编号

毕业设计





二〇一九年六月

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)(题 目:_____)是本人在导师的指导下独立进行研 究所取得的成果。尽本人所知,除了毕业设计(论文)中特别加以标 注引用的内容外,本毕业设计(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。

(学号):

基于深度学习的滚动轴承故障预测方法

摘 要

随着我国航空技术的发展,C919的成功研制以及C929的研发战略实施,对飞机发动机 的各方面技术性能要求均在不断提高。航空发动机的滚动轴承在发动机转子系统中具有极其 重要的作用,因此,对滚动轴承的可靠性的要求也越来越高。然而,航空发动机的滚动轴承 经常在高转速、重载荷的恶劣环境下运转,极易产生各种故障,严重威胁着发动机的使用可 靠性和安全性。因此,对于滚动轴承的状态监控及其重要,而对轴承故障预测是进行状态监 控必要的手段。近年来,深度学习在故障预测方面展现了巨大的优势。本文利用卷积神经网 络,通过三种数据图像处理方法,借助西储大学轴承数据比较分析三种数据处理方法的效果, 并找出效果最好的数据处理方法。最后,将本文基于深度学习的滚动轴承故障预测方法应用 到带机匣的航空发动机轴承故障预测中,通过对实验数据的计算和分析,结果表明,本文所 提出的基于深度学习的滚动轴承故障预测方法具有很好的故障识别精度,平均准确度达 95%, 为实际航空发动机滚动轴承的故障预测找出了一种新的解决方案。

关键词: 深度学习,卷积神经网络,滚动轴承,故障预测

Rolling bearing fault prediction method based on deep learning

Abstract

With the development of China's aviation technology, the successful development of C919 and the implementation of C929's R&D strategy, the technical performance requirements of all aspects of aircraft engines are constantly improving. The rolling bearing of an aero-engine has an extremely important role in the engine rotor system, and therefore, the reliability of the rolling bearing is also becoming higher and higher. However, the rolling bearings of aero-engines often operate under the harsh environment of high speed and heavy load, which is prone to various faults and seriously threatens the reliability and safety of the engine. Therefore, the monitoring of the condition of the rolling bearing is important, and the prediction of the bearing failure is a necessary means for state monitoring. In recent years, deep learning has shown great advantages in fault prediction. In this paper, the convolutional neural network is used to compare the effects of three data processing methods with the data processing methods of the Western Reserve University, and to find out the best data processing methods. Finally, the prediction method of rolling bearing fault based on deep learning is applied to the prediction of aero-engine bearing fault with belt,. Through the calculation and analysis of experimental data, the results show that the proposed method for predicting rolling bearing fault based on deep learning has Good fault identification accuracy, with an average accuracy of 95%, finds a new solution for the fault prediction of actual aero-engine rolling bearings.

Key Words: Deep learning; Convolution neural network; Rolling bearing; Failure prediction;



摘 要i
Abstractii
第一章 绪 论1
1.1 课题研究背景与意义1
1.2 滚动轴承故障状态分析2
1.3 滚动轴承故障预测研究现状2
1.3.1 特征提取2
1.3.2 故障预测
1.4 论文研究内容5
第二章 数据处理相关方法6
2.1 概述
2.2 矩阵图法
2.2.1 矩阵图
2.2.2 矩阵图种类6
2.2.3 矩阵图构造7
2.3 快速谱峭图算法7
2.3.1 谱峭度7
2.3.2 快速谱峭图
2.4 小波时频图法10
2.4.1 小波变换10
2.4.2 小波时频窗的面积不变性12
2.5 本章小结13
第三章 卷积神经网络与故障预测14
3.1 卷积神经网络结构14
3.1.1 卷积层14

3.1.2 池化层
3.1.3 全连接层16
3.1.4 激活函数16
3.1.5 Softmax 回归17
3.1.6 损失函数
3.2 卷积神经网络故障预测流程19
3.2.1 滚动轴承故障预测模型19
3.2.2 滚动轴承故障预测流程19
第四章 基于 CNN 的滚动轴承故障预测
4.1 基于美国凯斯西储大学轴承数据的滚动轴承故障预测22
4.2 基于带机匣的航空发动机数据的滚动轴承故障预测27
4.2.1 实验内容及结果分析27
第五章 总结与展望
5.1 总结
5.2 展望
参考文献
致 谢

第一章 绪 论

1.1 课题研究背景与意义

滚动轴承在旋转机械中担任一个极其重要的角色。在机械运行过程中会由于很多原因致 使轴承的使用寿命下降,影响机械的运转,进而降低其寿命。当滚动轴承的故障发生在飞机 的动力源——航空发动机上时,轻则影响飞机飞行姿态,重则可能会造成飞机坠落造成巨大 损失。因此,对于滚动轴承的故障预测,提早发现其故障极其重要,而对轴承故障预测是进 行寿命预测必要的手段。

飞机在空中飞行的时候,由于各种原因可能造成飞机上部件发生故障。在这些部件中如 果作为唯一给飞机产生动力的航空发动机出现故障,会严重降低飞机安全性,甚至会造成严 重的飞行事故。像在 2005 年到 2013 年的 8 年里,中国的某型战机由于发动机主轴承发生故 障损伤的情况致使发动机出现故障进而造成数起空中停车重大事故,给国家造成了重大损失, 损失金额高达数亿美金。就在 2014 年,我国南航 CZ3739 在载客飞行时,因发动机损伤,发 生"畸变",导致飞机引擎在未着陆时引擎着火,幸运的是没有人员伤亡;2018 年 4 月 17 号, 西南航空的一架 Boeing737 客机在进行巡航飞行任务时发动机故障爆炸,造成 1 人死亡,多 人受伤。

在 2015 年中国国务院颁布的《中国制造 2025》战略布局中,将航空领域里倍受关注的 装备——航空发动机放入在未来 10 年里国家实现自主研制及应用的重要突破目标中^[1]。翻看 民航的适航条款规章,在 2011 年的修订版里,CCAR 33 部中第 33.70 条发动机限寿件中明文 规定:要求相关人员充分执行本条要求,充分了解并预测发动机限寿件,在它达到规定的使 用寿命时而且在对发动机造成危害性前,将限寿从发动机上拆下来,确保发动机的安全性和 可靠性。

基于上文提到的一些要素,作为航空发动机的重要限寿件——滚动轴承,很大程度上对 飞机的安全性产生了威胁,航空发动机的故障大部分源于滚动轴承的损坏进而造成在飞机飞 行中的严重事故。因此,提前对航空发动机滚动轴承故障进行有效预测的并结合相应故障采 取相应措施,防止由于潜在的故障对滚动轴承造成更严重的损伤。这样不仅能够提高航空发 动机的使用寿命,而且符合了我国对现代航空发动机发展的客观需求,具有极其重要的实际

南京航空航天大学

意义。

1.2 滚动轴承故障状态分析

在设备运转过程中,机器的各种原因都会有可能造成轴承的损伤,像异物侵入、装配偏差、润滑不当、油液侵蚀和过负荷运转等等。滚动轴承主要的几种故障模式:疲劳剥落、磨损、锈蚀、断裂、胶合等等。

