

编号 202111028



南京航空航天大学

本科毕业设计（论文）

题目 一种基于 EMD-EWT 的滚动轴承 故障特征提取新方法

学生姓名	张泽宇
学 号	202111028
学 院	通用航空与飞行学院
专 业	交通运输（民航维修工程）
班 级	2021201 班
指导教师	陈果 教授

二〇二五年六月

南京航空航天大学

本科毕业设计（论文）诚信承诺书

本人郑重声明：所呈交的毕业设计（论文）是本人在导师的指导下独立进行研究所取得的成果。尽我所知，除了文中特别加以标注和致谢的内容外，本设计（论文）不包含任何其他个人或集体已经发表或撰写的成果作品。对本设计（论文）所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。

作者签名：

张泽宇

日期：2025 年 5 月 18 日

南京航空航天大学

毕业设计（论文）使用授权书

本人完全了解南京航空航天大学有关收集、保留和使用本人所送交的毕业设计（论文）的规定，即：本科生在校攻读学位期间毕业设计（论文）工作的知识产权单位属南京航空航天大学。学校有权保留并向国家有关部门或机构送交毕业设计（论文）的复印件和电子版，允许论文被查阅和借阅，可以公布论文的全部或部分内容，可以采用影印、缩印或扫描等复制手段保存、汇编论文。保密的论文在解密后适用本声明。

论文涉密情况：

☒ 不保密

☐ 保密，保密期（起讫日期： ）

作者签名：

张泽宇

导师签名：

江

日期：2025 年 5 月 18 日

日期：2025 年 5 月 18 日

摘 要

现代航空发动机是飞行器动力系统里的核心单元，其可靠性会直接影响到飞行安全与经济运行，而轴承更是发动机的核心零部件，其运行的稳定性直接关系到飞行安全与运营效益。

传统的信号处理方法在进行故障诊断时，早期的微弱故障信号很容易被噪声淹没，难以检测出轴承故障。针对上述缺陷，本文提出了一种融合经验模态分解（Empirical Mode Decomposition, EMD）与经验小波变换（Empirical Wavelet Transform, EWT）的滚动轴承故障特征提取新方法。具体研究内容如下：

（1）运用 EMD 对原始振动信号进行自适应分解，获取本征模态函数（Intrinsic Mode Functions, IMF），以此来突出故障冲击成分；针对 EMD 存在的模态混叠问题，引入 EWT 对 IMF 分量进行二次分解，提取了故障特征的低频和低频成分。

（2）为进一步提升诊断的可靠性，本文结合包络谱分析与自相关归一化算法，构建了一个故障敏感指标参数用于诊断发动机轴承故障。

（3）使用该方法对航空发动机整机数据进行试验，成功提取出故障特征频率成分。结果表明，EMD-EWT 方法具有显著降低噪声影响的作用。

关键词：滚动轴承，经验模态分解（EMD），经验小波变换（EWT），包络分析，故障特征提取

ABSTRACT

As the core unit of an aircraft's power system, the reliability of modern aero-engines directly impacts flight safety and operational efficiency. Bearings, as critical components of engines, play a decisive role in operational stability, which is closely tied to flight safety and economic performance.

Traditional signal processing methods for fault diagnosis often struggle to detect early-stage weak fault signals in bearings due to their susceptibility to noise interference. To address these limitations, this paper proposes a fault feature extraction method for rolling bearings that integrates Empirical Mode Decomposition (EMD) and Empirical Wavelet Transform (EWT). The specific research contributions are as follows:

(1) EMD is applied to adaptively decompose raw vibration signals into Intrinsic Mode Functions (IMFs) to highlight fault-induced impulse components. To mitigate the mode mixing issue inherent in EMD, EWT is further introduced to perform spectral segmentation and adaptive wavelet filtering on key IMFs, thereby precisely extracting fault-related frequency bands.

(2) To enhance diagnostic reliability, a fault-sensitive indicator is constructed by integrating envelope spectrum analysis and an autocorrelation normalization algorithm for identifying bearing faults in aero-engines.

(3) Experimental validation using full-engine data from an aero-engine successfully demonstrates the extraction of fault characteristic frequency components. The results indicate that the EMD-EWT method significantly reduces noise interference and effectively enhances the accuracy of fault feature extraction.

KEY WORDS: Rolling bearings, Empirical Mode Decomposition(EMD), Empirical Wavelet Transform (EWT), Envelope analysis, Fault Feature Extraction

目录

第一章 绪论.....	1
1.1 滚动轴承故障诊断研究背景和意义	1
1.2 国内外研究现状	2
1.2.1 概述	2
1.2.2 基于经验模态分解的研究现状	3
1.2.3 基于经验小波变换的研究现状	3
1.3 问题的提出及本文研究内容	4
第二章 基于 EMD—EWT 的滚动轴承故障信号分析新方法	6
2.1 方法原理及总体流程	6
2.2 关键技术	7
2.2.1 EMD 理论及分解过程	7
2.2.2 EWT 理论及分解过程	10
2.2.3 基于 EMD-EWT 的算法改进原理	14
2.3 主轴承故障指标构建	16
2.3.1 数据平稳性检验	16
2.3.2 频带分析	16
2.3.3 故障频率特征提取	16
2.3.4 故障频率特征的判定标准	18
2.4 本章小结	18
第三章 基于已有整机试车数据的试验验证	20
3.1 试验背景	20
3.2 轴承参数及数据采集	20
3.3 试验验证	21
3.3.1 EMD 处理	21
3.3.2 EWT 处理	25
3.3.3 EMD-EWT 处理	27
3.4 试验结果对比	29
3.4.1 第一组数据	29
3.4.2 第二组数据	30
3.4.3 第三组数据	31
3.5 EMD-EWT 诊断结果	31
3.6 本章小结	32
第四章 总结与展望	33
4.1 研究总结	33
4.2 研究展望	33
参考文献	35
致谢	37

第一章 绪论

1.1 滚动轴承故障诊断研究背景和意义

伴随着我国制造强国战略目标的迈进，制造业作为国民经济的关键支柱行业，正加速朝着高、精、尖方向发展。在这一进程中，能源、交通、冶金等众多工业领域的关键设备长期处于复杂且恶劣的工况环境下运行，如果核心设备的突然失效将引发多重连锁反应，首先会造成生产流程中断，致使企业面临巨额的经济损失，更为严重的是有可能诱发安全事故，危及工作人员生命健康，对社会造成重大影响。因此，提升关键设备的运行可靠性已成为保障现代工业安全生产的重要课题。通过实施科学的状态监测与维护策略，及时识别设备早期异常特征，制定预防性维修计划，对保障设备平稳运行具有显著的实际价值。




