2(\mathbf{p}) \leq \text{fit}_2(\mathbf{p}_{gd}) \text{ and } \text{fit}_3(\mathbf{p}) \succ \text{fit}_3(\mathbf{p}_{gd}) \end{array} \right. \end{array} \right. \quad (3-15)$$

因此，根据优先度的概念，这些优化目标可按照适当的顺序被依次满足，从而依照问题的主次程度进行针对性优化。特别地，这一策略保证了最大化识别准确率被首先满足，最小化的最优分类点数量在识别准确率度不降低的前提下进行自适应地确定，最后，在前两个目标不劣化的前提下，最大化距离关系也得到相

应优化。

对于不同特征的数据集，由于最优分类点是自适应确定的，若所有的 $n_{oc}(l)$ 都等于 1，则自适应最优分类点又转变成为单最优分类点，因此自适应最优分类点将继续保持单最优分类点的识别优势。另一方面，若任意的 $n_{oc}(l)$ 不等于 1，意味着某些类别拥有多最优分类点，而多最优分类点的优势将有助于准确识别此类数据集。因此，基于自适应最优分类点的识别原理拓展了算法应用范围，使得更多的数据集能被准确识别。

同样为了验证基于自适应最优分类点的识别能力，证明其分类性能是对单最优分类点的继承和拓展，而表 3-1 和表 3-7 的数据集将共同用来比较自适应最优分类点和 3.2.2 节所引用部分算法的识别性能，各算法参数设置如 3.2.2 节所示，需要新设置的参数为初始化最优分类点个数，根据各数据集特点，初始化最优分类点个数如表 3-16 所示。同样在相同运行环境下连续计算 50 次来获得最小值、均值、最大和标准差这四种统计参数，综合反映各算法性能优劣。比较结果如表 3-8 至表 3-15 所示。

表 3-8 对 Two moons 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Two moons	Adaptive points	1	1	1	0
	Single point	0.8360	0.8372	0.8480	0.0038
	BP	1	1	1	0
	LVQ	0.9940	0.9956	0.9980	0.0010
	SVM	1	1	1	0
	Bayesian	0.8700	0.9545	0.9800	0.0343

表 3-9 对 Spiral 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Spiral	Adaptive points	0.9936	0.9994	1	0.0020
	Single point	0.6656	0.6656	0.6656	0
	BP	1	1	1	0
	LVQ	0.6401	0.5460	0.6783	0.0080
	SVM	1	1	1	0
	Bayesian	0.6178	0.7065	0.7580	0.0303

表 3-10 对 Three circles 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Three circles	Adaptive points	0.9967	0.9990	1	0.0011
	Single point	0.3807	0.4744	0.6570	0.0983
	BP	0.9922	0.9922	1	0.0025
	LVQ	0.6426	0.6925	0.7758	0.0370
	SVM	1	1	1	0
	Bayesian	0.7980	0.9095	0.9767	0.0471

表 3-11 对 Wine 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Wine	Adaptive points	0.9625	0.9772	1	0.0091
	Single point	0.9625	0.9737	0.9875	0.0040

表 3-12 对 ILP 的分类性能比较

数据集	算法	Min	Mean	Max	STD
ILP	Adaptive points	0.6833	0.7165	0.7583	0.0171
	Single point	0.6667	0.7100	0.7500	0.0232

表 3-13 对 WDBC 的分类性能比较

数据集	算法	Min	Mean	Max	STD
WDBC	Adaptive points	0.9611	0.9611	0.9611	0
	Single point	0.9611	0.9611	0.9611	0

表 3-14 对 Seeds 的分类性能比较

数据集	算法	Min	Mean	Max	STD
Seeds	Adaptive points	0.9556	0.9683	0.9778	0.0065
	Single point	0.9556	0.9627	0.9778	0.0080

表 3-15 对 HS 的分类性能比较

数据集	算法	Min	Mean	Max	STD
HS	Adaptive points	0.6762	0.6853	0.6952	0.0040
	Single point	0.6667	0.6857	0.6952	0.0076

如表 3-8 至表 3-15 所示，根据对不同数据集的识别结果可以得出如下结论：

(1) 对于 **Two moons**, **Spiral** 和 **Three circles**, 自适应最优分类点的识别准确率明显优于单最优分类点；而同其它算法相比较，自适应最优分类点的识别性能要稍弱于 **SVM**, 而基本等同于或优于 **BP 网络**、**LVQ 网络**和 **Bayes** 分类器。

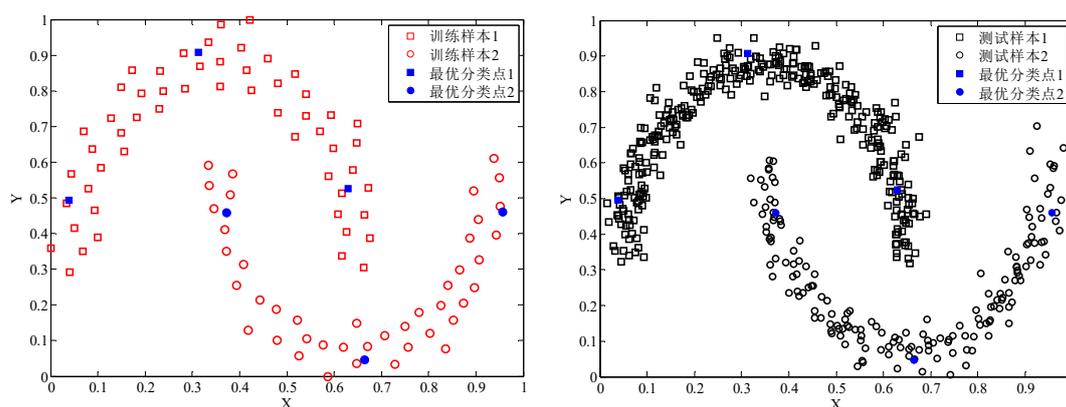
(2) 而对于其它数据集，自适应最优分类点的识别性能基本上与单最优分类点相同，甚至是更优。其它算法因识别原理的差异性，使他们只对其中的一些数据集有较好的识别准确率，但是基于最优分类点的分类算法对所列所有数据集都是有效的。

毫无疑问，基于自适应最优分类点的识别原理保留了单最优分类点分类原理的优势，而且，它进一步扩展了适用范围，使得能够对具有线性不可分的数据集起到良好的识别效果。实质上，造成表 3-8 至表 3-15 中识别准确率差异的主要原因还是在于不同算法的识别原理有各自的侧重，使其只能处理某一类特定的数据集。如前所述，**SVM** 利用基于核函数的非线性分类超平面；**BP 网络**利用传递函数的非线性映射关系；**LVQ 网络**利用到获胜神经元的距离；而 **Bayesian** 分类器将训练样本的混合正态分布作为先验概率分布。对于具有明显类间间隔的数据，**SVM** 和 **BP 网络**都能容易地进行识别，所以对于 **Two moons**, **Spiral** 和 **Three circles**, 它们都有较高的准确率。但是，不能否认神经网络的性能容易受到网络结构和随机权重设置的影响^[156]。尽管理论上混合高斯分布能够用来描述未知概率密度的分布，但实际上 **Bayesian** 分类器很难处理好具有复杂分布特性的数据，它更适合处理具有高斯分布的数据集，所以它依然对数据的概率分布敏感。与单最优分类点类似，**LVQ** 也不适合用来处理具有明显非线性间隔的数据集，另一方面，这些基于距离的识别原理更适合于处理具有不规则空间分布的数据集，所以对于 **ILP**, 它们都具有相对较好的性能。总之，表 3-8 至表 3-15 的结果证明了基于自适应最优分类点的识别原理对不同分布特征的数据集具有良好的识别能力，而且随机性也几乎没有对算法性能造成影响，算法保持了良好的计算稳定性。显然，自适应最优分类点进一步为故障模式识别提供了更为有利的技术支撑。同时，表 3-16 记录了 8 个数据集在 50 次实验中最优分类点数量变化的统计，统计结果表明：算法能够根据不同数据特点，自适应调整最优分类点数量，确保最大识别准确率的能力。

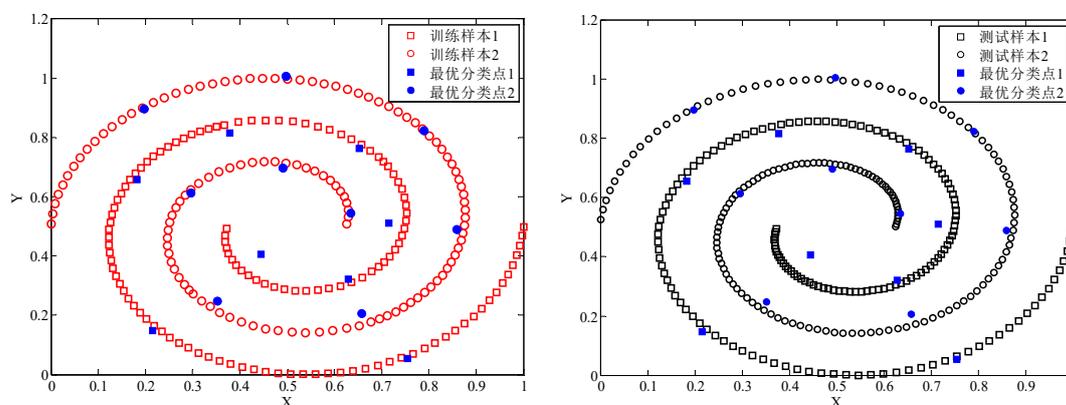
表 3-16 各测试数据集最优分类点数量变化统计

数据集	类别	初始最优解	最优分类点统计			
			Max	Mean	Min	STD
Two moons	2	$2 \times 15 = 30$	6	6	6	0
Spiral	2	$2 \times 15 = 30$	25	23	20	1.5
Three circles	3	$3 \times 15 = 45$	26	22.5	18	2.0286
Wine	3	$3 \times 15 = 45$	7	4.9778	3	1.0551
ILP	2	$2 \times 15 = 30$	2	2	2	0
WDBC	2	$2 \times 15 = 30$	2	2	2	0
Seeds	3	$3 \times 15 = 45$	3	3	3	0
HS	2	$2 \times 15 = 30$	2	2	2	0

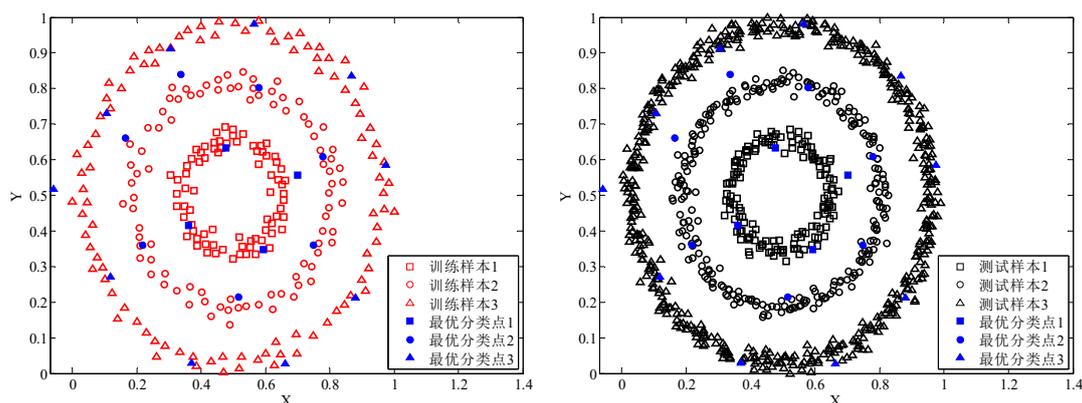
对于三个 2 维非线性分布的数据集而言，图 3-7 直观的给出了基于自适应最优分类点的识别效果，与图 3-6 的识别效果相比较，根据数据集本身分布特性，在保障分类准确率的基础上，自适应地确定最优分类点数量，证明了基于自适应最优分类点的识别原理的有效性和实用性。



(a)



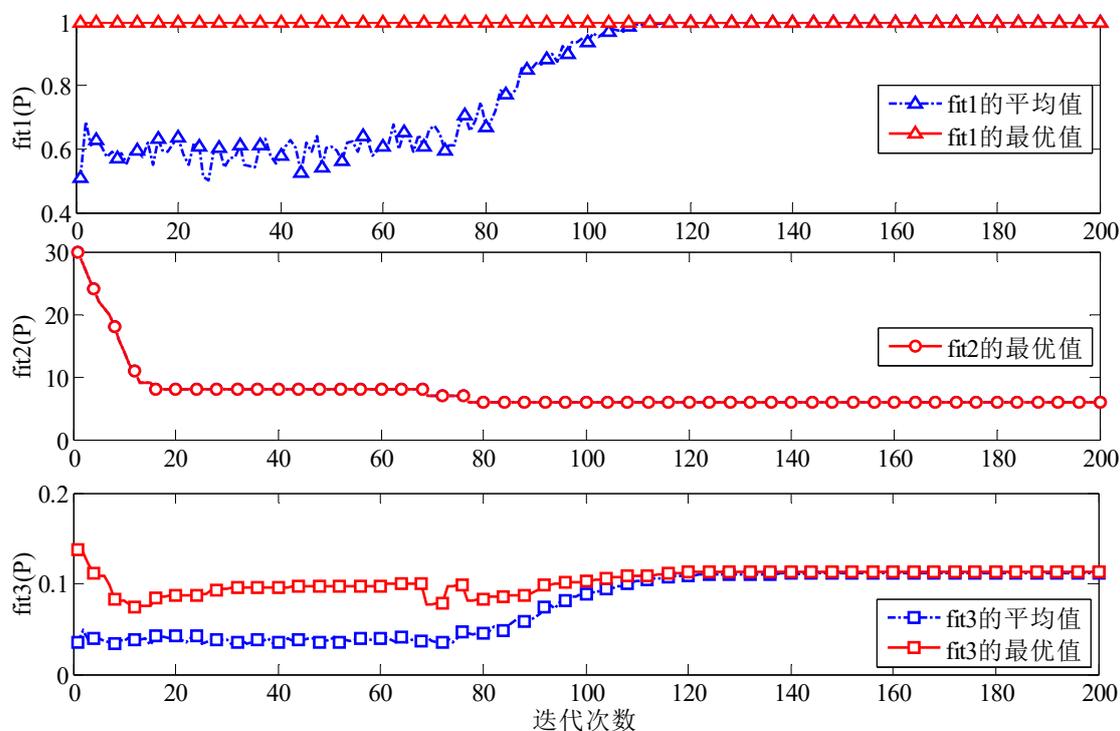
(b)



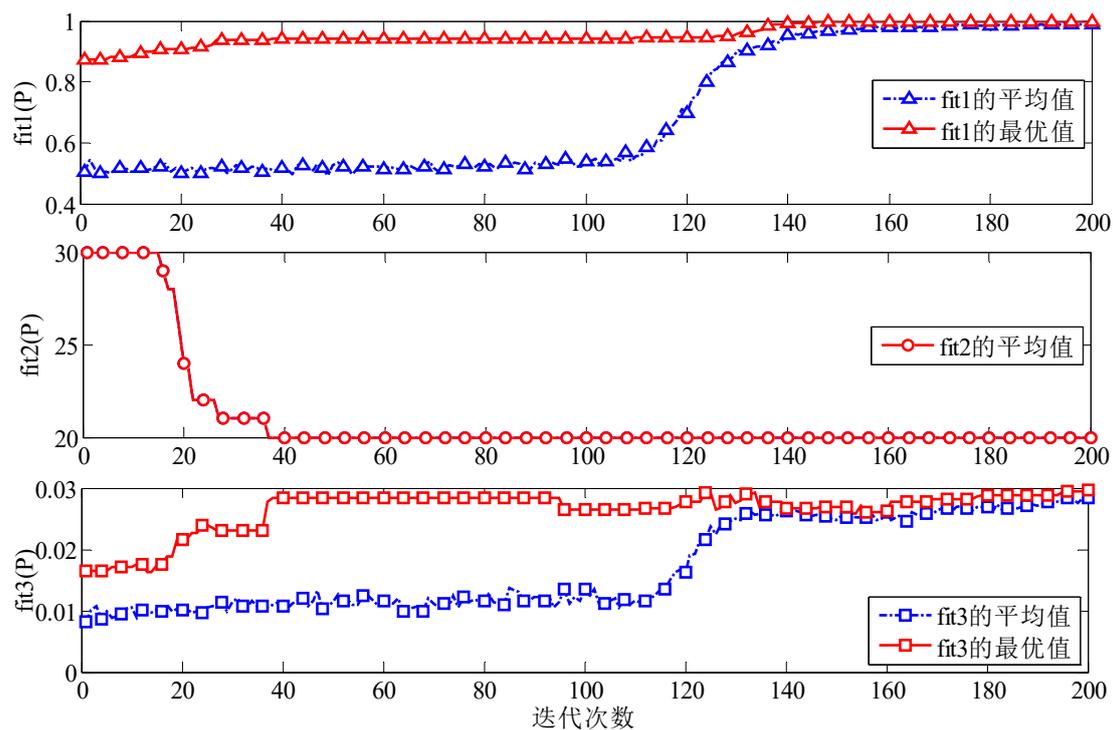
(c)

图 3-7 基于自适应最优分类点的识别效果。(a) “Two moons” 数据集的识别效果图；
(b) “Spiral” 数据集的识别效果图；(c) “Three circles” 数据集的识别效果图

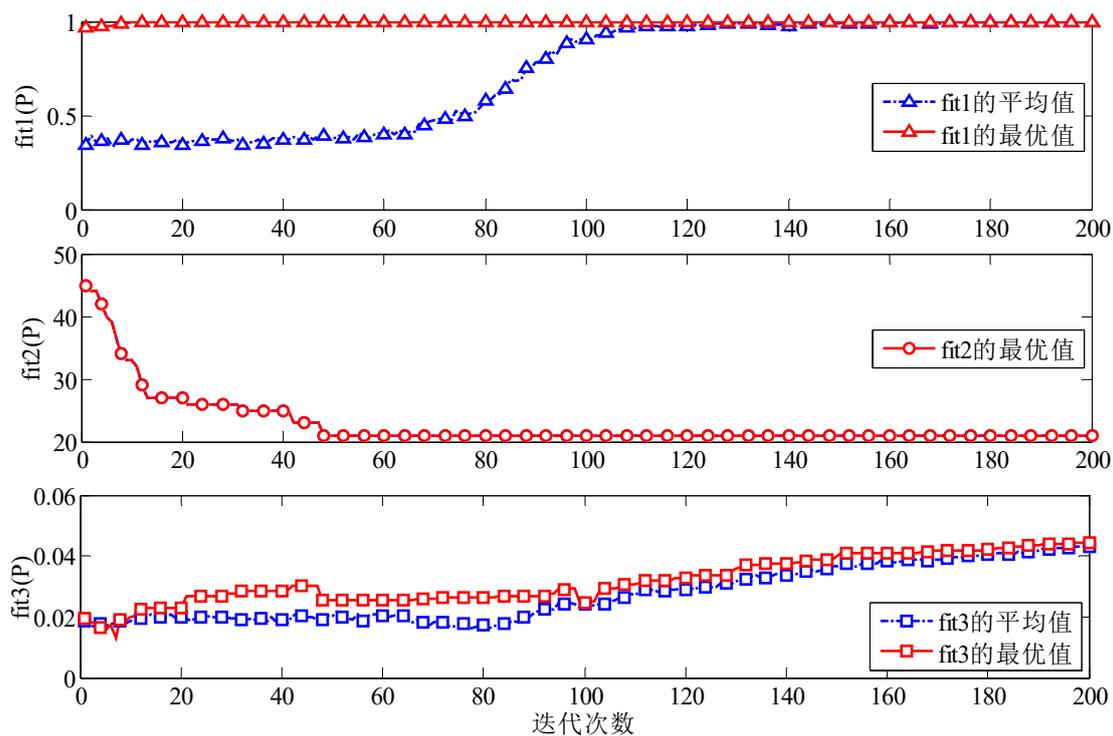
另外,对同样的三个数据集,图 3-8 给出了三个目标函数的适应度值变化曲线。如图 3-8 所示:三个适应度值的变化趋势完全按照设计的优化方式进行更新,有效地反映了本文所设计的基于优先度的多目标优化方法的合理性,每个优化目标按照预先设定的优先度依次被满足,从而实现了在优先保证识别准确率的前提下,进而满足最优分类点数量及分布情况的合理性,为线性不可分数据的识别提供了新的途径。



(a)



(b)



(c)

图 3-8 基于优先级的适应度曲线变化趋势。(a) “Two moons” 的适应度值变化曲线；
(b) “Spiral” 的适应度值变化曲线；(c) “Three circles” 的适应度值变化曲线

3.4 故障模式识别应用及分析

3.4.1 在轴承故障识别中的应用

滚动轴承作为连接电机固定和旋转端的关键部件，其故障发生容易引起重大事故，甚至是不可接受的长期的维修停机^[157]。因此，准确识别轴承运行过程中的未知故障模式，对确保工业生产安全，降低经济损失具有重要意义。这一节将根据轴承运行的振动信号提取时域和频域关键特征，形成相应的轴承运行状态数据库，再利用基于 MELPSO 的故障模式识别方法进行轴承故障诊断，准确判断故障原因，及时进行针对性维修，降低故障损耗。

振动信号数据使用 Case Western Reserve University (CWRU) 的轴承数据中心的数据^[158]。振动信号由如图 3-9 所示的测试平台测量，该测试平台由一个 2 马力的电机，转矩传感器和测功装置所组成，而实验轴承由瑞典 SKF (Svenska Kullager Fabriken) 轴承公司生产，并支撑电机主轴。对于驱动端轴承，使用电火花加工工艺，产生单点故障，分别为具有 0.007 和 0.021 英寸缺陷的外圈故障，具有 0.007 和 0.021 英寸缺陷的内圈故障，以及具有 0.007 和 0.021 英寸缺陷的滚动体故障。通过加速度计来测量振动信号，分别测量正常驱动端轴承和 6 种故障轴承的振动信号，每秒采集 12000 个振动数据。因此，共有包括 1 种正常工况和 6 种故障状态的 7 种驱动端轴承振动状态数据。每一原始时域信号被划分成 100 个子信号。

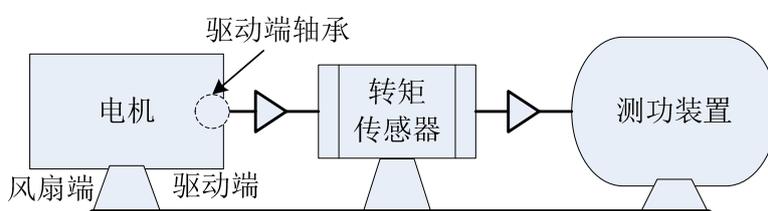


图 3-9 实验装置示意图

根据信号处理方法，分别提取信号的时域和频域典型特征。包括 4 个时域特征：均值(Mean)、均方根(Root Mean Square)、裕度(Clearance Factor)、峭度(Kurtosis Factor)。实质上，均值描述了信号的静态特性；均方根反映了信号的振幅特性，而且均方根对早期故障不敏感，但是具有良好的稳定性；裕度和峭度都是无量纲的统计参数，尽管稳定性较差，但它们对早期故障敏感。基于各个特征所反映的信号特点，选择这 4 个时域特征，其计算公式如下：

$$\text{Mean}(s_t) = \frac{1}{n_t} \sum_{i=1}^{n_t} s_i \quad (3-16)$$

$$\text{Rms}(s_t) = \sqrt{\frac{1}{n_t} \sum_{i=1}^{n_t} (s_i)^2} \quad (3-17)$$

$$C_f(s_t) = \frac{\max(s_t)}{\left(\frac{1}{n_t} \sum_{i=1}^{n_t} \sqrt{|s_i|}\right)^2} \quad (3-18)$$

$$K_f(s_t) = \frac{\frac{1}{n_t} \sum_{i=1}^{n_t} s_i^4}{(\text{Rms}(s_t))^4} \quad (3-19)$$

式中： s_t 是原始的时域信号； n_t 是信号的数据点数量； s_i 表示信号 s_t 的第 i 个数据点； $\max(s_t)$ 是用来获取 s_t 最大值的函数。

对原始时域信号 s_t 进行快速傅里叶变换，选择 3 个频域特征，其计算公式为：

$$F_1 = \frac{1}{n_f} \sum_{i=1}^{n_f} s_i \quad (3-20)$$

$$F_2 = \frac{1}{n_f} \sum_{i=1}^{n_f} (s_i - F_1)^2 \quad (3-21)$$

$$F_3 = \frac{1}{n_f \cdot \sqrt{F_2}} \sum_{i=1}^{n_f} (s_i - F_1)^3 \quad (3-22)$$

式中： s_f 是经变换后的频域信号； n_f 是谱线总数。 F_1 表示在频域振动能量的大小； F_2 是偏差，反映了频谱的分散和集中情况；而 F_3 同样反映了频谱的分散和集中。表 3-17 显示了 7 类轴承振动状态数据的分布情况。每类数据随机选择 60%作为训练样本，余下的 40%作为测试样本。

表 3-17 轴承振动状态数据

训练样本数量	测试样本数量	缺陷大小 (英寸)	运行状态	类别标签
60	40		正常	1
60	40	0.007	外圈	2
60	40	0.021	外圈	3
60	40	0.007	内圈	4
60	40	0.021	内圈	5
60	40	0.007	滚动体	6
60	40	0.021	滚动体	7

利用时域的 $Rms(s_t)$, $Cf(s_t)$, $kf(s_t)$, 以及频域的 F_1 , F_2 , F_3 , 分别表示出轴承振动状态的 3 维数据分布, 如图 3-10 所示。图 3-10 表明振动状态数据具有较好的可分性, 此外, 也表明了本文所选择的时频域特征有助于故障模式识别。

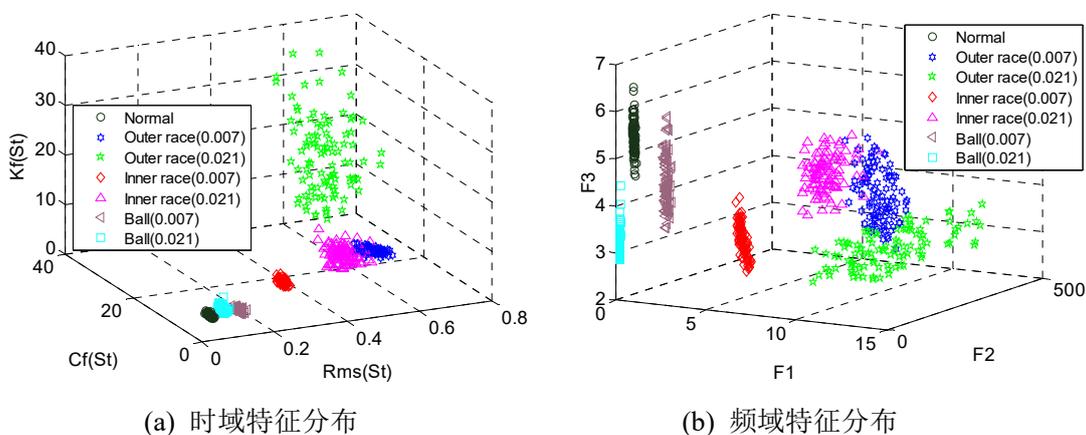


图 3-10 轴承振动状态数据分布。(a) 时域特征分布; (b) 频域特征分布

利用前述的算法, 包括基于 MELPSO 寻优的单最优点和自适应最优点识别方法, BP 网络^[151]和 LVQ 网络^[152], SVM^[68]及 Bayesian 算法^[153], 对轴承的振动状态进行识别, 从而判定轴承的故障类型, 所有算法设置如如 3.2.2 节所示, 通过对未知状态识别准确率的比较, 验证算法性能优劣。比较结果如表 3-18 所示, MELPSO 算法稳定的、可靠的全局收敛能力, 使得本文所提算法具有更小的标准差, 确保了分类点具有最佳的空间位置, 提高了对轴承未知振动状态的识别准确率, 保证了算法在故障模式识别方面的有效性和实用性, 故障模式识别性能符合工程实践应用要求。

表 3-18 对轴承振动状态识别的比较

算法	Min	Mean	Max	STD
Adaptive points	0.9929	0.9968	1	0.0019
Single point	0.9929	0.9974	1	0.0020
BP	0.9750	0.9867	1	0.0060
LVQ	0.8250	0.8454	0.8571	0.0086
SVM	0.9821	0.9981	1	0.0044
Bayesian	0.9429	0.9665	0.9821	0.0085

3.4.2 在航空发动机小样本故障状态识别中的应用

航空发动机是保障飞行安全的最关键部件，同时也是复杂的、精密的工业机器。对航空发动机进行合理、高效的故障诊断，既是保障飞行安全的关键环节，也是航空公司机队运行管理中的重要课题。而航空发动机的故障模式特征，不仅是各子系统共同运行状态的体现，也是运行环境、机械性能等多项指标的综合反映，所以航空发动机的故障模式与监控参数间的关系可由下式进行表征：

$$y_{fm} = f(\mathbf{m}) \quad (3-23)$$

式中： \mathbf{m} 为监控指标向量，而 $f(\cdot)$ 是由监控指标到故障模式（Fault Mode）间的映射， y_{fm} 是航空发动机的具体故障模式。正因为航空发动机运行过程的高度非线性、运行机理的高度复杂性，以及各子系统、运行环境间的高度耦合性，确定一个可以用来表征监控指标与具体故障模式间关系的具有解析形式的映射函数，几乎是一件很难完成的任务。因此，各发动机厂商在具体生产实践中，都发展了适用的状态监控和健康诊断系统，主要通过对气路性能参数的偏差分析，以确定发动机核心部件的性能状态，从而为维修决策与故障诊断提供参考^[159]。而随着先进传感器技术的快速发展，通过对航空发动机关键系统、重要参数、运行环境等的监测、分析，结合地面实际诊断结果，构建发动机故障模式数据库，已成为了发动机故障诊断新的发展方向，对快速、准确判别故障模式、定位故障位置提供了有效的参考。高效、准确的模式识别算法恰好为这一发展方向奠定了坚实的基础，使得通过数据分析来确定发动机故障模式成为可能，而本章所提出的基于单最优分类点和自适应最优分类点的模式识别算法，为航空发动机故障诊断提供了新的途径。

民航发动机在运行过程中，主要通过实际发动机排气温度（Exhaust Gas Temperature, EGT）偏差，燃油流量（Fuel Flow, FF）偏差，以及高/低压转子转速（High / Low Pressure Rotors Speed, N2/N1）偏差的监控，来判断发动机的运行状态。当发动机状态存在异常时，会引起相应监控参数变化趋势的异常改变，通过分析、对比典型的参数偏差量图，从而确定引起异常的部件，为进一步排故指明方向^[159]。以某型发动机某一次因空气流量引气控制活门故障而引起的引气异常为研究对象，通过收集、整理、分析真实的飞行监控数据，综合考虑该发动机对运行环境、性能参数的监控，构造一个判别该故障模式的故障数据库。该数据库的监控指标向量包含马赫数（Mach, M），气压高度（Pressure Altitude, PA），外界总温（Outside Air Temperature, OAT），油门杆角度（Throttle Lever Angle, TLA），FF, EGT, N1, N2, 压气机排气温度（Compressor Delivery Temperature, T2），压气机出口压力（Compressor Delivery Pressure, P2），共 10 个指标。发动机共有