滚动轴承在出现各种损伤时,其内部所产生的振动信号在运动过程中会发生不同程度的 变化,由此,滚动轴承在工作状态时表现出的故障依照其振动形式的差异,通常能够分成磨 损故障和表面损伤类故障^[2]。在磨损类故障中,故障的轴承虽然振动较为剧烈,但是不会造 成突变性伤害,对设备所造成的危害较小。在表面损伤类故障中,所产生的故障通常会在轴 承表面产生突变性冲击,对设备会造成很大的危害。所以,基于表面损伤类故障的轴承故障 常常更值得人们的关注。论文中通过人工在轴承内圈、外圈以及滚动体上制造损伤点来模拟 实际情况,来获取振动信号并进行分析,最后通过提取振动信号将得到特征应用到故障预测 的输入。

1.3 滚动轴承故障预测研究现状

滚动轴承在旋转机械中担任非常重要的角色,及时并精确的预测分析出滚动轴承的故障 模式对于排除隐患,保证设备安全等具有重要的意义。目前滚动轴承的故障预测分析方法, 按照监测数据源的区别,可以分为振动检测技术、油液检测技术等^[3]。振动诊断技术对冲击 类的早期故障灵敏,可实现故障隔离,方法多样;油液诊断技术对早期故障以及非剥落类故障不 敏感,无法实现故障隔离。因此,在面对 1.2 节提到的表面损伤类故障时,采取振动诊断技 术效果更佳。

振动诊断技术需要三个阶段:数据采集,特征提取和故障预测(模式分类)。其中特征提 取和故障预测尤为重要。

1.3.1 特征提取

特征提取作为故障预测的核心。提取的特征敏感度能够干扰故障预测的准确率。如果提 取的特征不敏感,可能导致最后故障预测的精度不足,甚至没有效果。基于振动诊断技术的 特征提取主要应用的是信号处理技术,提取的特征量可进一步分为时域特征量、频域特征量、 时频域特征量等。

毕业设计(论文)报告纸

常见的时域特征量^[4-7]包括带量纲特征和无量纲特征。带量纲特征中包括有效值、方根幅 值等;无量纲特征像峭度、峰值指标、裕度及冲击指数等。常见的频域特征量^[4]有重心频率、 频率方差、均方频率等等。相比于时域和频域方法,时频分析能更加有效地分析不稳定信号。 在滚动轴承发生故障的时候,其振动信号属于极不稳定的信号,通过相应的时频分析技术可 以提取出有效表征轴承状态的时频特征量。时频分析建立在对信号分解与重构的基础上,根 据分解方法的不同可以分为线性时频表示、双线性时频分布、时变高阶谱、参数自适应时频 分析、非参数自适应时频分析等方法^[8]。

滚动轴承局部损伤引发的冲击会对滚动轴承信号进行调制,为了得到轴承的故障信息, 通常使用解调对调制信号进行相应处理。包络分析是提取滚动轴承频域特征的重要手段^[6], 在包络分析前经常会先分解信号,如小波分解、经验模式分解、局部均值分解等;而线性预 测^[10]、自适应噪声消除技术(Adaptive Noise Cancellation, ANC)^[11-12]、离散随机分离(Discrete Random Separation, DRS)^[13]、时域同步平均(Time Synchronous Averaging, TSA)^[14]以及基于信 号分解重构的降噪方法(如小波降噪^[15])等方法常被用于消除噪声的影响;而谱峭度^[16]和 Protrugram^[17]等方法可以用于最优频带的选取。基于循环平稳理论的相关分析方法也可用于调 制解调^[18],这类方法原理简单并且计算量小,但被分析信号需满足周期平稳(cyclostationarity) 假设。长期以来,滚动轴承的信号解调多基于希尔伯特变换,而近年来基于能量算子的解调 方法逐渐走向人们的视野^[19]。

1.3.2 故障预测

20世纪末,大批的浅层机器学习模型接连出现,例如:支持向量机(Support Vector Machines, SVM),最大熵方法等。随着互联网的发展,人们开始将浅层机器学习模型应用到故障预测领域。时文刚等人^[20]利用支持向量机对往复泵泵阀构造了一个多值分类的模型,并对其故障进行分类。但是由于航空发动机上的滚动轴承振动信号具有信息量大而杂论、导致故障信息微弱,而且浅层学习模型在结构上相当于一层隐层结点或没有,在学习航空发动机上的轴承信号数据时就显得有些吃力。

在Hinton和他的学生公开了一篇关于深度学习的文章之后,深度学习便在学术和工业两 大领域中一下子沸腾了。由于硬件设备性能的不足,深度学习在大部分领域只能是理论研究 ^[21]。随着科技的发展,GPU的出现,提高了计算机的性能,满足了深度神经网络的对硬件设

备性能的要求^[22]。作为深层的机器学习中的深度学习被普遍应用在语音辨认、故障诊断和图像处理等领域。深度学习的神经网络类别主要分为:递归神经网络(Recursive Neural Networks, RNN),深度置信网络(Deep Belief Networks, DBN),卷积神经网络(Convolution Neural Networks, CNN)等。下面主要介绍基于递归神经网络,深度置信网络和卷积神经网络的故障预测三种方法:

(1)基于递归神经网络的故障预测:递归神经网络能够将这形态在本身网络中循环传递, 能承受更宽泛的时间序列结构输入,因而它可以形容非静态的时间行为。陈伟等人^[23]提出的 通过 RS-LSTM 来辨别滚动轴承故障,该方法将非线性的原始信号输入模型中,同时运用 LSTM 和深度神经网络的混合网络增强模型识别能力。杨秋英、陈卉等^[24]人提出的递归神经 网络,通过向网络模型中引入偏差单元,构造预测模型用于齿轮箱系统故障辨别。

(2) 基于深度置信网络的故障预测:深度置信网络将许多受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)单元堆叠起来能够直接对时域信号进行处理的网络,其中低层体现原始数据细节而高层体现数据属性或者特征。Prasanna Tamilselvan, Pingfeng Wang 等人^[25]提出了基于深度信念学习的健康分类的故障诊断案例,李巍华,单外平等人^[26]提出通过使用深度信念网络实现对轴承故障的分类的措施。

(3) 基于卷积神经网络的系统故障预测:卷积神经网络是深层前馈神经网络的一种。一般包含输入层、卷积层、池化层、全连接层和输出层。它的网络模型能够直接将最初的图像 作为输入,从而能够绕过对图像的前期预处理并且解决了在传统分辨算法中复杂的特征提取 和数据重建的困难。Chenlu等人^[27]提出的运用卷积神经网络模型的图像识别能力来实现对滚 动轴承智能故障辨别和健康分类;赵维等人^[28]提出了通过新的深度卷积神经网络训练方法解 决实际使用过程中轴承面临的嘈杂环境以及不同工作负荷情况下进行故障预测的一种办法。

小结,递归神经网络在处理延迟事件时长距离信息需要在到达当前处理单元前要按顺序 经过所有的结点,这很容易造成梯度消散,导致其无法学习到数据中的长期依存关系;深度 置信网络的生成模型在处理分类问题时会建立样本数据与标签之间的分布,因此它会忽略掉 差异类别间的最优划分区的位置,致使分类精度比较低;卷积神经网络由于它特有的网络结 构可以使其中的神经元能够一起使用一套权值,这样在更新参数的时候可以简化网络模型, 而且它的稀疏连接每一个特征图的像素只与上一层特征图的小区域有关,保证特征具有平移

毕业设计(论文)报告纸

不变性。在故障预测领域中,卷积神经网络展现了超过前两种神经网络的优势。

1.4 论文研究内容

这里借助振动信号的特点,将其转化为矩阵图,快速谱峭图,时频图三种图像类型,结 合卷积神经网络可以直接将图像作为输入的能力,充分比较三种图像类型应用在滚动轴承故 障预测的各自的优缺点。同时,论文就在卷积神经网络模型建立时面对的多种参数,给出一 定的理解,选择恰当的参数运用到模型中。