图 1.1 轴承失效图

其中轴承失效往往是设备故障的主要原因，滚动轴承的失效模式严格按照其最初失效的原因进行分类, GB/T24611—2009/ISO 15243: 2004《滚动轴承损伤和失效术语、特征及原因》将滚动轴承的失效模式分为 6 个大类, 即滚动接触疲劳、断裂和开裂、磨损、腐蚀、塑性变形、电蚀，如图 1. 1。轴承一旦失效往往带来发动机停车、电机停止供电、液压系统故障等严重后果。值得关注的是，在各类设备故障案例中，轴承类部件故障占据显著比例。据统计资料显示，旋转机械故障案例中约 30%源于轴承失效，电机故障中该比例超过 80%，而齿轮箱故障也有近 20%由轴承异常引发^[1, 2, 3]。现代航空发动机作为飞行器动力系统的核

心单元，轴承是其支撑旋转部件的关键零件，其可靠性对飞行安全与经济运行有着直接影响。在发动机复杂的机械结构中，轴承系统中支撑转子系统的轴承，承担着传递动力、减少摩擦以及承受高动态载荷的关键作用。由此可见，滚动轴承在航空发动机中占据着至关重要的地位，发展轴承故障诊断技术对提升设备可靠性具有重要作用。

在轴承故障诊断领域，滚动轴承的异常状态识别已成为关键研究方向。随着智能诊断技术的发展，基于振动信号分析的故障辨识方法逐渐成为研究热点，其核心价值在于通过特征频率检测实现故障的早期预警与精确定位，这样就可以提前准备所需备件，并有针对性地进行维护，能够减少停工时间和很多维护工作量，从而降低生产损失。

因此本研究以滚动轴承为研究对象，针对航空动力系统旋转支承部件的健康监测需求，提出一种新的轴承故障特征提取方法，为航空发动机滚动轴承故障诊断提供高效解决方案。

1.2 国内外研究现状

1.2.1 概述

滚动轴承故障诊断技术刚开始发展的时候主要关注传统信号分析方法，这其中包括时域分析、频域分析以及时频域分析这三大体系，它的关键难题在于怎样对不同故障类型的信号进行有效的提高识别，也就是依靠放大不同故障模式之间的表征差异参数，实现故障类型的精确辨识，它的本质是构建高鲁棒性特征表征体系，也就是对信号所呈现出的特征信息进行提取、分析以及处理。

在机械故障诊断技术不断发展的过程中，时域特征参数作为早期故障辨识的核心依据起到了关键作用，很多国内外的研究人员依据信号在时域上的分布特征来进行故障诊断，Gustafsson O 等人^[4]于 1962 年首先突破了传统定性分析框架，开创性地建立了振动峰值与轴承损伤程度的量化关系模型，借助峰值因子实现了轴承故障的定量化检测。

频域分析的核心是利用正交变换算法对时域信号进行频谱分解，实现信号能量在频带维度上的精确映射，凭借构建正余弦基函数与原始信号的投影关系，解析各频率成分的幅值分布特性，揭示隐藏在时域波形中的周期性故障特征。1998 年，Wang Y F 等人^[5]对信号频谱运用包络分析技术，凭借构造信号包络完成了故障的精确检测。

时频分析法是建立在信号平稳性与线性时不变假设基础之上的，其本质属于线性系统理论框架下的稳态处理方法，然而滚动轴承故障引发的振动信号有非平稳特性，具体表现为冲击响应序列的非线性调制与瞬态能量突变，这种动态时变特性使得单一维度的时域或频域解析难以全面分析其故障特征演化规律。而时频分析法依靠构建时频域能量密度函数，

突破了传统方法的维度限制，实现了信号瞬态特征在时间-频率二维平面上的精确定位。该方法的核心在于成功建立非稳态信号的时频联合表征模型，这样就能更精准的揭示出时间维度上信号的演变以及频域中波动的动态特征。经典的时频域分析法有以下几个：短时 Fourier 变换、小波变换、Wigner-Ville 分布、广义 S 变换等^[6]。

1.2.2 基于经验模态分解的研究现状

1998 年, Huang 等人^[7]提出了一种基于经验模态分解 (Empirical Mode Decomposition, EMD) 的方法, 该方法自适应的实现了非平稳信号的平稳化处理, 能够将源信号分解成处于不同频段的调制信号, 可有效反应原始信号的初始属性。相比于传统的故障诊断方法, EMD 由于表现效果较好, 在轴承故障诊断领域里有着非同一般的影响力, 被广泛使用。

但 EMD 分解存在模态交叠和边界失真等现象。针对上述问题, 刘佳昕等人^[8]针对模态混淆现象, 引入人为添加的高斯白噪声, 对其在降噪方面的效果进行了研究。张琛^[9]等针对模态混叠现象提出了改进包络拟合算法, 表现出了较好的结果。Guo T 等人^[10]提出将粒子群优化算法 (PSO) 与 EMD 的交叉融合, 有效克服模态混叠效应, 再通过包络分析完成故障特征的精准提取。之后童靳于等人^[11]引入不同的权重和选择最优模态函数来提高分解能力和分解精度, 解决了 CEEMDAN 方法中的噪声残留问题。李翠省等人^[12]通过集合 EMD 与相关峭度准则结合, 提出一个新的故障诊断方法, 显著提升了故障特征提取能力。2024 年, 高云峰等人^[13]将快速独立分类分析 (FastICA) 与经验模态分解 (EMD) 相结合, 其原理主要通过相关性分析搭建噪声信道, 利用 FastICA 将噪声与原信号分离, 降低干扰, 实现故障诊断, 建立了一种显著降低噪声干扰的方法。

1.2.3 基于经验小波变换的研究现状

经验模态分解 (EMD) 凭借其良好的自适应信号分解能力, 在非平稳、非线性振动信号解析领域展现出独特优势。然而, 该算法存在一些缺陷, 例如缺乏完备的理论支撑、易产生模态混叠现象、迭代筛分过程的计算复杂度高。在此背景下, 信号处理领域涌现了大量的创新和改进。其中, Gilles^[14]提出的经验小波变换 (Empirical Wavelet Transform, EWT) 受到广泛关注。EWT 作为一种强大的信号分析方法, 它的核心思想是对信号自适应的频谱区间划分, 这一点与经典的 Fourier 变换有着本质的区别。通过这种方式, EWT 可以有效的去除噪声和非平稳成分, 从而清晰的展示信号的动态特征。在构建小波滤波器时, 要重视频谱的划分, 之后通过对其滤波得到具有实际的物理意义的分量, 这些分量往往包含了信号的主要特征信息。基于以上特点, EWT 因其独特的优势获得了众多专家与学者的青睐, 基于 EWT 的改进算法层出不穷。