两种状态：正常运行状态和引气活门故障状态，分别用“0”和“1”表示。鉴于航空发动机故障数据的有限性，随机选择 19 个样本作为训练样本，其中 11 个样本为正常样本，8 个样本为故障样本，剩余的 17 个样本作为测试样本来验证各算法的性能，13 个样本为正常样本，而 4 个样本为故障样本。显然，由于样本数量的限制，样本在空间分布必然呈稀疏性，所提供的信息更加有限，因而对算法性能提出了更高的要求，更能检验算法的分类能力。部分数据如表 3-19 所示。

表 3-19 某型航空发动机状态信息表

	M	PA (fleet)	OAT (°C)	TLA (°)	FF (lb/h)	N1 (%)	N2 (%)	EGT (°C)	T2 (°C)	P2 (psia)	D
训练 样本	0.746	34082	-25.1	64.9	1200	85.82	91.69	712	4	7.8	1
	0.726	26578	-6.1	67.7	1568	86.62	94.24	736	23.7	10.5	1
	⋮										
	0.744	34094	-11.8	68.1	1300	88.71	94.7	787	19.7	7.8	2
	0.739	31078	-3.2	75.2	1448	89.13	95.73	795	28.6	8.8	2
测试 样本	0.746	27584	1.4	69.6	1640	88.12	96.27	803	31.5	10.3	1
	⋮										
	0.725	26576	-1.4	67.9	1632	87.44	95.45	774	29	10.5	2

本实验依然利用在同一运行环境下连续计算 50 次获得的统计参数来比较在前述章节中所引用的各算法性能，各算法参数设置如前所示。计算结果如表 3-20 所示，基于自适应最优点和单最优点的识别方法对这组数据基本有着相似的性能，识别准确率也高于其它算法，且具有相对较高的稳定性。所以，诊断结果清楚地表明了本章所提的识别策略对实际的故障模式识别问题依然是有效的，同时也证明了所提策略具有更佳的识别性能，能够为实际的故障诊断提供有效参考。

表3-20 某型航空发动机引气故障诊断结果比较

算法	Min	Mean	Max	STD
Adaptive points	0.8235	0.8353	0.8824	0.0241
Single point	0.8235	0.8265	0.8824	0.0300
BP	0.7059	0.7912	0.8235	0.0356
LVQ	0.6471	0.6941	0.7647	0.0452
SVM	0.7647	0.8235	0.8824	0.0427
Bayesian	0.5882	0.6891	0.7647	0.0422

3.4.3 在航空发动机气路状态识别中的应用

在民航发动机实际运行过程中，对气路性能进行监控、分析，是判定发动机工作状态，进行故障诊断的有效方法，在发动机航线维护和运营管理中被广泛采用。主要是通过监控、分析发动机的 EGT、FF、N2、N1、EPR (Engine Pressure Ratio) 等主要性能参数的偏差变化，来判断发动机及子系统、部件当前的性能水平、退化趋势，根据发动机运行的状态特征来定位相应的气路部件、单元体或子系统等故障。而引起发动机气路参数变化趋势明显改变的主要有三类故障：飞机或发动机相关传感器、指示系统的故障，如飞机的大气数据传感器，被监控参数传感器发生故障等；发动机相关子系统故障，主要有引气系统、防冰系统、放气系统、涡轮间隙控制系统、静子叶片调节 VSV 系统等；发动机本体故障，主要包含风扇 (Fan)、低压压气机 (Low-Pressure Compressor, LPC)、高压压气机 (High-Pressure Compressor, HPC)、燃烧室 (Burner)、低压涡轮 (Low-Pressure Turbine, LPT)、高压涡轮 (High-Pressure Turbine, HPT) 等^[138, 160]。

某型发动机通过监控巡航阶段的 EGT 偏差、FF 偏差、N2 偏差的变化趋势来判断发动机性能状态，为进一步确定故障部件提供诊断依据。通过性能监控参数偏差的变化可确定该型发动机 5 类性能状态：(a) Fan Efficiency -1%；(b) LPT Efficiency -1%；(c) HPC Efficiency -1%；(d) HPT Efficiency -1%；(e) Overboard Bleed +1%。表 3-21 给出了由发动机厂商提供的在典型巡航条件下，3 个参数间变化量的标准比例关系。在实际状态监控过程中，以监控参数变化量间的比值 (EGT 偏差/EGT 偏差 : FF 偏差/EGT 偏差 : N2 偏差/EGT 偏差) 与标准比例关系的相似度大小来确定发动机的性能状态。同时，如表 3-21 所示，因风扇和低压涡轮，高压压气机和高压涡轮，这两组部件性能下降导致的 3 个参数变化量的比例关系是非常接近的，因此在实际中，风扇和低压涡轮被定义为低压系统，而高压压气机和高压涡轮被定义为高压系统。

表 3-21 某型发动机典型巡航条件下监控参数变化量标准比例关系

发动机具体性能状态	Delta EGT (Deg C)	Delta FF (%)	Delta N2 (%)
典型巡航条件：30000 英尺，0.8 马赫，国际标准大气压			
Fan Efficiency -1%	1	0.3601	0.0552
LPT Efficiency -1%	1	0.3576	0.0542
HPC Efficiency -1%	1	0.0929	-0.0187
HPT Efficiency -1%	1	0.0904	-0.0178
Overboard Bleed +1%	1	0.1267	0.0145

以某次该型发动机性能退化为例，工程人员监控到巡航阶段的 EGT 上升了约 55° ，FF 上升了约 5.1%，而 N2 下降了约 0.8%，根据 3 个参数的变化关系，可判断为高压系统的故障，但具体是高压压气机还是高压涡轮，则需要根据变化量的比例关系与标准关系的相似程度来确定，3 个参数的变化量比例关系为： $55/55 : 5.1/55 : -0.8/55=1 : 0.0927 : -0.0145$ ，通过与表 3-21 对比，与高压涡轮效率下降更接近，则可判断为高压涡轮故障导致发动机性能退化，经过工程人员进一步孔探检测，确定为涡轮叶片损伤引起的性能退化，在更换叶片后，发动机性能恢复到了正常水平。此例表明了通过气路性能的变化可以有效确定发动机的故障部件，提高诊断效率，保障飞行安全。

经过对整个机队的该型发动机状态数据的长期监控、分析、整理，实质上，已形成该型发动机的气路状态数据库，从而为实现自动快速地对未知状态的识别提供了支撑，避免了人为主观因素的影响。其中共整理获得 805 个状态样本，随机选择其中的 605 个样本作为训练样本，而余下的 200 个样本作为测试样本，图 3-11 给出了 5 种性能衰退样本的 2 维空间分布。如图 3-11 所示，由于高压系统和低压系统所涉及的两类样本彼此非常接近，因此增加准确识别高压系统或低压系统中具体故障部件的难度。

本实验依然利用在同一运行环境下连续计算 50 次获得的统计参数来比较在前述章节中所引用的各算法性能，各算法参数设置如前所示。如图 3-11 所示，由于 2 维数据分布不存在明显的非线性，但为验证自适应最优点的算法性能，将各类的初始最优点数设为 5。计算结果如表 3-22 所示，其中图 3-12 是某一次求解的单最优分类点的空间分布图。表 3-22 表明：基于最优分类点的算法对气路状态的识别性能相对更优，而且单最优点要优于自适应最优点，主要是因为相同的迭代数条件下，自适应最优点需要不断调整最优点数，每一次调整都可能导致额外的搜索开销，从而降低有效迭代数。同时，由于高压系统和低压系统中两类样本非常接近，导致各算法易出现误判，特别是对于 LVQ 网络分类性能影响最明显，识别准确率较其它算法明显降低，这样因为获胜神经元对非常相似的样本都具有相同的敏感度，因而对高压和低压系统的相似样本出现了误判。由于对 SVM 的核参数和罚系数进行了有效优化，使得 SVM 表现出了最好的稳定性。因此，在对航空发动机气路状态的识别中，基于最优分类点的算法依然表现出了良好的识别性能，识别准确率基本满足工程实践的需要，显然可以为航空发动机的维修决策提供可靠参考。

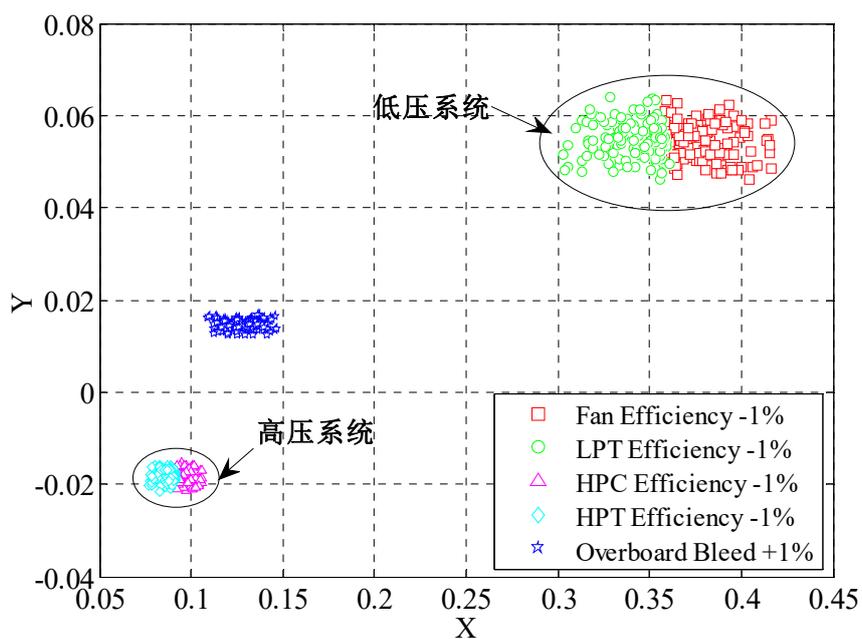


图 3-11 某型发动机气路状态样本空间分布图

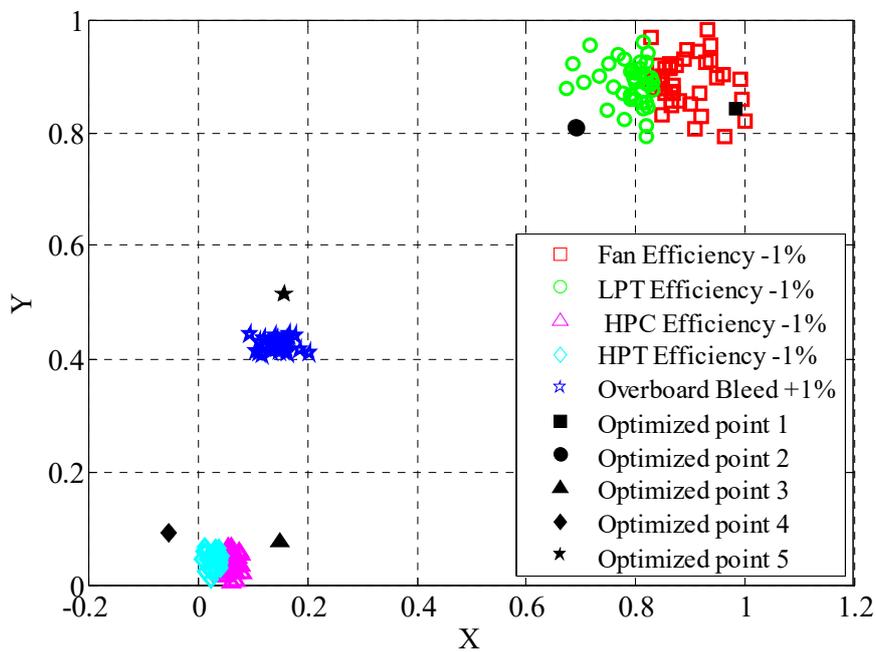


图 3-12 基于单最优点的某次求解结果空间分布图

表3-22 发动机气路状态识别结果比较

算法	Min	Mean	Max	STD
Adaptive points	0.9800	0.9894	1	0.0064
Single point	0.9850	0.9926	1	0.0054
BP	0.9800	0.9895	0.9900	0.0021
LVQ	0.7750	0.7885	0.7950	0.0063
SVM	0.9850	0.9850	0.9850	0
Bayesian	0.9550	0.9767	0.9900	0.0092

3.5 本章小结

借助 MELPSO 算法稳定、可靠的全局优化能力获得每类的单个最优分类点，通过比较到最优分类点的距离大小来实现未知模式的识别，使得基于单最优点的识别原理表现出了较好的分类性能。但基于单最优分类点的识别原理存在着不能准确识别具有线性不可分数据集的缺陷，进而提出了基于自适应最优分类点的改进识别原理，以提高对线性不可分数据的识别准确率，两者的不同之处在于：最优点的数量是算法根据数据集分布特点自适应确定的。自适应最优分类点满足最大的训练样本识别准确率，最小的分类点数量，以及最大的距离关系，是一个三目标优化问题。为求解这三目标优化问题，提出了优先度的概念，使得优化目标可按照适当的顺序被满足，从而依据问题的主次程度进行优化。基于自适应最有分类点的识别原理不仅保留了单最优分类点分类原理的优势，还进一步扩展了应用范围，使得能够对具有线性不可分的数据集起到良好的识别效果。在实际故障诊断问题应用中，本章所提的识别原理表现出更佳的识别性能，能够为实际故障诊断提供可靠参考。

第四章 基于图形割裂的粒度计算及其在故障数据压缩中的应用

随着科学技术的进步与发展，现代机械设备日益趋于大型化、集成化、自动化和精密化，而传感器技术的快速发展，使得对机械设备运行状态进行监控成了保障运行安全、缩短维修周期、降低使用成本、提高工作效率的必要手段。因此，机械设备运行过程中积累了大量反映设备运行状态的各类数据，有力促进了基于数据驱动的各类故障诊断算法的快速发展。基于数据驱动的算法有效地避免了对复杂设备运行过程的数学描述，而着力揭示数据隐藏规律与含义，从而通过数据特征来判别机械设备的运行状态，有效降低了对数学物理知识的依赖，开辟了故障诊断方法发展新方向，极大拓展故障诊断的应用范围，解决了许多工程实践中的难题^[127, 128, 136]。

毫无疑问，故障诊断准确率是诊断技术所追求的第一性能指标。海量监控数据能够准确清晰地描述机械设备的运行状态特征，为精准定位故障提供保障。但海量数据随之带来的另一问题是存在大量相似或者重复的，反映设备同一运行状态的数据，这类数据实质上对算法训练有着几乎类似的作用，因而变相地增加了样本规模，对诊断算法训练效率有着直接影响，处理海量数据导致计算开销的明显增大，降低算法的实时性。因此，如何快速、准确处理运行状态大数据，有效提高故障诊断效率，成为了故障诊断研究的重要课题。为了改进算法的训练效率，最直接的手段是对状态数据进行压缩，减少训练样本规模。然而，从训练样本中消除部分样本可能带来以下两方面的影响，即数据的信息丢失，改变了数据分布特性，影响故障诊断的准确率；或者消除了不相关数据、冗余数据和噪声数据，改善诊断算法训练效率^[161]。因此，必须要在维持数据原始分布状态尽量不改变的基础上，对状态数据进行压缩，从而既保证诊断准确率不降低，又提高计算效率。

粒度计算（Granular Computing, GrC）是一种基于问题概念空间划分的新型智能计算理论，主要研究关于多层次粒结构的思维方法、问题求解方法、信息处理模式及相关理论的学科^[162]。GrC 主要用于处理不确定的、模糊的、不完整的和海量的信息，它可以通过降低问题的复杂性，以较低的计算开销来获取满意的近似解，同时，也可以通过改变粒度的大小，来隐藏或者揭示问题的细节^[163]。因此，凡是在分析和求解问题中，应用了分组、分类和聚类等手段的理论和方法均属于 GrC 的研究范畴^[164, 165]。本章将结合粒度计算的概念，探索粒度生成新方法，这对处理海量状态监控数据，提高故障诊断效率，保障故障诊断准确率具有重要的理论意义和使用价值。

基于 GrC 的数据压缩用于分类，主要思想是通过相应的粒度划分方法构建粒度空间，获得一系列信息粒，用信息粒代替传统的训练样本，构建基于信息粒的新样本集，从而压缩样本数量，提高效率。通常情况下，由于数据压缩导致的训练样本空间分布情况的变化，会引起分类算法泛化能力的损失，从而降低对未知样本的识别精度。因此，在维持泛化能力不弱化的前提下，开展基于 GrC 的数据压缩研究，是此项研究的难点。

在实际故障诊断应用中，诊断准确率是首要前提，任何以数据压缩为手段的计算效率提高，都不能以降低诊断准确率为代价。如前分析，造成计算效率低下的主要原因是大量非常相似或者重复的样本存在，基于此，本文将提出一种不同于上述方法的粒度计算模型，将根据训练样本的相似度，利用图形割裂的方法来划分粒，而在粒度的划分过程中，遵循维持样本原始空间分布的原理。因此，尽管训练样本被压缩，但新样本的空间分布继承了原始样本空间分布的特性，有利于保持泛化能力，以较低的计算开销获得满意的诊断准确率。

4.1 相似度的定义及图形的生成

4.1.1 无量纲相似度的定义

描述向量之间的相似度有多种度量方法，如明可夫斯基距离、马氏距离、曼哈顿距离、切比雪夫距离、皮尔逊相关系数和余弦相似度等^[140-143]。而欧氏距离通过测量两个样本间的空间距离大小来度量样本间的相似度，因其直观的含义，简洁的表达，已广泛应用于各类算法当中。欧式距离取值在 $[0, +\infty)$ 区间，取值越小意味着两个样本在空间中距离越近，也越相似，而“0”表示两个样本是完全重合的，反之亦然。为了更接近人类的思维方式，很多学者构建出基于欧式距离的相似度计算方法，相似度取值在 $(0, 1]$ 区间，“1”表示样本是完全一致的，若样本间的欧式距离趋于无穷，则相似度为0。文献^[166]提出了基于逆欧式距离的相似度计算方法，而文献^[167, 168]分别提出了基于指数欧式距离的相似度计算方法，这些相似度都在 $(0, 1]$ 区间取值，且已被应用到实际计算当中。如果令 \mathbf{X} 表示一个数据集， $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$ ，而 $\mathbf{x}_i=[x_{i1}, x_{i2}, \dots, x_{iD}]$ ， $|\mathbf{x}_i|=D$ ， D 是样本的维数，则 Huang^[166]和 von Luxburg^[168]提出的相似度计算公式分别如下所示：

$$S(\mathbf{x}_i, \mathbf{x}_j) = \frac{1}{\sqrt{\sum_{d=1}^D (x_{id} - x_{jd})^2 + 1}} \quad (4-1)$$

$$S(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(-\sqrt{\sum_{d=1}^D (x_{id} - x_{jd})^2} \right) \quad (4-2)$$

由于样本每一维的数据通常会具有不同的量纲，不同量纲易造成样本中每一维数据的数量级有显著差异，即各维数据可能在一个相差很大的数据分布范围内取值。这时上述的相似度计算方法将存在明显的缺陷。对具有不同量纲的数据集，欧式距离存在较大的取值，导致样本间的相似度往往易趋近于 0，显然不利于描述样本间的相似度指标。因此，定义一种无量纲相似度计算方法，通过引入每个属性的极差以消除量纲差异，从而使数据具有相同的口径，以克服量纲对传统相似度的影响。因此，在 \mathbf{x}_i 和 \mathbf{x}_j 间的无量纲相似度计算如下：

$$\begin{cases} S(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(-\frac{1}{\sqrt{2}} \cdot \sqrt{\sum_{d=1}^D \frac{(x_{id} - x_{jd})^2}{r_d}} \right) \\ r_d = \max(x_{1d}, x_{2d}, \dots, x_{nd}) - \min(x_{1d}, x_{2d}, \dots, x_{nd}) \end{cases} \quad (4-3)$$

式中， r_d 代表样本集第 d 列的极差。在式(4-3)中，尽管 $S(\mathbf{x}_i, \mathbf{x}_j)$ 也是在(0, 1]区间取值，但却克服了基于传统欧式距离的相似度计算缺陷。

4.1.2 图形的生成

图形是图形割裂的基础，只有生成图形后，才能进行图形割裂操作，进而产生粒。所以，在这个理论中，一个三元组用来描述图形系统(Graph System, GS)，三元组的定义如下：

$$GS = (\mathbf{X}, s, \mathbf{M}) \quad (4-4)$$

式中， \mathbf{X} 表示由样本所构成的非空样本集，通常也被称为论域， $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$ ， $n=|\mathbf{X}|$ ； s 是相似度阈值，通过相似度阈值将样本联系起来，通常较低的相似度阈值会产生较粗的粒度，相反，较高的相似度阈值会产生较精细的粒度； \mathbf{M} 是相似度矩阵，相似度矩阵的元素 $e_{i,j} \in \{0, 1\}$ ，任意元素可由下式计算所得：

$$e_{i,j} = \begin{cases} S(\mathbf{x}_i, \mathbf{x}_j), S(\mathbf{x}_i, \mathbf{x}_j) \geq s \\ 0, \text{otherwise} \end{cases} \quad (4-5)$$

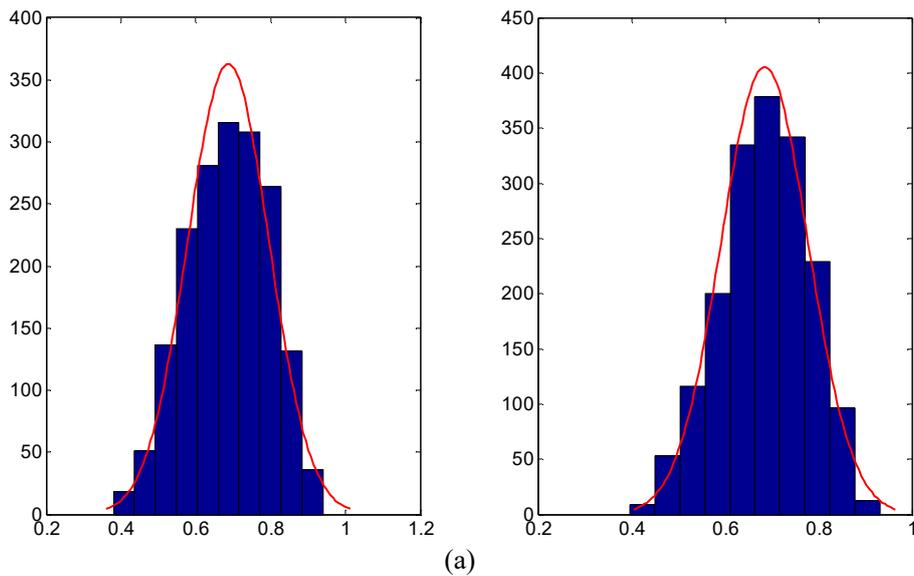
由于 $\|\mathbf{x}_i - \mathbf{x}_j\| = \|\mathbf{x}_j - \mathbf{x}_i\|$ ，而且 $\|\mathbf{x}_i - \mathbf{x}_i\| = 0$ ，则相似度矩阵可按照如下形式进行表示：

$$\mathbf{M}_{n \times n} = \begin{bmatrix} 0 & e_{12} & \cdots & e_{1n} \\ 0 & 0 & \cdots & e_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix} \quad (4-6)$$

显然，相似度矩阵是一个对角线元素全为 0 的上三角矩阵，对任意元素而言，若 $e_{ij} \neq 0$ ，则表示在样本 \mathbf{x}_i 和 \mathbf{x}_j 间是有边相连接，且边的权重为 e_{ij} ，否则，这两个样本间是不相连的。因此根据图形系统，可产生由样本所构成的图形 $\mathbf{G} = (\mathbf{X}, \mathbf{M})$ ，实质上，对于图形而言，原来的样本集 \mathbf{X} 转变成了图形中的点集，而相似度矩阵 \mathbf{M} 代表了图形中的边集。

在实际应用当中，确定合适的相似度阈值是一个重要而困难的问题^[164-166]。一般而言，没有明确的理论来指导确定 s ，而 s 通常可根据试凑法或者专家知识来确定，但这一过程无疑具有认知的主观性，没有从整体上把握相似度的分布情况。为更好地确定合适的 s ，本文利用频率直方图先对相似度矩阵进行统计，相似度区间 $(0, 1]$ 被等分为一定数量的子区间，属于各个子区间的元素数量可以被统计出来，从而样本间相似度的频率分布可以直观显示，为 s 的确定提供了数值支撑，不在仅仅依靠专家经验，在根据实际问题或者专家经验对相似度阈值 s 进行调整，确定合适的 s 。这一方法的优势在于直观地给出了相似度矩阵元素的分布情况，有利于确定合适的相似度阈值 s ，同时，保证了粒度划分能够实现。

用第三章轴承的内外圈故障数据来验证各相似度定义的计算结果，通过与文献[166]和[168]相似度计算方法的比较，验证无量纲相似度的优势。各方法计算的相似度矩阵的频率直方图如图 4-1 所示。



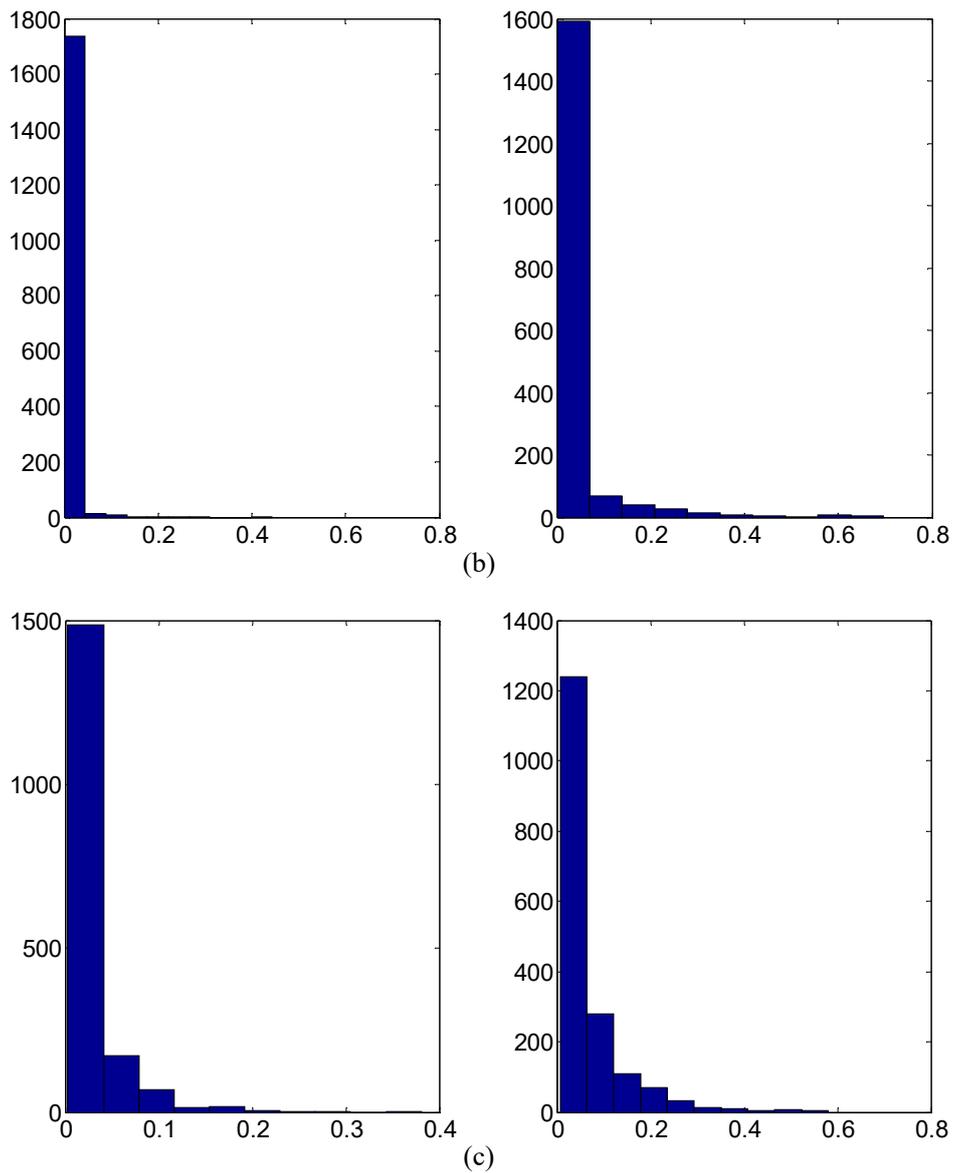


图 4-1 基于不同相似度方法的频率直方图比较。(a) 基于无量纲相似度的频率直方图；(b) 基于指数欧式距离的频率直方图；(c) 基于逆欧式距离的频率直方图

如图 4-1 所示，由于不同量纲的影响，频率直方图显示基于文献[166]和[168]计算的相似度几乎趋于或接近于 0，从工程观点来看，如果大量样本几乎处于很低的相似度水平，说明样本基本是不相似的，无疑限制了其进一步应用。而基于无量纲相似度计算的频率直方图，呈现出较好的正态分布，这符合客观规律，为数据进一步处理和应用提供了前提。同时，用频率直方图能直观地显示相似度矩阵元素的分布情况，为确定合理的相似度阈值提供有效参考，降低主观认知的影响。

假设反映某一状态特征的样本有 10 个，利用无量纲相似度计算样本间的相似度指标，定义相似度阈值 $s = 0.9$ ，则相似度矩阵为：

$$M_{10 \times 10} = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.97 & 0.95 & 0.97 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.98 & 0.94 & 0 & 0 & 0.93 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.96 & 0.93 & 0.97 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.97 & 0 & 0.98 & 0.91 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0.98 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0.93 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix} \quad (4-7)$$

则根据图形生成规则产生的图如图 4-2 所示。

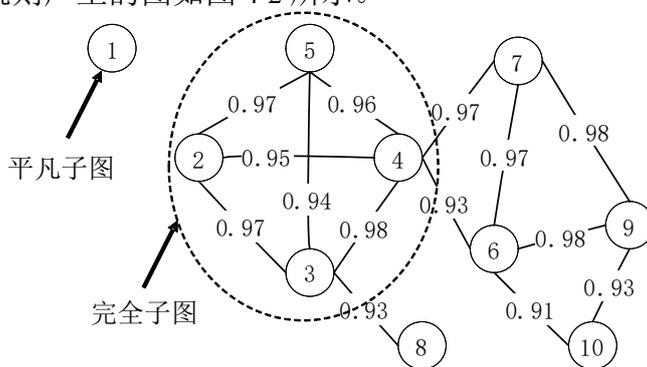


图 4-2 根据 **GS** 产生的加权简单图

按照图论的定义，凡是不包含环或者多重边的图定义为简单图；若一个图的每一对不同顶点恰有一条边相连，则称为完全图。而由 **GS** 产生的图形，一定是一个简单图，而且是带权重的简单图。在简单图中，若某结点和其他任意结点都无边连接，则定义为平凡子图，如图 4-2 所示，结点“1”即是简单图的平凡子图。除去所有平凡子图后所余下的简单子图，则用于提取无包含关系的完全子图集。因此，从样本集到图形割裂的操作如图 4-3 所示。

