

中图分类号: V263;TH133.3

论文编号: 102872026-SZ003

学科分类号: 086100

专业学位硕士学位论文

一种融合 EMD 和 EWT 的滚动轴承故障信号分析方法及其应用

研究生姓名	马一杰
专业类别	交通运输
专业领域	智能诊断与专家系统
指导教师	陈果 教授

南京航空航天大学

研究生院 通用航空与飞行学院

二〇二六年二月

Nanjing University of Aeronautics and Astronautics

The Graduate School

College of General Aviation and Flight

A Fault Signal Analysis Method for Rolling Bearings Combining EMD and EWT and Its Application

A Thesis in

Transportation Engineering

by

Ma Yijie

Prof. Chen Guo

Submitted in Partial Fulfillment

of the Requirements

for the Degree of

Master of Transportation Engineering

February, 2026

独创性声明

本人声明所呈交的硕士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。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，也不包含为获得南京航空航天大学或其他教育机构的学位或证书而使用过的材料。

研究生签名： ↓ - 杰 日期： 2026年3月17日

使用授权声明

本人完全了解南京航空航天大学有关保留、使用学位论文的规定，即学校有权保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权南京航空航天大学可以将本学位论文的全部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。

研究生签名： ↓ - 杰 导师签名： _____ 日期： _____

摘要

滚动轴承是航空发动机关键支撑部件，工作在高速、高温环境，同时还要承受强烈的时变冲击载荷，因此极易产生故障，其运行状态直接影响发动机可靠性及使用寿命，因此，对其故障进行诊断尤为重要。然而，由于滚动轴承深埋在航空发动机内部，其故障振动信号呈现出明显的非平稳性、多分量混叠以及强背景噪声的特征，传统的信号处理方法面临极大的挑战。因此，如何对滚动轴承早期故障进行精确诊断以及特征提取，成为当前故障诊断重要研究的方向，为了提高滚动轴承的故障诊断精度，本文结合经验模态分解（Empirical Mode Decomposition, EMD）以及经验小波变换（Empirical Wavelet Transform, EWT）两种方法的优势，提出了一种融合 EMD 与 EWT 的新算法，并通过大量试验验证，证明了新方法的优势和有效性。主要研究工作如下：

（1）介绍 EMD 算法和 EWT 算法的理论基础，提出了融合 EMD 算法和 EWT 算法的新方法，利用仿真数据比较分析发现，融合两种算法之后可根据信号的局部时变特性进行自适应分解从而避免 EMD 算法的端点效应以及模态混叠的缺点，而无需使用镜像延拓等方法。

（2）利用国际通用的西储大学滚动轴承故障数据集以及南京航空航天大学带机匣的转子-滚动轴承试验器的滚动轴承故障模拟试验数据，详细对比了 EMD 算法、EWT 以及 EMD-EWT 融合算法的分解效果。结果表明，EMD-EWT 融合算法相较于单一的 EMD 算法和单一的 EWT 算法在滚动轴承外圈、内圈、滚动体故障中能够更加清晰地分离出故障冲击分量，其提取的包络谱中的故障特征频率以及其倍频成分更加突出。最后建立了一个滚动轴承故障无量纲指标，更有利于滚动轴承故障的识别。

（3）利用真实航空发动机主轴承故障演化的试车数据，进一步对新算法的效果进行验证。结果表明，在滚动轴承试验机与真实复杂的航空发动机主轴承中，EMD-EWT 算法相较于单一的 EMD 算法和单一的 EWT 算法诊断精度更高，同时还具有很低的虚警率，结果充分表明了本文新方法的正确有效性。

论文研究成果为航空发动机主轴承故障检测与预警提供了新的思路和方法，同时，可以推广到其他领域的滚动轴承早期故障的检测与预警。

关键词：滚动轴承，故障诊断，经验模态分解（EMD），经验小波变换（EWT），包络分析，航空发动机

ABSTRACT

Rolling bearings are critical supporting components in aircraft engines, operating in high-speed and high-temperature environments, while also enduring strong time-varying impact loads. As a result, they are prone to failure, and their operating condition directly affects the engine's reliability and service life. Therefore, fault diagnosis of rolling bearings is of utmost importance. However, due to the deep internal placement of rolling bearings in aircraft engines, their fault vibration signals exhibit significant non-stationarity, multi-component aliasing, and strong background noise, which poses great challenges for traditional signal processing methods. Hence, accurately diagnosing early faults and extracting features from rolling bearings has become an essential research focus in fault diagnosis. To improve the fault diagnosis accuracy of rolling bearings, this paper combines the advantages of Empirical Mode Decomposition (EMD) and Empirical Wavelet Transform (EWT), proposing a new algorithm that integrates EMD and EWT. Through extensive experimental validation, the superiority and effectiveness of the new method have been demonstrated. The main research work is as follows:

(1) The theoretical foundations of the EMD algorithm and the EWT algorithm are introduced. A new method that integrates the EMD and EWT algorithms is proposed. A comparison and analysis using simulation data show that, after combining the two algorithms, the signal can be adaptively decomposed based on its local time-varying characteristics, thus avoiding the end-effect and mode mixing issues inherent in the EMD algorithm, without the need for techniques such as mirroring extension.

(2) Using the internationally recognized bearing fault dataset from Case Western Reserve University and experimental data from rolling bearing fault simulations on a rotor-bearing test rig from Nanjing University of Aeronautics and Astronautics, the decomposition effects of the EMD algorithm, EWT, and the EMD-EWT fusion algorithm are compared in detail. The results show that the EMD-EWT fusion algorithm can more clearly separate fault impact components in the outer race, inner race, and rolling elements of the bearing compared to the single EMD and EWT algorithms. The fault characteristic frequencies and their harmonic components extracted from the envelope spectrum are more prominent. Additionally, a dimensionless index for rolling bearing faults is established, which facilitates more accurate fault identification.

(3) The effectiveness of the new algorithm is further validated using real-life test data from the evolution of main bearing faults in an aircraft engine. The results show that the EMD-EWT algorithm provides higher diagnostic accuracy compared to the single EMD and EWT algorithms, while also having a much lower false alarm rate. The results fully demonstrate the correctness and

effectiveness of the new method proposed in this paper.

The research findings provide a new approach and method for fault detection and early warning of aircraft engine main bearings, which can also be extended to the early fault detection and early warning of rolling bearings in other fields.

Keywords:Rolling bearings, Fault diagnosis, Empirical Mode Decomposition(EMD), Empirical Wavelet Transform (EWT), Envelope analysis, Aeroengine

目 录

第一章 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究进展及现状.....	2
1.2.1 滚动轴承故障信号分析和特征提取方法研究现状.....	2
1.2.2 基于 EMD 的滚动轴承故障信号分析.....	3
1.2.3 基于 EWT 的滚动轴承故障信号分析研究现状.....	4
1.3 问题的提出及本文研究内容.....	6
1.3.1 问题的提出.....	6
1.3.2 本文主要研究内容.....	7
第二章 滚动轴承剥落故障的振动故障信号仿真.....	9
2.1 引言.....	9
2.2 滚动轴承振动机理.....	9
2.2.1 滚动轴承基本结构.....	9
2.2.2 滚动轴承的故障机理及种类.....	10
2.2.3 滚动轴承故障特征频率的计算.....	12
2.3 滚动轴承剥落故障振动信号仿真分析.....	13
2.3.1 外圈故障信号仿真.....	15
2.3.2 内圈故障信号仿真.....	17
2.3.3 滚动体故障仿真信号.....	19
2.4 本章小结.....	21
第三章 融合 EMD 和 EWT 的信号处理新方法.....	23
3.1 引言.....	23
3.2 EMD-EWT 算法的基本原理.....	23
3.2.1 融合算法理论.....	23
3.2.2 方法流程.....	25
3.2.3 关键技术.....	32
3.2.4 仿真信号的 EMD-EWT 算法分析.....	32
3.3 基于特征频率的滚动轴承故障无量纲指标.....	36
3.3.1 数据平稳性检验.....	36
3.3.2 频带分析.....	37

3.3.3 无量纲量的计算	37
3.4 本章小结	38
第四章 基于滚动轴承故障模拟试验器的试验验证	39
4.1 引言	39
4.2 基于凯斯西储大学滚动轴承故障模拟试验验证	39
4.2.1 试验数据简介	39
4.2.2 滚动轴承外圈故障分析结果	40
4.2.3 滚动轴承内圈故障分析结果	45
4.2.4 滚动轴承滚珠故障分析结果	51
4.3 基于带机匣航空发动机转子试验器滚动轴承故障模拟试验验证	56
4.3.1 试验介绍	56
4.3.2 滚动轴承外圈故障转速 2400rpm 分析结果	58
4.3.3 滚动轴承外圈故障转速 2000rpm 分析结果	63
4.3.4 其他转速状态下整体 F_{dB} 分析	68
4.4 基于带机匣航空发动机转子试验器正常轴承模拟试验验证	68
4.5 特征阈值判定方法的建立	70
4.6 本章小结	71
第五章 真实航空发动机主轴承试验验证	73
5.1 引言	73
5.2 故障主轴承整机试验验证	73
5.2.1 试验简介	73
5.2.2 试验数据分析结果	77
5.3 故障主轴承试验器试验验证	86
5.3.1 试验简介	86
5.3.2 试验数据分析结果	87
5.4 正常主轴承试验器试验验证	93
5.5 正常主轴承整机航空发动机试车试验验证	94
5.6 算法计算时间及实时性分析	95
5.7 本章小结	
第六章 总结与展望	98
6.1 全文工作总结	98
6.2 本文主要创新点	99
6.3 未来工作展望	100

参考文献	101
致 谢	106
在学期间的研究成果及发表的学术论文	107

图表清单

图 1.1 轴承失效图	1
图 1.2 本文研究内容及结构关系图	7
图 2.1 滚动轴承典型结构	9
图 2.2 滚动轴承故障类型	11
图 2.3 滚动轴承故障冲击信号仿真	14
图 2.4 外圈故障冲击仿真信号	16
图 2.5 内圈故障冲击仿真信号	19
图 2.6 滚动体故障冲击仿真信号	21
图 3.1 EMD-EWT 融合算法流程图	25
图 3.2 EMD 算法完整流程图	27
图 3.3 傅里叶频谱分割示意图	28
图 3.4 EWT 算法完整流程图	29
图 3.5 仿真信号时域波形	32
图 3.6 仿真信号频谱	32
图 3.7 EMD 算法分解结果	33
图 3.8 EWT 二次精细化处理后的结果	34
图 3.9 EMD 处理后的频谱	35
图 3.10 EWT 二次精细化处理后的频谱	36
图 4.1 凯斯西储大学试验台	39
图 4.2 6205-2RS JEM SKF 深沟球轴承基本结构	40
图 4.3 时域波形图	40
图 4.4 频谱图	41
图 4.5 EMD 分解后 IMF 分量包络谱	42
图 4.6 EWT 分解后子带包络谱	43
图 4.7 EWT 算法二次精细化分解后包络谱	44
图 4.8 全部数据 F_{dB} 值变化趋势	45
图 4.9 时域波形图	46
图 4.10 频谱图	46
图 4.11 EMD 分解后 IMF 分量包络谱	47
图 4.12 EWT 分解后子带包络谱	48
图 4.13 EWT 算法二次精细化分解后包络谱	49
图 4.14 全部数据 F_{dB} 值变化趋势	51

图 4.15 时域波形图	52
图 4.16 频谱图	52
图 4.17 EMD 分解后 IMF 分量包络谱	53
图 4.18 EWT 分解后子带包络谱	54
图 4.19 EWT 算法二次精细化分解后包络谱	55
图 4.20 全部数据 F_{dB} 值变化趋势	56
图 4.21 航空发动机转子试验器	57
图 4.22 故障加工后的 6206 型滚动轴承实物图	57
图 4.23 试验所用的传感器与采集卡	58
图 4.24 时域波形图	58
图 4.25 频谱图	59
图 4.26 EMD 分解后 IMF 分量包络谱	59
图 4.27 EWT 分解后子带包络谱	60
图 4.28 EWT 算法二次精细化分解后包络谱	61
图 4.29 所有数据的 F_{dB} 变化趋势	63
图 4.30 时域波形图	63
图 4.31 频谱图	64
图 4.32 EMD 分解后 IMF 分量包络谱	65
图 4.33 EWT 分解后子带包络谱	65
图 4.34 EWT 算法二次精细化分解后包络谱	67
图 4.35 整体 F_{dB} 变化趋势	67
图 4.36 1800rpm 转速状态下整体 F_{dB} 变化趋势	68
图 4.37 2400rpm 转速状态下整体 F_{dB} 值变化趋势	69
图 4.38 2000rpm 转速状态下整体 F_{dB} 值变化趋势	69
图 4.39 1800rpm 转速状态下整体 F_{dB} 值变化趋势	69
图 5.1 三支点主轴承剥落实物图	74
图 5.2 传感器布置示意图	76
图 5.3 振动数据采集界面	76
图 5.4 东华 8302 型数据采集器实物图	77
图 5.5 时域波形图	78
图 5.6 频谱图	78
图 5.7 EMD 分解后 IMF 分量包络谱	79
图 5.8 EWT 算法二次精细化分解后包络谱	80

图 5.9 时域波形图	81
图 5.10 频谱图	81
图 5.11 EMD 分解后 IMF 分量包络谱	82
图 5.12 EWT 算法二次精细化分解后包络谱	83
图 5.13 整体 F_{dB} 变化趋势	84
图 5.14 98.5%转速比以上数据 F_{dB} 变化趋势	85
图 5.15 A602 轴承试验器主体结构图	86
图 5.16 主轴承疲劳剥落故障	87
图 5.17 扬州晶明硬件系统	87
图 5.18 时域波形图	88
图 5.19 频谱图	88
图 5.20 EMD 分解后 IMF 分量包络谱	89
图 5.21 EWT 算法二次精细化分解后包络谱	90
图 5.22 整体 F_{dB} 变化趋势	92
图 5.23 98.5%转速比以上数据 F_{dB} 变化趋势	92
图 5.24 整体 F_{dB} 值变化趋势图	93
图 5.25 整体 F_{dB} 值变化趋势图	94
表 2.1 滚动轴承典型结构轴承参量表	10
表 4.1 轴承参数	40
表 4.2 F_{dB} 值汇总表	42
表 4.3 F_{dB} 值汇总表	43
表 4.4 F_{dB} 值汇总表	44
表 4.5 轴承参数	46
表 4.6 F_{dB} 值汇总表	47
表 4.7 F_{dB} 值汇总表	48
表 4.8 F_{dB} 值汇总表	49
表 4.9 轴承参数	51
表 4.10 F_{dB} 值汇总表	53
表 4.11 F_{dB} 值汇总表	54
表 4.12 F_{dB} 值汇总表	55
表 4.13 人工故障轴承的基本尺寸参数	57
表 4.14 基于带机匣转子试验器的人工故障轴承试验方案	57

表 4.15 滚动轴承外圈故障数据信息	58
表 4.16 F_{dB} 值汇总表	60
表 4.17 F_{dB} 值汇总表	60
表 4.18 F_{dB} 值汇总表	61
表 4.19 轴承参数	63
表 4.20 F_{dB} 值汇总表	66
表 5.1 传感器参数	74
表 5.2 轴承参数	77
表 5.3 F_{dB} 值汇总表	80
表 5.4 F_{dB} 值汇总表	83
表 5.5 试验器性能指标	86
表 5.6 轴承参数	87
表 5.7 F_{dB} 值汇总表	90

注释表

r_1	内径	A_1, A_2	幅值参数
r_2	外径	L	信号长度
d	滚动体直径	SD	标准差阈值
α	接触角	$x(t)$	原信号
Z	滚动体个数	$C_n(t)$	特征模态分量
f_r	转频	$f(\omega)$	Fourier 频谱
v_b	滚动体中心点的线速度	$\beta(x)$	平滑过渡函数
ω_b	角速度	$w_f^e(0, t)$	逼近系数
v_i	接触点的线速度	m	时间延迟参数
ω_i	接触点的角速度	SI	平稳性指标
f_0	外圈故障特征频率	$W_1(f)$	第 1 个频带包络谱值
θ_0	滚动体在内圈旋转一周的时间内绕静止的外圈轴心旋转的角度	Ne	包络谱的谱线数
f_i	内圈故障特征频率	S_{al}	包络谱的均值
θ_i	滚动体在内圈旋转一周的时间内绕内圈轴心旋转的角度	δf	特征频率的容差范围
f_c	保持架故障特征频率	Δf	包络谱的间隔
$S_{fault}(t)$	故障冲击信号	S_{ol}	无量纲特征量
$S_{noise}(t)$	噪声信号	F_{dB}	故障特征量
μ	均值	σ	标准差
c	归一化系数	ξ	阻尼系数
f_n	轴承共振的固有频率	f_{fault}	故障特征频率
$g_0(t)$	首次冲击	$\delta(nT_{fault})$	周期单位脉冲函数

缩略词

缩略词	英文全称
EMD	Empirical Mode Decomposition
IMF	Intrinsic Mode Function
EWT	Empirical Wavelet Transform
FFT	Fast Fourier Transform

第一章 绪论

1.1 研究背景及意义

航空发动机作为现代航空装备的核心部件，其性能直接关系到飞行器的安全性、经济性和作战能力。航空发动机的结构极为复杂，其研制过程涉及材料学、机械加工、流体力学、燃烧学、自动控制等众多学科领域，需要先进的科学技术和极高的制造工艺作为支撑，成功研制一款航空发动机的技术难度极高，是一个国家科学技术、工业实力以及军事国防力量的重要象征^[1]。其中，主轴承作为发动机中的关键部件，承担着支承涡轮、压缩机以及其他高速旋转部件的重要职责，是保障发动机稳定运行的基础，既要满足长寿命和高可靠性需求。还要不断适应持续发展的高速、重载、高温、乏油、断油等极限工况及变速、变载等复杂循环工况。然而，在复杂且恶劣的环境下，主轴承容易发生剥落、点蚀、磨损、胶合等轴承失效情况，一旦主轴承发生故障，将导致转子动力学特性异常、转静子碰摩、油路温度异常、严重甚至会导致航空发动机发生结构损毁，将会对航空发动机整机造成极大的影响，因此，提高航空发动机滚动轴承的早期故障检测和健康监测能力，对保障航空安全与降低维修成本具有不可替代的重要意义。滚动轴承的失效模式有很多种，大致有如下分类：滚动接触剥落、断裂和开裂、磨损、腐蚀等，如图 1.1 所示。




图 1.1 轴承失效图

主轴承的故障是由多种因素共同作用下的结果，外在因素包括其在极端主轴承的故障原因由多种因素共同作用，外在因素包括其在极端复杂且快速变化的工况环境下运行时所承受的负

荷, 如剧烈变化的热-力耦合载荷、润滑条件的恶化以及服役过程中可能出现的颗粒污染等; 内在因素则涉及材料、结构和制造工艺等固有特征, 如轴承的微观组织状态、表面粗糙度、结构设计的可靠性, 以及装配过程中的应力分布等。

在航空发动机等机械故障案例中, 轴承部件故障比例极为显著^{[2]-[4]}, 因此, 滚动轴承状态监测与故障诊断在航空发动机中占据极为重要的地位, 是保障航空发动机使用安全、减少飞行事故的关键技术。

1.2 国内外研究进展及现状

1.2.1 滚动轴承故障信号分析和特征提取方法研究现状

早期对于振动信号的故障特征主要从时域进行提取, 张沛朋^[5]等人通过提取振动信号的 12 个时域特征, 对 12 个基本时域特征进行主成分分析, 最终对轴承故障进行诊断。Wang^[6]等人提出了一种基于递归定量分析 (RQA)-贝叶斯-支持向量机 (SVM) 的滚动轴承故障诊断技术。递归图能够表征轴承状态, 而 RQA 可以提取用于故障模式和程度区分的非线性参数。但是伴随着旋转机械的结构、功能等方面日益复杂, 时域分析已经无法完全满足故障特征提取的需求, 因此陈永会^[7]等人通过希尔伯特变换对时域信号进行解调和精细频谱分析, 从而提取故障信号的特征频率。但是对于复杂的机械设备, 存在强噪声等干扰因素, 轴承的周期性故障特征非常微弱, 因此许多其他的方法被引入从而提升故障冲击特征。郑近德^[8]等人通过引入广义经验模态分解 (GEMD) 和改进的直接正交解调 (IDQ) 对信号进行分解, 通过定义不同的均值曲线获得多个 IMF, 并在每个级别中选择最佳的 IMF, 然后利用改进的经验 AM-FM 分解和 IDQ 对分量进行解调, 最终得到故障冲击信号。于德介^[9]等人通过经验模态分解 (EMD) 将原始调制信号分解为多个 IMF, 然后定义包含主要故障信息的 IMF 包络谱中不同故障特征频率的振幅比作为特征振幅比, 将其输入到 SVM 分类器进行故障识别。张亿雄^[10]等人探讨了利用小波包分析进行滚动轴承故障诊断的方法, 并编写了相应的程序。张国新、鞠晨^{[11]-[14]}等人通过小波包分解提取特征参数向量, 并将这些向量输入 BP 神经网络进行状态识别。杨学存^[12]等人提出了一种基于小波分析的滚动轴承故障诊断方法, 利用小波阈值降噪法进行数据消噪处理, 并对消噪后的数据进行了 5 层小波分解, 再根据轴承故障特征频率, 对故障特征频率所在层进行小波重构, 计算功率谱密度, 该方法能够有效识别滚动轴承内圈、外圈和滚动体的故障。刘长良^[13]等人通过变分模态分解对故障信号进行分解, 使用奇异值分解提取模态特征, 再结合模糊 C 均值聚类进行故障识别。

时域分析方法以及频域分析方法为滚动轴承故障诊断提供了有效的信号处理方向, 但是随

着滚动轴承故障诊断的要求的提高,传统的时频域分析方法表现出了一定的局限性,尤其在处理非平稳、非线性、复杂的滚动轴承故障信号时。因此经验模态分解(EMD)和经验小波变换(EWT)作为近年来发展起来的先进信号处理方法,得到了广泛的关注与应用。

1.2.2 基于 EMD 的滚动轴承故障信号分析

经验模态分解(Empirical Mode Decomposition, EMD)作为一种典型的故障诊断方法,在滚动轴承故障诊断中有着非常广泛的应用。经验模态分解不依赖基函数,其分解过程可以根据信号本身局部的信号特征来完成自适应分解。经验模态分解通过将复杂的振动信号分解成若干个本征模态函数(IMF),从而分解得到不同尺度的振动成分,以此来增强早期故障冲击成分的表现。因此,EMD算法在滚动轴承故障特征提取、降噪以及早期故障诊断中已有相当成熟的应用。

Wu等人^[15]提出了基于经验模态分解的新方法EEMD(集合经验模态分解),通过引入有限且无穷小幅值的白噪声,从而迫使集合在筛选过程中有无穷个解,不同尺度的信号在双域滤波器组规定的适当的固有模态函数(IMF)中排列。经过多次筛选,将平均值作为最终结果进行输出。雷亚国^[16]等人介绍了EMD算法,阐明了EMD算法的有效性,并将其应用在滚动轴承、齿轮、转子等方面。Huang^[17]等人基于使用经验模态分解对白噪声进行数值试验,发现固有模态函数(IMF)都是呈正态分布,并对这些固有模态函数进行特性统计,最终建立了一种能够从任何噪声数据中为IMF分量分配信息内容统计的方法。Zhou^[18]等人针对快速傅里叶变换(FFT)难以提取轴承信号特征频率的问题,提出了一种基于经验模态分解(EMD)、峭度以及希尔伯特解调相结合的故障诊断方法。Wu^[19]等人提出了一种结合经验模态分解-希尔伯特包络谱分析和BP神经网络的滚动轴承故障诊断方法。Zong^[20]等人提出一种基于微分的经验模式分解(DEMD)模糊熵和支持向量机(SVM)相结合的滚动轴承故障诊断方法。吕勇^[21]等人提出了一种基于多变量经验模态分解的滚动轴承故障特征提取新方法,采用非局部均值(NL-Means)去噪和相关性分析。Liu^[22]提出了一种基于经验模态分解(EMD)和局部切空间对齐算法(LTSA)的特征提取方法,该方法能够从滚动轴承的振动信号中提取敏感故障特征,提高了对滚动轴承早期故障的模式识别和故障诊断能力。Huang^[23]等人提出一种基于经验模态分解(EMD)和卷积循环神经网络(CRNN)的利用振动信号的方法。

但是EMD算法本身存在了端点效应与模态混叠等不可避免地问题。Yeh^[24]等人通过提出一种新的算法CEEMD(互补集合经验模态分解),增加了正负白噪声,有效地解决了经验模态分解模式混叠的问题,并且由于EEMD(集合经验模态分解)算法,减少了残余噪声。N.Rehman^[25]等人提出了一种用于多变量信号时间频率分析的多变量经验模态分解(Multivariate EMD)方法,通过在超球面上沿多个方向进行实值投影计算信号包络和局部均值,解决了传统EMD在多变

量信号处理中的局限性。胡爱军^[26]等人提出了一种基于集合经验模态分解（EEMD）和峰度准则的包络解调方法，用于滚动轴承的精确故障诊断，有效抑制了 EMD 的模态混叠现象，并避免了共振解调方法中的中心频率和滤波带宽选择问题。司莉^[27]等人提出了一种改进的经验模态分解方法，通过镜像扩展和余弦窗函数处理信号端点，以及采用高频谐波与掩膜信号抑制模态混叠，有效解决了传统方法中的端点效应和模态混叠问题，Xiao^[28]等人运用微分的方法对传统的经验模式分解在滚动轴承故障诊断中出现的混波问题并进行改进，通过提高其高频分量的能量比进行更好的故障分量提取，并结合 Hilbert 变换后的包络谱分析完成对滚动轴承故障类型的分析判断。Meng^[29]等人提出了一种自适应波形匹配延拓的算法来抑制经验模态分解的端点效应，并结合信息熵、峭度值和希尔伯特-黄变换用于轴承的故障诊断。