Kedadouche M 等人^[15]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^[16]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^[17]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 等人^[18]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^[19]，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^[20]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

为了更有效的进行健康状态监测，更精准的进行故障诊断，本研究提出了一种融合自适应信号分解与频谱重组技术的新型故障特征提取方法，即构建经验模态分解与经验小波变换融合的诊断模型。EMD 的自适应极值驱动包络迭代实现了信号平稳化处理，相比于传统的故障诊断方法，EMD 在消除原始信号的背景噪声以及自适应性方面效果较好，但也存在许多缺点。针对其模态交叠、边界失真、伪分量等问题，学者们提出了经验小波变换，EWT 通过傅里叶谱分割技术，构建可调节小波滤波器组实现频谱成分的精确提取，规避了模态混淆与边界效应。但工程实践中发现，该方法的频带划分机制易受高频噪声污染，导致特征信息提取完整性降低。

本文主要的目的是研究滚动轴承故障特征提取新方法。研究路线分为理论创新与实验验证两大模块：首先系统性的分析 EMD、EWT 的理论知识，着重探讨 EMD 算法的自适应特性，以及详细论述 EWT 的频谱分割原理与滤波器构建机制。通过对比 EMD 与 EWT 的优势与不足，提出一种新型的改进的信号分解方法，即 EMD-EWT 融合的双模态协同处理，再对分解后的信号做包络分析，经过自相关降噪处理后，使用我们定义的轴承故障指标 FdB 值进行计算，最终得到 FdB 值最大的频带，观察其外圈故障特征。

最后对提出的新方法进行了试验验证，通过对真实发动机数据进行双模态联合分解，成功提取出了故障特征频率成分，并使用我们构建的故障指标判定机制对其诊断。

本研究的架构设计如下：

第一章 研究背景与理论框架，系统阐述了航空动力系统健康监测的研究价值，综述国内外轴承故障诊断技术发展历程，重点概述了 EMD 和 EWT 方法的发展，对比分析两类方法在非平稳信号处理中的优势与局限；

第二章 介绍新方法的原理和总体框架。首先论述了 EMD 和 EWT 的基本原理，详述 EMD 的自适应分解机制和 IMF 分量的约束条件，以及 EWT 频带的划分准则和小波滤波器构建流程。针对 EMD 和 EWT 的优缺点提出新型 EMD-EWT 故障诊断方法，完整叙述了融合后新方法的分解流程，并介绍其特点，之后展示了定义的轴承故障指标 FdB 值计算过程；

第三章 分别使用三种方法对真实发动机数据分解，观察频率特征。进行试验验证后，对比三种方法的试验结果，最终得出结论；

第四章 总结全文，对今后的研究做出总结和展望。

第二章 基于 EMD—EWT 的滚动轴承故障信号分析新方法

2.1 方法原理及总体流程

在信号处理这个领域当中，传统的方法一般都是依靠预先设定好的基函数来对信号实施分解操作，然而当面对一些并非平稳的信号时，这些传统方法就暴露出了局限性，很难有效地去表征信号的瞬态时频特性。为突破这一技术瓶颈，Huang 研究团队于 1998 年提出具有里程碑意义的自适应信号解析技术——经验模态分解（Empirical Mode Decomposition, EMD），它的创新之处在于完全摆脱了预设基函数的约束框架，和传统的时频分析手段相比，传统时频分析手段需要人工去选择小波基，其分解效果会受到基函数类型以及参数设置的影响比较大，而 EMD 作为典型的数据驱动型方法，是借助构建动态筛选机制将复杂信号自主地分解为若干个本征模态分量（Intrinsic Mode Functions, IMFs）。这一突破性的进展成功地解决了传统方法在非稳态信号处理方面的适应性缺陷，它的核心优势体现在算法借助极值点驱动的包络迭代过程来实现信号的自分解，不需要任何先验参数设定，分解过程完全是由信号自身的特性来主导的，这样的分解特性让它在旋转机械振动分析、生物医学信号处理等领域呈现出独特的价值，在处理强非线性和有突变特征的工程信号时，比传统频谱分析方法有更优的时频分辨率。

经验模态分解在非线性振动信号分析领域表现出了良好效果，但也有缺点，会出现过度分解、计算效率不高等问题。针对这些缺陷，Gilles 于 2013 年提出了经验小波变换，该技术依靠融合小波多分辨率分析与 EMD 数据驱动特性的双重优势，构建了自适应小波滤波器组架构，把信号分解为多个明确有物理意义的模态分量（AM-FM 分量），适用于非平稳、非线性信号处理，尤其在噪声干扰下表现出色。不过 EWT 也有缺点，尽管 EWT 的端点效应弱于 EMD，但其频域处理仍可能导致边界误差，并且 EWT 虽然使用高频模态隔离了噪声，但是在低信噪比（SNR）场景下仍存在局限。

针对上面存在的问题，本研究创新性的提出了一种基于 EMD-EWT 融合的轴承故障特征提取新方法。利用 EMD 的自适应性和 EWT 的精确频带划分，来克服各自的缺点。主要核心机理是，先用 EMD 分解，筛选迭代后得到多个 IMF，然后对每个 IMF 进行 EWT 处理，进一步提取更精细的特征。

总体流程图如图 2.1:




图 2.1 EMD-EWT 算法框架图

2.2 关键技术

2.2.1 EMD 理论及分解过程

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残余项，即

$$x(t) = \sum_{i=0}^n c_i(t) + r_n(t) \quad (1.1)$$

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^[21]：

- (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震动范围。该算法的实施过程包含以下三个阶段^[22]:

(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

$$h_1(t) = x(t) - m(t) \quad (1.2)$$

(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

$$c_1(t) = h_1(t) \quad (1.3)$$

筛选过程的终止条件由下式决定^[7]:

$$SD = \frac{1}{L} \sum_{t=1}^L \frac{[h_{i(k-1)}(t) - h_{ik}(t)]^2}{h_{ik}^2(t)} \leq \theta \quad (1.4)$$