下面就文中各个章节主要内容给予介绍:

第一章:绪论。本章内容介绍航空发动机滚动轴承故障预测研究背景和意义,指出本文 的主要研究对象,并对其故障形式进行了分析。然后,对滚动轴承故障预测的研究现状进行 了论述,进而给出了本文采用的神经网络类别。在接下来会就论文的框架给予说明。

第二章:所采用的方法的相关基础理论。本章节介绍处理数据所使用的矩阵图、快速谱 峭图、时频图三种图像类型所采用的方法原理。

第三章:卷积神经网络与故障预测。本章节首先详细介绍了 CNN 结构的基本组成,并且 论述了使用卷积神经网络完成故障预测的步骤。

第四章: 基于 CNN 的滚动轴承故障预测。本章节介绍了实验内容,数据组合,以及分析 了三种图像类型结合 CNN 模型的故障预测效果。此章节通过两个实验,一个以公开的滚动轴 承数据为例,通过矩阵图、快速谱峭图、小波时频图三种方法结合卷积神经网络模型,比较 故障预测准确率,选取预测准确率较高的方法用于实际应用中。另一个实验将第一个实验的 到的结果应用到南京航空航天大学实验室采集的带机匣的航空发动机滚动轴承数据的故障预 测,验证结果鲁棒性,证明结果的可用性。

第五章:总结与展望。此章节主要是对论文钻研内容的一个总结并且给出研究的结论, 并指出本论文中存在的一些需要提高的地方,希望后面能够进一步研究,得到更好的结果。

南京航空航天大学

第二章 数据处理相关方法

2.1 概述

本文采用了矩阵图法、快速谱峭图法、小波变换法三种算法获取矩阵图、快速谱峭图、时频图三种不同类型的图像。

2.2 矩阵图法

2.2.1 矩阵图

矩阵图法又称矩阵表法。它经过数学矩阵展示元素彼此间的关联性,从其中找寻问题并 寻求处理方案的一种措施。矩阵图的长处是能够便利的找到对应元素之间的交叉点,清晰地 表现出对应元素之间的相关性。

2.2.2 矩阵图种类

根据元素组的数量,矩阵图法按照其元素的维度完成分类,并根据其形状命名。常见的 几种矩阵图类型: T型矩阵图、L型矩阵图、X型矩阵图等^[29]。其中L型矩阵图包含两个元 素组群,即它是通过二维矩阵的行列进行表达的;T型矩阵图有三个元素组群;X型矩阵图 有四个元素组群。根据本文采用的数据是二维的,因此下面详细介绍L型矩阵图。

L型矩阵表示是最简单的矩阵表示方法,包含两个元素组群。在L型矩阵图中,a是一个元素组群,它下面的具体元素是 a1、a2、a3、a4、…,其排列为矩阵行;b 是另一个元素组群,具体如下为 b1、b2、b3、b4、…,其布列在矩阵的列中;这里列和行的交点体现了元素 a 和 b 会存在怎样的关联性。图 2.1 给出了L型矩阵图示意图。



图 2.1 L 型矩阵图示意图

2.2.3 矩阵图构造

首先,获取具有标准时间尺度和幅度尺度的测量数据;然后将每种状态的数据集分成一系列时间子序列,通过连续交错采样,将这些时间子序列排序,以便产生数据矩阵,最后将这些子序列使用如图 2.2 所示方法建立矩阵图。(这里以 20×20 为例)



图 2.2 子序列建立矩阵图

2.3 快速谱峭图算法

2.3.1 谱峭度

谱峭度是一种谱的描述工具,最初由 Dwyer 提出,根本思想是通过算出每条频率线上的 峭度寻找潜在的不稳定性的存在,利用频带表现出来。

假设非平稳信号 X(t)的 Wold-Crame'r 分解的频域相应 Y(t) [30]:

$$Y(t) = \int_{-\infty}^{+\infty} e^{j2ft} H(t, f) dX(f)$$
 (2-1)

其中H(t, f)表示信号X(t)在对应频率f处的复包络,是一个随机量。这里将Y(t)的四阶频谱累积的谱峭度表示为:

$$C_{4Y}(f) = S_{4Y}(f) - 2S_{2Y}^{2}(f) \quad \text{ and } f \neq 0$$
(2-2)

其中 S(f)表示谱瞬时矩,这里以S_{2nY}(f)为 2n 阶谱瞬时矩为例:

$$S_{2nY} \square E\{ \left| H(t,f) dX(f)^{2n} \right| \} / df$$

$$(2-3)$$

南京航空航天大学

谱峭度体现了概率密度函数的峰值,给出其定义:

$$K_{Y}(f) = \frac{C_{4Y}(f)}{S_{2Y}^{2}(f)} = \frac{S_{4Y}(f)}{S_{2Y}^{2}(f)} - 2$$
(2-4)

谱峭度是用来体现共振频率与频带带宽的之间的关系的函数,其值取决于共振频带。
 在航空发动机的滚动轴承上获取的振动信号通常是含有有用信息和干扰信号的,其中干扰信息为n(t)有用信息即非平稳信号X(t),它的峭度可以用公式(2-5)表现为:

$$K_{s}(f) = \frac{K_{f}(f)}{\left[1 + S_{n}(f) / S_{f}(f)\right]^{2}}$$
(2-5)

其中, $S_n(f)$ 和 $S_f(f)$ 代表的n(t)和X(t)的功率谱密度^[31]。

2.3.2 快速谱峭图

快速谱峭图(或称快速峭度图)用来作为处理信号的四阶谱的措施,可以对信号的不稳 定性进行检测和表征。快速峭度图算法是利用频带交替二分解法或者三分解法,将信号进行 分解,将其谱峭度在 (*f*,Δ*f*)平面区域内表现出来以得到最优频率 *f* 和频率分辨率 Δ*f* 组合下 的谱峭度值。下面介绍快速谱峭图方法原理。

(1)假设h(n)表示一截止频率为1/8的标准滤波器,将h(n)在频带[0,1/4]和[1/4,1/2]内,
 构建低、高滤波器:低通滤波器h₀(n),高通滤波器h₁(n):

$$h_0(n) = h(n)e^{\frac{jn\pi}{4}}, f \in [0, 1/4]$$
 (2-6)

$$h_1(n) = h(n)e^{\frac{j3n\pi}{4}}, f \in [1/4, 1/2]$$
 (2-7)

信号经高低滤波器分解示意图如图 2.3 所示:



图 2.3 滤波器结构示意图

南京航空航天大学

毕业设计(论文)报告纸

(2)利用低通滤波器 $h_0(n)$ 和高通滤波器 $h_1(n)$ 按照金字塔形式不断迭代,对信号进行连

续的滤波后,得到滤波器的树状图。图 2.4 为多次迭代后的树状图。



图 2.4 迭代树状示意图

(3) 然后在上面的基础上,另外在频带[0,1/6],[1/6,1/3]和[1/3,1/2]内构建三个准解 析带通滤波器 g_j(n), j = 0,1,2。在第 k 层和第 k+1 层之间引入这三个准解析带通滤波器,进一 步细化频带,引入低、中、高频部分分为三个子序列。多次重复滤波后,分别计算每个子序 列的谱峭度,最后像图 2.5 所示的快速谱峭图示意图。