尽管经验模态分解（EMD）在处理非线性和非平稳信号方面展现出显著的优势，但其仍存在一些固有缺点。首先，EMD 的分解结果对端点效应较为敏感，尤其在处理信号的边缘部分时，容易产生不准确的模态分量，这会影响到最终的分析结果。此外，EMD 算法容易发生模态混叠现象，特别是在信号的低频部分，不同的模态可能会重叠在一起，导致无法有效地提取出独立的故障特征。为了解决这些问题，通常需要采用如镜像延拓等额外处理手段^[20]，但这些手段存在着一定的主观性，往往不能完全消除问题，且可能引入新的误差。因此，如何克服 EMD 算法中的模态混叠与端点效应问题，成为提升其准确性和鲁棒性的关键挑战。

1.2.3 基于 EWT 的滚动轴承故障信号分析研究现状

经验小波变换（Empirical Wavelet Transform, EWT）是一种自适应时频分析的方法，与传统小波变换相比，不再依赖于提前预定的母小波函数，其根本思想在于根据信号的实际频谱特性自适应地构建小波滤波器组，从而实现信号分解，这种分解方式能够分解非平稳性、频率成分较为复杂以及冲击能量微弱的滚动轴承振动信号。首先，经验小波变换根据信号频谱的局部极值点自动确定边界的分解，将频谱划分为若干个子频带。这种自适应机制能够避免传统小波变换中频带划分固定，难以提取复杂机械振动信号中冲击成分的缺陷，使其在处理滚动轴承振动信号时使故障特征频率具有更高的频率成分及灵活性。其次，EWT 算法构建的经验小波具有更优良的带通特性，能够使分解更加稳定，从而更好地对弱故障冲击信号进行捕捉。因此国内外学者针对 EWT 算法进行了大量的研究。

Xu^[30]等人提出了一种新颖的频谱分割方法来改善 EWT 在边界划分方面的缺点。所提方法考虑了频谱本身的波形。首先，通过迭代计算频谱的上包络函数和下包络函数的均值来获得不同的频谱趋势。然后，根据准则选取最合适的趋势，并通过检测趋势的局部最小值来实现频谱分割。最后，通过一组带通滤波器获得经验模态。Zheng^[31]等人通过开发一种新的分割方法，提出了一种改进的经验小波变换（IEWT）方法。同时，将 IEWT 与经验模态分解（EMD）和

EWT 进行比较, 以验证 IEWT 在分解精度方面的优越性。通过结合精细复合多尺度分散熵 (RCMDE), 这是一种用于振动信号不规则性测量的强大非线性工具, 提出了一种基于 IEWT、RCMDE、多聚类特征选择和支持向量机的新型诊断方法。Ou^[32]等人提出了一种基于集合经验小波变换 (EWT)、全变差最小化 (TV-MM) 和改进粒子群优化 (IPSO) 的滚动轴承故障检测集成分析方法。盛嘉玖^[33]等人针对经验小波变换 (EWT) 在滚动轴承故障信号最优频带提取中存在的问题, 提出一种基于提取能量包络趋势线以自适应划分频带的改进 EWT 方法, 并应用于滚动轴承故障诊断。利用 Teager 能量算子将频谱转换成能量谱, 通过反复希尔伯特变换得到能量包络线。提取极大值并平滑处理, 获得能量包络趋势线, 对其进行 1 阶差分, 选取有效极值点以自适应划分频带。构造一种归一化故障特征频率显著性指标, 作为故障诊断和最优共振频带选取的有效判据。Li^[34]等人提出了一种将改进的自适应无参数经验小波变换 (IAPEWT) 和自适应稀疏编码收缩去噪 (ASCS) 算法相结合的滚动轴承故障诊断方法。李志农^[35]等人采用 EWT 方法自适应地对信号进行分解, 通过在频域提取最大值点分割傅立叶谱, 构建正交波let 函数, 提取具有紧凑傅立叶谱的 AM-FM 分量。并与传统 EMD 算法进行比较, 证明 EWT 算法具有更强的信号分解能力, 能够有效地识别机械故障特征。郑近德^[36]等人提出了一种自适应无参数经验小波变换 (APEWT) 方法, 结合改进的归一化希尔伯特变换 (INHT), 有效应用于转子系统故障诊断。通过改进经验小波变换, 实现了无需参数设置的信号时频分析, 并提出了 INHT 以更准确地估计信号的时间-频率分布。Pan^[37]等人提出了一种增强型经验小波变换 (EEWT) 并应用于滚动轴承故障诊断, 通过对比 Hilbert-Huang 变换 (HHT), 证明了 EEWT 在故障诊断中的有效性及优越性。该方法通过改进经验小波变换, 提出了一种新的时间-频率分析方法, 首先使用 EEWT 将非平稳信号分解为具有紧支撑频谱的多个固有模态函数 (IMFs), 然后通过解调每个 IMF 获得原始信号的时间-频率分布。Muhammad^[38]等人提出了一种基于多变量经验小波变换 (MEWT) 的框架, 通过多尺度主成分分析进行预处理以增强鲁棒性, 采用自动化通道选择策略, 并使用 MEWT 进行子带对齐获取联合瞬时幅值和频率分量。Kedadouche M 等人^[39]将操作模态分析 (OMA) 融入 EWT 框架, 在 Fourier 谱上利用振动信号的动力学特性分割边界, 显著提升了频带划分的物理适配性。然后 Zheng J^[40]又提出改进方案, 该方案引入正交导数的归一化希尔伯特变换 (QDNHT) 构建自适应阈值选择机制, 并且无需参数设置, 成功消除传统方法对人工调参的依赖。XU Y 等人^[41]开发快速 EWT (FEWT) 算法, 通过 Fourier 变换重构频谱趋势, 谱段划分选择使用极小值来检测, 并通过边界构造小波滤波器分解。HU Y^[42]等人提出增强 EWT (EEWT) 架构, 其核心在于采用顺序统计滤波器 (OSF) 动态筛选最佳共振频带。此外, 他们为了克服从包络谱或包络阶次谱中很难检测到轴承故障特征的问题, 将 EEWT 与新型脊线提取算法相结合^[43], 构建了一种自适应无转速计阶次分析方法对动态路径优化处理后的信号进行故障特征提取, 实现了变速轴承的故障诊断。高中强等人^[44]为了选取自适

应划分频带，提出了一种自适应去噪的 ADEWT 方法，该方法主要采用双重融合指标去噪，利用边界自适应滤波，从而实现诊断。

1.3 问题的提出及本文研究内容

1.3.1 问题的提出

在滚动轴承故障诊断中，振动信号往往是非平稳、非线性的，整机发动机更是如此，使得信号分析方法对其自适应性以及分解精度有着极高的要求。经验模态分解与经验小波变换就是两类典型的自适应信号处理方法。

经验模态分解是一种完全以数据为基础的时频分析方法，其优势主要在于无需预设基函数，可以根据信号的局部特性自适应地将原始信号分解成若干个本征模态分量函数（IMF）。这种自适应分解的特性能够适用于滚动轴承振动信号的非平稳、非线性的特性^{[15],[45],[46]}。此外，EMD 算法能够将不同尺度的振动信号进行有效的分离，更大尺度地凸显微弱地故障冲击特征。但是同时 EMD 算法有着自身局限性。首先，EMD 算法对噪声高度敏感。容易产生模态混叠地影响，即不同的频率成分混杂在同一个 IMF 分量中，或同一个频率成分被分解到多个 IMF 分量中，导致需要的故障特征频率成分被淹没。其次，由于 EMD 算法本身需要依赖极值点进行插值，分解出的 IMF 分量非常容易产生端点效应，具体表现为端点的偏移以及两端波形发生畸变等^[47]。

经验小波变换能够根据振动信号的实际频谱结构自适应构建经验小波滤波器组，能够更好地划分频带，使频带划分得更加合理。这种方法能够有效地克服传统小波变换频带划分固定且难以进行优化的问题，使故障特征频率在复杂环境下能够更好地被提取。并且，通过 EWT 构造的滤波器具备更优良的数学正交性以及带通特性，能够让分解结果更加稳定，降低频带之间的能量泄漏。在强噪声环境下表现更加明显^[29]。但是经验小波变换由于依赖于频谱的局部极值点，容易受到噪声的影响。当振动信号被噪声严重污染时，频谱边界容易识别错误而导致信号分解失败。此外，经验小波变换更适用于相对平稳的信号，对于频率变化极大以及不规则的信号，分解效果会变差。同时相较于 EMD 算法，EWT 算法在时域局部特征捕捉方面有着很大的不足^[48]。

在进行真实整机发动机振动数据分析时，由于采集到的振动信号往往会伴随着强烈的噪声、复杂的固有频率以及不规则的振幅，EMD 算法与 EWT 算法不能对信号进行有效的分解。因此，亟须寻求一种能够处理极低信噪比下复杂振动信号的方法尤为重要。

1.3.2 本文主要研究内容

通过对 EMD 与 EWT 算法的详细研究发现，两者的优势呈互补关系，EMD 算法具有极强的时域局部特征自适应性，而 EWT 算法则对于频域特征具有极强的自适应性，两者在时域以及频域方面形成天然的互补。相较于 EMD 与 EWT，其他算法都有各自的局限性。VMD（变分模态分解）虽然具有更加严格的标准，但是其需要预先设定模态数量，不具备自适应分解的条件，更不适应于复杂工况下的故障诊断；WT（小波变换）需要依赖固定的小波基函数，难以适应非平稳信号。因此将二者相融合构建 EMD-EWT 算法具有极大的可行性。将 EMD 算法作为信号预处理步骤，对非平稳且噪声强烈的原始信号进行自适应分解，产生的 IMF 分量是相对平稳且频率更加清晰的 IMF 分量，从而降低噪声以及不规则信号对于 EWT 分解的影响，接着对含有故障关键信息的 IMF 分量进行 EWT 二次精细化频带划分，从而避免 EMD 算法固有的模态混叠及端点效应的问题，使得分解后的成分故障特征更加明显。经过 EMD-EWT 融合处理，既结合了 EMD 算法对于时域的自适应性，又结合了 EWT 算法频域优化的能力。

本文旨在研究 EMD 算法与 EWT 算法相结合的可行性与处理复杂信号的准确性，通过 MATLAB 进行融合代码的编写，最终基于试验器数据以及整机振动数据进行实验验证。如图 1.2 所示。

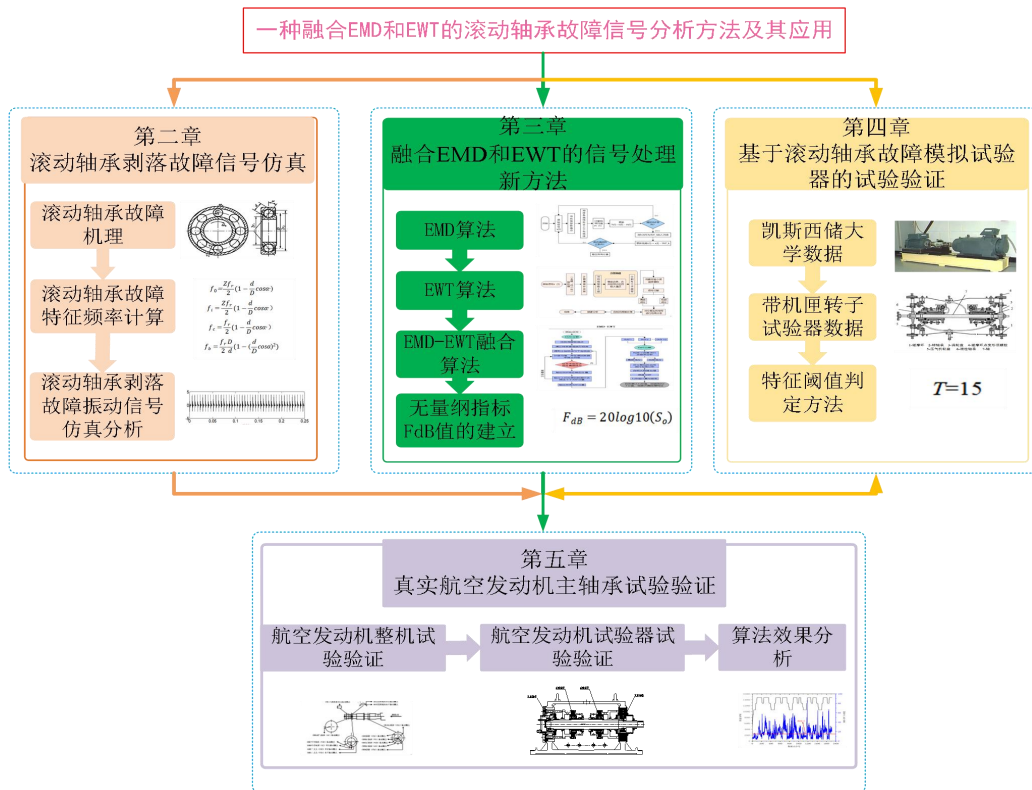


图 1.2 本文研究内容及结构关系图

具体的研究内容为：

(1) EMD 算法：研究 EMD 算法在处理振动数据时的优势与劣势，通过仿真振动数据分析端点效应与模态混叠的存在形式。

(2) EMD-EWT 融合算法：研究 EWT 算法在处理振动数据时的优势与劣势，进行 EWT 算法与 EMD 算法融合代码的编写，通过仿真数据验证 EMD 算法的端点效应以及模态混叠能否得到有效抑制。

(3) 数据验证：通过对西储大学滚动轴承故障公开数据集、带机匣试验器滚动轴承故障模拟试验数据、真实航空发动机主轴承故障模拟试验数据进行处理，提出滚动轴承故障无量纲诊断指标。将结果进行对比，得出结论，并验证融合算法的有效性。

第二章 滚动轴承剥落故障的振动故障信号仿真

2.1 引言

本章主要介绍了滚动轴承的基本结构、常见故障类型、故障机理以及特征频率的计算方法。滚动轴承作为航空发动机及其他高精密机械设备中的核心部件，其运行状态对设备的可靠性和安全性具有重要影响。为有效进行滚动轴承的故障诊断，首先需要了解其结构组成和常见故障模式。接着，分析故障的发生机制和相应的特征频率，进而为故障检测与识别提供理论依据。在此基础上，本章进一步构建了滚动轴承外圈、内圈以及滚动体故障的仿真信号模型，为后续的故障诊断方法研究奠定了基础。通过对这些模型的深入分析与模拟，能够为滚动轴承的早期故障预警和健康监测提供有力支持。

2.2 滚动轴承振动机理

2.2.1 滚动轴承基本结构

滚动轴承根据其结构不同可以分为不同的种类，如单列深沟球轴承、圆柱滚子轴承、角接触球轴承等。滚动轴承典型结构如图 2.1，参数见表 2.1




图 2.1 滚动轴承典型结构

表 2.1 滚动轴承典型结构轴承参量表

名称	符号	含义
内径	$2r_1$	内圈平均直径
外径	$2r_2$	外圈平均直径
节径	D	滚动体球心所在圆的平均直径
滚动体直径	d	滚动体平均直径
接触角	α	滚动体受力方向与内外圈垂直线的夹角
滚动体个数	Z	滚动体的个数

2.2.2 滚动轴承的故障机理及种类

滚动轴承是广泛应用于各类机械设备中的关键部件，广泛用于汽车、航空、铁路、风力发电、矿山等领域。由于其承载着旋转部件的负载，并且长期处于高速运转的状态，滚动轴承在运行过程中会受到多种因素的影响，从而引发不同类型的故障。滚动轴承故障不仅会导致机械设备性能下降，还可能对设备的安全性、可靠性产生严重影响。因此，了解滚动轴承故障产生的方式和种类，对于提高设备的可靠性、延长使用寿命至关重要。

滚动轴承的故障通常是由以下几点造成的

(1) 润滑不良：润滑剂的不足、劣化或污染是导致滚动轴承故障的主要原因之一。润滑不良会导致轴承内摩擦增加，从而导致温升过高，润滑油膜破裂，金属表面直接接触产生磨损。长时间的润滑不良会导致轴承表面产生热损伤、磨损加剧，甚至出现疲劳裂纹。

(2) 过载：轴承在长时间的超负荷运转下，承受的压力超过了其设计承载能力，导致材料的塑性变形和疲劳损伤。过载会导致滚动体和滚道的接触点产生较大的接触应力，导致轴承表面损伤，甚至发生剥离现象。

(3) 材料缺陷：轴承在制造过程中，若材料的质量不达标或生产工艺存在问题，可能会在轴承的滚动体、内圈或外圈表面产生微小缺陷。随着运行时间的延长，这些缺陷会逐渐发展，最终导致裂纹或剥离现象的发生。

(4) 外部冲击：外部振动、冲击负荷或安装不当也可能引发滚动轴承故障。设备运行时的冲击力会导致滚动体和滚道之间的接触产生瞬间高压，从而引发轴承的磨损或局部的疲劳损伤。

(5) 环境因素：如温度过高或过低、湿度过大、腐蚀性物质的侵蚀等，也会影响滚动轴承的运行。高温环境会导致润滑油变质，降低润滑效果；湿气或污染物进入轴承，可能引起腐蚀，导致表面损伤，进而引发故障。

而根据滚动轴承故障的产生原因以及其表现，可以将滚动轴承故障分成以下几种类别：

(1) 磨损故障：磨损是轴承故障中最常见的一种类型。通常由于润滑不足、污染或载荷过大等因素引起的，磨损会使得滚动体和滚道的接触面逐渐损坏，出现磨痕或凹坑，导致轴承的运行精度下降、噪声增加，最终影响轴承的使用寿命。常见的磨损故障包括滑动磨损、擦伤磨损和腐蚀磨损等。

(2) 剥落故障：剥落是由于滚动轴承表面发生疲劳裂纹扩展而产生的一种故障。当轴承长期在过载或不良润滑环境下工作时，表面会逐渐产生微裂纹，这些裂纹随着时间的推移会扩大并导致局部材料脱落。剥落故障通常发生在滚动体或滚道表面，导致设备的振动和噪声增加，甚至可能使轴承彻底失效。

(3) 疲劳故障：轴承的疲劳故障是指由于长期承受反复的循环载荷，导致轴承材料的疲劳破裂。常见的疲劳故障形式包括表面疲劳裂纹、滚道疲劳损伤和滚动体疲劳损伤。疲劳故障会导致轴承表面产生裂纹或崩落现象，通常出现在高负荷、高速度和不良润滑条件下。

(4) 腐蚀故障：腐蚀是由于环境因素（如湿气、盐分等）或不合格的润滑剂引起的。腐蚀会导致轴承表面发生局部的化学反应，形成氧化膜或腐蚀坑，进而加速轴承的损坏。腐蚀故障通常发生在高湿度或有化学物质污染的环境中，容易造成轴承失效。

(5) 噪声和振动故障：滚动轴承在发生故障时，往往会表现出异常的噪声和振动。故障类型如剥落、裂纹或磨损都会使得滚动体和滚道之间的接触不再均匀，导致局部振动的产生。随着故障的加剧，振动和噪声的幅度会逐渐增大，最终影响设备的正常运行。

(6) 热损伤：热损伤是由于轴承长期工作在过高温度下导致的故障。温度过高会导致润滑油的性能下降，增加摩擦和磨损，同时高温还可能引起材料的软化或变形，严重时可能导致轴承发生卡死或损坏。

(7) 误差故障：安装误差、加工误差或装配不良等因素，也可能导致轴承发生故障。这些误差会导致轴承的运行不平稳，产生不均匀的载荷分布，增加摩擦和磨损，进而引发故障。如图 2.2 所示为滚动轴承故障的三种类型。




图 2.2 滚动轴承故障类型

2.2.3 滚动轴承故障特征频率的计算

故障特征频率的影响因素有其自身的结构以及转速。为了便于计算，假设外圈固定，内圈与轴旋转，接触角为 0° 。轴承基本参数如表 2.1 所示，在表中用 f_r 代表转频， $D/2$ 代表滚动体的中心点到轴心的距离， v_b 代表滚动体中心点的线速度， ω_b 代表角速度， $(D-d)/2$ 代表滚动体与内圈的接触点到轴心的距离，其中 v_i 代表该接触点的线速度， ω_i 代表该接触点的角速度，外圈为静止状态，故有如下关系式：

$$v_i = 2v_b \quad (2.1)$$

$$\omega_i(D-d) = 2\omega_b D \quad (2.2)$$

f_0 是外圈故障特征频率，计算内圈旋转一周的时间内通过外圈故障点的滚动体个数， $T=1/f_r$ 为内圈旋转一周所需要的时间。滚动体在内圈旋转一周的时间内绕静止的外圈轴心旋转的角度记为 θ_0 ：

$$\theta_0 = \omega_b T = \frac{\omega_i(D-d)}{2D} T = \frac{2\pi f_r(D-d)}{2D f_r} = \pi(1-d/D) \quad (2.3)$$

相当于单个滚动体绕轴心旋转角度 $1/2(1-d/D)$ ，与外圈故障点接触次数为 $1/2(1-d/D)$ 次。其中滚动体个数为 Z ，滚动体与外圈故障点接触的次数在内圈旋转一周的时间 T 内为 $1/2Z(1-d/D)$ 次，因此 f_0 为：

$$f_0 = \frac{Z f_r}{2} \left(1 + \frac{d}{D}\right) \quad (2.4)$$

f_i 是内圈故障特征频率，计算内圈旋转一周的时间内通过内圈故障点的滚动体个数， $T=1/f_r$ 为内圈旋转一周所需要的时间。滚动体在内圈旋转一周的时间内绕内圈轴心旋转的角度记为 θ_i ：

$$\theta_i = (\omega_i - \omega_b) T = \left(\omega_i - \frac{\omega_i(D-d)}{2D}\right) T = \omega_i \frac{D+d}{2D} T = \pi(1+d/D) \quad (2.5)$$

相当于单个滚动体绕轴心旋转角度 $1/2(1+d/D)$ ，与内圈故障点接触次数为 $1/2(1+d/D)$ 次。其中滚动体个数为 Z ，滚动体与内圈故障点接触的次数在内圈旋转一周的时间 T 内为 $1/2Z(1+d/D)$ 次，因此 f_i 为：

$$f_i = \frac{Z f_r}{2} \left(1 + \frac{d}{D}\right) \quad (2.6)$$

保持架故障特征频率与外圈和内圈故障特征频率的计算方式一致，保持架故障特征频率 f_c 的表达式为：

$$f_c = \frac{f_r}{2} \left(1 - \frac{d}{D}\right) \quad (2.7)$$

滚动体的故障特征频率与上述保持架、外圈、内圈故障特征频率的计算都不一致，可以理解为在内圈旋转周期 T 内，滚动体在内圈或外圈上的自转圈数。滚动体的自转圈数就是滚动体

在外圈上滚动的全部距离除以周长：

$$n_0 = \frac{\theta_i D + d}{\pi d} = \frac{\pi(1 - d/D)D + d}{\pi d} = \frac{D}{2d} \left(1 - \left(\frac{d}{D}\right)^2\right) \quad (2.8)$$

滚动体在内圈上的自转圈数如下：

$$n_i = \frac{\theta_i D - d}{\pi d} = \frac{\pi(1 + d/D)D - d}{\pi d} = \frac{D}{2d} \left(1 - \left(\frac{d}{D}\right)^2\right) = n_0 \quad (2.9)$$

故滚动体故障特征频率不管是从内圈还是外圈来计算，结果是一致的：

$$f_b = \frac{f_r D}{2d} \left(1 - \left(\frac{d}{D}\right)^2\right) \quad (2.10)$$

但是不同的轴承类别，接触角也会发生变化，如深沟球轴承的接触角为 0° ，则在深沟球轴承的故障诊断中不需要考虑接触角的影响，但是在角接触球轴承中存在接触角的变化，则需要考虑接触角。

对于有接触角的情况，外圈、内圈、滚动体、保持架的故障特征频率计算方式发生改变，滚动体与轴中心的距离仍然记为 D ，但是内圈与滚动体的接触点与轴的距离发生改变，变为 $(D - d \cos \alpha)/2$ ，故滚动轴承各故障特征频率如下：

$$f_0 = \frac{Z f_r}{2} \left(1 - \frac{d}{D} \cos \alpha\right) \quad (2.11)$$

$$f_i = \frac{Z f_r}{2} \left(1 - \frac{d}{D} \cos \alpha\right) \quad (2.12)$$

$$f_c = \frac{f_r}{2} \left(1 - \frac{d}{D} \cos \alpha\right) \quad (2.13)$$

$$f_b = \frac{f_r D}{2d} \left(1 - \left(\frac{d}{D} \cos \alpha\right)^2\right) \quad (2.14)$$

2.3 滚动轴承剥落故障振动信号仿真分析

滚动轴承的故障信号可以理解为在故障特征信号的基础上叠加噪声信号即故障冲击信号 $S_{\text{fault}}(t)$ 和噪声信号 $S_{\text{noise}}(t)$ 的叠加。

$$S(t) = S_{\text{fault}}(t) + S_{\text{noise}}(t) \quad (2.15)$$

上式中 $S(t)$ 表示采集的振动信号。

(1) 噪声信号

在使用传感器采集滚动轴承振动信号时往往会受到许多噪声因素的干扰，如环境噪声、结构噪声等，在进行滚动轴承故障信号仿真时，将复杂的、随机性强的噪声信号简化为高斯白噪声，利用高斯白噪声来模拟滚动轴承故障信号中的噪声成分。高斯白噪声可以通过正态分布独立重采样：

$$S_{\text{noise}}(t) \sim N(\mu, \sigma^2) \quad (2.16)$$

在式 2.16 中 μ 代表着均值, σ 代表着标准差。在通常情况下将 μ 设为 0, 只通过 σ 的大小来控制高斯白噪声的幅值。

(2) 故障冲击信号

故障冲击信号是由于损伤的滚动轴承在运行时, 接触表面的损伤点产生冲击, 进而引发轴承共振的现象。故障冲击信号的幅值呈指数发生衰减, 单次冲击信号可由下式 (2.17) 得到:

$$g_i(t) = \begin{cases} c \cdot \exp\left(-2\pi\xi f_n \left(t - \frac{i}{f_{\text{fault}}}\right)\right) \sin\left(-2\pi f_n \sqrt{1-\xi^2} \left(t - \frac{i}{f_{\text{fault}}}\right)\right) & t \geq \frac{i}{f_{\text{fault}}}, i \in N \\ 0 & \text{其他} \end{cases} \quad (2.17)$$