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 的值一般预设为 $0.2 \sim 0.3$ ^[23], 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。

(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

$$r_1(t) = x(t) - c_1(t) \quad (1.5)$$

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 的条件分量:

$$\begin{cases} r_2(t) = r_1(t) - c_2(t) \\ r_3(t) = r_2(t) - c_3(t) \\ \vdots \\ r_n(t) = r_{n-1}(t) - c_n(t) \end{cases} \quad (1.6)$$

(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(1.1)的形式。

EMD 的分解过程整体示意图如图 2.2:




图 2.2 EMD 流程图

EMD 具有如下性质：

(1) 自适应性

EMD 无需预设基函数或先验参数，完全依赖信号自身的极值点分布构造上下包络，由信号本身的特征尺度决定，这种自适应特性使其能够灵活处理不同形态的信号（如突变、趋势项混杂等），尤其适用于未知特征的非线性系统分析。

各 IMF 分量均表现出具有自适应的特征。首阶分量往往承载着信号的最高频成分，对应瞬态冲击，而末阶分量反应了信号的趋势，频率会趋近于零，中间分量按照梯度降序排列。

(2) 处理非平稳性与非线性

传统方法在分析非平稳信号时可能由于全局平均效应丢失细节信息，而 EMD 通过局部包络均值逐级分离信号的高频细节与低频趋势，有效分解了非平稳信号中的瞬态成分与缓变趋势。

(3) 分解完备性

各个 IMF 分量可以完全重构源信号。

(4) 正交性

为了方便验证 EMD 的该性质，我们先令 $r_n(t) = c_{n+1}(t)$ ，然后对式(1.1)两边同时平方，得到

$$x^2(t) = \sum_{i=1}^{n+1} c_i^2(t) + 2 \sum_{i=1}^{n+1} \sum_{j=1}^{n+1} c_i(t)c_j(t) \quad (1.7)$$

当上式最后一项 $2 \sum_{i=1}^{n+1} \sum_{j=1}^{n+1} c_i(t)c_j(t) = 0$ 时，EMD 的分解满足正交特性。由文献^[24]中得知以下

指标

$$IO = \sum_{t=0}^T \left[\sum_{i=1}^{n+1} \sum_{j=1}^{n+1} c_i(t)c_j(t) / X^2(t) \right] \quad (1.8)$$

其中 T 为信号长度，在深入的研究过程中，Huang 反复多次试验后验证得到：IO 一般都会小于 1%，但在某些特殊情况下，信号长度过短的信号的 IO 可能会超过 5%。

2.2.2 EWT 理论及分解过程

EWT 是由 Gilles^[14]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。接下来我们将展示 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，

$$\hat{f}(\omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} s(t)e^{-i\omega t} dt \quad (1.9)$$

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 $[\Omega_{n-1}, \Omega_n]$ ^[25]，并且

$$\Omega_{n-1} = \frac{\omega_{n-1} + \omega_n}{2} \quad n = 2 \sim N, N \leq P \quad (1.10)$$

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

再令 $\Lambda_n = [\Omega_{n-1}, \Omega_n]$, 其中 Ω_{n-1}, Ω_n 表示划分结果, 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 2.3 的阴影部分。




图 2.3 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 可以简单的取为 $\tau_n = \gamma\Omega_n$, $0 < \gamma < 1$ 。则 $[\Omega_{n-1}, \Omega_n]$ 的尺度函数和小波函数为

$$\hat{\phi}_n(\omega) = \begin{cases} 1, & |\omega| \leq (1-\gamma)\Omega_n \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{|\omega| - (1-\gamma)\Omega_n}{2\gamma\Omega_n}\right)\right], & (1-\gamma)\Omega_n \leq |\omega| \leq (1+\gamma)\Omega_n \\ 0, & \text{others} \end{cases} \quad (1.11)$$

$$\hat{\psi}_n(\omega) = \begin{cases} 1, & (1+\gamma)\Omega_n \leq |\omega| \leq (1-\gamma)\Omega_{n+1} \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{|\omega| - (1-\gamma)\Omega_{n+1}}{2\gamma\Omega_{n+1}}\right)\right], & (1-\gamma)\Omega_{n+1} \leq |\omega| \leq (1+\gamma)\Omega_{n+1} \\ \sin\left[\frac{\pi}{2}\beta\left(\frac{|\omega| - (1-\gamma)\Omega_n}{2\gamma\Omega_n}\right)\right], & (1-\gamma)\Omega_n \leq |\omega| \leq (1+\gamma)\Omega_n \\ 0, & \text{others} \end{cases} \quad (1.12)$$

式中: $\beta(x)$ 是平滑过渡函数 (如升余弦函数), 表示为

$$\begin{cases} \gamma < \min_n\left(\frac{\Omega_{n+1} - \Omega_n}{\Omega_{n+1} + \Omega_n}\right), 0 < \gamma < 1 \\ \beta(x) = x^4(35 - 84x + 70x^2 - 20x^3) \end{cases} \quad (1.13)$$

对于 $f(t)$ 而言, 在 N 个子频带上利用尺度函数式(1.11)和小波函数式(1.12)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^[26]为

$$w_f^\varepsilon(n, t) = \langle f, \psi_n \rangle = \int f(\tau) \psi_n^*(\tau - t) d\tau = F^{-1} \left[\hat{f}(\omega) \hat{\psi}_n^*(\omega) \right] \quad (1.14)$$

逼近系数为

$$w_f^\varepsilon(0, t) = \langle f, \phi_1 \rangle = \int f(\tau) \phi_1^*(\tau - t) d\tau = F^{-1} \left[\hat{f}(\omega) \hat{\phi}_1^*(\omega) \right] \quad (1.15)$$

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

$$f_0(t) = w_f^\varepsilon(0, t) * \phi_1(t) \quad (1.16)$$

$$f_k(t) = w_f^\varepsilon(k, t) * \psi_k(t) \quad (1.17)$$

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:

$$f(t) = w_f^\varepsilon(0, t) * \phi_1(t) + \sum_{n=1}^N w_f^\varepsilon(n, t) * \psi_n(t) = F^{-1} \left[\hat{w}_f^\varepsilon(0, \omega) \hat{\phi}_1(\omega) + \sum_{n=1}^N \hat{w}_f^\varepsilon(n, \omega) \hat{\psi}_n(\omega) \right] \quad (1.18)$$

EWT 的分解流程图如图 2.4:




图 2.4 EWT 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^[14]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 $\{M_i\}_{i=1}^M$ 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的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。

