

## 摘 要

刀具切削状态的有效监测是先进制造技术中的关键技术之一，对于推进切削加工自动化与无人化的过程具有十分重要的意义。直接测量与刀具体积有关参数的方法无法满足在线实时监测的要求，因此测量反映刀具磨损、破损影响程度各种参数的间接方法成为目前国内外研究和应用的重点。但由于刀具监测中存在切削加工条件的多样性、切削参数的多变性、刀具磨钝的随机性、模糊性和监测信号单调性的矛盾，为了提高刀具失效监测的可靠性和准确性，人们提出了多传感器信息融合的刀具状态监测技术。

本文结合监测系统三大部分，即信号检测、特征提取、状态识别，进行基于多传感器信息融合的刀具状态监测研究：选择对刀具磨损反应敏感的切削力信号和振动信号作为检测对象；根据信号的特点，分别在时域、频域和时频域对检测到的信号进行分析和信号特征提取；以神经网络模型实现多传感器信息融合，对刀具状态进行识别决策，构造出在单一工况和多工况条件下进行刀具状态监测的系统。

实验数据表明，不同程度磨损的刀具在切削过程中产生的切削力信号和振动信号具有明显的差异，因此这两种信号可以作为监测信号反映刀具磨损的情况。同时，在不同的工况下，这两种监测信号对刀具磨损反应的敏感度不一样，因而采用多传感器信息融合的方式进行刀具状态监测具有更高的准确性。在信号特征提取方面，针对信号的不同特性采用不同信号处理方法。对于切削力，其功率谱比较集中，可用傅立叶变换的方法把时域信号转换成到频域上进行功率谱分析；对于振动信号，由于其功率谱比较分散，难以在时域或纯频域内提取其特征值，本文用小波包分解的方法，把时域信号分解成不同频域段对应的子信号，从这些子信号中选择最大程度上反映刀具磨损的组合作为研究对象，再对这些组合进行特征提取。神经网络是一个具有高度非线性的超大规模的连续时间动力系统，具有大规模并行处理能力，而且具有很强的鲁棒性、容错性、自学习性，因此基于神经网络技术所建立的监测系统能快速适应变化的环境，实现智能决策。然而传统的BP神经网络并不是一个十分完善的网络，它存在着的一些诸如学习速度较慢，在学习过程中出现局部收敛等缺陷使其应用受到限制。文中通过调整网络结构、在可调节参数的调整公式中引入动量项、在学习过程中采用变学习率和最小误差保留策略等优化学习算法加速神经网络学习速度，改善其收敛性。并就传统BP网络和小波神经网络的学习效果作实例对比。在实际刀具监测模型的构造中，对于单一工况条件下的刀具监测系统，比较了以单一传感器检测信号和采用多传感器信号建立刀具磨损监测模型在各种工况条件下的刀具识别性能，从神经网络的输出效果和监测信号对刀具磨损反应的敏感性两方面论证了采取多传感器信息融合建模

的必要性；至于多工况条件下的刀具监测，提出了基于正交工况条件实验数据的刀具监测系统建立方案，按照这一方法建立的刀具监测模型具有对刀具磨损程度识别的有效性和对工况条件的扩展性。

最后给出了本课题的主要结论，并就有关问题提出改进方案和展望。

**关键词：**刀具状态监测；信息融合；小波分析；神经网络

## Abstract

Tool condition effective monitoring is the key technology in the advanced manufacture system, which plays an essentially important part in automatic processes. The degree of the tool wear can be gotten by measuring the parameters relating to the volume of the cutting tool, but this method can't satisfy the requirements of on-line monitoring. So researchers, internal or external, focus on the other methods using sensor signals to monitor the cutting tool wear during the machining process. Due to the multiplicity of the machining condition, the variability of the cutting parameters, the randomness of tool wear, using single sensor signals to monitor the condition of cutting tool is often fallibility, so the concept of sensor fusion is put forward.

Combining with three parts of the monitoring system (signals acquirement, feature extraction and condition identification), this paper carries out the research of the cutting tool wear monitoring based on the sensor fusion as follow. Firstly, select the cutting force and cutting vibration signals which are sensitive to tool wear as the monitored signals. Then according to the features of the monitored signals, analyze them and process feature extraction. Finally, identify the condition of the tool, build up the tool condition monitoring system to perform the tool wear monitoring under single cutting condition or multiple cutting conditions.

The data show that cutting force signal and cutting vibration signal of different tool wear are different each other, which means that these two kinds of signals can be used to monitor the wear of cutting tool. However, these two kinds of sensor signals have different sensitivity to the tool wear, so it would be better to build up the tool wear monitoring system using sensor fusion. As for the feature extraction of sensor signals, because of different character of the sensor signals, different methods of data processing should be used. Take the cutting force signal for example, its power spectrum is relative concentrative, it can be transformed from the time domain to the frequency domain to analyze its power spectrum. While the cutting vibration, for its power spectrum is relative dispersive, it is difficult to get its characteristic values either in the time domain or in the frequency domain. This paper, using the method of wavelet packet

decomposing, decomposes the vibration signal into different channel results and then picks out the certain channel results that reflect the tool wear evidently to process feature extraction. Neural network is a non-linear continuous dynamic system, which have the ability to carry out parallel processing of vast information and has the character of robusticity, fault tolerance ability and self-studying ability. So tool condition monitoring system based on neural network can rapidly adapt to the circumstance and realize the tool wear intelligent identification. BP neural network is the neural network widely used, but it is not the perfect one. There are some problems in BP neural network such as low learning velocity, local convergence and so on. To improve the performance of traditional BP neural network, this paper introduce some methods such as adjust the structure of neural network, add the momentum unit to the adjustment formula of adjustable parameters, adopt alterable learning rate and strategy of reserving the least error. To be further, use some examples to compare the learning result of traditional BP neural network with that of wavelet neural network. There are two kinds of tool wear monitoring models discussed in this paper, for single cutting condition and for multiple cutting conditions. In the first one, the paper compares the identification ability of the model that uses only one sensor signal to build up with the one that uses multiple sensor signals, draws the conclusion from the comparison result that using sensor fusion to build up the monitoring model is meaningful. As for the second one, put forward the modeling method based on orthogonal experimental data. Tool wear monitoring model for multiple cutting conditions using such method to build up has validity for the identification of tool wear and expansibility for other cutting condition.

At last, some primary conclusions of this paper are given and perspective of the future development in tool condition monitoring is put forward.

**Key words:** tool condition monitoring; sensor fusion; neural network; wavelet analysis

# 华南理工大学

## 学位论文原创性声明

本人郑重声明：所呈交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本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。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律后果由本人承担。

作者签名：邵志伟

日期：2003年5月20日

## 学位论文授权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校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。本人授权华南理工大学可以将本学位论文的全部或部分内  
容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存  
和汇编本学位论文。

保密口，在 \_\_\_\_\_ 年解密后适用本授权书。

本学位论文属于

不保密口。

(请在以上相应方框内打“√”)

作者签名：邵志伟

日期：2003年5月20日

导师签名：

姚锡凡代 日期：2003年5月20日

# 第一章 绪论

加工状态监控是保证自动化加工顺利进行的重要技术,在先进制造技术中占据重要地位,自从本世纪 50 年代,各个国家都开始研究该课题<sup>[1]</sup>。在自动化加工中,最为常见的故障便是刀具状态的变化,因此刀具状态监测是加工过程监控最为重要最为关键的技术之一。研究表明,数控系统配置刀具监测仪后可减少故障停机时间的 75%,提高生产率 10%~60%,提高机床利用率 50%以上;美国 Kennametal 公司的研究表明,刀具监测系统不仅提高了刀具本身的利用率,而且可避免刀具失效所导致的工件报废及机床故障,能节约费用达 30%。目前,刀具监测技术已成为各国公认的重大关键技术,受到极大的重视<sup>[2-3]</sup>。

## 1.1 刀具监测技术概况

多年来,人们在刀具监测技术上做了大量的工作,开发出不少新的检测方法,有些已经用于生产。日本、美国、德国及瑞典等在刀具监测技术方面处于领先地位,拥有一批成果及专利,并有产品面市<sup>[6-9]</sup>。

对于不同的加工过程及刀具切削状态,相应地出现了许多不同种类的检测方法,总的来看检测方法可分为直接法和间接法。

直接法是测量与刀具体积有关的参量,一般只能在刀具不切削时进行。因而有两个明显的缺点:(1)要求停机检测,占用生产工时;(2)不能检测出加工过程中出现的刀具突然损坏,其应用受到了一定的限制。

而间接法是测量反映刀具磨损、破损的各种影响程度参量,如电机功率、切削力、振动、声发射等,能在刀具切削过程中检测,不影响切削加工过程,其关键技术在于如何剔除检测中各种干扰影响,提取出特征信号,是目前国内外研究和应用的重点。

近年来,刀具监测系统开发应用有如下特点<sup>[10]</sup>:

### 1. 监测技术开发的重点已趋于集中:

在多种多样的监测方法中,重点开发和应用刀具实时监测技术及系统发展较快,应用较普遍。

### 2. 普遍扩展了系统的监测功能

从 80 年代初投入市场的监测系统到 80 年代中期都扩展了功能,如瑞典 Sanvik 公司将单通道刀具监测仪(TM-SU-1001 型)扩展为 6 通道监测仪(TM-BU-1001 型),并增加存储容量,可存储多达 999 个不同切削工艺参数。

### 3. 致力于提高监测可靠性

由于切削加工中的时变因素多，随机性大，特别是工件、刀具材料不一致性以及随机的突发误动作，因此在开发具有实时监测系统的同时，都十分重视研究、开发高可靠性的监测技术。

#### 4. 主机系统交联

该工作是以监测系统开发单位为主与NC系统开发单位合作进行。一种方法是研制可实现通讯的交联接口；另一种方法是采用模块式结构，与NC系统一体化。基于国际上NC机床发展很快，对于监测系统的要求之迫切性增大，国外专家曾对未来生产模式及其监测系统作过种种预测，其中共性之一就是要适应NC加工和柔性自动化生产发展的需要。

### 1.2 一般加工过程监测系统的组成<sup>[14]</sup>

机械加工过程是一个复杂的物理、化学过程，对加工过程的在线监测涉及很多相关技术，如传感器技术、信号处理技术、计算机技术、人工智能技术以及切削机理。

一般的加工过程监测系统由信号检测、特征提取，状态识别三部分组成，如图 1-1 所示：




图 1-1 监测系统的一般组成

Fig 1-1 General constitution of tool condition monitoring system

#### 1.2.1 信号检测

信号检测是监测系统的首要一步，加工过程的许多状态信号从不同角度反映加工状态的变化。可见信号检测直接决定监测系统的成败。加工过程中常见的被检测信号包括：切削力、切削功率/电流、声发射信号(AE)、振动信号、切削温度、切削扭矩等。一般要求监测信号应具备迅速准确地反映加工状态的变化，便于在线测量，不改变加工系统结构，被检测信号受影响因素少，抗干扰能力强等特点。

## 1.2.2 特征提取

特征提取是对检测信号的进一步加工处理,从大量信号中提取出与加工状态变化相关的参数,一方面可以提高信号的信噪比,另一方面可以减少后期数据的处理量,提高运算速度。目前采用的方法主要有时域方法(均值、差值、相关系数、导数值等)、频域方法(FFT、功率谱等)和时频分析方法(短时FFT、维格分布、小波分析)。提取特征参数的品质对监测系统的性能和可靠性具有很重要的影响作用。

## 1.2.3 状态识别

状态识别实质上是通过建立合理的模型,根据所获取的特征参数对加工过程的状态进行分类判断。从数学角度来理解就是建立特征参数与加工过程状态的映射。当前采用建模的主要方法有统计方法、模式识别、专家系统、模糊推理判断、神经网络等。

# 1.3 加工过程智能监测关键性技术

## 1.3.1 智能传感器技术

在加工过程状态监测中,传感器主要是把切削过程的物理量(如切削力)转换成电信号,便于后一阶段的处理。因此要求采集到的电信号必须如实准确反映加工过程状态信息。其次,传感器要与机床配套使用,满足在线检测的需要,要求传感器安装简单易行,抗干扰能力强。

传统单一的传感器技术很难准确地反映切削状态,向多传感器发展是必然结果。多传感器能反映切削过程多方面的信息,更完整地表现事实的全貌<sup>[12]</sup>。

## 1.3.2 信号处理技术

信号处理技术是加工过程状态检测技术的核心技术,通过对采集到的信号分析处理,获取信号的特征值,然后对特征值进行决策分析最终达到监测的目的。

用于加工过程监测的信号处理方法极为丰富<sup>[13-16]</sup>,传统加工过程监测系统中所采用的信号处理技术多集中在时域、频域的统计分析。近十年来信号处理技术向时频分析和智能技术方向发展,尤其是时频分析成为信号分析的主流。时频分析方法主要包括维格分布技术和小波分析技术。维格分布的主要特性在于变换后具有定义域同一性,这就满足局部分析信号的要求,维格分布当其时轴求和便可表现出频率下的谱密度,频率求和表现为该时域下的瞬时功率。但维格分布非线性处理会产生一个多余的交叉项,对信号有用信息的提取造成干扰,影响其应用<sup>[17]</sup>;小波技术是当前信号处理中最具有影响的方法,具有多分辨率分析的特点,而且在时频两域都具有表征信号局部特征的能力,是一种窗口大小固定不变但其形状可改变的时频局部化分析方法。即在低频部分具有较高的频率分辨率和较低的时间分辨率,在高频部分具有较低



的频率分辨率和较高的时间分辨率,适合于探测正常信号中夹带瞬态反常现象并展示其成份,具有广宽的应用前景<sup>[18]</sup>。

### 1.3.3 智能学习决策技术

总结加工过程监测技术的发展,90年代以来,人们为监测系统学习能力的提高作出了不懈的努力。智能科学的复苏兴起给很多难以解决的问题带来了希望,智能学习和决策为解决加工过程监测中难以解决的关键性技术提供了有效的方法。目前加工过程监测系统中采用的智能技术主要有:模式识别、神经网络、专家系统以及模糊系统在上述三者中的融合<sup>[19]</sup>。

**1.3.3.1 模式识别技术** 最早应用于加工过程监测系统的模式识别技术是非线性决策函数。模糊模式识别是模糊数学在模式识别技术中实际应用的一个成功的分支。切削过程是一个模糊过程,例如刀具的磨损状态就是一个模糊的概念。人们在以模糊模式识别技术应用于加工过程监测系统方面作出过不少的尝试,如文献<sup>[20]</sup>利用模糊模式识别技术对切削过程进行识别(是否是稳定切削的状态等);文献<sup>[21]</sup>对金刚石刀具的磨损状态利用模糊分类理论建立起分类模式,最后从动态切削力分析中获取刀具状态。

**1.3.3.2 专家系统** 专家系统<sup>[13][16]</sup>应用于加工过程监测主要体现在对切削数据的管理和推理,特别对于刀具寿命管理方面开展的工作较多些,但取得的成果不大,主要是因为专家系统获取知识较为困难,而且因为专家系统需要大量的知识即知识库。建立一个知识库为加工过程监测系统服务成本较高不易被接受。资料表明,这方面工作较少有报道,但专家系统中的决策具体方法可以作为参考解决一些局部问题。

**1.3.3.3 神经网络** 近年来,人工神经网络(ANN或NN)以其独特的优点引起了人们极大的研究热情。其基本思想是从仿生学的角度对人脑的神经系统进行模拟,使机器具有人脑那样的感知、学习和推理等智能。最早在加工过程监测系统中应用的是Dornfeld教授用NN集成多传感器<sup>[22]</sup>。神经网络与其它方法相比主要具有如下优点<sup>[23]</sup>:

1. 并行结构,便于集成多信号;
2. 学习功能,系统获取知识能力较强;
3. 联想推理,系统具有自调整功能;
4. 非线性映射功能,适用于复杂系统建模。

神经网络技术应用于加工过程监测系统是今后的重要方向,然而在应用神经网络中会出现了一些困难,如学习速度较慢,在学习过程中出现局部收敛,一些模糊信号无法处理以及神经网络结构很难理解而难以被接受等。为改善神经网络的学习性能,人们提出了许多优化学习算法<sup>[24-25]</sup>。另外神经网络与模糊系统的融合也是近年来的研究热点。以往文献资料展示不少两者成功结合的例子<sup>[26-28]</sup>。

## 1.4 刀具监测系统的发展趋势

综合先进国家在加工过程监测的研究现状和企业界对研究开发者的要求,智能技术

运用于加工过程监测被企业界广泛接受是必然之路。加工过程监测系统的发展趋势如下<sup>[29]</sup>：

1. 智能传感器的研究开发，包括多传感器融合、信号处理决策和传感器的集成等内容；
2. 信号处理技术的深入研究。信号处理技术的最终目的在于提取与加工过程状态相关信号特征，小波分析的应用研究将是主流；
3. 智能技术的进一步深入研究。模糊系统与神经网络的融合是主流方向，基因遗传算法的渗透有望解决系统的关键性问题，另外神经网络更注重于无监督学习型的发展应用；
4. 实用化方向发展，主要包括快速响应能力、强大可操作能力，与制造系统集成、高鲁棒性、低安装费用以及友好界面、改造系统较小、占空间小、维护方便等。

## 1.5 本论文的主要内容及结构组织

课题的目标是构造一个刀具状态监测系统，对用多传感器信息融合的方法实现刀具状态在线，实时，准确的监测进行研究和探讨。

全文总分五章。第一章作为论文的综述，首先说明建立刀具加工状态监测系统的意义，然后介绍当前刀具监测技术概况，叙述一般的加工过程监测系统的组成，并对监测系统的各部分组成进行简单介绍。接着进一步讨论到加工过程智能监测关键技术并对刀具监测系统的发展趋势提出展望。

接下来的几章以刀具监测系统组成的各个部分为顺序展开讨论，并在其中穿插着由实验所得的数据进行验证说明。

第二章关于刀具磨损监测信号的选择及信息融合。论文从刀具磨损的原理出发，分析由检测信号推断刀具磨损状态的可能性，对各种检测信号进行简单介绍并比较各自的优缺点，论述本课题研究所采用监测信号的依据，引入多传感器信息融合概念，通过实验数据说明多传感器信息融合应用于刀具状态监测的必要性。

第三章关于刀具监测信号的特征提取。首先介绍刀具监测信号处理的代表方法，包括傅立叶分析和小波分析。然后对本课题研究中所选择的切削力和切削振动刀具监测信号进行详细的分析，针对信号的不同特性提出了具体的信号特征提取方案。

第四章就前向神经网络技术问题进行讨论。首先介绍前向神经网络的结构，然后推导出广泛用于前向神经网络学习的 BP 算法，给出标准 BP 算法的示例程序。针对标准 BP 算法存在的问题，提出 BP 算法的改进方案，显示 BP 算法经过改进后的实际效果。最后以 Gauss 小波函数作为激发函数构造小波神经网络。

第五章综合运用前面章节介绍的理论，结合实验的数据，建立刀具状态监测模型，同时进行多种方案的对比，展开基于多传感器信息融合的刀具状态监测研究。首先介

介绍构造刀具监测系统的总体实验方案，引入神经网络建模的步骤，对输入数据进行预处理，接着对如何以神经网络实现刀具磨损的有效监测进行详细论述。对于单一工况条件下的刀具监测，比较了传统 BP 神经网络建模和小波神经网络建模的识别效果，还比较了以单一传感器检测信号和采用多传感器信号建立的刀具监测模型在各种工况条件下的刀具识别性能。至于多工况条件下的刀具监测，提出了基于正交工况条件实验数据的刀具监测系统建立过程，并通过实验数据验证按照这一方法建立的刀具状态监测模型的有效性和对工况条件的扩展性。

最后给出了本课题的主要结论，并就有关问题提出改进方案和展望。

## 第二章 刀具磨损监测信号的选择及信息融合

对于刀具切削状态检测的方法,总的来说可分为直接法和间接法。直接法是测量与刀具体积有关的参量,一般只能在刀具不切削时进行,有明显的缺点,其应用受到限制;而间接法是测量反映刀具磨损、破损的各种影响程度参量,能在刀具切削过程中检测,不影响切削加工过程,是目前国内外研究和应用的重点。由于刀具监测中存在着切削加工条件的多样性、切削参数的多变性、刀具磨钝的随机性、模糊性和监测信号单调性的矛盾,为了提高刀具失效监测的可靠性和准确性,人们提出了多传感器信息融合的刀具状态监测技术。

### 2.1 刀具磨损概述<sup>[30]</sup>

#### 2.1.1 刀具磨损的形式

刀具切削时,刀具的前刀面、后刀面经常与切屑、工件接触,会产生剧烈的摩擦,同时,在接触区内有很高的温度和压力。因此在前刀面和后刀面上都将随着切削时间的增长而产生磨损。由于切削材料、切削条件的不同,刀具磨损的形态也将出现如下差别:

##### 1. 前刀面磨损(月牙洼磨损)

切削塑性金属时,如果切削速度较高、切削厚度较大,这时刀具与切屑接触区的压力和温度都很高,切屑易在前刀面磨出一个月牙洼,这种磨损也称为前刀面磨损:

##### 2. 后刀面磨损

刀具切削时,工件上的加工表面不断地与刀具后刀面产生接触和摩擦(摩擦速度等于切削速度),由于接触面积很小,接触压力很大,因而在很短时间后刀面上就会磨出一个后角为零的小棱面,称为后刀面磨损带。在后刀面磨损带的中间部位,磨损比较均匀,以 $V_B$ 表示其平均磨损值。在切削铸铁和以较小的切削厚度及切削速度切削塑性金属时,主要发生这种磨损,这时月牙洼磨损则不明显。

##### 3. 前、后刀面同时发生磨损

以中等切削用量切削塑性金属时,通常产生这种形式的磨损。

#### 2.1.2 刀具磨损过程和磨钝标准

##### 2.1.2.1 刀具的磨损过程

通常所说的刀具磨损主要是指后刀面的磨损,其磨损过程分为三个阶段:

##### 1. 初期磨损阶段

这一阶段磨损曲线的斜率较大,这是因为新刃磨的刀具表面总是存在粗糙不平的,并且易形成显微裂纹、氧化或脱碳层等缺陷;此外,新刃磨的刀具与加工表面的接触面积小,压应力较大,故磨损较快。初期磨损量为 $VB=0.05\sim 0.1\text{mm}$ 。后刀面经过研磨的刀具,初期磨损量小,刀具耐磨得多。

### 2. 正常磨损阶段

经初期磨损后,刀具表面已经磨平,后刀面上磨出一条狭窄棱面,压强减小,故磨损量随切削时间增长而缓慢增加,并且比较稳定,这时刀具处于正常磨损阶段。这个阶段中的磨损曲线基本上是一条上升的直线,其斜率即代表磨损强度,它是衡量刀具切削性能的重要指标之一。