在式 2.17 中, c 是归一化系数, ξ 是阻尼系数, 代表冲击信号衰减的速率, f_n 是轴承共振的固有频率, f_{fault} 为故障特征频率, i/f_{fault} 代表第 i 次冲击发生的时刻。在转速不变的情况下, 每两次冲击之间间隔时间是固定的为 $T_{\text{fault}} = 1/f_{\text{fault}}$, 而由间隔为 T_{fault} 的冲击叠加得到的就是完整的故障冲击信号, 从理论上来说, 如果每一次的冲击大小是相同的, 则完整的冲击信号可以看作是首次冲击 $g_0(t)$ 和周期单位脉冲函数 $\delta(nT_{\text{fault}})$ 的时域卷积, 如图 2.3 所示: 图 2.3 (a) 是首次冲击的时域波形和频谱, 其中基本参数 $\xi = 0.15$, $f_n = 1500\text{Hz}$, $f_r = 50\text{Hz}$; 图 2.3 (b) 是周期单位脉冲函数 $\delta(nT_{\text{fault}})$ 的时域波形和频谱, 其中基本参数 $n \in N, T_{\text{fault}} = 1/175\text{s}$; 图 2.3 (c) 是根据傅里叶变换时域卷积定理得到的仿真故障冲击信号 $g(t)$ 的时域波形以及频谱。

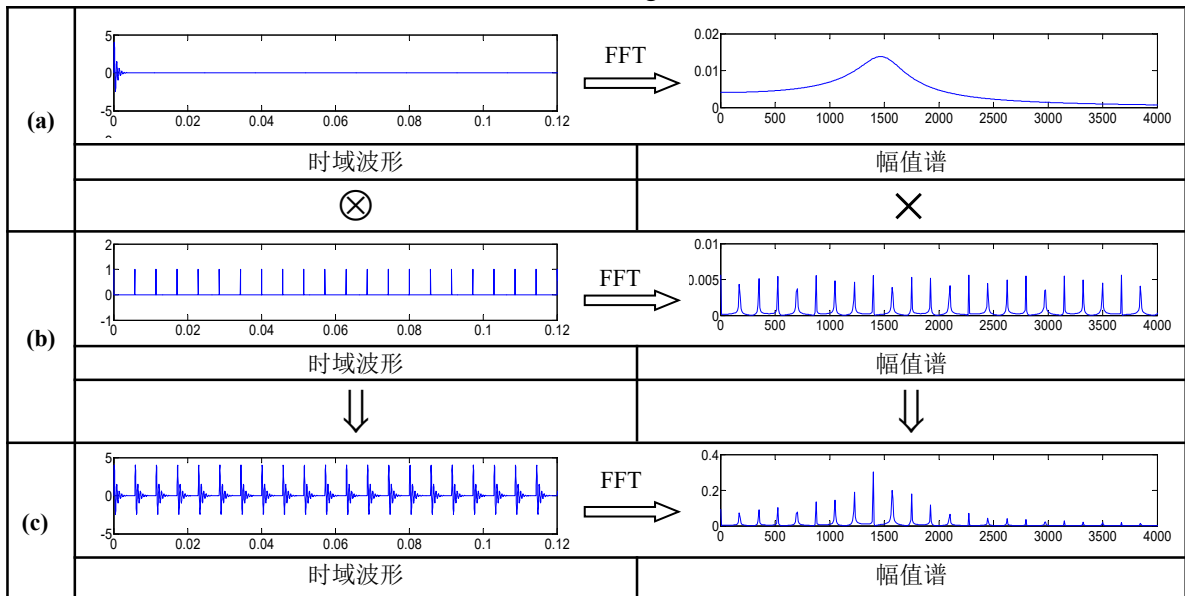


图 2.3 滚动轴承故障冲击信号仿真

不同故障位置会导致传感器采集到的冲击响应幅值发生变化, 这主要是由于损伤位置与传感器之间的距离不同所引起的。接下来, 将针对滚动轴承外圈、内圈和滚动体的故障信号进行仿真建模, 假设滚动轴承的转动模式为外圈固定, 内圈旋转。


2.3.1 外圈故障信号仿真

当滚动轴承外圈发生故障时，其故障点的位置与传感器的方位和距离是恒定的，因此每次冲击大小在理想情况下也是恒定的，所以，滚动轴承外圈故障特征信号可以表示为：


$$S_{fault}(t) = \sum_{i=0}^N g_i(t) \quad (2.18)$$

令参数 $\xi = 0.15$, $f_n = 1500\text{Hz}$, $f_r = 50\text{Hz}$, $f_{fault} = 3.5f_r$, $f_s = 32\text{kHz}$ 。


图 2.4 展示了外圈故障仿真过程中，信号在时域、频域及包络谱域中的表现，以及加入白噪声后的变化。图 2.4(a) 显示了外圈故障冲击信号的时域波形，呈现出周期性的冲击特征，峰值明显且间隔稳定，符合滚动轴承外圈故障的典型特征。图 2.4(b) 展示了加入白噪声后的时域信号，噪声的引入使得冲击信号的峰值变得不再清晰，波形的随机波动增加，导致信号的可识别性下降。图 2.4(c) 为外圈故障信号的频谱图，其中特征频率 f_0 和其倍频成分清晰可见，频谱中的主峰对应于外圈故障的特征频率，次级峰值为其倍频。图 2.4(d) 展示了加入白噪声后的频谱图，噪声的干扰使得频谱中的故障特征峰值被噪声成分覆盖，降低了故障信号的可辨识度。图 2.4(e) 为外圈故障信号的包络谱图，故障特征频率 f_0 及其倍频在包络谱中表现得尤为突出，能够有效地过滤高频噪声，突出显示低频的故障特征。图 2.4(f) 展示了加入白噪声后的包络谱，噪声的干扰对包络谱的影响相对较小，故障特征频率仍能清晰识别。总体而言，尽管噪声的加入对时域信号和频谱信号产生了较大干扰，但包络谱分析能够有效抑制噪声影响，突出显示外圈故障的特征频率，为故障诊断提供了可靠的支持。




(a) 故障冲击信号时域波形




(b) 含噪声故障信号时域波形




(c) 故障冲击信号频谱



(d) 含噪声故障信号频谱



(e) 故障冲击信号包络谱



(f) 含噪声故障信号包络谱

图 2.4 外圈故障冲击仿真信号


2.3.2 内圈故障信号仿真

当滚动轴承内圈发生故障时，内圈故障点的位置相对于传感器会发生变化，因此，滚珠经过内圈故障点时产生的振动冲击幅值也会随之变化。因此，滚动轴承内圈损伤的故障特征信号可以表示为：


$$S_{fault} = (2 + \cos(2\pi f_r t)) \sum_{i=0}^N g_i(t) \quad (2.19)$$

$$\text{令 } \xi = 0.15, f_n = 1500 \text{ Hz}, f_r = 50 \text{ Hz}, f_{fault} = 5.5 f_r, f_s = 32 \text{ kHz}。$$


图 2.5 展示了内圈故障仿真过程中的时域图、频谱图和包络谱图，以及在加入白噪声后的信号分析结果。图 2.5(a) 呈现了内圈故障冲击信号的时域波形，信号表现为周期性的冲击特征，振幅较为明显，且信号间隔稳定，反映出内圈故障产生的周期性冲击。图 2.5(b) 则为加入白噪声后的时域信号，噪声的引入使得故障信号的峰值被掩盖，波形的清晰度降低，信号中出现了更多的随机波动，导致故障信号的辨识难度增加。图 2.5(c) 展示了内圈故障冲击信号的频谱图，频谱中可以看到在特征频率 f_i 处存在明显的峰值，并且在其倍频处也有一定的能量分布，标志着内圈故障的典型频谱特征。图 2.5(d) 为加入白噪声后的频谱图，噪声的加入使得频谱中的故障特征峰值被噪声成分淹没，导致信号的频谱特征不再那么明显，尤其是低频故障信号在噪声的影响下几乎不可辨识。图 2.5(e) 展示了内圈故障冲击信号的包络谱，包络谱中故障特征频率 f_i 及其倍频 $2f_i$ 等成分显著突出，包络谱的提取有助于增强故障特征的可辨识度，尤其是在存在噪声的情况下，包络分析能够有效滤除高频噪声，突出低频故障成分。图 2.5(f) 为加入白噪声后的包络谱图，尽管噪声的影响依然存在，但包络谱仍能够清晰地识别出故障的特征频率和倍频。白噪声的加入对时域信号和频谱信号的影响较为显著，但包络谱能够有效地抑制噪声的干扰，保持较高的故障信号识别度。因此，包络谱分析在噪声环境下仍然是内圈故障诊断中的一种有效手段，能够帮助提高故障诊断的精确性。通过对比不同的信号分析结果，可以发现噪声的加入对信号的影响是显著的，尤其是在时域和频域的信号中，噪声容易掩盖故障信号的特征，而包络谱则能够有效地提高故障诊断的可行性和准确性。




(a) 故障冲击信号时域波形




(b) 含噪声故障信号时域波形




(c) 故障冲击信号频谱



(d) 含噪声故障信号频谱



(e) 故障冲击信号包络谱



(f) 含噪声故障信号包络谱

图 2.5 内圈故障冲击仿真信号

2.3.3 滚动体故障仿真信号

当滚动轴承的滚动体发生故障时，滚动体故障点与传感器的相对位置会随着保持架的旋转而变化。因此，滚动体故障点在与内圈或外圈接触时所产生的冲击信号的幅值也会发生变化。因此，滚动体故障的特征信号可以表示为：


$$S_{fault} = A_1(2 + \cos(2\pi f_c t)) \sum_{i=0}^N g_i(t) + A_2(2 + \cos(2\pi f_c t)) \sum_{i=0}^N g_i\left(t - \frac{i}{2f_b}\right) \quad (2.20)$$

式中， A_1 和 A_2 是幅值参数，分别表征滚珠缺陷与外、内滚道接触而产生的冲击幅值大小。一般情况下，滚动轴承外圈与传感器距离较近，故应取 $A_1 > A_2$ 。令 $\xi = 0.15$ ， $f_n = 1500$ Hz， $f_c = 0.4f_r$ ， $f_b = 2.2f_r$ ， $f_r = 50$ Hz， $f_s = 32$ kHz， $A_1 = 1$ ， $A_2 = 0.4$ 。


图 2.6 展示了外圈故障仿真过程中的时域图、频谱图、包络谱图，以及在加入白噪声后的信号表现。图 2.6(a) 呈现了外圈故障冲击信号的时域波形，信号呈现周期性冲击特征，峰值间隔为 $1/f_b$ ，该波形反映了滚动轴承外圈故障引发的冲击振动，特征明显，波形周期规律，符合典型的外圈故障振动信号特征。图 2.6(b) 则是加入白噪声后的时域信号，噪声的加入显著影响了故障信号的可辨识度。原本清晰的冲击波形被噪声的随机波动所淹没，信号的幅值不再明显，周期性特征也变得不易识别，这表明在实际应用中，噪声的干扰会对故障信号的检测造成一定挑战，尤其是低幅度故障信号。图 2.6(c) 展示了外圈故障冲击信号的频谱图。频谱中的主峰出现在故障特征频率 f_b 处，并且在其倍频处出现了相应的峰值，表明外圈故障的特征频率和倍频成分清晰可见。该频谱反映了外圈故障产生的振动频率特征，可以通过频谱分析有效识别故障的位置和类型。图 2.6(d) 为加入白噪声后的频谱图，噪声的加入使得频谱中的故障特征峰值被噪声成分所覆盖，频谱图中的故障信号显得更加模糊。噪声的干扰使得频谱的辨识度降低，尤其是在低频段，故障信号的峰值几乎消失，进一步验证了噪声对故障信号频谱的影响。图 2.6(e) 展示了外圈故障冲击信号的包络谱图。包络谱有效地提取了低频故障特征，特征频率 f_b 和其倍

频成分在包络谱中呈现出明显的峰值。包络分析能够有效抑制高频噪声成分，突出显示故障信号的低频特征，是诊断滚动轴承故障的一种有效方法，尤其是在噪声环境下，包络谱的优势尤为突出。图 2.6(f) 为加入白噪声后的包络谱图。尽管噪声的加入对时域信号和频谱信号产生了显著影响，但包络谱仍能清晰地识别出故障特征频率 f_b 及其倍频成分。包络分析通过滤除高频噪声，使得低频的故障特征得以保持，显著提高了故障信号的可辨识度，证明了包络谱在噪声环境中的有效性。


需要注意的是，滚珠与滚道接触的每一次都会导致外滚道的接触一次，因此，针对滚珠故障的频谱表现，通常会关注滚珠自频率的 2 倍频^[21]。包络谱中也可以看出， $f = 2f_b$ 处对应的谱峰比 $f = f_b$ 处的谱峰更为突出。




(a) 故障冲击信号时域波形




(b) 含噪声故障信号时域波形




(c) 故障冲击信号频谱



(d) 含噪声故障信号频谱



(e) 故障冲击信号包络谱



(f) 含噪声故障信号包络谱

图 2.6 滚动体故障冲击仿真信号

2.4 本章小结

本章主要围绕滚动轴承故障机理和剥落故障振动信号仿真分析展开。首先，介绍了典型滚动轴承的基本构造和基本参数，最重要的是节径、滚珠直径和滚珠数，这三者直接关系到滚动轴承故障特征频率；之后，由于滚动轴承故障诊断的关键就是提取滚动轴承故障特征频率，所以阐述了滚动轴承故障特征频率的计算方法，推演了滚动轴承外圈、内圈、滚动体故障特征频率的计算公式。

最后，根据滚动轴承故障信号的特点，进行了外圈、内圈、滚动体故障信号的仿真建模，通过对仿真信号的时域冲击特性、频谱以及包络谱进行分析，展示了不同位置故障信号在振动

响应中的不同。外圈故障通常表现为稳定的有周期性的冲击，内圈故障因为损伤点和传感器位置的相对运动的关系会导致冲击信号受到转频调制的影响，滚动体故障信号受保持架转频调制呈现出更加明显的非平稳特征，其故障特征频率更加分散。引入噪声后，各个仿真信号的时域波形、频谱和包络谱都受到了不同程度的干扰，时域波形中的冲击成分几乎被完全淹没、频谱中尽管仍然存在着共振峰，但是在低频范围内仍然难以识别其故障特征频率。

第三章 融合 EMD 和 EWT 的信号处理新方法

3.1 引言

本章在上一章滚动轴承故障机理与典型剥落故障振动信号特征规律研究的基础上进一步对故障特征频率提取方法进行分析,探究更加具有适应性的时频分析的特征提取方法。经验模态分解(EMD)能够根据信号自身的尺度进行自适应分解,分解出若干个固有模态分量,但是在处理信号时容易出现端点效应、模态混叠及分解不稳定的问题。经验小波变换(EWT)通过自适应频谱划分的方法构造小波滤波器组,具有良好的频带聚焦能力和抗噪性能,但是对频带划分的合理性和信号本身的特性具有极强的依赖。本章利用仿真信号对经验模态分解的缺点进行完整的展现,并且提出了融合算法,该方法利用 EMD 算法对原先的非平稳信号进行处理,再结合 EWT 算法对关键的模态分量进行进一步分解,从而抑制端点效应和模态混叠,增强故障特征频率。

3.2 EMD-EWT 算法的基本原理

3.2.1 融合算法理论

在复杂机械振动信号处理中,由于信号通常具有明显的非平稳性、多尺度特征以及强噪声干扰,单一信号处理方法往往难以同时兼顾时域与频域特征的有效提取。因此,有必要从信号分解理论角度分析不同方法的适用特性,并构建具有互补优势的融合算法。

经验模态分解(Empirical Mode Decomposition, EMD)是一种典型的自适应时频分析方法,其核心思想是通过局部极值点构造上下包络线,并通过迭代筛选过程将复杂信号分解为若干个本征模态函数(Intrinsic Mode Function, IMF)。EMD 的分解过程完全依赖于信号自身的局部时间尺度特征,不需要预设基函数,因此能够有效处理非线性和非平稳信号。从理论上讲,任意复杂信号 $x(t)$ 可以表示为若干 IMF 分量与残余项的叠加:

$$x(t) = \sum_{i=1}^n IMF_i(t) + r_n(t) \quad (3.1)$$

其中 $IMF_i(t)$ 表示第 i 个本征模态函数, $r_n(t)$ 为残余趋势项。通过 EMD 分解,可以将原始信号在不同时间尺度上进行分离,从而突出信号中的局部冲击特征。然而,由于 EMD 的分解过程依赖于信号局部极值点分布,当信号中存在强噪声或多尺度振荡成分时,不同尺度的信号

成分可能被分解到同一 IMF 分量中，从而产生模态混叠现象。此外，由于样条插值在信号边界处缺乏足够约束，EMD 分解还容易产生端点效应，从而影响分解精度。

经验小波变换 (Empirical Wavelet Transform, EWT) 则是一种基于频域自适应划分的信号分解方法。EWT 首先对信号进行傅里叶变换，然后根据信号频谱中的局部极值点对频谱进行自适应分割，并构建对应的小波滤波器组实现信号分解。与传统小波变换依赖固定小波基函数不同，EWT 能够根据信号实际频谱结构动态构建滤波器组，从而提高信号分解的自适应性。对于信号 $f(t)$ ，其 EWT 分解结果可表示为：

$$f(t) = \sum_{k=0}^N f_k(t) \quad (3.2)$$

其中 $f_k(t)$ 表示不同频带内的信号分量。由于 EWT 在频域进行自适应划分，因此在频率分离能力方面具有明显优势，能够有效抑制不同频率成分之间的混叠。然而，当原始信号受到强噪声干扰或频谱结构复杂时，频谱极值点的识别容易受到影响，从而导致频带划分不准确。

从信号处理机理角度来看，EMD 属于基于时域局部特征的自适应分解方法，能够有效提取信号中的瞬态冲击信息；而 EWT 属于基于频域结构的自适应分解方法，能够实现不同频率成分的精细分离。两种方法在信号分解机制上具有明显的互补性。

基于上述理论分析，本文提出一种 EMD-EWT 融合信号处理方法。该方法首先利用 EMD 对原始振动信号进行自适应分解，将复杂非平稳信号分解为多个具有不同时间尺度的 IMF 分量，从而降低噪声干扰并突出冲击特征。随后选取包含主要故障信息的 IMF 分量作为 EWT 分解的输入信号。由于 IMF 分量相较于原始信号具有更为清晰的频谱结构，因此能够提高 EWT 频带划分的准确性。通过这种方式，可以实现信号在时间尺度与频率尺度上的联合自适应分解，从而有效抑制模态混叠并增强故障特征。

因此，将 EMD 与 EWT 相结合不仅能够充分发挥两种方法在时域与频域上的优势，而且能够提高复杂机械振动信号的分解精度，为滚动轴承故障特征提取提供更加可靠的信号处理手段。

3.2.2 方法流程

为了解决经验模态分解 (EMD) 算法的端点效应和模态混叠和经验小波变换依赖原始信号稳定性和平稳性的缺点，本文提出了一种将二者相融合的融合算法。

(1) 该算法首先对原始信号进行 EMD 预分解，将原始信号分解为若干个具有局部冲击特性的特征模态分量，认定为 IMF1-IMFn。这样就实现了将原始信号从高频到低频进行多尺度分离，使信号特征更稳定。但是端点效应和模态混叠仍然存在，大大影响了故障特征的提取。

(2) 因此对于 IMF 分量进行二次精细化分解，对 IMF 分量进行 EWT 分解，将得到的 IMF 分量进行频谱检视，选择包含故障冲击信号的 IMF 分量作为 EWT 分解的输入，对其进行自适应分割，确定各个峰值主导的频带，据此构造小波滤波器组，对信号在每个频带内进行解析和

重构，以此获得更加纯净的分量。这样既能有效地抑制 EMD 算法的端点效应和模态混叠又能给 EWT 算法提供更加稳定的输入，使故障相关成分得到进一步增强。

(3) 随后对重构后的信号进行包络分析：首先对信号及逆行希尔伯特变换得到瞬时幅值包络，并对包络进行 FFT 得到包络谱；再结合自相关分析和归一化处理提高周期性冲击的可见度。

(4) 最后提出一种故障指标的计算，从而判定轴承的故障状态。

算法的流程图如图 3.1 所示。

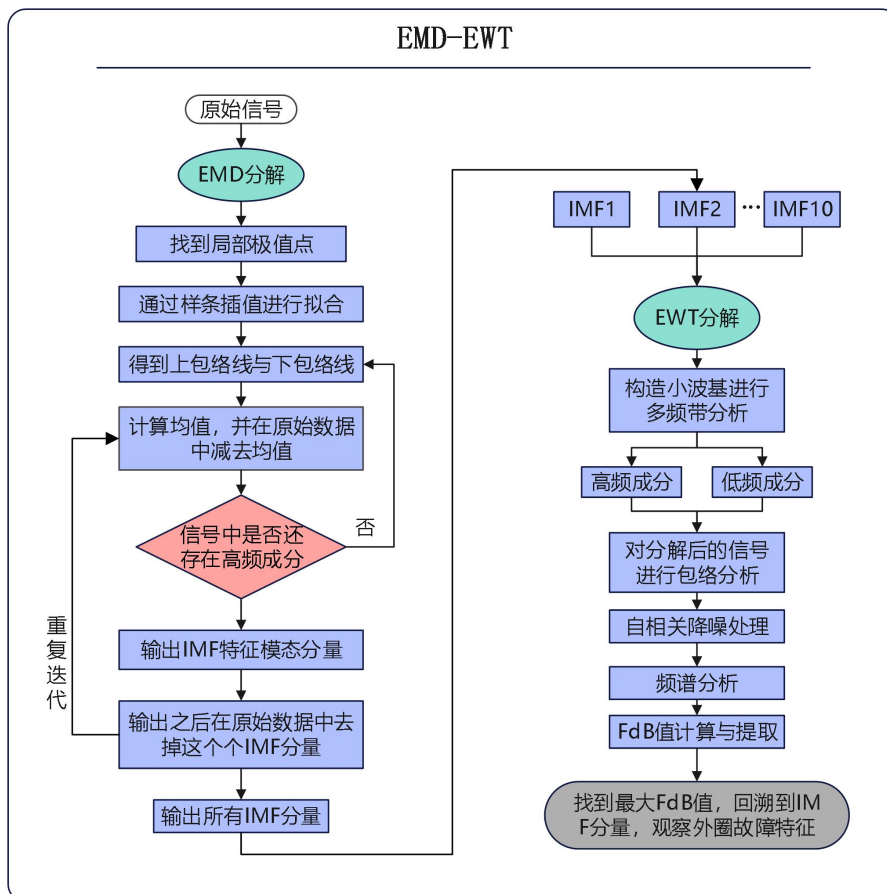


图 3.1 EMD-EWT 融合算法流程图

3.2.3 关键技术

3.2.3.1 信号的 EMD 分解

EMD 的特殊之处在于它是对所分析的信号进行自适应分解，其原理是通过信号的局部极值动态构造时变包络，逐级提取不同时间尺度的振荡成分，最终揭示信号内在的多尺度特征，核心步骤是通过迭代筛选过程将信号分解为多个本征模态函数和余项，即

$$x(t) = \sum_{i=0}^n c_i(t) + r_n(t) \quad (3.3)$$

本征模态分量就是原始信号被 EMD 分解之后得到的各层信号分量。Huang 认为，所有复杂信号均能解析为若干个满足特定约束条件的 IMF 分量的线性叠加。

本征模态分量需满足以下条件^[49]：

(1) 分量极值点数量与过零点数量需保持等量关系或仅存在单个差异；

(2) 由局部极值构建的上下包络线需保持动态平衡，确保各时间点的局部均值为零，即整个数据内正负半周期的面积相等；

(3) 包络线的定义必须清晰，即局部极值点构成的包络线要能够界定信号的振动范围。

该算法的实施过程包含以下四个阶段^[50]：

(1) 首先检测整个信号，然后找到局部极值点，通过三次样条插值法连接信号极值点，构建上下包络曲线并计算其均值 $m(n)$ ，将原始信号与均值进行做差处理获得分量 IMF1，记为

$$h_1(t) = x(t) - m(t) \quad (3.4)$$

(2) 判断 $h_1(n)$ 是否满足 IMF。若满足， $h_1(n)$ 为 IMF1；不满足，将 $h_1(n)$ 看成初始信号继续做差处理，只有满足 IMF 的条件后，将其作为 IMF1，且记作

$$c_1(t) = h_1(t) \quad (3.5)$$

筛选过程的终止条件由下式决定^[51]：

$$SD = \frac{1}{L} \sum_{t=1}^L \frac{[h_{i(k-1)}(t) - h_{ik}(t)]^2}{h_{ik}^2(t)} \leq \theta \quad (3.6)$$

式中： L 代表信号长度，即信号采样后的总样本数； SD 表示为标准差阈值，我们将 θ 的值一般预设 0.2 ~ 0.3^[52]，当连续迭代分量 SD 间的相对误差低于 θ 时停止筛选。通过这种渐进式分解机制，最终实现信号的自适应解析。