EWT 的特性主要有三点：

（1）自适应性

EWT 的核心优势在于其完全自适应的频带划分能力,无需依赖人工预设基函数或固定频段。通过分析信号的傅里叶频谱,检测能量集中的频段或局部极大值点,自动划分频带边界(如频谱的极小值点或突变点)。并且可以通过调整参数(如频带数量、过渡带宽)控制分解粒度。

(2) 抗模态混叠能力

EWT 借助频域分割手段有效减少了模态混叠现象,同 EMD 依靠时域极值点插值不同,EMD 因信号瞬时频率变化极易引发不同尺度模态混叠,EWT 直接于频域分离不同频段,保证各模态主频不会重叠,在实际的机械故障诊断里,要是信号含有相近频率的振动成分,EWT 可清晰地将两者分离,而 EMD 有可能混合成单一模态,造成误判情况的发生。

(3) 抗端点效应

EWT 对噪声和信号端点干扰具有较强鲁棒性,噪声能量通常分布在高频宽频带,EWT 通过频域分割将其隔离至特定模态,方便后续去噪。EMD 在时域插值时易因端点极值估计偏差导致包络失真,而 EWT 的频域在全局处理可以减少端点影响。

2.2.3 基于 EMD-EWT 的算法改进原理

通过上面的介绍,得知了 EMD 和 EWT 的优缺点。EMD 分解时主要依据信号自身所具有的性质,可以将多成分的复杂信号分解成一个个简单的分量,这种方法避免了使用基函数,也不需要遵循所谓的频带划分规则,一切都基于经验性的筛选。但是 EMD 也有缺陷,除了上述提到的模态混叠和端点效应,还存在过度分解,无法滤除转频干扰,并且没有完备的数学理论框架,缺乏理论推导。

相比于 EMD,EWT 解决了 EMD 理论性不足和容易过度分解的问题,并在其他方面都有改进,具备自适应性、频带分离和正交性,从而提高了分解的准确性和有效性。但若信号主频被噪声淹没,EWT 可能将噪声频段误判为有效模态,即面对强噪声,依然会受到干扰。

为了解决上述缺点,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(1.2)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(1.4)，得到 IMF1。再由式(1.6)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(1.11)、(1.12)即可得出。之后通过式(1.14)、式(1.15)计算得到高频细节系数和低频逼近系数，最后再利用式(1.16)和式(1.17)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 $XH_i(n)$ 。

为了更好的观察到频率特征，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^[27]，得到 $XHR_i(n)$ ，记为

$$R_{xx}[m] = \sum_{n=0}^{N-m-1} XH_i[n+m] \cdot XH_i[n] \quad (1.19)$$

$$R_{xx, \text{normalized}}[m] = \frac{1}{R_{xx}[0]} R_{xx}[m] \quad (1.20)$$

$$XHR_i[m] = \frac{1}{R_{xx}[0]} R_{xx}[m] \quad (1.21)$$

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 $W_l(f_i), l=1, 2; i=0, 1, 2, \dots, N-1$ 。

2.3 主轴承故障指标构建

为了更加有效且直观的观察故障特征，本节将构建一个轴承故障指标来提取频带中的故障特征信息。

2.3.1 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 ；

$$SI = \text{Max} / \text{Min} \quad (1.22)$$

(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。

2.3.2 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 2.2.3 (2)；

(2) 接着对包络信号进行自相关分析，通过式(1.19)、式(1.20)和式(1.21)得到 $XHR_l(n)$ ；

(3) 再由章节 2.2.3 (2) 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 $W_l(f_i), l=1,2; i=0,1,2,\dots,N-1$ 。

2.3.3 故障频率特征提取

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^[28]。

设高压转子转速的转频为无符号量 f_N ，随后在频带包络谱中提取故障特征频率，特征频率包括：外圈故障频率、内圈故障频率、滚动体故障频率、保持架故障频率。它们的计算方法分别为：

转频：

$$f_n = n_r / 60 \quad (1.23)$$

外圈故障特征频率：

$$f_o = \frac{f_n}{2} \left(1 - \frac{d}{D} \cos \alpha \right) z \quad (1.24)$$

内圈故障特征频率：

$$f_i = \frac{f_n}{2} \left(1 + \frac{d}{D} \cos \alpha \right) z \quad (1.25)$$

滚动体故障特征频率：

$$f_b = \frac{f_n}{2} \left(1 - \frac{d^2}{D^2} \cos \alpha \right) \frac{D}{d} \quad (1.26)$$

保持架故障特征频率：

$$f_c = \frac{f_n}{2} \left(1 - \frac{d}{D} \cos \alpha \right) \quad (1.27)$$

式中参数说明见表表 2. 1：

表 2. 1 轴承参数说明

参数	说明
n_r	转速
d	轴承滚动体直径
D	节圆直径
z	滚动体个数
α	接触角

本研究主要针对于外圈故障频率，选用外圈故障特征频率计算公式得到 f_o ，设特征频率 f_o 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）先在整个包络谱的的频带范围内 $(0 - f_s / 2)$ 去掉 9 倍转频的频率分量，即

$$W_l(f) = \begin{cases} 0, & |f - 9f_N| < 0.05f_N \\ W_l(f), & \text{others} \end{cases} \quad (1.28)$$

（2）接着设 10Hz— $2f_o$ 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

$$S_{al} = \frac{1}{N_e} \sum_{i=0}^{N_e-1} W_l(f_i) \quad (1.29)$$

（3）提取故障频率特征量。首先需要确定频率的搜索范围，设定 90% 工况以上的接触

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

$$S_{dl} = \max[W_l(f_{o1} + i\Delta f)], i \in [0, m], l = 1, 2, 3, 4 \quad (1.30)$$

接着构造出一个无量纲特征量 S_{ol} ，记为

$$S_{ol} = \frac{S_{dl}}{S_{al}}, l = 1, 2, 3, 4 \quad (1.31)$$

通过式(1.31)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

$$S_o = \max_{l=1}^4 [S_{ol}] \quad (1.32)$$

最终，将其转化为分贝 dB 值，定义 FdB 为故障特征量，记为

$$F_{dB} = 20 \log_{10}(S_o) \quad (1.33)$$

至此，设定的故障特征指标构建完成。

2.3.4 故障频率特征的判定标准

为了更加便捷的进行故障诊断，本文最后使用外圈故障频率特征的 FdB 值趋势图与正常航空发动机的 FdB 值趋势图进行对比诊断，以此判定故障。

2.4 本章小结

本章主要介绍了 EMD 算法与 EWT 算法的理论基础和分解过程，经过对比总结其优缺点，提出了 EMD-EWT 融合的改进算法，并且为了更好的进行故障诊断，构建了一种无量纲特征值 FdB，对其构建过程进行了详细论述。