### 3. 急剧磨损阶段

当磨损带宽度增大到一定限度后,切削力和切削温度迅速增大,磨损急剧加速,继而刀具损坏。此阶段的磨损强度很大,因此刀具的重磨应在急剧磨损之前进行。

#### 2.1.2.2 刀具的磨钝标准

刀具磨损到一定限度后就不能继续使用,需要重磨或更换新刀,这个磨损限度称为“磨钝标准”。由于一般刀具的后刀面上都有磨损,它对加工精度和切削力的影响比前刀面磨损的影响要显著,并且易于控制和测量,故通常都以后刀面磨损带宽度 $VB$ 作为刀具磨钝标准。

切削条件不同,所确定的磨钝标准也不同。精加工的磨钝标准(一般 $VB=0.1\sim 0.3\text{mm}$ )较粗加工(粗车碳钢时 $VB=0.6\sim 0.8\text{mm}$ )为小,以保证加工质量。工艺系统性较差时,应规定较小的磨钝标准。因为 $VB$ 较大时,径向切削力会显著增大,容易引起振动。粗车钢件、特别是粗车合金钢和高温合金时,磨钝标准要比粗车铸铁时取得小些。因为在加工这些材料时,随 $VB$ 的增大,切削力和切削温度增加得更为显著,易造成刀具损坏。加工同一种工件材料时,硬质合金刀具的磨钝标要比高速刀具取得小些。因为硬质合金性脆,磨损过大时,容易产生振动而引起崩刃。

#### 2.1.3 刀具使用寿命

##### 2.1.3.1 刀具使用寿命的定义

刀具使用寿命是指刃磨后的刀具自开始切削直到磨损量达到磨钝标准为止的切削时间,它是指净切削时间,不包括用于对刀、测量、快进、回程等非切削时间。刀具使用寿命是很重要的数据。在同一条件下切削同一工件材料时,可以用刀具使用寿命来比较不同加工刀具材料的切削性能;同一刀具材料切削各种工件材料,又可以用刀具使用寿命来比较工件材料的加工性;也可以用刀具寿命来判断刀具几何参数是否合理。工件材料、刀具材料的性能对刀具的使用寿命影响很大。在切削用量中,影响刀具使用寿命最主要的因素是切削速度,其次是进给量、切削深度。此外,刀具几何参

数对刀具使用寿命也有重要影响。

### 2.1.3.2 刀具使用寿命的经验公式

20世纪初, 美国工程师泰勒建立了泰勒公式, 确立切削速度与刀具使用寿命的关系:

$$v_c = A/T^m \text{ 或 } T = C_1/v_c^z \quad (z=1/m) \quad (2-1)$$

式中 $T$ 为刀具使用寿命,  $v_c$ 为切削速度,  $C_1$ 、 $A$ 为系数。公式(2-1)是选择切削速度的重要依据。指数 $m$ 或 $z$ , 表示切削速度对刀具寿命的影响程度, 对于高速钢刀具,  $m=0.1\sim 0.125$ ; 对于硬质合金钢,  $m=0.1\sim 0.4$ 。 $m$ 大, 表明切削速度对刀具使用寿命影响小, 即刀具的切削性能较好。

按照求 $v_c - T$ 关系式的方法, 同样可以求得进给速度与刀具使用寿命之间和切削深度与刀具使用寿命之间的关系式:

$$f = B/T^n \quad (2-2)$$

$$a_p = C/T^p \quad (2-3)$$

式中 $B$ 、 $C$ 为系数,  $n$ 、 $p$ 为指数。

综合式(2-1)、(2-2)和(2-3), 可以得到刀具使用寿命的三因素公式:

$$T = \frac{C_T}{v_c^{1/m} \cdot f^{1/n} \cdot a_p^{1/p}} \quad (2-4)$$

式中 $C_T$ 是与工件材料、刀具材料和其他切削条件有关的系数。对于不同的工件材料和刀具材料, 在不同的切削条件下, 式(2-4)中的系数和指数可在资料中查到。

式(2-4)就是刀具使用寿命的预报方程。泰勒公式所确定的刀具使用寿命是预测刀具磨损的重要依据, 但刀具使用寿命由多种因素确定, 由(2-4)式确定的关系式是以刀具的平均寿命为依据建立, 并有一定的适用范围, 因此完全依靠泰勒公式无法完全实现对刀具切削状态进行实时、准确的监测。

## 2.2 刀具磨损监测信号的选择

### 2.2.1 用于监测刀具磨损常用信号

在切削过程中, 当刀具发生破损、磨损时, 一些与切削过程密切相关的物理量如切削力、切削温度等都将发生变化; 反过来说, 如果监测到这些信号已发生变化, 就

意味着刀具的状态有可能发生了变化。所以跟踪这些信号并识别它们的变化,是刀具监测的主要工作,可以说每一种现象或信号都可以作为刀具监测的依据。下面就一些较有代表性的监测信号加以介绍并对各种监测信号的优缺点加以比较<sup>[10][31-32]</sup>。

### 1. 光学摄像信号

用光学探头(显微镜)对准刀刃,接收刃口部分的图象,通过摄像机将图象拍摄下来,获得光学摄像信号。根据图象上各点辉度的不同将信号数字化并存入计算机,计算机对图象进行处理,滤去干扰信号后和原来计算机存储的值比较,从而确定刀具的状态。这种方法比较直观,适用于在线、非实时监测多种刀具磨损及破损,但计算机处理图象的时间较长,另外摄像机的安装也受到限制,所以通用性较差,在生产中难以推广。

### 2. 电机电流与功率

电机电流或功率是最早应用的刀具磨损监测信号之一。用霍尔元件感应或直接提取主轴驱动电机的电流或功率,当刀具破损或剧烈磨损时,电流或功率信号将发生明显的变化。这种方法比较简便,不需对机床作大的改动;但是它的灵敏度不高,不一定能反映切削过程中较为细微的变化,电机功率消耗较小时更是如此,所以比较适于对粗加工和重切削时刀具状态监测。

### 3. 红外线辐射信号

将红外辐射温度计对准切削区得到红外线辐射信号。由于切削区的红外辐射强度与切削区的温度有直接关系,这样红外辐射温度计就反映出切削区温度的变化情况。而切削区的温度和刀具的磨损、破损又是直接相关的,所以系统能够捕捉到刀具破损或剧烈磨损前切削温度陡然上升这一变化,从而预报刀具的剧烈磨损或破损。但在测量红外线辐射信号时,如果切屑缠绕刀具,切削区被遮挡时,测量的就不是切削区的温度,而是切屑的温度而引起误判。另外使用这种方法时,因不能使用切削液而使其应用受到限制。

### 4. 振动信号

振动与刀具破损、磨损有密切的关系,刀具发生破损或磨损加剧都将使切削工艺系统(刀具—工件—机床)的振动状态发生变化。一般来讲,振动传感器是一个有压电效应的加速度传感器,用磁铁或胶固定在刀具表面上,应尽可能接近刀刃。输出的信号放大后记录下来,并加以处理。以加速度计、振动传感器检测加工过程的振动信号及其变化,用于车、钻、铣等,有应用前景,但需解决刀具的自激振动及环境噪声的干扰。

### 5. 声发射信号

声发射(AE)是金属材料发生变形或断裂时释放的能量。声发射监测法的基本传感器是一个高频压电传感器,相应频率带宽为75KHz到1MHz。当刀具破损或磨损时,AE信号在时域或频域将发生变化,以此来判断刀具的状态。声发射信号直接来源于切

削加工点,与刀具磨损、破损相关程度高,受切削条件变化影响小,具有灵敏度高、响应时间快、使用和安装方便且干涉切削加工过程的优点,具有广阔的应用前景。但由于AE传感器的灵敏度较高,切削过程中除了工件材料剪切变形变成切屑而产生的AE信号之外,切屑之间、切屑与工件之间、机床的碰撞以及轴承、齿轮的运动和周围的噪声都会产生干扰信号,而干扰信号的强度与剪切区AE信号的强度相差不大,所以如何从这些合成信号中提取有用信号是AE监测法正确运用的关键且困难的问题。

#### 6. 切削力监测方法

切削力一直是表征切削过程的最重要特征,切削过程的变化都是和切削力密切相关。用切削力监测刀具状态具有突出的优点:切削力信号直接真实,不受加工区内切屑和冷却液的影响;切削力传感器的灵敏度可以做得较高以感知切削力的微小变化;与前面的监测信号相比,切削力信号幅度较大,干扰信号对它的影响较小,抗干扰能力较强。切削力刀具监测是当今最具有实用价值的方法。

应用切削力作为监测信号存在传感器的安装问题。在多数实验室研究工作中,测量铣、钻削过程切削力大都是将力传感器固定在机床工作台上,这样可以直接使用现成的测力仪,但这种方法在生产中是行不通的,因为实际加工时不可能把工件安装在测力仪上;也有一些切削力监测系统把力传感器安装在主轴轴承上(即测力轴承),但这种方法的灵敏度较低,只能检测重切削过程的过载或刀具折断。现时的发展方向是将力传感器固定在装夹钻头或铣刀的刀柄内,制成测力刀柄。这种刀柄的灵敏度高;不受切削力作用点位置的影响,反映切削力真实、准确;同一刀柄可以更换不同的刀具,互换性好;安装方便,对机床几乎不用做任何改动,是一种可以在生产中大力推广的方案。

#### 7. 超声波信号监测方法

集成超声波传感是一种接收和传送一体化的超声波传感器,用它可以监测刀具的磨损。具体的做法是:在车刀刀杆中安装集成超声波传感器,切削时传感器接收从刀具后刀面反射的超声波能量,系统通过处理这种信号来判断后刀面的磨损。实验表明,刀具的磨损与超声波能量之间有一定的关系,并随刀具的不同而不同。但这种方法受切削振动影响,目前尚处于研究阶段。

#### 8. 摩擦电势

Feimi效应是导体之间本身具有的一种导通现象:即自由电子会从电子逸出功较低的导体向电子逸出功较高的导体移动。由于Feimi效应的存在,刀具-工件接触面之间将产生摩擦电势,摩擦电势和刀具磨损之间存在着一定的关系,通过采集、处理摩擦电势可以判断刀具的状态。这种方法和平常采用的热电偶测量刀具温度很类似,只是热电偶测温法的依据是Seebeck效应,测量的是热电势。实验表明,随着后刀面磨损量的增加,摩擦电势功率谱中能量较高频率段的幅值将减小。



## 2.2.2 本课题研究中的监测信号选择

本课题开展的刀具状态监测研究是选择高速钢立铣刀作为具体的监测对象，以数控教室的XK5140型立式数控铣床作为试验平台（具体的实验配置详见第五章）。基于铣削加工具体特点和教室的实验条件，选择切削力和切削振动作为铣刀磨损的监测信号，具体理由如下：

1. 如前面所介绍，切削力是表征切削过程的最重要特征，切削力信号直接真实，抗干扰能力较强，灵敏度高，可以感知切削力的微小变化，切削力刀具监测是当今最具有实用价值的方法；

2. 铣削过程，由于切削厚度不断变化而导致切削力的变化，同时铣削过程是一个断续的切削过程，每一刀齿周期性的切入和切出形成周期性的机械冲击，这种切削特点更容易产生切削振动，振动信号能有效地反映出刀具在加工过程的状态变化；

3. 切削力信号和切削振动信号作为刀具磨损的监测信号具有互补性。在频域上看，切削力信号反映的是低频信息，频谱比较集中；而切削振动信号的频谱比较分散，频率成份丰富，两者从不同的方面反映刀具的状态。

在实际信号监测时，采用瑞士KISTLER公司制造的9257A型压电晶体测力仪和5006型电荷放大器，监测纵向和横向切削力；采用北京测振仪器厂生产的YD-5型加速度传感器并配同一厂家生产的DHF-2型电荷放大器检测切削振动。因为本课题的研究只需比较信号的相对变化，因而本文所有的实验数据及信号特征值均不考虑单位，只是仪器的直接记录。

图2-1、图2-2显示在工况条件切削深度 $2.00\text{mm}$ 、进给速度 $73.83\text{mm}/\text{min}$ 、主轴转速 $502\text{转}/\text{min}$ 条件下采集到的切削力信号、切削振动信号和它们各自的频谱。




图 2-1 不同程度磨损刀具产生的切削力信号

Fig.2-1 Cutting force signals produced by the milling cutters of different wear




图 2-2 不同程度磨损刀具在相同工况下产生振动信号

Fig.2-2 Vibration signals produced by the milling cutters of different wear under the same cutting condition

从图2-1和图2-2可看出，刀具的不同程度磨损可以在上述加工条件下的切削力信号和切削振动信号中明显地被反映出来，也即意味着确实可以选择切削力和切削振动作为刀具磨损的监测信号。

## 2.3 多传感器信息融合

### 2.3.1 多传感器信息融合概念的引入

从前面介绍的用于监测刀具磨损常用信号可知，在切削过程中，一些与切削过程密切相关的物理量如切削力、切削温度的变化可以从不同方面反映出刀具状态的变化，但采用不同的监测信号在不同的条件下互有优势和局限。

实验数据还表明，在不同的工况下，同一类型的监测信号对刀具磨损的敏感度也不一样。例如，在图2-1和图2-2所示的工况下，不同程度磨损刀具的切削力信号和切削振动信号差异都很明显，在这种工况条件下只凭切削力信号或切削振动信号都可以区分出刀具的磨损程度。但在另一种工况条件下情况又大不相同。图2-3所示的是在工况

切深2.00mm, 进给速度60.5mm/min, 主轴转速700r/min的条件下采集到的切削力信号和振动信号。

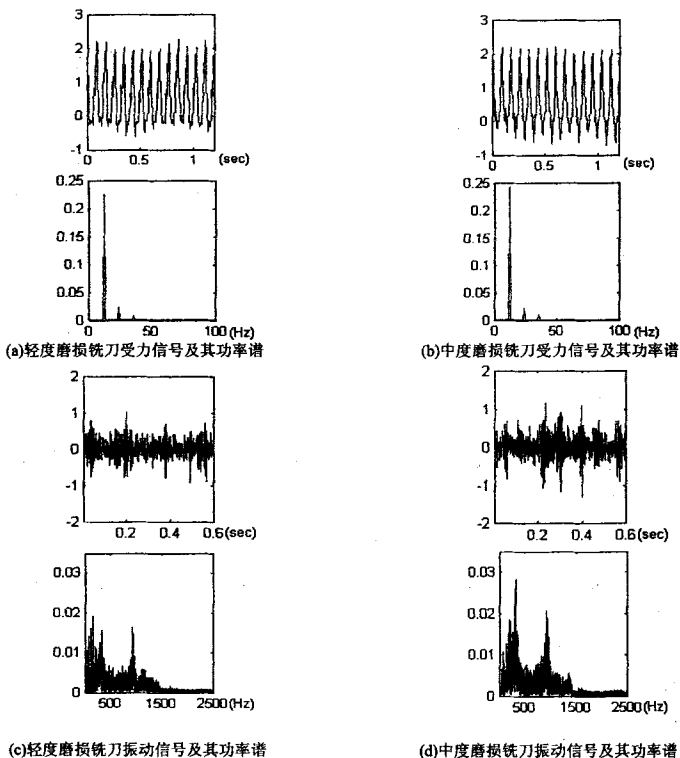


图 2-3 不同程度磨损刀具对应力信号及振动信号之比较

Fig 2-3 The comparison between the cutting force and the vibration signal produced by the milling cutters of different wear

在图2-3所示的工况中, 铣刀不同程度的磨损在切削力信号上无论是时域还是频域反映的差异都不大, 单靠切削力信号不容易对刀具的磨损程度作出准确的判断, 而在振动信号上反映的差异则较为明显。

正是由于刀具监测中存在切削加工条件的多样性、切削参数的多变性、刀具磨钝的随机性、模糊性和监测信号单调性的矛盾, 为了提高刀具失效监测的可靠性和准确性, 有必要以多传感器信息融合的方式实现刀具监测。制造过程中的多传感器信息融合是指通过各种的传感器, 提取制造过程对象的各种信息(在本课题研究中是提取振动信号和切削力信号), 充分利用多个传感器的资源, 依据某个判断准则来组合传感器

组的空间上或时间上冗余或互补信息，从而综合反映制造过程特征。

多传感器信息融合与经典信号处理方法间存在本质的区别，其关键是信息融合所处理的信息具有更复杂的形式，而且可以在不同的信息层次上出现。多维信息具有信息冗余性、信息的互补性、信息的实时性和信息的低成本性等特点。实践表明，多传感器信息综合监测方法能提高刀具磨损监测的精确度与可靠性，具体表现为<sup>[33]</sup>：

1. 在某个传感器出了问题时，仍能正确地识别刀具状态；
2. 多传感器的综合可以获得一些单个独立传感器无法获得的信息；
3. 多传感器的并行处理方式提高了信息的获取速度与效率。

### 2.3.2 基于神经网络的多传感器信息融合

智能科学的发展为多传感器信息融合提供了决策方法。目前应用于加工过程监测系统中智能技术主要有：专家系统、模糊识别、神经网络技术以及上述三者的融合。

鉴于其特点和优点，在多传感器信息融合与决策方法中，神经网络被公认为是很有前途的方法，本论文也将选择神经网络作为刀具状态决策建模的基础，并在第四章和第五章作更深入的探讨。基于神经网络多传感器融合的一般结构及过程如图2-4所示：

它的处理过程如下：




图 2-4 基于神经网络多传感器融合的一般结构  
Fig-2-4 General constitution of the sensor fusion based on artificial neural network

1. 采用合适的N个传感器监测加工过程的刀具状态；
2. 采集N个传感器的测量信号，并进行预处理；
3. 对N个传感器测量信号预处理结果，分别进行特征提取；
4. 将选择的N个传感器特征信号进行归一化处理以作为神经网络的标准化输入；
5. 训练阶段。将测量所得的N个传感器信号经上述处理的归一化特征信号与已知的刀具状态值作为训练，直至达到期望的性能为止；
6. 工作阶段。将归一化后的多传感特征信息作为训练所得的神经网络的输入，经过神经网络的联想，即可获得当前刀具状态值。

## 2.4 本章小结

本章首先介绍了刀具磨损的机理，包括刀具磨损的形式、刀具磨损过程和磨钝标准，并引入刀具使用寿命的定义。接着介绍用于监测刀具磨损常用信号并比较了各自的优缺点，特别是对本课题研究中监测信号的选择作出较为详细的解释说明。鉴于采用不同的监测信号在不同的条件下互有优势和局限，引入多传感器信息融合概念，并通过课题实验数据说明多传感器信息融合应用于刀具状态监测的必要性。最后简单介绍了为多传感器信息融合提供的决策方法，尤其是在以后章节将会用到的人工神经网络方法。

## 第三章 刀具监测信号的处理

刀具监测信号的处理是对监测信号的进一步加工,是从大量信号中提取出与加工状态变化相关的特征值。信号特征提取的作用在于,一方面可以提高信号的信噪比,另一方面可以减少后期数据的处理量,提高运算速度,因此,提取特征参数的品质对监测系统的性能和可靠性具有很重要的影响作用。目前采用的方法主要有时域方法、频域方法和时频分析方法。本章针对信号的不同特性采用不同的信号处理方法提取信号的特征值。

### 3.1 刀具监测信号处理的代表方法

#### 3.1.1 傅立叶分析<sup>[34-36][40]</sup>

把瞬时多变的时域信号转换到频域上去分析往往更有利于了解和掌握信号的特征和性质,傅立叶变换是频域分析的重要方法。傅立叶变换的数学表达式如下:

$$F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-i\omega t} dt \quad (3-1)$$

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega)e^{i\omega t} d\omega \quad (3-2)$$

式中  $f(t) \in L^1(R)$ , 即满足:

$$\int_{-\infty}^{+\infty} |f(t)| dt < \infty \quad (3-3)$$

由于一般的物理信号都满足(3-3),因而傅立叶变换得到了广泛的应用。

以周期为  $T_s$  的冲激序列  $\delta_T(t)$  对连续信号  $f(t)$  作  $N$  点均匀抽样,抽样时间为  $T$ ,离散化成序列:

$$f(k) = f(t)\delta_T(t) = \sum_{k=0}^{N-1} f(t)\delta(t - kT_s) \quad (3-4)$$

对式(3-4)作傅立叶变换,得到序列的傅立叶变换:

$$\begin{aligned} \bar{F}(\omega) &= \int_{-\infty}^{+\infty} \sum_{k=0}^{N-1} f(t)\delta(t - kT_s)e^{-i\omega t} dt \\ &= \sum_{k=0}^{N-1} f(k) e^{-i\omega kT_s} \end{aligned} \quad (3-5)$$

其中  $f(kT_s)$  简记为  $f(k)$ 。式(3-5)显示,序列对应的频域是以抽样频率  $\omega_s = 2\pi/T_s$  为周期的连续函数。对式(3-5)在频域的一个周期  $0 \sim \omega_s$  内作积分可得序列的傅立叶逆变换:

$$f(k) = \frac{1}{w_s} \int_0^{w_s} \bar{F}(w) e^{i k w T_s} dw \quad (0 \leq k \leq N-1) \quad (3-6)$$

由卷积定理可推导出序列的傅立叶变换与相应连续信号傅立叶变换的关系式:

$$\bar{F}(w) = \frac{1}{T_s} \sum_{n=-\infty}^{\infty} F(w - n w_s) \quad (3-7)$$

从(3-7)式可知,  $f(k)$ 的频谱  $\bar{F}(w)$  是原连续信号  $f(t)$  频谱  $F(w)$  周期延拓, 周期为抽样角频率  $w_s$ , 幅值为  $F(w)$  的  $\frac{1}{T_s}$ 。

对序列  $f(k)$  的傅立叶变换  $\bar{F}(w)$  在一个周期  $[0, w_s]$  内以取样间隔  $\frac{2\pi}{NT_s}$  作  $N$  点取样可得  $f(k)$  的  $N$  点离散傅立叶变换(DFT):

$$F(n) = \sum_{k=0}^{N-1} f(k) e^{-i \frac{2\pi}{N} kn} \quad 0 \leq n \leq N-1 \quad (3-8)$$

相应的离散傅立叶逆变换(IDFT)为:

$$f(k) = \frac{1}{N} \sum_{n=0}^{N-1} F(n) e^{i \frac{2\pi}{N} nk} \quad 0 \leq k \leq N-1 \quad (3-9)$$

离散傅立叶变换是一种时域和频域均离散化的变换, 在理论上解决了用计算机作傅立叶分析的问题。快速傅立叶变换算法(FFT算法)的出现使DFT的运算效率提高1~2个数量级, 使数字信号处理形成了一个学科, 并在70年代以后得到飞速发展。

傅立叶分析在信号分析处理中的突出贡献, 在于它可以将复杂的时域信号转换到频域中, 用频谱特性去分析和表现时域信号的特性。但是用傅立叶变换不总是方便有效的, 主要表现为:

1. 从式(3-1)可看出  $F(w)$  仅是单变量  $w$  即频率的函数, 没有提供关于时间的信息, 因此可以说傅立叶变换提取了频率特征而淹没了时间特征。通过加窗函数的办法对傅立叶变换加以改进(Gobar 变换)虽然可以解决傅立叶变换无法反映时域信息的问题, 但 Gobar 变换固定的时频窗无法适合信号本身的规律;
2. 从式(3-8)可看出, 每计一条谱值需要全部的采样值, 当信号只在某一局部变化时, 都会影响每一个谱值的变化
3. 离散傅立叶变换存在栅栏效应, 频谱泄漏和混迭失真。栅栏效应可以通过添加零值来补救, 但频谱泄漏和混迭失真难以完全克服;
4. 傅立叶变换给出的是在一系列频率点上的信息, 这种信息可以细腻地反映信号的高低频率特征, 但当需要了解某些局部时段所对应的主要频率或某些频率的信息出现在哪些时段, 即对信号有时一频局部化要求时, 傅立叶分析是无能为力的。

由于傅立叶分析的局限性和存在的问题, 促使人们从理论上和实践上寻求新的分析方

法。

### 3.1.2 小波分析<sup>[37-40]</sup>

#### 3.1.2.1 小波变换

设  $f(t), \psi(t)$  是平方可积函数, 且  $\psi(t)$  满足条件

$$\int_R |\Psi(w)|^2 / w dw < \infty, \quad (3-10)$$

则称 
$$\frac{1}{\sqrt{a}} \int_R f(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt = \langle x(t), \psi_{a,b}(t) \rangle, \quad a > 0 \quad (3-11)$$

是  $f(t)$  的连续小波变换, 记为  $W_f(a, b) = \frac{1}{\sqrt{a}} \int_R f(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt$ , 称  $\psi(t)$  为小波函数或小波母函数, 称  $a$  为尺度因子,  $b$  为平移因子, 因参数  $a, b$  是连续变化的, 故称上述的变换为连续小波变换。符号  $\langle \rangle$  代表内积运算, 上标  $-$  代表共轭。

与其它积分变换一样, 小波变换只有在其逆变换存在的条件下才有意义。小波变换逆变换存在的条件也称为小波的容许条件:

$$0 < \int_0^{+\infty} \frac{|\Psi(w)|^2}{w} dw < +\infty \quad (3-12)$$

并由此可推出:

$$\Psi(0) = \int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (3-13)$$

由(3-12)可知  $\psi(t)$  应具有快速衰减性, 由(3-13)可知  $\psi(t)$  具有波动性。可以想象,  $\psi(t)$  的图像是快速衰减的振动曲线, 这就是  $\psi(t)$  被称为小波的原因。

当满足小波容许条件(3-12)时, 有小波变换的反演公式:

$$f(t) = \frac{1}{C_\psi} \int_0^{+\infty} \int_{-\infty}^{+\infty} \frac{1}{a^2} W_f(a, b) \psi_{a,b}(x) db da \quad (3-14)$$

其中

$$C_\psi = \int_0^{+\infty} \frac{|\Psi(w)|^2}{w} dw \quad (3-15)$$

基小波  $\psi(t)$  伸缩平移系  $\psi_{a,b}(t)$  在小波变换中对被分析的信号起着观测窗的作用, 与 Gobar 变换固定的时频窗不同, 由  $\psi_{a,b}(t)$  确定的时频窗是自适应变化的: 当  $a$  值小时, 时轴上观察范围小, 而在频域上相当于用高频小波作细致观察; 当  $a$  值较大时, 时轴上考察范围大, 而在频域上相当于用低频小波作概貌观察。这种时频局部化的特点还可计算  $\psi_{a,b}(t)$  的窗口中心和窗口宽度作定量验证。

为了便于计算机计算和减小数据的冗余, 应将连续小波离散化。通常的做法是取



$a = a_0^j, j = 0, \pm 1, \pm 2, \dots$ ; 位移参数取  $b = ka_0^j b_0$ 。这样离散化后的小波函数为:

$$\psi_{j,k}(t) = a_0^{-j/2} \psi(a_0^{-j}t - kb_0), \quad j, k \in Z \quad (3-16)$$

称其对应的小波变换

$$W_f(j, k) = \int_R f(t) \bar{\psi}_{j,k}(t) dt \quad (3-17)$$

为  $f(t)$  的离散小波变换。要实现由离散小波变换  $W_f(j, k)$  重构  $f(t)$ ,  $\{\psi_{j,k}(t)\}_{j,k \in Z}$  必须要能构成一个小波框架, 即对于任何  $f(t) \in L^2(R)$ , 有

$$A\|f\|^2 \leq \sum_{j,k} | \langle f, \psi_{j,k} \rangle |^2 \leq B\|f\|^2, \quad 0 < A \leq B < +\infty \quad (3-18)$$

特别地, 当  $A=B=1$  时, 小波框架  $\{\psi_{j,k}(t)\}_{j,k \in Z}$  是小波正交基。其对应的离散小波变换所含信息是没有冗余的。

### 3.1.2.2 多尺度分析

S.Mallat 和 Y.Meyer 在多尺度逼近的基础上提出的多尺度分析是理解和构造小波的统一框架, 他们的研究将小波理论和应用推向了新的阶段。

多尺度分析(MRA)是指满足下述条件的  $L^2(R)$  中的一系列嵌套子空间  $\{V_j\}_{j \in Z}$  及一个函数  $\phi(t)$ , 记为  $(\{V_j\}_{j \in Z}, \phi(t))$ :

$$(1) V_j \subseteq V_{j-1}, \quad j \in Z,$$

$$(2) f(t) \in V_j \Leftrightarrow f(2t) \in V_{j-1},$$

$$(3) f(t) \in V_j \Rightarrow f(t - 2^j k) \in V_j, k \in Z,$$

$$(4) \bigcap_{j \in Z} V_j = \{0\}, \bigcup_{j \in Z} V_j = L^2(R),$$

$$(5) \text{存在尺度函数 } \phi(t) \in V_0, \text{ 且 } \{\phi(t-k)\}_{k \in Z} \text{ 是 } V_0 \text{ 标准正交基。}$$

从多尺度分析上述性质可推出对于任何  $f(t) \in V_0$ , 有  $f(\frac{t}{2^j}) \in V_j$ , 且容易验证, 函数系

$\{\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j}t - k)\}_{j,k \in Z}$  构成了  $V_j$  的一组标准正交基。

记  $W_j$  是  $V_j$  在  $V_{j-1}$  中的正交补空间, 即  $V_{j-1} = V_j \oplus W_j, V_j \perp W_j, j \in Z$ , 有递推关系:

$$V_{j-1} = V_j + W_j = V_{j+1} + W_{j+1} + W_j = \dots = V_{j+s} + W_{j+s} + W_{j+s-1} + \dots + W_{j+1} + W_j \quad (3-19)$$

令  $s \rightarrow \infty$ , 有  $V_{j-1} = \bigoplus_{k=j}^{+\infty} W_k$ , 又令  $j \rightarrow -\infty$ , 有

$$L^2(R) = \bigoplus_{k=-\infty}^{+\infty} W_k \quad (3-20)$$

这表明,  $L^2(R)$ 可表示为子空间  $W_j$  的直和分解。值得注意的是,  $W_j$  中的函数也有对伸缩变换的特点: 若非零函数  $f(t) \in W_j \Leftrightarrow f(2t) \in W_{j-1}$ 。我们称  $W_j$  为尺度为  $j$  的小波空间,  $V_j$  为尺度为  $j$  的尺度空间。

可以证明, 由一个给定的多尺度分析 ( $\{V_k\}_{k \in \mathbb{Z}}, \phi(t)$ ) 可确定一个小波函数  $\psi(t)$  和相应的小波空间  $\{W_j\}_{j \in \mathbb{Z}}$ , 并能满足  $\psi(t)$  的伸缩平移系  $\{\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k)\}_{k \in \mathbb{Z}}$  构成  $W_j$  的标准正交基。对于  $\phi(t) \in V_0$ ,  $\psi(t) \in W_0$ , 有序列  $\{h_k\}_{k \in \mathbb{Z}}$  和  $\{g_k\}_{k \in \mathbb{Z}}$  使如下关系成立:

$$\phi\left(\frac{t}{2}\right) = \sqrt{2} \sum_{k \in \mathbb{Z}} h_k \phi(t-k) \quad (3-21)$$

$$\psi\left(\frac{t}{2}\right) = \sqrt{2} \sum_{k \in \mathbb{Z}} g_k \psi(t-k) \quad (3-22)$$

式(3-21)、(3-22)称为双尺度方程, 是多尺度分析赋予尺度函数  $\phi(t)$  与小波函数  $\psi(t)$  最基本的性质。由式(3-20)可知, 对任何  $f(t) \in L^2(R)$  有:

$$f(t) = \sum_{j,k \in \mathbb{Z}} d_{j,k} \psi_{j,k}(t) \quad (3-23)$$

其中  $d_{j,k} = \langle f(t), \psi_{j,k}(t) \rangle$ ,  $j, k \in \mathbb{Z}$ 。由离散小波变换的定义知,  $\{d_{j,k}\}_{j,k \in \mathbb{Z}}$  就是  $f(t)$  的正交小波变换, 式(3-23)称为  $f(t)$  的正交小波分解。

若记  $d_{j,k} \psi_{j,k}(t) = g_j(t)$  则  $g_j(t) \in W_j$ , 而  $V_{j-1} = V_j \oplus W_j$ ,  $V_j$  的频率范围恰是  $V_{j-1}$  的一半, 且是  $V_{j-1}$  的低频表现部分, 所以  $W_j$  的频率表现在  $V_j$  与  $V_{j-1}$  之间的部分, 它表现的是个有限频带。通常,  $V_j$  表现  $V_{j-1}$  的“概貌”,  $W_j$  表现了“ $V_{j-1}$ ”的“细节”。由于  $W_j$  的频带是互不重叠的, 所以  $W_j$  表现的是不同频带的“细节”。在这样的记法下, 式(3-23)可写成:

$$f(t) = \sum_{j \in \mathbb{Z}} g_j(t) \quad (3-24)$$

实际上, 任何函数  $f(t) \in L^2(R)$  只有有限的细节, 因为物理仪器能记录下的信号总是只有有限的分辨率, 在实际操作上, 我们可以假设  $f(t) \in V_0$  (将有最精细的函数空间记为  $V_0$ )。由于

$$V_0 = V_1 + W_1 = V_2 + W_2 + W_1 = \dots = V_j + W_j + W_{j-1} + \dots + W_1 \quad (3-25)$$

所以  $f(t) = f_j(t) + g_j(t) + g_{j-1}(t) + \dots + g_1(t)$ , 即

$$f(t) = \sum_{k \in \mathbb{Z}} c_{j,k} \phi_{j,k}(t) + \sum_{i=1}^j \sum_{k \in \mathbb{Z}} d_{i,k} \psi_{i,k}(t) \quad (3-26)$$

其中

$$c_{j,k} = \langle f(t), \phi_{j,k}(t) \rangle, k \in Z \quad (3-27)$$

$$d_{i,k} = \langle f(t), \psi_{i,k}(t) \rangle, k \in Z \quad (3-28)$$

式(3-26)的第一项  $f_j(t)$  表示的是  $f(t)$  有尺度  $J$  下的一种逼近, 它表示的是  $f(t)$  频率不超过  $2^{-J}$  的成分; 而第二项中的  $g_i(t)$ , 是  $f(t)$  的频率在  $2^{-i}$  到  $2^{-i+1}$  之间的细节成分。式(3-26)对于所有的  $J(J \geq 1)$  成立, 因此可得到不同尺度下的逼近式。我们称

$$f_j(t) = \sum_{k \in Z} c_{j,k} \phi_{j,k}(t) \quad (3-29)$$

为  $f(t)$  的尺度为  $J$  的连续逼近, 称其系数(3-27)为  $f(t)$  的离散逼近, 称

$$\sum_{k \in Z} d_{i,k} \psi_{i,k}(t) \quad (3-30)$$

为  $f(t)$  在尺度  $i$  下的连续细节, 称其系数(3-28)为  $f(t)$  的离散细节。在实际计算离散逼近及离散细节时有快速的递推分解算法和回复算法(Mallat 算法):

$$c_{j+1,n} = \sum_{k \in Z} c_{j,k} \bar{h}_{k-2n}, n \in Z \quad (3-31)$$

$$d_{j+1,n} = \sum_{k \in Z} c_{j,k} \bar{g}_{k-2n}, n \in Z \quad (3-32)$$

$$c_{j,n} = \sum_{k \in Z} c_{j+1,k} h_{n-2k} + \sum_{k \in Z} d_{j+1,k} g_{n-2k}, k \in Z \quad (3-33)$$

其中  $\{h_n\}_{n \in Z}$  和  $\{g_n\}_{n \in Z}$  为双尺度的传递系数, (3-31)、(3-32)是分解算法, (3-33)是回复算法。

### 3.1.2.3 小波包分析

设正交小波函数  $\psi(t)$ 、尺度函数  $\phi(t)$ , 它们满足双尺度方程 (3-21)及(3-22), 记  $u_0(t) = \phi(t)$ ,  $u_1(t) = \psi(t)$ , 双尺度方程变成:

$$\begin{cases} u_0(t) = \sqrt{2} \sum_{k \in Z} h_k u_0(2t - k) \\ u_1(t) = \sqrt{2} \sum_{k \in Z} g_k u_0(2t - k) \end{cases} \quad (3-34)$$

进一步写成递推形式有:

$$\begin{cases} u_{2n}(t) = \sqrt{2} \sum_{k \in Z} h_k u_n(2t - k) \\ u_{2n+1}(t) = \sqrt{2} \sum_{k \in Z} g_k u_n(2t - k) \end{cases} \quad (3-35)$$

把上述定义的函数集合  $\{u_n(t)\}_{n=0,1,2,\dots}$  称为由  $u_0(t) = \phi(t)$  确定的小波包。

可以证明,  $u_n(t)$  具有两种正交性:

1. 平移正交性, 即:

$$\langle u_n(t-j), u_n(t-k) \rangle = \delta_{j,k}, \quad j, k \in Z, n=0,1,2,\dots \quad (3-36)$$

2. 相关正交性, 即:

$$\langle u_{2n}(t-j), u_{2n+1}(t-k) \rangle = 0, \quad j, k \in Z, n=0,1,2,\dots \quad (3-37)$$

以  $u_n(t)$  的伸缩平移系生成的空间称为小波包空间, 具体表达式如下:

$$U_j^n = \text{span}\{2^{-j/2} u_n(2^{-j}t-k), k \in Z\} \quad (3-38)$$

由  $u_n(t)$  的平移正交性容易推出它的伸缩平移系  $\{2^{-j/2} u_n(2^{-j}t-k), k \in Z\}$  也是标准正交, 构成小波空间  $U_j^n$  的标准正交基。根据递推关系可得到小波包的空间分解:

$$V_j = U_{j+k}^0 \oplus U_{j+k}^1 \oplus U_{j+k}^2 \oplus \dots \oplus U_{j+k}^{2^j-1} \quad (3-39)$$

$$W_j = U_{j+k}^{2^k} \oplus U_{j+k}^{2^k+1} \oplus U_{j+k}^{2^k+2} \oplus \dots \oplus U_{j+k}^{2^{k+1}-1} \quad (3-40)$$

以  $V_0$  空间为例, 其分解情况如图 3-1 所示, 形成了一个以  $V_0$  为根的树结构图。正如树形图所示, 每一层的各子空间是相互正交的。如称  $V_0$  为零层, 则第一层的二个小子空间  $U_1^0$ 、 $U_1^1$  所对应的频率各占  $V_0$  所对应频带的一半, 而第二层的四个小子空间  $U_2^0$ 、 $U_2^1$  和  $U_2^2$ 、 $U_2^3$  所对应的频带分别是  $U_1^0$ 、 $U_1^1$  所对应频带的一半, 以此类推, 第  $j$  层的  $2^j$  个子空间  $U_j^0$ 、 $U_j^1$ , ...,  $U_j^{2^j-1}$  所对应的频带, 从低到高依次占  $V_0$  频带的  $1/2^j$ , 这样就可达到提高频域局部化的目的。




图 3-1  $V_0$  空间的树结构分解  
Fig.3-1 The tree-structure decomposition of  $V_0$  space

若  $L^2(R)$  中的函数  $f_j^n(t) \in U_j^n$ , 对应于小波包的空间分解关系,  $f_j^n(t)$  可表示为:

$$f_j^n(t) = \sum_l d_l^{j,n} 2^{-j/2} u_n(2^{-j}t-l) \quad (3-41)$$

根据  $u_n(t)$  正交性的性质, 可直接得到投影系数:

$$d_l^{j,n} = \langle f_j^n(t), 2^{-j/2} u_n(2^{-j}t-l) \rangle \quad (3-42)$$

与多尺度分析类似地，小波包分解也有类似的快速分解算法和回复算法：

$$\begin{cases} d_m^{j+1,2n} = \sum_l d_l^{j,n} \bar{h}_{l-2m}, m \in Z, \\ d_m^{j+1,2n+1} = \sum_l d_l^{j,n} \bar{g}_{l-2m}, m \in Z. \end{cases} \quad (3-43)$$

$$d_k^{j,n} = \sum_m (d_m^{j+1,2n} \bar{h}_{k-2m} + d_m^{j+1,2n+1} \bar{g}_{k-2m}) \quad (3-44)$$

与小波分解相比，小波包分解提供了一种更为灵活的信号处理方法：既可以对低频部分进行分解，也可以对高频部分分解，还可以根据对信号的经验估计，任意地加强某些特定时段和特定频段的观察和分析。因此小波包分析是一种应用更广泛的小波分析方法。

## 3.2 刀具监测信号的分析及特征提取

在第二章也曾提及，因为本课题的研究对同一类检测信号只需要比较它们的相对变化，而且最终作为模式输入的特征向量也会进行归一化处理，所以本文中所有的实验数据均不考虑单位，只是仪器的直接记录，数据的绝对值表示量的相对大小，其符号表示矢量方向。这一简化的处理方法不影响最终研究结果。

### 3.2.1 切削力分析及特征提取

#### 3.2.1.1 切削力的时域分析

以切深 1.00mm、进给速度 60.46mm/min、主轴转速 603 转/min 加工条件为例，实测 y 向和 x 向受力曲线如图 3-2、图 3-3 所示，采样频率为 200Hz。因为在课题研究中需要在许多种工况条件下采集数据，为了叙述和数据组织的方便，有必要对每组工况条件进编号，编号的方法可参考第五章的说明，具体上述的工况条件记为工况 122。

在理想情况下，立铣刀在铣削过程中，铣刀的每个齿的受力应该是均匀的，因而在主轴每个旋转周期内将重复数目与铣刀齿数相同的受力波形（实验中采用三齿立铣刀），但图 3-2、图 3-3 显示的结果并非如此。这是由于本实验用的数控机床较为陈旧，刀具装夹后存在无法消除的偏心现象，切削过程中表现为各齿间受力明显不均，只有一个刀齿受力较大，每个相似波形中只出现一个突出的峰值，其余的两个峰值不明显。实验中发觉，铣刀一次装夹后经过长时间铣削会出现单齿磨损严重，这一现象也证实了如上解释。同时曲线波形表现出一定的周期性，例如在工况 122 中，主轴转速为 600r/min，即主轴频率为 10Hz，在 1 秒数据采样中出现 10 个相似的波形。

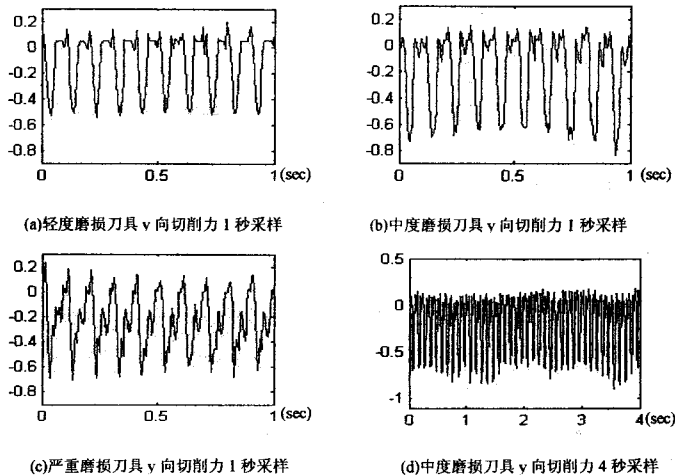


图 3-2 工况 122 下 y 向切削力曲线  
Fig.3-2 Cutting force of y direction under the cutting condition of 122

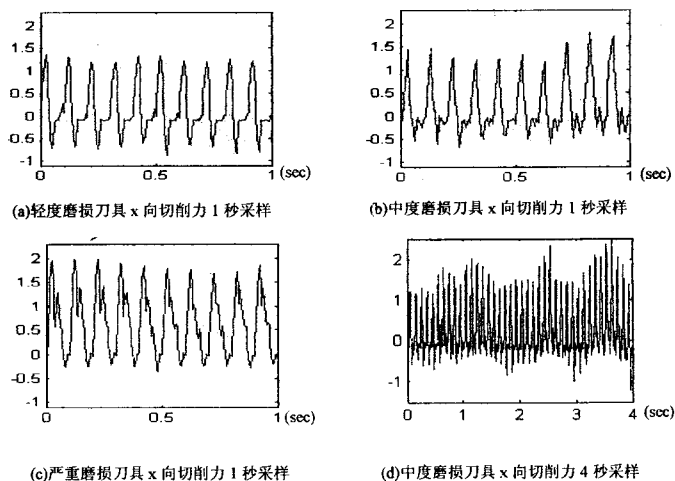


图 3-3 工况 122 下 x 向切削力曲线  
Fig.3-3 Cutting force of x direction under the cutting condition of 122

从图 3-2 和图 3-3 可看出, 同一工况下不同磨损刀具产生的受力波形可能有明显的差别。对较长时间受力信号的数据采样观察还可发现, 受力曲线并不稳定, 图 3-2 和图 3-3 的 y 向和 x 向受力 4 秒采样曲线明显包含引起曲线波动的因素。通过不同磨损刀具在不同工况下产生受力曲线的相互比较还可看出, 由于加工过程中存在着许多影响切削力的随机因素, 每个波形中包含不规则变化, 相似波形并不完全相同, 有时甚至相差较大。正是因为影响切削力的随机因素和不稳定因素的存在, 在时域内提取可靠的、反映刀具磨损的特征值是有困难的。因此, 有必要进行数据处理, 把切削力的时域信号转换到频域进行分析。

### 3.2.1.2 切削力的频域分析

仍以工况 122 为例, 将工况 122 的 y 向和 x 向切削力采样数据进行快速傅立叶变换可得功率谱如图 3-4 和图 3-5 所示。




图 3-4 工况 122 下 y 向切削力功率谱  
Fig.3-4 Power spectrum of the cutting force of y direction under the condition of 122




图 3-5 工况 122 下 x 向切削力功率谱  
Fig.3-5 Power spectrum of the cutting force of x direction under the condition of 122