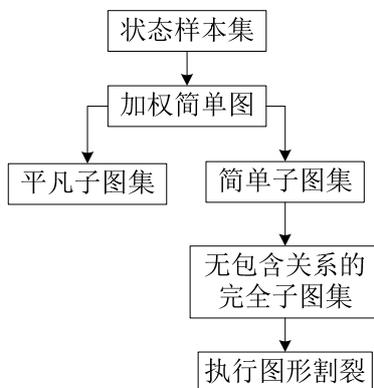


图 4-3 从样本集到图形割裂的流程图

如图 4-3 所示, 根据相似度矩阵, 由状态样本集生成加权简单图, 在加权简单图中提取平凡子图集和无包含关系的完全子图集, 进而对无包含关系的完全子图集进行图形割裂。对于简单的样本关系, 可以直接通过人工操作对图形进行操作, 但对复杂的、大数据的样本关系, 只能将图形矩阵化, 借助于计算机的矩阵运算进行。

4.2 基于无量纲相似度的图形割裂

4.2.1 平凡子图集和完全子图集的提取

一般情况下, 人工操作只能处理简单的、少量的样本, 但对于复杂的、大数据的样本, 只能将图形进行矩阵化, 利用计算机来执行图形割裂操作。图形的矩阵化可以利用相似度矩阵表示, 因此, 实质上是利用计算机算法对相似度矩阵进行操作判断。

令 G_{ts} 表示平凡子图集, G_{cs} 表示完全子图集, M 为相似度矩阵, $n=|X|$ 。判断一个结点是否为平凡子图的算法描述如下:

$$G_{ts} = \left\{ \{x_i\} \mid \exists \sum_{j=1}^n (M(i, j) + M(j, i)) = 0, i = 1, 2, \dots, n \right\} \quad (4-8)$$

对于完全子图的提取较为复杂, 对任意 $x_i, i=1, 2, \dots, n-1$, 所有与 x_i 相连接的结点所构成的图形中提取完全子图, 其算法过程描述如下:

Step1: 确定由与 x_i 相连接的所有结点构成的结点子集 X_s :

$$X_s = \{x_i\} \cap \{x_j \mid \forall e_{ij} \neq 0, j = i+1, \dots, n\} \quad (4-9)$$

Step2: 产生由 X_s 所构成的 $|X_s| \times |X_s|$ 相似度子矩阵 $M_s = M(X_s, X_s)$ 。

Step3: 确定计数标志 $tag=0$ 和位置矩阵 P 的状态:

$$\forall e_{ij} = 0 \Rightarrow \begin{cases} tag = tag + 1 \\ P(t) = [X_s(i), X_s(j)] \end{cases} \quad i = 1, \dots, |X_s| - 1, j = i + 1, \dots, |X_s| \quad (4-10)$$

因此, $tag \neq 0$, 意味着至少有一对样本在图形上是不相连的, 它们不可能存在于同一完全子图当中, 而位置矩阵 P 记录下了这对样本。

Step4: 生成完全子图。若 $tag = 0$, 则与 x_i 相连接的结点所构成的图形就是一个完全子图, 即 $G_{cs} = \{G_{cs}, \{X_s\}\}$ 。若 $tag \neq 0$, 令 G_{cs-t} 用于临时储存完全子图集, $G_{cs-t} = \{X_s\}, t=1, \dots, tag, k=1, \dots, |G_{cs-t}|$, 则根据位置矩阵 P 对 G_{cs-t} 进行拆分, 生成正确的完全子图集, 其过程如下:

$$\exists P(t) \in G_{cs-t}(k) \Rightarrow \begin{cases} G_{cs-t}(k) = G_{cs-t}(k) - P(t,1) \\ G_{cs-t}(|G_{cs-t}|+1) = G_{cs-t}(k) + P(t,1) \end{cases} \quad (4-11)$$

最后令 $G_{cs} = \{G_{cs}, G_{cs-t}\}$ 。

Step5: 删除具有包含关系的完全子图:

$$\forall G_{cs}(i) \in G_{cs}(j), i, j = 1, 2, \dots, |G_{cs}|, j \neq i \Rightarrow G_{cs}(i) = \emptyset \quad (4-12)$$

此时所得到的 G_{cs} , 任意子集都不具有包含关系。图 4-4 给出了平凡子图集和完全子图集的提取流程。

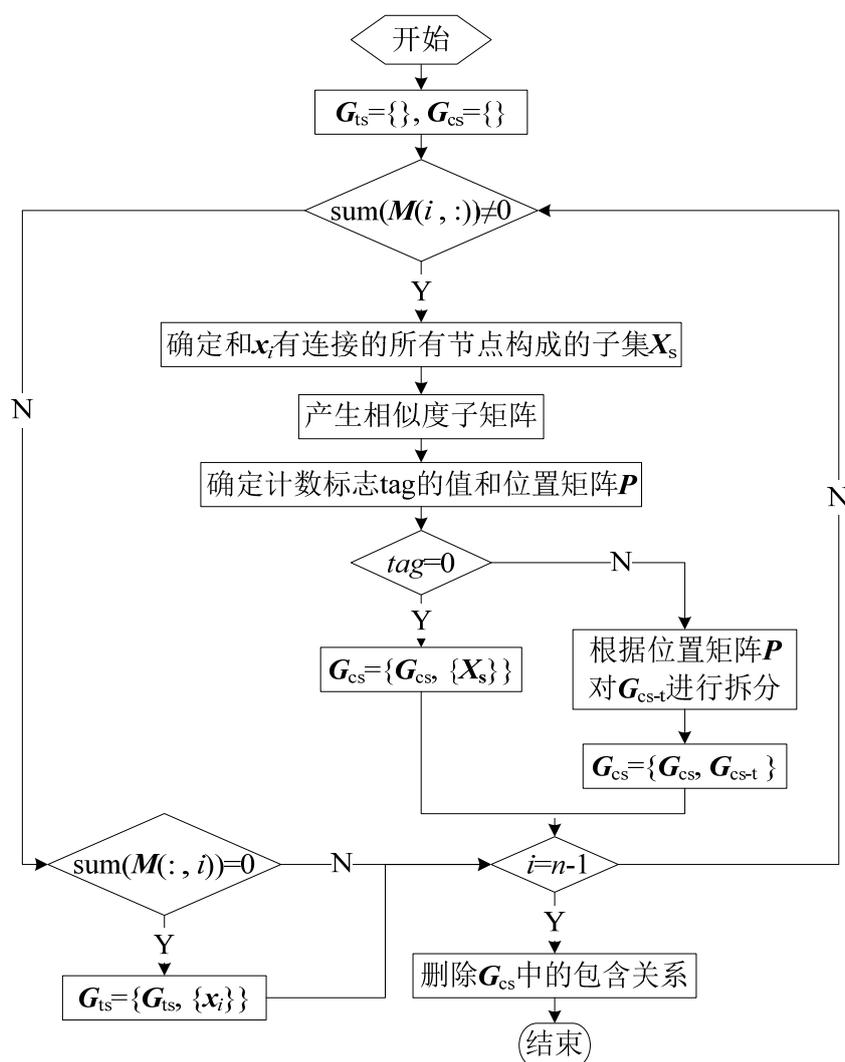


图 4-4 平凡子图集和完全子图集的提取流程图

以图 4-2 所示的简单图为例, 提取的完全子图集 $G_{cs} = \{\{x_2, x_3, x_4, x_5\}, \{x_3, x_8\}, \{x_4, x_6, x_7\}, \{x_6, x_7, x_9\}, \{x_6, x_9, x_{10}\}\}$, 而平凡子图集 $G_{ts} = \{x_1\}$ 。

4.2.2 图形割裂的原则和粒度的生成

图形割裂是对完全子图集进行的操作，是粒度生成的主要途径，怎样对图形进行有效割裂，确保最相似的样本划归为同一粒度，是本节研究的重点。由于简单图的边是带权重的，权重值即是两个结点间的相似度，因此图形的割裂针对结点间带权重的边进行操作，设 $Gr=\{\}$ 表示粒度集合，则主要依据如下 5 条原则来执行图形割裂，生成粒度：

Rule1: 完全子图集中具有最高平均相似度的完全子图将优先进行割裂操作，形成一个粒度。 $G_{cs}(i)$ 构成了第 i 个完全子图的点集，而点集所对应的相似度矩阵 $M_{cs}(i)$ 则构成了边集，则由 $(G_{cs}(i), M_{cs}(i))$ 构成了加权的完全子图集，其平均相似度计算如下：

$$m(i) = \frac{\text{sum}(M_{cs}(i))}{0.5 \times |G_{cs}(i)| \times (|G_{cs}(i)| - 1)} \quad (4-13)$$

则 $Gr=\{Gr, G_{cs}(i)\}$ ，其中： $m(i)=\max(m)$ 。

Rule2: 若任意完全子图具有相同的平均相似度，则依据于它们所含的结点数而定，含结点数多的完全子图优先进行割裂，形成一个粒度，则 $Gr=\{Gr, G_{cs}(i)\}$ ，其中： $|G_{cs}(i)| \geq |G_{cs}(j)|$ ， $m(i)=m(j)$ 。

Rule3: 若一个完全子图被确定为粒度，则存在于该完全子图的结点将不能再存在于其它完全子图当中，即此类结点将从其它完全子图中删除。此规则使得图形割裂过程中完全子图数量不断减少，有些完全子图有可能转变为平凡子图，即仅含有一个结点的图形。

Rule4: 一旦某一完全子图 $G_{cs}(i)$ 被确定为一个粒度，则 $Gr=\{Gr, G_{cs}(i)\}$ ，其后它将从完全子图集 G_{cs} 中删除。

Rule5: 所有平凡子图将单独形成一个粒度。

由于从完全子图到形成粒度的过程，是根据平均相似度值将部分子图从原始简单图中割裂开，因此该方法被定义为基于图形割裂的粒度计算，图 4-5 给出了粒度生成的流程图。

再以图 4-2 所示的简单图为例，因 $G_{cs}=\{\{x_2, x_3, x_4, x_5\}, \{x_3, x_8\}, \{x_4, x_6, x_7\}, \{x_6, x_7, x_9\}, \{x_6, x_9, x_{10}\}\}$ ，则根据式(4-13)， G_{cs} 的平均相似度为 $m=(0.9617, 0.93, 0.9567, 0.9767, 0.94)$ ，根据 5 条原则，最后生成的粒度为 $Gr=\{\{x_1\}, \{x_8\}, \{x_{10}\}, \{x_2, x_3, x_4, x_5\}, \{x_4, x_6, x_7\}\}$ ，其中 $\{x_8\}$ 和 $\{x_{10}\}$ 是由图形割裂后产生的平凡子图形成的粒度。图 4-6 直观地显示了图形割裂和粒度生成的过程。

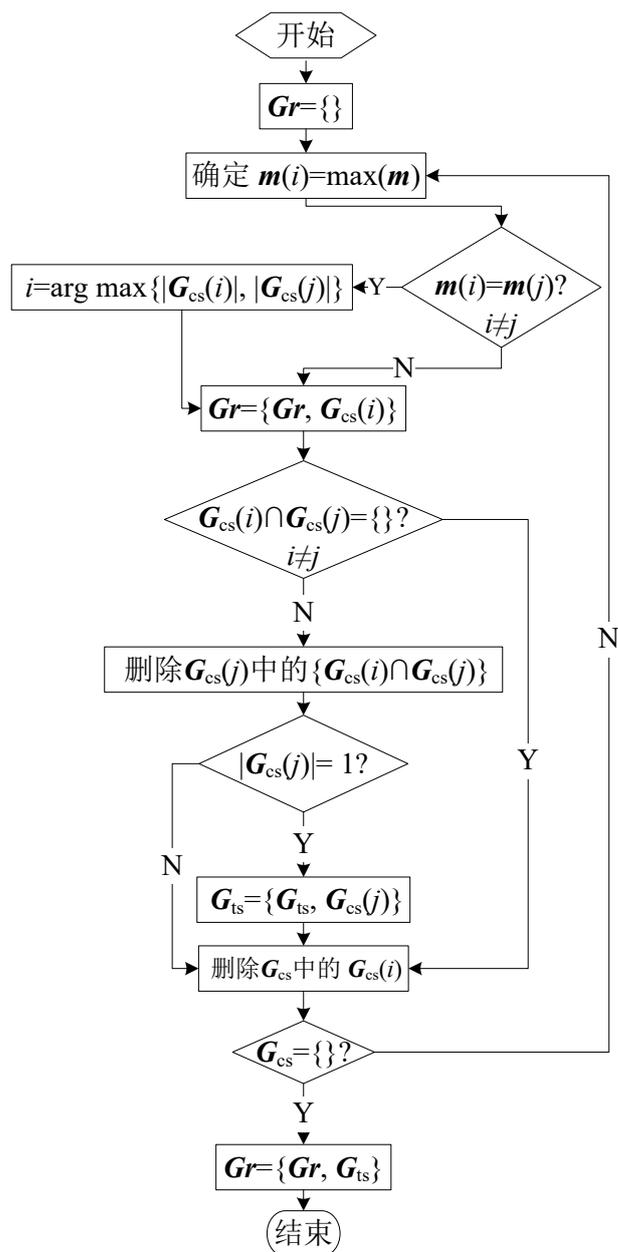


图 4-5 粒度生成流程图

如前分析，对于简单的、少量的样本，借助于直观的图形割裂方法，可容易地进行粒度的生成，但面对实际过程中产生的复杂的、大数据的样本时，算法的矩阵化计算方式可借助于计算机进行快速操作，生成粒度。同时，正是由于与其他结点没有相似关系的平凡子图，以及因图形割裂而产生的平凡子图独立形成粒度，使得粒度空间保持了与原始样本空间相似的空间分布，这有利于利用粒度计算压缩原始样本的同时，维持样本的空间分布基本不改变，保持数据的分类能力。这对提高故障诊断的效率，保持诊断准确率有着重要意义。

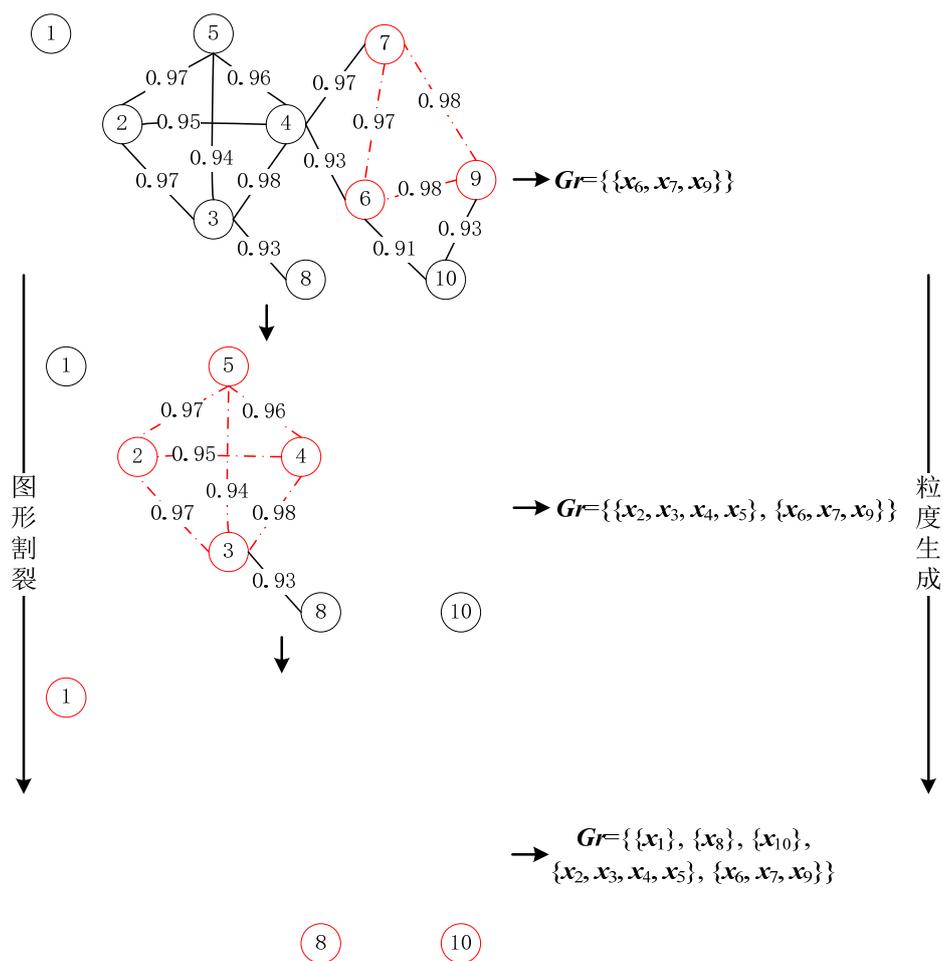


图 4-6 图形割裂和粒度生成过程

4.3 粒度的应用及样本空间分布变化的评价

由于数据间的冗余性或者相似性，在利用大数据训练算法时，实质上没有必要所有的数据都参与训练，毫无疑问，训练时间开销与样本量是成正相关的。而在生成粒度以后，由于粒度本身是由最相似的样本所构成的，因此可由粒度来重构某一样本，来代替粒度中的样本进行训练，这对压缩训练样本，改善计算效率具有重要意义，所以将粒度计算应用到故障诊断中是非常有必要的。同时，为了评价数据压缩的质量，即因数据压缩后导致的样本分布空间的变化程度，本文提出相应的评价体系。

4.3.1 粒度在故障诊断中的应用

在粒度生成过程中，满足某一相似度指标的训练样本可以形成一个粒度。而在故障数据采集过程中，对表征某一故障模式的数据，往往在故障特征空间中是彼此接近的，它们对故障模式判别的贡献基本是一致的。因此，利用某一特定样

本来代替此类相似样本进行训练是合理的，这有助于改善故障诊断效率。

由生成的粒度重构出新的样本，基本是利用粒度几何中心的数据来重构新样本，从而用新样本来代替粒度中的原始样本^[169]，本文也采用此方法，同时将新样本定义为粒中心样本 \mathbf{x}_{gc} ，对于第 i 个粒度 $\mathbf{Gr}(i)$ ，粒中心样本 \mathbf{x}_{gc}^i 可由下式计算：

$$\mathbf{x}_{gc}^i = \frac{\sum_{j=1}^{|\mathbf{Gr}(i)|} \mathbf{x}_j}{|\mathbf{Gr}(i)|} \quad (4-14)$$

式中： \mathbf{x}_j 是第 i 个粒度中的样本。显然，在空间分布中，粒中心样本 \mathbf{x}_{gc} 处于一个小空间邻域的中心位置，与其它粒度中样本相比较，它更能够综合地反映同一故障模式特征。而且，粒度中任意两个样本的最小相似度满足： $S_{\min}(\mathbf{x}_i, \mathbf{x}_j) \geq s$ ，则粒中心样本 \mathbf{x}_{gc} 与粒度中其它样本的相似度满足： $S(\mathbf{x}_{gc}, \mathbf{x}_j) > S_{\min}(\mathbf{x}_i, \mathbf{x}_j)$ ，这表明粒中心样本与粒度中其它样本具有更高的相似度，因此，用粒中心样本来代替其它样本是最合适的。

4.3.2 空间分布变化的评价

原始样本在空间中的分布情况反映了故障模式的空间分布，代表同一故障模式的样本呈现出分布的连续性，不同的故障模式呈现出分布的间断性，处于同一邻域空间的样本通常代表着某一类型的故障模式。毫无疑问，任何对原始样本显著地改变，例如：删除、移动、替换等，都会改变故障模式的空间分布情况，从而影响到对未知样本的识别。因此，通过粒度来重构新样本，并压缩原始样本，需要对压缩质量进行定量评价，以衡量数据空间分布的改变状况，确保在识别准确率和计算开销中达到合适的平衡。

为了评价原始样本的空间分布变化情况，首先定义 \mathbf{x}_{oc}^i 为第 i 类样本原始样本几何中心，其等于样本均值，由粒中心样本 \mathbf{x}_{gc} 对原始样本进行替换后，形成新的重构样本的几何中心为 \mathbf{x}_{nc} 。同时令 \mathbf{x}_j^i 为属于第 i 类别的第 j 个样本， $j=1, 2, \dots, |\mathbf{X}^i|$ ， \mathbf{x}_{gck}^i 为属于第 i 类别的第 k 个重构样本， $k=1, 2, \dots, |\mathbf{Gr}^i|$ ，显然有 $|\mathbf{X}^i| \geq |\mathbf{Gr}^i|$ 。因样本数量的减少，必定会引起一定信息的丢失，即样本空间分布的改变，因此，可利用以下两个因素来综合评价空间分布的改变：

(1) 基于重构样本和原始样本数量的对比

因样本数量的减少，两类样本的特征显然会发生变化，但考虑到分类，通常情况能够提供类别间差异信息的主要是空间分布中位于边界的样本，而不是位于中心区域的样本，所以，满足如下条件的原始样本才可用来对比重构样本：

$$\|\mathbf{x}_j^i - \mathbf{x}_{oc}^i\| \geq \min \|\mathbf{x}_{gck}^i - \mathbf{x}_{oc}^i\| \quad (4-15)$$

原始样本到 \mathbf{x}_{oc}^i 的距离按照由小及大的顺序，且满足式(4-15)，构成了原始距离向量 \mathbf{d}_{od} ，而所有重构样本到 \mathbf{x}_{oc}^i 的距离按照由小及大的顺序构成了重构距离向量 \mathbf{d}_{rd} ，按照式(4-15)的限制，则 $\min(\mathbf{d}_{od}) \geq \min(\mathbf{d}_{rd})$ ，且 $|\mathbf{d}_{od}| \geq |\mathbf{d}_{rd}|$ 。则基于重构样本和原始样本数量变化的评价指标为：

$$EI_1 = \frac{|\mathbf{d}_{od}| - |\mathbf{d}_{rd}|}{|\mathbf{d}_{od}|} \quad (4-16)$$

式(4-16)表明： $0 \leq EI_1 \leq 1$ ， EI_1 本质上是根据样本数量差异，将重构样本空间分布到原始样本空间分布的边界进行对比，是从保持分类性能的角度评价空间分布的变化。当 $|\mathbf{X}^i| = |\mathbf{Gr}^i|$ ，即原始样本和重构样本一致时， $EI_1=0$ 。由于式(4-15)的限制，从样本分类角度提供了由原始样本边界到重构样本分布的比较，因此 EI_1 值越大，重构样本引起的空间分布改变越不利于样本识别，但 EI_1 越小，重构样本越趋于分布于原空间边界，但却不一定意味着适合于分类，因此进一步引出基于中心差异的评价指标。

(2) 基于重构样本和原始样本中心差异的对比

基于重构样本和原始样本中心差异的对比，着重于对从总体分布的角度评价空间分变化。当原始样本中心 \mathbf{x}_{oc} 和重构样本中心 \mathbf{x}_{nc} 存在较大差异时，空间分布改变是显著的。为能够定量描述 \mathbf{x}_{oc} 和 \mathbf{x}_{nc} 差异，利用如下相似度公式计算二者差异：

$$EI_2 = \exp\left(-\frac{1}{2} \cdot \sqrt{\frac{\|\mathbf{x}_{oc} - \mathbf{x}_{nc}\|^2}{D}}\right) \quad (4-17)$$

因 $EI_2 \in (0, 1]$ ， $EI_2=1$ 时，样本中心完全重合，当样本中心欧式距离趋于无穷大时， EI_2 趋于 0。对样本空间分布变化的评价，从与边界分布的差异和总体分布改变的两方面进行评价，即考虑到重构后的新样本分类性能，又把握样本中心变化情况，从而对复杂空间分布变化情况进行有效评价，最终表达式如下：

$$EI = \frac{EI_1}{EI_2} \quad (4-18)$$

通过相似度阈值 s ，评价指标 EI 和样本数量 $|\mathbf{X}|$ 这三个参数的变化情况来体现三者间的关系，说明加权相对误差设计的合理性，因 $0 \leq s \leq 1$ ， $0 \leq EI$ ，而 $|\mathbf{X}|$ 表示某一故障模式的原始样本数量。图 4-7 表明了这三个参数间的相互变化关系，有两种特

殊情况存在。当 $s=0$ 时，意味着所有的样本构成一个粒度，则此时只能重构出一个新样本，在这样情况下，显然 EI 达到最大值；当 $s=1$ 时，意味着只能由单独一个样本构成一个粒度，则此时重构出的新样本和原始样本是完全一致的，样本数量没有发生改变，而这样情况下， $EI=0$ ，达到最小值。因此，随着相似度阈值 s 的增大，评价指标 EI 具有减小的趋势，由粒度所重构的样本和原始样本的空间变化越微小，而对原始样本的压缩率也越小，所以，应该根据实际问题求解需要，确定合适的相似度阈值，来保障在不降低识别准确率的基础上，提高计算效率。

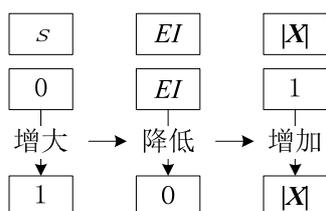


图 4-7 s , EI , $|X|$ 的变化关系

通过一组 2 维样本的空间分布变化来进一步阐述评价指标 EI 的原理，并说明其合理性。原始样本共有 401 个，样本空间分布如图 4-8 所示，重构样本为唯一样本，且是原始样本均值。显然，重构样本没有保持任何原始样本的分布特性，尽管中心样本差异最小， $EI_2=1$ ，但与原始样本边界分布差异明显，重构样本完全失去了原始样本的分类性能， EI_1 达到最大值，总体评价 $EI=1$ ，显然，空间分布改变是明显的。

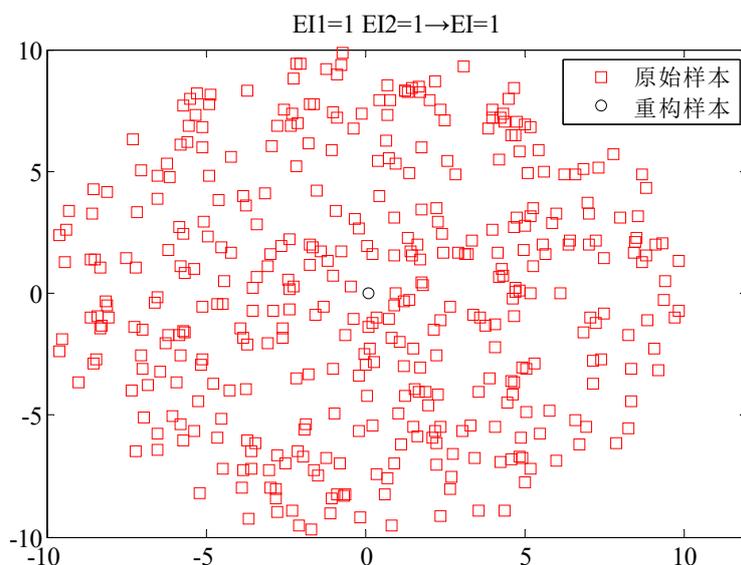


图 4-8 重构样本数为 1 时的空间分布变化评价

当样本空间分布如图 4-9 所示，重构样本和原始样本完全一致时，此时 EI_1 达

到最小值, $EI_1=0$, 而 EI_2 达到最大值, 因此, EI 达到最小值, 表明重构样本完全维持了原始样本的分布特性和分类性能。

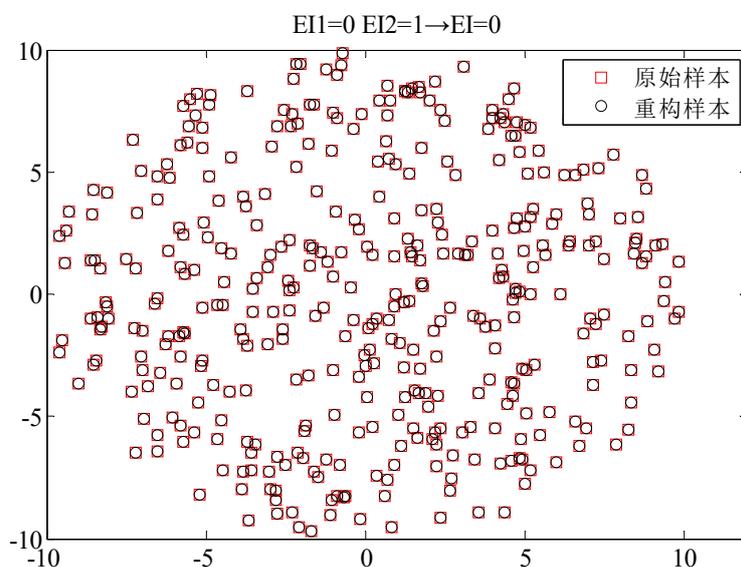


图 4-9 重构样本数为 401 时的空间分布变化评价

当样本空间分布如图 4-10 所示, 重构样本数为 21, 由于重构样本相对于原始样本, 呈内圆分布, 偏离原始样本边界明显, 所以 EI_1 增大, 重构样本的分类性能明显降低。而样本中心也出现一定程度的偏移, EI_2 也降低。

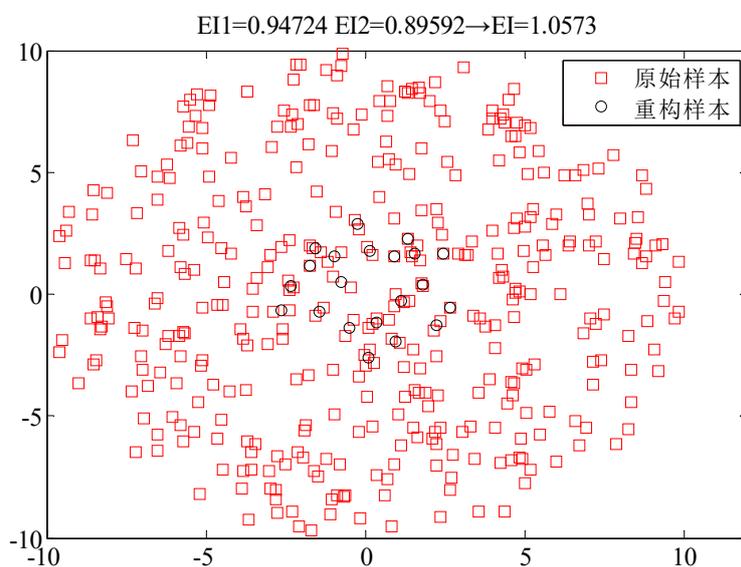


图 4-10 重构样本数为 21 时的空间分布变化评价

当样本空间分布如图 4-11 所示, 重构样本的内圆分布相对扩大, 重构样本数为 74, 此时 EI_1 减小, 表明相较于图 4-10, 重构样本更加靠近边界, 更利于分类。

样本中心位置基本没有改变。

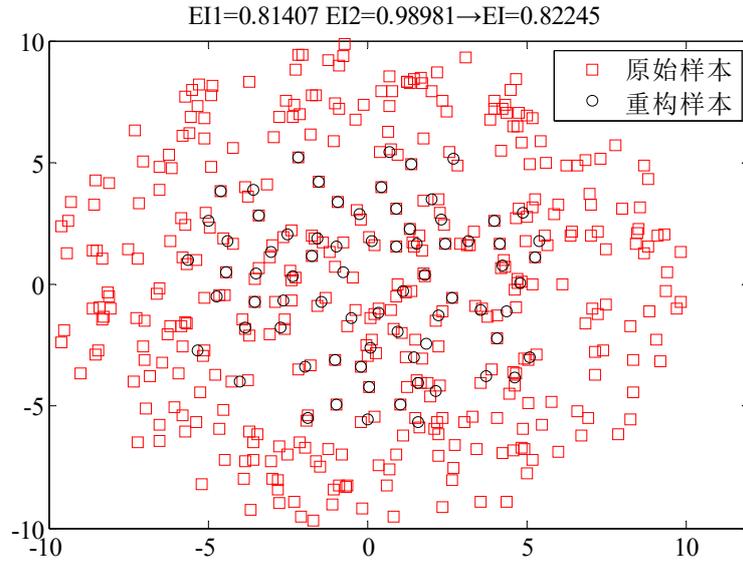


图 4-11 重构样本数为 74 时的空间分布变化评价

当样本空间分布如图 4-12 所示，重构样本数为 65，重构样本此时呈环形分布，实质上，图 4-12 的重构样本边界和图 4-11 的重构样本边界分布是一致的，因此 EI_1 基本相似，表明两者的分类性能基本是一致的，同时，由于重构样本呈现环形状，样本中心位置基本没有改变。所以，图 4-11 和图 4-12 的评价指标 EI 基本是一致的。