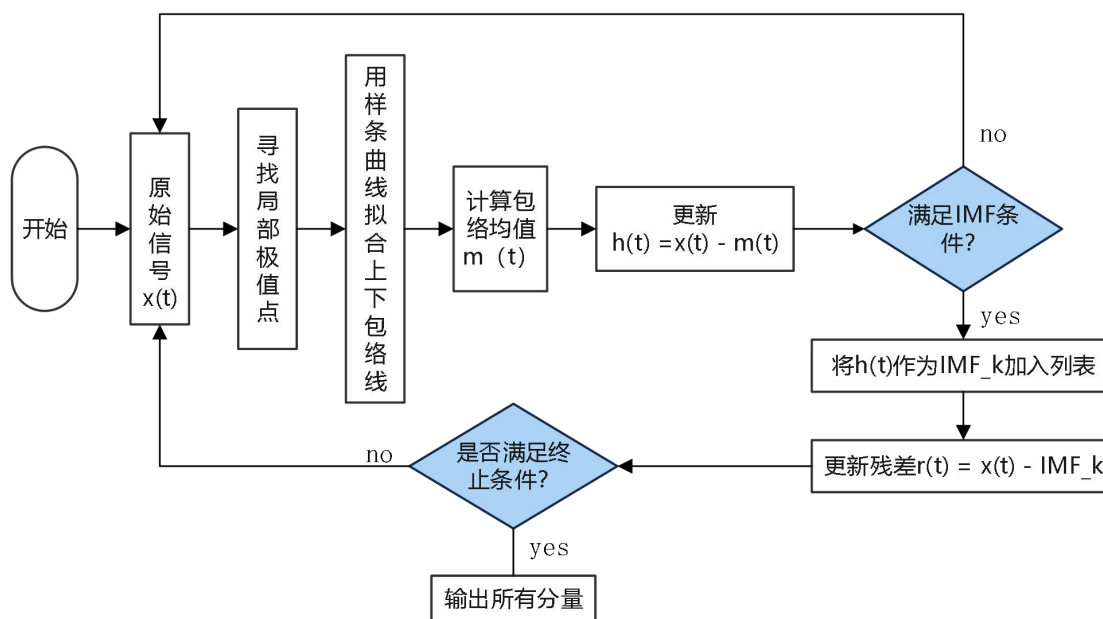


图 3.2 EMD 算法完整流程图

(3) 我们对原信号 $x(t)$ 与 IMF1 即 $c_1(t)$ 进行做差, 得到 $r_1(t)$, 则

$$r_1(t) = x(t) - c_1(t) \quad (3.7)$$

在后面的计算过程中, 我们把 $r_1(t)$ 作为初始信号, 通过下式的计算过程, 最终得到全部的满足 IMF 的条件的分量:

$$\begin{cases} r_2(t) = r_1(t) - c_2(t) \\ \dots \\ r_n(t) = r_{n-1}(t) - c_n(t) \end{cases} \quad (3.8)$$

(4) 当 $r_n(t)$ 符合筛选的停止准则时, 停止筛选, 此时信号 $x(t)$ 被分解为若干个 IMF 分量和残差的和, 最终分解为式(3.1) 的形式。EMD 分解的完整流程图如图 3.2 所示。

3.2.3.2 信号的 EWT 分解

EWT 是由 Gilles^[53]在 2013 年提出的结合了 EMD 和小波变换的优点。EMD 是基于数据驱动的自适应分解, 而小波变换使用预定义的基函数。EWT 的目标是在保持自适应性的前提下, 克服 EMD 的一些缺点, 比如模态混叠。理论部分包括频谱分割、小波滤波器组构建和分解过程。EWT 的关键步骤是将信号的傅里叶谱分割成不同的频带, 每个频带对应一个模态, 然后设计相应的小波滤波器提取这些模态。接下来将展示 EWT 的分解过程, 如下:

(1) 先对振动信号 $f(t)$ 进行 Fourier 变换, 转化到傅里叶谱 $[0, \pi]$ 上,

$$\hat{f}(\omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} s(t)e^{-i\omega t} dt \quad (3.9)$$

将 Fourier 频谱记成 $f(\omega) = |\hat{f}(\omega)|$ ，且 $\omega \in [0, \pi]$ 。

(2) 对信号的傅里叶谱进行自适应划分分割频带。

对信号的 Fourier 频谱 $f(\omega)$ 进行极值扫描，提取 P 个满足条件的极大值，通过筛选后得到有序频率集合记作 $\{\omega_n, n=1 \sim P-1\}$ 。设目标分析频带的区间为 $[0, \pi]$ ，若子频带要分割为 $N(N \leq P)$ 个，则需要 $N-1$ 个边界。设 AM-FM 分量的中心是 ω_n ，其所在子频带为 $[\Omega_{n-1}, \Omega_n]$ ^[54]，并且

$$\Omega_{n-1} = \frac{\omega_{n-1} + \omega_n}{2} \quad n = 2 \sim N, N \leq P \quad (3.10)$$

令 $\Omega_0 = 0$ ， $\Omega_N = \pi$ ，将信号划分为 N 个子频带。

再令 $\Lambda_n = [\Omega_{n-1}, \Omega_n]$ ，则 $\bigcup_{n=1}^N \Lambda_n = [0, \pi]$ 。然后以 ω_n 为中心，宽度 $T_n = 2\tau_n$ ，对每个频带定义过渡带并设计对应的 $\hat{\phi}_n(\omega)$ ，如图 3.3 的阴影部分。




图 3.3 傅里叶频谱分割示意图

(3) 构造小波滤波器组

经验小波是定义在 $[\Lambda_n, \Lambda_{n+1}]$ 的带通滤波器，主要利用 Meyer 小波的思想来构建。其中参数 τ_n 可以简单地取为 $\tau_n = \gamma\Omega_n$ ， $0 < \gamma < 1$ 。则 $[\Omega_{n-1}, \Omega_n]$ 的尺度函数和小波函数为：

$$\hat{\phi}_n(\omega) = \begin{cases} 1, & |\omega| \leq (1-\gamma)\Omega_n \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{|\omega| - (1-\gamma)\Omega_n}{2\gamma\Omega_n} \right) \right], & (1-\gamma)\Omega_{n+1} \leq |\omega| \leq (1+\gamma)\Omega_{n+1} \\ 0, & \text{others} \end{cases} \quad (3.11)$$

$$\hat{\psi}_n(\omega) = \begin{cases} 1, & (1+\gamma)\Omega_n \leq |\omega| \leq (1-\gamma)\Omega_{n+1} \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{|\omega| - (1-\gamma)\Omega_n}{2\gamma\Omega_n} \right) \right], & (1-\gamma)\Omega_{n+1} \leq |\omega| \leq (1+\gamma)\Omega_{n+1} \\ \sin \left[\frac{\pi}{2} \beta \left(\frac{|\omega| - (1-\gamma)\Omega_n}{2\gamma\Omega_n} \right) \right], & (1-\gamma)\Omega_n \leq |\omega| \leq (1+\gamma)\Omega_{n+1} \\ 0, & \text{others} \end{cases} \quad (3.12)$$

式中： $\beta(x)$ 是平滑过渡函数（如升余弦函数），表示为

$$\begin{cases} \gamma < \min_n \left(\frac{\Omega_{n+1} - \Omega_n}{\Omega_{n+1} + \Omega_n} \right), & 0 < \gamma < 1 \\ \beta(x) = x^4(35 - 84x + 70x^2 - 20x^3) \end{cases} \quad (3.13)$$

对于 $f(t)$ 而言，在 N 个子频带上利用尺度函数式 (3.9) 和小波函数式 (3.10) 可以设计出

一个低通滤波器和 $N-1$ 个带通滤波器所组成的自适应小波滤波器组。

(4) 在子频带 $[\Omega_{n-1}, \Omega_n]$ 上, 根据经典小波变换的构造方法来构造经验小波变换, 细节系数^[55]为

$$w_f^e(n, t) = \langle f, \Psi_n \rangle = \int f(\tau) \Psi_n^*(\tau - t) d\tau = F^{-1}[\hat{f}(\omega) \hat{\Psi}_n^*(\omega)] \quad (3.14)$$

逼近系数为

$$w_f^e(0, t) = \langle f, \phi_1 \rangle = \int f(\tau) \phi_1^*(\tau - t) d\tau = F^{-1}[\hat{f}(\omega) \hat{\phi}_1^*(\omega)] \quad (3.15)$$

式中: $F^{-1}[\bullet]$ 为傅里叶逆变换, $\hat{\phi}_1^*(\bullet)$ 、 $\hat{\psi}_n^*(\bullet)$ 分别表示为 $\phi_1^*(\bullet)$ 、 $\psi_n^*(\bullet)$ 的共轭。分解得到的低频分量和高频分量分别为

$$f_0(t) = w_f^e(0, t) * \phi_1(t) \quad (3.16)$$

$$f_k(t) = w_f^e(k, t) * \Psi_k(t) \quad (3.17)$$

式中: * 是函数的卷积计算。

原始信号是可以重构的, 重构公式为:

$$f(t) = w_f^e(0, t) * \phi_1(t) + \sum_{n=1}^N w_f^e(n, t) * \phi_n(t) = F^{-1} \left[\hat{w}_f^e(0, \omega) \hat{\phi}_1(\omega) + \sum_{n=1}^N \hat{w}_f^e(n, \omega) \hat{\phi}_n(\omega) \right] \quad (3.18)$$

EWT 分解的完整流程图如图 3.4 所示:

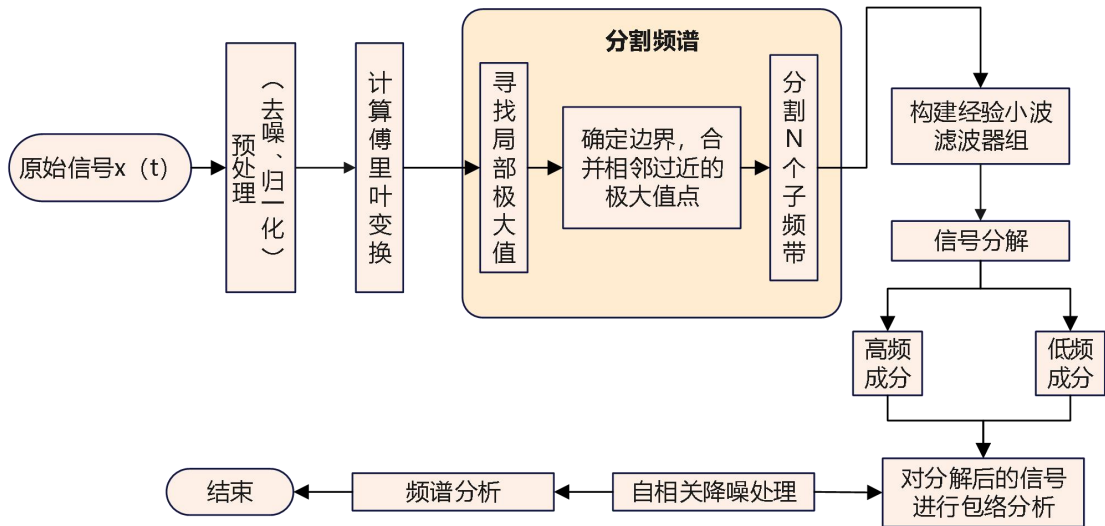


图 3.4 EWT 算法完整流程图

其中, EWT 分解时最重要的是滤波器边界的确定。将傅里叶频谱分割为 N 个频段需确定 $N+1$ 个边界点, 其中首尾边界固定为 0 和 π , 其余 $N-1$ 个边界需通过频谱分析动态确定。Gilles 在文献^[51]中提出的局部极大值检测法, 可以用来确定边界数 N , 要先找到频谱中的全部极大值点, 构成集合 $M = \{M_1, M_2, \dots, M_n\}$ 再按降序排布, 得到有序序列 $M_{(1)} \geq M_{(2)} \geq \dots \geq M_{(n)}$ 。我

们假设现在有 M 个极大值点，则会出现以下两种情况：

(1) 当检测到的极值点数量 M 与预设分割数 N 满足 $M \geq N$ 时，极大值点个数能够确定边界数量，保留前 $N-1$ 个幅值最大的极值点。

(2) 当 $M < N$ 时，无法确定边界数，动态调节机制便通过迭代优化重新确定有效分割数，调整为 $N = M$ 。

这种双重判定逻辑有效平衡了频谱特征密度与分解精度的关系。当我们确定了我们所需要的极大值个数，再使用降序排列得到的极大值集合 $\{M\}$ ，以此作为频带划分的依据。Gilles 提出了两种边界 ω_n 的定位方法。

(1) 中点法 (Loxmax)：将相邻极值点连接起来，然后选取它们的中点作为边界。

(2) 极小值法 (Loxmaxmin)：定位相邻极值点间频谱的最小值点作为自然频带边界。

但是在实际的工程信号应用中，我们很难去寻找并确定分解的特征分量数，所以工程实践中常采用自动极值检测流程。其核心规则为：Fourier 频谱的幅值里所挑选出来的极大值，一定要高于所探测到的其他极大值，且必须远高于其他。设集合 $\{M_i\}_{k=1}^M$ 中都是被检测的极大值，首先我们要对其按频率从大到小排序为 $(M_1 \geq M_2 \geq \dots \geq M_M)$ ，通常会对其做归一化处理，把数据中的极大值幅值调整到 $[0,1]$ ，以便更准确的描述分布特征。随后再挑选出所有符合规则的极大值，其中我们要满足 $M_i > M_1 + \alpha(M_1 - M_M)$ ， $0.3 \leq \alpha \leq 0.4$ ，最终再进行边界 ω_n 的确定。

但通过局部极大值检测法找到的边界会存在一些缺点，比如在强噪声的干扰下就很难得到想要的结果。Gilles 针对该问题又提出了一种无参化的尺度-空间表示法，该方法可以简单快捷地在频谱上找到有意义的模态分量。主要原理是将确定的划分频谱区间的边界等价于在 $f(x)$ 的柱状图上寻找谷值或局部等效的最小值。利用该方法，信号 $f(x)$ 的极小值视为一个与时间 t 相关的函数，在这个函数中，当尺度参数达到临界值时，极小值轨迹的收敛速率显著降低，函数下降的速度放缓，不再随时间的增大而降低，这时就是最小值。

本文将 EMD 与 EWT 结合起来，充分发挥每个方法的优势之处，取其精华，去其糟粕。主要步骤如下：

(1) EMD 初步分解优化

对信号进行预处理后，先用 EMD 方法分解信号。

首先要在信号上找到局部极大极小值，通过三次样条插值进行拟合，得到上下包络线，再由式 (3.4) 计算均值，得到中间信号，检查是否满足 IMF 条件，若满足，输出 IMF1，若不满足，重新进行上述步骤，直到满足式 (3.6)，得到 IMF1。再由式 (3.8) 经过多次筛除计算后，便获得了所有 IMF 分量。

但是分解后的 IMF 可能包含模态混叠，尤其是高频部分可能有噪声干扰，所以再用 EWT

方法对所有 IMF 分量进行二次精细化分解。

(2) EWT 二次精细化分解

将 IMF 分量作为 EWT 分解的对象，令 $\Omega_0 = 0$ ， $\Omega_N = \pi$ ，使频带 $[0, \pi]$ 划分成若干子频带。然后在子频带上构造滤波器组，依据式 (3.11) (3.12) 即可得出。之后通过式 (3.14) 式 (3.15) 计算得到高频细节系数和低频逼近系数，最后再利用式 (3.16) 和式 (3.17) 求出每个子频带的分解分量，通过该流程最终实现信号在时频域内的多分辨率表达，即得到了所有 IMF 分量的低频成分和高频成分。

然后分别对每个 IMF 分量的低频和高频模态进行包络分析，设信号为 $xf_i(n), i=1, 2, \dots, N-1$ ，然后使用 Hilbert 变换得到 $XFH_i(n)$ ，再对 $XFH_i(n)$ 取模得到 $|XFH_i(n)|$ ，将 $|XFH_i(n)|$ 去除平均值后得到 $XH_i(n)$ 。

为了更好地观察到频率特征，且保留子信号的物理意义和消除量纲影响，便于对比不同之处，我们对各个低频和高频成分使用包络分析，在完成包络信号后，分别对 $XH_i(n), i=1, 2, \dots, N-1$ ，进行归一化自相关分析变换^[59]，得到 $XHR_i(n)$ ，记为

$$R_{xx}[m] = \sum_{n=0}^{N-m-1} XH_i[n+m] \cdot XH_i[n] \quad (3.19)$$

$$R_{xx,normalized}[m] = \frac{1}{R_{xx}[0]} R_{xx}[m] \quad (3.20)$$

$$XHR_i[m] = \frac{1}{R_{xx}[0]} R_{xx}[m] \quad (3.21)$$

式中： m 称为时间延迟参数，且 $0 \leq m \leq N-1$ 。

最后，再分别对 $XHR_i(n), i=0, 1, 2, \dots, N-1$ 进行频谱分析。先对 $XHR_i(n)$ 进行 Fourier 变换，得到 $XHRF_i(n)$ ，其中 $XHRF_i(n)$ 的输出点数为 N 个点，然后对复数 $XHRF_i(n)$ 取模，除以 N ，乘以 2，得到各个频带的包络谱 $W_l(f_i), l=1, 2; i=0, 1, 2, \dots, N-1$ 。

3.2.3.3 信号的包络分析

令 $x(t)$ 为实的非平稳信号，为方便分析需要把 $x(t)$ 转化为复信号 $z(t)$ 的，使得 $z(t)$ 的实部与 $x(t) = a(t) \cos \phi(t)$ 相同^[56]。为实现这一转化，可直接以 $x(t)$ 作为 $z(t)$ 的实部，并构造“虚信号” $s(t)$ 作为 $z(t)$ 虚部，即

$$z(t) = x(t) + js(t) \quad (3.22)$$

如果将 $z(t)$ 写成极坐标的形式

$$z(t) = a(t)e^{j\phi(t)} \quad (3.23)$$

显然有：

$$a(t) = \sqrt{x^2(t) + s^2(t)}, \phi(t) = \arctan \left[\frac{s(t)}{x(t)} \right] \quad (3.24)$$

上式中， $a(t)$ 是 $x(t)$ 的瞬时幅值， $\phi(t)$ 是 $x(t)$ 的瞬时相位。根据式(3-5)可看出， $a(t)$ 不小于 $x(t)$ ，也就是说， $a(t)$ 包裹着 $|x(t)|$ 的曲线，故常将 $a(t)$ 称为包络。

3.2.4 仿真信号的 EMD-EWT 算法分析

在实际滚动轴承振动信号的采集中，采集到的信号是复杂的，非平稳性的，EMD 算法由于这些特质会产生端点效应和模态混叠，而简单的仿真信号并不能很好地模拟真实的采集环境，所以本文设计出一个仿真信号遵循多尺度叠加和非平稳性的标准从而展现 EMD 算法的端点效应以及模态混叠的影响和解决。

在采样频率和时间设计中，采样频率 $f_s = 1000\text{Hz}$ ，时间序列 $t=0:1/f_s:2$ ，构造成 2s 的离散信号，并设计为 N 个采样点。在主体信号的构造上采用多个频率叠加的形式仿真滚动轴承振动信号的多尺度特征，表达式如下：

$$x(t) = \sin(6\pi t) + 0.5 \sin(11\pi t) + 0.8 \sin(25\pi t) \quad (3.25)$$

其中，三项分别对应低频中频和高频三种成分且幅值比例设置为 1:0.5:0.8，这种组合在时域中有着更为复杂的局部极值分布与多尺度振荡效应，符合实际滚动轴承振动信号中的“多元激励、频带叠交、成分非平稳”的基本特性^[59]，同时由于 EMD 算法依赖于局部极值点构造上下包络并进行迭代筛选，多频耦合能够显著提高拟合难度，为了使仿真信号更加贴合实际振动信号，在仿真信号中引入幅值渐变衰减，衰减系数 $\xi = 0.5$ 。仿真信号时域波形和频谱如图 3.5、图 3.6 所示。




图 3.5 仿真信号时域波形




图 3.6 仿真信号频谱

首先，用 EMD 算法对信号进行分解，共得到 3 个 IMF 分量如图 3.7 所示：




图 3.7 EMD 算法分解结果

在图 3.7 中，3.7 (a)、3.7 (b)、3.7 (c) 分别表示高频、中频、低频三种分量。IMF1 分量为高频分量，在信号中的振荡幅值以及相位表现得相对稳定，能够更好地表现出原始信号的快速变化的特性。但是在起始点位置能够观察到幅值发生畸变于波形不对称的现象，表现形式为局部震荡被拉伸，说明在端点处由于上下包络线的偏差导致均值估计不准确，引入了伪高频成分，表明 EMD 分解在时域波形中受到端点效应的影响导致拟合不准确。IMF2 为中频分量，受端点效应的影响更加显著，在信号两端出现了幅值的突变以及周期性不连续，端点附近的波峰和波谷被明显的抬高和压低，产生了相位的偏移，IMF3 为低频趋势量，理论上应当是平稳的，但是在两端出现了明显的翘曲和回弹，在端点处发生了明显的偏移，这使整体趋势发生了偏置。总体来看，IMF1、IMF2、IMF3 均受到了端点效应的影响，在中、低频表现更加明显。

为了解决上述现象，引入 EWT 算法对 IMF 分量进行二次精细化分解，将 IMF 分量作为输入信号，用 EWT 算法进行自适应分解。结果如图 3.8：





图 3.8 EWT 二次精细化处理后的结果


经 EWT 算法对 IMF 分量进行二次自适应处理之后，三组 IMF 分量的端点效应都得到了有效地抑制。在 IMF1 高频分量中，重构后的信号的波形在 2s 内保持稳定，震荡规律一致，幅值的包络趋于恒定，波峰和波谷的对称性显著增强，起止点附近不再出现幅值的突变和伪震荡，与 EMD 分解的 IMF 分量相比较，相位的连续性得到了显著的优化，局部也没有像 EMD 一样发生拉伸或压缩，说明 EWT 算法通过聚焦于频带削弱了端点外推导致的端点对高频信号的污染。在 IMF2 分量中，经过 EWT 二次处理后的波形进行正弦波形，周期分布均匀，端点两端不再存在相位的偏移，端点效应得到了明显的改善。在 IMF3 分量中，低频分量表现为平稳的趋势项，端点出现的翘曲和回弹消失，端点效应得到明显的改善。总体而言，EWT 二次精细化处理之后的信号在保留故障信息的同时，抑制了端点效应的干扰，为后续的处理提供了基础。

接着，对每个 IMF 分量进行 FFT 变换得到幅值谱，EMD 处理后的幅值谱如图 3.9 所示。在图 3.9 中，图 3.9 (a)、3.9 (b)、3.9 (c) 分别对应 IMF1、IMF2、IMF3 的频谱，在图中出现了明显的模态混叠特征。从理论上来说经过 EMD 分解得到的 IMF 分量应当满足由高到低、

逐级递减的分布规律，只含有单一尺度成分。但是在图 3.9 (a) 中 IMF1 分量的主峰在 12.5Hz 处，符合预设的频率，但是在 5.5Hz 处仍然包含明显的次峰，说明原始信号由于模态混叠的影响并没有被完全分离；在图 3.9 (b) 中 IMF2 分量的主能量出现在 3Hz 处，而正确的峰值 5.5Hz 受到模态混叠的影响而被掩盖，这种 IMF 分量频带交叠导致同一频率出现在不同的 IMF 分量正是模态混叠的表现，是由于在 EMD 的筛分过程中尺度分离的不彻底导致的。而在 IMF3 分量中理论上应当出现低频分量，但是处理结果中并没有体现，这是因为低阶的分量已经接近残余的趋势项，并且信号的主要振荡成分在 IMF1 和 IMF2 中已经被大致提取，剩余的信号以缓慢的变化为主，极值点的尺度开度大，从而在 IMF3 分量的频谱中难以形成明确的峰值成分，表现为接近为 0 的趋势量。




(a) IMF1 频谱




(b) IMF2 频谱

图 3.9 EMD 处理后的频谱

为了解决上述模态混叠的问题，同样对经过 EWT 二次精细化处理并重构后的 IMF 分量进行 FFT 变换，得到频谱如图 3.10 所示：



(a) EWT 二次精细化处理后 IMF1 频谱



(b) EWT 二次精细化处理后 IMF2 频谱

图 3.10 EWT 二次精细化处理后的频谱

在用 EWT 对 EMD 分解后的 IMF 分量进行二次精细化处理之后，频谱的结果显示出显著的频率分量分离和聚焦。在图 3.10 (a) 中，高频分量的频谱能量全部集中在 12.5Hz 处，EMD 分解的 5.5Hz 次峰干扰完全消失，说明 EMD 分解泄露的中频成分已经被剥离，能量集中度显著增强。在图 3.10 (b) 中，中频分量得到了正确的提取，主要频率分量附近的杂散成分以及低频成分被有效地抑制，谱线更加单一，能量更加集中。上述现象表明 EWT 的二次精细化处理能够使主要频率精确地被提取，并且对其他频率成分起到了很好的抑制作用。有效地解决了 EMD 算法中模态混叠的问题。

3.3 基于特征频率的滚动轴承故障无量纲指标

轴承组件表面受到缺陷时，会引发振动响应，该响应具有显著特征。当滚动体与存在局部剥落或裂纹的滚道接触时，受动态载荷作用将产生瞬态冲击，该冲击响应会激发轴承系统固有频率范围内的谐振响应，该响应频率便是具有故障辨识价值的特征频率，不同位置的损伤，其特征频率的大小也不同^{[57],[58]}。

3.3.1 数据平稳性检验

- (1) 设待分析的信号数据长度为 N ，数据点按序编号为 $0 \sim N-1$ ；
- (2) 将数据分成 200 段，其中第 i 段数据的起始编号为 $(i-1) * \text{floor}(N / 200)$ ，第 i 段数据终止编号为 $i * (\text{floor}(N / 200)) - 1$ ，其中 i 取值 $1 \sim 200$ ， $\text{floor}()$ 表示向下取整；
- (3) 对每一段数据进行计算，得出绝对平均值；
- (4) 在 200 段数据中，找出绝对平均值的最大值 Max 和最小值 Min ；
- (5) 依据下式计算可以获得平稳性指标 SI ；

$$SI = \text{Max} / \text{Min} \quad (3.21)$$

- (6) 如果 $SI < SI_{cr}$ (SI_{cr} 的值我们设为 1.7)，则表明该数据平稳，进行下一步计算；

(7) 若高于 1.7, 则不再进行计算。

3.3.2 频带分析

(1) 对已经完成信号分解的频带进行包络分析, 分析过程参考章节 3.2.2.3;