图 2.5 快速谱峭图分层结构图

图中包括了整个 $(f,\Delta f)$ 平面中的每个节点的谱峭度值。图中会通过使用颜色来显示值的

南京航空航天大学

大小,亮度越大表示峭度值越大而且体现的 f 和 Δf 即为最佳的带通滤波器共振频率和带宽。

下面以西储大学的数据[23]为例给出快速谱峭图来介绍图像中相应的信息,如图 2.6 所示。



图 2.6 快速谱峭图示例

从图 2.6 中可以看到,快速谱峭图中包含以下几个信息:滤波器分层数(纵轴),频率(横轴),谱峭度值(右侧)。图中用相应颜色来表示子序列相应的谱峭度值。以上图为例,对应 谱峭值最大 4.5 处是处于第 2.5 层的为 5500Hz 共振频率,相应带宽为 1000Hz。

2.4 小波时频图法

时频图是对信号的一个时间和频率的二维描绘。其原理是在时间轴上对应每个时间刻度, 给出相应的频率描述,这就构造出一张纵轴为频率,横轴为时间的二维时频分布图,准确的 展现出非平稳信号频率的特征信息。而小波时频图是采用小波变换的方法构造出的时频图。 下面介绍小波变换算法。

2.4.1 小波变换

小波变换作为一种窗函数的信号分析工具,相比于窗函数形状固定的傅里叶变换,小波变换算法中的窗函数的面积是固定的,即它的窗函数形状是随着信号不同会改变的。小波变

毕业设计(论文)报告纸

换会在低频部分能够取得更高的频率分辨率,在高频部分能够取得更高时间分辨率。这种优势,让小波变换在分析复杂信号中脱颖而出。

定义一个平方可积的函数 $\psi(t) \in L^2(R)$,若 $\psi(t)$ 的傅里叶变换 $\Psi(\omega)$ 满足:

$$0 < C_{\psi} = \int_{0}^{\infty} \frac{|\Psi(\omega)|}{\omega} d\omega < \infty$$
(2-8)

这里称ψ(t)为母小波(或者基本小波),经过平移和伸缩产生的函数能够表现为:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi(\frac{t-b}{a}) \tag{2-9}$$

其中, *a*和*b*是两个任意实数。变量*a*和*b*分别表示伸缩因子(或称尺度系数)和平移因子(或称位移系数)。

根据小波的定义,对信号 f(t)的小波变换为可以表示为:

$$W(a,b) = \int_{-\infty}^{+\infty} \Psi_{a,b}(t) f(t) dt \qquad (2-10)$$

这里W(a,b)为小波变换系数。从W(a,b)重建f(t)的逆变换,即小波逆变换为:

$$f(t) = \frac{1}{C} \int_{a=-\infty}^{+\infty} \int_{b=-\infty}^{+\infty} \frac{1}{|a|^2} W(a,b) \psi_{a,b}(t) dadb$$
(2-11)

其中 $C = \int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|^2}{\omega} d\omega$ 。

下面同样以西储大学的数据为例给出小波时频图来介绍图像中相应的信息,如图 2.7 所示。



图 2.7 小波时频图示例

从图 2.7 中可以看到,小波时频图中包含以下几个信息:频率(纵轴),时间(横轴), 能量值(右侧)。图中可以看到一条条能量带,不同频率下对应的能量带中包含轴承在某种故 障状态下的能量信息。

2.4.2 小波时频窗的面积不变性

南京航空航天大学

在小波变换法中,平移因子b确定频窗在时间上的平移,就确定了窗的不同位置。伸缩 因子a确定了时窗在频率上的位置。因此,可以通过控制参数a和b来控制窗的外形和位置。 图 2.8 即由参数a和b确定的窗函数图。



图 2.8 小波变换时频示意图

从上面的小波变换时频示意图可以看出,时窗和频窗在宽度上成反比。时间宽度变长时, 频率宽度会变窄。这种特性使得小波变换能够根据信号的频域和时域特点,在观察时间轴时, 同时兼顾频率轴的信息,避免了对信息的遗漏。

2.5本章小结

本章就所采用的三种图像生成方法进行了介绍,同时简要的就三种方法的优势进行了阐述。(1)矩阵图清晰地表现出对应元素之间的相关性,同时矩阵图中包括这信号的全部原始信息;(2)快速谱峭图通过寻找频率和频率分辨率的最佳组合,使谱峭度的值最大化。使用三分法作为原始信号的二维表示,对不同轴承转速形成可识别的模式;(3)小波时频图由于小波变换法中时频窗的适应性,使得其在信号的高低频部分都有很好的频率分辨率。

南京航空航天大学

第三章 卷积神经网络与故障预测

深度学习这个概念在 2006 年由 Hinton 提出后,在学术界很快掀起了一股浪潮。相比较 机器学习,深度学习拥有更强的特征提取的能力,能很好地构建从底层信号到高层特征的映 射关系。深度学习目前被广泛地应用在语音识别、图像识别和故障预测等领域。其中 CNN 作 为深度学习众多的模型中的一种典型,在故障预测领域有着很显著的成就。

3.1 卷积神经网络结构

卷积神经网络基本上是由输入层、卷积层、池化层、全连接层和输出层组成。其中输入 层即是完成卷积神经网络的数据输入,这里的数据一般指图像。卷积层和池化层组合互相辅 佐实现对数据特征的提取,卷积神经网络中一般含有多个池化层和卷积层,两者组合也称隐 含层,全连接层的任务是将卷积层和池化层提取到特征进行整理分类,输出层即将分类结果 进行输出。CNN 模型的基本结构如图 3.1 所示。



图 3.1 卷积神经网络基本结构图

3.1.1 卷积层

卷积神经网络中的卷积层主要利用卷积核对输入的图像数据进行卷积运算来提取特征。 其中卷积核使用的算法即卷积运算,卷积层的名称也因此得来,一般指的运算包括连续卷积 和离散卷积。因为卷积神经网络的输入的图像像素为间断的数据点,是离散的,所以这里所 采用到的运算是指离散卷积运算。

$$y(n) = x(n) * h(n) = \sum_{i=0}^{N-1} x(i)h(n-i)$$
(3-1)

其中 y(n)表示特征映射, x(n)表示输入的图像, h(n)表示卷积核函数。

在卷积神经网络里面,一般输入层的数据输入都是高维数据,而且经过一定优化算法获

得的卷积核也是高维数组格式。在卷积神经网络中,像这样的高维数据格式通常被称为张量。 因为进入到卷积核内部的各个因子是需要单独分开来进行存储,通常存储为一个稀疏矩阵, 所以在有限点集外都采用零进行填充。因此,能够利用稀疏矩阵中有限数组因子的和来代替 无限数组因子的和,完成计算。

(3-1)式是对一维卷积核而言,下面介绍的公式是对二维卷积核而言。假设*K*(*m*,*n*)为二维卷积核,*I*(*i*,*i*)为输入图像,两者卷积运算如下所示:

$$S(i, j) = (I^*K)(i, j) = \sum_{m} \sum_{n} I(m, n) K(i - m, j - n)$$
(3-2)

由于卷积运算具有可交换性,式(3.2)能够改写为:

$$S(i, j) = (I * K)(i, j) = \sum_{m} \sum_{n} I(i - m, j - n) K(m, n)$$
(3-3)

其中*m*,*n*代表卷积核的长和宽的大小。在卷积层中,需要考虑对卷积运算的特征结果 进行一个偏置,公式如下:

$$x_{j}^{l} = f(\sum_{i \in M_{j}} x_{j}^{l-1} * k_{i,j}^{l} + b_{j}^{l})$$
(3-4)