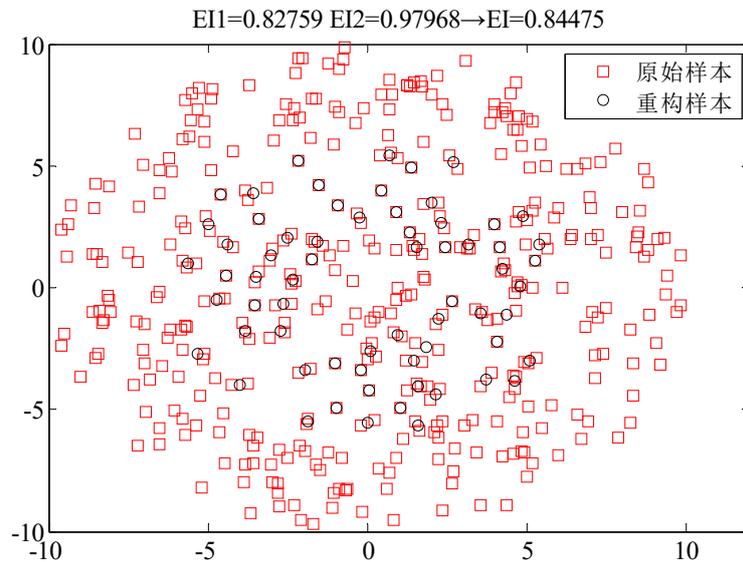


图 4-12 重构样本数为 65 时的空间分布变化评价

当样本空间分布如图 4-13 所示，重构样本数为 111，与图 4-12 相比较，重构

样本依然呈环形，但更靠近外侧，因此分类性得到进一步增强，所以， EI_1 进一步降低，而样本中心位置改变也不明显。

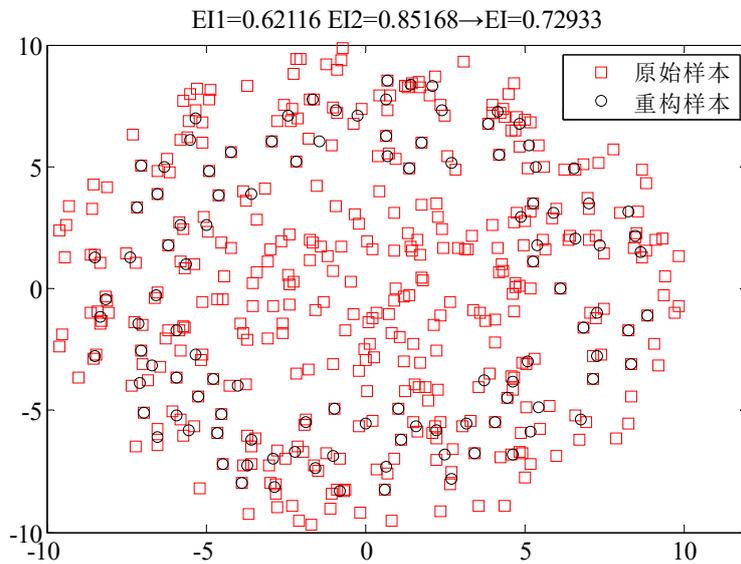


图 4-13 重构样本数为 111 时的空间分布变化评价

当样本空间分布如图 4-14 所示，重构样本数为 55，尽管重构样本依然呈环形，但重构样本边界和原始样本边界分布是基本一致的，因此，相较于图 4-13， EI_1 更进一步降低，基本保持了原始样本的分类能力。同时，样本中心位置也基本保持一致。

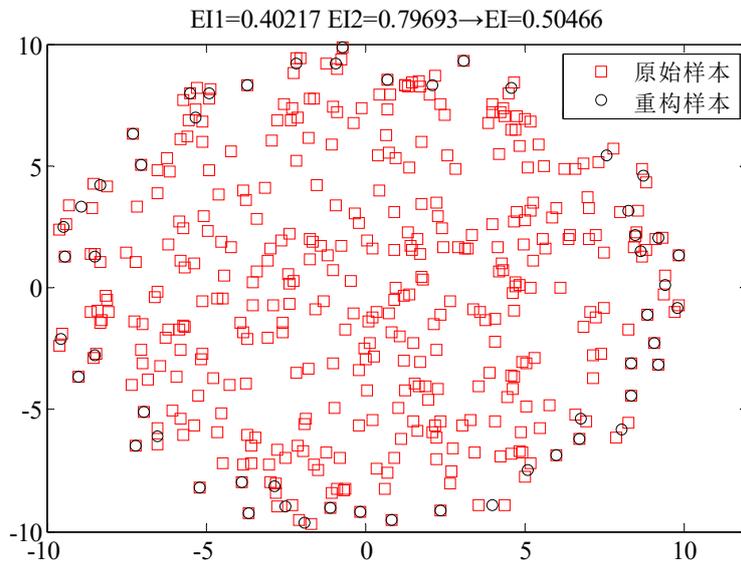


图 4-14 重构样本数为 55 时的空间分布变化评价

当样本空间分布如图 4-15 所示，此时是一种特殊情况，尽管 $EI_1=0.6$ ，从数据

来看，重构样本应该保留了原始样本的部分分类性能，虽然重构样本位于边界区域，但是重构样本仅为 2，实际上基本不具备原始样本的分类能力，所以，此时依靠 EI_1 进行评价指标修正，因重构样本中心偏差明显，使得最终评价 $EI=8.5235$ ，合理地表征了样本空间分布的变化。

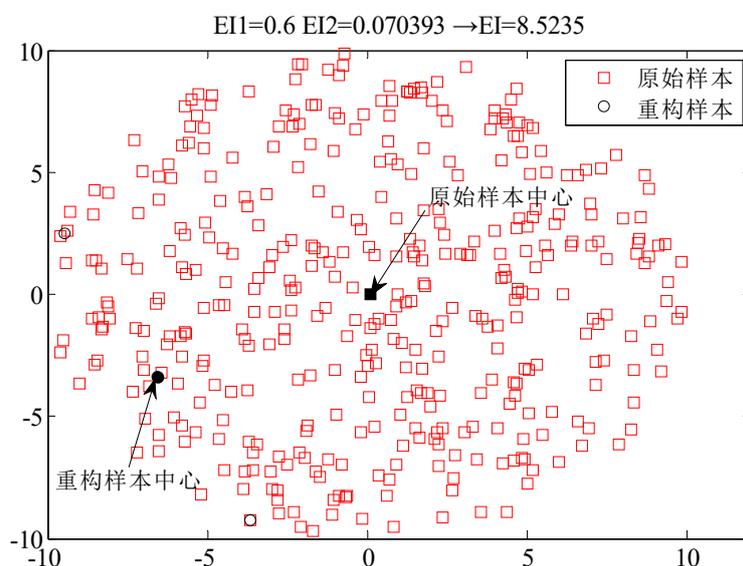


图 4-15 重构样本数为 2 时的空间分布变化评价

通过图 4-8 至图 4-15 的演示，表明空间分布变化指标设计的合理性。较小的 EI_1 ，不一定意味着较好的分类性能，同时较大的 EI_1 ，也不一定意味着较好的空间分布一致性，因此必须既要考虑样本压缩后对分类性能的影响，又考虑样本中心改变对空间分布的影响，这样才能够较全面、准确的衡量空间分布改变状况，为数据压缩提供指导。

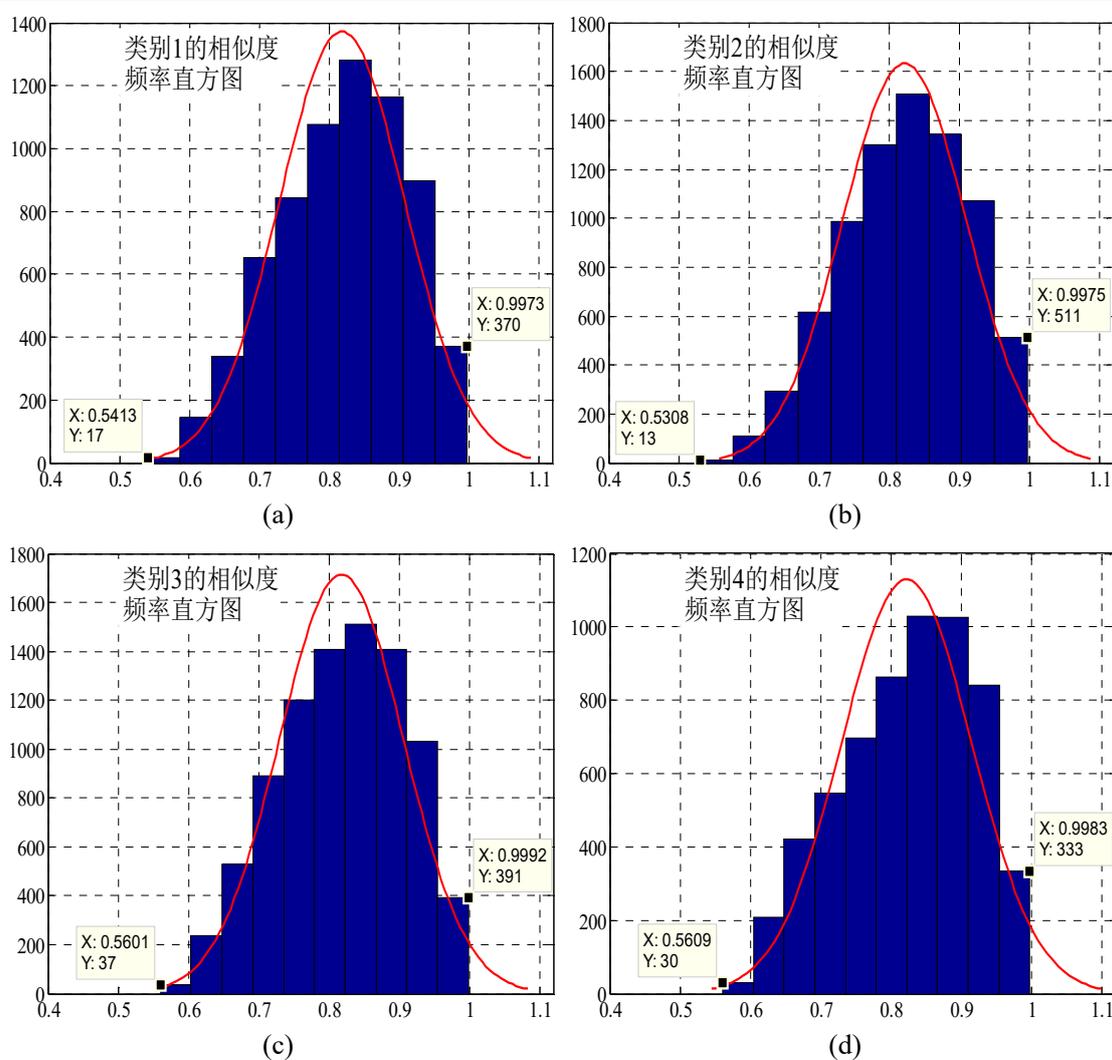
4.4 算法应用及其性能评价

基于图形割裂的粒度计算主要将最为相似的样本生成粒度，并利用粒中心样本 x_{gc} 替代粒中的原始样本，从而起到数据压缩，提高计算效率的效果。同时，由于新重构的样本较好地维持了原始样本空间分布特性，有效避免了因样本压缩而导致的信息丢失，识别准确率过度降低的缺陷。为了测试算法的应用性能，利用第三章的航空发动机气路状态 2 维数据，以及某型装备的 7 种运行状态的高维监控数据来验证算法的应用性能，两种数据集的相关信息如表 4-1 所示。训练样本和测试样本随机确定。利用无量纲相似度计算数据集各类别的相似度矩阵，并利用频率直方图对相似度矩阵进行统计，相似度区间(0, 1]被等分为 10 个子区间，图 4-16 和 4-17 显示了直方图统计的相似度频率分布结果，表明了无量纲相似度计算结果

有效克服了各监控特征属性不同量纲间的影响，证明了无量纲相似度的合理性和有效性，确保了后续粒度的生成。

表4-1 数据集相关信息

特征	数据集	
	气路状态数据 (data1)	状态监控数据 (data2)
维数	2	7
类别数	5	7
训练样本	605 (117+125+132+110+121)	490 (70+70+70+70+70+70+70)
测试样本	200 (40+40+41+39+50)	210 (30+30+30+30+30+30+30)



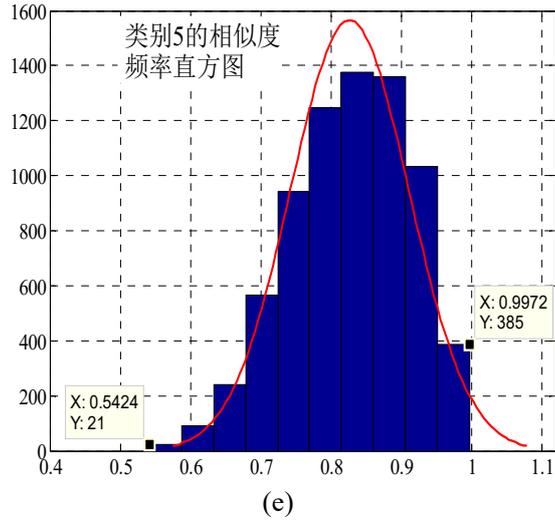
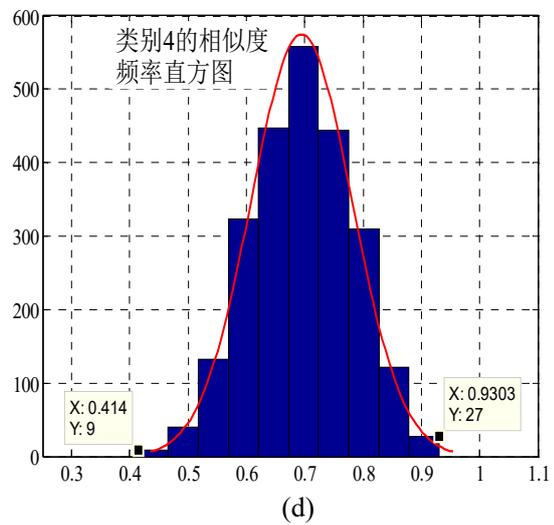
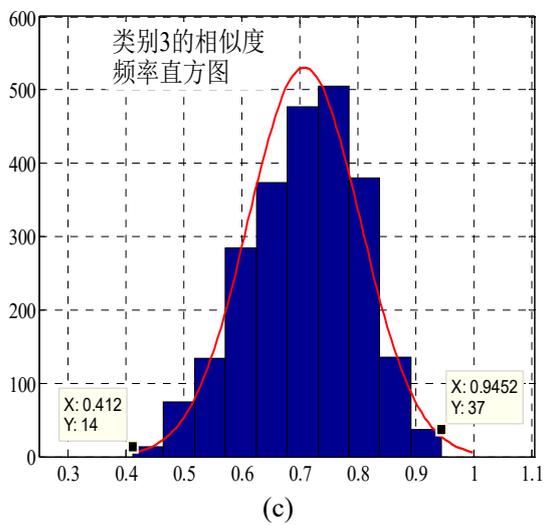
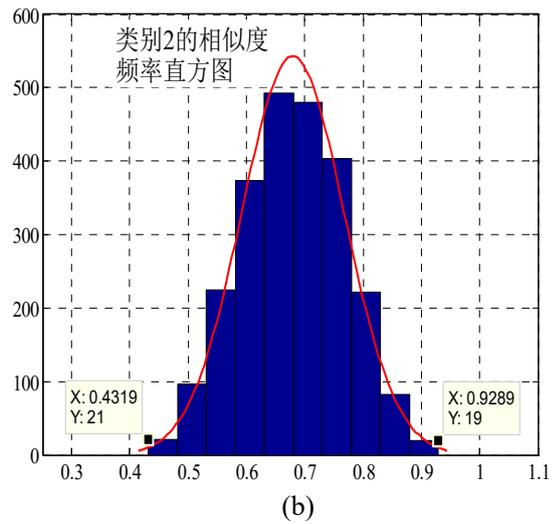
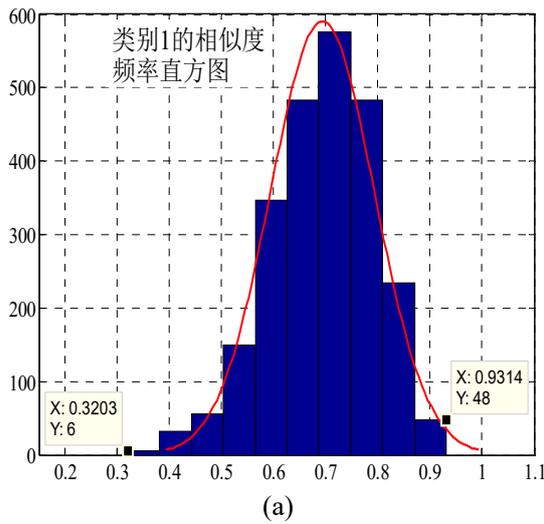


图 4-16 航空发动机气路状态数据相似度频率直方图。(a) 类别 1 相似度频率直方图；
(b) 类别 2 相似度频率直方图；(c) 类别 3 相似度频率直方图；(d) 类别 4 相
似度频率直方图；(e) 类别 5 相似度频率直方图；



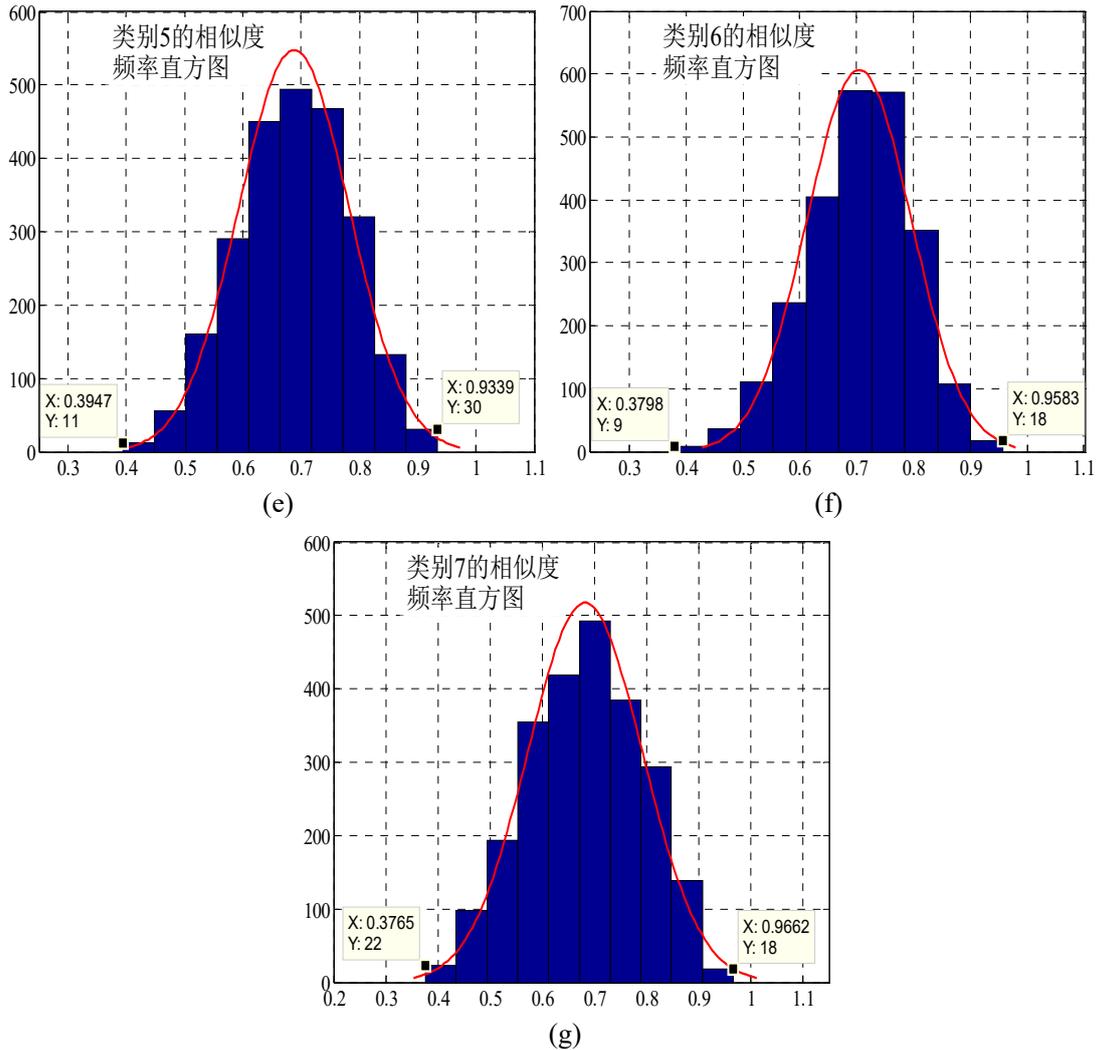


图 4-17 某型设备状态监控数据相似度频率直方图。(a) 类别 1 相似度频率直方图；
 (b) 类别 2 相似度频率直方图；(c) 类别 3 相似度频率直方图；(d) 类别 4 相似度频率直方图；
 (e) 类别 5 相似度频率直方图；(f) 类别 6 相似度频率直方图；(g) 类别 7 相似度频率直方图；

4.4.1 相似度阈值 s 、空间变化评价指标 EI 和样本数量 $|X|$ 间关系

如前分析，不同的相似度阈值 s 会产生粗细不同的粒度，而根据各粒中心样本 \mathbf{x}_{gc} 重构出的新样本，虽起到了数据压缩的效果，但也势必会引起样本的空间分布发生变化。按照图 4-7 显示的 s 、 EI 和 $|X|$ 三者间的关系，将根据不同的相似度阈值产生粒度，并计算当前条件下的 EI 和 $|X|$ ，对 data1 的计算结果如表 4-2 所示，对 data2 的计算结果如表 4-3 所示。表 4-2 和表 4-3 列出了数据压缩的时间开销：时间开销相较于分类算法训练本身而言，是很小的。图 4-18 和图 4-19 直观地显示了随着 s 的减小，重构样本的数量是减小的，而 EI 具有增大的趋势，这与前面的分析

是一致的，进一步证明了各参数设计的合理性，尤其是空间变化评价指标 EI ，可以有效定量评价重构样本的空间分布变化情况。对于二维的气路状态数 $data1$ ，按照重构样本数依次为 425、181、103、60 时，画出与原始样本的空间分布比较图，如图 4-20 至图 4-23 所示。

表 4-2 不同相似度的粒度计算情况($data1$)

类别 1	s	0.9777	0.9577	0.9377	0.9177	0.8977	0.8777	0.8577
	$ X $	75	49	35	26	20	17	11
	EI	0.3593	0.5707	0.6943	0.7737	0.8216	0.8445	0.9060
类别 2	s	0.9741	0.9541	0.9341	0.9141	0.8941	0.8741	0.8541
	$ X $	78	48	30	21	17	14	11
	EI	0.3764	0.6138	0.7614	0.8207	0.8552	0.8834	0.9028
类别 3	s	0.9855	0.9655	0.9455	0.9255	0.9055	0.8855	0.8655
	$ X $	104	68	44	29	25	19	13
	EI	0.2122	0.4811	0.6644	0.7756	0.8096	0.8556	0.8873
类别 4	s	0.9852	0.9652	0.9452	0.9252	0.9052	0.8852	0.8652
	$ X $	87	55	38	28	20	18	12
	EI	0.2019	0.4910	0.6419	0.7363	0.8154	0.8357	0.8757
类别 5	s	0.9780	0.9580	0.9380	0.9180	0.8980	0.8780	0.8580
	$ X $	81	53	34	25	21	17	13
	EI	0.3306	0.5584	0.7143	0.7918	0.8056	0.8334	0.8918
重构样本数		425	273	181	129	103	85	60
时间开销		0.6046s	2.0671s	2.0905s	2.4814s	4.3420s	4.6875s	5.2963s

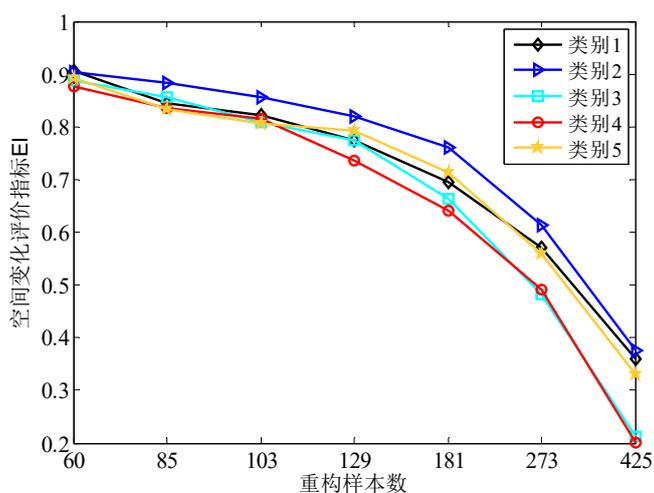
图 4-18 $data1$ 的评价指标随重构样本的变化趋势

表 4-3 不同相似度的粒度计算情况(data2)

类别 1	s	0.9197	0.8897	0.8597	0.8297	0.7997	0.7697	0.7397
	$ X $	69	60	46	32	24	19	12
	EI	0.0143	0.1434	0.2850	0.5407	0.6622	0.7018	0.8427
类别 2	s	0.9344	0.9044	0.8744	0.8444	0.8144	0.7844	0.7544
	$ X $	70	65	56	49	39	29	22
	EI	0	0.0727	0.1909	0.2888	0.4511	0.6259	0.6945
类别 3	s	0.9452	0.9152	0.8852	0.8552	0.8252	0.7952	0.7652
	$ X $	70	62	49	43	34	24	18
	EI	0	0.1164	0.5460	1.0643	0.9573	4.8589	10.0022
类别 4	s	0.9329	0.9029	0.8729	0.8429	0.8129	0.7829	0.7529
	$ X $	70	65	56	43	34	23	18
	EI	0	0.0726	0.2039	0.3790	0.5113	0.7055	0.7815
类别 5	s	0.9330	0.9030	0.8730	0.8430	0.8130	0.7830	0.7530
	$ X $	69	61	56	43	35	29	21
	EI	0.0143	0.1294	0.2029	0.3952	0.5116	0.5932	0.6705
类别 6	s	0.9515	0.9215	0.8915	0.8615	0.8315	0.8015	0.7715
	$ X $	69	66	56	44	38	30	22
	EI	0.0149	0.0608	0.2132	0.5096	0.6044	0.7039	0.8800
类别 7	s	0.9578	0.9278	0.8978	0.8678	0.8378	0.8078	0.7778
	$ X $	69	67	52	41	35	24	19
	EI	0.0195	0.0656	0.7091	3.2591	1.8428	3.9455	13.3183
重构样本数		486	446	371	295	239	178	132
时间开销		0.1094s	0.1406s	0.2813s	0.7344s	2.0625s	2.5938s	3.2188s

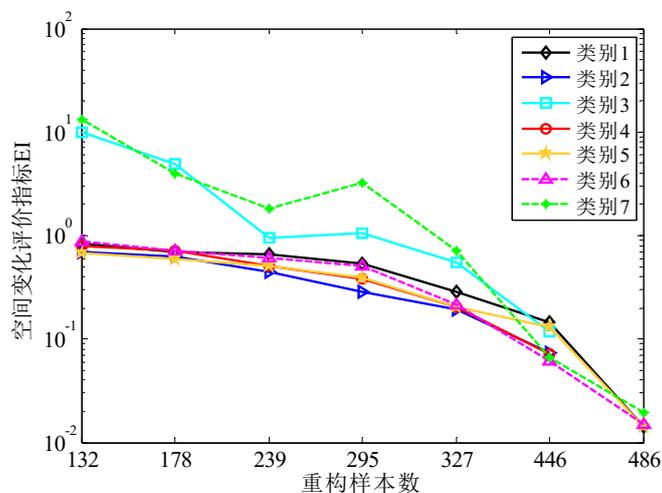


图 4-19 data2 的评价指标随重构样本的变化趋势

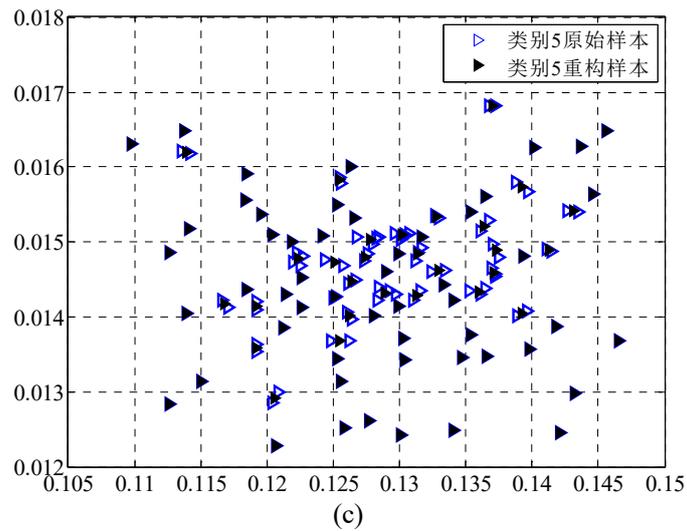
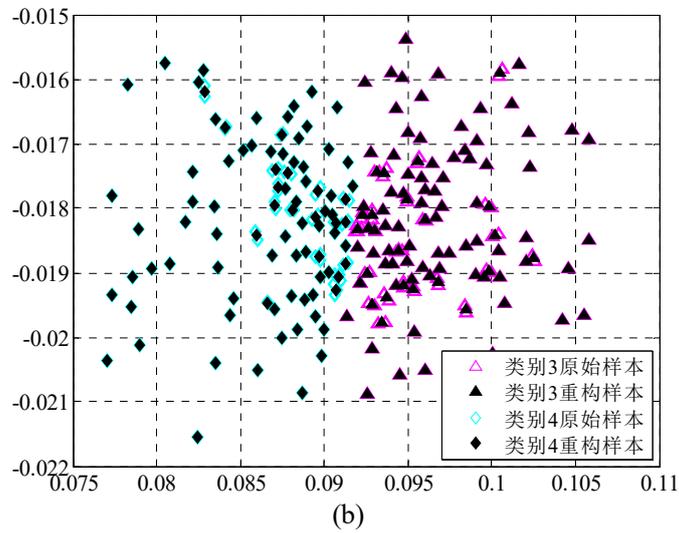
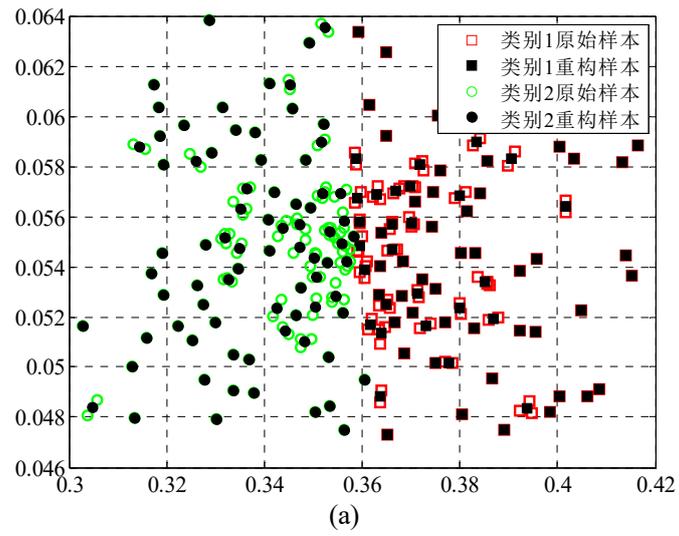
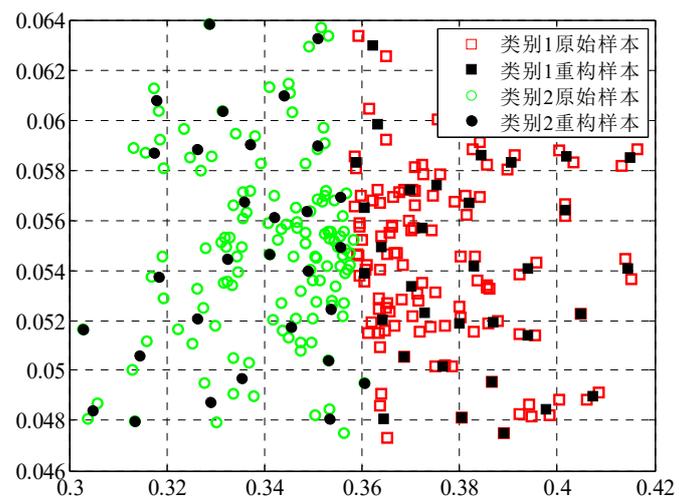
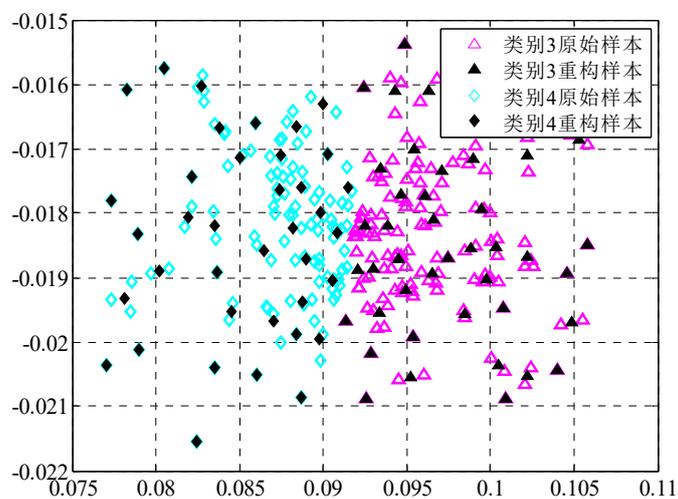