(2) 接着对包络信号进行自相关分析, 通过式 (3.17) 式 (3.18) 和式 (3.19) 得到 $XHR_l(n)$;

(3) 再由章节 3.2.2.3 中构建包络谱图的方法对频带信号进行频谱分析, 得到各个频带的包络谱 $W_l(f_i), l=1,2; i=0,1,2,\dots,N-1$ 。

3.3.3 无量纲量的计算

首先, 根据故障特征频率计算公式 (2.4) (2.6) (2.7) (2.10) 计算得到故障特征频率 f_0 , 设特征频率 f_0 及其各阶倍频附近有其特征谱峰存在, $W_l(f)$ 为第 l 个频带包络谱值, $l=1,2$ 。

(1) 先在整个包络谱的频带范围内 ($0 - fs/2$) 去掉 9 倍转频的频率分量, 即

$$W_l(f) = \begin{cases} 0, & |f - 9f_N| < 0.05f_N \\ W_l(f), & \text{others} \end{cases} \quad (3.22)$$

(2) 接着设 10Hz—2fo 频率范围内的包络谱的谱线数为 N_e , 那么所求包络谱的均值为

$$S_{al} = \frac{1}{N_e} \sum_{i=0}^{N_e-1} W_l(f_i) \quad (3.23)$$

(2) 提取故障频率特征量。首先需要确定频率的搜索范围, 设定接触角变化范围为 $\alpha_1 \sim \alpha_2$, 再根据外圈故障特征频率计算公式得到特征频率的变化范围为 $f_{o1} \sim f_{o2}$ 。接着在 $f_{o1} \sim f_{o2}$ 范围内的包络谱中, 扫描特征频率处的谱线最大值, 设特征频率的容差范围为 $\delta f = |f_{o2} - f_{o1}|$, 包络谱的间隔为 Δf , 那么容差范围内的频率点数为 $m = \delta f / \Delta f$, 则第 l 个频带包络谱中故障频率的最大值为

$$S_{dl} = \max[W_l(f_{o1} + i\Delta f)], i \in [0, m], l = 1,2,3,4 \quad (3.24)$$

接着构造出一个无量纲特征量 S_{ol} , 记为

$$S_{ol} = \frac{S_{dl}}{S_{al}}, l = 1,2,3,4 \quad (3.25)$$

通过式 (3.25) 得到各频带的 S_{ol} 后, 再比较各个频带信号的特征值, 选择其中最大的值作为最终特征值, 记为

$$S_o = \max_{l=1}^4 [S_{ol}] \quad (3.26)$$

最终, 将其转化为分贝 dB 值, 定义 FdB 为故障特征量, 记为

$$F_{dB} = 20 \log_{10}(S_o) \quad (3.27)$$

3.4 本章小结

本章主要介绍了经验模态分解 (EMD) 算法以及经验小波变换 (EWT) 的基本原理、融合机制理论以及实现流程。EMD 算法主要介绍了基于局部极值点提取并进行包络拟合的筛选及终止机制以及 IMF 模态分量的提取流程, 介绍了其自适应的优点以及缺陷。EWT 算法部分主要介绍了其自适应频谱切割的能力, 小波滤波器组的建立以及子带重构的步骤, 突出了其抗噪以及频带分解的优势。在此基础上, 本章详细介绍了融合 EMD-EWT 算法的完整流程: 先对原始信号进行 EMD 分解, 再对分解出的 IMF 分量进行 EWT 二次精细化处理与重构, 从而结合 EMD 和 EWT 分别在时域以及频域上的优势。为了验证融合算法的特性, 本章构造了模拟真实振动数据的仿真信号, 并对其分别进行 EMD 分解以及 EMD-EWT 融合分解, 得出结果并进行比较, 结果表明融合算法很好地克制了 EMD 算法端点效应以及模态混叠的固有缺点, 证明了融合算法的优势。

最后, 本章建立了滚动轴承故障无量纲指标 F_{dB} , 详细地解释了计算流程及其物理意义, 为后续章节在试验器试验及整机发动机试验中提供了统一的量化指标, 更好地比较融合算法的优势。

总体而言, 本章为复杂滚动轴承故障信号特征提取提供了方法支撑以及理论依据。

第四章 基于滚动轴承故障模拟试验器的试验验证

4.1 引言

本章在前述算法原理以及仿真验证的基础上，进一步对真实工况下的数据集进行实验验证与对比分析。滚动轴承故障振动信号在实际采集的过程中受到转速以及信号传递路径、背景噪声等的影响较大，呈现出明显的非平稳与故障特征不明显的特性，因此更能体现出算法的差异性与适用性。为此，本章选取了国际公开的西储大学滚动轴承故障数据集以及自行搭建的带机匣的转子-滚动轴承试验器采集数据分别进行处理分析，验证算法在复杂工况以及带机匣传递条件下的处理能力。

以上面两组数据集为基础，本章分别采用 EMD 算法、EWT 算法以及 EMD-EWT 算法对数据进行处理分析比较，评价各个算法在不同故障位置及工况中的适用性与稳定性。最后结合无量纲特征指标 F_{dB} 的计算结果，给出量化结果的比较，从而验证融合算法在试验器环境下的适用性。

4.2 基于凯斯西储大学滚动轴承故障模拟试验验证

4.2.1 试验数据简介

凯斯西储大学轴承数据集是国际公开的轴承故障数据集，用于故障诊断以及预测的研究，该数据集包含了不同故障模式如滚动轴承外圈故障、滚动轴承内圈故障以及滚动体故障的轴承振动数据。试验平台如图 4.1 所示。




图 4.1 凯斯西储大学试验台

该试验器由一个 1.5kW 的电动机、一个扭矩传感器、一个功率测试机、一个电子控制器组成。分别采集了基座振动数据、电机驱动端振动数据以及电机风扇振动数据三组数据，本文以基座振动数据为目标数据分别对外圈故障、内圈故障、滚动体故障的数据进行分析处理。

凯斯西储大学采用的轴承型号是 6205-2RS JEM SKF 深沟球轴承，轴承结构如图 4.2 所示：




图 4.2 6205-2RS JEM SKF 深沟球轴承基本结构

为了系统地分析滚动轴承故障数据，我们挑选每种故障模式下的不同转速下的一组数据进行详细比较，在总体 F_{dB} 值趋势计算中采用全部数据进行趋势分析。

4.2.2 滚动轴承外圈故障分析结果

随机挑选的滚动轴承外圈故障数据进行分析，数据信息如表 4.1 所示，该数据的时域波形及频谱如图 4.3 和图 4.4 所示。

表 4.1 轴承参数

序号	转速/rpm	采样率 /Hz	振动测点	内径	外径	节径	滚动体直径	接触角	滚动体数
1	1796	12K	基座	25mm	52mm	39.04mm	7.94mm	0°	9




图 4.3 时域波形图





图 4.4 频谱图


如图所示，该振动信号的时域波形整体呈现出明显的随机性特征，信号幅值在较小范围内快速波动，未观察到清晰、孤立的周期性冲击成分，表明在强噪声背景下故障冲击已被严重淹没，时域分析难以直接提取有效的故障信息。对应的频谱图中，能量主要集中在中高频段，约在某一频率区间内出现较为明显的共振峰，反映了结构固有频率或系统激励作用的影响；而低频范围内未出现清晰、突出的特征频率及其倍频成分，故障相关信息被宽带噪声和高频共振成分所掩盖。这表明仅依靠传统的时域和频谱分析方法难以有效识别该振动信号中的故障特征，有必要引入更具针对性的信号处理方法对潜在的故障信息进行增强和提取。

4.2.2.1 EMD 算法结果分析


对信号进行 EMD 分解，分解出的 IMF 分量如图 4.5 所示。




(a) EMD 分解 IMF1 分量



(b) EMD 分解 IMF2 分量



(c) EMD 分解 IMF3 分量



(d) EMD 分解 IMF4 分量

图 4.5 EMD 分解后 IMF 分量包络谱

根据表 4.1 中的轴承参数，计算后可以得到 $f_o=107.36\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.2。


表 4.2 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	305	63	46	47


从 IMF5 分量开始为 EMD 分解的残余分量故不参与计算。经过计算可得 IMF1 分量为最大 F_{dB} 所在分量，故取 IMF1 的结果为最佳分解结果进行输出。

4.2.2.2 EWT 算法结果分析

对信号进行 EWT 分解，分解结果如图 4.6 所示。



(a) EWT 分解子带 1 包络谱



(b) EWT 分解子带 2 包络谱

图 4.6 EWT 分解后子带包络谱


根据表 4.1 中的轴承参数，计算后可以得到 $f_0=107.36\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对两个子带进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.3。

表 4.3 F_{dB} 值汇总表


序号	子带 1	子带 2
F_{dB}	376	370

4.2.2.3 EMD-EWT 算法结果分析


接着利用 EWT 算法对每一个 IMF 分量进行二次精细化处理，每一个 IMF 分量进行二次处理后会有 N 条子带，选取在故障特征频率正负 10Hz 范围内能量占比最大的子带进行输出，EWT 二次处理包络谱如图 4.7。




(a) EWT 二次分解后 IMF1 包络谱



(b) EWT 二次分解后 IMF2 包络谱



(c) EWT 二次分解后 IMF3 包络谱



(d) EWT 二次分解后 IMF4 包络谱

图 4.7 EWT 算法二次精细化分解后包络谱

根据表 4.1 中的轴承参数，计算后可以得到 $f_0=107.36\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.4。

表 4.4 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	1093	790	459	277

在图 4.5 中，红色虚线表示外圈故障特征频率，传统的 EMD 算法对信号进行分解后产生了 5 个包含有效故障信息的 IMF 分量，在理论外圈故障特征频率处有着相对明显的峰值，但是 EMD 算法容易受到噪声干扰而产生模态混叠以及端点效应，在包络谱上有着大量的杂波干扰和背景噪声，说明 EMD 算法无法有效地抑制噪声引发的模态混叠和端点效应，使得有效的故障特征被淹没，能量不够集中。在图 4.6 中，传统 EWT 算法在对信号分解后产生了 2 个包含故障信息的子带，在理论外圈故障特征频率处同样有着明显的峰值，但传统 EWT 算法容易受到噪声的影响，在包络谱中同样存在着大量的杂波干扰和背景噪声。在表 4.2 中，分别给出了 IMF1-IMF5 的无量纲量 F_{dB} 的计算结果，在表 4.3 中分别给出了两个子带的无量纲 F_{dB} 的计算结果。

EWT 算法能够在 EMD 算法的基础上进一步进行频带的自适应划分，使能量更为集中。EWT 算法利用谱能量密度的变化自适应划分频带，这就解决了 EMD 算法自身的端点效应问题和模态混叠问题。在图 4.6 中，能够明显地看到，背景噪声得到了充分的抑制，杂波干扰也大幅地减轻，并且故障特征频率的特征峰值都有着明显的提升。这说明在进行二次精细化处理之后，EWT 将原先混叠在一起的能量从背景噪声中有效地分离，使特征频率的表达更加清晰。将表

4.2、表 4.3、表 4.4 做比较,可以发现经过 EWT 二次处理后的无量纲量 F_{dB} 是 EMD 结果和 EWT 结果的两倍有余。这就意味着融合算法能够更加清晰地观察故障特征频率,使故障更容易被识别。

综上所述,EMD-EWT 算法相较于传统的 EMD 算法和 EWT 算法在滚动轴承外圈故障特征提取中有着明显的优势: EWT 的自适应频带划分有效解决了 EMD 算法中的模态混叠以及端点效应的问题,提高了分解的稳定性。EMD 对于时域的处理有效解决了 EWT 算法对于噪声敏感导致过分解的缺点,提高了分解的稳定性和准确性。

通过分析随机选取的外圈故障数据,可以发现融合算法的优势。为了证明算法的普适性,我们对全部数据进行批量分析,只输出 F_{dB} 最大的分量进行宏观比较,比较结果图 4.8。

在图 4.8 中黑色实线、红色实线、蓝色划线以及绿色点线的线条分别代表转速、EMD-EWT 算法的 F_{dB} 值计算结果、EMD 算法的 F_{dB} 值计算结果以及 EWT 算法的 F_{dB} 值计算结果,经过比较可得在不同转速下,融合算法相较于 EMD 算法的 F_{dB} 和 EWT 算法的 F_{dB} 都更高,意味着故障频率更加突出,诊断效果更好。




图 4.8 全部数据 F_{dB} 值变化趋势

4.2.3 滚动轴承内圈故障分析结果

随机挑选的滚动轴承内圈故障数据基本信息见表 4.5。时域波形及频谱如图 4.9、图 4.10 所示。

表 4.5 轴承参数

转速 /rpm	采样率 /Hz	振动测 点	内径	外径	节径	滚动体 直径	接触角	滚动体 数
1755	12K	基座	25mm	52mm	28.5mm	6.75mm	0°	8

从图 4.9 可见，该振动信号在时域上整体呈现为宽带随机振动叠加明显的幅值起伏，波形包络存在较为规律的周期性调制特征，但单个冲击并不尖锐、可辨性不强，说明信号中既包含结构/转动激励引起的调幅成分，也伴随一定的噪声干扰。图 4.10 频谱显示能量主要集中在中高频段，约在 1.2 kHz 附近出现最显著的主峰及其邻近的边带/簇状分布，同时在 3.3–3.6 kHz 区域存在第二个明显的共振能量集中带，表明系统响应受结构共振放大影响较强；此外在更高频段（约 5 kHz 附近）仍可观察到较弱的能量成分。总体而言，该信号呈现“调制+共振放大”的典型特征，故障相关的低频特征往往易被高频共振与噪声掩盖，需要进一步采用包络解调、共振带选取等方法以增强特征频率可识别性。




图 4.9 时域波形图






图 4.10 频谱图

4.2.3.1 EMD 算法结果分析


对信号进行 EMD 分解，得到 IMF 分量如图 4.11 所示。




(a) EMD 分解 IMF1 分量



(b) EMD 分解 IMF2 分量



(c) EMD 分解 IMF3 分量



(d) EMD 分解 IMF4 分量

图 4.11 EMD 分解后 IMF 分量包络谱

根据表 4.5 中的轴承参数，计算后可以得到 $f_i=144\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.6。


表 4.6 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	135	375	28	16


从 IMF5 分量开始为 EMD 分解的残余分量故不参与计算。经过计算可得 IMF1 分量为最大 F_{dB} 所在分量，故取 IMF1 的结果为最佳分解结果进行输出。

4.2.3.2 EWT 算法分解结果分析

对信号进行 EWT 分解，分解结果如图 4.12 所示。



(a) EWT 分解子带 1 包络谱



(b) EWT 分解子带 2 包络谱

图 4.12 EWT 分解后子带包络谱


根据表 4.5 中的轴承参数，计算后可以得到 $f_1=144\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.7。

表 4.7 F_{dB} 值汇总表


序号	分量 1	分量 2
F_{dB}	142	366

4.2.3.3 EMD-EWT 算法结果分析


接着利用 EWT 算法对每一个 IMF 分量进行二次精细化处理，每一个 IMF 分量进行二次处理后会有 N 条子带，选取在故障特征频率正负 10Hz 范围内能量占比最大的子带进行输出，EWT 二次处理包络谱如图 4.13。




(a) EWT 二次分解后 IMF1 包络谱



(b) EWT 二次分解后 IMF2 包络谱



(c) EWT 二次分解后 IMF3 包络谱



(d) EWT 二次分解后 IMF4 包络谱

图 4.13 EWT 算法二次精细化分解后包络谱

根据表 4.5 中的轴承参数，计算后可以得到 $f_i=144\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.8。

表 4.8 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	415	76	21	14

从 IMF5 分量开始为 EMD 分解的残余分量故不参与计算。经过计算可得 IMF1 分量为最大 F_{dB} 所在分量，故取 IMF1 的结果为最佳分解结果进行输出。

通过对滚动轴承内圈故障轴承利用 EMD、EWT、EMD-EWT 算法进行分解，分解结果与 F_{dB} 故障特征指标如图 4.11、图 4.12、图 4.13、表 4.6、表 4.7、表 4.8 所示。三种方法都能够将振动信号中的故障特征提取出来，并在包络谱中有所体现。但是，EMD 算法由于在分解过程中存在模态混叠、能量分散以及受噪声敏感性高的缺陷，导致特征提取的能力受到限制，EWT 算法由于过分解的影响，只有两个有效分量，且受噪声干扰影响非常大。相比之下 EMD-EWT 融合分解算法在特征增强、特征频率聚焦以及故障提取方面有着更加明显的优势。

从 EMD 的分解结果来看，在 IMF1-IMF4 中的故障特征频率的幅值都很低，同时包含着大量的背景噪声，干扰频率非常明显。在表 4.6 中可以看出 EMD 算法计算出的 F_{dB} 相较于 EMD-EWT 算法很低，说明 EMD 算法对于故障特征提取与聚焦能力有限。

从 EWT 的分解结果来看，在两个分量中受噪声及干扰频率的影响很大，在两个子带分量中噪声及干扰频率非常明显，在表 4.7 中可以看出计算结果相较于融合算法很低，说明 EWT 算法的抗噪声及干扰能力有限。

经过 EWT 二次处理之后的 IMF 分量在谱线结构上更加清晰、包络谱中的噪声显著减少、故障特征的幅值大幅提高，这说明 EWT 算法进行二次处理之后能够有效地抑制噪声，大幅降低 EMD 算法的模态混叠的影响，在表 4.8 中 F_{dB} 计算结果比较更加清晰，显著高于 EMD 算法的计算结果。

综上所述，EMD-EWT 算法相较于传统的 EMD 算法在滚动轴承内圈故障特征提取中有着明显的优势：EWT 的自适应频带划分有效解决了 EMD 算法中的模态混叠以及端点效应的问题，提高了分解的稳定性。

经过分析随机选取的外圈故障数据，可以发现融合算法的优势。为了证明算法的普适性，我们对全部数据进行批量分析，只输出 F_{dB} 最大的分量进行宏观比较，比较结果图 4.14。

在图 4.14 中黑色实线、红色实线、蓝色划线以及绿色点线分别代表转速、EMD-EWT 算法的 F_{dB} 值计算结果、EMD 算法的 F_{dB} 值计算结果以及 EWT 算法的 F_{dB} 值计算结果，经过比较可得在不同转速下，融合算法相较于 EMD 算法的 F_{dB} 和 EWT 算法的 F_{dB} 都更高，意味着故障频率更加突出，诊断效果更好。




图 4.14 全部数据 F_{dB} 值变化趋势

4.2.4 滚动轴承滚珠故障分析结果

滚动轴承故障诊断中滚珠故障是最难以监测的部分，传统的信号处理办法往往因为滚珠故障的隐蔽性不能很好地观察到理论滚珠故障特征频率，只能观察到二倍频的分量，而融合算法既能观察到理论特征频率，又可以使理论特征频率的二倍频更加明显。

随机挑选的滚动轴承内圈故障数据参数见表 4.9。时域波形及频谱如图 4.15、图 4.16 所示。

表 4.9 轴承参数

序号	转速 /rpm	采样率 /Hz	振动测点	内径	外径	节径	滚动体直径	接触角	滚动体数
1	1732	12K	基座	25mm	52mm	28.5mm	6.75mm	0°	8

由图 4.15 可见，滚动体故障信号在时域上整体呈现为高频随机振动特性，振动幅值相对稳定，未出现明显、规则的周期性冲击，这主要是由于滚动体故障点在内外圈之间不断变化接触位置，其激励具有显著的随机性和非平稳性，故障冲击在时域中容易被背景噪声所掩盖。由图 4.16 的频谱可知，信号能量主要集中在中高频区域，在约 3.5–4 kHz 附近出现幅值显著的主峰，表明滚动体故障激励有效激发了轴承—结构系统的共振响应；而低频范围内未呈现清晰、突出的特征频率及倍频成分，故障信息更多体现在高频共振带内。总体而言，滚动体故障信号表现为冲击特征分散、频谱中高频共振明显、低频特征不突出，单纯依靠时域和频谱分析难以直接识别故障特征频率，需结合包络解调或自适应信号分解方法进一步提取故障信息。




图 4.15 时域波形图






图 4.16 频谱图

4.2.4.1 EMD 算法结果分析


对信号进行 EMD 分解，分解出的 IMF 分量如图 4.17 所示。



(a) EMD 分解 IMF1 分量



(b) EMD 分解 IMF2 分量






图 4.17 EMD 分解后 IMF 分量包络谱

根据表 4.9 中的轴承参数，计算后可以得到 $f_b=58.2\text{Hz}$ ，但是由于在滚珠故障中，滚珠每旋转一圈缺陷点都会与轴承内外滚道各接触一次，因此，在对滚珠故障信号进行故障诊断时，常常更关注滚珠自转频率的 2 倍频即 $2f_b=116.5\text{Hz}$ 。得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.10。

表 4.10 F_{dB} 值汇总表


序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	135	375	28	16

从 IMF5 分量开始为 EMD 分解的残余分量故不参与计算。经过计算可得 IMF3 分量为最大 F_{dB} 所在分量，故取 IMF3 的结果为最佳分解结果进行输出。


4.2.4.2 EWT 算法结果分析

对信号进行 EWT 分解，分解结果如图 4.18 所示。

从图中可以看出，经过 EWT 分解后得到的子带包络谱能够有效突出故障特征频率。图(a)为 EWT 分解子带 1 的包络谱，横坐标为频率 (Hz)，纵坐标为加速度幅值 (g)。在约 110 Hz 处出现一定的谱峰（图中红色虚线所示位置），该频率与滚动轴承滚动体故障特征频率基本一致，说明该频率成分在信号中具有显著能量。



(a) EWT 分解子带 1 包络谱



(b) EWT 分解子带 2 包络谱

图 4.18 EWT 分解后子带包络谱

根据表 4.9 中的轴承参数，计算后可以得到 $f_b=58.2\text{Hz}$ ，但是由于在滚珠故障中，滚珠每旋转一圈缺陷点都会与轴承内外滚道各接触一次，因此，在对滚珠故障信号进行故障诊断时，常常更关注滚珠自转频率的 2 倍频即 $2f_b=116.5\text{Hz}$ 。得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.11。


表 4.11 F_{dB} 值汇总表

序号	IMF1	IMF2
F_{dB}	107	66


4.2.4.2 EMD-EWT 算法结果分析

接着利用 EWT 算法对每一个 IMF 分量进行二次精细化处理，详细步骤见章节 3.2，每一个 IMF 分量进行二次处理后会有 N 条子带，选取在故障特征频率正负 10Hz 范围内能量占比最大的子带进行输出，EWT 二次处理包络谱如图 4.19。


如图所示，为采用 EMD-EWT 融合算法对滚动轴承振动信号处理后得到的包络谱结果。其中图(a)和图(b)分别为 EWT 二次分解后得到的 IMF1 与 IMF2 分量的包络谱。从图中可以看出，在约 110 Hz 处均出现明显的谱峰（图中红色虚线所示），该频率与滚动轴承滚动体故障特征频率相对应。特别是在 IMF1 分量的包络谱中，该特征频率处的幅值最为突出，同时在其倍频附近还存在一定的谱线分布，表明信号中存在由滚动体局部缺陷引起的周期性冲击成分。相比之下，IMF2 分量中虽然也能够观察到该特征频率，但幅值相对较弱，说明其包含的故障特征信息较少。通过 EMD 对原始信号进行自适应分解后，再利用 EWT 对有效分量进行进一步细化分析，能够更加有效地分离不同频带的振动信息，增强故障特征频率的可识别性，从而验证了 EMD-EWT 融合方法在滚动轴承滚动体故障特征提取中的有效性与优越性。



(a) EWT 二次分解后 IMF1 包络谱



(b) EWT 二次分解后 IMF2 包络谱



(c) EWT 二次分解后 IMF3 包络谱

图 4.19 EWT 算法二次精细化分解后包络谱

根据表 4.9 中的轴承参数，计算后可以得到 $f_b=58.2\text{Hz}$ ，但是由于在滚珠故障中，滚珠每旋转一圈缺陷点都会与轴承内外滚道各接触一次，因此，在对滚珠故障信号进行故障诊断时，常常更关注滚珠自转频率的 2 倍频即 $2f_b=116.5\text{Hz}$ 。得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对五个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.12。

表 4.12 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3
F_{dB}	166	37	26

从 IMF3 分量开始为 EMD 分解后的残余分量故不进行 F_{dB} 值的计算。经过计算可得 IMF1 分量为最大 F_{dB} 所在分量，故取 IMF1 的结果为最佳分解结果进行输出。

通过对滚动轴承内圈故障轴承利用 EMD、EWT、EMD-EWT 算法进行分解，分解结果与 F_{dB} 故障特征指标如图 4.17、图 4.18、图 4.19、表 4.10、表 4.11、表 4.12 所示。传统的 EMD 算法

在分解过程中表现出了明显的局限性，各个 IMF 分量之间存在明显的模态混叠与端点效应，分解后的 IMF 分量端点处出现了明显的虚假频率成分，导致单倍滚珠故障特征频率无法被有效的监测，并且 F_{dB} 值明显比融合算法的结果低，特征显著度低于融合算法。EWT 算法受噪声影响较大，导致完全无法观察到单倍滚珠故障特征频率。

综上所述，EMD-EWT 算法相较于传统的 EMD 算法在滚动轴承滚珠故障特征提取中有着明显的优势：EWT 的自适应频带划分有效解决了 EMD 算法中的模态混叠以及端点效应的问题，提高了分解的稳定性，凸显了滚珠故障理论特征频率的频率成分。

经过分析随机选取的外圈故障数据，可以发现融合算法的优势。为了证明算法的普适性，我们对全部数据进行批量分析，只输出 F_{dB} 最大的分量进行宏观比较，比较结果如图 4.20 所示，在转速相同、工况相同的前提下，EMD-EWT 融合算法的 F_{dB} 值要显著高于传统 EMD 算法和 EWT 算法的计算结果，能够更加可靠地反映出滚动轴承内圈故障的故障，融合算法在故障特征增强、特征频率聚焦以及抗噪等方面有着明显的优势，更适用于滚动轴承早期故障诊断。