图 3-4、图 3-5 显示, 在工况 122 下,  $x$  向和  $y$  向受力功率谱分布很有规律, 切削力能量主要集中在主轴旋转频率对应点上, 实验数据进一步表明, 这一规律可推广至其它工况条件。还可看到, 在特定工况下, 不同程度磨损的刀具在主轴旋转频率对应点上的功率差别明显: 例如在工况 122 下, 严重磨损刀具、中度磨损刀具、轻度磨损刀具产生的  $y$  向切削力和  $x$  向切削力在主轴旋转频率对应点的功率谱依次递减, 据此可区分出刀具相应的磨损。

以下图 3-6 则显示, 主轴旋转频率对应点的功率反映刀具磨损具有稳定性。图 3-6 记录了不同程度磨损刀具在相同工况下得到的 16 组切削力在主轴旋转频率对应点的功率。图中以三种不同类型的点对应于三种不同程度磨损刀具, 每一类型的点都有 16 个, 每个点代表一组切削力在主轴旋转频率对应点的功率值 (已经归一化处理)。从图中可以看出, 对于每种同一程度磨损刀具, 其 16 组切削力在主轴旋转频率对应点的功率基本是恒定的, 因为同一类型的 16 个代表点几乎在一条水平线上。




图 3-6 不同程度磨损刀具在同一工况下的各自 16 组切削力在主轴旋转频率对应点上的功率

Fig.3-6 16 groups of cutting force power values corresponding to the principal axis frequency produced by milling cutters of different wear under the same cutting condition

切削力在主轴旋转频率对应点的功率反映刀具磨损的有效性和稳定性决定了选择该值作为刀具监测系统中切削力的特征值是合适的。当然, 仅仅以切削力信号作为刀具磨损判断依据仍无法在所有工况条件下获得良好的判断效果, 这一点在第五章的神经网络建模比较中得到进一步证实。

## 3.2.2 切削振动分析及特征提取

### 3.2.2.1 切削振动的时域及频域分析



以切深  $1.00\text{mm}$ 、进给速度  $73.83\text{mm/min}$ 、主轴转速  $704\text{转/min}$  加工条件为例, 实测振动信号曲线及其功率谱曲线如图 3-7、图 3-8 所示。采样频率为  $5000\text{Hz}$ , 采样时间  $0.6\text{秒}$ 。




图 3-7 不同磨损程度刀具的振动信号  
Fig.3-7 The vibration signal of the cutting tool of different wear




图 3-8 不同磨损程度刀具振动信号的功率谱  
Fig.3-8 The vibration signal power spectrum of the cutting tool of different wear

从不同程度磨损刀具振动的时域曲线及其功率谱可看出, 刀具振动信号包含丰富的频率成份且能量分散, 因此难以用时域或纯频域的数据处理方法获得表征刀具磨损程度的特征向量。

### 3.2.2.2 振动信号的小波包分解及特征向量提取

为了获取振动信号反映刀具磨损程度的特征值, 本文用小波包分解的方法把振动信号分解到互不重叠的各个频段中进行进一步分析。在工况 133 下, 三种不同程度磨损刀具对应振动信号的小波包分解各频道结果及其频谱如图 3-9、图 3-10、图 3-11 所示。

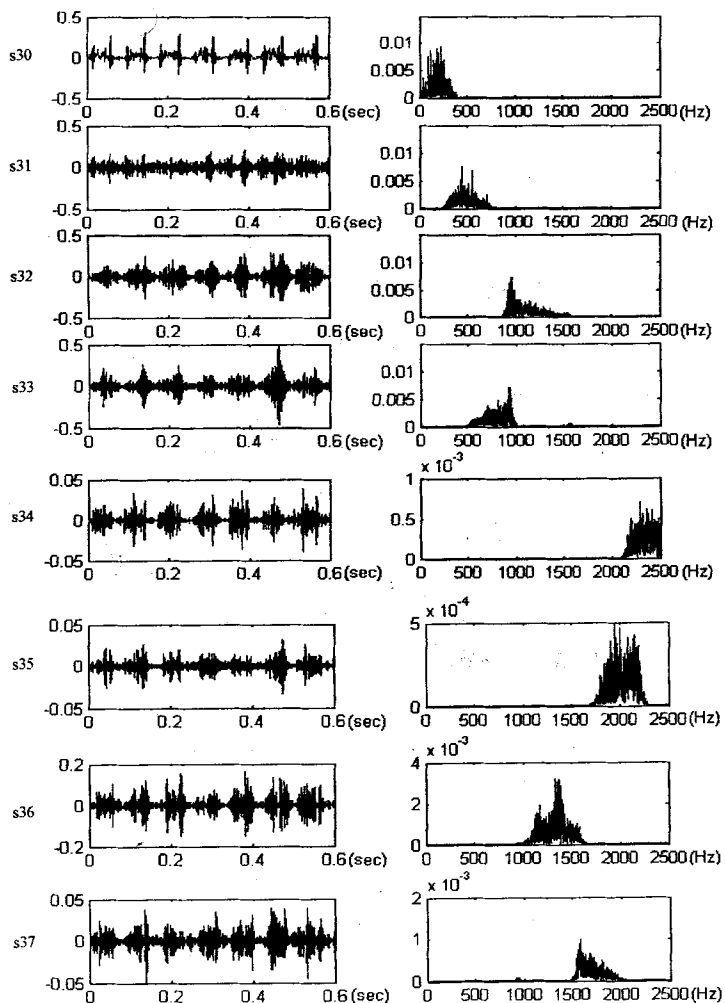


图 3-9 轻度磨损刀具对应振动信号的小波包分解各频道结果及其频谱  
 Fig.3-9 Vibration signal from cutting tool of slight wear decomposed by Wavelet packet,  
 with the results of channels and their spectrums

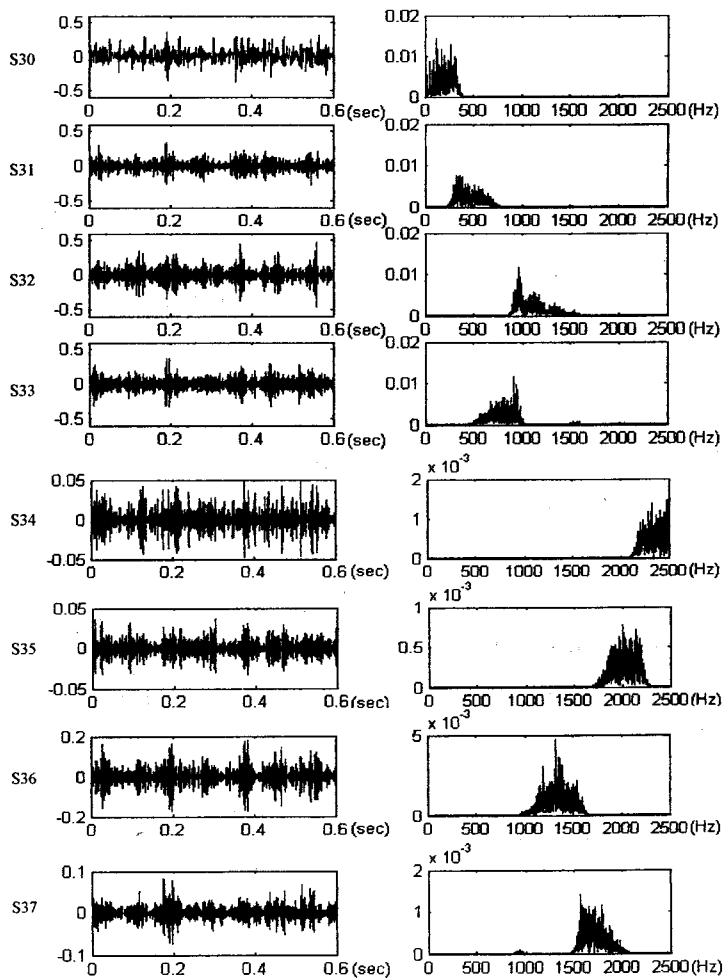


图 3-10 中度磨损刀具对应振动信号的小波包分解各频道结果及其频谱  
 Fig.3-10 Vibration signal from cutting tool of medium wear decomposed by Wavelet packet, with the results of channel and their spectrums

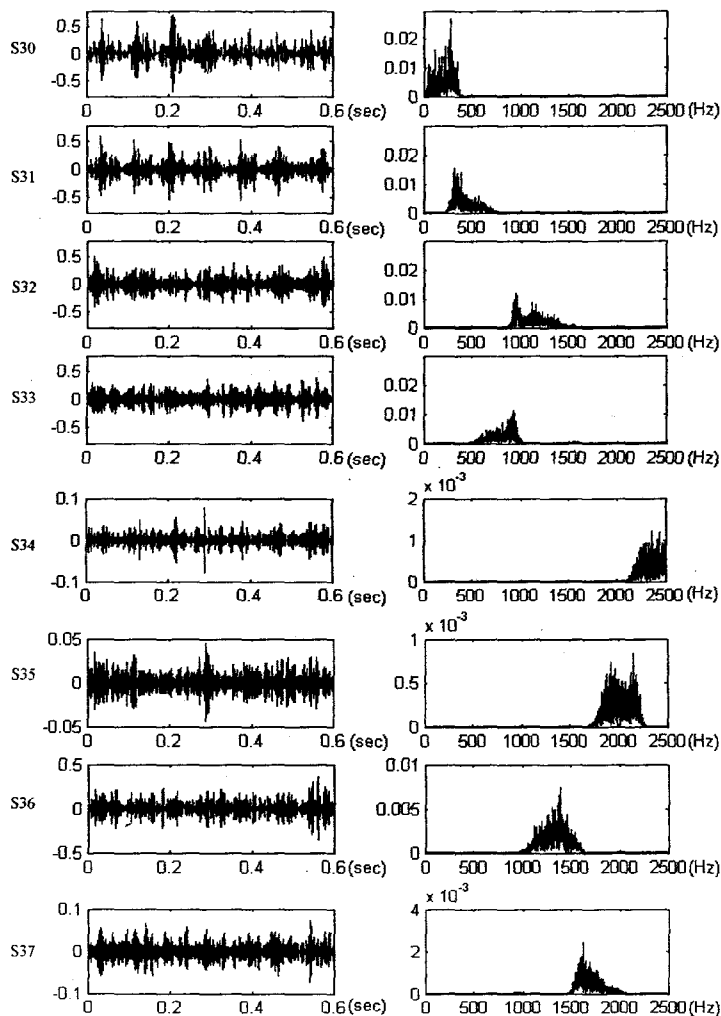


图 3-11 严重磨损刀具对应振动信号的小波包分解各频道结果及其频谱  
 Fig.3-11 Vibration signals from cutting tool of serious wear decomposed by Wavelet packet, with the results of channels and their spectrums

小波包分解的原理及意义在第二小节已作详细的介绍，以上各图中是采用 *db8* 小波包对振动信号进行三层分解，即把每组振动信号分解成 8 组频带范围的信号。*db* 小波是从双尺度方程系数  $\{h_i\}$  出发而设计的紧支撑正交小波，可实现信号正交分解和精确重构，适合于分析象振动这一类频率成份比较丰富的信号。小波包三层分解树结构图如图 3-12 所示：




图 3-12 小波包三层分解树结构

Fig.3-12 Tree structure of wavelet packet decomposition of three layers

Matlab 软件中的小波工具箱为对信号进行小波分析提供了方便而强大的支持。对振动信号的小波包分解可用如下语句实现：

```
load s133_vi.dat           %载入振动信号文件 s133_vi.dat;
[t,d]=wpdec(s133_vi,3,'db8','shannon'); %以 db8 小波对振动信号进行 3 层小波包
                                分解，采用 'shannon' 熵标准，并返回小
                                波包分解结构；
s30=wprcoef(t,d,[3,0]);    %利用小波包分解系数重构第三层结点信
...                          号，结点 (3,0) 的信号存入 s30 向量中，
s37=wprcoef(t,d,[3,7]);    其它结点类推。
```

由此一组振动信号  $s$  可以表示为： $s = s30 + s31 + \dots + s37$ 。从以上振动信号小波包分解各频道结果及其频谱图可看出，信号  $s30 \sim s37$  的频带分布并非按频率顺序排列，这是因为在小波包分解过程是隔点采样，对信号高频部分的分解会发生频率折迭，导致信号频率分布顺序错乱。对于三层小波包分解结果正确的频带分布顺序应为： $s30$ 、 $s31$ 、 $s33$ 、 $s32$ 、 $s37$ 、 $s36$ 、 $s34$ 、 $s35$ 。本课题的数据采样实验中，振动信号在被采集之前已经低通滤波，可认为获取的振动信号最高频率为滤波器的截止频率 2500Hz，因此 8 组分解信号对应的频带范围如表 3-1 所示：

表 3-1 分解信号及其对应的频带  
Table 3-1 Decomposed Vibration signal and their frequency band

信号	S30	S31	S32	S33
频率范围(Hz)	0-312.5	312.5-625	937.5-1250	625-937.5
信号	S34	S35	S36	S37
频率范围(Hz)	1875-2187.5	2187.5-2500	1562.5-1875	1250-1562.5

从振动信号分解的各频道结果及其频谱图还可看出，振动信号的能量主要集中在中低频段。对于同一磨损刀具产生的振动信号，不同频段的能量固然不同，对于不同

程度磨损刀具产生的振动信号，其相同频段的能量也存在差异，即可以通过比较各频带信号的能量去识别刀具磨损程度。定义各频带信号的能量为：

$$E_{3j} = \sqrt{\sum_{k=1}^{3000} |x_{jk}|^2} \quad (j = 0, 1, \dots, 7) \quad (3-45)$$

$x_{jk}$  表示各分解信号  $s_{3j}$  离散点的幅值。各频带信号的能量计算结果列于表 3-2：

表 3-2 各频带信号的能量

Table 3-2 Energy of the channel signals

	$E_{30}$	$E_{31}$	$E_{32}$	$E_{33}$	$E_{34}$	$E_{35}$	$E_{36}$	$E_{37}$
轻度磨损刀具	4.5329	3.8257	4.9478	4.6716	0.5943	0.4559	2.2264	0.7072
中度磨损刀具	8.5327	7.3207	7.2779	7.2588	1.2315	0.7887	3.1362	1.1103
严重磨损刀具	12.7152	8.7335	8.6114	7.7882	0.9925	0.6694	5.3017	1.5132

为了便于直观地比较不同磨损程度刀具信号同一信道的能量值，把表 3-2 中的数据画成曲线图如图 3-13 所示。




图 3-13 各频带信号的能量

Fig3-13 Energy of the channel signals

数据比较显示，不同程度磨损刀具分解信号  $s_{30}$ 、 $s_{31}$ 、 $s_{32}$ 、 $s_{33}$ 、 $s_{36}$  的能量值表现出较大的差异，可作为区分刀具磨损的依据。为了简化刀具监测系统模型的结构，本文仅采用分解信号中的  $s_{30}$ 、 $s_{33}$  及  $s_{36}$  的能量值作为切削振动的特征值。

同分析切削方信号的特征值相类似地，比较不同程度磨损刀具在同一工况下各自 16 组切削振动的特征值并绘出曲线图如图 3-14 所示。




图 3-14 不同程度磨损刀具在同一工况下各自 16 组切削振动特征值

Fig.3-14 16 groups of vibration character values produced by cutting tool of different wear under the same cutting condition

图 3-14 表明, 采用分解信号  $s_{30}$ 、 $s_{33}$  及  $s_{36}$  的能量值作为切削振动的特征值来识别刀具磨损的效果是稳定的。

### 3.3 本章小结

本章是关于刀具监测信号的处理。

首先介绍刀具监测信号处理的代表方法, 包括傅立叶变换和小波变换。傅立叶分析是传统的频域分析方法, 可以把瞬时多变的时域信号转换到频域上去分析; 小波分析是对信号进行时频分析的方法。小波变换相当于透过由基小波  $\psi(t)$  伸缩平移系  $\psi_{a,b}(t)$  确定的时频窗对信号进行观测, 而且这种时频窗是自适应变化的。多尺度分析是小波分析中非常重要的理论, 是理解和构造小波的统一框架。对信号进行多尺度小波分解, 可以把信号分解成不同频带的细节之和, 相邻尺度的频带宽度相差一倍, 随尺度的不同这些频带互不相叠, 且充满整个频率空间。小波包分解提供了一种更为灵活的信号处理方法, 可以对高频部分进一步分解, 任意地加强某些特定时段和特定频段的观察和分析, 是一种更广泛应用的小波分析方法。

对于本课题研究中所选择的切削力和切削振动刀具监测信号, 针对信号的不同特性提出了具体的信号特征提取方案。对于切削力, 其功率谱比较集中, 可用傅立叶变换的方法把时域信号转换成到频域上进行功率谱分析; 对于振动信号, 由于其功率谱比较分散, 难以在时域或纯频域内提取其特征值, 用小波包分解的方法, 把时域信号分解成不同频域段对应的子信号, 从这些子信号中选择最大程度上反映刀具磨损的组合作为研究对象, 再对这些组合进行特征提取。

## 第四章 刀具状态识别的神经网络技术

基于多传感器信息融合的刀具状态监测系统,在完成了多传感器信号数据采集及对这些数据进行特征值提取以后,接下来就是要建立合理的辨识模型,根据所获取的特征参数对加工过程的刀具状态进行分类判断。由于神经网络具有非线性映射、联想推理、自学习、自适应和大规模并行分布处理等能力<sup>[41]</sup>,因此适用于刀具状态监测辨识模型的建立。本章就本课题所采用的前向神经网络技术问题进行详细讨论。

### 4.1 前向神经网络的结构

神经网络是由大量处理单元广泛互连而成的网络,其基本思想是从仿生学的角度对人脑的神经系统进行模拟,使机器具有人脑那样的感知、学习和推理等智能<sup>[42]</sup>。

神经元是神经网络的基本处理单元,其结构如图 4-1 所示。




图 4-1 神经元模型  
Fig.4-1 Neural unit model

每一个神经元(如神经元  $i$ )接受来自其它神经元(如神经元  $j$ )的信息,总的输入为:

$$I_i = \sum_{j=1}^n w_{ij} x_j - \theta_i \quad (4-1)$$

式中  $w_{ij}$  表示神经元  $i$  和神经元  $j$  间的连接权;  $x_j$  为神经元  $j$  的输出;  $\theta_i$  表示神经元  $i$  的阈值。

神经元  $i$  的输出为:

$$O_i = f(I_i) \quad (4-2)$$

式中函数  $f()$  被称为激发函数。目前应用得最为广泛的激发函数是 Sigmoid 函数,即取神经元的输出为:

$$O_i = \frac{1}{1 + e^{-I_i}} \quad (4-3)$$

神经元按照一定的规则互联构成神经网络。神经网络有多种拓扑结构,而多层前向神经网络是其中一种主要类型。多层前向神经网络的结构如图 4-2 所示(图中为三层



网络), 包含输入层、隐层和输出层:




图 4-2 三层前向神经网络结构  
Fig.4-2 The forward neural network structure of three layers

可以证明, 任何一个非线性的映射都可以用一个三层前向网络来很好地逼近<sup>[43]</sup>, 这为前向人工神经网络的实际应用奠定了理论基础。

## 4.2 误差反向传播学习算法

神经网络是通过网络中各连接权值的改变实现信息的处理和贮存, 因此神经网络的学习算法, 说到底就是网络连接权的调整算法。在神经网络发展史上, 误差反向传播算法(简称 BP 算法)占有重要地位。早在 20 世纪 60 年代, 人们就认识到单个基本感知器的作用有限, 只能解决线性问题, 同时意识到多层前向神经网络有极大的发展潜力。但是, 由于当时还没有为多层前向神经网络找到一种有效的学习方法, 使人们对多层前向网络, 以至对整个神经网络的研究进入低潮。直到 1986 年, 以 Rumelhart 和 McClelland 为首的科学研究小组提出并行分布信息处理 (Parallel Distributed Processing) 网络思想及误差反向传播学习算法(BP 算法), 系统地解决了多层前向神经网络中隐层节点连接权值的学习问题, 才推动神经网络研究的复苏, 并促使神经网络的研究进入新的高潮。

BP 算法的基本思想是沿着误差负梯度的方向不断地修正权值及阈值, 使误差达到最小。由于 BP 算法思想直观, 容易理解, 直到现在, 仍然是多层神经网络最有效、最简单的学习算法之一。有时也将按这一学习算法进行训练的多层神经网络称为 BP 神经网络。BP 网络的学习由四个过程组成:

1. 输入模式由输入层经中间层向输出层的“正向传播过程”;
2. 网络的期望输出与实际输出的误差信号由输出层经中间层向输入层的“误差反向传播过程”;
3. 由“正向传播过程”与“误差反向传播过程”反复交替进行的网络“记忆训练过程”;
4. 网络趋收敛的“学习收敛过程”。

## 4.2.1 标准 BP 算法的基本计算原理和过程

以下以三层前向神经网络为例推导 BP 算法。

对于一个三层 BP 网络, 设输入模式向量  $X_k = (x_1, x_2, \dots, x_n)$ ,  $n$  为输入单元数, 希望输出的向量  $Y_k = (y_1, y_2, \dots, y_q)$ ,  $q$  为输出单元数; 中间层单元输入向量  $S_j = (s_1, s_2, \dots, s_p)$ , 输出向量  $B_k = (b_1, b_2, \dots, b_p)$ ,  $p$  为中间层单元数; 输出层单元输入向量  $L_t = (l_1, l_2, \dots, l_q)$ , 输出向量是  $C_k = (c_1, c_2, \dots, c_q)$ ; 输入层至中间层的连接权  $\{w_{ij}\}$   $i=1, 2, \dots, n$   $j=1, 2, \dots, p$ ; 中间层至输出层的连接权  $\{v_{jt}\}$   $j=1, 2, \dots, p$   $t=1, 2, \dots, q$ ; 中间层各单元输出阈值为  $\{\theta_j\}$   $j=1, 2, \dots, p$ ; 输出层各单元输出阈值为  $\{r_t\}$   $t=1, 2, \dots, q$ 。以上  $k=1, 2, \dots, m$ ,  $m$  为学习模式对数。

首先看 BP 网络的正向传播过程。根据前述的人工神经元模型及数学表达式可计算中间层各单元的输入  $\{s_j\}$  及输出  $\{b_j\}$  为:

$$s_j = \sum_{i=1}^n w_{ij} x_i - \theta_j \quad (4-4)$$

$$b_j = g(s_j) \quad j=1, 2, \dots, p \quad (4-5)$$

输出层各单元的输入向量  $\{l_t\}$  及输出向量  $\{c_t\}$ :

$$l_t = \sum_{j=1}^p v_{jt} b_j - r_t \quad (4-6)$$

$$c_t = f(l_t) \quad t=1, 2, \dots, q \quad (4-7)$$

输入信息正向传播结束后, 误差的反向传播开始。设第  $k$  个学习模式第  $t$  个输出单元的输出与实际输出的偏差为:

$$\delta_t^k = (y_t^k - c_t^k) \quad t=1, 2, \dots, q \quad (4-8)$$

$\delta_t^k$  的均方差为:

$$\begin{aligned} E_k &= \sum_{t=1}^q (y_t^k - c_t^k)^2 / 2 \\ &= \sum_{t=1}^q (\delta_t^k)^2 / 2 \quad t=1, 2, \dots, q \end{aligned} \quad (4-9)$$