其中, x_{j}^{l} 为第1层(当前为卷积层)输出的第*j*个特征图,卷积层在输出前需要经过f(x)激活函数的计算, M_{j} 为输入的特征图,*为卷积数学符号, $k_{i,j}^{l}$ 为卷积核的权重矩阵。在卷积运算过程中,引入一个相应的偏置b对应相应的输出图,来提取输入图像的深层特征并尽可能保留信息,同时对其进行了去噪,使得到的特征更具有说服力,提高故障识别和分类的准确率。

3.1.2 池化层

卷积神经网络中的池化层主要目的是对卷积层产生的特征图进行降维。池化层可以降低 CNN 中特征图的参数数量,去除大多不重要的信息,还可以降低计算量,而且可以防止过拟 合的出现。池化层除了可以减少特征图的维度外,还具有模糊滤波器的作用,能够将经过卷 积层而输出的特征图进行二次特征提取。经过池化层后,特征图的大小会被缩减,但尺度不 变。

池化一般分为均值池化和最大值池化两种办法。均值池化是将池化窗口中的所有数值取均值输出。最大值池化是取窗口中的最大值进行输出。本文采用的池化操作是最大值池化,

毕业设计(论文)报告纸

因为最大值池化得到的结果与输入矩阵的位置无关,提高了结果对位移的鲁棒性。池化层的 公式如下:

$$x_{j}^{l} = f(\beta_{j}^{l} down(x_{i}^{l-1}) + b_{j}^{l})$$
(3-5)

其中, x_j^l 为l层(当前为池化层)输出的第j个特征图, down(x)为池化函数, 对于每个输出图都会有给定的b和 β_i^l 。

设池化尺寸为2×2,步长为2,最大值池化操作如图 3.2 所示:



图 3.2 最大值池化计算示例

3.1.3 全连接层

全连接层一般位于卷积神经网络最后一层池化层或者卷积层后,主要作用是把上一层输 出的特征矩阵转换为一维向量,方便网络分类。全连接层计算公式如下所示:

$$y^{k} = f(w^{k}x^{k-1} + b^{k})$$
(3-6)

其中, k表示第k层网络层, y^k 表示全连接层的输出, x^{k-1} 表示上一层的输出, 即全连接层的输入, w^k 表示权值, b^k 为偏置项。 f(x)表示分类函数, 这里本文采用的分类函数是目前最常用的 Softmax 函数。

3.1.4 激活函数

向卷积神经网络中引入激活函数能够使得网络中增加了非线性元素,弥补了由于卷积层 等都是线性计算而使神经网络不能满足非线性因素的表达的不足,增强了模型的分类能力。 常用的激活函数,有以下几种:逻辑回归(Sigmoid)函数、双曲正切(Tanh)函数以及校正 线性单元(ReLU)函数。其中 Sigmoid 函数表达式:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{3-7}$$

南京航空航天大学

Tanh 函数表达式:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$
(3-8)

ReLU 函数表达式:

$$f(x) = \begin{cases} 0 & x < 0 \\ 1 & x \ge 0 \end{cases}$$
(3-9)





图 3.3 三种激活函数图

由图像可以看出: 三种激活函数中, Sigmoid 函数极易饱和, 在处理输入远离坐标原点的 数据时, 其导数易接近于零, 梯度很小, 不利于权值的更新, 这会导致模型训练时出现问题。 Tanh 函数和 Sigmoid 函数曲线形状很相似, 同时可以看出收敛速度好于 Sigmoid 函数, 但同 样, 在处理输入远离坐标原点的数据时, 与 Sigmoid 函数面临同样的问题。相比较前两种函 数, ReLU 函数的线性特性不但可以加快网络的训练速度, 同时还避免了前两种函数因输入 绝对值过大时出现的梯度消失问题。因此, 本文采用 ReLU 函数作为故障预测模型的激活函 数。

3.1.5 Softmax 回归

Softmax 回归一般在全连接层之后,作为输出层,将全连接层的输出进行处理后,产生一

南京航空航天大学

个关于输入样本为某个类别的概率的向量。

将全连接层处理获得的一个一维向量y_i,再经过 Softmax 回归处理后为:

Soft max
$$(y_i) = \frac{e^{y_i}}{\sum_i e^{y_i}}$$
 (3-10)

Softmax 处理得到概率分布,可以通过损失函数进一步得到模型预测的概率与真实分布的概率之间的距离。这样从另一个角度观察模型分类能力的好坏。

3.1.6 损失函数

损失函数也可称代价函数,它是一个非负实数函数。在深度学习中,即通过最小化损失 函数求解和评估模型分类能力。这里介绍常用的几种损失函数,来比较分析并选择应用在本 文模型中。

(1) 0-1 损失函数(0-1 Loss Function)

此函数可以很直观的展现模型预测的错误率。

$$L(y, f(x, \theta)) = \begin{cases} 0 & \text{if } y = f(x, \theta) \\ 1 & \text{if } y \neq f(x, \theta) \end{cases} = I(y \neq f(x, \theta))$$
(3-11)

其中I(·)表示指示函数。

虽然 0-1 损失能够客观的评价模型的好坏,但缺点是数学性质不是很好:不连续且到数 为 0,难以优化。所以很难应用于 CNN 模型中。

(2) 平方损失函数(Quadratic Loss Function)

此函数经常用在预测标签 y 为实数值的任务中。

$$L(y, f(x, \theta)) = \frac{1}{2} (y - f(x, \theta))^2$$
(3-12)

这里可以看出,其表示预测值与实际值差的平方,所以一般不适用于分类问题。

(3) 交叉熵损失函数(Cross-Entropy Loss Function)

其一般适合用在分类问题中,公式如下:

$$L(y'_{i}, y_{i}) = -\sum_{i} y'_{i} \log(y_{i})$$
(3-13)

其中 y_i表示预测分布, y_i表示输入样本为第i种类别的预测概率; y_i表示真实分布值, 由 公式可以看出交叉熵能够很好的表达预测与真实之间的距离。这里以交叉熵作为损失函数与

南京航空航天大学

Softmax 计算结和应用。

3.2 卷积神经网络故障预测流程

上一节对卷积神经网络的卷积层、池化层、全连接层、激活函数、Softmax 回归以及损失 函数作了一定的介绍。本节将对基于卷积神经网络的故障预测流程进行介绍。下面介绍滚动 轴承预测模型和故障预测(图像识别)的进行流程。

3.2.1 滚动轴承故障预测模型

本文构建的卷积神经网络包括: 4 个卷积层, 4 个池化层和 1 个全连接层。输入图像大小为150×150×3, 其中前两位参数代表图像大小, 第三位参数代表图像像素的灰度级。采用的是最大值池化, 激活函数为 ReLU, 批量大小 batchsize=128, 迭代次数 k=50。CNN 模型结构如图 3.4 所示:



图 3.4 卷积神经网络结构图

其参数如表 3.1 所示:

表 3.1 CNN 模型的参数									
层名称	C1	P1	C2	P2	C3	P3	C4	P4	F
卷积核	5×5	2×2	5×5	2×2	5×5	2×2	5×5	2×2	1×1
数量	32	32	64	64	128	128	128	128	512

一般卷积层的卷积核大小为2×2、3×3、4×4、5×5、....、10×10,从表 3.1 中可以看 到本文卷积层的卷积核大小选用的为5×5。这里通过对比不同卷积核对 CNN 模型的训练错误 率的影响进行了分析整合,分析结果在图 3.5 中给出。