(1) EMD 针对分析信号自身所具有的特点来进行自适应性分解，可以有效、快速的提取信号的故障特征信息，但其分解结果存在过度分解的情况，并且受噪声影响较大，缺乏完整的数学模型和理论基础。

（2）EWT 通过分析信号傅里叶谱的局部极值特征，自适应构建小波滤波器组实现频带划分，解决了 EMD 中的缺点，且 EWT 拥有完备的理论基础，但是分解结果依然受噪声影响和转频干扰，使其分解的有效性降低。

（3）EMD-EWT 方法有效的结合了上述两种方法的优点，理论方面可以更有效的降低噪声干扰，提高分解的有效性，并且结合本文所构建的故障特征指标 FdB 值，可以捕捉到前期微弱的早期故障。

第三章 基于已有整机试车数据的试验验证

3.1 试验背景

航空发动机在高温、高速、高压、变工况等极端恶劣的环境下工作时，发动机承受变载荷，导致滚动轴承极易损坏。然而，与其他机械零件相比，滚动轴承的寿命离散型很大，难以实现定时维修。为了有效地实现航空发动机视情维修，滚动轴承的状态监测与故障诊断至关重要。

本次试车的目的是通过开展 B20056 发动机主轴承状态监控和失效预警技术考核试验，对发动机机载健康诊断系统、发动机整机振动模型、便携式高频振动健康诊断系统原型、便携式铁谱分析系统等原型参试系统、以及其他搭试品进行验证。

3.2 轴承参数及数据采集

本次试车用 XXB 发动机，编号为 20056，该发动机依据《轴承状态监控测试改装要求》（S10.JT.1973）进行了测试改装，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。

本次试车在该发动机共安装 16 个传感器进行数据采集，具体安装位置如图 3.1 所示。




图 3.1 传感器安装示意图

选用该发动机数据进行试验，其轴承参数见表 3.1。

表 3.1 B20056 发动机参数

采样率	滚珠直径	节径	滚珠数	接触角
200kHz	22.225mm	167.5375mm	20	39°

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。软件部分数据采集界面如图 3.2。




图 3.2 振动数据采集界面

3.3 试验验证

3.3.1 EMD 处理

挑选其中的一组数据处理，如图 3.3 所示，为该组数据的时域图和 Fourier 频谱图：




图 3.3 原始数据

现在采用 EMD 算法分解信号，得到的分解后的前 10 个分量时域波形图如图 3.4:




图 3.4 前 10 个分量时域图

经过自相关归一化处理的包络频谱图如下:




图 3.5 IMF1、2 分量包络谱图




图 3.6 IMF3、4 分量包络谱图




图 3.7 IMF5、6 分量包络谱图




图 3.8 IMF7、8 分量包络谱图




图 3.9 IMF9、10 分量包络谱图

从图 3.5 中可以明显看出，在归一化的频谱中，包含频率成分最多的为第一个分量 IMF1。接下来通过本文构建的故障指标计算每条频带的特征量 FdB 值，所得结果如下表：

表 3.2 EMD 分量 FdB 值

	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
FdB 值	30.43	9.31	5.81	-15.8	-26.76	-35.14	-38.02	-42.94	-42.25	-41.15

表 3.2 可以看到第一条分量的 FdB 值最大，所以故障频率特征也最为明显。

为了确定频率搜索范围，本文设定接触角变化范围为 0-100 度，且由于是外圈故障，选用式(1.24)，然后根据计算公式得到频率变化范围。

为了方便表示，将接触角为 0 度时的特征频率记为 f_{o1} ，接触角为 100 度时的特征频率记为 f_{o2} ，那么特征频率的变化范围为 $f_{o1} \sim f_{o2}$ ，利用轴承参数计算得出变化区间为 2102.57~2479.99 Hz，该组数据的外圈故障特征频率 $f_{oc} = 2144.00$ Hz，例如图 3.5 中红色双虚线即为特征频率的变化范围。

在特征频率变化范围内也可以很明显的找到频率 2144Hz，但是并不能确定为外圈故障频率，因为通过频谱可以观察到存在很大的干扰，有可能是转频干扰，也可能是其他噪声的干扰，如图 3.5 中 IMF1 所示。

EMD 通过信号自身特征尺度实现自适应分解，无需预设基函数和固定参数，能够将各个分量自适应的分解到不同频带。然而该方法存在一定的局限性，首先是分解时容易产生与源信号无关的伪模态分量，这都是过度分解时形成的虚假特征信息。其模态混叠与端点效应也会干扰故障特征的提取，除了上述提到的缺点外，还无法有效的滤除噪声干扰。并

且 EMD 的理论体系缺乏严格的数学推导与分析框架，分解过程依赖经验性的筛选而非普适性数学模型。

3.3.2 EWT 处理

依然使用该组数据，现采用 EWT 方法分解信号，其余步骤与 EMD 分解时相同，根据式(1.24)得出 $f_{o1} = 2102.57 \text{ Hz}$ ， $f_{o2} = 2479.99 \text{ Hz}$ ，且外圈故障频率为 $f_{oc} = 2144.00 \text{ Hz}$ ，经过归一化自相关算法后的包络谱图如图：




图 3.10 EWT 模态 1、2 包络谱图




图 3.11 EWT 模态 3、4 包络谱图




图 3.12 EWT 模态 5、6 包络谱图




图 3.13 EWT 模态 7、8 包络谱图




图 3.14 EWT 模态 9 包络谱图

可以看出低频信号与高频信号进行了有效的分离。接下来计算每个模态的 FdB 值：

表 3.3 EWT 处理 FdB 值

	1	2	3	4	5	6	7	8	9
FdB	-42.36	-16.09	-76.78	-63.58	-61.32	-45.20	-33.78	-33.96	26.13

经过观察模态九的 FdB 值最大为 26.13，其故障特征频率也最明显，通过图 3.14 不难发现，频率变化范围内存在明显的 2145Hz，但是存在很多其他噪声的干扰。