为使  $E_k$  随连接权值及神经元阈值的修正按梯度下降, 则需求  $E_k$  对网络各连接权值及神经元阈值的偏导。先考虑输出层和隐层之间连接权值  $v_{jt}$  的调整过程。按梯度下降的原则, 连接权  $v_{jt}$  的调整量  $\Delta v_{jt}$  与  $\frac{\partial E_k}{\partial v_{jt}}$  的负值成正比, 即:

$$\Delta v_{jt} = -\alpha \frac{\partial E_k}{\partial v_{jt}} \quad 0 < \alpha < 1 \quad t=1, 2, \dots, q \quad j=1, 2, \dots, p \quad (4-10)$$

又有:  $\frac{\partial E_k}{\partial v_{jt}} = \frac{\partial E_k}{\partial c_t^k} \cdot \frac{\partial c_t^k}{\partial l_t} \cdot \frac{\partial l_t}{\partial v_{jt}}$

$$\begin{aligned}
 &= -(y_i^k - c_i^k) \cdot f'(l_i) \cdot b_j \quad t=1,2,\dots,q \quad j=1,2,\dots,p \\
 &= -\delta_i^k \cdot f'(l_i) \cdot b_j
 \end{aligned} \tag{4-11}$$

把(4-11)代入(4-10)得:

$$\begin{aligned}
 \Delta v_{jt} &= \alpha \cdot (y_i^k - c_i^k) \cdot f'(l_i) \cdot b_j \\
 &= \alpha \cdot \delta_i^k \cdot f'(l_i) \cdot b_j \quad t=1,2,\dots,q \quad j=1,2,\dots,p
 \end{aligned} \tag{4-12}$$

设输出层各单元的一般化误差为  $d_i^k$ ,  $t=1,2,\dots,q$   $k=1,2,\dots,m$ 。  $d_i^k$  定义为  $E_k$  对输出层输入  $l_i$  负偏导, 可得:

$$\begin{aligned}
 d_i^k &= -\frac{\partial E_k}{\partial l_i} = -\frac{\partial E_k}{\partial c_i^k} \cdot \frac{\partial c_i^k}{\partial l_i} = (y_i^k - c_i^k) \cdot f'(l_i) = \delta_i^k \cdot f'(l_i) \\
 &t=1,2,\dots,q; \quad j=1,2,\dots,p; \quad k=1,2,\dots,m
 \end{aligned} \tag{4-13}$$

则连接权  $v_{jt}$  的调整量  $\Delta v_{jt}$  可表示为

$$\Delta v_{jt} = \alpha \cdot d_i^k \cdot b_j \quad t=1,2,\dots,q; \quad j=1,2,\dots,p; \quad k=1,2,\dots,m \tag{4-14}$$

同理, 由输入层至中间层连接权的调整, 仍按梯度下降法的原则进行。连接权  $w_{ij}$  的微小变化, 对第  $k$  个模式的均方差的影响, 可由下式推导:

$$\begin{aligned}
 \frac{\partial E_k}{\partial w_{ij}} &= \left[ \sum_{t=1}^q \frac{\partial E_k}{\partial c_i^k} \cdot \frac{\partial c_i^k}{\partial l_i} \cdot \frac{\partial l_i}{\partial b_j} \right] \cdot \frac{\partial b_j}{\partial s_j} \cdot \frac{\partial s_j}{\partial w_{ij}} \\
 &= \left[ \sum_{t=1}^q -(y_i^k - c_i^k) \cdot f'(l_i) \cdot v_{jt} \right] \cdot g'(s_j) \cdot x_i \\
 &= \left[ \sum_{t=1}^q -d_i^k \cdot v_{jt} \right] \cdot g'(s_j) \cdot x_i \\
 &i=1,2,\dots,n; \quad j=1,2,\dots,p; \quad t=1,2,\dots,q; \quad k=1,2,\dots,m
 \end{aligned} \tag{4-15}$$

设中间层各单元的一般化误差为  $\{e_j^k\}$   $j=1,2,\dots,p$ ;  $k=1,2,\dots,m$ 。  $e_j^k$  定义为  $E_k$  对中间层输入  $s_j$  的负偏导:

$$\begin{aligned}
 e_j^k &= -\frac{\partial E_k}{\partial s_j} = -\left[ \sum_{t=1}^q \frac{\partial E_k}{\partial c_i^k} \cdot \frac{\partial c_i^k}{\partial l_i} \cdot \frac{\partial l_i}{\partial b_j} \right] \cdot \frac{\partial b_j}{\partial s_j} \\
 &= -\left[ \sum_{t=1}^q -(y_i^k - c_i^k) \cdot f'(l_i) \cdot v_{jt} \right] \cdot g'(s_j)
 \end{aligned}$$

$$= \left[ \sum_{t=1}^q d_t^k \cdot v_{jt} \right] \cdot g'(s_j) \quad (4-16)$$

其中  $j=1,2,\dots,p$ ;  $t=1,2,\dots,q$ 。

则式(4-15)可表示为:

$$\frac{\partial E_k}{\partial w_{ij}} = -e_j^k \cdot x_i \quad (4-17)$$

$$i=1,2,\dots,n; j=1,2,\dots,p$$

与式(4-10)类似, 连接权  $w_{ij}$  的调整量应为:

$$\begin{aligned} \Delta w_{ij} &= -\beta \frac{\partial E_k}{\partial w_{ij}} \\ &= \beta \cdot e_j^k \cdot x_i \end{aligned} \quad (4-18)$$

$$i=1,2,\dots,n; j=1,2,\dots,p; \quad 0 < \beta < 1$$

同理, 阈值  $\{r_j\}$  及  $\{\theta_j\}$  的调整量为:

$$\Delta r_t = -\gamma \cdot d_t^k \quad t=1,2,\dots,q; \quad 0 < \gamma < 1 \quad (4-19)$$

$$\Delta \theta_j = -\lambda \cdot e_j^k \quad j=1,2,\dots,p; \quad 0 < \lambda < 1 \quad (4-20)$$

以上的推导仅是针对一组学习模式进行, 各个连接权的调整量是分别与各个学习模式对的误差函数  $E_k$  成比例变化, 这种可调变量的学习方法称为标准误差反向传播算法。根据以上的推导过程, 可得到BP算法的具体学习步骤:

(1) 初始化 给各连接权  $\{w_{ij}\}$ 、 $\{v_{jt}\}$  及阈值  $\{\theta_j\}$ 、 $\{r_t\}$  赋予  $(-1,+1)$  间的随机值;

(2) 选第一模式对  $X_k = (x_1^k, x_2^k, \dots, x_n^k)$ ,  $Y_k = (y_1^k, y_2^k, \dots, y_q^k)$  提供给网络;

(3) 用输入模式  $X_k = (x_1^k, x_2^k, \dots, x_n^k)$ , 连接权  $\{w_{ij}\}$  及阈值  $\{\theta_j\}$  计算中间层各单元的输入  $s_j$ ; 然后用  $\{s_j\}$  通过中间层的激发函数  $g(s_j)$  计算中间层的输出  $\{b_j\}$ ;

$$s_j = \sum_{i=1}^n w_{ij} x_i - \theta_j$$

$$b_j = g(s_j) \quad j=1,2,\dots,p$$

(4) 用中间层的输出  $\{b_j\}$ 、连接权  $\{v_{jt}\}$  和阈值  $\{r_t\}$  计算输出层各单元的输入  $\{l_t\}$ , 然后通输出层的激发函数  $f(l_t)$  计算输出层各单元的响应  $\{c_t\}$ ;

$$l_t = \sum_{j=1}^p v_{jt} b_j - r_t$$

$$c_t = f(l_t) \quad t=1,2,\dots,q$$

(5) 用希望输出模式  $Y_k = (y_1^k, y_2^k, \dots, y_q^k)$ 、网络实际输出  $\{c_i\}$ ，计算输出层的各单元的一般化误差  $\{d_i^k\}$ ：

$$d_i^k = -\frac{\partial E_k}{\partial l_i} = -\frac{\partial E_k}{\partial c_i^k} \frac{\partial c_i^k}{\partial l_i} = (y_i^k - c_i^k) \cdot f'(l_i)$$

$$i=1, 2, \dots, q; \quad j=1, 2, \dots, p; \quad k=1, 2, \dots, m$$

(6) 用连接权  $\{v_{jt}\}$ 、输出层的一般化误差  $\{d_i^k\}$ 、中间层的输出  $\{b_j\}$  计算中间层的一般化误差  $\{e_j^k\}$ ：

$$e_j^k = -\frac{\partial E_k}{\partial s_j} = \left[ \sum_{i=1}^q d_i^k \cdot v_{jt} \right] \cdot g'(s_j)$$

$$j=1, 2, \dots, p; \quad t=1, 2, \dots, q$$

(7) 用输出层各单元的一般化误差  $\{d_i^k\}$ 、中间层各单元的输入  $\{b_j\}$  修正连接权  $\{v_{jt}\}$  和阈值  $\{r_t\}$ ：

$$v_{jt}(N+1) = v_{jt}(N) + \alpha \cdot d_i^k \cdot b_j$$

$$r_t(N+1) = r_t(N) - \gamma \cdot d_i^k$$

$$j=1, 2, \dots, p \quad t=1, 2, \dots, q$$

(8) 用中间层各单元的一般化误差  $\{e_j^k\}$ 、输入层各单元的输入  $X_k = (x_1^k, x_2^k, \dots, x_n^k)$  修正连接权  $\{w_{ij}\}$  和阈值  $\{\theta_j\}$ ：

$$w_{ij}(N+1) = w_{ij}(N) + \beta \cdot e_j^k \cdot x_i^k$$

$$\theta_j(N+1) = \theta_j(N) - \lambda \cdot e_j^k$$

$$i=1, 2, \dots, n \quad j=1, 2, \dots, p \quad t=1, 2, \dots, q$$

(9) 选取下一个学习模式对提供给网络，返回步骤(3)，直至全部  $m$  个模式对训练完成；

(10) 重新从第一个学习模式对开始，返回步骤(3)，直至网络全局误差  $E_k$  小于预先设定值，即网络收敛，如学习回数大于预先设定值，则网络无法收敛；

(11) 结束学习。

## 4.2.2 标准BP算法的Matlab实现

程序一是以 Matlab 语言演示标准 BP 算法的程序。在示例中建立一个结构为 2-2-1 前向网络模型，反映如表 4-1 所示的样本数据所描述的输入输出关系：

表4-1 标准BP算法示例程序输入输出数据样本

Table 4-1 Training samples of standard BP arithmetic program

模式(k)	1	2	3	4	5	6	7
$x_1^k$	0.1111	0.5556	0.7778	1.0000	0.9444	0.8333	0.6667
$x_2^k$	0.1235	0.3086	0.6049	1.0000	0.8920	0.6944	0.4444
$y^k$	0.6025	0.9024	0.9597	1.0000	0.98930	0.9723	0.9377

程序中以 Sigmoid 函数作为网络隐层激发函数，输出层神经元的激发函数取为线性函数，不考虑隐层和输出层的阈值，学习上限次数为 2000 次，目标误差 0.0001。根据前面介绍 BP 算法并沿用各公式符号记法和意义，结合实际所用的激发函数，直接写出迭代运算时连接权的调整量如下：

$$\Delta v_j = \alpha \cdot (y_i^k - c_i^k) \cdot b_j \quad (4-21)$$

$$\Delta w_{ij} = \beta \left[ \sum_{l=1}^q (y_l^k - c_l^k) \cdot v_{jl} \right] \cdot [g(s_j)(1-g(s_j))] \cdot x_i \quad (4-22)$$

其中  $b_j = g(s_j) = \frac{1}{1+e^{-s_j}}$ ,  $s_j = \sum_{i=1}^n w_{ij} x_i$ ,  $i=1,2$ ,  $j=1,2$ 。

程序一：

```

max_traintimes=2000; %设定最大学习次数
learning_times=0; %初始化学习次数
err_goal=0.0001; %误差目标
n=2; %输入层节点数
p=2; %隐层节点数
q=1; %输出层节点数
m=7; %输入模式数
learning_coefficient_w=0.9; %输入层与隐层权值学习率
learning_coefficient_v=0.8; %隐层与输出层权值学习率
x=[0.1111,0.5556,0.7778,1.0,0.9444,0.8333,0.6667; %输入输出数据及初始化可调参数
    0.1235,0.3086,0.6049,1.0,0.892,0.6944,0.4444];
y=[0.6025,0.9024,0.9597,1.0,0.9830,0.9723,0.9377];
v=[0.845177,-0.735398];
w=[-0.934225,-0.641090,0.764541,-0.432453];

for k=1:m %记录初始误差
s=w*x(1:2,k);
b=1./(1+exp(-s));
l(k)=v*b;
end
error=sum(0.5*(y(1:q,l:m)-l).*(y(1:q,l:m)-l));

```

```

plot_error(1)=error;

for traintimes=1:max_traintimes
for k=1:m
s=w*x(1:2,k);
b=1./(1+exp(-s));
l=v*b;
c=l;
d=y(1:q,k)-c;
deviate_v=learning_coefficient_v*d*b';
e=(v*d).*(b.*(1-b));
deviate_w=learning_coefficient_w*e*x(1:2,k);
v=v+deviate_v;
w=w+deviate_w;
end
learning_times=learning_times+1;
for k=1:m
s=w*x(1:2,k);
b=1./(1+exp(-s));
l(k)=v*b;
end
error=sum(0.5*(y(1:q,1:m)-l).*(y(1:q,1:m)-l));
plot_error(traintimes+1)=error;
if error<=err_goal
break;
end
end
plot(plot_error)
l
y
learning_times
error
    
```

%隐层的输入  
 %隐层的输出  
 %输出层的输入  
 %输出层的输出  
 %实际输出与网络输出的偏差  
 %隐层与输出层权值单次的调整值  
 %输入层与隐层权值单次的调整值  
 %经调整后隐层与输出层权值  
 %经调整后隐层与输入层权值  
 %每经过一次循环学习计算一次误差  
 %如果达到误差要求则退出学习  
 %画出误差曲线  
 %最终网络输出值  
 %实际输出值  
 %学习次数  
 %最终误差

运行以上程序，经过1931次迭代学习后，误差由初始值4.3834降到9.9961e-005，达到误差要求，学习误差曲线如图4-3所示：




图 4-3 标准 BP 算法学习误差曲线  
Fig 4-3 Learning error curve of standard BP arithmetic

## 4.2.3 改进的BP算法及效果示例比较

标准误差反向传播网络并不是一个十分完善的网络，它存在着以下的一些主要缺陷：

- (1) 学习收敛的速度太慢，即使一个比较简单的问题，也需要几百次甚至上千次的学习才能收敛；
- (2) 不能保证收敛到全局最小值，即存在能量函数局部极小值；
- (3) 容易引起振荡效应。

针对BP算法的缺点，文献<sup>[43-44]</sup>提出了不少的改进方案。在前人研究基础上，在本文中为加速BP网络学习的收敛速度及削弱学习振荡的可能性，在算法上引入如下机制：

- (1) 在权值的调整公式中引入动量项，即调整公式变为：

$$\Delta W(N+1) = -\beta \frac{\partial E_k}{\partial W} + \eta \Delta W(N)$$
。式中  $\Delta W(N+1)$  为第  $N+1$  次迭代计算时的修正值；

$\Delta W(N)$  为前一次迭代计算时所得的可调参数  $w$  修正值。动量项  $\eta \Delta W(N)$  的加入起到平滑梯度方向的剧烈变化，增加算法的稳定性；

- (2) 在学习过程中采用变学习率和最小误差保留策略。引入学习率增加因子和学习率降低因子，经过每一轮的学习，都将本次误差与前一次误差作比较，如果本次误差较大时说明参数调整幅度过大，使网络产生振荡，于是将本次参数调整结果放弃，降低学习率和动量因子，并返回到前一次参数基础上重新进行修正，直到网络误差脱离振荡，回到下降状态；如果本次误差比前一次误差较小时，则保留此次参数修正结果，并增大学习率，加快学习速度。这样，既可以加快网络收敛速度，又可以保证学习过程结束时，算法的输出就是学习过程中记录的最小误差及其相应的所有可调参数。

以 Matlab 语言演示引入上述机制的改进的 BP 算法如程序二所示，程序二同样采用表 4-1 的数据作为学习样本，学习上限次数和目标误差与程序一的设定相同。

程序二：

```

max_traintimes=2000;           %最大学习次数
learning_times=0;             %初始化学习次数
deviate_v=0;                  %初始化连接权 v 的值
deviate_w=0;                  %初始化连接权 w 的值
err_goal=0.0001;              %误差目标
n=2;                           %输入层节点数
p=2;                           %隐层节点数
q=1;                           %输出层节点数
m=7;                           %输入模式数
learning_coefficient_w=0.6;    %学习率
learning_coefficient_v=0.1;
learning_coefficient_acc_plus=1.01; %连接权学习率加速度
learning_coefficient_acc_minus=0.95;
momentum_coefficient=0.9;     %动量系数
x=[0.1111,0.5556,0.7778,1.0,0.9444,0.8333,0.6667;

```



```

    0.1235,0.3086,0.6049,1.0,0.892,0.6944,0.4444];
y=[0.6025,0.9024,0.9597,1,0.9830,0.9723,0.9377];
v=[0.845177,-0.735398];
w=[-0.934225,-0.641090;0.764541,-0.432453];
for k=1:m
    s=w*x(1:2,k);
    b=1./(1+exp(-s));
    l(k)=v*b;
end
old_error=sum(0.5*(y(1:q,1:m)-l).*(y(1:q,1:m)-l));           %记录下最初的误差值
plot_error(1)=old_error;
for traintimes=1:max_traintimes
    v_bak=v;
    w_bak=w;
    for k=1:m
        s=w*x(1:2,k);
        b=1./(1+exp(-s));
        l=v*b;
        c=1;
        d=y(1:q,k)-c;

%加入附加动量项的隐层与输出层权值单次的调整值
        deviate_v=learning_coefficient_v*d*b'+momentum_coefficient*deviate_v;
        e=(v*d).*(b.*(1-b));

%加入附加动量项的隐层与输入层权值单次的调整值
        deviate_w=learning_coefficient_w*e*x(1:2,k)+momentum_coefficient*deviate_w;

    v=v+deviate_v;
    w=w+deviate_w;
    end
    learning_times=learning_times+1;

%每经过一次循环学习计算一次误差，如果达到误差要求则退出学习
for k=1:m
    s=w*x(1:2,k);
    b=1./(1+exp(-s));
    l(k)=v*b;
end
new_error=sum(0.5*(y(1:q,1:m)-l).*(y(1:q,1:m)-l));
plot_error(traintimes)=new_error;
if new_error<=err_goal
    break;
end

%如果本次误差比前次小，则增加学习率以加快学习速度
if new_error<old_error
    learning_coefficient_v=learning_coefficient_v*learning_coefficient_acc_plus;
    learning_coefficient_w=learning_coefficient_w*learning_coefficient_acc_plus;
    momentum_coefficient=0.9;
    old_error=new_error;

%如果本次误差比前次大，则减小学习率和减小动量系数以减小振荡，并返回前一次参数的基础上重新进行修正，直到网络误差脱离振荡，回到下降状态。
elseif new_error>old_error
    learning_coefficient_v=learning_coefficient_v*learning_coefficient_acc_minus;
    learning_coefficient_w=learning_coefficient_w*learning_coefficient_acc_minus;

```

```

momentum_coefficient=0;
v=v_bak;
w=w_bak;
end
end
for k=1:m
s=w*x(1:2,k);
b=1./(1+exp(-s));
l(k)=v*b;
end
last_error=sum(0.5*(y(1:q,1:m)-l).*(y(1:q,1:m)-l)) %最终学习误差
plot(plot_error); %画出误差曲线
l %最终网络输出值
y %实际输出值
learning_times %学习次数

```

运行以上程序，经过143次迭代学习后误差由初始值4.3834降到9.9055e-005，达到误差要求，学习误差曲线如图4-4所示：




图 4-4 改进 BP 算法学习误差曲线  
Fig.4-4 Learning error curve of improved BP arithmetic

比较图 4-3 和图 4-4 的学习误差曲线可看出，经改进的 BP 算法的学习效率获得大大的改善。

### 4.3 小波神经网络

#### 4.3.1 小波神经网络参数调整公式

在前向神经网络中，Sigmoid 函数被广泛应用为激发函数，但由于 Sigmoid 函数自身的特性，基于 Sigmoid 函数作为神经元激发函数的神经网络只是一个次优网络<sup>[45]</sup>。人们为选择更优的激发函数作出努力的探索，小波神经网络正是这一领域内研究的成果，我们称神经元激发函数采用小波函数的神经网络为小波神经网络<sup>[46-47]</sup>。小波神经网络在解决复杂非线性函数关系等实际问题所表现出的优良已初步得到证实。文献<sup>[48]</sup>指出采用正交小波基代替传统的 Sigmoid 函数作为激发函数可以得到更适合于函数逼

近的函数逼近器；文献<sup>[49]</sup>还证明了对采用小波函数构成的单隐层小波神经网络，只要有足够多的隐层节点，则可以对任意非线性映射进行逼近。

本文以 Gauss 小波的伸缩平移系作为隐层激发函数构造小波网络。Gauss 小波基函数的表达式为：

$$\psi(t) = te^{-t^2/2} \quad (4-23)$$

Gauss 小波网络与传统 BP 神经网络不同在于隐层输出为：

$$g(s_j) = \psi_{a_j, h_j}(s_j) = \frac{1}{a_j} \frac{(s_j - h_j)^2}{a_j} e^{-\frac{(s_j - h_j)^2}{2a_j^2}} \quad (4-24)$$

直接写出迭代运算时各可调参数的调整量如下：

$$\Delta v_{ji} = \alpha \cdot (y_i^k - c_i^k) \cdot b_j \quad (4-25)$$

$$\Delta w_{ij} = \beta \left[ \sum_{t=1}^q (y_i^k - c_i^k) \cdot v_{jt} \right] \cdot \frac{\partial b_j}{\partial s_j} \cdot \frac{\partial s_j}{\partial w_{ij}} \quad (4-26)$$

$$\Delta a_j = \gamma \left[ \sum_{t=1}^q (y_i^k - c_i^k) \cdot v_{jt} \right] \cdot \frac{\partial b_j}{\partial a_j} \quad (4-27)$$

$$\Delta h_j = \lambda \left[ \sum_{t=1}^q (y_i^k - c_i^k) \cdot v_{jt} \right] \cdot \frac{\partial b_j}{\partial h_j} \quad (4-28)$$

其中：  $\frac{\partial b_j}{\partial s_j} = \left[ \frac{1}{a_j^2} - \frac{(s_j - h_j)^2}{a_j^4} \right] e^{-\frac{(s_j - h_j)^2}{2a_j^2}} ; \frac{\partial s_j}{\partial w_{ij}} = x_i ; \frac{\partial b_j}{\partial h_j} = -\frac{\partial b_j}{\partial s_j} ;$

$$\frac{\partial b_j}{\partial a_j} = \left[ -\frac{2(s_j - h_j)}{a_j^3} + \frac{(s_j - h_j)^3}{a_j^5} \right] e^{-\frac{(s_j - h_j)^2}{2a_j^2}} ; \alpha、\beta、\gamma、\lambda \text{ 为学习系数。}$$