图 3.5 卷积核大小的影响

由图 3.5 中的结果得到,模型训练错误率随着卷积核的增大而降低,直到卷积核为5×5时, 错误率达到最低 0.21,当卷积核大小超过 5×5继续增加时,模型训练错误率反而增加。所以, 论文的 CNN 模型卷积层中卷积核大小采用 5×5。

3.2.2 滚动轴承故障预测流程

滚动轴承故障预测进行步骤如下:

1).运用加速度传感器获取滚动轴承处于不同状态下的振动信号;

2).在 Matlab 环境下,分别采用矩阵法、快速谱峭图法、小波变换法将采集到的振动信号 处理为矩阵图、快速谱峭图、小波时频图,为 CNN 模型做准备;

3).将第二步处理好的数据每种图像样本按照 8:2 的比例分为训练样本集合测试样本集;

4).将训练样本集输入 CNN 模型后,模型通过不断学习,优化更新网络参数,以达到最 准确的分类结果;

5).待模型训练完成后,把测试样本集作为输入应用到训练完成的模型中,输出测试结果, 完成滚动轴承故障预测。

图 3.6 和图 3.7 给出了基于卷积神经网络的滚动轴承故障预测流程框图和 CNN 内部构造图:



图 3.6 故障预测流程框图

图 3.6 中①和代表步骤进行顺序: ①先②后, ①表示模型训练, ②表示模型测试。



CNN模型内部

图 3.7 CNN 模型内部构造图

第四章 基于 CNN 的滚动轴承故障预测

4.1 基于美国凯斯西储大学轴承数据的滚动轴承故障预测

本实验数据来自美国西储大学 bearing data center 网站提供的滚动轴承数据。其中包括正常的轴承数据和故障轴承数据。实验平台如图 4.1 所示。



图 4.1 西储大学轴承实验平台

由图 4.1 所示,实验台由两马力的电机(左侧),转矩传感器(中间),功率计(右侧) 以及相关电子控制设施(图上未标出)组成。这里经过人工加工的措施在轴承上加工单点故 障,来得到轴承故障数据,故障部位加工直径分别为7密耳、14密耳、21密耳(1密耳=0.254 毫米)。轴承型号:SKF6205。实验中,将测试轴承安装在电机轴上,加速度传感器安装电机 壳上的驱动端和风扇端,通过加速度传感器获取轴承振动信号,并且在 Matlab 中进行处理。 数字信号的采样频率 12kHz,驱动端采样频率 48kHz。

由于借用西储大学数据作为媒介,因此本文选择使用驱动端轴承振动信号,其中包括正常和故障数据。将其分成 10 种状态,分别为正常和滚动体在故障加工直径为 7 密耳、14 密耳、21 密耳,转速为 1730rpm、1750rpm、1772rpm 三种转速下的状态。由于正常情况下数据相对较多,这里将正常数据分为 960 个样本,其余的每种状态的数据分成 240 个样本,共组成 3120 个样本。对选取的数据使用第二章提到的三种方法进行处理后,得到 10 种状态模式

南京航空航天大学

毕业设计(论文)报告纸

下的三种图像。如图 4.2 至图 4.4 所示。



图 4.2 至图 4.4 中,从上到下,从左到右为故障一、二、三、四、五、六、七、八、九和

毕业设计(论文)报告纸

正常情况。图中的子图(a)-(j)依次对应损伤直径为7密耳、14密耳和21密耳情况下转速(rpm) 为 1770、1750、1730,加上正常情况。从图 4.2 至图 4.4 中能够看出,不管哪种图像类别,都能够看出不同故障之间存在着差别。但是如果仅仅靠人的眼睛来分辨这些图像的话,那么 图像之间的很多细节,往往会被忽略掉,费时费力,不符合目前社会发展的低经济,高效率 的要求。因此,下面通过引入卷积神经网络采用故障预测,代替人工分辨,来分辨哪种数据 图像在故障预测中能够取得好的效果。将分好的训练样本作为 CNN 的输入,得到预测结果并并对结果进行对比分析。实验结果如图 4.5 至图 4.11 所示,其中包括故障预测训练过程和验 证过程的分类准确值以及损失值,其中 Training acc 代表样本训练过程的故障识别率, Validation acc 代表样本测试的故障识别率, Training loss 代表样本训练过程的损失值,







图 4.6 矩阵图的损失函数图

毕业设计(论文)报告纸











图 4.9 小波时频图的识别效果图



图 4.10 小波时频图的损失函数图



图 4.11 三种方法预测分类结果

通过上面结果可以看出,三种方法都随着迭代次数的增加,各组训练精度和测试精度的 误差都在下降,预测分类精度在不断上升,小波时频图分类结果最好,达97%左右,矩阵图 和快速谱峭图结果相近在85%左右浮动,结果相差不大。从图4.6、图4.8和图4.10三种方法 各自的损失值,同样可以看出,小波时频图的损失值最小,对应训练误差和测试误差最小, 也能够证明小波时频图方法效果最好。由图4.11中看出,矩阵图在分类过程中,速度最快达 到稳定;小波时频图分类结果精度最高,在验证过程中虽然小波时频图结果精度较其他两种 方法振荡剧烈。但总体来说,小波时频图结合卷积神经网络在西储大学数据基础下滚动轴承 故障预测分类结果最好,下面我们将小波时频图方法应用于第二个实验,一来验证本方法的

南京航空航天大学

毕业设计(论文)报告纸

有效性,二来为航空发动机的实际应用找到一种较为理想的方法。 4.2 基于带机匣的航空发动机数据的滚动轴承故障预测

4.2.1 实验内容及结果分析

本实验采用数据来源于南京航空航天大学 IDES 研究室,在带机匣的航空航天发动机转 子实验台上通过传感器采集到的轴承数据,该设备以某某型号航空发动机为原型,由中航工 业 606 研究所按照 1:3 缩小设计制造。本实验采用的设备具有某某型号航空发动机的相似结 构,能够有效的模拟真实航空发动机上滚动轴承振动信号经传递路径的衰减过程。设备实物 图和剖面图如图 4.12 所示。



图 4.12 设备实物图 (左)和设备剖面图 (右)

为了验证实验一中得到的结果,实验二采用 6206 单列深沟球轴承,利用电火花线切割加 工方式在 6206 轴承的滚动体表面加工一个半径约 0.5mm,深度为 2mm 的柱型凹坑,用来模 拟滚动体损伤所产生的冲击;分别在外圈和内圈表面加工一条宽约 6mm 的裂痕,用来模拟轴 承滚动表面损伤所产生的冲击,加工的故障图如图 4.13 所示,将它们安装在转子实验台上进 行实验。轴承的基本尺寸和参数如表 4.1 所示。



外圈故障

内圈故障

滚动体故障

图 4.13 6206 型轴承加工故障后的实物图

毕业设计(论文)报告纸

表 4.1 6206 型单列深沟球轴承轴承基本尺寸									
型号	滚动体直径	外圈直径	内圈直径	节径/mm	滚珠数/个	接触角/(°)			
	/mm	/mm	/mm						
6206	9.5	62	30	46	9	0			

本实验中,将测试轴承(正常、滚动体故障、外圈故障、内圈故障)安装在转子实验台上, 通过 B&K4805 加速度传感器收集振动信号,图 4.14 中给出了传感器安装位置。通过 NI USB9234 数据采集卡进行采集不同转速下振动信号,转速分别为 1500、1800rpm,采样频率 为 10240Hz。