图 4.20 全部数据 F_{dB} 值变化趋势

4.3 基于带机匣航空发动机转子试验器滚动轴承故障模拟试验验证

4.3.1 试验介绍





(a) NI USB9234 采集卡



(b) B&K 4805 加速度传感器

图 4.23 试验所用的传感器与采集卡

下面将对采集的不同转速下的外圈故障信号进行 EMD、EMF-EWT 处理，得出结论并进行对比。

4.3.2 滚动轴承外圈故障转速 2400rpm 分析结果

随机挑选的滚动轴承外圈故障数据信息见表 4.15。时域波形及频谱如图 4.24、图 4.25 所示：

表 4.15 滚动轴承外圈故障数据信息

序号	转速 /rpm	采样频率/Hz	振动测点	内径	外径	节径	滚动体直径	接触角	滚动体个数
1	2400	10.24K	机匣上	30mm	62mm	46mm	9.5mm	0°	9

由图 4.24 可见，该振动信号在时域上呈现出明显的随机振动特性，整体幅值在一定范围内波动，局部区段存在较为突出的瞬态峰值，但冲击间隔不规则、周期性不明显，表明信号中故障激励较弱且受到噪声和多源激励的共同影响。由图 4.25 的频谱分析可知，信号能量主要集中在低频区域，低频段存在若干离散谱峰，其中个别频率成分幅值较为突出；与此同时，在约 3.3–3.6 kHz 附近可观察到较为集中的能量带，显示出结构共振对振动信号的放大效应。总体来看，该信号具有“低频主导、高频共振叠加”的典型特征，故障相关信息在频谱中分散且易受噪声掩盖，仅依靠传统时域和频域分析难以准确识别特征频率，有必要进一步引入包络分析或时频方法以增强潜在故障特征。




图 4.24 时域波形图






图 4.25 频谱图

4.3.2.1 EMD 算法结果分析


对信号进行 EMD 分解，得到的 IMF 分量如图 4.26 所示。




(a) EMD 分解 IMF1 分量



(b) EMD 分解 IMF2 分量



(c) EMD 分解 IMF3 分量



(d) EMD 分解 IMF4 分量

图 4.26 EMD 分解后 IMF 分量包络谱

根据表 4.15 中的轴承参数，计算后可以得到 $f_o=141.6\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对四个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.16。


表 4.16 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	4	36	17	6


从 IMF5 分量开始为 EMD 分解的残余分量故不参与计算。经过计算可得 IMF2 分量为最大 F_{dB} 所在分量，故取 IMF2 的结果为最佳分解结果进行输出。

4.3.2.2 EWT 算法结果分析

对信号进行 EWT 分解，得到的子带分量如图 4.27 所示。



(a) EWT 分解后子带 1 包络谱



(b) EWT 分解后子带 2 包络谱

图 4.27 EWT 分解后子带包络谱


根据表 4.15 中的轴承参数，计算后可以得到 $f_o=141.6\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对四个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.17。

表 4.17 F_{dB} 值汇总表


序号	子带 1	子带 2
F_{dB}	29	13

4.3.2.3 EMD-EWT 算法结果分析


接着利用 EWT 算法对每一个 IMF 分量进行二次精细化处理, 每一个 IMF 分量进行二次处理后会有 N 条子带, 选取在故障特征频率正负 10Hz 范围内能量占比最大的子带进行输出, EWT 二次处理包络谱如图 4.28。




(a) EWT 二次精细化分解后 IMF1 包络谱



(b) EWT 二次精细化分解后 IMF2 包络谱



(c) EWT 二次精细化分解后 IMF3 包络谱



(d) EWT 二次精细化分解后 IMF4 包络谱

图 4.28 EWT 算法二次精细化分解后包络谱

根据表 4.13 中的轴承参数, 计算后可以得到 $f_o=141.6\text{Hz}$, 得到外圈故障频率后可计算故障

特征频率无量纲量 F_{dB} ，对四个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.18。

表 4.18 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	5	64	6	3

对于在转速 2400rpm 的转速状态下的数据分别进行了 EMD、EMD-EWT 分解，由图 4.26 可得 EMD 分解结果的包络谱整体噪声成分较多，高频段背景噪声非常显著，特征频率主要集中在 IMF2 模态分量中，幅值约为 0.027，能量集中度非常有限，同时由于模态混叠的影响，导致特征频率的能量被泄露在 IMF3 模态分量中，导致故障冲击频率没有被有效地分离，体现在 F_{dB} 值的计算结果中，EMD 分解的 F_{dB} 最大仅为 36。由图 4.27 可得 EWT 分解由于噪声和干扰频率的影响仅分解出两个分量，且幅值仅为 0.015，能量集中度非常有限，这是由于 EWT 自身分解能力的影响，极易发生过分解而导致特征频率无法被有效地分离出来，EWT 分解的 F_{dB} 最大仅为 29。

相比之下，在 EWT 算法对 IMF 分量进行二次精细化处理之后，有效地克服了模态混叠的影响，在 IMF2 中振动冲击信号被有效地分离出来，特征频率的幅值达到 0.045，提升约 70%。同时包络谱整体噪声基底降低，谱线结构更加清晰。在 F_{dB} 值的计算结果中，IMF2 的 F_{dB} 值达到 64，显著高于 EMD 算法的 36 和 EWT 算法的 29。这说明 EMD-EWT 算法能够增强故障特征频率的能量表达，增强故障冲击。

经过分析随机选取的外圈故障数据，可以发现融合算法的优势。为了证明算法的普适性，我们对 2400rpm 转速状态下的全部数据进行批量分析，只输出 F_{dB} 最大的分量进行宏观比较，比较结果图 4.29。

在图 4.29 中蓝色划线表示传统 EMD 算法提取特征频率之后的 F_{dB} 值变化趋势，红色的曲线表示 EMD-EWT 融合算法提取特征频率之后的 F_{dB} 值变化趋势，绿色点线表示 EWT 算法提取特征频率之后的 F_{dB} 值变化趋势。EMD-EWT 融合算法的 F_{dB} 值显著高于 EMD 算法的 F_{dB} 值和 EWT 算法的 F_{dB} ，始终维持在 30 以上大部分处于 50 以上，而 EMD 算法的 F_{dB} 值和 EWT 算法的 F_{dB} 值大部分在 20-40 之间。这说明 EMD-EWT 算法能够更有效地识别滚动轴承外圈故障，不会发生漏判以及误判。




图 4.29 所有数据的 F_{dB} 变化趋势

4.3.3 滚动轴承外圈故障转速 2000rpm 分析结果

随机挑选的滚动轴承外圈故障数据参数见下表 4.19。时域波形及频谱如图 4.30、图 4.31 所示。

表 4.19 轴承参数

序号	转速 /rpm	采样率 /Hz	振动测点	内径	外径	节径	滚动体直径	接触角	滚动体数
1	2012	10.24K	机匣上	30mm	62mm	46mm	9.5mm	0°	9

由图 4.30 可见，该振动信号在时域上以随机振动为主，整体幅值围绕零均值上下波动，叠加有少量幅值较大的瞬态波动，但未呈现出清晰、规则的周期性冲击特征，表明故障激励较弱且信号受背景噪声影响明显。从图 4.31 频谱图可以看出，信号能量主要集中在低频区域，低频段存在若干离散谱峰，对应转动系统的转频及其谐波成分；与此同时，在中高频段约 3 - 4 kHz 附近出现一段较为集中的能量分布，反映了结构共振对振动响应的放大作用。总体而言，该信号呈现出低频成分占主导、高频共振叠加的特征，故障相关频率在频谱中不够突出，仅依靠常规时域和频域分析难以实现有效识别，需要进一步结合包络分析或自适应信号分解方法以增强潜在故障特征。




图 4.30 时域波形图






图 4.31 频谱图

4.3.3.1 EMD 算法结果分析


对信号进行 EMD 分解，分解出的 IMF 分量如图 4.32 所示。




(a) EMD 分解 IMF1 分量



(b) EMD 分解 IMF2 分量



(c) EMD 分解 IMF3 分量



(d) EMD 分解 IMF4 分量

图 4.32 EMD 分解后 IMF 分量包络谱

根据表 4.19 中的轴承参数，计算后可以得到 $f_0=119\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对四个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.20。


表 4.20 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	4	32	25	12


从 IMF5 分量开始为 EMD 分解的残余分量故不参与计算。经过计算可得 IMF2 分量为最大 F_{dB} 所在分量，故取 IMF2 的结果为最佳分解结果进行输出。

4.3.3.2 EWT 算法结果分析

对信号进行 EWT 分解，分解出的子带分量如图 4.33 所示。



(a) EWT 分解后子带 1 包络谱



(b) EWT 分解后子带 2 包络谱

图 4.33 EWT 分解后子带包络谱


根据表 4.19 中的轴承参数, 计算后可以得到 $f_0=119\text{Hz}$, 得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} , 对四个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出, 计算结果如表 4.21。

表 4.21 F_{dB} 值汇总表


序号	子带 1	子带 2
F_{dB}	30	5

4.3.3.3 EMD-EWT 算法结果分析


接着利用 EWT 算法对每一个 IMF 分量进行二次精细化处理, 每一个 IMF 分量进行二次处理后会有 N 条子带, 选取在故障特征频率正负 10Hz 范围内能量占比最大的子带进行输出, EWT 二次处理包络谱如图 4.34。




(a) EWT 二次精细化分解后 IMF1 包络谱



(b) EWT 二次精细化分解后 IMF2 包络谱



(c) EWT 二次精细化分解后 IMF3 包络谱



(d) EWT 二次精细化分解后 IMF4 包络谱

图 4.34 EWT 算法二次精细化分解后包络谱

根据表 4.19 中的轴承参数，计算后可以得到 $f_0=119\text{Hz}$ ，得到外圈故障频率后可计算故障特征频率无量纲量 F_{dB} ，对四个特征模态分量进行计算后输出 F_{dB} 值最大的分量作为结果分量进行输出，计算结果如表 4.22。

表 4.22 F_{dB} 值汇总表

序号	IMF1	IMF2	IMF3	IMF4
F_{dB}	6	66	7	5

同 2400rpm 状态下的数据类似，EMD-EWT 算法克服了 EMD 算法的模态混叠的影响，减少了不同频带间能量的泄露，在 IMF2 分量中能量更加集中，特征频率得到了增强，噪声得到了抑制。

经过分析随机选取的外圈故障数据，可以发现融合算法的优势。为了证明算法的普适性，我们对 2400rpm 转速状态下的全部数据进行批量分析，只输出 F_{dB} 最大的分量进行宏观比较，比较结果图 4.35。

在图 4.35 中蓝色划线表示传统 EMD 算法提取特征频率之后的 F_{dB} 值变化趋势，红色的曲线表示 EMD-EWT 融合算法提取特征频率之后的 F_{dB} 变化趋势，绿色点线表示 EWT 算法提取特征频率之后的 F_{dB} 值变化趋势。EMD-EWT 融合算法的 F_{dB} 值显著高于 EMD 算法的 F_{dB} 值与 EWT 算法的 F_{dB} 值，始终维持在 20 以上这说明 EMD-EWT 算法能够更有效地识别滚动轴承外圈故障，不会发生漏判以及误判。




图 4.35 整体 F_{dB} 变化趋势

4.3.4 其他转速状态下整体 F_{dB} 分析

下面给出整体 F_{dB} 变化趋势，从趋势中分析两种算法的优劣。

在图 4.36 中蓝色划线表示传统 EMD 算法提取特征频率之后的 F_{dB} 值变化趋势，红色的曲线表示 EMD-EWT 融合算法提取特征频率之后的 F_{dB} 值变化趋势，绿色点线表示 EWT 算法提取特征频率之后的 F_{dB} 值变化趋势。可以明显地看出，融合算法 F_{dB} 值显著高于 EMD 算法的 F_{dB} 值和 EWT 算法的 F_{dB} 值，这说明融合算法能够更好地诊断出预设的外圈故障。




图 4.36 1800rpm 转速状态下整体 F_{dB} 变化趋势

4.4 基于带机匣航空发动机转子试验器正常轴承模拟试验验证

在上一节中，针对带机匣试验器在不同的转速工况条件下的故障信号进行分析，比较了 EMD 算法与 EMD-EWT 融合算法的特征频率分布以及 F_{dB} 的大小，验证了融合算法在故障特征提取方面的优越性。为了进一步建立稳健的故障判定标准，需要对无故障条件下的振动信号进行分析。

无故障条件下的振动信号有着能量分布稳定、特征成分少、谱线结果简单的特点，其特征模式与故障状态存在本质上的差异，通过对正常数据进行分析，可以为后续实际整机发动机设定故障阈值，以此来判断整机发动机的故障状态。

因此，本节将对带机匣航空发动机转子试验器的正常轴承的振动数据进行分析，分别采用 EMD 算法与 EMD-EWT 融合算法对振动数据进行处理，从而计算 F_{dB} 值，最终为完整的故障诊断系统提供基础数据支持。

分别对 1800、2000、2400rpm 转速状态下的数据进行处理，轴承基本参数与 4.3 章节的参数一致，得到整体 F_{dB} 值变化趋势如图 4.37、图 4.38、图 4.39 所示：




图 4.37 2400rpm 转速状态下整体 F_{dB} 值变化趋势




图 4.38 2000rpm 转速状态下整体 F_{dB} 值变化趋势




图 4.39 1800rpm 转速状态下整体 F_{dB} 值变化趋势

在图 4.37、图 4.38、图 4.39 中分别给出了在三种不同的转速状态下经过 EMD 和 EMD-EWT 算法处理后的 F_{dB} 值变化趋势曲线，从整体上看，不同转速下两种算法的 F_{dB} 值曲线都非常低，这说明在特征频率范围内没有明显的峰值，是典型的正常状态特征，说明在正常工况下，滚动

轴承振动信号中没有明显的冲击成分，能量分布非常平稳。在变化趋势图中 EMD 算法的结果基本稳定在 3-6 之间，EWT 算法普遍分布在 10-15 之间而 EMD-EWT 融合算法稳定在 10 以下，并没有出现 EWT 算法突增的情况。

对比而言，融合算法计算出的 F_{dB} 值普遍高于 EMD 算法，这是由于融合算法使得信号中的背景噪声被大幅度降低，从而使包络谱的能量有所提升，这也说明了融合算法能够更好地提取出早期微弱的故障成分。融合算法的 F_{dB} 值仍然维持在一个较低的水平，说明轴承状态依然是正常的状态。而 EWT 算法由于自身的局限性受噪声影响较大，无法对振动信号进行准确的分解而产生过分解的情况，导致正常轴承的 F_{dB} 值仍然出现突增的情况且普遍较高，因此无法单独使用 EWT 算法对振动数据进行处理。

基于正常轴承与外圈故障轴承的特征值的计算，可以给出一个比较稳健的阈值，从而判定滚动轴承是否处于异常状态。

4.5 特征阈值判定方法的建立

在经过前述对于正常轴承以及故障轴承振动数据的系统分析后，可以明显地发现在不同状态下 F_{dB} 值的变化趋势存在着显著的差异。为了实现对轴承运行状态的识别以及早期微弱故障诊断，在大量数据中逐个数据进行分析显然不切实际，需要建立一套阈值，从而通过 F_{dB} 值对轴承状态进行判定。

因此，本节将通过前述正常轴承与故障轴承的 F_{dB} 变化规律，结合统计分析的方法进行阈值的构建，为后续整机试验提供基础。

本文选取均值为 $\pm 3\sigma$ 的正态统计模型对特征阈值进行界定，以 EMD-EWT 融合算法提取的无量纲特征量 F_{dB} 为例，在各个转速正常工况下采集振动信号，得到样本集合

$$\{F_{dB}^{(n)}(1), F_{dB}^{(n)}(2), \dots, F_{dB}^{(n)}(N)\} \quad (4.1)$$

在工况稳定、采集数据足够的情况下，正常状态下的 F_{dB} 可用高斯随机变量进行建模：

$$F_{dB}^{(n)} \sim N(\mu_n, \sigma_n^2) \quad (4.2)$$

其中 μ_n 与 σ_n 分别为正常状态下 F_{dB} 的均值和标准差，可通过样本估计为

$$\mu_n = \frac{1}{N} \sum_{i=1}^N F_{dB}^{(n)}(i) \quad (4.3)$$

$$\sigma_n = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (F_{dB}^{(n)}(i) - \mu_n)^2} \quad (4.4)$$

根据正态分布的特性，约有 99.7% 的数据落在 $[\mu_n - 3\sigma_n, \mu_n + 3\sigma_n]$ 的区间内，因为设定的阈值是为了区分故障状态，所以为了保证不进行虚报和误报，选取上界进行界定，因此：

$$T_{3\sigma} = \mu_n + 3\sigma_n \quad (4.5)$$

以此为阈值上限，则正常状态被误判为故障的概率为：

$$P_{FA} = P_r(F_{dB}^{(n)} > T_{3\sigma}) \approx 0.08\% \quad (4.6)$$

能够有效地控制误报率。

因此在本文中，分别对三种转速状态下的 F_{dB} 进行统计，分别得到各自的 μ_n 与 σ_n ，并计算出响应的 $T_{3\sigma}$ 。基于计算结果，可以将阈值设为：

$$T=15 \quad (4.7)$$

作为轴承状态判别的阈值，即 $F_{dB} < 15$ 时判定为正常状态， $F_{dB} > 15$ 时认定存在故障，需要进一步进行诊断。

4.6 本章小结

本章主要围绕滚动轴承故障模拟试验器的实验验证展开，以振动数据为基础，从算法的准确性、无量纲特征量 F_{dB} 变化趋势以及阈值界定的方法进行系统分析，旨在验证 EMD-EWT 融合算法在模拟实际工况的背景下对于微弱故障诊断以及故障特征提取的优势和可靠性。

首先，针对国际通用的凯斯西储大学数据集，分别用 EMD 算法以及 EMD-EWT 融合算法进行分解和包络分析。结果表明，传统的 EMD 算法虽然能够对信号的故障特征频率进行识别，但是普遍存在模态混叠、端点效应等缺陷，导致能量发生泄漏不够集中，无量纲特征量 F_{dB} 普遍较低，无法对故障状态进行准确的诊断。而 EMD-EWT 融合算法在 EMD 算法的基础上进一步进行自适应频带划分从而实现能量的重构，使得故障特征频率在包络谱中表现更高的峰值，并且很好的抑制了噪声的影响，使得无量纲特征量 F_{dB} 更高，这充分说明了 EMD-EWT 融合算法在故障特征增强、抗噪性能以及弱特征提取方面远优于传统的 EMD 算法，对于故障的诊断能力更加突出。

其次，为了验证算法在实际环境中的适用性，自主搭建了带机匣滚动轴承实验平台，通过采集带机匣试验器的振动数据，进一步验证融合算法的实用性。结果表明 EMD-EWT 融合算法依然能够克服 EMD 算法自身的模态混叠以及端点效应等的缺陷，无量纲特征量 F_{dB} 更高，诊断能力更强。

接着本章针对无故障的正常轴承数据进行分析，结果表明正常状态下的无量纲特征量 F_{dB} 整体分布非常低，稳定在 3-8 之间。值得注意的是，虽然 EMD-EWT 融合算法在结果中比传统的 EMD 算法结果偏高，但是仍比故障数据低得多，且只提高 0-2。这主要是由于融合算法将微

弱的周期性成分能量聚集，噪声基底被抑制的原因，并不代表存在故障，而 EWT 算法由于过分解的影响受噪声影响更大，导致正常数据的 F_{dB} 也处于较高的状态。

最后基于故障和正常状态下的全面分析，本章最后利用统计模型对特征阈值进行了推导，最终确定了特征阈值为。即无量纲特征量 F_{dB} 整体结算结果超过 15 则认定为存在故障，需要进行进一步诊断。

综上所述，本章从通用数据库以及实际工程信号两方面验证了融合算法在滚动轴承早期故障诊断方面有着显著的优势，明确了其噪声抑制、特征增强、特征频率提取等方面远优于 EMD 算法的诊断性能。同时，基于振动数据设定了阈值，建立了可靠的判定标准，为下一章在实际整机试验进行故障分析奠定了基础。

第五章 真实航空发动机主轴承试验验证

5.1 引言

在前面几章的研究中，基于滚动轴承故障模拟试验器以及凯斯西储大学公共数据库，对不同类型的滚动轴承故障信号进行了系统的分析，并重点验证了 EMD-EWT 融合算法在故障提取以及早期故障诊断中的有效性。通过对外圈、内圈、滚动体故障数据的分解结果、能量指标及其趋势变化进行了深入的对比，证明了 EMD-EWT 融合算法相较于传统 EMD 算法与 EWT 算法的优势。同时根据对处理结果进行统计分析，得到了特征阈值，为实际工程应用中提供了辨别故障状态的依据。

然而，实验室模拟试验信号相较于真实航空发动机的运行环境仍然有巨大的差异，航空发动机处于高温、高速、高载荷的复杂服役环境下，振动传递路径长、背景噪声强、结构复杂，信号特征往往表现出非平稳性和不确定性的特征。因此，为了进一步验证 EMD-EWT 融合算法在实际工程环境中的适用性，有必要利用真实发动机主轴承故障试验进行验证。在真实的整机试验与试验器中由于环境极为复杂，EWT 算法极易产生过分解而导致分解失败，故在本章中不再使用 EWT 算法对振动数据进行处理。

本章基于 B2XX56 型航空发动机主轴承故障数据、B2X3 型航空发动机正常轴承以及真实航空发动机 A602 试验器故障数据，对前文提出的方法展开工程验证。通过对比不同工况下的真实轴承振动信号分解结果、特征提取效果以及 F_{dB} 变化趋势，评估融合算法在高噪声，高干扰环境下的适用性和可靠性。旨在全面评估融合算法在早期故障方面的监测能力与判断准确性。

5.2 故障主轴承整机试验验证

5.2.1 试验简介

本次试车试验采用 XXB 型发动机，编号为 20056，该发动机依据《轴承状态监测测试改装要求》（S10.JT.1973）进行测试改装，以满足在三支点轴承座安装边、斜支板后机匣等位置安装振动在线传感器，在发动机滑油供油管路、后腔回油管路分别加装滑油金属屑在线监控传感器，同时，在总回油路上加装磁性金属屑末信号器以收集金属屑末。

由于 XX 型发动机三支点主轴承故障多发，因此在发动机主轴承故障剥落整机试验中，重点研究三支点主轴承典型剥落情况下的特征与规律，相应的预设故障轴承实物图如图 5.1 所示。

本次试车共安装 16 个传感器进行数据采集分别为位于进气机匣的 CH05 进气机匣 (A1) 振动测点, 位于中介机匣的 CH07 中介机匣 (V34) 振动测点、CH06 中介机匣 (V2) 垂直振动测点、CH02 三支点 (V32) 垂直振动测点、CH01 三支点 (V31) 水平振动测点, 位于后机匣的 CH03 涡轮 (V53) 振动测点、CH09 后机匣 (V5) 振动测点、CH10 后机匣 (V56) 振动测点、CH08 后机匣 (A4) 振动测点、CH04 涡轮 (V54) 振动测点、CH14 后机匣 (V55) 振动测点, 位于飞附机匣的 CH11 飞附机匣垂直振动测点, 位于发附机匣的 CH13 发附机匣垂直振动测点、CH12 发附机匣水平振动测点, 传感器参数如下表及布置情况如表 5.1 所示, 具体安装位置如图 5.2 所示:




图 5.1 三支点主轴承剥落实物图

本次试车共安装 16 个传感器进行数据采集分别为位于进气机匣的 CH05 进气机匣 (A1) 振动测点, 位于中介机匣的 CH07 中介机匣 (V34) 振动测点、CH06 中介机匣 (V2) 垂直振动测点、CH02 三支点 (V32) 垂直振动测点、CH01 三支点 (V31) 水平振动测点, 位于后机匣的 CH03 涡轮 (V53) 振动测点、CH09 后机匣 (V5) 振动测点、CH10 后机匣 (V56) 振动测点、CH08 后机匣 (A4) 振动测点、CH04 涡轮 (V54) 振动测点、CH14 后机匣 (V55) 振动测点, 位于飞附机匣的 CH11 飞附机匣垂直振动测点, 位于发附机匣的 CH13 发附机匣垂直振动测点、CH12 发附机匣水平振动测点, 传感器参数如下表及布置情况如表 5.1 所示, 具体安装位置如图 5.2 所示:

表 5.1 传感器参数

通道号	测点名称	安装位置	传感器编号	传感器灵敏度 (pC/g)	传感器灵敏度 (pC/g)	传感器 量程	频响范围 (Hz)
1	三支点 (V31) 水平振动测点	中介机匣与 三支点轴承 座安装边	S/N22216	20.4624	19.8	500	20000
2	三支点 (V32)	中介机匣与	S/N22255	20.3448	19.8	500	20000

通道号	测点名称	安装位置	传感器编号	传感器灵敏度 (pC/g)	传感器灵敏度 (pC/g)	传感器 量程	频响范围 (Hz)
	垂直振动测点	三支点轴承 座安装边					
3	涡轮 (V53) 振 动测点	斜拉杆的后 机匣斜支板 头部	S/N22272	20.2566	19.8	500	20000
4	涡轮 (V54) 振 动测点	斜拉杆的后 机匣斜支板 头部	S/N22262	20.566	19.8	500	20000
5	进气机匣 (A1) 振动测点	进气机匣左 侧 90°	S/N22125	20.1978	19.8	500	20000
6	中介机匣 (V32) 垂直振动测点	中介机匣正 下方	S/N23198	20.17	19.8	500	20000
7	中介机匣 (V34) 振动测点	中介机匣左 侧斜下方	S/N22111	20.0508	19.8	500	20000
8	后机匣 (A4) 振动测点	后机匣正下 方	S/N23197	20.54	19.8	500	20000
9	后机匣 (V5) 振动测点	后机匣左侧	S/N22126	20.0508	19.8	500	20000
10	后机匣 (V56) 振动测点	飞附机匣水 平方向	S/N22102	20.3644	19.8	500	20000
11	飞附机匣垂直 振动测点	飞附机匣垂 直方向	S/N21654	20.3056	19.8	500	20000
12	发附机匣水平 振动测点	发附机匣水 平方向	S/N22098	20.4918	19.8	500	20000
13	发附机匣垂直 振动测点	发附机匣垂 直方向	S/N22124	20.4232	19.8	500	20000
14	后机匣 (V55) 振动测点	后机匣右上 方	S/N22119	20.4526	19.8	500	20000
15	N1 转速						
16	N2 转速						