相比于 EMD，EWT 解决了 EMD 理论性不足和容易过度分解的问题，通过傅里叶谱边界检测机制建立严格的数学框架，解决了其理论体系薄弱的问题。并在其他方面都有改进，采用正交小波滤波器组抑制模态冗余，从而降低了过度分解发生率，提高了分解的有效性。并且从包络谱图中可以观测到信号中有很多周期性瞬态冲击特征，可能是噪声的干扰，也可能是转频干扰，这些都会极大程度的影响人们的判断。

3.3.3 EMD-EWT 处理

依然是同一组数据，现在采用 EMD-EWT 方法处理。先用 EMD 自适应分解信号得到 10 条 imf 分量，再用 EWT 方法进行二次分解，得到了每条分量的低频模态和高频模态，下面给出前 5 条分量的低频和高频模态包络谱图：




图 3.15 IMF1 的高频与低频模态




图 3.16 IMF2 的高频与低频模式




图 3.17 IMF3 的高频与低频模式




图 3.18 IMF4 的高频与低频模式




图 3.19 IMF5 的高频与低频模态

其中红色包络谱图为高频模态，蓝色包络谱图为低频模态，由于后 5 条分量无明显频率信息，所以此处只放出前 5 条分量被 EWT 分解的结果。通过观察不难看出，噪声被有效的分离到了高频模态。接下来计算每个模态的 FdB 值如下：

表 3.4 EMD-EWT 分解前 5 条分量 FdB 值

	IMF1	IMF2	IMF3	IMF4	IMF5
高频	-18.48	-79.24	-57.21	-95.84	-41.33
低频	19.74	26.66	42.84	12.51	-2.32

表 3.4 中第三条分量 IMF3 的低频模态的 FdB 值最大，所以其故障特征频率也最为明显。

不难发现，图 3.17 中 IMF3 在接触角范围内存在明显的 2145Hz，可以确定其为外圈故障特征频率，没有观察到明显的杂散频率干扰，且特征频率非常明显，噪声的干扰较小，能量更加集中。

对比 EMD 和 EWT，其特征频率在包络谱上非常显著，并且根据本文所构建的轴承故障指标，EMD-EWT 方法计算得出的 FdB 值也是最大的，充分表明了其分解的有效性。

3.4 试验结果对比

3.4.1 第一组数据

本节中将上节中数据处理结果进行对比，且重新使用两组数据分别使用三种方法处理，此处简化过程，只看结果的对比，如图 3.20。




图 3.20 数据 1 对比图

不难发现，EMD-EWT 方法处理的结果受噪声干扰最小。再看故障指标 FdB 值的对比（只挑选频率特征最明显频带的 FdB 值）：

表 3.5 数据 1FdB 值对比

	EMD	EWT	EMD-EWT
FdB 值	30.43	26.13	42.84

可以看出，EMD-EWT 方法计算得出的 FdB 值也是最大的，远高于其他两个方法，这样就可以更加明显的找到故障频率特征，相比于 EMD 和 EWT，EMD-EWT 方法可以更快速的捕捉早期微弱故障。

3.4.2 第二组数据

使用同发动机的另一组数据处理结果如图 3.21：




图 3.21 数据 2 对比图

EWT 与 EMD-EWT 在接触角范围内存在明显的 2124Hz，可以确定其为外圈故障特征频率，没有观察到明显的倍频成分，通过图像发现，EMD 很难找到外圈故障频率，而 EWT 与 EMD-EWT 可以发现特征频率非常明显，噪声的干扰较小。

表 3.6 数据 2FdB 值对比

	EMD	EWT	EMD-EWT
FdB 值	23.08	36.47	43.47

由 FdB 值可以看出，EWT 与 EMD-EWT 均远高于 EMD 与 EWT，外圈故障频率特征明显。

3.4.3 第三组数据

依然使用同一发动机不同时刻的信号数据：




图 3.22 数据 3 对比图

从上图中可以发现，该组数据三种方法虽然都无法完全有效的消除噪声影响，但是 EMD-EWT 方法受噪声影响最小。其 FdB 值计算结果如下：

表 3.7 数据 3FdB 值对比

	EMD	EWT	EMD-EWT
FdB 值	13.91	24.98	33.34

该组数据中，EMD-EWT 均远高于其他二者，且 EMD-EWT 的 FdB 值依然为最大，更加充分说明了 EMD-EWT 发现微弱故障的能力优于 EMD 与 EWT。

3.5 EMD-EWT 诊断结果

本节中将采用 EMD-EWT 方法对整个发动机数据进行批量诊断，即将采集到的所有数据全部使用该方法分析处理，每一个时刻的信号都计算出所构建的故障指标 FdB 值，最终判断该方法的适用性。通过计算得出所有时刻信号的 FdB 值如图 3.23，再将其与正常状态下的 FdB 值趋势图如图 3.24 对比即可得出结论。其中红色细实线代表 FdB 值，黑色细实线为发动机转速。




图 3.23 异常发动机 FdB 值趋势图




图 3.24 正常发动机 FdB 值趋势图

由图 3.24 看出，正常发动机的 FdB 值在 15-20 之间波动，当二者转速都在 14000r/min 以上时，异常发动机的 FdB 值明显高于正常发动机，在 40-45 之间波动，由此我们得出结论，该发动机存在外圈故障。

3.6 本章小结

通过三组数据的对比发现，EMD 受噪声影响过大，无法有效的提取故障特征，EWT 相比 EMD，抗噪能力略有提升，但存在许多杂散频率干扰，极大的影响了人们的观察。而 EMD-EWT 能够有效的观察到外圈故障频率，其对噪声的处理远强于上述两个方法，频带的能量更加集中，并且使用构建的故障指标 FdB 计算时，EMD-EWT 方法所得出的 FdB 值最大的频带能够更有效的观察到外圈故障特征频率，进行状态监测。

第四章 总结与展望

4.1 研究总结

轴承是旋转机械中最重要的零部件之一，在航空发动机的正常运行中有着极其重要的作用。发动机主轴承往往在恶劣的环境下工作，因此极易损坏。如果能够在轴承发生故障的早期就可以检测到故障的发生，对于飞机的维修工作就能提高很大的效率，并且提高了飞机飞行的安全性和可靠性，在很大程度上减少轴承故障对飞机带来的影响。为了能够更好地识别早期微弱故障，本文针对轴承故障诊断中非平稳信号的故障特征难以提取的问题，提出了一种基于 EMD-EWT 的故障特征提取新方法。通过与单一 EMD、EWT 方法的对比实验及理论分析，验证了该方法的优势，具体的工作内容如下：