图 4.14 B&K4805 加速度传感器安装位置图

图中传感器位置(测点位置)机匣上方为 CH1,机匣下方为 CH2,机匣左侧为 CH3,机 匣右侧为 CH4,其中包括转速测点位置。

这里分别在垂直方向和水平方向随机选取一个测点进行下面的实验。本实验分别在两种转速下(1500rpm、1800rpm)两种测点位置测得的数据进行处理。实验方法如下表 4.2 所示。

序号	转速(rpm)	轴承状态	测点位置	
1	1500	正常、滚动体故障	CH1	
		外圈故障、内圈故障	CH4	
2	1800	正常、滚动体故障	CH1	
		外圈故障、内圈故障	CH4	

表 4.2 实验二数据处理方案

对应表中四种轴承状态,每 1024 个数据为一个样本,除正常状态下每种轴承状态下含 490 个样本,正常状态下 700 个样本,这样每个测点共组成 2170 个样本。对处理好的样本使

毕业设计(论文)报告纸

用第二章提到的三种方法进行处理后,得到两种测点下四种状态下的矩阵图、快速谱峭图、 小波时频图。如图 4.15 至图 4.17 所示(下面以机匣上方测点 CH1 转速为 1500rpm 情况下为 例)。



图 4.17 小波时频图样本

图中(a)、(b)、(c)、(d)分别对应正常、外圈损伤故障、内圈损伤故障、滚动体损伤 故障四种轴承状态。在快速谱峭图和小波时频图中的颜色分别代表谱峭度和能量值大小。在 上面每种样本图中,都能看出四种状态的不同。下面结合本文建立的 CNN 模型,一方面验证 实验一给出的结果是否正确,一方面测试小波时频图在处理微弱的带机匣的航空发动机上的 轴承数据时的故障预测的准确度是否适用。下面给出不同处理方法的卷积神经网络的结果。

南京航空航天大学

毕业设计(论文)报告纸

同一测点下不同转速的滚动轴承故障预测结果,如图 4.18 至图 4.21 所示。



图 4.18 CH1 测点 1500rpm 下故障预测结果



图 4.19 CH1 测点 1800rpm 下故障预测结果



图 4.20 CH4 测点 1500rpm 下故障预测结果



图 4.21 CH4 测点 1800rpm 下故障预测结果

下面为了观察本文采用的方法的鲁棒性,将相同测点位置测得不同转速下四种状态数据, 进行混合处理。将 1500rpm 和 1800rpm 转速下的样本按照 8:2 的比例分为训练集和验证集, 再将不同转速同种状态的训练样本混在一起作为新的测试样本,将不同转速同种状态的验证 样本混在一起作为新的验证样本。新训练样本数为 3472,新验证样本数 868。滚动轴承故障 预测的结果如图 4.22 和图 4.23 所示。



图 4.22 CH1 测点全转速对比结果





表43	不同方法的准确值
12 4.5	

方法	准确值							
15000000-01		1900 CIII	1500	1000	全转速	全转速	亚均齿	
	1500rpm-CHI	1800rpm-CHI	1500rpm-CH4	1800rpm-CH4	-CH1	-CH4	十均沮	
矩阵图	92. 5%	84.8%	85. 3%	84.7%	89.3%	88.1%	87.5%	

南京航空航天大学

毕业设计(论文)报告纸

表4.3 (续)

快速谱	91 5%	87 9%	80.3%	88 6%	90.7%	87.6%	80.3%
峭图	51.5%	01. 5%	05.5%	00.0%	50.1%	01.0%	03. 5%
小波时	06 1%	05 2%	05 0%	05.2%	06.2%	04 0%	05 2%
频图	90.1%	95.2%	95.0%	95.2%	90.2%	94.0%	90. 3%
SVM	90.4%	89.7%	93.2%	91.1%	86.1%	84.7%	89.2%

观察滚动轴承故障预测的结果图 4.18 至图 4.23 和表 2 结果来分析,相同测点情况下,矩 阵图法和快速谱峭图法所得到的故障预测准确度都会随着转速的增加而降低,其中矩阵图最 低,平均水平只有 87.5%;同时在这里可以看到,小波时频图方法在三者中预测分类精度随 着转速的增加,此方法的故障预测准确度依旧很理想,平均达到 95.3%。相同转速下,单单 只观察一种方法,可以发现矩阵图在垂直方向上比水平方向分类精度稍微好一点;快速谱峭 图在垂直方向上比水平方向上分类精度高出大约 3 个百分点;而小波变换构造时频图的方法 相较于其他两种方法,平均准确率有很明显的优势,而且不同方向不同转速下分类准确度差 别很小,分类精度稳定。在不同测点处不同转速下结合准确率的平均值来看,矩阵图相对来 说效果不好,快速谱峭图分类精度其次,小波时频图效果稳定且最好。而且由于全转速情况 下的样本数较单测点单转速情况下的样本数有所增加,从结果图中纵向比较,全转速下的结 果精度在随着迭代次数的增加而增加,相邻迭代次数之间,振荡减小,变得平稳,能够说明 样本数的增加和迭代次数对实验结果有一定的好处。通过与传统机器学习分类方法 SVM 比 较,可以看出虽然在单个测点转速下,SVM 分类效果相对矩阵图和快速谱峭图较好,但是在 面对多转速情况时,SVM 分类精度有很大幅度下降,与深度学习的方法有着一定差距。通过 SVM 的引入,进一步说明了本文采用的方法的鲁棒性。

南京航空航天大学

第五章 总结与展望

5.1总结

本文通过矩阵图法、快速谱峭图法和小波变换法三种数据处理方法来构造矩阵图、快速 谱峭图、小波时频图三种数据图像,结合卷积神经网络的图像识别功能,通过使用美国凯斯 西储大学公开的滚动轴承数据来比较三种数据处理方法结合 CNN 的分类准确率,找到基于滚 动轴承振动信号的故障预测分类精度较高的模型,进而应用到对带机匣的航空发动机滚动轴 承振动信号数据的故障预测。

在本文中关于美国西储大学的轴承数据第一个实验中,可以发现小波变换法构造时频图 结合 CNN 模型的分类进度最高,准确率在 97%左右。

在基于带机匣的航空发动机的滚动轴承数据实验中,可以发现该方法同样有很好的预测 分类准确率,最高在 96.5%,最差也在 94.0%,平均在 95.3%。同时在此实验中,进行的不同 测点全转速样本预测分类中,依旧有着很高的准确率,可以发现此方法在面对不同工况时, 有着很好的识别效果,能够清楚地分辨故障结合与传统机器学习方法 SVM 的比较,一方面 验证了此方法的鲁棒性,另一方面说明了其具有一定的泛化能力。

5.2展望

本文通过使用卷积神经网络预测小波变换构造的时频图的研究过程中,虽取得了一定的 效果,然而限于作者的工作时间以及知识水平,论文还存在一些需要提高的地方。下面针对 文中的不足和未来对故障预测领域做出一些展望。

(1)卷积神经网络在建造时中,需要不断的调节大量参数,例如:卷积核大小、数量, 输入图片的大小,学习率的选择等等。参数都是根据不断试验得到的结果好坏进行修改的, 限于硬件的条件,每次试验都需要花费一定的时间,因此这需要研究人员的丰富经验和花费 大量时间。未来能够找到一定方法,简化这一工作,可以为研究工作者节约宝贵时间,加快 研究进度,提高工作效率。

(2)航空发动机运行环境极端杂乱,轴承信号成分复杂,虽然小波变换构造时频图结合
 本文建立的卷积神经网络取得了较好的效果,但是就其泛化能力而言,还存在一定的不确定
 性,需要后续建立更多不同领域的滚动轴承数据,进行验证。