### 4.3.2 小波神经网络效果示例

程序三是以 Matlab 语言演示 Gauss 小波神经网络的程序。在示例中反映的仍是如表 4-1 所示的样本数据所描述的输入输出关系，其步骤过程、初始化设定和程序二大致相同，所不同的在于增加尺度因子和位移因子作为可调参数，而且各可调参数的调整公式有所差异。

程序三：

```

max_trainimes=2000;           %最大学习次数
learning_times=0;             %初始化学习时间
err_goal=0.0001;              %误差目标
n=2;                           %输入层节点数
    
```

```

p=2; %隐层节点数
q=1; %输出层节点数
m=7; %输入模式数
deviate_v=0; %初始化各连接权值偏移量
deviate_w=0;
deviate_a=0; %初始化尺度因子、时间因子偏移量
deviate_h=0;
learning_coefficient_w=0.6; %初始化各可调参数
learning_coefficient_v=0.6;
learning_coefficient_h=0.4;
learning_coefficient_a=0.4;
learning_coefficient_acc_plus=1.02; %连接权学习率加速度
learning_coefficient_acc_minus=0.98; %连接权学习率加速度
momentum_coefficient=0.4; %动量系数

x=[0.1111,0.5556,0.7778,1,0,0.9444,0.8333,0.6667;0.1235,0.3086,0.6049,1,0,0.892,0.6944,0.4444];
y=[0.6025,0.9024,0.9597,1,0.9830,0.9723,0.9377];
v=[0.845177,-0.735398];
w=[-0.934225,-0.641090;0.764541,-0.432453];
a=[1;1];
h=[1;1];

for k=1:m
s=w*x(1:2,k);
b=(s-h)/a.^2.*exp(-(s-h).^2./a.^2./2);
l(k)=v*b;
end
old_error=sum(0.5*(y(1:q,1:m)-l).*(y(1:q,1:m)-l)); %记录下最初的误差值
plot_error(1)=old_error;

for traintimes=1:max_traintimes
v_bak=v;
w_bak=w;
a_bak=a;
h_bak=h;
for k=1:m
s=w*x(1:2,k); %隐层的输入
b=(s-h)/a.^2.*exp(-(s-h).^2./a.^2./2); %隐层的输出
l=v*b; %输出层的输入
c=l; %输出层的输出
d=y(1:q,k)-c; %实际输出与网络输出的偏差

%隐层与输出层权值单次调整值
deviate_v=learning_coefficient_v*d*b'+momentum_coefficient*deviate_v;

%输入层与隐层权值单次调整值
e=(v*d).*(1./a.^2-(s-h).^2./a.^4).*exp(-(s-h).^2./a.^2./2));
f=(v*d).*(-2*(s-h)/a.^3.*exp(-1/2*(s-h).^2./a.^2)+(s-h).^3./a.^5.*exp(-1/2*(s-h).^2./a.^2));
deviate_w=learning_coefficient_w*e*x(1:2,k)'+momentum_coefficient*deviate_w;

%位移因子单次调整值
deviate_h=-learning_coefficient_h*e+momentum_coefficient*deviate_h;

%尺度因子单次调整值
deviate_a=learning_coefficient_a*f+momentum_coefficient*deviate_a;

```

```

%可调参数的调整
v=v+deviate_v;
w=w+deviate_w;
h=h+deviate_h;
a=a+deviate_a;
end
learning_times=learning_times+1;

%每经过一次循环学习计算一次误差，如果达到误差要求则退出学习
for k=1:m
    s=w*x(1:2,k);
    b=(s-h)/a.^2.*exp(-(s-h).^2./a.^2./2);
    l(k)=v*b;
end
new_error=sum(0.5*(y(1:q,1:m)-l)*(y(1:q,1:m)-l));
plot_error(traintimes+1)=new_error;
if new_error<=err_goal
    break;
end

%如果本次误差比前次小，则增加学习率以加快学习速度
if new_error<old_error
    learning_coefficient_v=learning_coefficient_v*learning_coefficient_acc_plus;
    learning_coefficient_w=learning_coefficient_w*learning_coefficient_acc_plus;
    learning_coefficient_a=learning_coefficient_a*learning_coefficient_acc_plus;
    learning_coefficient_h=learning_coefficient_h*learning_coefficient_acc_plus;
    momentum_coefficient=0.4;
    old_error=new_error;

%如果本次误差比前次大，则减小学习率和减小动量系数以减小振荡，并返回前一次参数的基础上重新进行修正，直到网络误差脱离振荡，回到下降状态。
elseif new_error>old_error
    learning_coefficient_v=learning_coefficient_v*learning_coefficient_acc_minus;
    learning_coefficient_w=learning_coefficient_w*learning_coefficient_acc_minus;
    learning_coefficient_a=learning_coefficient_a*learning_coefficient_acc_minus;
    learning_coefficient_h=learning_coefficient_h*learning_coefficient_acc_minus;
    momentum_coefficient=0;
    v=v_bak;
    w=w_bak;
    a=a_bak;
    h=h_bak;
end
end

for k=1:m
s=w*x(1:2,k);
b=(s-h)/a.^2.*exp(-(s-h).^2./a.^2./2);
l(k)=v*b;
end
last_error=sum(0.5*(y(1:q,1:m)-l)*(y(1:q,1:m)-l))
plot(plot_error);
l
y
learning_times
    
```

运行以上程序，经过 58 次迭代学习后误差由初始值 1.9152 降到  $9.9934e-005$ ，达到误差要求，学习误差曲线如图 4-5 所示：




图 4-5 小波神经网络学习误差曲线  
Fig.4-5 Learning error curve of wavelet neural network

从图 4-5 小波神经网络的学习误差曲线可看出，小波神经网络可以实现快速的学习。

#### 4.4 本章小结

本章就课题研究所采用的前向神经网络相关技术问题进行讨论。首先介绍前向神经网络的结构，然后推导被广泛用于前向神经网络学习的 BP 算法，并以 Matlab 语言给出具体的示例程序。针对标准 BP 算法存在诸如学习速度过慢、局部收敛及学习过程中出现振荡等问题，提出 BP 算法的改进方案，并以程序演示 BP 算法经过改进后的实际效果。小波神经网络是神经网络研究中一个新的重要分支，是小波理论与人工神经网络思想的结合。本文以 Gauss 小波函数作为激发函数构造小波神经网络，并编写网络实例程序，示例程序表明 Gauss 小波神经网络是一种强收敛性的网络。

## 第五章 刀具状态监测的实现与分析

前面已就构成刀具状态监测的各个部分进行详细的介绍，本章综合运用前面提及的理论，结合实验的数据，建立刀具状态监测模型，同时进行多种方案的对比，展开基于多传感器信息融合的刀具状态监测研究。

### 5.1 刀具监测系统的实验方案

#### 5.1.1 实验装置简介

本刀具监测试验系统原理图如图 5-1 所示。

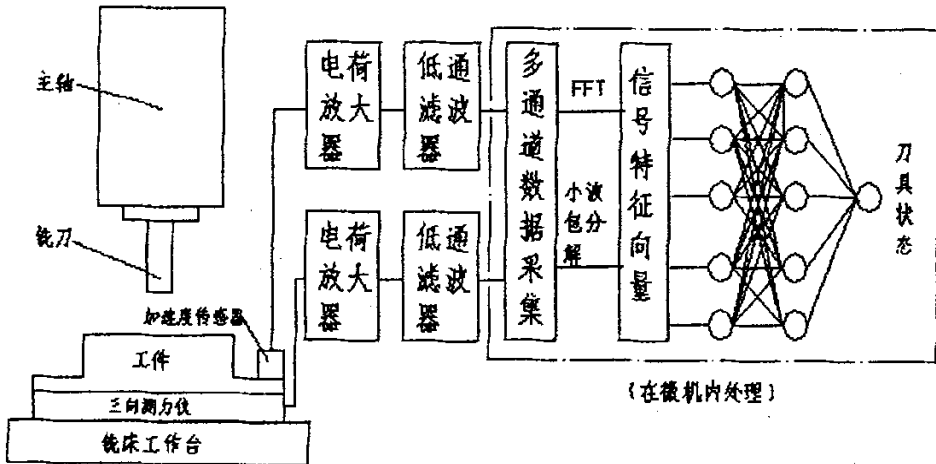


图 5-1 刀具监测试验系统示意图

Fig.5-1 The sketch map of tool condition monitoring system

在本刀具监测试验系统中，利用三向测力仪和加速度传感器对铣削过程中切削力信号和振动信号进行检测，以快速傅立叶变换和小波包分解对检测信号进行特征提取，用神经网络模型实现数据融合，完成对 HSS 直柄三刃立铣刀磨损的监测。本试验系统的实验装置如图 5-2 所示，包括如下部分：

- ◇ 采用 XK5140 型立式数控铣床作为铣床工作台；
- ◇ 采用三菱公司型号为 FR-540 变频调速器对铣床主轴调速；
- ◇ 采用瑞士 KISTLER 公司制造的 9257A 型压电晶体测力仪和 5006 型电荷放大器，检测 X、Y 向切削力；


- ◇ 采用北京测振仪器厂生产的 YD-5 型加速度传感器并配同一厂家生产的 DHF-2 型电荷放大器检测切削振动;
- ◇ 采用工控机采集信号, 提高稳定性;
- ◇ 采用研华(ADVANTECH)有限公司生产的型号为 NI PCI6024 数据采集板卡采集数据, 该板卡提供 16 条模拟信号输入通道, 2 条模拟信号输出通道和 8 条数字信号输入 / 输出通道;
- ◇ 工件材料选用 20 厚 90×120 的 A3 板料;
- ◇ 刀具选用  $\phi 12$  三齿高速钢立铣刀。



DHF-2 型电荷放大器、5006 型电荷放大器及采集数据用的工控机 (内有 NI PCI6024 数据采集板卡)



9257A 型压电晶体测力仪、YD-5 型加速度传感器与刀具



NI PCI6024 数据采集板卡外部连线

图 5-2 实验装置的照片

Fig.5-2 Graph of experimental devices



### 5.1.2 工况条件的设计及数据的记录组织

在正式进行信号采集实验之前要准备不同磨损程度的刀具。本系统以 $\phi 12$ 高速钢立铣刀作为监测对象。先用铣刀对棒料进行正常工况条件下的反复切削，经过一段时间的切削后，取下刀具在显微镜下观察其磨损量，如未达到预定磨损值则重新装刀继续“磨刀”，直到产生符合实验要求的磨损的刀具。由于本实验用的数控铣床较为陈旧，刀具装夹后存在无法消除的偏心现象，因此对同一把铣刀进行多次装夹时有意改变其安装角度，力求三齿获得大致相同的磨损量。图 5-3 为在显微镜下观测铣刀磨损量的照片。用这种方法产生三把分别代表轻度磨损、中度磨损和严重磨损的铣刀；其实测平均后刀面磨损量分别为 $0.105\text{mm}$ 、 $0.304\text{mm}$ 和 $0.598\text{mm}$ 。




图 5-3 在显微镜下观测铣刀磨损量  
Fig. 5-3 Measure the wearing value of milling cutter using the microscope

至于工况条件的选取，结合半精加工参数选择标准和实验的具体条件限制（工件安装在 9257A 型压电晶体测力仪切削时无法用冷却液），把切削三要素中的切削深度、进给速度和主轴转速分别按高、中、低分成三个等级：切削深度分别选用  $1.00\text{mm}$ 、 $2.00\text{mm}$  和  $3.00\text{mm}$ ；进给速度分别选用  $47.09\text{mm}/\text{min}$ 、 $60.46\text{mm}/\text{min}$  和  $73.83\text{mm}/\text{min}$ ；主轴转速分别选用 502 转/min、603 转/min、704 转/min，先对切削深度、进给速度和主轴转速的三个等级参数优先按正交实验进行组合得到 9 组工况条件，然后把切削三要素的三个等级随机组合得到另外的 4 组工况条件，共得到 13 组工况条件组合。接着分别用已准备好的不同程度磨损的铣刀在上述 13 种工况条件下进行纵向直线切削，在切削过程中同时采集 x 向切削力信号、y 向切削力信号和振动信号，在每一种工况条件下都采集 16 组样本数据（预定 8 组作为训练样本，8 组作为校核样本），共得到  $31 \times 3 \times 16 = 1488$  组数据（工况条件与磨损刀具组合数  $\times$  监测信号类型数  $\times$  同种类型信号采集组数）。对数据采样时，切削力信号的采样频率为 200Hz，采样时间为 1.2 秒；振动信号的采样频率 5000Hz，采样时间为 0.6 秒，采样数据以文件形式存贮在计算机中。表 5-1 列出数据采集试验参数选择。

表 5-1 数据采集试验参数选择表  
Table 5-1 Machining parameters of collecting data experiment

刀具磨损量 (mm)	工况条件			工况简记
	切削深度 (mm)	进给速度 <i>mm/min</i>	主轴转速 转/min	
0.102	1.00	47.09	502	S111*
	1.00	60.46	603	S122*
	1.00	73.83	704	S133*
	2.00	47.09	603	S212*
	2.00	60.46	704	S223*
	2.00	73.83	502	S231*
	3.00	47.09	704	S313*
	3.00	60.46	502	S321*
	3.00	73.83	603	S332*
	1.00	73.83	502	S131
0.304	1.00	47.09	502	M111*
	1.00	60.46	603	M122*
	1.00	73.83	704	M133*
	2.00	47.09	603	M212*
	2.00	60.46	704	M223*
	2.00	73.83	502	M231*
	3.00	47.09	704	M313*
	3.00	60.46	502	M321*
	3.00	73.83	603	M332*
	3.00	60.46	603	M322
0.598	1.00	47.09	502	L111*
	1.00	60.46	603	L122*
	1.00	73.83	704	L133*
	2.00	47.09	603	L212*
	2.00	60.46	704	L223*
	2.00	73.83	502	L231*
	3.00	47.09	704	L313*
	3.00	60.46	502	L321*
	3.00	73.83	603	L332*
	2.00	73.83	603	L232
3.00	60.46	704	L323	

(注：带\*号的工况组合构成正交实验组合)

在上表和以后讨论中，为了叙述和数据组织的方便，进行这样的约定：用数字 1、2、3 来代表切削用量中的三个等级；用字母 s、m、l 来代表刀具的轻度磨损 (small wear)、中度磨损 (medium wear) 和严重磨损 (large wear)；用“切削深度-进给速度-主轴转速”组合的方式来表示工况。在这样的约定下，对于轻度磨损刀具在切削深度 1mm、进给速度 47.09mm/min、主轴转速 502 转/min 的工况可简记为 s111，在此工况下记录的 x 向切削力、y 向切削力、切削振动数据分别记为 s111\_fx、s111\_fy 和 s111\_vi。

## 5.2 神经网络建模的引入及输入数据处理

第三章已对切削力信号及切削振动信号作了详细的分析,并得出结论:  $x$  向切削力和  $y$  向切削力在主轴旋转频率对应点的功率、切削振动经小波包分解的频段信号  $s_{30}$ 、 $s_{33}$  及  $s_{36}$  对应能量值包含刀具的磨损信息,可作为刀具监测系统中切削力和切削振动的特征值。把这些特征值分别简记为  $x_1^k$ 、 $x_2^k$ 、 $x_3^k$ 、 $x_4^k$  和  $x_5^k$ ,  $k$  表示获得这些特征值的实验序号。按照前述数据采集实验的设计,刀具与工况条件有 31 种组合,在每种组合下采集 16 组切削力和 16 组切削振动数据,因此  $k$  有最大值为  $k_{\max} = 31 \times 16 = 496$ 。这 5 种特征值和刀具的后刀面的磨损量(以  $VB$  表示)通过一定的映射关系联系起来,可表示为:

$$VB = f(x_1^k, x_2^k, x_3^k, x_4^k, x_5^k) \quad (5-1)$$

然而,这种映射关系显然是相当复杂的,难以找到确定的数学方程进行描述。因为神经网络具有逼近任意非线性映射的能力,可以用来描述这一关系,本刀具监测正是以神经网络模型实现这种映射,而采用的网络类型为第四章所讨论的前向神经网络。具体的做法是:将切削力和切削振动的特征值组成特征向量,在获得一定数量的特征向量和相应后刀面磨损量后,将特征向量作为神经网络的输入,而相应后刀面磨损量作为输出对神经网络进行训练,当网络的输出误差达到足够小时就可实现式(5-1)反映的映射关系,这种被训练好的网络可用来进一步实现利用特征向量来辨识刀具的磨损状况。

神经网络在训练时的收敛速度与输入数据的分布密切相关,有必要对特征值进行归一化处理。在本模型构造中,作为识别刀具磨损程度的 5 种特征值被视为相互独立的输入数据,对它们的归一化处理按 5 组类别分别进行。归一化公式如下:

$$x_i^k = \frac{x_i^k - \min(x_i^1, x_i^2, \dots, x_i^{496})}{\max(x_i^1, x_i^2, \dots, x_i^{496}) - \min(x_i^1, x_i^2, \dots, x_i^{496})} \quad (5-2)$$

$$k = 1, 2, 3, 4, 5$$

把所有特征值按公式(5-2)进行归一化处理后组成特征向量得到神经网络的学习样本和校对样本的输入值。

## 5.3 刀具状态监测的实现

### 5.3.1 单一工况条件下刀具状态监测

对刀具状态监测的研究遵循先简单后复杂的次序,先对单一工况条件下的刀具监测系统进行讨论。以下两小节比较采用单一传感器检测信号与采用多传感器信号监测刀具磨损的异同以及不同神经网络的学习性能。

## 5.3.1.1 以切削力信号作为监测信号进行建模

为比较不同神经网络的学习性能, 进行以下尝试:

## 1. 首先用传统 BP 网络建模。

神经网络的输入是经归一化处理后的  $x$  向切削力和  $y$  向切削力在主轴旋转频率对应点的功率组成特征向量, 隐层数取为 5 个, 输出为铣刀的磨损量, 网络结构为 2-5-1。以工况 122 作为示例详细讨论建模过程。随机选取 3 种磨损程度刀具各自对应的 8 组切削力实验数据经特征值提取后组成特征向量, 即 24 组特征向量, 作为训练样本如表 5-2 所示。具体建模时以 Sigmoid 函数  $\frac{1}{1+e^{-x}}$  作为网络隐层激发函数, 输出层神经元的激发函数取为线性函数, 不考虑隐层和输出层的阈值, 将学习次数上限设为 2000 次, 不设定误差目标, 学习算法采用第四章所介绍的改进 BP 算法。

表 5-2 在工况 122 下以切削力为特征值建模的训练样本

Table 5-2 The training samples of network model that only used the character values of cutting force as the inputs under the condition of 122

序号	1	2	3	4	5	6	7	8
$X_1$	0.0580	0.1450	0.4176	0.0575	0.1430	0.4148	0.0550	0.1304
$X_2$	0.0603	0.1096	0.3669	0.0731	0.1226	0.3547	0.0779	0.1352
VB(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
序号	9	10	11	12	13	14	15	16
$X_1$	0.4346	0.0779	0.1767	0.4228	0.0642	0.1908	0.4302	0.0586
$X_2$	0.3704	0.0877	0.1430	0.3648	0.0979	0.1374	0.3804	0.0986
VB(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
序号	17	18	19	20	21	22	23	24
$X_1$	0.1500	0.4143	0.0638	0.1633	0.4208	0.0715	0.1538	0.4198
$X_2$	0.1453	0.3589	0.1066	0.1651	0.3666	0.1095	0.1336	0.3631
VB(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6

对神经网络进行训练时, 初始连接权值及神经元的阈值由随机数产生, 因此每次训练结果会有不同, 表 5-3 中列出对传统 BP 网络 18 次的训练结果。

表 5-3 传统 BP 网络 18 次的学习结果

Table 5-3 Learning results of 18 times of traditional BP network

训练序号	1	2	3	4	5	6
最终误差	0.0079	0.0070	0.0072	0.0067	0.0073	0.0065
训练序号	7	8	9	10	11	12
最终误差	0.0060	0.0063	0.0069	0.0074	0.0061	0.0076
训练序号	13	14	15	16	17	18
最终误差	0.0066	0.0067	0.0072	0.0071	0.0075	0.0068

从表 5-3 看出, 对于传统的 BP 网络模型, 尽管由随机数产生的初始值各异, 但每次学习最终误差相差不大, 界于 0.0079 与 0.0060 之间。为验证学习结果有效程度, 取最优学习组别的结果对包含 24 组测试向量的检验样本进行检验。其中最优学习组别的学习结果为:

$$w = \begin{bmatrix} -1.0172 & -0.8588 \\ 0.9663 & -1.2454 \\ -4.3961 & -2.2689 \\ -0.9671 & -1.0710 \\ -1.9469 & -0.9278 \end{bmatrix}, \quad v = [0.2440 \quad 1.2249 \quad -1.6122 \quad 0.3031 \quad -0.2845]$$

其中  $w$  为输入层与隐层的权值,  $v$  为隐层与输出层之间的权值。检验样本如表 5-4 所示:

表 5-4 在工况 122 下以切削力为特征值建模的检验样本

Table 5-4 The testing samples of network model that only used the character values of cutting force as the inputs under the condition of 122

测试向量序号	1	2	3	4	5	6	7	8
$X_1$	0.0572	0.1758	0.4196	0.0549	0.1397	0.4140	0.0725	0.1734
$X_2$	0.0734	0.1163	0.3621	0.0898	0.1245	0.3591	0.0899	0.1417
VB(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
测试向量序号	9	10	11	12	13	14	15	16
$X_1$	0.4250	0.0616	0.1678	0.4295	0.0623	0.1833	0.4289	0.0601
$X_2$	0.3697	0.0900	0.1322	0.3774	0.0945	0.1420	0.3763	0.0928
VB(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
测试向量序号	17	18	19	20	21	22	23	24
$X_1$	0.1765	0.4141	0.0680	0.1930	0.4234	0.0669	0.1583	0.4207
$X_2$	0.1534	0.3557	0.1023	0.1413	0.3833	0.1126	0.1490	0.3694
VB(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6

完成训练后的传统 BP 网络对表 5-4 检验样本的输出如表 5-5 所示:

表 5-5 传统 BP 网络对表 5-4 检验样本的输出

Table 5-5 The output of traditional BP network for the testing samples of table 5-6

测试向量序号	1	2	3	4	5	6	7	8
实际磨损(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
输出磨损(mm)	0.0879	0.3218	0.5988	0.0902	0.2624	0.5954	0.1250	0.3242
误差(%)	12.1406	7.2646	0.2079	9.7557	12.5463	0.7649	24.9567	8.0587
测试向量序号	9	10	11	12	13	14	15	16
实际磨损(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
输出磨损(mm)	0.6008	0.1036	0.3126	0.6021	0.1068	0.3403	0.6019	0.1018
误差(%)	0.1330	3.5902	4.1905	0.3444	6.8367	13.4237	0.3203	1.7951