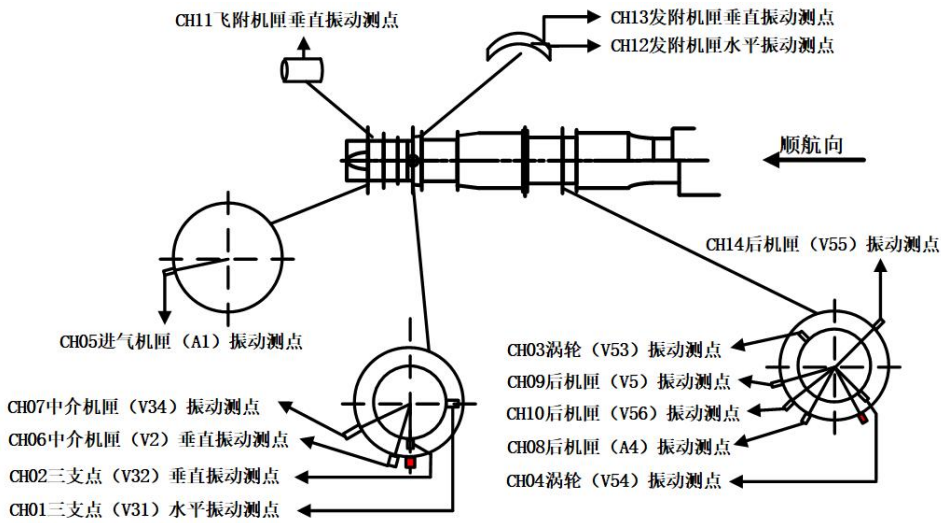


图 5.2 传感器布置示意图

振动数据采集软件为航空发动机振动健康诊断系统 AVHDS (Aero-Engine Vibration Health Diagnosis System)，AVHDS 是专门用于航空发动机整机振动测试和信号分析以及故障诊断的专用软件。软件具有小波分解、自相关分析、希尔伯特变换、傅里叶变换等使用于航空发动机振动信号分析的信号处理方法，可以实现航空发动机各种轴承零部件的故障特征频率的计算和信号特征提取，同时可以监控发动机振动总量。该软件能够实现发动机转子系统、主轴承系统，以及附件机匣系统的故障诊断。软件采用 Microsoft VisualC++6.0 进行程序开发，采用工程管理的方式，可同时保存多种试车任务的试验数据，既可以在线采集分析，也可以进行离线数据回放和分析。

软件部分数据采集界面如图 5.3 所示。本次试验采用江苏东华测试技术股份有限公司 DH8302 数据采集器。该数据采集器具有 16 路通道，其中两路用于发动机转速采集，其余通道用于振动加速度的采集。DH8302 型数据采集器如图 5.4 所示。

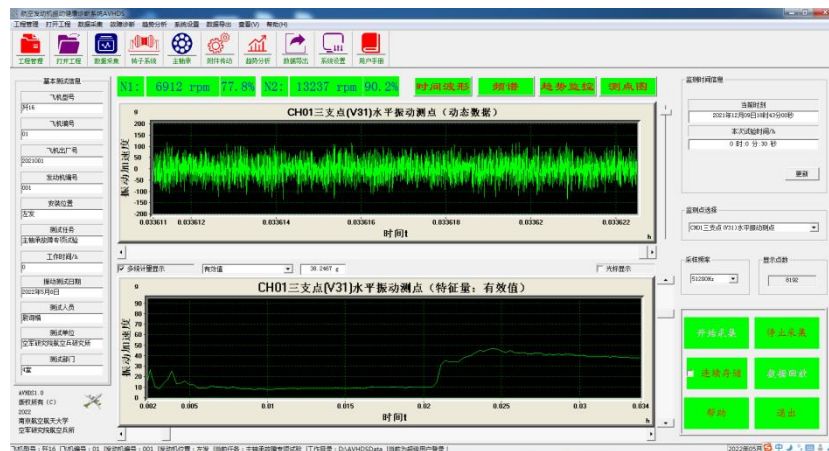


图 5.3 振动数据采集界面



图 5.4 东华 8302 型数据采集器实物图

5.2.2 试验数据分析结果

为了研究故障轴承在高速状态下的振动状态，我们挑取转速比在 98.5% 以上的数据进行分析比较，随机挑选两组数据进行详细分析。

随机挑选的滚动轴承外圈故障数据参数见表 5.2。

表 5.2 轴承参数

序号	采样频率	转速	节径	滚动体直径	接触角	滚动体个数
1	256K	14554	167.5mm	22.225mm	20° -40°	20
2	256K	10508	167.5mm	22.225mm	20° -40°	20

试验所选轴承为角接触球轴承，所以在运行过程中接触角是不断发生变化的，变化范围在 20°—40° 之间。下面对这两组数据进行 EMD 分解以及 EMD-EWT 融合分解，比较两者的分解结果。

5.2.2.1 数据 1 分解结果比较

对于整机航空发动机而言，由于噪声影响较大，结构复杂，固有频率成分影响较大，所以分解结果无效分量多。因此选取在特征频率范围内能量占比突出的分量进行比较分析。图 5.5 和图 5.6 是振动数据的时域波形图和频谱图。




图 5.5 时域波形图






图 5.6 频谱图

由图 5.6 可见，整机振动信号在时域上呈现出幅值范围大、波形密集的宽带随机特征，信号中多种激励源同时作用，振动响应连续且无明显、规则的周期性冲击，这反映了整机系统中转子、轴承、机匣及连接结构等多部件耦合振动的综合结果。与试验器工况下以单一或少量激励为主的振动信号相比，整机振动在时域上表现出更强的非平稳性和更高的背景噪声水平。频谱分析结果表明，整机振动能量分布范围较宽，在低频至中频区域存在多种离散谱峰，对应整机转频、倍频及相关结构模态；同时，在约 4 kHz 及其邻近频段出现幅值显著的高频峰值，说明整机结构共振对振动响应具有明显放大效应。总体而言，整机振动信号频谱成分复杂、特征峰密集且相互叠加，故障相关信息极易被其他结构与工况激励所淹没，其特征提取与故障识别难度明显高于试验器条件下的振动信号。


由表 5.2 所给出的参数进行计算可得滚动轴承外圈故障特征频率范围为：2123Hz—2179Hz。图 5.7 为 EMD 分解后 IMF 分量包络谱图，图 5.8 为 EWT 算法对 IMF 分量进行二次精细化分解后的包络谱图。




(a) EMD 分解 IMF1 分量包络谱



(b) EMD 分解 IMF2 分量包络谱




(c) EMD 分解 IMF3 分量包络谱




(d) EMD 分解 IMF4 分量包络谱

图 5.7 EMD 分解后 IMF 分量包络谱


在图 5.5 中，红色的虚线表示外圈故障特征频率范围，即接触角在 20° - 40° 之间变化时特征频率的变化范围。在理论特征频率范围内，EMD 算法分解后的 IMF 分量几乎观察不到特征频率，这表明在整机试验环境下，信号受到传递路径复杂，噪声强等的影响导致 EMD 算法分解效果极差，无法有效地对特征频率进行识别。因此，仅采用 EMD 算法对整机振动复杂的信号进行分解的能力有限，因此，在 EMD 算法的基础上引入 EWT 算法对 IMF 分量进行二次分解，分解结果如图 5.6 所示：




(a) EWT 二次精细化分解后 IMF1 包络谱



(b) EWT 二次精细化分解后 IMF2 包络谱



(c) EWT 二次精细化分解后 IMF3 包络谱



(d) EWT 二次精细化分解后 IMF4 包络谱

图 5.8 EWT 算法二次精细化分解后包络谱

图 5.8 是在 EMD 分解的基础上对分解后的 IMF 分量进一步进行 EWT 二次精细化分解后的包络谱图。相较于传统的 EMD 分解，EMD-EWT 分解能够突出整机滚动轴承的故障特征。观察故障特征频率范围内的谱线可以清晰地发现，在 IMF2 分量中经过 EWT 二次精细化分解出现了故障特征频率 2129Hz。这说明 EMD-EWT 算法能够在复杂的整机振动环境中有效地对振动信号进行处理，降低了噪声干扰的影响，有效克服了 EMD 算法的模式混叠的问题。为了对比较结果进行量化比较，分别计算两种方法分解后的 IMF 分量的 F_{dB} 值，结果如表 5.3。

表 5.3 F_{dB} 值汇总表

	IMF1	IMF2	IMF3	IMF4
EMD	1.71	7.73	10.08	2.87
EMD-EWT	3.46	23.16	11.14	4.01

通过对 F_{dB} 值的比较可得 EMD 算法四个 IMF 分量的 F_{dB} 值均在 15 以下，结合章节 4.5 建立的判定阈值，结果并不能表现整机滚动轴承的故障状态。而在 EMD-EWT 算法分解后的 IMF

分量的 F_{dB} 值中, IMF 分量的计算结果高于设定的阈值 15, 表明滚动轴承出现了故障。因此, 在滚动轴承早期微弱故障诊断中, EMD-EWT 算法能够更好地识别滚动轴承的故障状态, 避免出现有故障不报的情况。

5.2.2.2 数据 2 分解结果比较

图 5.9 和图 5.10 是振动数据的时域波形图和频谱图。




图 5.9 时域波形图






图 5.10 频谱图


由表 5.2 所给出的参数进行计算可得滚动轴承外圈故障特征频率范围为: 1533Hz—1573Hz。图 5.11 为 EMD 分解后 IMF 分量包络谱图, 图 5.12 为 EWT 算法对 IMF 分量进行二次精细化分解后的包络谱图。




(a) EMD 分解 IMF1 分量包络谱



(b) EMD 分解 IMF2 分量包络谱




(c) EMD 分解 IMF3 分量包络谱




(d) EMD 分解 IMF4 分量包络谱

图 5.11 EMD 分解后 IMF 分量包络谱


由图 5.11 可以看出，对于不同转速下的数据，EMD 分解效果相同。




(a) EWT 二次精细化分解后 IMF1 包络谱



(b) EWT 二次精细化分解后 IMF2 包络谱



(c) EWT 二次精细化分解后 IMF3 包络谱



(d) EWT 二次精细化分解后 IMF4 包络谱

图 5.12 EWT 算法二次精细化分解后包络谱

在通过 EWT 算法对 IMF 分量进行二次精细化处理之后，可以发现，在 IMF2 分量中的故障特征频率范围内有着明显的频率成分 1536Hz。 F_{dB} 值计算结果如表 5.4 所示。


表 5.4 F_{dB} 值汇总表

	IMF1	IMF2	IMF3	IMF4
EMD	1.56	3.14	7.97	6.10
EMD-EWT	4.01	16.02	7.67	19.46


通过对比两种算法的 F_{dB} 值，结合章节 4.5 建立的阈值，可得 EMD 算法无法对滚动轴承的故障状态进行有效地识别，而 EMD-EWT 融合算法能够识别出整机滚动轴承的故障状态。因此，在滚动轴承早期微弱故障诊断中，EMD-EWT 算法能够更好地识别滚动轴承的故障状态，避免出现有故障不报的情况。

5.2.2.3 整体 F_{dB} 值变化趋势分析

在前文中, 本文基于典型数据对 EMD 与 EMD-EWT 融合算法的分解结果进行了对比分析, 验证了融合算法在整机航空发动机复杂的振动环境下对故障轴承的诊断效果, 为了进一步对算法进行评估验证, 本节从整体的角度对 F_{dB} 值的变化趋势进行分析。因此, 本节将对不同状态下的数据进行 F_{dB} 值的计算, 结果如图 5.13 所示。



(a) EMD 算法 F_{dB} 变化趋势



(b) EMD-EWT 算法 F_{dB} 变化趋势

图 5.13 整体 F_{dB} 变化趋势



(a) 98.5%转速比以上数据 EMD 算法 F_{dB} 变化趋势(b) 98.5%转速比以上数据 EMD-EWT 算法 F_{dB} 变化趋势图 5.14 98.5%转速比以上数据 F_{dB} 变化趋势

图 5.13(a) 与图 5.13(b) 分别给出了基于 EMD 算法和 EMD-EWT 融合算法计算得到的 F_{dB} 特征值随数据序号变化的整体趋势。可以看出，在相同转速工况条件下，传统 EMD 算法得到的 F_{dB} 值整体水平偏低，大多数数据点位于阈值 15 附近或以下，仅在少数数据段出现零散的突增峰值，特征表现不够稳定，容易受到背景噪声和工况波动的影响。经过统计 EMD 算法计算得的 F_{dB} 值超过设定阈值 15 的数据仅占比 3%。而 EMD-EWT 融合算法下的 F_{dB} 值整体显著抬升，超过阈值的数据点数量明显增多，且峰值分布更加连续，能够在较长时间尺度上保持对故障相关特征的有效表征。经过统计 EMD-EWT 算法计算得的 F_{dB} 值超过设定阈值 15 的数据占比 87%，而在试验关注的高转速状态下即转速比在 98.5% 以上的数据中，传统 EMD 算法报警率为 55%，而融合算法的报警率为 90%，转速状态在 98.5% 以上的数据如图 5.14。这表明 EMD-EWT 融合算法通过对 IMF 分量的二次精细化分解，进一步抑制了无关噪声成分并增强了故障成分，使得 F_{dB} 指标在整机复杂振动环境中具有更高的敏感性和稳定性，从而在整体趋势分析和早期故障识别方面明显优于单一 EMD 算法。

5.3 故障主轴承试验器试验验证

5.3.1 试验简介

本次试验在 A602 试验器上进行。A602 试验器主体结构原理见图 5.15，试验器主体能够同时安装 2 套轴承进行试验，能够模拟轴承在发动机上的转速、载荷、装配关系和润滑条件，进行轴承的性能、耐久性、寿命试验及相关的专项研究试验，还可以进行模拟转子工作条件的轴承—转子系统工况模拟试验技术研究。试验过程中，能够对主轴转速、试验轴承温度、供回滑油温度、振动、磨损颗粒度等参数进行实时监测，自动控制运行试验程序，自动采集、存储和初步处理试验数据。




图 5.15 A602 轴承试验器主体结构图

试验器性能指标见表 5.5。

表 5.5 试验器性能指标

参数	A602 指标
电主轴功率	50kW
转速	1000~20000rpm
轴向载荷	0~70000N
径向载荷	0~60000N
试验供油	0~30L/min
试验回油	100 L/min
设备供油	0~20L/min
设备回油	60L/min
供油温度	0~200℃
试验轴承外径	380mm

本次试验的主轴承预设故障实物图如图 5.16 所示，为外圈疲劳剥落故障。



图 5.16 主轴承疲劳剥落故障

本次试验采用扬州晶明的传感器及采集器，采集硬件系统架构如图 5.17 所示，军工电脑运行系统采集软件，可以直接采集电压和 IEPE 传感器信号，通道线和电脑采集口直连。电荷型传感器需要接入电荷放大器，经过电荷放大器将电荷信号转化为电压信号后和电脑采集口相连。放大器最大支持 8 个电荷传感器。




图 5.17 扬州晶明硬件系统

5.3.2 试验数据分析结果

为了研究故障轴承在高速状态下的振动状态，我们挑取转速比在 98.5% 以上的数据进行分析比较，随机挑选一组数据进行详细分析。

随机挑选的滚动轴承外圈故障数据参数见表 5.6。

表 5.6 轴承参数

序号	转速/rpm	采样频率	节径	滚动体直径	接触角	滚动体个数
1	14749	256K	167.5mm	22.225mm	20° -40°	20

试验所选轴承为角接触球轴承，所以在运行过程中接触角是不断发生变化的，变化范围在 20° —40° 之间。下面对这组数据进行 EMD 分解以及 EMD-EWT 融合分解。

5.3.2.1 分解结果比较

根据表 5.6 可以得出两组数据的外圈故障频率范围是：2151Hz—2208Hz，因此需要在外圈故障频率范围内寻找特征频率，图 5.18 为信号的时域波形图、图 5.19 是信号的频谱图、图 5.20 为 EMD 分解后 IMF 分量包络谱图。




图 5.18 时域波形图






图 5.19 频谱图


由图 5.18 可见，整机振动信号在时域上呈现出幅值范围较大、能量密集的宽带随机振动特征，整体波形表现为多源激励叠加后的复杂响应，未出现清晰、可分辨的周期性冲击结构。这与试验器单一激励条件下的振动信号相比，体现出整机系统中转子、轴承、机匣及附属结构等多部件耦合作用所引入的显著复杂性和强背景噪声特征。由图 5.19 的频谱可以看出，信号频率成分分布范围较宽，在低频至中频区间内存在多个离散谱峰，反映了整机转动部件转频、倍频以及结构模态的共同影响；同时，在中高频段仍可观察到若干幅值较大的峰值成分，表明局部结构共振对整机振动响应具有明显放大作用。总体而言，整机振动信号表现为频谱成分繁杂、特征频率密集且相互耦合，故障相关信息易被其他结构与工况激励所掩盖，其特征提取难度明显高于试验器工况下的振动信号，需要借助更具针对性的信号分离与特征增强方法进行分析。




(a) EMD 分解 IMF1 分量包络谱



(b) EMD 分解 IMF2 分量包络谱




(c) EMD 分解 IMF3 分量包络谱




(d) EMD 分解 IMF4 分量包络谱

图 5.20 EMD 分解后 IMF 分量包络谱


在图 5.20 中，红色虚线表示外圈故障特征频率根据接触角变化而变化的范围，通过 EMD 分解后，在特征频率变化范围内没有明显的特征频率，因此传统的 EMD 算法由于受到干扰频率的影响导致特征频率被淹没，无法有效地对主轴承故障状态进行监控，对故障特征及逆行识别，因此需要在 EMD 的基础上引进 EWT 算法对 IMF 分量进行二次精细化处理，结果如图 5.21。




(a) EWT 二次精细化分解后 IMF1 包络谱



(b) EWT 二次精细化分解后 IMF2 包络谱



(c) EWT 二次精细化分解后 IMF3 包络谱



(d) EWT 二次精细化分解后 IMF4 包络谱

图 5.21 EWT 算法二次精细化分解后包络谱

在图 5.21 中，可以在 EWT 精细化二次分解后的 IMF2 分量中清晰地看到在故障特征频率范围内存在着故障特征频率 2195Hz。相较于传统的 EMD 算法，将 EMD 算法中模态混叠的部分进行了有效的分离，从而使得干扰频率被分离在不同的子带中，从而降低了干扰频率对故障特征频率的影响。经过计算后的 F_{dB} 值结果如表 5.7 所示。

表 5.7 F_{dB} 值汇总表

IMF1	IMF2	IMF3	IMF4
------	------	------	------


	IMF1	IMF2	IMF3	IMF4
EMD	2.29	9.35	2.83	0.92
EMD-EWT	13.22	29.60	2.87	3.29

通过比较 F_{dB} 值的计算结果，可以明显地看出 EMD-EWT 融合算法对于故障特征的识别明显优于传统的 EMD 算法，结合章节 4.5 建立的阈值，可得 EMD 算法无法对滚动轴承的故障状态进行有效的识别，而 EMD-EWT 融合算法能够有效识别出滚动轴承的故障状态。因此，在滚动轴承早期微弱故障诊断中，EMD-EWT 算法能够更好地识别滚动轴承的故障状态，避免出现有故障不报的情况。


5.3.2.2 整体 F_{dB} 值变化趋势分析

通过对上文中随机挑选的数据进行详细分解后可以看出融合算法的优势，为了进一步验证融合算法的优越性，对全部采集到的数据进行两种不同算法的分解，并比较 F_{dB} 值的变化趋势，结果如图 5.22 所示。

在图 5.22 中，图 5.22 (a) 和图 5.22 (b) 分别给出了基于 EMD 算法和 EMD-EWT 融合算法计算得到的 F_{dB} 特征值随数据序号变化的整体趋势。从整体方面来看，在整个试验过程中，EMD 算法的报警率即 F_{dB} 值超过 15 的比例在 23%，而融合算法的报警率在 70%，大幅减轻了不报的情况，而在试验关注的高转速范围内（转速大于 98.5%）传统的 EMD 算法报警率为 54%，而融合算法的报警率为 90%，如图 5.23 所示，基本实现了对高速状态下滚动轴承的准确诊断。




(a) EMD 算法 F_{dB} 变化趋势




(b) EMD-EWT 算法 F_{dB} 变化趋势

图 5.22 整体 F_{dB} 变化趋势



(a) 98.5%转速比以上数据 EMD 算法 F_{dB} 变化趋势




(b) 98.5%转速比以上数据 EMD-EWT 算法 F_{dB} 变化趋势

图 5.23 98.5%转速比以上数据 F_{dB} 变化趋势


5.4 正常轴承试验器试验验证

在上一节中，对 A602 试验器故障轴承的振动数据进行了两种算法的分析比较，为了进一步对算法的可靠性进行验证，将 A206 故障试验器中的故障轴承替换为正常轴承再次进行振动信号的采集，通过对正常信号的处理结果 F_{dB} 值的趋势比较，验证算法的可靠性。得到的整体 F_{dB} 值变化趋势图如图 5.24 所示。

在图 5.24 中，图 5.24 (a) 和图 5.24 (b) 分别给出了基于 EMD 算法和 EMD-EWT 融合算法计算得到的 F_{dB} 特征值随数据序号变化的整体趋势。从整体来看传统的 EMD 算法的 F_{dB} 特征值起伏波动大，最高值达到了近 100，而融合算法分解得更加稳定，最高不超过 30，并且在 EMD 算法的结果中，报警率为 10%，而融合算法的报警率仅为 1%，在重点关注的高速转动状态下时即转速占比超过 98.5% 时 EMD 算法的报警率为 15%，而融合算法的报警率仅为 2%，说明融合算法很好地克制了误报率，能够将轴承的安全状态良好的分别出来。



(a) EMD 分解整体 F_{dB} 值变化趋势图




(b) EMD-EWT 融合分解整体 F_{dB} 值变化趋势图

图 5.24 整体 F_{dB} 值变化趋势图


5.5 正常主轴轴承整机航空发动机试车试验验证

上一节中对航空发动机主轴轴承试验器的正常轴承数据进行了两种算法的对比分析，可得融合算法对于正常数据处理更加稳定且误报率降低至 1%，极大程度上减少了正常轴承误报的情况，本节将继续对正常轴承数据进行分析，对正常主轴轴承整机航空发动机试车数据进行进一步对比分析。整体 F_{dB} 值变化趋势图如图 5.25 所示。

在图 5.25 中，图 5.25 (a) 和图 5.25 (b) 分别给出了基于 EMD 算法和 EMD-EWT 融合算法计算得到的 F_{dB} 特征值随数据序号变化的整体趋势。从整体来看传统的 EMD 算法的 F_{dB} 特征值起伏波动大，最高值达到了近 100，而融合算法分解得更加稳定，最高不超过 40，且在 EMD 算法的结果中，报警率为 11%，而融合算法的报警率仅为 4%，在重点关注的高速转动状态下时即转速占比超过 98.5% 时 EMD 算法的融合算法都将报警率控制在了 1% 及以下。



(a) EMD 分解整体 F_{dB} 值变化趋势图



(b) EMD-EWT 融合分解整体 F_{dB} 值变化趋势图

图 5.25 整体 F_{dB} 值变化趋势图

5.6 算法计算时间及实时性分析

在航空发动机状态监测与故障诊断系统中，算法不仅需要具有较高的诊断准确率，同时还需要满足一定的计算效率要求。由于航空发动机在实际运行过程中会持续产生大量振动监测数据，若算法计算时间过长，将会影响故障诊断系统的实时性和工程应用价值。因此，有必要对本文提出的 EMD-EWT 融合算法的计算效率进行分析，并评估其在工程应用中的实时性能。

为了对算法计算时间进行客观评估，本文在 MATLAB 环境下对 EMD 算法、EWT 算法以及本文提出的 EMD-EWT 融合算法进行了计算时间统计实验。实验平台配置为 Intel Core i9 处理器，主频 3.2GHz，内存 16GB，操作系统为 Windows11，软件环境为 MATLAB R2023b。选取航空发动机主轴承振动信号作为测试数据，信号采样频率为 128kHz，每段信号长度为 1s。为了降低偶然误差对实验结果的影响，对每种算法重复运行 20 次，并统计其平均计算时间作为算法的运行时间指标。三种算法的平均计算时间统计结果如表 5.8 所示。

表 5.8 计算时间统计结果

算法	平均计算时间
EMD	0.82s
EWT	0.34s
EMD-EWT	1.05s

从表 5.8 可以看出，不同算法在计算效率方面存在一定差异。EMD 算法在信号分解过程中需要进行多次筛选迭代，每一次迭代均需要进行极值点检测和样条插值计算，因此其计算时间相对较长。EWT 算法主要通过傅里叶变换和频谱划分实现信号分解，其核心计算过程为快速傅里叶变换（FFT）以及滤波器构建，因此整体计算效率相对较高。

本文提出的 EMD-EWT 融合算法首先利用 EMD 对原始信号进行预分解，再对包含主要故障信息的 IMF 分量进行 EWT 二次精细化分解。由于融合算法在 EMD 分解基础上增加了 EWT 分解过程，因此其计算时间略高于单一算法。但由于 EWT 分解仅作用于少数关键 IMF 分量，因此整体计算时间增加幅度较小，仍然保持在较低水平。