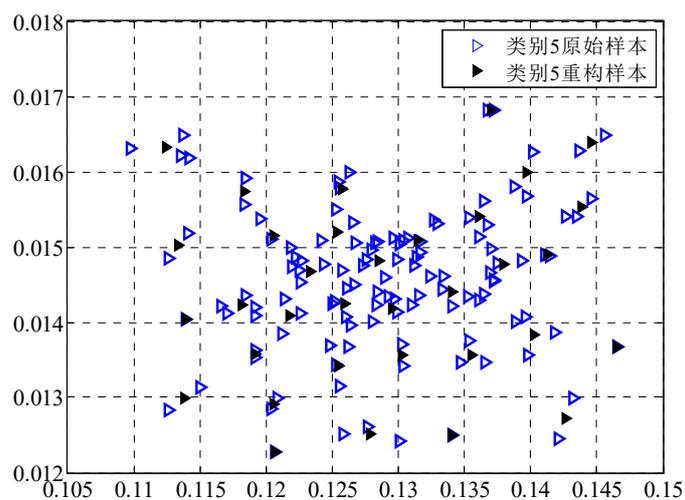
图 4-20 重构样本数为 425 时的空间分布比较。(a) 类别 1 和 2 的空间分布比较；(b) 类别 3 和 4 的空间分布比较；(c) 类别 5 的空间分布比较



(a)

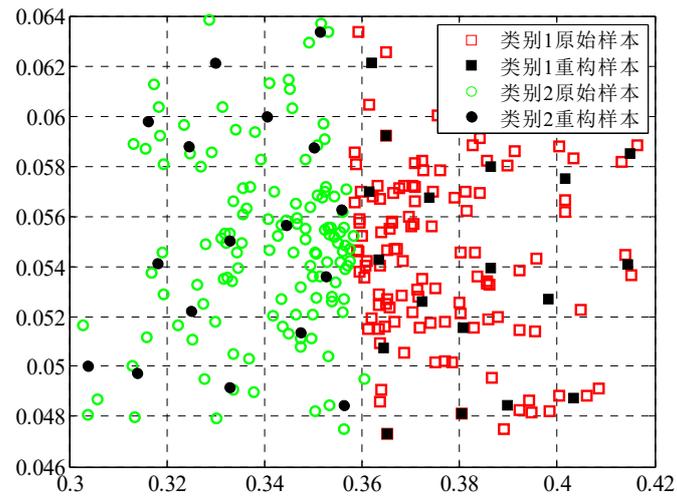


(b)

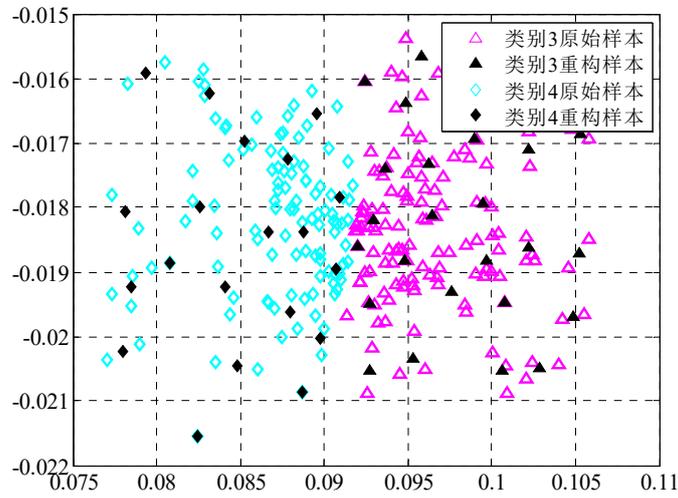


(c)

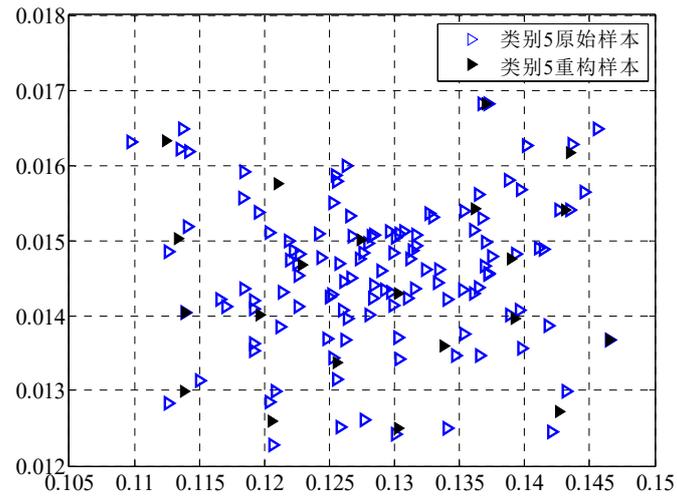
图 4-21 重构样本数为 181 时的空间分布比较。(a) 类别 1 和 2 的空间分布比较；(b) 类别 3 和 4 的空间分布比较；(c) 类别 5 的空间分布比较



(a)



(b)



(c)

图 4-22 重构样本数为 103 时的空间分布比较。(a) 类别 1 和 2 的空间分布比较；(b) 类别 3 和 4 的空间分布比较；(c) 类别 5 的空间分布比较

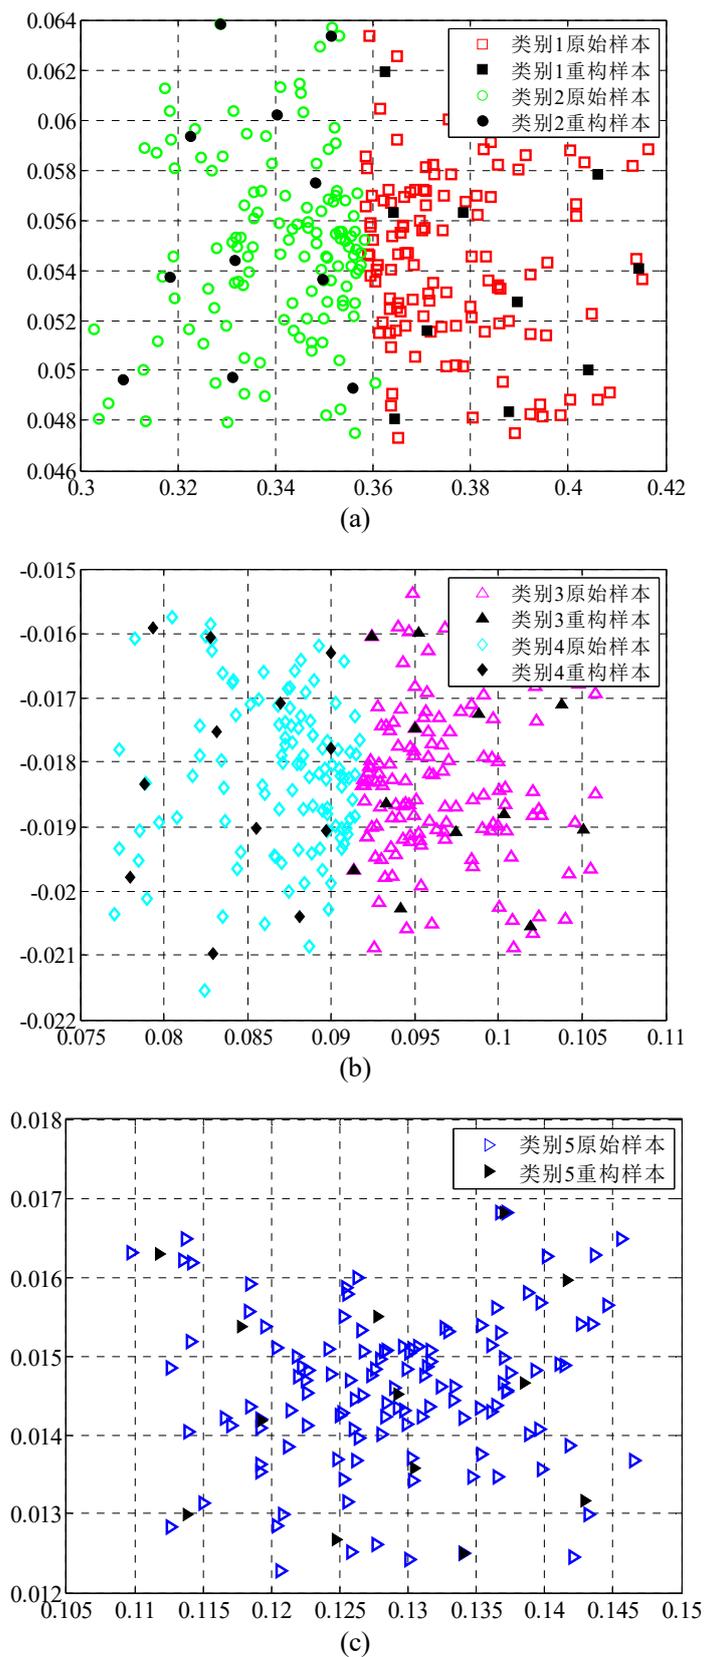


图 4-23 重构样本数为 60 时的空间分布比较。(a) 类别 1 和 2 的空间分布比较；(b) 类别 3 和 4 的空间分布比较；(c) 类别 5 的空间分布比较

图 4-20 至图 4-23 表明了基于图形割裂的粒度计算在数据压缩当中的应用效果。基本上, 在对应的每一相似度阈值条件下, 新样本都是在维持原始样本空间分布的前提下进行重构的, 基本保留了原始样本的分类性能, 因此, 重构样本的空间分布都是接近于原始样本分布的, 且较大的 EI 意味着重构样本越稀疏, 空间分布变化越明显。

4.4.2 基于图形割裂的粒度计算对分类性能的影响

实质上, 对于分类算法, 特别是基于迭代运算的算法, 计算的时间开销往往受训练样本数量的影响, 训练样本数量越大, 时间开销也越大, 反之亦然。但训练样本数量减少以后, 是否对分类准确率产生显著影响。因此, 重构样本的分类性能, 包括分类准确率和时间开销需要进一步验证, 以证明基于图形割裂的粒度计算的合理性和有效性。第 3.2.2 节使用的经典分类算法, 包括单最优点的识别原理, SVM, BP 网络和 LVQ 网络, 将用来检验粒度计算的应用效果, 各算法的参数设定如 3.2.2 所示。

没有免费的午餐(No Free Lunch, NFL)定理已经证明: 任何一种模式分类器都不可能对所有问题有效, 总是存在一定程度上的分类器偏差^[154], 而四类算法的分类原理和运算规则是完全不同的, 因此, 其识别准确率也会存在显著差异。在相同的运算环境下, 图 4-24 和图 4-25 显示了这四类算法针对 data1 和 data2 不同重构数据分类时的时间开销。如图 4-24 和图 4-25 所示, 随着训练样本的减少, 计算的时间开销是减少的, 因此对样本数量进行压缩, 可有效提高计算效率。但对原始样本的压缩, 势必引起样本空间分布的改变, 从而影响对未知样本的识别准确率, 而基于图形割裂的粒度计算是从维持样本空间分布的角度进行数据压缩, 特别是维持样本的边界分布, 因此有利于保持重构样本的分类性能, 图 4-26 和图 4-27 显示了不同重构样本训练条件下的识别准确率。

基于图形割裂的粒度计算对故障数据进行压缩, 如前所述, 其意义在于通过减少重复或者相似的训练样本数量, 从而达到提高训练效率的目的。若 k_{\max} 为最大迭代数, N 表示种群粒子个数, n_{ts} 为训练样本总数, n_c 表示样本的类别数, 实质上数据压缩改变的是 n_{ts} 的大小。MELPSO 算法完成一次识别过程的时间开销与 $(k_{\max} \times N \times n_{ts} \times n_c)$ 是正相关的, 当 k_{\max} 、 N 、 n_c 三者为常数的情况下, 其时间复杂度为 $O(n_{ts})$, 显然, 此时训练样本数量就直接影响到了算法的计算效率。所以, 如图 4-24 和图 4-25 所示, 基于 MELPSO 算法的单最优识别原理的开销基本比 SVM、BP 网络、LVQ 网要高很多, 这是由于 MELPSO 算法的原理所决定的, 但随着样本数量

的减少，这种时间开销差异也逐渐在减小，因此，基于图形割裂的粒度计算对提高 MELPSO 算法识别效率是具有重要意义的。

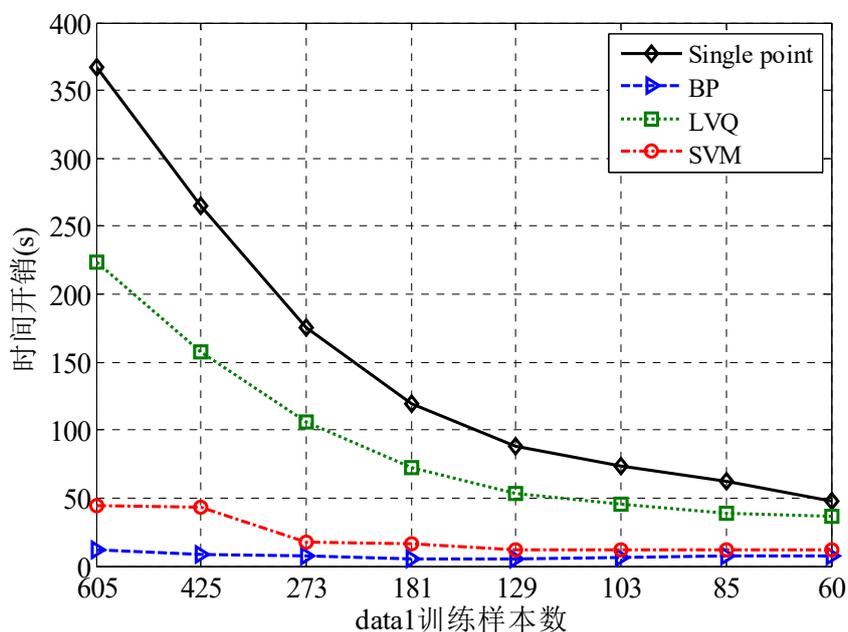


图 4-24 不同重构样本条件下，对 data1 的训练时间开销

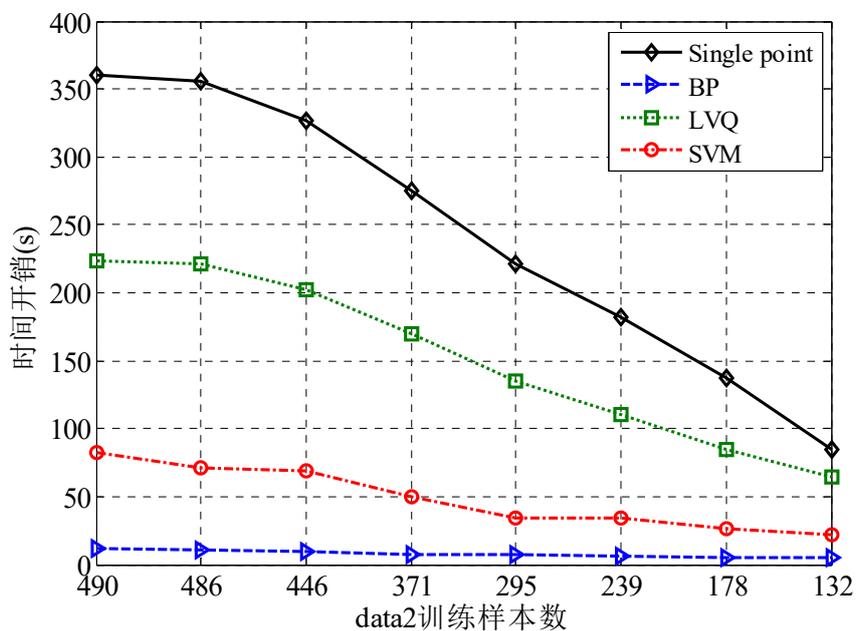


图 4-25 不同重构样本条件下，对 data2 的训练时间开销

如图 4-26 和图 4-27 所示，对 data1 而言，各算法在不同的重构样本训练下，基本维持了分类性能，随着重构样本的减少，识别准确率基本保持不变，甚至某些重构样本条件下，识别准确率还得到提高。对 data2 而言，除了 LVQ 存在识别

准确率较大变化外，其它算法也基本保持着识别准确率不变，而对较小的重构样本，SVM 还表现更佳的分性能，所以，较少的样本并不总意味着较差的分类性能。

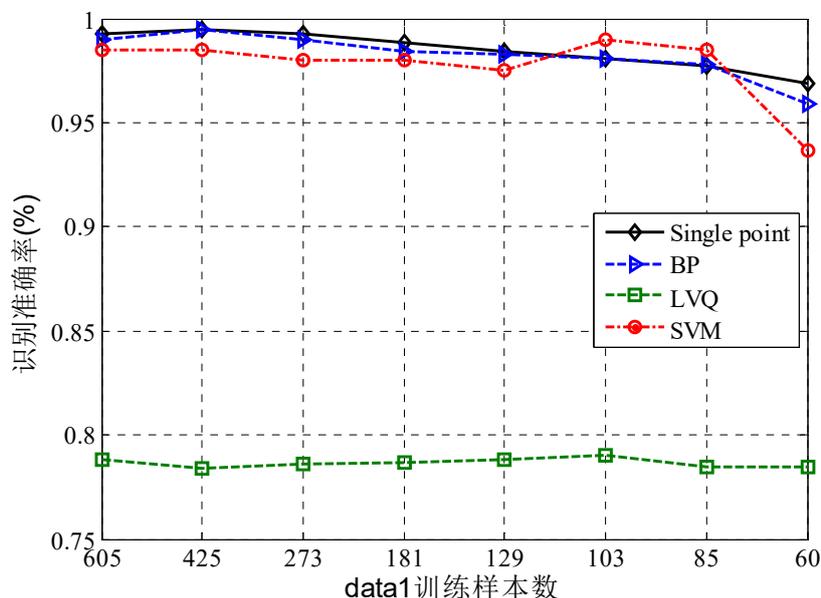


图 4-26 不同重构样本条件下，对 data1 的识别准确率

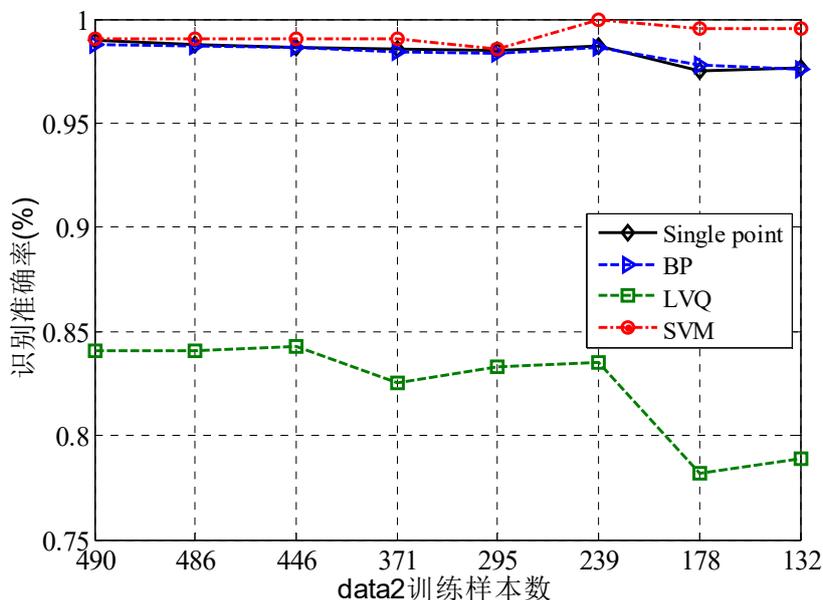


图 4-27 不同重构样本条件下，对 data2 的识别准确率

从计算的时间开销和识别准确率的角度表明了基于图形割裂的粒度计算在数据压缩方面的有效性，能够在基本保持识别准确率不变的前提下，提高算法计算效率，特别是基于 PSO 优化的最优分类点识别原理，进一步增强了各算法的实用

性，为改善排故效率，缩短维修周期提供计算支撑。但也注意到，对某些算法，尽管随着重构样本数量的减少，却并不一定意味着识别准确率显著降低，反而分类性能得到改善，因此针对不同相似度阈值条件下的识别准确率应是下一步关注的重点，以确定获得合适的相似度，保障识别准确率有效提高。

4.5 本章小结

基于 PSO 算法的模式识别方法尽管在分类性能上具有较好的性能，但算法的计算原理导致计算效率不高，为减少算法的时间开销，提出了基于图形割裂的粒度计算方法，形成了从样本到图形，到粒度，再到重构的完整数据压缩过程。图形生成时，无量纲相似度保障了样本间相似度的合理分布，借助于图论的概念，通过完全子图集合和平凡子图集的提取，形成粒度，由于只有满足相似度阈值的样本集合才能形成粒度，因而维持了原始样本的边界分布，使得重构样本基本继承了原始样本的分类性能。基于图形割裂的粒度计算应用于故障模式识别，不仅有利于改善计算效率，同时恰当的相似度阈值条件下的重构样本，还能进一步提高识别准确率。

第五章 基于 MELPSO 算法的航空发动机性能参数预测

航空发动机安全可靠运行, 必须保证发动机所有性能指标都在规定安全范围以内, 包括气路性能、机械性能、电气性能、油路性能等。随着发动机状态监控手段的多样化、精密化和实时化, 准确反映发动机运行状态的众多性能指标被记录, 并根据一定时间序列绘制成趋势图, 供工程技术人员分析、决策, 判断发动机当前运行状态^[170]。而在工程实践中, 除了实时监控发动机健康状态外, 对发动机主要性能指标变化趋势进行预判, 提前预警发动机性能衰退时刻, 并制定科学合理的发动机调配和维护决策, 这不仅对保障发动机出勤率、降低运营成本具有重要意义, 更对保障飞行安全具有直接影响。因此, 利用智能化、网络化方法, 从大量状态监控数据尽早获取发动机趋势信息, 是发动机故障预测与健康管理的重点发展方向。

在航空工业中, 安全意味着对生命最高保障, 而航空发动机是保障飞行安全的关键部件。由于发动机运行在相对严苛的工作环境中, 从而由发动机所引起的航空事故, 在所有事故中占到很高的比例^[171]。因此开展航空发动机的健康状态预测研究对保障飞行至关重要。一些主要的性能参数, 如发动机排气温度、燃油流量、以及高/低压转子转速、滑油中金属屑含量等, 都能直接反应出发动机的运行状态。当今世界著名的发动机制造厂商也相继开发了基于 CBM 的监控软件记录、分析发动机运行状态, 如 GE 公司开发 SAGE, RR 公司开发的 COMPASS, PW 公司开发的 EHM, 这些软件都已记录了各型发动机运行过程中的大量重要的实时性能数据^[10]。根据这些性能趋势数据, 并结合发动机特定的运行环境, 使得对性能趋势的预测成为可能。

随着航空发动机等复杂大型装备的持续发展, 对系统退化机理、耦合关系、不确定性影响等基础研究变得更加复杂, 使得基于物理模型的故障预测与健康管理工作研究进展缓慢, 而基于运行状态数据驱动的方法得到更多关注, 取得了更多应用成果, 准确的预测有助于制定合理的维修计划, 缩短维修周期, 降低维修成本, 保障装备安全可靠运行。在性能预测方面, 现阶段根据研究对象的不同, 国内外更多采用支持向量回归 (Support Vector Regression, SVR)^[69]、自回归滑动平均模型 (Autoregressive Moving Average Mode, ARMA)^[172]、灰色模型 (Grey Model, GM)^[173]、神经网络 (Artificial Neural Networks, ANN)^[174]、卡尔曼滤波 (Kalman Filter, KF)^[175]、粒子滤波 (Particle Filter, PF)^[176]、马尔科夫 (Markov) 模型^[177]等基于数据驱动的方法。刘永建利用改进的神经网络预测航空发动机的性能衰退趋势^[178]; 郑波等利用优化 SVM 预测航空发动机的磨损趋势^[69]; Long 等采用 AR

模型跟踪电池容量的退化趋势,并使用粒子群优化算法来确定 AR 模型的阶数^[179]。

PSO 算法是经典的群体智能优化算法,其主要应用范围集中在优化领域^[180]。在充分利用 PSO 算法优化性能的基础上,近些年,PSO 算法的应用范围也扩展到了模式识别领域,如文本聚类、故障诊断等。而在预测领域的应用,PSO 算法通常作为辅助优化工具对其它预测算法进行优化,从而改进预测性能,Leu 等利用 PSO 算法优化 GM,提高了算法预测精度,对 GM 而言,预测对象适合于具有指数变化趋势的数据,本质上限制了 GM 的应用^[181];郑波等利用改进的 PSO 算法优化 SVR 的核函数参数和罚系数^[69];Long 等利用 PSO 算法来确定 AR 模型的阶数^[179];高海兵等利用 PSO 算法来优化神经网络算法的初始权值,提高算法的稳定性^[156];赵文涛等利用 PSO 算法来优化组合预测模型中各预测方法的取值比例,以改善预测性能,提高预测精度^[67]。而直接将 PSO 算法应用于预测,对 PSO 算法而言是一个新的研究方向,丰富了 PSO 算法的应用范围。尽管如此,改进算法以适应预测的需求成了一个新的研究挑战,例如,对数据的预处理、预测机制、误差评价、适应度函数设计等。而对航空发动机性能趋势数据具有强烈的非线性、不确定性,对其开展预测研究,提高预测精度具有十分重要的意义。本章将重点对预测机理开展研究,以适应预测对象的要求。

5.1 基于预测的适应度函数设计

根据预测对象及预测目的的不同,当前的预测理论和方法主要采用回归预测、时间序列预测、灰色预测、卡尔曼滤波预测、神经网络预测、专家系统预测、优化组合预测等方法,各方法预测机理不同,各有优劣。而针对航空发动机的运行特点,依靠系统建模的卡尔曼滤波预测方法显然难以应用到航空发动机预测中,因为难以建立精确描述航空发动机复杂运行过程的数学模型;而发动机运行过程中的性能参数受多因素影响,样本数据分布规律不明显,呈现较强的非线性特性,回归预测和时间序列预测误差较大;神经网络具有较强的非线性映射能力,动态自适应能力强,适合非线性复杂系统的智能预测,能够较好地反映出装备运行状态的性能趋势与状态信息间的关系,但神经网络的随机权值设定极易导致网络陷入局部最优区域,从而导致预测结果的不确定性^[182]。

航空发动机的气路性能参数可以直接反映出它的运行状态,随着发动机运行时间的增加,性能退化会越发显著,而 EGT,作为一个重要的性能参数,是其它性能指标退化的综合体现,因此,EGT 是判断发动机健康状态的一个主要指标。EGT 监控数据容易受到一些不确定因素影响,比如运行环境、机械因素、飞行状态等,具有非线性、非封闭性和不确定性等特点。传统方法很难准确刻画 EGT 数

据的内在规律。MELPSO 算法具有可靠和稳定的优化性能，基于 MELPSO 算法的预测方法主要思想是充分利用 MELPSO 算法的寻优性能，获得最优的描述输入与输出关系的适应度函数。

适应度函数是优化效果的直接体现，直接用于预测的适应度函数，是对 PSO 算法应用范围的拓展。适应度函数的设计要满足 EGT 等航空发动机性能参数的特点，因此，假设 \mathbf{x} 为 D 维已知输入向量，通过某种函数的映射作用，可获得一个输出预测值 y ，这一过程可表示为： $y=f(\mathbf{x})$ ，此即预测原理，本质上是构造一个非线性映射函数作用于向量 \mathbf{x} ，以描述数据的非线性和不确定性。因此，图 5-1 显示了由 $\mathbf{x} \rightarrow y$ 的映射过程。