毕业设计(论文)报告纸

(3) 在论文中的第二个实验中,快速谱峭图虽然在处理带机匣的航空发动机轴承信号时,最 后得出的结果不是很理想,平均水平仅有 89.3%,但根据之前的给出样本图,可以发现快速 谱峭图对每种状态都形成了可识别的模式,具有清晰的分辨效果,而且和 SVM 的分类结果 平均值计较,快速谱峭图的准确率平均值略高。因此快速峭度图法结合卷积神经网络实现故 障预测存在着极大的提升空间。

南京航空航天大学

参考文献

- [1] 中华人民共和国国务院. 中国制造[M]. 2025. 北京: 中华人民共和国国务院, 2015.
- [2] 基于卷积神经网络的胶印机滚动轴承故障诊断方法研究[D]. 西安理工大学, 2018.
- [3] 姚瑞琦. 基于信息熵的直升机自动倾斜器滚动轴承故障诊断方法研究[D]. 2017.
- [4] 梅宏斌. 滚动轴承振动监测与诊断[M]. 机械工业出版社, 1995.
- [5] Feng Z, Liang M, Chu F. Recent advances in time frequency analysis methods for machinery fault diagnosis: A review with application examples[J]. Mechanical Systems & Signal Processing, 2013, 38(1):165-205.
- [6] Hlawatsch F, Boudreaux-Bartels G F. Linear and quadratic time-frequency signal representations[J]. IEEE SIGNAL PROCESSING MAGAZINE, 1992, 9(2):21-67.
- [7] Hess-Nielsen N, Wickerhauser M V. Wavelets and time-frequency analysis[J]. Proceedings of the IEEE, 1996, 84(4):523-540.
- [8] Mallat S. A Wavelet Tour of Signal Processing, Third Edition: The Sparse Way[M]. Academic Press, 2008.
- [9] Kay S M, Jr S L M. Spectrum Analysis A Modern Perspective[J]. Proceedings of the IEEE, 1981, 69(11):1380-1419.
- [10] Chaturvedi G K. Bearing Fault Detection Using Adaptive Noise Cancelling[J]. Journal of Mechanical Design, 1982, 104(2):280-289.
- [11] Ho D, Bearing Diagnostics and self adaptive noise cancellation[D]. Sydney: University of New South Wales.
- [12] Antoni J, Randall R B. Unsupervised noise cancellation for vibration signals: part I—evaluation of adaptive algorithms[J]. Mechanical Systems & Signal Processing, 2004, 18(1):89-101.
- [13] Mcfadden P D. A Model for the Extraction of Periodic Waveforms by Time Domain Averaging.[J]. Mechanical Systems & Signal Processing, 1987, 1(1):83-95.
- [14] Braun S. The synchronous (time domain) average revisited[J]. Mechanical Systems & Signal Processing, 2011, 25(4):1087-1102.
- [15] 袁静, 何正嘉, 王晓东, et al. 平移不变多小波相邻系数降噪方法及其在监测诊断中的应用[J]. 机械工 程学报, 2009, 45(4):155-160.
- [16] [15] Antoni J, Randall R B. The spectral kurtosis: application to the vibratory surveillance and diagnostics of rotating machines[J]. Mechanical Systems & Signal Processing, 2006, 20(2):308-331.
- [17] 孟涛, 廖明夫. 利用时延相关解调法诊断滚动轴承的故障[J]. 航空学报, 2004, 25(1).
- [18] 明安波, 褚福磊, 张炜. 滚动轴承故障特征提取的频谱自相关方法[J]. 机械工程学报, 2012, 48(19):65-71.
- [19] 胥永刚, 崔涛, 马朝永,等. 基于 LCD 和 Teager 能量算子的滚动轴承故障诊断[J]. 北京工业大学学报, 2015, 41(3):340-346.
- [20] 时文刚, 刘树林, 张嘉钟,等. 基于支持向量机的往复泵泵阀故障诊断方法[J]. 机械强度, 2002, 24(3):362-364.
- [21] 余凯, 贾磊, 陈雨强,等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9):1799-1804.
- [22] 刘炳集. 基于时频图和 CNN 的直升机自动倾斜器滚动轴承故障诊断方法研究[D].
- [23] 陈伟, 陈锦雄, 江永全,等. 基于 RS-LSTM 的滚动轴承故障识别[J]. 中国科技论文, 2018, 13(10):51-58.
- [24] 杨秋英, 陈卉. 带偏差单元递归神经网络齿轮箱故障诊断[J]. 现代电子技术, 2013(20):33-37.

- [25] Tamilselvan P, Wang P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115(7):124-135.
- [26] 李巍华, 单外平, 曾雪琼. 基于深度信念网络的轴承故障分类识别[J]. 振动工程学报, 2016, 29(2):340-347.
- [27] Chen L, Wang Z, Zhou B. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification[J]. Advanced Engineering Informatics, 2017, 32:139-151.
- [28] 错误!未找到引用源。..
- [29] 王为人.QC 新七大工具之五:矩阵图法[J].中国卫生质量管理,2018,25(06):135-137.
- [30] 蔡艳平, 李艾华, 石林锁, et al. 基于 EMD 与谱峭度的滚动轴承故障检测改进包络谱分析[J]. 振动与冲击, 2011, 30(2):167-172.
- [31] Vrabie V, Granjon P, Serviere C. Spectral kurtosis from definition to application[M]. Grado, Italy:IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing 2003.



致 谢

时光匆匆,岁月静好。大学四年时光闭上眼,感觉就在眼前,论文是我在就读南京航空 航天大学本科期间学习和研究的工作总结,从选择毕设题目开始,再到设计研究实验,最后 到总结完稿,这个过程中受益于指导老师陈果和学长张向阳的宝贵指导和热情帮助。

首先感谢陈果老师对我的毕业设计的悉心指导,陈果教授渊博的学识、严谨的科研态度、 务实的工作作风深深地影响了我。在整个毕业设计过程中,陈果教授对我严格要求、认真负 责,在每次组会讨论中都让我感到收获很多。

感谢张向阳和贺志远学长的耐心指导和技术支持,在毕业设计过程中,在遇到困难时, 学长们给我的鼓励,帮助我继续努力研究。

感谢班主任孙见忠老师在学习中和生活上的教导和帮助,感谢顾铮老师学习的引导,激 起了我对专业的学习兴趣。

感谢民航学院领导丁萌书记的关心和理解,感谢辅导员张秋寒老师的支持和帮助,我大 学的好多重大抉择都得益于他们的教导,他们既是我的良师又是我的益友。

感谢室友刘梓轩、岑益挺、田志宇四年来的陪伴和包容,让我在南京航空航天大学的四 年中拥有快乐的时光。感谢费航、郎玺博等班级同学和周围的朋友朱广均的热心帮助,大学 时光一路走来,愿友谊长存,天长地久。

感谢我伟大的父母,除了养育之恩和物质支持,更感谢他们对我精神上的理解、鼓励和 支持,我会用实际行动去报答他们。愿天下所有父母身体健康。

作为中共预备党员的我,感谢党的领导与教育,给了我在这个和平富裕的年代,能够自 由发展的机会。

谨以此论文作为对所有帮助我的亲人、老师和朋友们的感谢,在此我向你们致以最真挚 的问候,祝愿大家万事如意、身体健康。

最后,在这里向能够在百忙之中抽出时间来批阅论文的专家老师们献上我最真诚的致谢!