为了进一步分析算法的工程应用可行性，将算法计算时间与信号采集时间进行对比。在本实验条件下，振动信号采样频率为 128kHz，信号长度为 1s，即每秒采集 128000 个数据点。从实验统计结果可以看出，EMD-EWT 融合算法的平均计算时间明显小于信号采集时间，因此在离线分析以及准实时故障诊断场景下能够满足工程应用需求。

在航空发动机健康监测系统中，振动数据通常采用滑动时间窗口进行分析，窗口长度一般为 1s~5s，数据处理周期通常在数秒至数十秒之间。结合本文实验结果可以看出，EMD-EWT 融合算法在保证故障特征提取能力的同时，仍然具有较好的计算效率，能够满足航空发动机滚

动轴承故障诊断系统的实时性要求。

此外,在实际工程应用中,还可以通过算法优化进一步提升计算效率,例如采用并行计算、GPU 加速或将 MATLAB 算法移植至 C/C++ 实现等方式,从而进一步提高算法运行速度。因此,从计算效率和工程实现角度来看,本文提出的 EMD-EWT 融合算法在航空发动机滚动轴承故障诊断中具有良好的工程应用前景。

5.7 本章小结

本章围绕真实航空发动机整机与试验器主轴承故障特征提取及诊断,对 EMD-EWT 融合算法在复杂工况下的准确性以及适用性进行了验证。通过将航空发动机整机试验与航空发动机试验器试验相结合,分别对其故障与正常的数据进行两种算法的比较分析,全面评估了融合算法在高噪声、强干扰、载荷波动等复杂运行环境下的诊断性能。

首先,在故障主轴承整机试验中,针对高速变转速条件下获取的振动信号,分别采用传统 EMD 方法与 EMD-EWT 融合算法进行分解与对比分析。结果表明,传统 EMD 方法在整机复杂振动环境中易受到背景噪声和模态混叠的影响,难以在理论故障特征频率范围内稳定提取有效特征,导致故障识别能力有限。而在 EMD 分解基础上引入 EWT 算法对 IMF 分量进行二次精细化处理后,融合算法能够显著增强故障特征频率处的能量集中程度,有效抑制无关频率成分的干扰,从而实现主轴承外圈故障特征的准确提取。

其次,在故障主轴承试验器试验验证中,通过对比不同算法下 IMF 分量的包络谱特征及相应的 F_{dB} 指标变化规律,进一步验证了融合算法的稳定性与可靠性。分析结果显示,EMD-EWT 融合算法计算得到的 F_{dB} 指标在故障状态下整体水平显著提高,超过阈值的数据占比明显增加,且变化趋势与转速工况高度一致,能够在时间尺度上持续反映故障特征的演化过程,避免了传统 EMD 方法中故障特征间歇性丢失的问题。

之后,通过正常主轴承整机航空发动机试车试验以及正常主轴承试验器试验,对算法的误报情况进行了验证。结果表明,在正常工况下,融合算法能够将 F_{dB} 指标稳定控制在阈值以下,误报率显著低于传统 EMD 方法,说明该算法在保持较高故障识别灵敏度的同时,具备良好的抗干扰能力和工程实用性。

最后,比较了三种算法的计算时间,结果表明,虽然融合算法的计算时间要略高于单独算法的计算时间,但是仍然维持在较低水平,满足在工程实际中的需求。

综上所述,本章试验结果充分表明,EMD-EWT 融合算法能够有效克服传统 EMD 方法在复杂振动环境下存在的模态混叠和特征弱化问题,在真实航空发动机主轴承早期故障诊断中表现出更高的准确性、稳定性和可靠性,为航空发动机关键滚动轴承的状态监测与健康管

供了一种具有工程应用前景的技术手段。

第六章 总结与展望

6.1 全文工作总结

滚动轴承作为航空发动机转子系统的关键支撑部件，其服役环境呈现高温、高速、强载荷以及强背景噪声等典型特征，一旦发生早期损伤或剥落类故障，极易引发转子系统动力学性能劣化，进而对整机安全性与可靠性造成不利影响。针对航空发动机滚动轴承振动信号“强非平稳、弱故障特征易被淹没、工况波动显著”的工程问题，本文以滚动轴承故障机理与特征频率理论为基础，围绕“信号自适应分解—故障特征增强—定量指标构建—多工况试验验证”的研究主线，提出并验证了一种融合 EMD 与 EWT 的故障特征提取方法（EMD-EWT），并在真实航空发动机主轴承数据条件下开展了工程验证。全文主要工作与结论可概括如下。

（1）构建了滚动轴承故障机理以及特征频率的理论基础，开展典型故障仿真分析

本文首先梳理了滚动轴承的结构组成、典型故障形式及其振动响应机理，推导并给出了外圈、内圈与滚动体故障等典型缺陷对应的特征频率表达形式。在此基础上，结合故障激励的周期冲击特性与实际传递路径影响，开展了外圈、内圈及滚动体故障的仿真信号分析，明确了包络谱在故障特征频率识别中的优势，同时也揭示了在噪声叠加与工况波动条件下，故障特征存在被淹没的风险，为后续算法设计与指标构建提供了理论依据与问题导向。

（2）提出了 EMD-EWT 融合分解思路，强化复杂背景下的弱特征提取能力。

经验模态分解（EMD）具备自适应分解优势，但在实际振动信号处理中易受到端点效应与模态混叠影响，导致 IMF 分量物理意义不清、故障成分分散甚至丢失；经验小波变换（EWT）能够基于频谱分割构造滤波器组实现自适应分解，但其分割边界对信号谱形变化较敏感。针对上述问题，本文将二者优势进行互补融合：先利用 EMD 对复杂振动信号进行自适应模态分解以获得多尺度 IMF 分量，再引入 EWT 对关键 IMF 分量实施二次精细化分解，以增强故障频带能量聚集、抑制无关成分干扰，从而提升故障特征频率在包络谱中的可辨识度。该融合策略在不依赖复杂人工调参的前提下，能够更好适应信号的局部时变特性，为后续定量判别提供更稳定的特征基础。

（3）构建了基于包络谱的无量纲故障指标，并给出了相应的阈值确定方法

为实现不同方法分解效果的客观比较与工程判别，本文在包络谱分析基础上提出了面向故障特征频率的无量纲指标（文中以 F_{dB} 指标体系为核心），将“故障特征频带能量/幅值的突出程度”进行数值化表达，使得算法性能评价由定性识别转化为定量比较。同时，针对工程应用中“误报与漏报权衡”问题，本文结合正常状态统计特性，提出了基于统计分布假设与样本估

计的阈值确定思路：通过对正常样本的均值与方差进行统计，确定判别阈值上限，从而在保证故障敏感性的同时尽量降低虚警概率。该策略为后续在整机复杂工况数据上的可靠诊断提供了可执行的判别规定。

(4) 在公开数据集以及自行搭建的带机匣试验器平台上验证算法的有效性，证明融合算法的优势

为验证 EMD-EWT 融合方法的普适性与稳定性，本文首先选取国际通用的凯斯西储大学滚动轴承数据集开展对比试验，并进一步结合自建滚动轴承试验平台采集数据进行验证。结果表明：相较传统 EMD 分解，融合方法能够在包络谱中更稳定地突出故障特征频率及其倍频成分，有效缓解模态混叠导致的特征分散问题；同时，指标层面表现为故障状态下 F_{dB} 等特征量更容易越过阈值，且随工况变化的趋势更连续，为故障识别提供了更高的鲁棒性与可重复性。

(5) 对真实航空发动机主轴承进行试验验证，证明算法的工程适用性

在第五章中，本文进一步将研究对象扩展至真实航空发动机主轴承故障数据，分别开展了故障主轴承整机试验验证、故障主轴承试验器试验验证以及正常主轴承整机试车对比验证。结果表明：在整机复杂振动环境与转速波动条件下，传统 EMD 方法受到强背景噪声与干扰频率影响，故障特征频率在包络谱中稳定性不足，易出现“特征不显著或间歇性丢失”；而 EMD-EWT 融合方法通过对 IMF 分量的二次精细化分解，能够显著提升故障特征频带的能量集中程度，使得 F_{dB} 指标在故障状态下呈现更高水平与更强的连续性，在高速关键工况区间表现出更高的报警有效性。与此同时，在正常主轴承试车数据上，融合方法能够将特征指标稳定控制在阈值以下，误报水平明显低于对照方法，说明该方法在提升敏感性的同时具备较好的抗干扰能力与工程判别可靠性。

综上所述，本文围绕航空发动机滚动轴承故障特征弱、背景复杂、工况波动显著等难点，提出了 EMD-EWT 融合分解与基于包络谱的定量指标判别框架，并在多工况数据上完成验证，研究结果表明：所提方法能够有效抑制模态混叠与噪声干扰影响，增强故障特征频率的可辨识度，提高故障判别的稳定性与可靠性，为航空发动机主轴承状态监测与早期故障诊断提供了一种具有工程应用潜力的技术路线。

6.2 本文主要创新点

针对航空发动机滚动轴承振动信号强非平稳、强背景噪声以及传递路径复杂等工程特点，本文围绕滚动轴承早期故障特征提取问题开展研究，主要创新点体现在以下几个方面：

(1) 提出了一种面向极低信噪比复杂工程振动信号的 EMD-EWT 分层融合信号处理方法。

针对传统经验模态分解在强噪声条件下易产生端点效应和模态混叠的问题，本文引入经验

小波变换对 EMD 分解得到的关键 IMF 分量进行二次精细化处理,构建了一种“时域自适应分解 + 频域自适应重构”的分层融合框架。该方法充分利用 EMD 在时域局部特征提取方面的优势,以及 EWT 在频域自适应划分和能量聚焦方面的优势,有效抑制了端点效应和模态混叠对故障特征提取的影响。

(2) 构建了一种基于 EMD-EWT 分解结果的滚动轴承故障无量纲特征指标及判定方法。

在融合分解的基础上,结合包络分析、自相关分析及归一化处理,提出了一种将故障特征频率信息进行量化表征的无量纲特征指标,并基于统计模型建立了相应的故障判定阈值。该指标能够在不同转速和工况条件下保持较好的稳定性,为滚动轴承早期微弱故障的定量识别提供了有效手段。

(3) 在多层级实验平台上系统验证了所提方法在真实航空发动机环境下的有效性。

本文不仅利用仿真信号和国际公开数据集对所提方法进行验证,还进一步在带机匣的转子-滚动轴承试验器以及真实航空发动机主轴承整机试验数据上进行了工程验证。实验结果表明,在强噪声、复杂传递路径和多重结构耦合条件下,EMD-EWT 融合方法相比传统 EMD 方法能够更稳定、可靠地提取滚动轴承早期故障特征,具有较好的工程应用价值。

6.3 未来工作展望

本文对 EMD-EWT 融合算法展开了大量的研究与试验验证,但是因为研究时间以及试验条件等因素的影响,仍然存在很多值得改进的地方,以下问题需要进一步进行探讨。

(1) 开展在线实时性研究,推动算法工程落地

航空发动机健康监测管理更关注在线实时诊断能力。后续可在算法流程上开展轻量化改进,研究分段处理、增量更新与快速实现机制,降低计算开销;同时结合实际采集系统的采样频率、通道数与边缘计算条件,完成从离线分析到在线监测的算法迁移与工程实现。

(2) 融合数据的驱动方法,实现从故障监测到寿命预测的延伸

本文主要聚焦早期故障检测与识别。面向 PHM (预测与健康管理) 需求,未来可将本文构建的无量纲指标与深度学习、概率图模型或贝叶斯推断等方法结合,建立“特征演化—健康指数—剩余寿命预测”的一体化模型;同时研究指标在不同工况域间的迁移与自适应校准,提升模型跨平台、跨任务的可用性。

参考文献

- [1] 孔璐. 我国军用航空发动机发展路径及启示[J]. 中国设备工程, 2024, (19): 255-257.
- [2] 赵孝礼. 基于图嵌入自编码的滚动轴承故障诊断方法研究[D]. 东南大学, 2021.
- [3] 杨静. 旋转机械早期故障诊断关键技术研究[D]. 西安理工大学, 2020.
- [4] 肖婷, 汤宝平, 秦毅, 等. 基于流形学习和最小二乘支持向量机的滚动轴承退化趋势预测[J]. 振动与冲击, 2015, 34(09): 149-153.
- [5] 张沛朋, 郭飞燕. 基于 PCA-SVM 的滚动轴承故障诊断研究[J]. 组合机床与自动化加工技术, 2015, (11): 88-90. DOI:10.13462/j.cnki.mmtamt.2015.11.025.
- [6] Wang B, Qiu W, Hu X, et al. A rolling bearing fault diagnosis technique based on recurrence quantification analysis and Bayesian optimization SVM [J]. Applied Soft Computing, 2024, 156: 111506.
- [7] Yong-hui, CHEN et al. "Research of Rolling Bearings Fault Diagnosis", Noise and Vibration Control (2011): 137-140+145.
- [8] Jinde, ZHENG, and CHENG Junsheng. "Improved Hilbert-Huang Transform and Its Applications to Rolling Bearing Fault Diagnosis", Jixie Gongcheng Xuebao/Chinese Journal of Mechanical Engineering 51.1 (2015): 138-138.
- [9] Yang, Yu et al. "A Fault Diagnosis Approach for Roller Bearing Based on IMF Envelope Spectrum and SVM", Measurement 40.9-10 (2006): 943-950.
- [10] Yi-xiong, ZHANG et al. "Rolling Element Bearing Fault Diagnosis Using Wavelet Packets", Coal Mine Machinery (2009): 246-248.
- [11] Guo-xin, ZHANG, and LIU Zuo-shi. "The Rolling Bearing Fault Diagnosis Based on Wavelet Packet Decomposition", Journal of Jiangxi University of Science and Technology (2007): 20-23.
- [12] Xue-cun, YANG. "Rolling Bearing Fault Diagnosis Research Based on Wavelet Spectrum Analysis", Coal Mine Machinery (2013)
- [13] Changliang, LIU et al. "Rolling Bearing Fault Diagnosis Based on Variational Mode Decomposition and Fuzzy C Means Clustering", Proceedings of the CSEE 35.13 (2015): 3358-3365.
- [14] Chen, JU et al. "Rolling Bearing Fault Diagnosis Based on Wavelet Packet Decomposition and PSO-BPN", Industry and Mine Automation (2020)
- [15] Wu, Zhaohua, and Norden E. Huang. "Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method", Advances in Data Science and Adaptive Analysis 1.1 (2009): 1-41.

- [16] Lei, Yaguo et al. "A Review on Empirical Mode Decomposition in Fault Diagnosis of Rotating Machinery", *Mechanical systems and signal processing* 35.1 (2013): 108-126.
- [17] Wu, ZH, and NE Huang. "A Study of the Characteristics of White Noise Using the Empirical Mode Decomposition Method", *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 460.2046 (2004): 1597-1611.
- [18] ZHOU H, JIA M. Analysis of Rolling Bearing Fault Diagnosis Based on EMD and Kurtosis Hilbert Envelope Demodulation [Z](2014 - 01 - 01).
- [19] Wu T. Fault diagnosis method of rolling bearing based on EMD-Hilbert envelope spectrum and BPNN [J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 632(5): 052084.
- [20] MENGZong, JIYan, YANXiao-li. Rolling Bearing Fault Diagnosis Based on Differential-based Empirical Mode Decomposition and Fuzzy Entropy [Z](2016 - 01 - 01).
- [21] Lv Y, Yuan R, Song G. Multivariate empirical mode decomposition and its application to fault diagnosis of rolling Bearing [J]. *Mechanical Systems and Signal Processing*, 2016, 81: 219 - 234.
- [22] Liu Q. Inchoate fault diagnosis of rolling bearings based on local tangent space alignment algorithm [Z](2012 - 01 - 01).
- [23] Huang M, Huang T, Zhao Y, et al. Fault diagnosis of rolling bearing based on empirical mode decomposition and convolutional recurrent neural network [J]. *IOP Conference Series: Materials Science and Engineering*, 2021, 1043(4): 042015.
- [24] Yeh, Jia-Rong et al. "Complementary Ensemble Empirical Mode Decomposition: a Novel Noise Enhanced Data Analysis Method.", *Advances in Data Science and Adaptive Analysis* 2.2 (2010): 135-156.
- [25] Rehman, N., and D. P. Mandic. "Multivariate Empirical Mode Decomposition", *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 466.2117 (2010): 1291-1302.
- [26] Hu et al. "Rolling Bearing Fault Feature Extraction Method Based on Ensemble Empirical Mode Decomposition and Kurtosis Criterion", *Proceedings of the CSEE* (2012)
- [27] Li, SI et al. "Improved method for empirical mode decomposition", *Computer Engineering and Applications* 38.14 (2014): 1199-1202.
- [28] Zheng X. Localized fault diagnosis of rolling bearing using differential improved EMD [Z](2014 - 01 - 01)..
- [29] Meng S, Kang J, Chi K, et al. Fault diagnosis of rolling bearing based on improved EMD algorithm [J]. *IOP Conference Series: Materials Science and Engineering*, 2020, 892(1): 012069.
- [30] Xu Y, Deng Y, Zhao J, et al. A Novel Rolling Bearing Fault Diagnosis Method Based on

- Empirical Wavelet Transform and Spectral Trend [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(6): 2891 - 2904.
- [31] Zheng J, Huang S, Pan H, et al. An Improved Empirical Wavelet Transform and Refined Composite Multiscale Dispersion Entropy-Based Fault Diagnosis Method for Rolling Bearing [J]. IEEE Access, 2020, 8: 168732 - 168742.
- [32] Ou Y, He S, Hu C, et al. Research on Rolling Bearing Fault Diagnosis Using Improved Majorization-Minimization-Based Total Variation and Empirical Wavelet Transform [J]. Shock and Vibration, 2020, 2020: 1 - 11.
- [33] 盛嘉玖,陈果,康玉祥,等.一种用于滚动轴承故障诊断的改进 EWT 方法[J].航空动力学报,2024,39(09):371-383.DOI:10.13224/j.cnki.jasp.20220677.
- [34] Li J, Wang H, Wang X, et al. Rolling bearing fault diagnosis based on improved adaptive parameterless empirical wavelet transform and sparse Denoising [J]. Measurement, 2020, 152: 107392.
- [35] Zhinong, Li et al. "Mechanical fault diagnosis method based on empirical wavelet transform",Chinese Journal of Scientific Instrument (2014): 2423-2432.
- [36] Jinde, Zheng et al. "Adaptive Parameterless Empirical Wavelet Transform(EWT)and Its Applications to Fault Diagnosis of Rotor System",China Mechanical Engineering 27.16 (2016): 2218-2224.
- [37] Jin-de, ZHENG et al. "Enhanced Empirical Wavelet Transform Based Time-Frequency Analysis and Its Application to Rolling Bearing Fault Diagnosis",Acta Electronica Sinica 46.2 (2018): 358-364.
- [38] Sadiq, Muhammad Tariq et al. "Motor Imagery EEG Signals Decoding by Multivariate Empirical Wavelet Transform-Based Framework for Robust Brain - Computer Interfaces",IEEE Access 7 (2019): 171431-171451.
- [39] Kedadouche M, Liu Z, Vu V H. A new approach based on OMA-empirical wavelet transforms for bearing fault diagnosis[J]. Measurement, 2016, 90: 292-308.
- [40] Zheng J, Pan H, Yang S, et al. Adaptive parameterless empirical wavelet transform based time-frequency analysis method and its application to rotor rubbing fault diagnosis[J]. Signal Processing, 2017, 130: 305-314.
- [41] Xu Y, Zhang K, Ma C, et al. An improved empirical wavelet transform and its applications in rolling bearing fault diagnosis[J]. Applied sciences, 2018, 8(12): 2352.
- [42] Hu Y, Li F, Li H, et al. An enhanced empirical wavelet transform for noisy and non-stationary

signal processing[J]. Digital signal processing, 2017, 60: 220-229.

[43] Hu Y, Tu X, Li F, et al. An adaptive and tachless order analysis method based on enhanced empirical wavelet transform for fault detection of bearings with varying speeds[J]. Journal of Sound and Vibration, 2017, 409: 241-255.

[44] 高中强, 郑近德, 潘海洋, 等. 基于自适应去噪经验小波变换的滚动轴承故障诊断方法[J/OL]. 轴承, 1-8[2025-05-14].

[45] Rilling, Gabriel et al. "On Empirical Mode Decomposition and Its Algorithms", openalex (2003)

[46] Rilling, Gabriel et al. "Bivariate Empirical Mode Decomposition", IEEE signal processing letters 14.12 (2007): 936-939.

[47] Bao-jie, XU et al. "A Study on the Method of Restraining the Ending Effect of Empirical Mode Decomposition (EMD)", Transactions of Beijing Institute of Technology 26.3 (2006): 196-200.

[48] Yan-ping, ZHU et al. "Enhanced Empirical Wavelet Transform with Application to Rolling Bearings Fault Diagnosis", Noise and Vibration Control 38.1 (2018): 199-203.

[49] 陈威. 基于卷积网络和迁移学习的轴承故障诊断研究[D]. 北京化工大学, 2024.

[50] Saidi L, Ali J B, Fnaiech F. Bi-spectrum based-EMD applied to the non-stationary vibration signals for bearing faults diagnosis[J]. ISA transactions, 2014, 53(5): 1650-1660.

[51] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences, 1998, 454(1971): 903-995.

[52] Ali J B, Fnaiech N, Saidi L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals[J]. Applied Acoustics, 2015, 89: 16-27.

[53] Gilles J. Empirical wavelet transform[J]. IEEE transactions on signal processing, 2013, 61(16): 3999-4010.

[54] Singh O, Sunkaria R K. ECG signal denoising via empirical wavelet transform[J]. Australasian physical & engineering sciences in medicine, 2017, 40: 219-229.

[55] 王友仁, 陈伟, 孙灿飞, 等. 基于能量聚集度经验小波变换的齿轮箱早期微弱故障诊断[J]. 中国机械工程, 2017, 28(12): 1484-1490.

[56] 于德介, 程军圣, 杨宇. 机械故障诊断的 Hilbert-Huang 变换方法. 北京: 科学出版社, 2007.

[57] 成心怡, 张琪, 郑建飞, 等. 考虑非平稳特征的滚动轴承健康指标构建方法[J/OL]. 哈尔滨工程大学学报, 1-10[2025-12-03]. <https://link.cnki.net/urlid/23.1390.U.20251125.1015.005>.

[58] 陈果.航空器检测与诊断技术导论[M]. 北京航空航天大学出版社, 2022..

[59] 林桐,陈果,滕春禹,等.基于机匣振动信号的滚动轴承故障协同诊断技术[J].航空动力学报,2018,33(10):2376-2384.

致谢

时光荏苒，转瞬间硕士研究生阶段的学习与科研生活即将结束。回顾过去的几年，既有挑战与困惑，也有收获与成长。能够顺利完成论文的撰写，我深知这不仅是个人努力的结果，更离不开许多师长、同学、家人和朋友的关心、指导与支持。在此，我谨向所有给予我帮助和鼓励的人表示最诚挚的感谢。

首先，我要衷心感谢我的导师 陈果 教授，感谢您在科研工作和学术成长过程中给予的悉心指导和耐心教诲。在课题选择、研究思路、实验设计以及论文撰写等各个环节，您都给予了细致入微的指导，让我在科研方法、学术规范和问题分析能力上都有了显著提升。导师严谨治学的态度、宽广的学术视野以及对科研的热情深深感染了我，为我树立了良好的学术榜样。每一次讨论和指导都令我受益匪浅，也让我在科研道路上更加坚定信心。

同时，我要感谢课题组的各位老师和同学们。在实验研究、数据分析及论文修改过程中，大家给予了我热情的帮助与建议。感谢盛嘉玖师兄、刘耀宾师兄、沈响响师兄在实验操作和数据处理上的耐心指导，感谢张瑞同学在科研思路讨论中的启发与交流，感谢整个团队在日常学习和工作中提供的支持与协作氛围。与你们的交流不仅让我学到了专业技能，更让我体会到团队合作的重要性和科研的乐趣。

此外，我要特别感谢学校及相关科研单位提供的良好科研平台与资源支持。在项目立项、实验设备使用及资料获取过程中，单位提供的帮助为我的研究提供了坚实保障。同时，也感谢基金项目、实验室经费及相关支持，使我的科研工作能够顺利开展。

在此，我还要感谢我的家人。感谢父母无条件的支持、理解与鼓励，你们的关心与信任始终是我前进的动力源泉。在我遇到困难和挫折时，家人的鼓励让我重新振作，坚定信念。感谢亲友们在生活和心理上的关怀，使我能够专心投入科研和学业。

最后，感谢所有在我研究生阶段给予帮助和启发的人。正是有了你们的关心、指导、支持与陪伴，我才能顺利完成硕士阶段的学习和论文工作。回首过去，我心怀感激；展望未来，我将带着这份感恩与责任，继续努力，追求更高的学术目标和人生价值。

谨以此致谢，向所有给予我关怀和支持的人表示诚挚谢意。

在学期间的研究成果及发表的学术论文

攻读硕士学位期间发表（录用）论文情况

陈果,马一杰, 吴英祥, 王浩, 尉询楷, 航空发动机主轴承剥落故障演化过程的整机振动响应分析[J]. 轴承. (已录用)

盛嘉玖, 陈果, 贺志远, 马一杰, 王浩, 尉询楷, 一种用于滚动轴承故障诊断的 VMD 参数优化方法[J/OL]. 振动工程学报, (录用在线发表)

攻读硕士学位期间参加科研项目情况

国家科技重大专项子课题：复杂服役环境下主轴承典型故障宏观动力学研究，2020-2024

国家自然科学基金项目：基于深度异常检测和元学习的航空发动机主轴承早期故障预警与演化诊断，2023-2026

中国航发燃机有限公司项目：燃机智能运维典型结构损伤模拟试验与故障监测技术，2024-2026

中国航发沈阳发动机研究所项目：发动机转子系统的整机耦合动力学模型技术研究，2025-2026