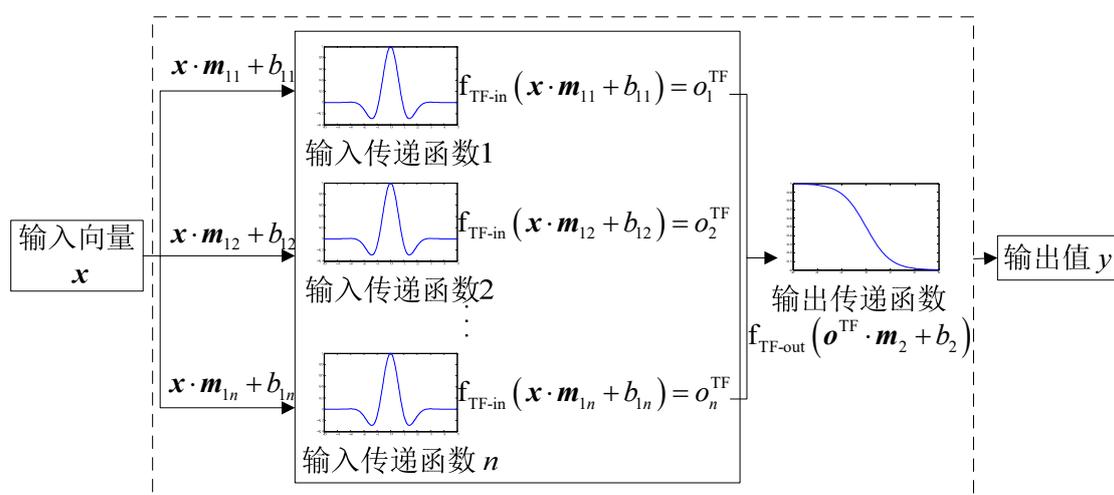


图 5-1 由 $\mathbf{x} \rightarrow y$ 的非线性映射过程

构建 $\mathbf{x} \rightarrow y$ 的映射过程的非线性函数表达如下：

$$f(\mathbf{x}) = f_{\text{TF-out}} \left(\begin{bmatrix} f_{\text{TF-in}}(\mathbf{x} \cdot \mathbf{m}_{11} + b_{11}) \\ f_{\text{TF-in}}(\mathbf{x} \cdot \mathbf{m}_{12} + b_{12}) \\ \vdots \\ f_{\text{TF-in}}(\mathbf{x} \cdot \mathbf{m}_{1n} + b_{1n}) \end{bmatrix}' \cdot \mathbf{m}_2 + b_2 \right) = y \quad (5-1)$$

其中，对 \mathbf{x} 作线性变换 $\mathbf{x} \cdot \mathbf{m}_{1i} + b_{1i}$ ，将其作为输入传递函数 $f_{\text{TF-in}}(\cdot)$ 的输入， $f_{\text{TF-in}}(\cdot)$ 是设计来从不同角度对 \mathbf{x} 进行非线性映射，共有 n 个 $f_{\text{TF-in}}(\cdot)$ 来对 \mathbf{x} 进行输入映射；对 $f_{\text{TF-in}}(\cdot)$ 的输出结果 o^{TF} 进行线性变换 $o^{\text{TF}} \cdot \mathbf{m}_2 + b_2$ 后，再通过输出传递函数 $f_{\text{TF-out}}(\cdot)$ 进行映射，则可描述出 \mathbf{x} 和 y 的关系，从而计算出预测值 y 。表达式中的 \mathbf{m}_{1i} 和 \mathbf{m}_2 分别定义为输入记忆向量和输出记忆向量，而 b_{1i} 和 b_2 则分别定义为输入偏置和输出偏置，其作用为直观地表示出 \mathbf{x} 和 y 间映射关系的系数。确定恰当的 \mathbf{m}_{1i} 和 \mathbf{m}_2 ，

b_{1i} 和 b_2 的值，即建立起 \mathbf{x} 和 y 间的映射关系。通过已知向量 \mathbf{x} 来计算预测值 y 的主要步骤，就是通过 MELPSO 算法不断寻优，获取恰当的记忆向量和偏置的过程。

输入传递函数 $f_{\text{TF-in}}(\cdot)$ 表达式为：

$$f_{\text{TF-in}}(I_i) = \cos(\alpha \cdot I_i) \cdot \exp(-I_i^2/2) \quad (5-2)$$

式中， $I_i = \mathbf{x} \cdot \mathbf{m}_{1i} + b_{1i}$ ，表示输入向量 \mathbf{x} 的第 i 个线性变换， α 为变换系数，通过改变 α 的大小，可改变输入传递函数的波形，图 5-2 给出了 α 不同取值情况下的输入传递函数的波形，其波形具有对称性。尽管不同的波形可以提供多样的映射形式，但要根据数据的输入输出关系，确定恰当的 α 取值，这也是 MELPSO 算法寻优的主要内容之一，保证非线性映射的准确性。而输出传递函数 $f_{\text{TF-out}}(\cdot)$ 表达式为：

$$f_{\text{TF-out}}(\mathbf{o}^{\text{TF}} \cdot \mathbf{m}_2 + b_2) = \frac{1}{1 + \exp(\mathbf{o}^{\text{TF}} \cdot \mathbf{m}_2 + b_2)} \quad (5-3)$$

而 $f_{\text{TF-out}}(\cdot)$ 具有单调性。 $f_{\text{TF-in}}(\cdot)$ 和 $f_{\text{TF-out}}(\cdot)$ 的组合构成了双层映射，确保了对 \mathbf{x} 和 y 非线性关系的刻画。

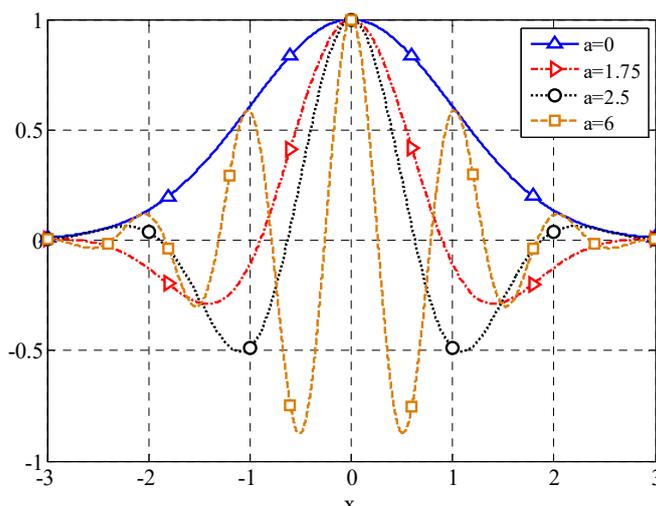


图 5-2 输入传递函数 $f_{\text{TF-in}}(\cdot)$ 的波形图

确定恰当的 \mathbf{m}_{1i} 和 \mathbf{m}_2 ， b_{1i} 和 b_2 的值是准确描述输入和输出映射关系的关键，因此，MELPSO 算法将依靠其突出的寻优能力来确定恰当的参数，保证预测的实行。所以，将设计出新的基于预测原理的适应度函数来指导粒子群进行种群更新。设 \mathbf{x} 为输入向量， y_t 为真实值， y_p 为对应的预测值，在种群更新的过程中，根据输入向量集 \mathbf{X} ，寻优参数将保持调整的状态，直至更新过程结束， $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{nv}]$ ，而 nv 表示输入向量个数。所以，对于输入向量集 \mathbf{X} ，对应有真实状态集 \mathbf{y}_t ，以及预测状态集 \mathbf{y}_p 。均方根误差 (Root Mean Square Error, e_{RMS}) 用来衡量 \mathbf{y}_t 和 \mathbf{y}_p 之

间的偏差, e_{RMS} 越大, 意味着 \mathbf{y}_t 和 \mathbf{y}_p 间偏差越显著, 相反, e_{RMS} 越小, 意味着 \mathbf{y}_t 和 \mathbf{y}_p 间误差越小, 越相似, 特别地, 当 $e_{\text{RMS}}=0$ 时, \mathbf{y}_t 和 \mathbf{y}_p 是完全一致的。同时, 为维持预测值序列和真实值序列变化趋势的一致性, 提出利用相关系数(R)来表征变化趋势的一致性, $R=[-1, 1]$, 若 $R>0$, 则意味着两个向量是正相关的; 若 $R=0$, 则意味着两个向量是不相关的; 若 $R<0$, 则意味着两个向量是负相关的。因此, 较大的 R 表征了 \mathbf{y}_t 和 \mathbf{y}_p 变化趋势的一致性。因此, 对 MELPSO 算法而言, 这是一个多目标优化问题, 要保证有最小的 e_{RMS} , 较大的 R 。为了问题的简化处理, 降低程序运行的复杂度, 将双目标的优化问题通过代数相加的形式转换为最小化的单目标优化问题, 则适应度函数 $\text{fit}(\mathbf{p})$ 为:

$$\begin{aligned} \text{fit}(\mathbf{p}) &= e_{\text{RMS}} - R_{\mathbf{y}_p \mathbf{y}_t} \\ &= \sqrt{\frac{\sum_{i=1}^{nv} (y_{pi} - y_{ti})^2}{nv}} - \frac{\sum_{i=1}^{nv} (y_{pi} - \bar{\mathbf{y}}_p)(y_{ti} - \bar{\mathbf{y}}_t)}{\sqrt{\sum_{i=1}^{nv} (y_{pi} - \bar{\mathbf{y}}_p)^2} \cdot \sqrt{\sum_{i=1}^{nv} (y_{ti} - \bar{\mathbf{y}}_t)^2}} \end{aligned} \quad (5-4)$$

式中: \mathbf{p} 表示一个粒子, 则 \mathbf{p} 的位置组织为:

$$\mathbf{p} = [\mathbf{m}_{11}, \mathbf{m}_{12}, \dots, \mathbf{m}_{1n}, b_{11}, b_{12}, \dots, b_{1n}, \mathbf{m}_2, b_2, \alpha] \quad (5-5)$$

所以, \mathbf{p} 是一个 $n \cdot (D+2) + 2$ 维向量, 这意味着 $n \cdot (D+2) + 2$ 参数需要被优化, 从而刻画出 \mathbf{x} 和 \mathbf{y} 间的非线性关系。记忆向量和偏置通常在 $[-6, 6]$ 区间取值, 而参数 α 在 $[0, 6]$ 区间取值, 以确定 $\text{fit}_{\text{in}}(\cdot)$ 特定的映射形式。

对式(5-4)所示的最小化优化问题, 经过 MELPSO 算法的进化, 粒子群的位置一直保持更新, 使得 $\text{fit}(\mathbf{p})$ 逐渐变小, 从而使得真实序列和预测序列间误差更小, 相关性更大, 变化趋势趋于一致。经过 MELPSO 算法优化的预测算法更适合于描述 EGT 等航空发动机性能数据非线性关系。

5.2 历史数据的组织结构形式

设历史数据为 $[x_1, x_2, \dots, x_D, \dots, x_{ns}]$, 其中 ns 为历史数据总数。为了实现基于 MELPSO 算法的数据预测, 根据之前讨论的预测机理及适应度函数, 历史数据的结构组织如表 5-1 所示。在对算法训练过程中, 每 D 个连续的历史数据构成一个输入向量 \mathbf{x} , 用于预测一个 y_p , 依次类推, 可得 $(ns-D)$ 个输入向量用于训练适应度函数, 所以有 $nv = ns - D$ 。而在预测过程中, 众所周知, 需要被预测的值一直都是未知的, 仅仅是已知的值才能用来预测未知值, 例如, 当要预测 y_{m+1} 时, 则要用到最后的 D 个连续历史数据, 但要预测 y_{m+1} 以后的数据时, 连续的历史数据已不

能形成一个完整的 D 维输入向量，此时，之前的预测值就要递补进去，从而出现在输入向量的尾端，形成一个新的完整的 D 维输入向量，例如，当要预测 y_{nv+2} 时，第一个预测值 y_{nv+1} 就要加入进输入向量，依次类推，才能构成一个完整的测试样本集，这样预测过程才是符合逻辑的，预测才能够实现。

表 5-1 历史数据的组织形式

	输入向量 \mathbf{x}	真实值 y_t	预测值 y_p
训练样本	$\mathbf{x}_1=[x_1, x_2, \dots, x_D]$	x_{D+1}	y_1
	$\mathbf{x}_2=[x_2, x_3, \dots, x_{D+1}]$	x_{D+2}	y_2
	$\mathbf{x}_3=[x_3, x_4, \dots, x_{D+2}]$	x_{D+3}	y_3
	\vdots		
	$\mathbf{x}_{nv-1}=[x_{ns-D-1}, x_{ns-D}, \dots, x_{ns-2}]$	x_{ns-1}	y_{nv-1}
	$\mathbf{x}_{nv}=[x_{ns-D}, x_{ns-D+1}, \dots, x_{ns-1}]$	x_{ns}	y_{nv}
测试样本	$\mathbf{x}_{nv+1}=[x_{ns-D+1}, x_{ns-D+2}, \dots, x_{ns}]$		y_{nv+1}
	$\mathbf{x}_{nv+2}=[x_{ns-D+2}, \dots, x_{ns}, y_{nv+1}]$		y_{nv+2}
	$\mathbf{x}_{nv+3}=[x_{ns-D+3}, \dots, x_{ns}, y_{nv+1}, y_{nv+2}]$		y_{nv+3}
	$\mathbf{x}_{nv+4}=[x_{ns-D+4}, \dots, x_{ns}, y_{nv+1}, y_{nv+2}, y_{nv+3}]$		y_{nv+4}
	$\mathbf{x}_{nv+5}=[x_{ns-D+5}, \dots, y_{nv+2}, y_{nv+3}, y_{nv+4}]$		y_{nv+5}
	\vdots		

假设有 np 个未知数据需要预测，则要求输入向量的维数应满足 $D \geq np$ ，这是为了保证至少有一个历史数据参与到预测当中，避免出现以未知数据预测未知数据的情况。同时，为了控制寻优参数个数，降低计算时间，简化适应度函数结构，本文将 D 设置为大于 np ，一般取 $D=np+1$ 。输入向量维数确定以后，所需的输入传递函数 $f_{TF-in}(\cdot)$ 个数由如下公式确定：

$$n = \text{round}\left(\sqrt{D^2 + D+1} + D\right) \quad (5-6)$$

式中， $\text{round}(\cdot)$ 是一个四舍五入函数，确保 n 为整数。这样可以依据预测对象来确定整个历史数据的结构组织形式，当然，也可根据数据预测结果对数据的结构组织形式进行调整。此时，需要寻优的参数个数为 $n \cdot (D+2)+2$ ，假设 $D=6$ ，则需要优化 106 个参数，这显然是一个复杂的多模态问题求解，MELPSO 算法因优异的寻优能力，能够保证求解值趋于全局最优区域。

同时为了压缩解空间的大小，提高粒子群搜索效率，增大寻获全局最优区域的概率，历史数据集要求归一化到 $[0, 1]$ 区间，归一化后，获得的新的历史数据 x' 等于如下表达式：

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5-7)$$

式中： $x_{\min} = \min([x_1, x_2, \dots, x_{ns}])$ ，而 $x_{\max} = \max([x_1, x_2, \dots, x_{ns}])$ 。相反地，由归一化后的历史数据计算所得的预测值 y'_p 也需要被转换成逆归一化后的值 y_p ，转换过程如下所示：

$$y'_p = y_p \cdot (x_{\max} - x_{\min}) + x_{\min} \quad (5-8)$$

最终，基于 MELPSO 算法的预测流程图如图 5-3 所示，其中，MELPSO 算法基本参数设置为：种群数量设置为 60，最大迭代数设置为 100，导师粒子数设置为 5。

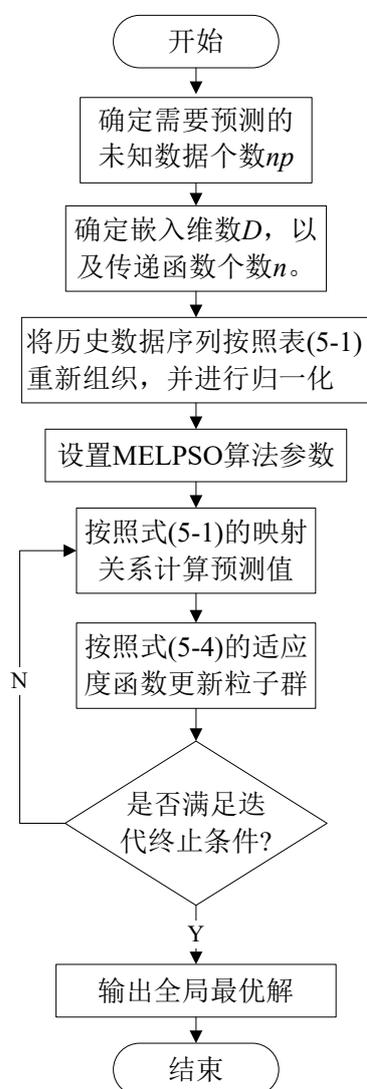


图 5-3 基于 MELPSO 算法的预测流程图

5.3 航空发动机性能参数预测

5.3.1 基于 MELPSO 算法的预测性能验证

起飞阶段时，航空发动机通常都会在最大功率状态下工作，此时 EGT 是最高的，此时 EGT 与 EGT 红线的差值定义为 EGT 裕度(EGT Margin, EGTM)，而 EGT 红线是指在航空发动机型号合格证里规定的航空发动机允许的起飞 EGT 最大值^[178]。因此，EGTM 的大小反映了发动机的整机性能，是衡量发动机性能衰退的主要指标。一般而言，随着发动机运行时间的增加，整体性能呈现出衰退的趋势，因此，如果能够准确预测 EGTM 的变化趋势，可以向维修人员提供重要的维修决策依据，保障旅客生命财产安全。所以选择某型航空发动机起飞阶段的 EGTM 为预测对象，以验证基于 MELPSO 算法的预测性能。本节中，预测将仅依靠 EGTM 的历史数据序列进行，而不考虑其它的影响因素。图 5-4 显示了由 114 个数据所构成的 EGTM 序列，数据序列是非线性的，呈现出衰退的趋势。其中将前 108 个数据作为历史数据，用于预测余下的 6 个数据，则嵌入维数 $D=7$ ， $n=15$ ，共需要优化 137 个参数。

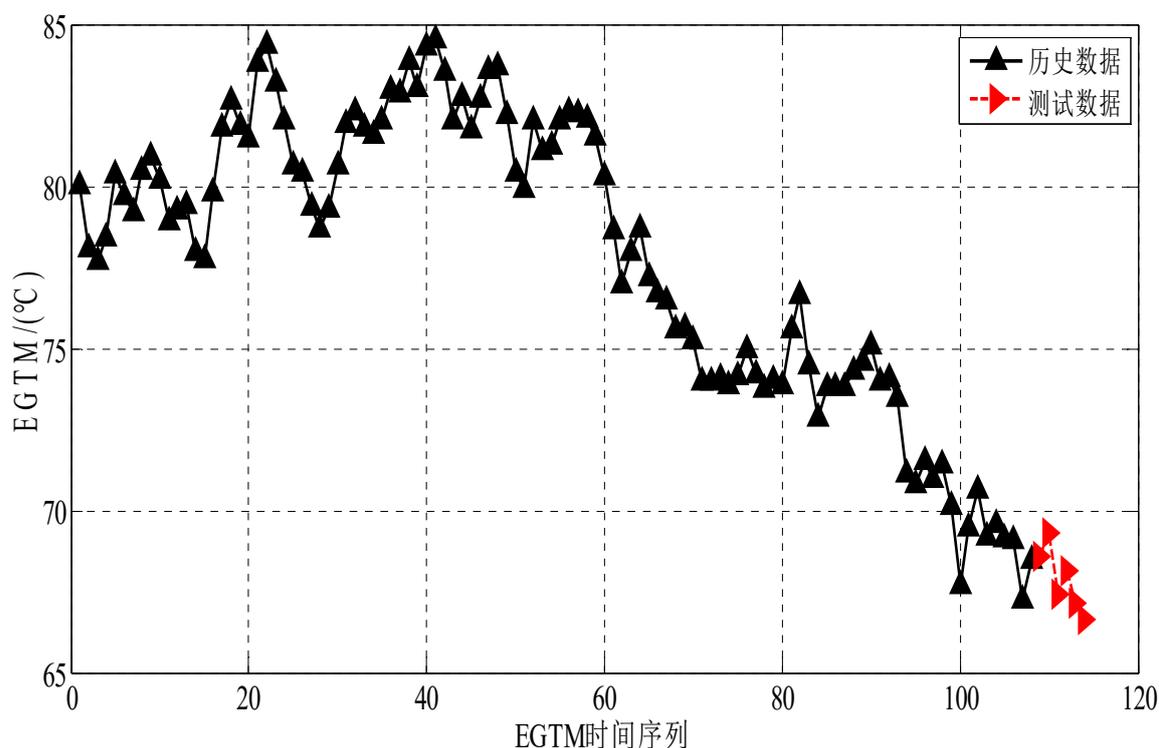


图 5-4 起飞阶段 EGTM 时间序列

为了验证 MELPSO 算法的预测性能和寻优能力，连续在相同条件下重复对数据执行 10 次预测。表 5-2 显示了 MELPSO 算法经过 10 次训练以后，对历史数据

拟合和对测试数据预测的比较。

表 5-2 预测性能验证表

实验 序号	历史数据				测试数据		
	e_{RMS}	R	e_{MR}	适应度值	e_{RMS}	R	e_{MR}
1	0.7464	0.9865	0.0076	-0.2401	1.0748	0.2847	0.0144
2	0.7045	0.9900	0.0070	-0.2855	0.9929	0.3248	0.0108
3	0.5785	0.9925	0.0058	-0.4140	0.8498	0.7971	0.0104
4	0.8043	0.9865	0.0082	-0.1822	0.7886	0.9491	0.0096
5	0.8760	0.9830	0.0085	-0.1070	0.7834	0.6342	0.0103
6	0.6073	0.9925	0.0061	-0.3852	1.0108	-0.2659	0.0129
7	0.7276	0.9881	0.0072	-0.2605	0.8161	0.8948	0.0099
8	0.5372	0.9936	0.0055	-0.4565	0.8097	0.7372	0.0103
9	0.6216	0.9918	0.0064	-0.3702	1.1072	0.4315	0.0130
10	0.8051	0.9853	0.0078	-0.1803	1.3230	-0.5054	0.0145
11	0.5696	0.9935	0.0058	-0.4239	0.8096	0.8846	0.0103

如表 5-2 所示, 适应度函数值, e_{RMS} , R , 平均相对误差 (Mean Relative Error, e_{MR}) 也列于其中, MELPSO 算法求解所得 m_{1i} 和 m_2 , b_{1i} 和 b_2 , α 在重构历史数据时, 都有较低的拟合误差, 所有变化趋势都是正相关, 且接近 1, 而对测试数据进行预测时, e_{RMS} 基本都维持在一个较低的范围。另一方面, 对高维参数的预测, MELPSO 算法从不同的空间方向趋近于全局最优区域会导致寻优结果的差异性, 因此各次计算产生的适应度函数也是存在差异性, 此外, 表 5-2 所示的比较结果表明对历史数据拟合较优的结果不一定对应有较优的预测结果。在这种情况下, 尽管整体的预测误差相对较低, 还是采用将多次预测结果的平均值作为最终的预测输出, 以进一步降低算法随机性对预测结果产生的影响。因此, 在表 5-2 中, 除了 10 次的预测结果外, 实验 11 是由 10 个拟合结果和预测结果的平均值所表征的性能指标。

在 10 次实验中, 将具有最高和最低适应度的计算结果同原始历史数据和实验 11 的计算结果进行比较, 比较结果如图 5-5 所示。同时将 11 个预测结果和测试数据进行比较, 比较结果如图 5-6 所示。显然, 图 5-5 和图 5-6 反映了基于 MELPSO 算法的计算结果能够很好地描绘原始数据的变化趋势, 与原始数据相比较, 具有相对较低的预测误差, 意味着预测结果能够指导实际工程应用, 为维修决策提供参考。

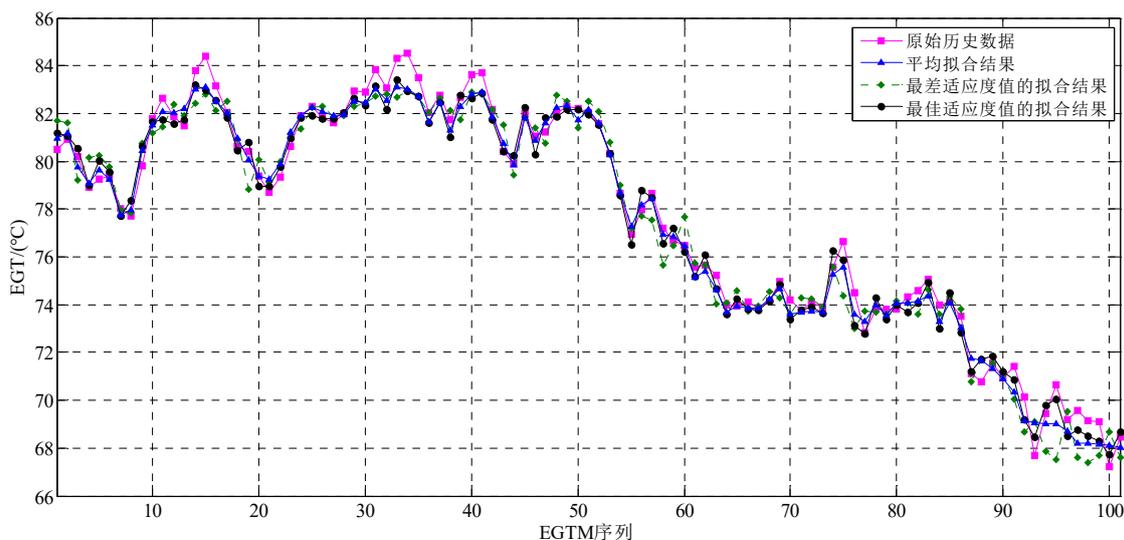


图 5-5 历史数据拟合结果比较

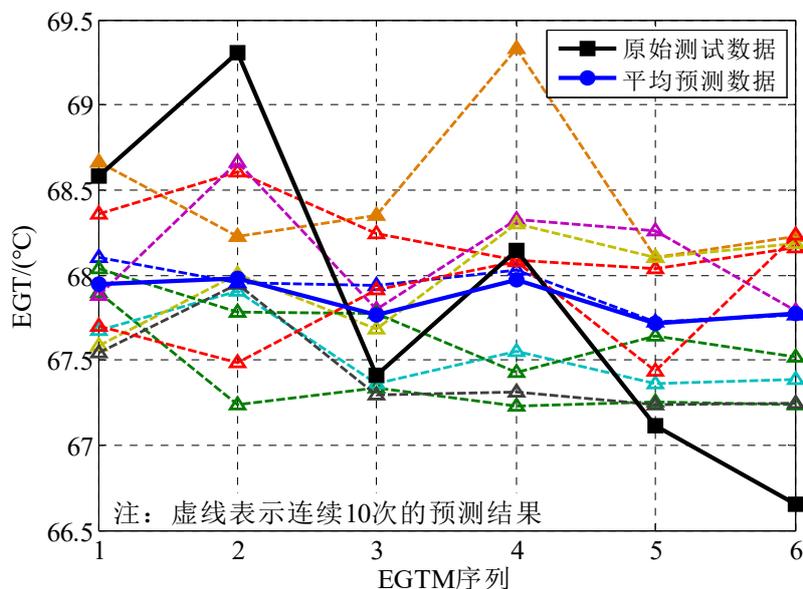


图 5-6 测试数据预测结果验证

图 5-7 显示了某一次计算是适应度函数 $fit(\mathbf{p})$ 的变化情况，尽管是一个多目标的优化问题，通过转化，变成了一个最小化单目标优化问题，简化了问题的求解过程，但各个优化目标依然按照预定的优化方向进行， e_{RMS} 是逐渐减小的，数据的均方根误差随着粒子群的更新不断减小，而 R 是逐渐增大的，数据间的相关性不断增大，使得拟合数据与历史数据的变化趋势基本一致，图 5-7 证明了适应度函数设计的合理性。

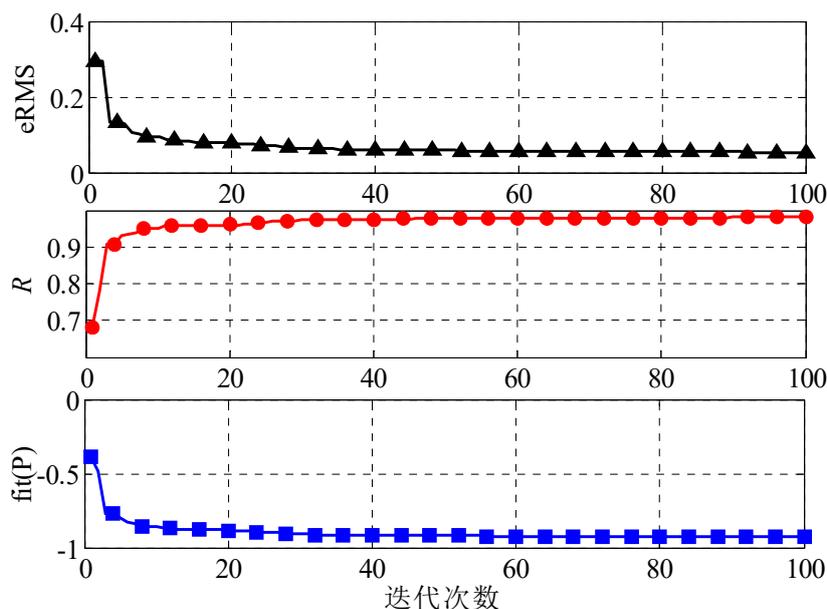


图 5-7 MELPSO 算法适应度函数变化

5.3.2 预测性能比较

基于 MELPSO 算法的预测性能在 5.3.1 节中得到验证, 预测结果表明了算法可以为航空发动机维修决策提供有效参考。在最近的研究中, 一些典型的、成熟的预测算法也广泛地应用到各类实际问题中。对于航空发动机性能预测而言, 预测精度是非常重要的。因此, 将本文所提的预测算法同其它算法进行比较, 对进一步证明本文的研究价值是很有必要的。考虑到 EGT 数据序列的非平稳性、非线性、不确定性, 将基于时间序列预测的 ARMA 模型^[183], 基于人工智能的 BP 神经网络模型^[184], 以及基于结构风险最小化的 SVR 算法^[69]与本文所提算法进行比较。根据[184]确定 BP 网络的网络结构确定, 而 SVR 算法核参数的确定则依据[69]。ARMA 模型的计算结果不受随机性影响, 该算法仅计算一次。因初始权重和核参数随机确定, 导致 BP 网络和 SVR 算法的计算结果也存在差异性, 这两种算法因与 MELPSO 算法一样, 易受到参数随机性影响, 因此也执行连续 10 次运算, 以检验算法预测性能。表 5-3 对比了各算法在 10 次计算过程中最佳、平均和最差的预测结果。

表 5-3 表明: 由于各算法的预测原理各不相同, 因此预测结果具有差异, ARMA 算法预测误差最大, 变化趋势为负相关; BP 网络的非线性映射较强, 对 EGTM 的预测误差相对较优, 变化趋势为正相关; SVR 算法预测稳定性相对较好, 但对历史数据拟合和对测试数据预测误差较大; 相比较而言, MELPSO 算法预测结果相对较优, 也表现出较好的稳定性。而图 5-8 直观地比较了各算法平均预测结果, 显

示出了基于 MELPSO 算法的预测优势。而这一优势正是依赖于 MELPSO 算法较强的全局寻优能力，相对于 BP 网络采用的梯度下降的优化过程，更能够在复杂、高维搜索空间中获得相对较优的参数寻优结果，能够更准确地映射出输入和输出样本间的关系。