（1）研究了 EMD 与 EWT 的基础理论及其各自的优缺点。传统 EMD 分解易受模态混叠影响，导致高频 IMF 中故障特征与噪声混淆；且易对高频噪声敏感。EWT 直接分解时若信号频谱结构复杂，频带划分易产生过分割或欠分割；且 EWT 依赖频谱质量，强噪声干扰可能导致频带误判。且使用 matlab 程序成功编码，利用两种方法对信号实行分解，将分解后的信号进行对比，得出结论。

（2）通过对 EMD 与 EWT 的学习，提出了一种结合两者优点的 EMD-EWT 方法，通过 EMD 初步分解提取局部特征，再对分解后的 IMF 进行 EWT 频带优化，大幅程度减少了模态混叠的发生。然后加入包络分析与自相关归一化算法，提升了该方法的抗噪性。最后构建主轴承故障指标 FdB 值，并设定故障阈值，利用 FdB 值的大小更好的进行故障诊断。

（3）将 EMD、EWT、EMD-EWT 三种方法分别对三组真实发动机信号数据进行分解处理，并对其计算故障指标 FdB 值。通过对处理结果进行对比，得出 EMD-EWT 方法具有比前二者更好的抗噪性，能够有效的降低噪声干扰，提高了信噪比，分解结果明显优于 EMD 与 EWT。

4.2 研究展望

尽管 EMD-EWT 方法在实验中表现优异，但在过程中，仍旧发现了以下不足：

（1）EMD 迭代筛选结合 EWT 频带优化的双重分解机制导致算法耗时较长，相比较于单一方法，其计算时间显著增加。

(2) 本文研究主要针对轴承的外圈故障，而实际情况中往往会发生多种故障，针对其他故障类型尚未进行试验，无法说明该方法对所有故障类型均有效。

(3) 本文构建的故障指标，其依据先验经验与前人数据所设定，针对未知故障可能影响其泛化性能。

针对上述不足，在未来可以结合以下方向：

(1) 基于 FPGA 或嵌入式 GPU 实现算法硬件加速，利用并行计算优化 EMD 迭代过程与 EWT 的运算，减少计算时间与算力损耗。

(2) 结合深度学习，构建“分解-特征提取-分类”端到端模型，利用 CNN 自动学习 EMD-EWT 分解后的多模态特征权重。且可以采用注意力机制（Transformer）强化故障频带特征，抑制无关噪声分量。

参考文献

- [1] 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.
- [2] 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.
- [3] 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.
- [4] Gustafsson, O. G., & Tallian, T. (1962). Detection of Damage in Assembled Rolling Element Bearings. A S L E Transactions, 5(1), 197–209.
- [5] Wang Y F, Kootsookos P J. Modeling of low shaft speed bearing faults for condition monitoring[J]. Mechanical systems and signal processing, 1998, 12(3): 415-426.
- [6] Yang Y ,Dong X ,Peng Z , et al.Vibration signal analysis using parameterized time–frequency method for features extraction of varying-speed rotary machinery[J].Journal of Sound and Vibration,2015,335350-366.
- [7] 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.
- [8] 刘佳昕,周风波.EMD 算法的改进及在信号去噪中的应用[J].电子制作,2024,32(04):73-75+27.
- [9] 张琛,赵荣珍,邓林峰.基于变分模态分解奇异值熵的滚动轴承微弱故障辨识方法[J].振动与冲击,2018,37(21):87-91+107.
- [10] Guo T, Deng Z. An improved EMD method based on the multi-objective optimization and its application to fault feature extraction of rolling bearing[J]. Applied Acoustics, 2017, 127: 46-62.
- [11] 童靳于,苏缪涎,郑近德,等.自适应噪声均值优选集成经验模态分解及其在滚动轴承故障诊断中的应用[J].电子测量与仪器学报,2021,35(02):41-49.
- [12] 李翠省,刘永强,廖英英.基于相关峭度准则 EEMD 及改进形态滤波的轴承故障诊断方法[J].轴承,2017,(02):55-59.
- [13] 高云峰,张金萍.基于 EMD 和 FastICA 的轴承故障诊断[J].机械设计与制造,2024,(06):48-52.
- [14] Gilles J. Empirical wavelet transform[J]. IEEE transactions on signal processing, 2013, 61(16): 3999-4010.
- [15] Kedadouch 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.
- [16] 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.
- [17] 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.
- [18] 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.
- [19] Hu Y, Tu X, Li F, et al. An adaptive and tacholeless 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.
- [20] 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].
- [21] 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.
- [22] 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.
- [23] 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.
- [24] Huang N E. Review of empirical mode decomposition[C]//*Wavelet Applications VIII*. SPIE, 2001, 4391: 71-80.
- [25] Singh O, Sunkaria R K. ECG signal denoising via empirical wavelet transform[J]. *Australasian physical & engineering sciences in medicine*, 2017, 40: 219-229.
- [26] 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.
- [27] 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.
- [28] 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..

致 谢

落笔至此，思绪万千。致谢是这篇文章的终章，也是我学生生涯的终点。我看到过太多致谢，但没想到这一天竟然来的如此之快。

大学四年匆匆，疫情便夺走了两年，是遗憾，但也是难忘。这里非常感谢我的第一位导师柳小营老师，人美心善，和蔼可亲，不但在学习生活中时刻帮助我，还包容我的错误，从来没有严厉苛责我，而是悉心教导我，纠正我。

在毕设工作中，我要感谢我的导师陈果教授，为我的毕设工作给予了很大帮助，给出了很多合理建议。同时，也十分感谢课题组的马一杰师兄，为我的毕设完成提供了非常多的贡献。感谢师兄悉心的指导，不厌其烦的回答我的问题，并且帮助我解决了许多疑难。

还要感谢我的父母对我二十余年的栽培，我十分的感谢他们能够永远支持我的选择，让我自己掌控人生的轨迹。同时感谢我的姐姐，为我提供了莫大的经济支持。

除此以外，感谢我相识十余年的朋友们，人生不过二十二载，朋友的陪伴便已过半数光阴。虽然毕业我们各奔东西，但是我们总会相逢的，是吧。

感谢南京航空航天大学，感谢学校提供的平台和资源，感谢我认识的大学同学，感谢所有关心和帮助过我的人，在此向你们表达十分真挚的感谢。

我想说的太多太多，大到每一个人和事，小到每一个留有回忆的地方。短短五百余字，道不完我的回忆。致谢临近末尾，是结束，也是新的开始。

祝愿我们都有一个美好的明天！

张泽宇

二〇二五年