续表 5-5

测试向量序号	17	18	19	20	21	22	23	24
实际磨损(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6
输出磨损(mm)	0.3319	0.5962	0.1212	0.3555	0.5965	0.1232	0.3011	0.5979
误差(%)	10.6487	0.6286	21.1962	18.5128	0.5857	23.2008	0.3618	0.3560

对表 5-5 所列的输出误差进行统计可得平均误差为 7.58%: 对于某个测试样本, 如果其输出误差不超过 15%时可认为这个样本正确的辨认, 按照这一标准, 可计算出传统 BP 网络对表 5-4 检验样本的辨认率为 83.33%(24 个检验样本中 20 个能被识别), 显然这个结果还不十分理想。

## 2. 用小波神经网络建模。

用第四章所讨论过的 Gauss 小波神经网络进行建模。仍以工况 122 作为示例进行讨论建模过程, 网络结构为 2-5-1, 用表 5-2 的学习样本对小波神经网络进行训练, 记录 12 次的训练结果如表 5-6 所示。

表 5-6 Gauss 小波神经网络 12 次的学习结果

Table 5-6 Learning results of 12 times of Gauss wavelet neural network

训练序号	1	2	3	4	5	6
最终误差	0.0052	0.0072	0.0054	0.0076	0.0063	0.0082
训练序号	7	8	9	10	11	12
最终误差	0.0015	0.0071	0.0083	4.408e-4	0.0058	0.0062

从上表看出, 经过训练, Gauss 小波神经网络的最终误差可以达很小, 但 12 次的学习结果相差很大, 这说明 Gauss 小波神经网络具有很大的“收敛潜力”, 但其学习效果对可调参数初始化取值十分敏感。为改善这种状况, 有必要寻找方法获得优秀的初始权值而不是只靠运气由随机数产生, 这对于小波神经网络尤为重要。文献<sup>[50]</sup>将小波神经网络初始权值的设置和学习样本、神经元激活函数发生联系, 为小波神经网络的参数初始化提供了实用的解决方案。本文以 Matlab 语言实现这种初始权值的设置:

```
%输入层与隐层间权值  $w_{ji}$  的初始化
%随机产生[-1,1]区间上的随机数作为  $w_{ji}$  初始值
w=rand(p,n);
w=w.*sign(w-0.5);

%对  $w_{ji}$  按行进归一化
base_w_one_column=(sqrt(sum((w.*w))));
for produce_column_n=1:n
base_w(1:produce_column_n)=base_w_one_column;
end
```

```

w=w./base_w;

%将  $w_{ji}$  乘以一个与输入层节点  $I$ 、隐层节点数  $J$  以及激活函数相关的因子
w=1.8*p^(1/n)*w;

%按公式  $w_{ji} = 2w_{ji} / (x_{i_{max}} - x_{i_{min}})$  取值  $w_{ji}$ 
x_max=(max(x'));
x_min=(min(x'));
one_line_max_min=x_max-x_min;
for produce_line_p=1:p
max_min(produce_line_p,1:n)=one_line_max_min;
end
w=2*w/max_min;

%隐层阈值的初始设置
%随机产生[-1,1]区间上的随机数作为  $\theta_j$  初始值
fa_one=rand(p,1);
fa_one=fa_one.*sign(fa_one-0.5);

%将  $\theta_j$  乘以一个与输入层节点  $I$ 、隐层节点数  $J$  以及激活函数相关的因子
fa_one=1.8*p^(1/n)*fa_one;

%按公式  $\theta_j = \theta_j - 0.5 \sum_{i=1}^I w_{ji} (x_{i_{max}} + x_{i_{min}})$  取值  $\theta_j$ 
fa_one=fa_one-0.5*w*(x_max+x_min);

%尺度因子初始化
a=(w*x_max'-w*x_min')/(2*1.22474487);

%平移因子初始化
h=(w*x_max'+w*x_min')/2;

%隐层与输出层间权重初始化
v=rand(q,p);
v=v.*sign(v-0.5);
    
```

按上述方法设置初始化参数后用表 5-2 的学习样本再对小波神经网络进行训练,记录 12 次的训练结果如表 5-7 所示:

表 5-7 优化初始参数的 Gauss 小波神经网络 12 次的学习结果  
 Table 5-7 Learning results of 12 groups of Gauss wavelet neural network that have the optimized initial parameters

训练序号	1	2	3	4	5	6
最终误差	2.512e-4	4.088e-4	0.002	5.279e-4	4.979e-4	0.0061
训练序号	7	8	9	10	11	12
最终误差	0.0016	2.034e-4	1.747e-4	0.0014	6.789e-4	6.159e-4

取最优学习组别(第九组)的训练结果确定网络可调参量并对表 5-4 检验样本进行验

证, 结果列于表 5-8:

表 5-8 小波神经网络对表 5-4 检验样本的输出

Table 5-8 The output of wavelet neural network for the testing samples of table 5-4

测试向量序号	1	2	3	4	5	6	7	8
实际磨损(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
输出磨损(mm)	0.1008	0.2967	0.6013	0.0968	0.2955	0.6009	0.0994	0.3032
误差(%)	0.7635	1.0895	0.2137	3.2169	1.5049	0.1428	0.6431	1.0758
测试向量序号	9	10	11	12	13	14	15	16
实际磨损(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
输出磨损(mm)	0.5991	0.0990	0.3061	0.6006	0.1001	0.3057	0.6007	0.0996
误差(%)	0.1558	0.9508	2.0327	0.0959	0.0569	1.9136	0.1128	0.3754
测试向量序号	17	18	19	20	21	22	23	24
实际磨损(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6
输出磨损(mm)	0.2934	0.5998	0.1015	0.3022	0.5983	0.1097	0.2992	0.6005
误差(%)	2.1861	0.0405	1.4502	0.7407	0.2890	9.7446	0.2803	0.0833

计得平均误差为 1.215%, 按先前识别率的标准, 识别率达 100%。通过表 5-5 与表 5-8 两种类型神经网络对检验样本输出的比较可知, 小波神经网络在刀具监测系统建模上确实优于传统的 BP 神经网络。

取这两种以切削力作为监测信号进行建模的神经网络分别对其它工况的训练样本进行学习, 取最优的学习结果对各自的检验样本进行校核, 得出的输出结果汇总如下表 5-9:

表 5-9 以切削力作为监测信号进行建模的神经网络在各工况的校核结果

Table 5-9 The testing results of the neural network that only use the cutting force as the monitoring signal to model under different cutting conditions

项目 工况	传统 BP 神经网络		小波神经网络	
	平均误差(%)	识别率(%)	平均误差(%)	识别率(%)
111	49.21	33.33	18.76	79.17
122	7.58	83.33	1.22	100.00
133	8.91	79.17	1.41	100.00
212	6.85	83.33	1.59	95.83
223	22.35	62.5	13.39	66.67
231	5.65	87.50	4.69	95.83
313	10.64	79.17	4.73	95.83
321	4.41	91.67	3.61	95.83
332	7.72	87.5	4.37	91.67

表 5-9 显示, 以切削力作为监测信号进行建模的神经网络, 尤其是小波神经网络, 在多数工况下对刀具磨损程度有良好的识别能力, 但在某些工况条件, 如工况 111 和工况 223, 两种神经网络模型对刀具监测效果均不能令人满意。主要原因在于, 切削力监测信号在某些工况条件对某些程度刀具的磨损反应不敏感。图 5-4 显示的不同程度



磨损刀具在工况 111 下的各自 16 组切削力特征值可解释这一情况。




图 5-4 不同程度磨损刀具在工况 111 下的各自 16 组切削力特征值  
Fig.5-4 16 groups of cutting force characteristic value coming from cutting tools of different wear under cutting condition of 111

从图 5-4 可看出，在工况 111 的条件下，轻度磨损刀具和中度磨损刀具的  $y$  向切削力特征值和  $x$  向切削力特征值都十分接近，也即是说如果刀具的磨损程度为轻度或中度，仅从  $x$  向和  $y$  向切削力特征值难以区别。基于这一原因，以多传感器融合信息进行建模是有必要的。

### 5.3.1.2 以多传感器信号作为监测信号进行建模

在本小节中讨论的是融合切削振动和切削力信号进行神经网络建模。神经网络的输入为经归一化处理后的切削力和切削振动的特征值( $x$  向切削力和  $y$  向切削力在主轴旋转频率对应点的功率和切削振动分解信号  $s_{30}$ 、 $s_{33}$  及  $s_{36}$  的能量值)，分别简记为  $X_1$ 、 $X_2$ 、 $X_3$ 、 $X_4$  和  $X_5$ ；隐层数取为 5 个，输出为铣刀的磨损量，网络结构为 5-5-1。以工况 111 作为示例比较多传感器信号作为监测信号和仅以切削力作为监测信号建模的刀具监测效果。

表 5-10 列出在工况 111 下以多传感器信号特征值建模的训练样本，表 5-11 则列出其检验样本：

表 5-10 在工况 111 下以多传感器信号特征值建模的训练样本

Table 5-10 The training samples of network model that used the characteristic values of multi sensor signals to model under the condition of 111

序号	1	2	3	4	5	6	7	8
$X_1$	0.0305	0.0522	0.2576	0.0269	0.0557	0.2514	0.0315	0.0511
$X_2$	0.0344	0.0580	0.3514	0.0460	0.0568	0.3432	0.0342	0.0644
$X_3$	0	0.0393	0.1405	0.0107	0.0398	0.1472	0.0233	0.0509
$X_4$	0.0144	0.1341	0.2710	0.0081	0.1217	0.3068	0.0081	0.1145
$X_5$	0.0015	0.0666	0.2794	0.0173	0.0675	0.2930	0.0225	0.0700
VB(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3

(续表 5-10)

序号	9	10	11	12	13	14	15	16
X <sub>1</sub>	0.2651	0.0309	0.0536	0.2570	0.0297	0.0460	0.2714	0.0284
X <sub>2</sub>	0.3413	0.0406	0.0655	0.3484	0.0351	0.0649	0.3449	0.0343
X <sub>3</sub>	0.1427	0.0231	0.0387	0.1478	0.0271	0.0325	0.1540	0.0276
X <sub>4</sub>	0.2576	0	0.1132	0.2908	0.0161	0.1241	0.2886	0.0104
X <sub>5</sub>	0.2866	0.0308	0.0769	0.2997	0	0.0752	0.3114	0.0206
VB(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
序号	17	18	19	20	21	22	23	24
X <sub>1</sub>	0.0483	0.2806	0.0333	0.0508	0.2671	0.0283	0.0576	0.2761
X <sub>2</sub>	0.0586	0.3435	0.0432	0.0687	0.3511	0.0443	0.0678	0.3432
X <sub>3</sub>	0.0353	0.1691	0.0294	0.0449	0.1697	0.0332	0.0422	0.1814
X <sub>4</sub>	0.1242	0.2864	0.0153	0.1223	0.2865	0.0181	0.1185	0.3064
X <sub>5</sub>	0.0609	0.2932	0.0250	0.0742	0.2927	0.0290	0.0736	0.2877
VB(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6

表 5-11 在工况 111 下以多传感器信号特征值建模的检验样本

Table 5-11 The testing samples of network model that used the characteristic values of multi sensor signals to model under the condition of 111

序号	1	2	3	4	5	6	7	8
X <sub>1</sub>	0.0272	0.0527	0.2512	0.0281	0.0559	0.2538	0.0384	0.0502
X <sub>2</sub>	0.0413	0.0572	0.3378	0.0402	0.0596	0.3448	0.0293	0.0587
X <sub>3</sub>	0.0072	0.0421	0.1473	0.0213	0.0425	0.1596	0.0172	0.0203
X <sub>4</sub>	0.0142	0.1263	0.2565	0.0038	0.1367	0.2796	0.0006	0.1205
X <sub>5</sub>	0.0022	0.0648	0.2790	0.0188	0.0751	0.2874	0.0220	0.0683
VB(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
序号	9	10	11	12	13	14	15	16
X <sub>1</sub>	0.2520	0.0295	0.0476	0.2672	0	0.0446	0.2698	0.0316
X <sub>2</sub>	0.3524	0.0413	0.0645	0.3396	0.0395	0.0589	0.3375	0.0347
X <sub>3</sub>	0.1365	0.0281	0.0293	0.1522	0.0172	0.0314	0.1658	0.0165
X <sub>4</sub>	0.2557	0.0153	0.1217	0.2735	0.0172	0.1220	0.2942	0.0121
X <sub>5</sub>	0.2996	0.0141	0.0816	0.3129	0.0172	0.0679	0.3145	0.0318
VB(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
序号	17	18	19	20	21	22	23	24
X <sub>1</sub>	0.0526	0.2806	0.0332	0.0550	0.2813	0.0370	0.0516	0.2691
X <sub>2</sub>	0.0595	0.3379	0.0342	0.0561	0.3384	0.0436	0.0550	0.3473
X <sub>3</sub>	0.0353	0.1783	0.0298	0.0341	0.1624	0.0278	0.0535	0.1815
X <sub>4</sub>	0.1197	0.3152	0.0157	0.1200	0.3096	0.0190	0.1231	0.3199
X <sub>5</sub>	0.0656	0.2911	0.0271	0.0760	0.3012	0.0282	0.0811	0.3004
VB(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6

分别采用传统的 BP 神经网络和小波神经网络对表 5-10 训练样本进行多次学习, 得到两种神经网络的最小误差值为: BP 神经网络 0.0026, 小波神经网络  $9.943 \times 10^{-4}$ 。取这两个最优学习组别的训练结果确定网络可调参量并对表 5-11 检验样本进行验证, 结果列于表 5-12 和表 5-13。

表 5-12 传统 BP 神经网络对表 5-11 检验样本的输出

Table 5-12 The output of traditional BP network for the testing samples of table 5-11

测试向量序号	1	2	3	4	5	6	7	8
实际磨损(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
输出磨损(mm)	0.1127	0.3079	0.5702	0.0916	0.3205	0.5977	0.0788	0.2922
误差(%)	12.652	2.6481	4.9711	8.4120	6.8292	0.3884	21.186	2.6051
测试向量序号	9	10	11	12	13	14	15	16
实际磨损(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
输出磨损(mm)	0.5626	0.1063	0.3026	0.5757	0.1116	0.3032	0.6012	0.1020
误差(%)	6.2327	6.3132	0.8711	4.0582	11.643	1.0730	0.2008	1.9519
测试向量序号	17	18	19	20	21	22	23	24
实际磨损(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6
输出磨损(mm)	0.2906	0.6314	0.1057	0.2915	0.6199	0.1127	0.2986	0.6392
误差(%)	3.1381	5.2397	5.7144	2.8311	3.3194	12.705	0.4808	6.5333

平均误差为 5.50%，识别率为 95.83%。

表 5-13 小波神经网络对表 5-11 检验样本的输出

Table 5-13 The output of wavelet neural network for the testing samples of table 5-11

测试向量序号	1	2	3	4	5	6	7	8
实际磨损(mm)	0.1	0.3	0.6	0.1	0.3	0.6	0.1	0.3
输出磨损(mm)	0.1149	0.3118	0.5779	0.0770	0.3085	0.5828	0.0914	0.2972
误差(%)	14.943	3.9362	3.6833	23.020	2.8192	2.8623	8.5845	0.9407
测试向量序号	9	10	11	12	13	14	15	16
实际磨损(mm)	0.6	0.1	0.3	0.6	0.1	0.3	0.6	0.1
输出磨损(mm)	0.5696	0.0886	0.3038	0.5973	0.1135	0.3010	0.6000	0.1121
误差(%)	5.0689	11.383	1.2649	0.4521	13.482	0.3246	0.0024	12.127
测试向量序号	17	18	19	20	21	22	23	24
实际磨损(mm)	0.3	0.6	0.1	0.3	0.6	0.1	0.3	0.6
输出磨损(mm)	0.2912	0.5887	0.1041	0.2953	0.5901	0.1058	0.2957	0.5979
误差(%)	2.9286	1.8864	4.0622	1.5642	1.6472	5.7997	1.4239	0.3503

平均误差为 5.19%，识别率为 95.83%。

按照上述建模过程，取切削力及切振动融合信息作为监测信号，采用传统 BP 神经网络和小波神经网络进行建模，分别对其它工况的训练样本进行学习，取最优的学习结果确定网络可调参量对各自的检验样本进行校核，得出的输出结果汇总于表 5-14。对比表 5-9 和表 5-14 的数据表明，以多传感器融合信息作为监测信号建立的刀具监测模型具有更好的适应性；以切削力作为监测信号进行建模的神经网络在工况 111 条件下最高只有 79.17% 的识别率，在工况 223 条件下最高识别率更只有 66.67%，而以多传感器融合信息作为监测信号建立的刀具监测模型在各种工况条件下都有很好的刀具磨损识别能力。

表 5-14 以多传感器融合信号进行建模的神经网络在各工况的校核结果

Table 5-14 The testing results of the neural network which using the fusing sensor signals to model under different cutting conditions

项目 工况	传统 BP 神经网络		小波神经网络	
	平均误差(%)	识别率(%)	平均误差(%)	识别率(%)
111	5.50	95.83	5.19	95.83
122	4.03	95.83	2.12	100.00
133	4.59	91.67	1.30	100.00
212	4.90	95.83	3.82	95.83
223	4.36	100.00	2.49	100.00
231	5.02	95.83	5.51	91.67
313	3.72	91.67	5.35	91.67
321	2.31	100.00	3.53	100.00
332	4.45	95.83	4.37	95.83

### 5.3.2 多工况条件下刀具状态监测

机械切削加工往往要在多种工况条件下进行,因此建立多工况条件下的刀具磨损监测系统更具现实意义。

#### 5.3.2.1 多工况条件下刀具状态监测系统的建模

本文提出了如下的建模方式:采用小波神经网络进行建模,把构成工况条件的切削三要素作为附加特征,它们与前面所提及的切削力和切削振动的特征值组成神经网络的 8 个输入,隐层节点数取为 8 个,输出为铣刀的磨损量,网络结构为 8-8-1。在实际加工条件下,由于工况的组合在理论上是无尽的,在实验中不可能完全包括。为挑选出代表性强的少数试验方案,按前述工况条件的设计,把主轴转速、进给速度、切削深度分成三个水平,分别用数值 0.3、0.5 和 1.0 来代表,然后进行正交组合,得到 9 种的工况条件,采集不同磨损程度的刀具在这些工况条件下各自 3 组切削力和切削振动信号作为学习样本来训练网络,另外采集 3 组信号作为检验样本。因此学习样本和检验样本各包含 81 组特征向量如附录 1、附录 2 所示。称按这种工况选择所建立的刀具监测系统为基于正交工况条件实验数据的刀具监测系统。

小波神经网络对训练样本进行多次学习,得到网络的最小误差值为 0.0084。这个最优学习组别的训练结果确定网络可调参量如下:

$$\omega = \begin{bmatrix} 0.2276 & 1.0310 & 0.9009 & 2.9660 & -1.9538 & 2.3820 & 5.7133 & 3.6867 \\ 2.9005 & 2.6501 & 4.1683 & 1.4756 & 1.6305 & 2.2685 & -1.2437 & -0.5951 \\ 1.3365 & -5.1529 & -4.9557 & -2.5109 & -1.6463 & -1.5952 & -1.7879 & 1.5777 \\ -2.6874 & 0.9023 & 2.6393 & -1.9112 & 7.3043 & -2.9082 & 1.1093 & 2.0732 \\ -2.4841 & -1.7177 & -1.4261 & 1.6177 & -0.9917 & -1.8254 & 2.9690 & -0.6211 \\ -2.0599 & 1.4622 & 2.4158 & 3.4315 & 0.9007 & 0.2750 & 3.8209 & -2.4542 \\ 0.0326 & 6.1113 & -3.1864 & -0.2259 & -1.0350 & -1.7396 & -1.0150 & -2.0966 \\ -0.9702 & 4.1407 & 3.4377 & 2.9094 & -0.4877 & 0.8926 & -2.4431 & -2.1944 \end{bmatrix}$$

$v = [1.9247 \quad -1.9386 \quad -11.9478 \quad -2.5428 \quad 0.0849 \quad 1.0779 \quad 0.5974 \quad 2.6741]$ ;  
 $a = [2.9787 \quad 3.7107 \quad -24.5472 \quad 2.8209 \quad 0.7729 \quad 3.3734 \quad -2.9128 \quad 3.2103]^T$ ;  
 $h = [6.7780 \quad 5.1376 \quad 6.3141 \quad 3.3847 \quad -0.9906 \quad 6.3380 \quad -2.0730 \quad 6.0254]^T$ 。

让完成学习的网络对附录 2 的检验样本进行验证, 结果如图 5-5 所示。




图 5-5 正交工况条件下建模的小波神经网络对附录 4 的检验样本输出结果

Fig.5-5 The output of wavelet neural network based on orthogonal cutting conditions for the testing samples of appendix 4

对验证结果进行统计可得平均误差为 5.75%，对刀具磨损状态识别率为 90.12%。由此可见，按照上述方法以小波神经网络建立的刀具磨损监测模型可以对正交工况条件下的刀具磨损实施有效监测。

### 5.3.2.2 基于正交工况条件刀具监测系统工况条件扩展能力讨论

为检验按正交工况条件实验数据建模的小波神经网络在其它工况对刀具磨损的监测能力，引入非正交工况条件下的 64 组向量数据作为检验样本，检验样本列于附录 3，让按正交工况条件实验数据建模并完成训练的的小波神经网络对检验样本再进行测试，结果如图 5-6 所示。




图 5-6 正交工况条件下建模的小波神经网络对其它工况检验样本输出结果

Fig.5-6 The output of wavelet neural network based on orthogonal cutting conditions for the testing samples of other cutting condition as showed in appendix 5

对验证结果进行统计可得平均误差为 9.38%，对刀具磨损状态识别率为 82.81%。由此可见，基于正交工况条件实验数据建立的刀具监测系统具有较强的工况条件扩展能力，可用于普遍工况条件下的刀具状态监测。

## 5.4 本章小结

本章综合运用前面章节介绍的理论,结合实验的数据,建立刀具状态监测模型,同时进行多种方案的对比,展开基于多传感器信息融合的刀具状态监测研究。首先介绍构造刀具监测系统的总体实验方案,包括实验装置简介、工况条件的设计及数据的记录组织形式;根据第四章对参与建模的切削力信号和切削振动在时域、频域和时频域进行详细的分析,确定这两种信号可反映刀具磨损程度的特征值及特征值提取方案;接着对如何以神经网络实现刀具磨损的有效监测进行详细论述。先对单一工况条件下的刀具监测系统进行讨论。其间比较了传统BP神经网络建模和小波神经网络建模的步骤和效果,指出以小波神经网络构成的刀具监测模型具有更优的性能;还比较了以单一传感器检测信号和采用多传感器信号建立刀具磨损监测模型在各种工况条件下的刀具识别性能,从神经网络的输出效果和监测信号对刀具磨损反应的敏感性两方面论证采取多传感器信息融合建模的必要性。至于多工况条件下的刀具监测,提出了基于正交工况条件实验数据的刀具监测系统建立过程,并通过实验数据验证按照这一方法建立的用于多工况条件下刀具磨损监测模型的有效性和对工况条件的扩展性。