表 5-3 基于时间序列的预测性能比较

算法		测试数据		
		e_{RMS}	R	e_{MR}
ARMA	预测结果	3.1950	-0.1160	0.0404
BP	最佳预测结果	0.8363	0.7721	0.0112
	平均预测结果	1.0071	0.5431	0.0131
	最差预测结果	2.1327	0.1271	0.0264
SVR	最佳预测结果	2.0407	-0.6871	0.0265
	平均预测结果	2.6803	-0.7932	0.0363
	最差预测结果	3.5462	-0.8154	0.0494
MELPSO	最佳预测结果	0.7886	0.9491	0.0096
	平均预测结果	0.8096	0.8846	0.0103
	最差预测结果	1.3230	-0.5054	0.0145

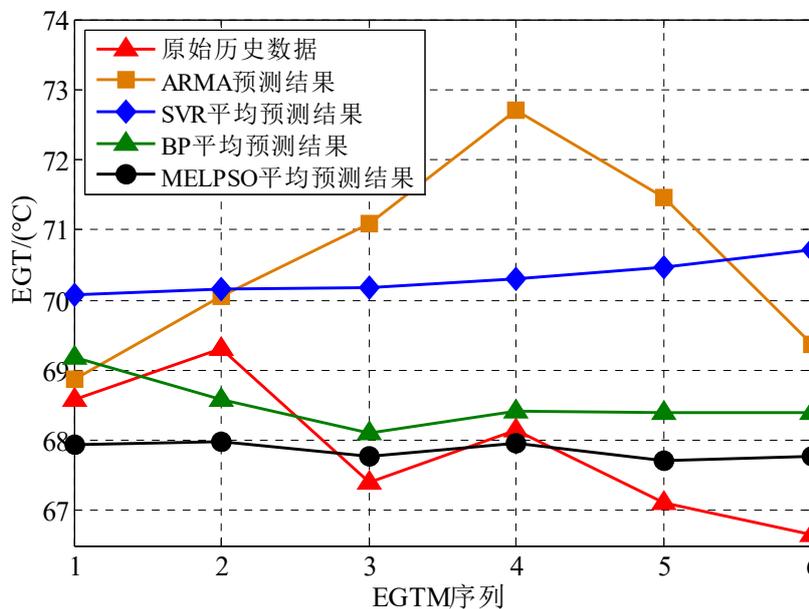


图 5-8 各算法预测结果比较

对于 EGT M 数据，如图 5-4 所示，变化趋势表现出了较强的非线性和不确定性，仅依靠时间序列的方式进行预测，而不考虑其它运行、环境、机械等影响因

素, 各算法的鲁棒性相对都较差, 预测结果波动性明显, 尤其对 MELPSO 算法, 寻优参数达到 137 个, 面对这样的高维搜索空间, 对任何优化算法都是挑战, 难以精确获得其全局最优解。但就预测精度而言, 相对于其它算法, MELPSO 算法总体表现出了较优的寻优性能, 从侧面进一步证明了 MELPSO 算法设计的科学性和合理性, 而且预测数据的变化趋势也基本符合测试数据的趋势变化。因此, 从航空发动机维修工程角度观点看, 基于 MELPSO 算法的预测方法是一个可靠的预测算法, 对判断发动机性能衰退, 制定合理维修计划, 保障飞行安全具有重要参考意义。

5.4 基于影响因素的 EGTM 预测

如 5.3.2 节分析, 由于 EGTM 的变化呈现出较强的非线性和不确定性特征, 仅依靠时间序列的方法进行趋势预测, 因数据所暗含的规律性较差, 导致各算法的计算稳定性和鲁棒性较差, 如图 5-6 所示, 算法预测结果偏差明显, 通过多次计算取平均值作为预测结果输出, 以降低算法随机性的影响。实质上, 造成 EGTM 变化特点的原因, 主要是航空发动机运行过程的不确定性, 不同的飞行环境、发动机机械因素、飞行状态等都会影响到 EGTM。因此, 对 EGTM 进行预测时, 应将影响 EGTM 变化的因素作为预测输入变量, 以提高预测的科学性和合理性。

以某型航空发动机为例, 构建出如式(5-9)所示的以影响因素为输入变量的 EGTM 预测函数:

$$y_{\text{EGTM}} = f(\mathbf{a}) \quad (5-9)$$

其中: $f(\cdot)$ 为从影响因素到 EGTM 值的映射函数, \mathbf{a} 为由影响因素所组成的向量。而在起飞过程当中, 影响 EGTM 的因素主要有: 起飞机场的温度条件、起飞机场的高度、起飞速度、燃油流量、高/低压转子转速、振动情况, 以及其它一些性能参数。在实际问题当中, 很多参数虽然对预测 EGTM 有重要作用, 但却是不可取的, 因为对于预测问题, 预测即意味着确定未知的状态, 例如, 转子转速对 EGTM 影响很大, 转速很高, 油耗越大, 排气温度自然越高。但通过发动机自身的监控, 如果转速能够测得, EGTM 自然也能测得, 这就失去了预测的意义。因此在确定影响因素时, 既要充分考虑影响因素的作用, 更要考虑预测问题的逻辑关系。而在众多的影响因素当中, PA 和 OAT 是在飞行前就可以提前获知的, 且是一个相对较准确的值, 因而将 PA 和 OAT 加入影响因素向量, 但这两个因素没有将起飞状态联系起来, 考虑到在众多的飞行参数中, 马赫数 M 是可控制的, 或者说是可提前决定的, 而且 M 确定以后, 由于发动机参数间的耦合性, 相应的其它参数也基

本被表征出来，因此将 M 也加入影响因素向量中。所以设 $\mathbf{a}=[OAT, PA, M]$ ，则式(5-9)可写为： $y_{EGTM}=f([M, OAT, PA])$ 。在起飞之前，通过确定起飞机场的温度、高度等信息，飞行员大致的起飞速度控制，通过映射函数的作用，即可预测出 EGTM。

但注意到式(5-9)没有考虑时间的影响，这又会出现一个不符合逻辑的问题，假如，飞机在某机场起飞，测得的 EGTM 为 t_1 ，当经过较长一段时间以后，测得的 EGTM 为 t_2 ，按照 \mathbf{a} 进行映射，若 OAT 基本不改变，此时 $t_1=t_2$ 。但随着飞行起降循环的增加，EGTM 是呈现下降趋势的，此时 $t_1 \geq t_2$ 。因此，还应将飞行起降循环次数 ci 加入 \mathbf{a} ，以表征时间对 EGTM 的影响。尽管在同一机场起飞，OAT 也基本一致，但在第 1 个起降所测得的 EGTM，和第 n 个起降所测得的 EGTM，是存在差异的。最终，构建出的映射函数为：

$$y_{EGTM} = f([M, OAT, PA, ci]) \quad (5-10)$$

式(5-10)在预测 EGTM 时，和之前的 EGTM 值没有关系，而仅和当前的运行环境、飞行速度状态、以及起降循环次数有关。以某型航空发动机冬季运行为例，其 EGTM 数据如图 5-9 所示。

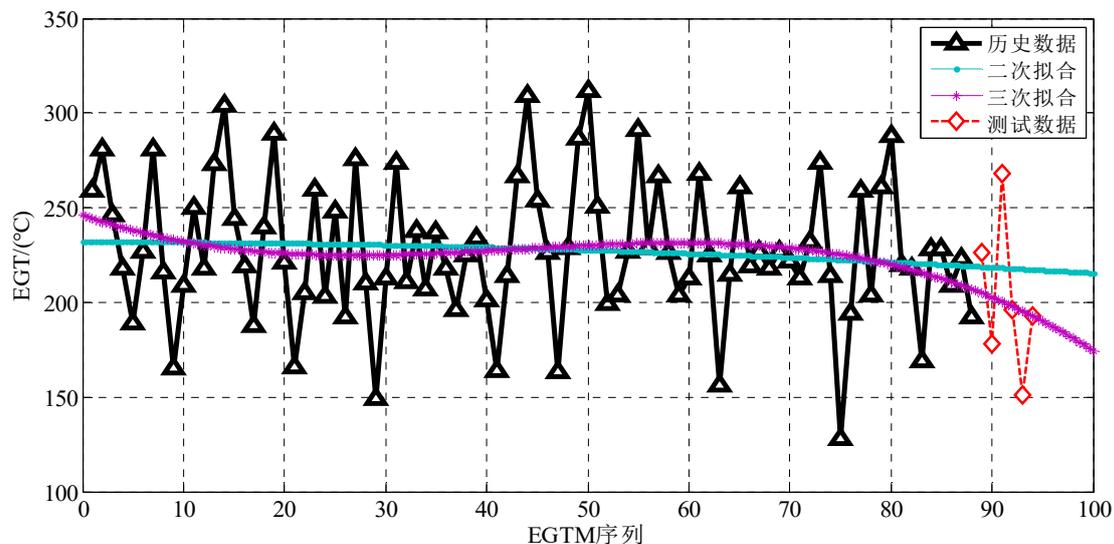


图 5-9 起飞阶段 EGTM 序列

图 5-9 分别给出了二次和三次拟合的曲线，拟合曲线显示了该型发动机的 EGTM 随着飞行循环次数的增加，EGTM 呈现出衰退趋势。若仅依靠时间序列的方式预测后 6 个循环的 EGTM，依然利用连续 10 次预测结果的平均值来衡量算法的预测性能，预测结果的比较如表 5-4 所示。表 5-4 表明：ARMA 的 e_{MR} 最小，而基于 MELPSO 算法的预测方法 e_{RMS} 和 R 最优。图 5-10 显示了 4 种算法平均预测

结果的比较图。因此，表 5-4 和图 5-10 都证明了仅依靠时间序列的方式进行预测，预测结果的偏差相对还是比较大的，各个算法的稳定性也相对表现较差。

表 5-4 平均预测结果比较

算法	测试数据		
	e_{RMS}	R	e_{MR}
ARMA	35.3880	0.3992	0.1519
BP	41.8386	0.2184	0.1901
SVR	46.9889	0.0338	0.2197
MELPSO	35.2715	0.7002	0.1726

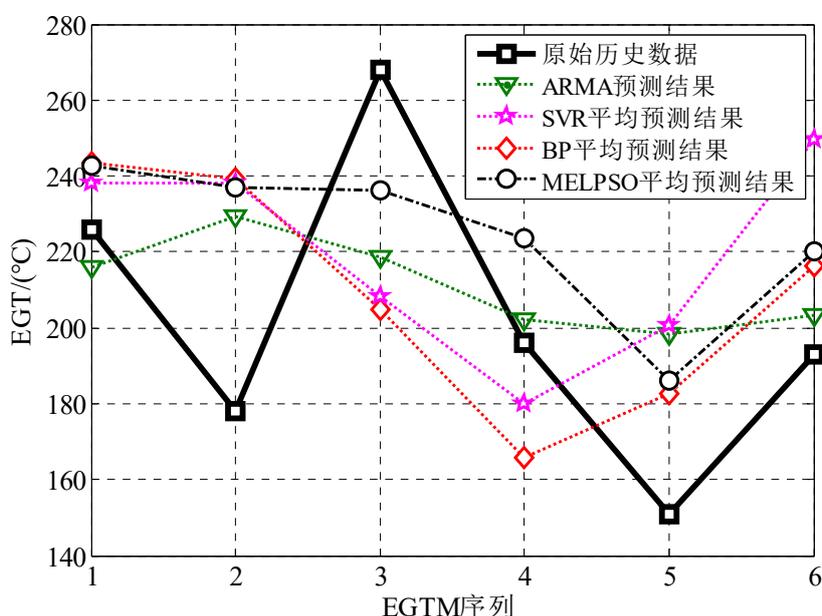


图 5-10 各算法预测结果比较

按照式(5-10)的方式进行 EGTM 预测，相关的影响因素数据如表 5-5 所示。从 89 次起降到 94 次起降之间对应的 EGTM 是需要预测的。因 ARMA 算法仅是关于时间序列的预测方法，因此仅利用 BP 网络和 SVR 算法进行比较，同样采用连续计算 10 次的方式，表 5-6 显示了各算法最佳预测结果、平均预测结果、最差预测结果的比较。

表 5-6 表明：采用基于影响因素的预测方法后，较表 5-4 所示的预测结果，各算法的预测准确性大幅提高，各算法的稳定性和鲁棒性得到显著增强，同时，图 5-11 至图 5-13 也分别显示了各算法最佳、平均、最差预测结果和测试数据的比较。图 5-11 至图 5-13 直观地显示了各算法在基于影响因素预测方法下的预测效果，有力证明了基于影响因素的预测方法在工程实践中是更加科学、合理、有效的预测

方法，能够为工程实践领域的设备性能趋势预测提供有价值的参考与决策。

表 5-5 影响 EGTM 的相关因素数据（部分）

M	OAT(°C)	PA(fleet)	c_i	EGTM
0.197	-10.4	-200	1	259
0.12	-24	1868	2	281
0.177	-8.5	-194	3	246
⋮				
0.162	-2.7	128	89	226
0.178	2.4	2364	90	178
0.092	-11.1	-88	91	268
0.118	6.6	-180	92	196
0.176	16.3	3760	93	151
0.17	7.4	-78	94	193

表 5-6 基于影响因素的预测性能比较

算法		测试数据		
		e_{RMS}	R	e_{MR}
BP	最佳预测结果	2.6306	0.9995	0.0105
	平均预测结果	8.0606	0.9925	0.0267
	最差预测结果	12.5654	0.9812	0.0425
SVR	最佳预测结果	8.5752	0.9803	0.0324
	平均预测结果	8.7057	0.9798	0.0327
	最差预测结果	9.9323	0.9745	0.0362
MELPSO	最佳预测结果	3.3008	0.9988	0.0127
	平均预测结果	3.1564	0.9974	0.0138
	最差预测结果	10.4016	0.9825	0.0444

另一方面，表 5-6 中的计算结果依然证明了 MELPSO 预测算法的优势，平均预测结果在三个算法中是最优的。同时，如图 5-11 至图 5-13 所示：在三种预测算法中，BP 网络仅对第 5 个数据预测偏差比较明显，SVR 算法整体的预测稳定性最高，MELPSO 预测算法与 BP 网络预测性能基本一致，平均预测结果要优于 BP 网络，但表现出了相对较明显的预测结果波动性，这与高维空间下搜索性能下降是有关的。总体而言，因采用基于影响因素的预测策略，不再仅将之前单一的 EGTM 变化状态作为预测依据，各算法的预测效果得到明显改善，预测结果和测试数据几乎保持着一致的变化趋势，有效增强了各算法的预测性能。

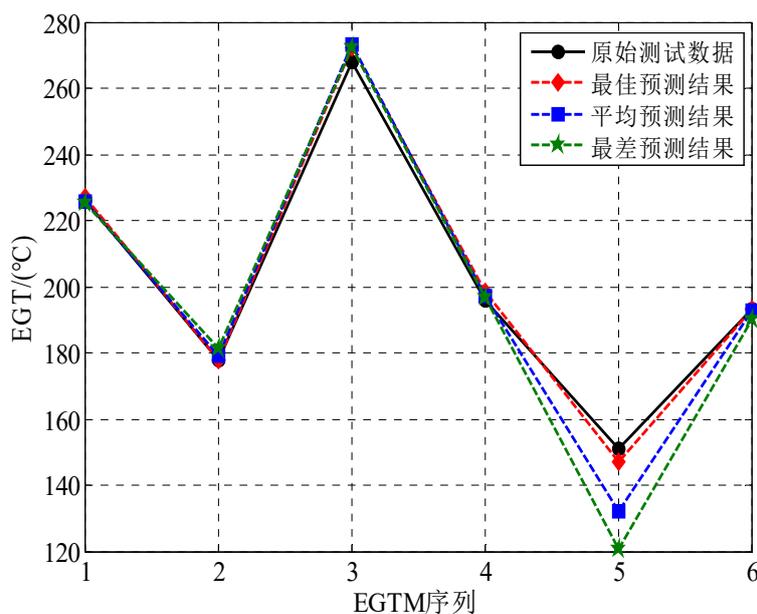


图 5-11 BP 网络基于影响因素的预测结果

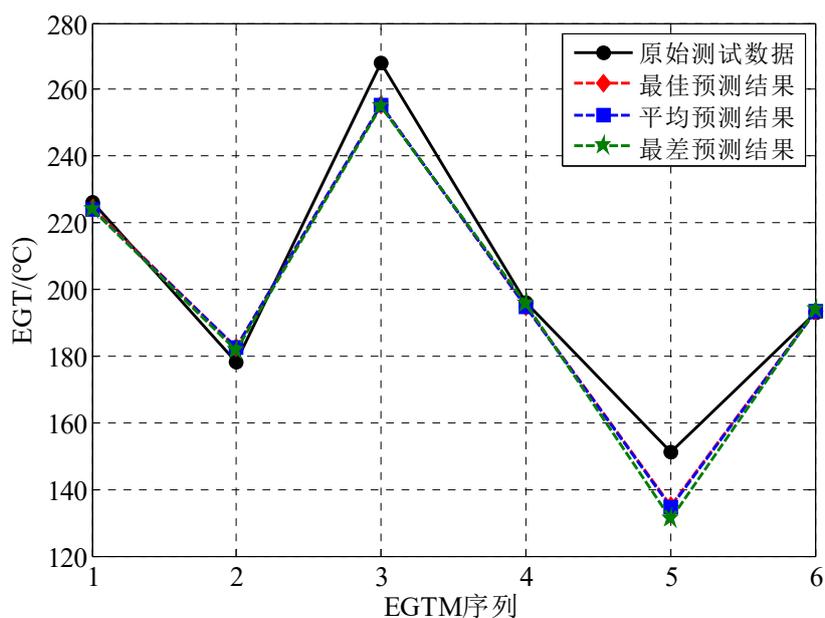


图 5-12 SVR 基于影响因素的预测结果

图 5-14 直观地比较了三种算基于影响因素的平均预测结果，三种预测结果与测试数据都呈现高度正相关特性，且就平均预测结果而言，MELPSO 预测算法的预测结果较优，这有力证明了研究 PSO 算法的意义。在充分利用发掘 PSO 算法优化潜能的基础上，可通过构造满足不同应用需求的适应度函数来拓宽 PSO 算法应用范围，为航空发动机故障诊断与预测提供技术支撑。

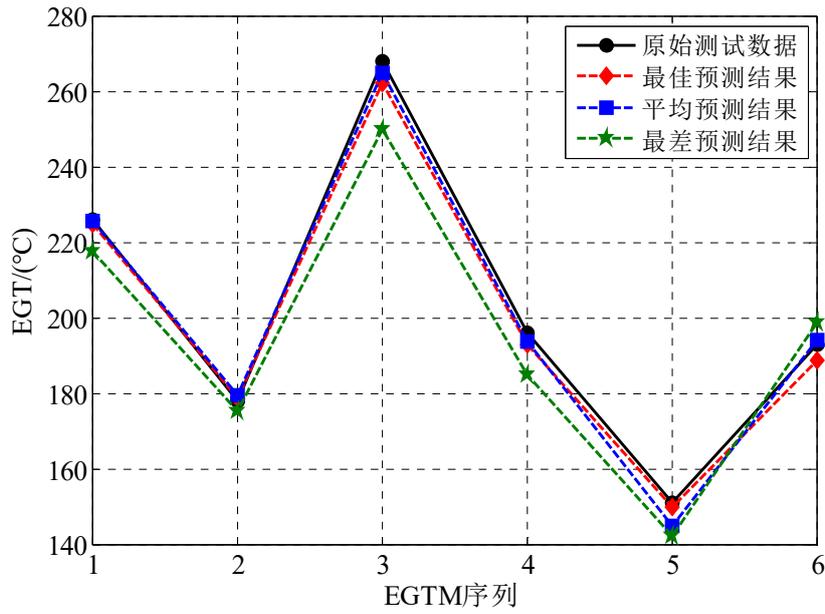


图 5-13 MEPLSO 基于影响因素的预测结果

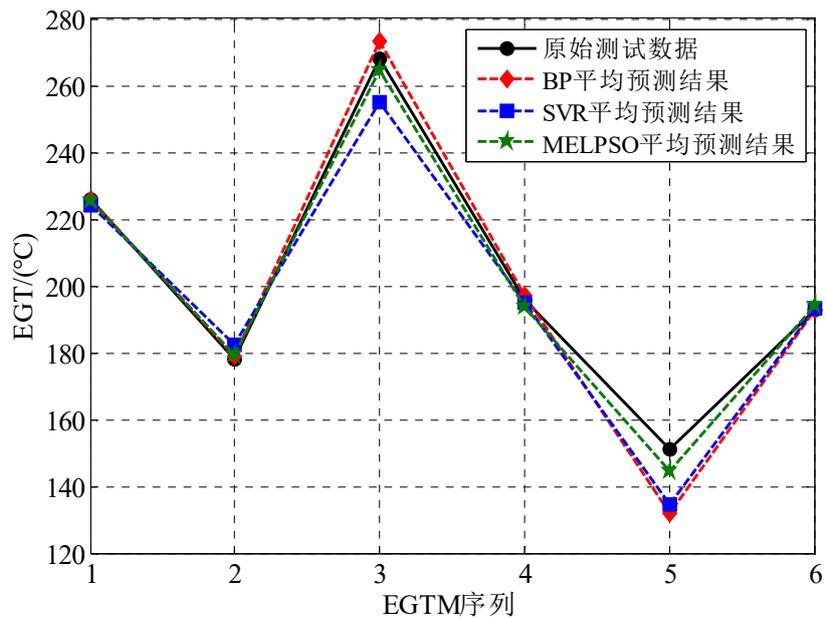


图 5-14 各算法基于影响因素的平均预测结果比较

5.5 本章小结

为向航空发动机性能衰退预测提供有效参考，确保制定合理的维修计划，在充分利用 MELPSO 算法寻优性能的基础上，设计出基于非线性映射的函数关系，描述具有非线性、不确定性等特征的航空发动机性能参数变化。通过实际数据验证了在基于时间序列的预测方法下，MELPSO 预测算法的预测误差基本满足工程实践需求，但算法稳定性较差，多次预测结果偏差明显。在此基础上提出了基于

影响因素的预测方法，将运行环境、飞行速度、起降循环等作为预测的因变量，综合考虑了环境、飞机、运行时间等因素，极大改善了各算法的预测效果，为航空发动机等工程设备的性能衰退预测提供了有价值的技术支撑。

第六章 全文总结与展望

6.1 全文总结

针对航空发动机的故障诊断、预测，以及数据处理，以 PSO 算法为技术手段，在深入分析影响 PSO 算法寻优性能的基础上，提出了改进的 MELPSO 算法，增强了算法的全局寻优能力；通过优化求解的方式，分别求解出单最优点和自适应最优点用于故障模式识别；利用粒度计算方式进行相似性数据压缩，提高了 MELPSO 算法的进化速度；同时构建出非线性映射函数，以时间序列方式和影响因素方式对航空发动机主要性能参数进行预测。

本文主要创新工作如下：

(1) 通过模拟人类学习行为，将人类的集体学习行为，私人辅导行为，以及研究行为用于改进粒子的更新方式，增强种群的多样性和交互性，平衡搜索过程的探索 and 开发，有效克服了早熟收敛的固有缺陷，提升了算法获得全局最优解的概率，增强了算法运行的稳定性和鲁棒性，拓展了算法的应用空间。经过对测试数据优化性能的分析与比较，有力证明了 MELPSO 算法稳定、可靠的全局优化能力。

(2) 借助 MELPSO 算法稳定、可靠的全局优化能力，优化求解出各类别的单个最优分类点，通过比较到最优分类点的距离大小来实现未知模式的识别，该方法识别原理简单，可同时实现对多类数据的识别。通过测试数据的比较，表明了基于单最优分类点识别原理具有较好的分类性能。

(3) 研究进一步表明尽管单最优分类点能够识别大多数数据，但对具有非线性间隔的数据分类效果较差，进而提出了基于自适应最优分类点的识别原理，通过优先度概念来组织多目标的优化，使得优化目标可按照适当的顺序被满足，从而依据问题的主次程度进行优化。基于自适应最优分类点的识别原理保留了单最优分类点分类原理的优势，对具有非线性间隔的数据集具有优良的识别效果。

(4) 结合实际研究问题发现重复或者相似数据对算法训练速度有很大影响，降低了故障诊断效率。因此利用基于图形割裂的粒度计算方式对满足相似性阈值的数据进行压缩，形成了从样本到图形，到粒度，再到数据重构的完整过程。同时，无量纲相似度克服了数据属性不同量纲间的影响，保障了样本间相似度的合理分布，通过完全子图集和平凡子图集的提取，形成粒度，因而维持了原始样本的边界分布，使得重构样本基本继承了原始样本的分类性能。

(5) 利用 MELPSO 算法求解出具有非线性映射功能的函数，描述具有非线性、不确定性等特征的航空发动机性能参数变化。在基于时间序列的预测方式下，

MELPSO 预测算法的预测误差基本满足工程实践需求，但算法稳定性较差，多次预测结果偏差明显。在此基础上提出了基于影响因素的预测方式，综合考虑预测逻辑、影响因素，将运行环境、飞行速度、起降循环作为预测变量，有效改进了预测算法的预测效果。

6.2 后续工作展望

本文研究工作涉及到故障诊断、预测、数据处理，对航空发动机的维修保障具有重要意义，实际的发动机运行数据应用验证了各算法的有效性、合理性。但要完全应用于航空发动机实际维修保障，尚有较远的路程要走，一些理论问题还需验证突破。未来主要研究问题有如下三点：

(1) 对 PSO 算法在高维求解空间的搜索机理，粒子群动态变化进程，求解稳定性需进一步研究和明确。因为在面对高维空间求解时，MELPSO 算法也表现了求解结果的不稳定性，尽管这固然与实际问题的解有关，但了解、明确在高维空间粒子种群的动态搜索过程，对进一步提升算法的优化性能，增强算法的实际应用能力具有重要意义。

(2) 基于图形相似度的粒度计算进行数据压缩应用时，怎样来确定一个恰当的相似度阈值，对保障重构数据对未知数据的识别准确率有重要作用，因此，下一步需要进行相似度阈值与识别准确率间的理论关系研究，明确相似度阈值的确定方式，在改善计算效率和提高准确率间进行最优平衡。

(3) 对航空发动机的性能趋势进行精准预测，在理论上实现是非常困难的。积极探索基于时间序列和影响因素相结合的预测算法，将影响主要性能参数的因素进行细化，找准、找好影响因素。同时，在映射函数设计时，传递函数的形式、个数，数据的嵌入维数都需要进行更为严格的理论证明，以保障预测的准确率和稳定性。

致 谢

在攻读博士学位期间，首先衷心感谢我的导师黄洪钟教授。人格魅力对人的影响是最直接有效的。我的导师黄洪钟教授深深地影响着我，让我感受到一位科学家和教育家崇高的人格魅力。黄老师对教育的忠诚，对学生的付出，对科学的严谨，对工作的勤勉，让我深为感动，也让我备受教诲。论文稿上一遍遍修改的痕迹是老师呕心沥血的见证，已深深镌刻进我的脑海。立德树人、品行为先，心怀家国、追求卓越，成为老师给予我最宝贵的财富，必将践行一身。老师就像一座灯塔，引导着奋力求索的学子到达成功的彼岸，祝老师永远明亮如初，照耀着这一片激荡而纯洁的大海。

四年的光阴里，对家庭的责任，工作的担当，学业的探求，使我承受了很多，收获了很多，也成熟了很多。回望这荆棘漫道的路途，庆幸自己选择了坚持不懈，毫无疑问，是家人给了我在艰难前行中坚定的勇气。他们默默为我承担着生活的琐碎，分担着各方的压力，他们执着的信任、无私的支持、如初的态度，成了我永不言弃的精神支柱，任何时刻，家就是我的港湾，父母妻儿就是我不竭的动力，我爱你们。

人生道路上，知己难逢，求学生涯中遇见了你们，是我莫大的荣幸，感谢这段时光的相濡以沫，相扶相持，祝大家前程似锦，幸福平安，感谢付国忠博士、殷毅超博士、彭兆春博士、张小强博士、李翔宇博士、周杰博士、黄承赓博士、郭骏宇博士、胡钧铭博士，在未来科学攀岩的道路上，继续携手并进，开创人生的荣光。

中国民用航空飞行学院的领导、同事们，向你们深深鞠一躬，感谢你们的支持和帮助。

最后，谨以此文献给所有关心、帮助我的人。

参考文献

- [1] 张璐. 民用航空发动机电气系统故障诊断方法研究[D]. 天津: 天津大学, 2016
- [2] A. Hess, L. Fila. The Joint strike fighter (JSF) PHM concept: potential impact on aging aircraft problem[C]. Proceedings of IEEE Aerospace Conference, Big Sky, 2002, 6: 3021-3026
- [3] A. Hess, L. Fila. Prognostics, from the need to reality-from the fleet users and PHM system designer / developers perspectives[C]. Proceedings of IEEE Aerospace Conference, Big Sky, 2002, 6: 2791-2797
- [4] 任占勇. 航空电子产品预测与健康管理工作[M]. 北京: 国防工业出版社, 2013
- [5] 周林, 赵杰, 冯广飞. 装备故障预测与健康管理工作[M]. 北京: 国防工业出版社, 2015
- [6] 蔡光耀, 高晶, 苗学问. 航空发动机健康管理系统发展现状及其指标体系研究[J]. 测控技术, 2016, 35(4): 1-5
- [7] 王宏力, 何星, 陆敬辉, 等. 惯性测量组合智能故障诊断及预测技术[M]. 北京: 国防工业出版社, 2017
- [8] 李应红, 尉询楷. 航空发动机的智能诊断、建模与预测方法[M]. 北京: 科学出版社, 2016
- [9] 艾廷廷, 王克明, 沙云东, 等. 航空发动机状态监测与故障诊断技术[M]. 北京: 北京理工大学出版社, 2017
- [10] S. B. Wang, X. F. Chen, C. W. Tong, et al. Matching synchrosqueezing wavelet transform and application to aeroengine vibration monitoring[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(2): 360-372
- [11] L. A. Urban. Gas path analysis applied to turbine engine condition monitoring[J]. Journal of Aircraft, 1972, 10(7): 400-406
- [12] L. C. Jaw. Recent advancements in aircraft engine health management (EHM) technologies and recommendations for the next step[C]. ASME Turbo Expo 2005: Power for Land, Sea, and Air, Reno, 2005: 683-695
- [13] 林兆福, 范作民. 发动机状态监控和故障诊断系统的研究[J]. 中国民航大学学报, 1993, 3: 1-11
- [14] 戴沅均. 航空发动机机械磨损的故障探析[J]. 中国设备工程, 2017, 24: 26-27
- [15] 马明明. 基于试飞数据的航空发动机滑油系统模型建立及应用[J]. 润滑与密封, 2017, 42(10): 121-126
- [16] W. Wang. A prognosis model for wear prediction based on oil-Based monitoring[J]. The Journal of the Operational Research Society, 2007, 58(7): 887-893

- [17] S. S. Panda, D. Chakraborty, S. K. Pal. Drill wear prediction using different neural network architectures[J]. International Journal of Knowledge-Based in Intelligent Engineering Systems, 2008, 12(5-6): 327-338
- [18] 尉询楷, 李应红, 王硕, 等. 基于支持向量机的航空发动机滑油监控分析[J]. 航空动力学报, 2004, 19(3): 392-397
- [19] 姜旭峰, 费逸伟, 王慧. 基于遗传算法的人工神经网络在航空发动机磨损预测中的应用[J]. 润滑与密封, 2007, 32(2): 168-171
- [20] 左洪福. 发动机磨损状态监控和故障诊断技术[M]. 北京: 航空工业出版社, 1996
- [21] 柳迎春, 李洪伟, 李明. 军用航空发动机状态监控与故障诊断技术[M]. 北京: 国防工业出版社, 2015
- [22] 董务江. 某型飞机发动机在役过程中的孔探检测[J]. 无损检测, 2012, 34(11): 66-69
- [23] 董务江, 郭平, 胡诚. 航空发动机内窥镜检测技术与无损检测[J]. 无损检测, 2013, 35(9): 69-73
- [24] 张海兵, 袁英民. 某型发动机 2 级压气机叶片的涡流探伤方法[J]. 无损检测, 2011, 33(2): 24-26
- [25] 张传明, 董德秀, 赵帅军, 等. 压气机叶片原位超声表面波检测[J]. 无损检测, 2013, 35(3): 62-65
- [26] 崔宗辉, 苏金波, 郑攀忠. 航空发动机高压压气机叶片损伤检查[J]. 无损检测, 2012, 34(4): 78-80
- [27] 刘念. 电气设备状态监测与故障诊断[M]. 北京: 中国电力出版社, 2016
- [28] 钟丽娜. 惯性/卫星组合导航自适应容错与精度性能增强关键技术研究[D]. 南京: 南京航空航天大学, 2016
- [29] Y. Yuan, X. F. Liu, S. T. Ding, et al. Fault detection and location dystem for diagnosis of multiple faults in aeroengines[J]. IEEE Access, 2017, 3(99): 17671-17677
- [30] T. Kobayashi, D. L. Simon. Evaluation of an enhanced bank of kalman filters for in-flight aircraft engine sensor fault diagnostics[J]. Journal of Engineering for Gas Turbines & Power, 2004, 127(3): 635-645
- [31] Y. Gao, H. F. Durrant-Whyte. Multi-sensor fault detection and diagnosis using combined qualitative and quantitative techniques[C]. IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, Las Vegas, 1994, 10: 43-50
- [32] 陈伟, 姜斌, 张柯, 等. 基于线性参数变化自适应观测器的鲁棒故障诊断[J]. 南京航空航天大学(英文版), 2009, 26(4): 288-294

- [33] 陈煜. 基于非线性模型的涡喷发动机气路故障诊断研究[D]. 南京: 南京航空航天大学, 2014
- [34] 范作民, 孙春林, 白杰. 航空发动机故障诊断导论[M]. 北京: 科学出版社, 2004
- [35] S. Mallat. A theory for multiresolution signal decomposition: the wavelet representation[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1989, (11): 874-893
- [36] 徐平, 郝旺身. 振动信号处理与数据分析[M]. 北京: 科学出版社, 2017
- [37] N. E. Huang, Z. Shen, S. R. Long, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[C]. Proceedings of the Royal Society A Mathematical Physical and Engineering Sciences, London, 1998, 454(197): 903-995
- [38] D. J. Yu, J. S. cheng, Y. Yang. Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings[J]. Mechanical Systems and Signal Processing, 2005, 19(2): 259-270
- [39] G. Gelle, M. Colas, G Delaunay. Blind sources separation applied to rotating machines monitoring by acoustical and vibrations analysis[J]. Mechanical Systems and Signal Processing, 2000, 14(3): 427-442
- [40] 栗祥. 基于 EMD 与 SVM 的航空发动机转子系统故障诊断[D]. 西安: 西安工业大学, 2017
- [41] 李国鸿, 李飞行. STFT 在航空发动机振动信号处理中的应用[J]. 测控技术, 2013, 32(4): 45-49
- [42] 肖蕾, 李颖晖, 赵鸥, 等. 基于小波变换的飞机电力作动系统故障诊断[J]. 空军工程大学学报, 2009, 10(5): 55-58
- [43] 殷彬彬, 李星星. 航空发动机控制系统振动信号处理方法研究[J]. 测控技术, 2017, (10): 50-52
- [44] 屈梁生. 机械故障的全息诊断原理[M]. 北京: 科学出版社, 2007
- [45] 屈梁生. 机械监测诊断中的理论与方法[M]. 西安: 西安交通大学出版社, 2009
- [46] 何正嘉, 袁静, 訾艳阳. 机械故障诊断的内积变换原理与应用[M]. 北京: 科学出版社, 2012
- [47] 何正嘉, 訾艳阳, 张西宁. 现代信号处理及工程应用[M]. 西安: 西安交通大学出版社, 2007
- [48] 刘尚坤. 基于振动信号处理的旋转机械故障诊断方法研究[D]. 北京: 华北电力大学, 2017
- [49] V. A. Svetlov, S. A. Dolenko. Development of the algorithm of adaptive construction of hierarchical neural network classifiers[J]. Optical Memory & Neural Networks, 2017, 26(1): 40-46

- [50] H. Z. Huang, P. Cui, W. Peng, et al. Fatigue lifetime assessment of aircraft engine disc via multi-source information fusion[J]. *International Journal of Turbo & Jet Engines*, 2014, 31(2): 167-174
- [51] J. Yang, H. Z. Huang, R. Sun, et al. Reliability analysis of aircraft servo-actuation systems using evidential networks[J]. *International Journal of Turbo & Jet Engines*, 2012, 29(2): 59-68
- [52] H. Z. Huang, H. K. Wang, Y. F. Li, et al. Support vector machine based estimation of remaining useful life: current research status and future trends[J]. *Journal of Mechanical Science and Technology*, 2015, 29(1): 151-163
- [53] M. He, Z. Wang, M. Leach, et al. Bio-inspired optimization algorithms applied to rectenna design[J]. *Big Data Analytics*, 2018, 3(1): 1-21
- [54] 刘平华. 飞机发动机故障诊断专家系统研究[D]. 青岛: 青岛科技大学, 2017
- [55] V. Y. Arkon, V. C. Patel, G. Kulikov, et al. Aircraft engine condition monitoring: Stochastic identification and neural networks[C]. *Proceedings of the 5th International Conference on Artificial Neural Networks*, Cambridge, 1997, 440: 295-299
- [56] F. Mustapha, S. M. Sapuan, N. Ismail, et al. A computer-based intelligent system for fault diagnosis of an aircraft engine[J]. *Engineering Computations*, 2004, 21(1): 78-90
- [57] T. A. Mast, A. T. Reed, S. Yurkovich, et al. Bayesian belief networks for fault identification in aircraft gas turbine engines[C]. *Proceedings of the IEEE International Conference on Control Applications*, Kohala Coast, 1999, 1: 39-44
- [58] 候胜利, 李应红, 尉询楷, 等. 基于免疫聚类分析的特征提取及其在发动机故障诊断中的应用[J]. *推进技术*, 2006, 27(6): 554-558
- [59] J. Lee. Measurement of machine performance degradation using a network model[J]. *Computers in Industry*, 1996, 30(3): 193-209
- [60] H. Q. Wu, Y. Liu, Y. L. Ding, et al. Fault diagnosis expert system for modern commercial aircraft[J]. *Aircraft Engineering and Aerospace Technology*, 2004, 76(4): 398-403
- [61] 朱家元, 张喜斌, 张恒喜, 等. 航空发动机故障的支持向量机智能诊断[J]. *推进技术*, 2003, 24(5): 414-416
- [62] R. B. Joly, S. Ogaji, R. Singh. Gas-turbine diagnostics using artificial neural-networks for a high bypass ratio military turbofan engine[J]. *Applied Energy*, 2004, 78(4): 397-418
- [63] T. Koboyashi, D. L. Simon. Hybrid neural network genetic-algorithm technique for aircraft engine performance diagnostics[J]. *Journal of Propulsion & Power*, 2001, 21(4): 751-758
- [64] X. Y. Yang, S. Pang, W. Shen, et al. Aero engine fault diagnosis using an optimized extreme learning machine[J]. *International Journal of Aerospace Engineering*, 2016, 2016:1-10

- [65] S. M. Lee, W. J. Choi, T. S. Ros, et al. Defect diagnostics of gas turbine with altitude variation using hybrid SVM-artificial neural network[J]. Synapse, 2007, 11(1): 222-232
- [66] 钱政, 严璋, 罗承沐. 范例推理与模糊数学的变压器故障诊断方法[J]. 高电压技术, 2001, 27(6): 1-2
- [67] 赵文涛, 殷建平, 龙军. 一种基于粒子群优化算法的组合预测模型[C]. 全国理论计算机科学学术年会, 西安, 2008, 53-55
- [68] 郑波. 基于 PSO-SVM 的民航发动机送修等级决策研究[J]. 推进技术, 2013, 34(5): 68-69
- [69] 郑波, 高峰. 基于 IPSO-SVM 的航空发动机磨损预测研究[J]. 润滑与密封, 2014, 39(11): 81-87
- [70] 张爱国, 莫军, 朱海, 等. 基于模糊神经网络故障诊断系统[J]. 电子测量技术, 2001, (1): 7-9
- [71] J. Kennedy, R. C. Eberhart. Particle swarm optimization[C]. Proceedings of IEEE International Conference on Neural Network, Perth, 1995, 4(8): 1942-1948
- [72] Y. H. Shi, R. C. Eberhart. Parameter selection in particle swarm optimization[C]. Proceedings of the 7th International Conference on Evolutionary Programming VII, London, 1998, 1447(25): 591-600
- [73] A. G. Li, Z. Qin, F. M. Bao. Particle swarm optimization algorithms[J]. Computer Engineering and Applications, 2017, 186(3): 454-458
- [74] M. J. Mahmoodabadi, Z. M. Salahshoor, A. Bagheri, HEPSON: high exploration particle swarm optimization[J]. Information Sciences, 2014, 273(18): 101-111
- [75] Y. H. Shi, R. C. Eberhart. Empirical study of particle swarm optimization[C]. Proceedings of the 1999 Congress on Evolutionary Computation, Seoul, 1999, 3: 1945-1950
- [76] K. E. Parsopoulos, M. N. Vrahatis. UPSO: A unified particle swarm optimization scheme[C]. Proceedings of the International Conference of Computational Methods in Sciences and Engineering, Zeist, 2004, 1: 868-873
- [77] M. Pant, T. Radha, V. P. Singh. Particle swarm optimization using gaussian inertia weight[C]. Proceedings of International Conference on Computational Intelligence and Multimedia Applications, Sivakasi, 2007, 1(01): 97-102
- [78] P. Bajpai, S. N. Singh. Fuzzy adaptive particle swarm optimization for bidding strategy in uniform price spot market[J]. IEEE Transactions on Power Systems, 2007, 22(4): 2152-2160
- [79] C. Liu, C. Ouyang, P. Zhu, et al. An adaptive fuzzy weight PSO algorithm[C]. Proceedings of International Conference on Genetic and Evolutionary Computing, Shenzhen, 2010: 8-10

- [80] W. H. Han, P. Yang, H. X. Ren, et al. Comparison study of several kinds of inertia weights for PSO[C]. Proceedings of IEEE international Conference on Progress in Informatics and Computing, Shanghai, 2010, 1: 280-284
- [81] M. Clerc, J. Kennedy. The particle swarm-explosion, stability, and convergence in a multidimensional complex space[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(1): 58-73
- [82] J. Ding, J. Liu, K.R. Chowdhury, et al. A particle swarm optimization using local stochastic search and enhancing diversity for continuous optimization[J]. Neurocomputing, 2014, 137: 261-267
- [83] G.Q. Bao, K. F. Mao. Particle swarm optimization algorithm with asymmetric time-varying acceleration coefficients[C]. Proceeding of IEEE International Conference on robotics and biomimetics, Guilin, 2009: 2134-2139
- [84] F. V. D. Bergh, A. P. Engelbrech. A cooperative approach to particle swarm optimization[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 225-239
- [85] D. Parrott, X. Li. Locating and tracking multiple dynamic optima by a particle swarm model using speciation[J]. IEEE Transactions Evolutionary Computation, 2006, 10(4): 440-458
- [86] H. Wang, Z. Wu, S. Rahnamayan, et al. Particle swarm optimization with simple and efficient neighbourhood search strategies[J]. International Journal of Innovative Computing & Applications, 2011, 3(2): 97-104
- [87] R. Mendes, J. Kennedy, J. Neves. The fully informed particle swarm: simpler, maybe better[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 204-210
- [88] J. Liang, P. N. Suganthan. Dynamic multi-swarm particle swarm optimizer with a novel constraint-handling mechanism[C]. Proceedings of IEEE international Conference on Evolutionary Computation, Vancouver, 2006: 9-16
- [89] G. Nápoles, I. Grau, R. Bello, Particle swarm optimization with random sampling in variable neighbourhoods for solving global minimization problems[C]. Proceedings of the 8th international conference on Swarm Intelligence, Brussels, 2012, 7461(1): 352-353
- [90] D. Yazdani, B. Nasiri, S. M. Alireza, et al. A novel multi-swarm algorithm for optimization in dynamic environments based on particle swarm optimization[J]. Applied Soft Computing Journal, 2013, 13(4): 77-93
- [91] F. Zou, L. Wang, X. Hei, et al. Teaching-learning-based optimization with dynamic group strategy for global optimization[J]. Information Sciences, 2014, 273: 112-131

- [92] M. Lovbjerg, T. K. Rasmussen, T. Krink. Hybrid particle swarm optimizer with breeding and subpopulations[C]. Proceedings of the IEEE International Conference on Genetic and Evolutionary Computation, San Francisco, 2001, 1: 469-476
- [93] N. Higashi, H. Iba. Particle swarm optimization with Gaussian mutation[C]. Proceeding of IEEE international Conference on Swarm Intelligence Symposium, Indianapolis, 2003: 72-79
- [94] 张庆科. 粒子群优化及差分进化算法研究[D]. 济南: 山东大学, 2017
- [95] 刘微, 孙榕彬, 王洪瑞. 嵌入模拟退火机制的免疫逃避的粒子群算法[J]. 吉林师范大学(自然科学), 2018, (1): 85-90
- [96] 张晓, 范洪, 张莉, 等. 融入免疫思想的粒子群优化算法[J]. 陕西师范大学(自然科学版), 2017, 45(3): 17-23
- [97] J. Sun, B. W. Xu, W. Fang. Diversity-guided quantum-behaved particle swarm optimization algorithm[C]. Proceedings of International Conference on Simulated Evolution and Learning, Hefei 2006, 4247: 497-504
- [98] 唐贤伦, 张衡, 周家林, 等. 多 Agent 结构的混沌 PSO 在无功优化中的应用[J]. 电机与控制学报, 2013, 17(6): 15-21
- [99] Z. Beheshti, S. M. H. Shamsuddin. CAPSO: centripetal accelerated particle swarm optimization [J]. Information Sciences, 2014, 258(3): 54-79
- [100] W. H. Lim, N. A. M. Isa. Bidirectional teaching and peer-learning particle swarm optimization [J]. Information Sciences, 2014, 280(4): 111-134
- [101] W. H. Lim, N. A. M. Isa. Teaching and peer-learning particle swarm optimization[J]. Applied Soft Computing, 2014, 18: 39-58
- [102] R. P. Singh, V. Mukherjee, S. P. Ghoshal. Particle swarm optimization with an aging leader and challengers algorithm for optimal power flow problem with FACTS devices[J], Electrical Power and Energy Systems, 2015, 64: 1185-1196
- [103] M. R. Tanweer, S. Suresh, N. Sundararajan. Self regulating particle swarm optimization algorithm[J]. Information Sciences, 2015, 294(10): 182-202
- [104] B. Zheng, H. Z. Huang, H. W. Xu, et al. A multi-team competitive optimization algorithm for bearing fault diagnosis[C]. 2016 Annual Reliability and Maintainability Symposium, Tucson, 2016: 1-7
- [105] 戴朝华. 搜索者优化算法及其运用研究[D]. 成都: 西南交通大学, 2009
- [106] Y. Li, Z. H. Zhan, S. Lin, et al. Competitive and cooperative particle swarm optimization with information sharing mechanism for global optimization problems[J]. Information Sciences, 2015, 293(3): 370-382

- [107] L. A. Zadeh. Fuzzy sets[J]. Information and Control, 1965, 8(3): 338-353
- [108] L. A. Zadeh. Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic[J]. Fuzzy Sets and Systems, 1997, 90(2): 111-12
- [109] L. A. Zadeh. Fuzzy logic - computing with words[J]. IEEE Transactions on Fuzzy Systems, 1996, 4(2): 103-111
- [110] J. R. Hobbs. Granularity[C]. Proceedings of the 9th international joint conference on Artificial intelligence, Los Angeles, 1985: 432-435
- [111] R. R. Yager, D. Filev. Operations for granular computing: mixing words and numbers[C]. IEEE World Congress on IEEE International Conference on Fuzzy Systems, Anchorage, 1998, 1: 123-128
- [112] T. Y. Lin. Granular computing[C]. Announcement of the BISC Special Interest Group on Granular Computing, 1997
- [113] 张铃, 张钊. 问题求解理论及应用[M]. 北京: 清华大学出版社, 2007
- [114] Z. Pawlak. Rough sets[J]. International Journal of Computer & Information Sciences, 1982, 11(5): 341-356
- [115] Z. Pawlak, Rough sets-theoretical aspects of reasoning about data[M]. Dordrecht: Kluwer Academic Publishers, 1991
- [116] B. Zhang, L. Zhang. Theory and application of problem solving[M]. North-Holland: Elsevier Science Publisher, 1992
- [117] 张铃, 张钊. 模糊商空间理论:模糊粒度计算方法[J]. 软件学报, 2003, 14(4): 770-776
- [118] L. A. Zadeh. Some reflections on soft computing, granular computing and their roles in the conception, design and utilization of information / intelligent systems[J]. Soft Computing, 1998, 2(1): 23-25
- [119] 赵立权. 模糊集、粗糙集和商空间理论的比较研究[J]. 计算机工程, 2011, 37(2): 22-24
- [120] Y. C. Tang, B. Jin, Y. Q. Zhang. Granular support vector machines with association rules mining for protein homology prediction[J]. Artificial Intelligence in Medicine, 2005, 35(1): 121-134
- [121] Y. C. Tang, B. Jin, Y. Q. Zhang, et al. Granular support vector machines using linear decision hyperplanes for fast medical binary classification[C]. Proceedings of International Conference on Fuzzy Systems, Reno, 2005: 138-142
- [122] X. G. Zhang. Using class-center vectors to build support vector machines[C]. Proceedings of IEEE Neural Networks and Signal Process, Madison, 1999: 3-11

- [123] H. Yu, J. Yang, J. W. Han, et al. Making SVMs scalable to large data sets using hierarchical cluster indexing[J]. *Data Mining and Knowledge Discovery*, 2005, 11(3): 100-128
- [124] 郭虎升, 王文剑. 基于神经网络的 SVM 学习算法[J]. *计算机工程与应用*, 2009, 45(2): 51-54
- [125] V. D. Bergh. An analysis of particle swarm optimizers[D]. Pretoria: University of Pretoria, 2002
- [126] Y. H. Shi, R. A. Eberhart. A modified particle swarm optimizer[C]. *IEEE World Congress on Computational Intelligence*, Anchorage, 1998: 69-73
- [127] B. Zheng, H. Z. Huang, W. Guo, et al. Fault diagnosis method based on supervised particle swarm optimization classification algorithm[J]. *Intelligent Data Analysis*, 2018, 22(1): 191-210
- [128] B. Zheng, H. Z. Huang, Y. F. Li. Aeroengine fault diagnosis method based on optimized supervised kohonen network[J]. *Journal of Donghua University*, 2015, 32(6): 1029-1033
- [129] R. Cheng, Y. C. Jin. A social learning particle swarm optimization algorithm for scalable optimization[J]. *Information Sciences*, 2015, 291(10): 43-60
- [130] X. J. Wang, B. T. Zhang, D. Y. Xu. Compression Factor with grey model of particle swarm optimization and its application in smart grid[J]. *Operations Research and Management Science*, 2012, 21(3): 114-118
- [131] 郑波, 高峰. 基于 S-PSO 分类算法的故障诊断方法[J]. *航空学报*, 2015, 36(11): 3640-3651
- [132] B. Yang, C. Wang, H. Huang, et al. A multi-agent and PSO based simulation for human behavior in emergency evacuation[J]. *Proceedings of International Conference on Computational Intelligence and Security*, Harbin, 2007: 296-300
- [133] A. Banks, J. Vincent, C. Anyakoha. A review of particle swarm optimization. Part II: hybridisation, combinatorial, multicriteria and constrained optimization, and indicative applications[J]. *Natural Computing*, 2008, 7(1): 109-124
- [134] P. Shakya, M. S. Kulkarni, A. K. Darpe. Bearing diagnosis based on Mahalanobis-Taguchi-Gram-Schmidt method[J]. *Journal of Sound and Vibration*, 2015, 337: 342-362
- [135] 丁福焰, 杜永平. 机车车辆故障诊断技术的发展[J]. *铁道机车车辆*, 2004, 24(4): 24-30
- [136] B. Zheng, H. Z. Huang, Y. F. Li. Intelligent fault recognition strategy based on adaptive optimized multiple centers[J]. *Mechanical Systems & Signal Processing*, 2018, 106: 526-536
- [137] P. M. Frank. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy: a survey and some new results[J]. *Automatics*, 1990, 26(3): 459-474

- [138] 郎荣玲, 潘磊, 吕永乐, 等. 基于支撑向量机的飞机故障诊断技术[M]. 北京: 国防工业出版社, 2016
- [139] 吕琛, 栾家辉, 王立梅, 等. 故障诊断与预测—原理、技术及应用[M]. 北京: 北京航空航天大学, 2012
- [140] X. C. Liu. Entropy, distance measure and similarity measure of fuzzy sets and their relations[J]. *Fuzzy Sets and Systems*, 1992, 52: 305-318
- [141] S. X. Xiang, F. P. Nie, C. S. Zhang. Learning a mahalanobis distance metric for data clustering and classification[J]. *Pattern Recognition*, 2008, 41(12): 3600-3612
- [142] J. Ye. Cosine similarity measures for intuitionistic fuzzy sets and their applications[J]. *Mathematical and Computer Modelling*, 2011, 53(11): 91-97
- [143] A. M. Neto. Pearson's correlation coefficient: a more realistic threshold for applications on autonomous robotics[J]. *Computer Technology and Application*, 2014, 2: 69-72
- [144] A. Airteimoori, S. Kordrostami. A euclidean distance-based measure of efficiency in data envelopment analysis[J]. *Optimization*, 2010, 59(7): 985-996
- [145] 李晶. 浅析 K -近邻分类技术[J]. 哈尔滨师范大学自然科学版, 2013, 29(4): 8-11
- [146] T. Kohonen. Improved version of learning vector quantization[J]. *Proceedings of International Joint Conference on Neural Network*, 1990, 1: 545-550
- [147] V. N. Vapnik. *The Nature of Statistical Learning Theory*[M]. New York: Springer-Verlag, 1999
- [148] 邓乃扬, 田英杰. 支持向量机——理论、算法与拓展[M]. 北京: 科技出版社, 2009
- [149] S. Kiranyaz, T. Ince, A. Yildirim. Evolutionary artificial neural networks by multi-dimensional particle swarm optimization[J]. *Neural Networks*, 2009, 22(10): 1448-1462
- [150] S. J. Nanda, G. Panda. Automatic clustering algorithm based on multi-objective immunized PSO to classify actions of 3D human models[J]. *Engineering Applications of Artificial Intelligence*, 2013, 26(5): 1429-1411
- [151] J. B. Ali, N. Fnaiech, L. Saidi, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration[J]. *Applied Acoustics*, 2015, 89(3): 16-27
- [152] B. Biswal, M. Biswal, S. Hasan, et al. Nonstationary power signal time series data classification using LVQ classifier[J]. *Applied Soft Computing*, 2014, 18(1): 158-166
- [153] M. M. Lange, N. A. Novikov. Bayes classifier based on tree-structured Gaussian mixtures[J]. *Pattern Recognition and Image Analysis*, 2012, 22(1): 136-143
- [154] C. J. D'Orsi. Computer-aided detection: there is no free lunch[J]. *Radiology*, 2001, 221(3): 585-586

- [155] 王诺, 吴迪, 黄祺, 等. 选择 Pareto 非劣解最优方案的量化方法: 性价比法[J]. 系统工程理论与实践, 2018, 38(3): 725-733
- [156] 董晴, 宋威. 基于粒子群优化的深度神经网络分类算法[J]. 传感器与微系统, 2017, 36(9): 143-146
- [157] C. Q. Shen, D. Wang, F. R. Kong, et al. Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier. *Measurement*, 2013, 46 (4): 1551-1564
- [158] X. Y Zhang, D. Y. Qiu, F. Chen. Support vector machine with parameter optimization by a novel hybrid method and its application of fault diagnosis. *Nuerocomputing*, 2015, 149: 641-651
- [159] 雷达. 基于智能学习模型的民航发动机健康状态预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2013
- [160] 郎荣玲, 潘磊, 吕永乐. 基于飞行数据的民航飞机故障诊断专家系统[M]. 北京: 国防工业出版社, 2014
- [161] R. Akhani, S. Kwek, N. Japkowicz. Applying support vector machines to imbalanced datasets[C]. *Proceedings of 15th European Conference on Machine Learning, Pisa, 2004*, 3201: 39-50
- [162] A. Skowron, J. Stepaniuk. Information granules: towards foundations of granular computing[J]. *International Journal of Intelligent Systems*, 2001, 16(1): 57-85
- [163] 张钺, 张铃. 粒技术未来发展方向探讨[J]. *重庆邮电大学学报*, 2010, 22(5): 538-540
- [164] Y. Y. Yao. Granular Computing: basic issues and possible solutions[C]. *Proceedings of the 5th Joint Conference on Information Sciences, Atlantic City, 2000*: 186-189
- [165] 李道国, 苗夺谦, 张东星, 等. 粒技计算研究综述[J]. *计算机科学*, 2005, 32(9): 1-12
- [166] 黄明, 王佳, 梁旭. 双阈值控制的遗传算法求解柔性作业车间调度问题[J]. *计算机集成制造系统*, 2007, 5(4): 329-331
- [167] 张鑫. 粒度支持向量机学习方法研究[D]. 太原: 山西大学, 2011
- [168] U. von Luvburg. A tutorial on spectral clustering[J]. *Statistics and Computing*, 2007, 17(4): 395-416
- [169] 王文剑, 门昌骞. 支持向量机建模及应用[M]. 北京: 科学出版社, 2014
- [170] 姚晨榕. 基于状态的民航发动机维修管理研究[D]. 南京: 南京航空航天大学, 2006
- [171] 马小骏, 左洪福, 刘昕. 大型客机运行监控与健康管理系统设计[J]. *交通运输工程学报*, 2011, 11(6): 119-126

- [172] 李晓白, 崔秀伶, 郎荣玲. 航空发动机性能参数预测方法[J]. 北京航空航天大学学报, 2008, 34(3): 253-256
- [173] 张菊, 钟新辉, 张峰. 灰色系统在发动机铁谱分析监测中的应用[J]. 内燃机, 2013, (3): 39-40
- [174] 陈果. 用结构自适应神经网络预测航空发动机性能趋势[J]. 航空学报, 2007, 28(3): 535-539
- [175] 陶金伟, 黄一桓, 鲁峰, 等. 基于融合 EKF 的航空发动机气路性能健康预测[J]. 测控技术, 2017, 36(7): 133-137
- [176] 孙磊, 贾云献, 蔡丽影, 等. 基于油液光谱分析和粒子滤波的发动机剩余寿命预测研究[J]. 光谱学与光谱分析, 2013, 33(9): 2478-2482
- [177] 李丽敏, 王仲生, 姜洪开. 基于多状态 MOG-HMM 和 Viterbi 的航空发动机突发故障预测[J]. 振动、测试与诊断, 2014, 34(2): 310-314
- [178] 刘永建. 基于改进神经网络的民航发动机故障诊断与性能预测研究[D]. 南京: 南京航空航天大学, 2012
- [179] B. Long, W. Xian, L. Jiang, et al. An improved autoregressive model by particle swarm optimization for prognostics of lithium-ion batteries[J]. Microelectronics Reliability, 2013, 53(6): 821-831
- [180] 孙家泽, 王曙燕. 群体智能优化算法及其应用[M]. 北京: 科学出版社, 2018
- [181] M. S. Leu, M. F. Yeh. Grey particle swarm optimization[J]. Applied Soft Computing, 2012, 12(9): 2985-2996
- [182] 彭喜元, 彭宇, 刘大同. 数据驱动故障预测[M]. 哈尔滨: 哈尔滨工业大学出版社, 2016
- [183] E. Erdem, J. Shi. ARMA based approaches for forecasting the tuple of wind speed and direction[J]. Applied Energy, 2011, 88(4): 1405-1414
- [184] M. Mavrouniotis, S. X. Yang. Training neural networks with ant colony optimization algorithms for pattern classification[J]. Soft Computing, 2015, 19(6): 1511-1522

攻读博士学位期间参与的科研项目及取得的成果

一、在学期间参与的项目研究

- [1] 国家自然科学基金项目：“基于混合不确定性信息处理的复杂分层系统健康评估”，项目编号：U13301055
- [2] 国家自然科学基金项目：“基于故障物理技术的结构疲劳可靠性设计理论及其应用研究”，项目编号：11272082
- [3] 总装备部武器装备预研基金项目：“航空发动机故障综合诊断与预测方法研究”，项目编号：9140A27020212DZ02310

二、在学期间发表的学术论文

- [1] **B. Zheng**, H. Z. Huang, Y. F. Li. Intelligent fault recognition strategy based on adaptive optimized multiple centers[J]. Mechanical Systems & Signal Processing, 2018, 106: 526-536 (SCI 检索)
- [2] **B. Zheng**, H. Z. Huang, W. Guo, et al. Fault diagnosis method based on supervised particle swarm optimization classification algorithm[J]. Intelligent Data Analysis, 2018, 22(1): 191-210 (SCI 检索)
- [3] **B. Zheng**, Y. F. Li, J. Y. Guo, et al. Aeroengine performance prediction based on double-extremum learning particle swarm optimization[J]. International Journal of Turbo & Jet-Engines, 2017: 1-13 (SCI 检索)
- [4] **B. Zheng**, Y. F. Li, G. Z. Fu. Discretization algorithm based on particle swarm optimization and its application in attributes reduction for fault data[J]. Journal of Shanghai Jiao Tong University (Science), 2018, 23(3): 1-5 (已录用, EI 源刊)
- [5] **B. Zheng**, H. Z. Huang, H. W. Xu, et al. A multi-team competitive optimization algorithm for bearing fault diagnosis[C]. 2016 Annual Reliability and Maintainability Symposium, Tucson, 2016: 1-7 (EI 检索)
- [6] 郑波, 高峰. 基于 S-PSO 分类算法的故障诊断方法[J]. 航空学报, 2015, 36(11): 3640-3651 (EI 检索)
- [7] **B. Zheng**, H. Z. Huang, Y. F. Li. Aeroengine fault diagnosis method based on optimized supervised kohonen network[J]. Journal of Donghua University, 2015, 32(6): 1029-1033

- [8] 郑波, 高峰. 基于 IPSO-SVM 的航空发动机磨损预测研究[J]. 润滑与密封, 2014, 39(11): 81-87
- [9] **B. Zheng**, H. Z. Huang, J. Zhou, et al. Graph partition based on dimensionless similarity and its application to fault diagnosis[C]. Asia Pacific Conference of the Prognostics and Health Management Society, Jeju, 2017: 154-164
- [10] J. Y. Guo, Y. F. Li, **B. Zheng**, et al. Bayesian degradation assessment of CNC machine tools considering unit non-homogeneity[J]. Journal of Mechanical Science and Technology, 2018, 32 (6): 2479-2485 (SCI 检索)