## 结论与进一步研究的方向

### 一. 结论

刀具磨损状态的有效监测对于推进切削加工自动化与无人化的过程具有十分重要的意义, 实践表明, 多传感器信息融合的监测方法能提高刀具磨损监测的精确度与可靠性。本文结合刀具监测系统的三大部分, 以高速钢立铣刀作为具体的监测对象, 结合实验的数据, 建立刀具状态监测模型, 同时进行多种方案的对比, 展开基于多传感器信息融合的刀具状态监测研究, 得出如下结论:

1. 基于铣削加工的具体特点, 本文所选用切削力信号和切削振动信号能较大地各自反映出切削过程中刀具状态的变化, 同时这两种信号作为刀具磨损的监测信号具有互补性: 切削力信号反映的是低频信息, 频谱比较集中; 而切削振动信号的频谱比较分散, 频率成份丰富, 两者从不同的方面反映刀具的状态。这种互补性还具体表现为以多传感器信息融合建立的刀具磨损监测模型比以单一传感器监测信号建立的模型在各种工况条件下都具有更优的刀具识别性能。
2. 本论文根据监测信号的不同特性采用灵活的数据处理方法。对于切削力, 其功率谱比较集中, 可用傅立叶变换的方法把时域信号转换到频域上进行功率谱分析; 对于振动信号, 其功率谱比较分散, 难以在时域或纯频域内提取其特征值, 用小波包分解的方法, 把时域信号分解成不同频段对应的子信号, 从这些子信号中选择最大程度上反映刀具磨损的组合作为研究对象, 再对这些组合进行特征提取。
3. 经过对切削力信号及切削振动信号详细的分析, 得出结论:  $x$  向切削力和  $y$  向切削力在主轴旋转频率对应点上的功率、切削振动经小波包分解的频段信号  $s_{30}$ 、 $s_{33}$  及  $s_{36}$  对应能量值包含刀具的磨损信息, 可作为刀具监测系统中切削力和切削振动的特征值。
4. 神经网络具有非线性映射、联想推理、自学习、自适应和大规模并行分布处理等能力, 可作为刀具状态决策建模的基础, 本文采用的前向神经网络能有效地实现切削力信号、切削振动信号与刀具磨损的映射关系。传统的 BP 神经网络存在着一些诸如学习速度较慢, 在学习过程中出现局部收敛等缺陷, 文中通过实例程序显示, 在 BP 算法中增加动量项, 采用变学习率和最小误差保留策略的改进方案能很大程度地改善 BP 网络的学习性能。本文还以 Gauss 小波函数作为激发函数构造小波神经网络, 并编写小波网络实例程序, 示例程序表明

Gauss 小波神经网络是一种强收敛性的网络。建模效果比较实验进一步表明，以小波神经网络建立的刀具监测模型在识别刀具磨损方面优于传统的 BP 神经网络。

5. 本文提出了多工况条件下刀具磨损监测系统的建模方式。为达到以较少的数据包容更多工况条件下的刀具状态信息，仅以正交工况条件下获得的实验数据完成相应小波神经网络的训练，并通过实验数据验证这种基于正交工况条件实验数据建立的刀具监测系统具有较强的工况条件扩展能力，可用于普遍工况条件下的刀具状态监测。

## 二. 进一步研究的方向

本课题从开题到完稿经历了差不多一年半时间，本人为课题的研究花费了大量的时间和精力，并取得一定的成果。但限于学识、时间和一些客观条件，本课题的研究未臻完善，还可从以下方面展开进一步的探讨：

1. 探讨以其它类型监测信号实现刀具监测的可行性，比较各种监测信号组合的优缺点；
2. 扩充建模所用的工况条件等级，细化刀具磨损程度的分类，使建立的刀具监测系统具有更大的工况条件适应性和刀具磨损程度的包容性；
3. 在算法设计中考虑不同类型的监测信号在不同工况下映射刀具磨损程度所做贡献的差异性；
4. 刀具监测中智能技术应用的进一步深入研究，模糊技术和神经网络的融合以及基因遗传算法在神经网络中的渗透为这方面的研究提供了思路；
5. 把现有的研究成果向实用化和通用化方向发展。



## 参考文献

- [1] 李小隼、董申, 先进制造中的智能监控技术, 科学出版社, 1999, 10
- [2] Tonshoff H K, et al. Developments and Trends in Monitoring in Monitoring and Control of Machining Processes, Annals of the CIRP, 1988, 37(2)
- [3] Tlustý J, et al. A Critical Review of sensors for Unmanned Machining. Annals of the CIRP, 1983, 32(2)
- [4] Ed Scharp. Tool Monitoring keeps on eye on automated turning. American Machinist, 1993, 137(10)
- [5] Tooling and Production Systems Inc. Tool Monitoring-downtime you can control. Automatic Machining, 1993, 54(6)
- [6] 公开特许公报 (A), 昭 61-79160
- [7] 公开特许公报 (A), 昭 59-142050
- [8] 公开特许公报 (A), 昭 61-79159
- [9] US-patent, 4135391(1960)
- [10] 雷继荣. 刀具监控技术的现状与发展. 组合机床与自动化加工技术, 1995 年第 5 期
- [11] 李小隼、董申, 先进制造中的智能监控技术, 科学出版社, 1999, 8-11
- [12] 游淳、翁世修, 基于神经网络的刀具状态实时监控系統, 组合机床与自动化加工技术, 1995 年第 9 期
- [13] Guinea D, Ruiz A and Barrios J. Multi-Sensor Integration and Automatic Feature Selection and State Identification. Proc. 1st CIRP Workshop on Intelligent Manufacturing Systems, CIRP Budapest Hungary 1991:159-175
- [14] Dornfeld D A. In Process Recognition of Cutting States. JSME International Journal, Vol.37, No.4, 1994:638-650
- [15] Lee J M and Choi D K. Real-Time Tool Breakage Monitoring for NC Turning and Drilling. Annals of the CIRP, Vol.43, 1994:81-84
- [16] Du R Elbestawi M A Automated Monitoring of Manufacturing Process. J. Engineering for Industry. Vol.117, May 1995:121-132
- [17] 李小隼、董申, 先进制造中的智能监控技术, 科学出版社, 1999, 14-15
- [18] 胡昌华、张军波、夏军、张伟, 基于 MATLAB 的系统分析与设计—小波分析, 西安电子科技大学出版社, 2000, 1-6
- [19] P.W. Prickett, C.Johns. An overview of approaches to end milling tool monitoring. International Journal of Machine Tools & Manufacture 39 (1999) 105-122

- [20] Dornfeld D A, Bollinger J G. On-line Frequency Domain Detection of Production Machinery Manufanctions. Proc. of the 18th Int. Machine Tool Design and Research Conf. , London, 1977:837~844
- [21] Zhang Y Z, Liu Z F, Pau L X, Y I, Yang W B. Recognition of Cutting States for the Difficult-to-cut Materials. CIRP Annals, Vol.31, No.1, 97~101
- [22] 邵华, 铣削功率监控研究与刀具监控系统研制, 上海交通大学博士学位论文
- [23] 周其节, 徐建闽, 神经网络控制系统的研究与展望, 控制理论与应用, 1992,9(6):569~577
- [24] 王伟. 人工神经网络原理—入门与应用. 北京航空航天大学出版社, 1995, 74~76
- [25] 赵林明, 多层前向人工神经网络, 黄河水利出版社, 1997.7, 29~37
- [26] Teshima T, Shibasaka T, Takuma M, Yamamoto A. Estimation of Cutting Tool life by Processing Tool Image with Neural Network. CIRP Annals, Vol. 42, No.1, 1993:59~62
- [27] Tarn Y S and Chen M C. An Intelligent Sensor for Detection of Milling Chatter. J. of Intelligent Manufacture, Vol.5. 1994:193~200
- [28] Monostori L and Egresits Cs. On Hybrid Learning and its Application in Intelligent Manufacturing. Preprints of the Second Int. Workshop on Learning in IMSSm Budapest, Hungaryn, April 20-21,1995:655-670
- [29] 李小康, 田淑艳, 关新平, 刀具状态智能监控技术, 高技术通讯, Vol.8, No.1, 1998:58~62
- [30] 许香谷、肖诗纲等, 金属切削原理与刀具, 重庆大学出版社, 1992年, 56~67
- [31] Dimla E. Dimla Snr, Sensor signals for tool-wear monitoring in metal cutting operations -a review of methods, International Journal of Machine Tools & Manufacture 40 (2000) 1073-1098
- [32] 刘晓东、诸乃雄, 切削过程刀具监测技术的发展概况, 上海机床 1997年第3期
- [33] 彭永红、陈统坚、周泽华, 制造系统的神经自适应控制, 华南理工大学学报, 第22卷第4期
- [34] 王仁明, 信号与系统, 北京理工大学出版社, 1994年, 17~105
- [35] 丁玉美、高西全, 数字信号处理, 西安电子科技大学出版社, 2001年, 28~127
- [36] 李培芳, 离散信号与系统分析, 浙江大学出版社, 2001年, 117~147
- [37] 李水根、吴纪桃, 分形与小波, 科学出版社, 2002年, 196~293
- [38] 徐长发、李国宽, 实用小波方法, 华中科技大学出版社 2001年, 42~153
- [39] 杨福生, 小波变换的工程分析与应用, 科学出版社, 1999,1~68
- [40] 刘令普等, 由付里叶分析到小波分析的进展, 数学的实践与认识, 2000年7月, 第30卷第3期
- [41] 彭永红、陈统坚、周泽华, 制造系统的神经自适应控制, 华南理工大学学报, 第

22 卷第 4 期

- [42] 焦李成, 神经网络系统理论, 西安: 西安电子科技大学出版社, 1991
- [43] 赵林明, 多层前向人工神经网络, 郑州: 黄河水利出版社, 1999
- [44] 王伟, 人工神经网络原理, 北京: 北京航空航天大学出版社, 1995
- [45] 焦李成, 神经网络的应用与实现, 西安电子科技大学出版社, 1996
- [46] Q.Zhang, A.Benveniste, Wavelet networks, IEEE Trans, On Neural Networks. 1992, 3(6), 89~898
- [47] C.Pati, S.Krishnaprasad. Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations. IEEE Trans. On Neural Network. 1993, 4(1) 73~85
- [48] J.Zhang, Gilbeft G.Walter etal. Wavelet neural networks for function learning. IEEE Trans. On Signal Processing. 1995, 43(6):1485~1497
- [49] 乔迎贤、周凤歧, 子波网络的近似能力分析, 西北工业大学学报, 1996, 14(3):415~419
- [50] 赵学智, 广义自适应小波分析及其在机械测试信号处理中的应用, 华南理工大学工学博士学位论文, 2001 年 5 月, 119~121

## 攻读学位期间发表的论文与获得奖励

### 发表的论文:

邝志伟, Sensor fusion using neural network for tool condition monitoring, 2002  
国际现场总线与管控一体化论文集, 2002年5月: 140~144

### 获得奖励:

获“2002年度香港隆辉奖学金”

## 致谢

首先应该感谢我的导师陈统坚教授。陈老师是一个儒雅的学者，他学识渊博，兴趣广泛，具有严谨的治学精神和包容的生活态度，为我们树立学习的典范，其风度神采令人神往。如今陈老师与我们相隔重洋，但他依然关心着本人课题的进展，给我的论文提出中肯而详细的修改意见，所有这些我将铭记于心。毕业在即，谨向导师表示崇高的敬意和衷心的感谢。

在本课题研究和试验平台构造过程中得到李春雄、陈秉均、彭永红、李伟光、姚锡凡等老师的指导和鼓励；在机床调试和具体实验过程中何家耀师傅丰富的加工经验为我解决了许多实际困难；在实验设备方面，徐静老师提供了部分必要的实验仪器和设备资料，汤勇老师、林颖老师和曾志新老师提供了压电晶体测力仪、加速度计和测速计；在实验工件准备方面，邝伟春师傅给予很大的帮助。在此向他们表示诚挚的感谢。

感谢本课题组的成员博士生温度和硕士生周建辉。在过去的一年多时间里，我们在同一课题的框架内共同协作，共同研究，彼此相互帮助，相处融洽，仿如兄弟姐妹。还有研究生学习阶段所认识的如裴胜伟、董重里、张毅、王灵军、朱金华等同学朋友，我们一起探讨学问，一起交流思想，和他们的相处的时间成为我人生美好的回忆。

在过去三年的学习生活中，机电系的王丹平书记对本人给予关注和爱护，宿管会管理处在住宿问题上给予方便，为本人提供良好的住宿环境，在此表示感谢。

特别需要感谢的是我的父亲、母亲和家人，他们的支持、鼓励和理解是我不断进步的动力。“谁言寸草心，报得三春晖”，此间的片言只语实难表达我对他们的感激之情，他们对我的恩情，本人不敢稍有忘怀。

三年光阴如电飞逝，回想重返校园求学情形仿如昨日，如今我又将在一个新的起点上踏上征程，我会一如既往地以积极乐观的态度面对未来的生活。

再一次感谢所有关心我，爱护我的人！

附录1 多工况刀具监测系统训练样本数据表

序号	$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$	$X_8$	VB(mm)
1	0.3000	0.3000	0.3000	0.0305	0.0344	0	0.0144	0.0015	0.1000
2	0.3000	0.3000	0.3000	0.0522	0.0580	0.0393	0.1341	0.0666	0.3000
3	0.3000	0.3000	0.3000	0.2576	0.3514	0.1405	0.2710	0.2794	0.6000
4	0.3000	0.5000	0.5000	0.0580	0.0603	0.0529	0.1468	0.0635	0.1000
5	0.3000	0.5000	0.5000	0.1450	0.1096	0.1705	0.2957	0.1519	0.3000
6	0.3000	0.5000	0.5000	0.4176	0.3669	0.2347	0.3480	0.2763	0.6000
7	0.3000	1.0000	1.0000	0.0417	0.0098	0.0574	0.0559	0.0899	0.1000
8	0.3000	1.0000	1.0000	0.1755	0.2086	0.2467	0.3435	0.1886	0.3000
9	0.3000	1.0000	1.0000	0.5957	0.4246	0.3920	0.4490	0.4661	0.6000
10	0.5000	0.3000	0.5000	0.4345	0.2001	0.2675	0.2565	0.2014	0.1000
11	0.5000	0.3000	0.5000	0.6070	0.3991	0.4058	0.5672	0.2046	0.3000
12	0.5000	0.3000	0.5000	0.6286	0.6069	0.5978	0.7359	0.2186	0.6000
13	0.5000	0.5000	1.0000	0.4790	0.3953	0.2814	0.3868	0.2624	0.1000
14	0.5000	0.5000	1.0000	0.6661	0.4327	0.4573	0.5933	0.2755	0.3000
15	0.5000	0.5000	1.0000	0.6728	0.7619	0.5183	0.7915	0.3124	0.6000
16	0.5000	1.0000	0.3000	0.5879	0.5686	0.1402	0.1711	0.1144	0.1000
17	0.5000	1.0000	0.3000	0.8075	0.6149	0.4266	0.1904	0.1381	0.3000
18	0.5000	1.0000	0.3000	0.9751	0.8446	0.4566	0.3473	0.1589	0.6000
19	1.0000	0.3000	1.0000	0.3968	0.4516	0.4176	0.7141	0.4912	0.1000
20	1.0000	0.3000	1.0000	0.5880	0.4620	0.7797	0.8683	0.8300	0.3000
21	1.0000	0.3000	1.0000	0.5953	0.7587	0.9802	0.9821	0.9850	0.6000
22	1.0000	0.5000	0.3000	0.3432	0.3216	0.2154	0.2142	0.3666	0.1000
23	1.0000	0.5000	0.3000	0.8198	0.5819	0.5010	0.2296	0.4289	0.3000
24	1.0000	0.5000	0.3000	0.8562	0.9499	0.5184	0.4270	0.6709	0.6000
25	1.0000	1.0000	0.5000	0.7819	0.5742	0.2109	0.3855	0.3027	0.1000
26	1.0000	1.0000	0.5000	0.8962	0.6024	0.5113	0.4103	0.4739	0.3000
27	1.0000	1.0000	0.5000	0.9084	0.9859	0.7090	0.5396	0.4835	0.6000
28	0.3000	0.3000	0.3000	0.0269	0.0460	0.0107	0.0081	0.0173	0.1000
29	0.3000	0.3000	0.3000	0.0557	0.0568	0.0398	0.1217	0.0675	0.3000
30	0.3000	0.3000	0.3000	0.2514	0.3432	0.1472	0.3068	0.2930	0.6000
31	0.3000	0.5000	0.5000	0.0575	0.0731	0.0573	0.1404	0.0714	0.1000
32	0.3000	0.5000	0.5000	0.1430	0.1226	0.1717	0.3046	0.1452	0.3000
33	0.3000	0.5000	0.5000	0.4148	0.3547	0.2407	0.3678	0.2682	0.6000
34	0.3000	1.0000	1.0000	0.0486	0.0072	0.0399	0.0306	0.1021	0.1000
35	0.3000	1.0000	1.0000	0.1849	0.2196	0.2498	0.3473	0.1898	0.3000
36	0.3000	1.0000	1.0000	0.5541	0.4153	0.4007	0.4470	0.4715	0.6000
37	0.5000	0.3000	0.5000	0.4494	0.2066	0.2692	0.2706	0.2047	0.1000
38	0.5000	0.3000	0.5000	0.6212	0.4017	0.3964	0.5694	0.2078	0.3000
39	0.5000	0.3000	0.5000	0.6408	0.6174	0.6025	0.7215	0.2343	0.6000
40	0.5000	0.5000	1.0000	0.4799	0.4052	0.2743	0.4102	0.2581	0.1000
41	0.5000	0.5000	1.0000	0.6704	0.4489	0.4425	0.5704	0.2782	0.3000
42	0.5000	0.5000	1.0000	0.6793	0.7793	0.5413	0.7952	0.3235	0.6000
43	0.5000	1.0000	0.3000	0.5885	0.5547	0.1458	0.1676	0.1136	0.1000
44	0.5000	1.0000	0.3000	0.7928	0.6044	0.4272	0.2240	0.1309	0.3000
45	0.5000	1.0000	0.3000	0.9797	0.8320	0.4829	0.3468	0.1634	0.6000
46	1.0000	0.3000	1.0000	0.4180	0.4123	0.4203	0.7361	0.4966	0.1000
47	1.0000	0.3000	1.0000	0.6118	0.4740	0.7797	0.8796	0.8358	0.3000

续附录 1

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	VB(mm)
48	1.0000	0.3000	1.0000	0.6283	0.7522	0.9704	0.9745	0.9991	0.6000
49	1.0000	0.5000	0.3000	0.3429	0.3055	0.1976	0.2154	0.3685	0.1000
50	1.0000	0.5000	0.3000	0.8219	0.5844	0.4754	0.2279	0.4318	0.3000
51	1.0000	0.5000	0.3000	0.8338	0.9424	0.4936	0.4410	0.6665	0.6000
52	1.0000	1.0000	0.5000	0.7795	0.5907	0.2093	0.3515	0.2992	0.1000
53	1.0000	1.0000	0.5000	0.8717	0.5909	0.5320	0.3972	0.4605	0.3000
54	1.0000	1.0000	0.5000	0.8777	0.9819	0.7112	0.5182	0.4767	0.6000
55	0.3000	0.3000	0.3000	0.0315	0.0342	0.0233	0.0081	0.0700	0.1000
56	0.3000	0.3000	0.3000	0.0511	0.0644	0.0509	0.1145	0.0225	0.3000
57	0.3000	0.3000	0.3000	0.2651	0.3413	0.1427	0.2576	0.2866	0.6000
58	0.3000	0.5000	0.5000	0.0550	0.0779	0.0632	0.1581	0.0748	0.1000
59	0.3000	0.5000	0.5000	0.1304	0.1352	0.1793	0.3034	0.1496	0.3000
60	0.3000	0.5000	0.5000	0.4346	0.3704	0.2231	0.3689	0.2715	0.6000
61	0.3000	1.0000	1.0000	0.0413	0.0113	0.0465	0.0235	0.0839	0.1000
62	0.3000	1.0000	1.0000	0.1473	0.2027	0.2279	0.3517	0.1914	0.3000
63	0.3000	1.0000	1.0000	0.5392	0.4229	0.4042	0.4619	0.4693	0.6000
64	0.5000	0.3000	0.5000	0.4041	0.2061	0.2558	0.2575	0.2143	0.1000
65	0.5000	0.3000	0.5000	0.6320	0.4146	0.4124	0.5647	0.2252	0.3000
66	0.5000	0.3000	0.5000	0.6410	0.6108	0.6074	0.7473	0.2321	0.6000
67	0.5000	0.5000	1.0000	0.4791	0.3957	0.2705	0.3936	0.2535	0.1000
68	0.5000	0.5000	1.0000	0.6642	0.4328	0.4806	0.5884	0.2584	0.3000
69	0.5000	0.5000	1.0000	0.6798	0.7659	0.4839	0.7956	0.3128	0.6000
70	0.5000	1.0000	0.3000	0.5771	0.5725	0.1556	0.1843	0.1089	0.1000
71	0.5000	1.0000	0.3000	0.7989	0.6018	0.4489	0.2041	0.1321	0.3000
72	0.5000	1.0000	0.3000	0.9963	0.8363	0.4885	0.3589	0.1572	0.6000
73	1.0000	0.3000	1.0000	0.4106	0.4316	0.4199	0.7296	0.5048	0.1000
74	1.0000	0.3000	1.0000	0.6145	0.4802	0.7873	0.8642	0.8373	0.3000
75	1.0000	0.3000	1.0000	0.6275	0.7449	0.9839	0.9750	0.9775	0.6000
76	1.0000	0.5000	0.3000	0.3423	0.3061	0.1854	0.2270	0.3697	0.1000
77	1.0000	0.5000	0.3000	0.8030	0.5791	0.4679	0.2578	0.4022	0.3000
78	1.0000	0.5000	0.3000	0.8355	0.9573	0.4909	0.4410	0.6692	0.6000
79	1.0000	1.0000	0.5000	0.7744	0.5781	0.2048	0.4020	0.3014	0.1000
80	1.0000	1.0000	0.5000	0.8643	0.6061	0.5344	0.4130	0.4637	0.3000
81	1.0000	1.0000	0.5000	0.8899	0.9855	0.7146	0.5193	0.4673	0.6000

附录 2 多工况刀具监测系统检验样本数据表 1

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	VB(mm)
1	0.3000	0.3000	0.3000	0.0272	0.0413	0.0072	0.0142	0.0022	0.1000
2	0.3000	0.3000	0.3000	0.0527	0.0572	0.0421	0.1263	0.0648	0.3000
3	0.3000	0.3000	0.3000	0.2512	0.3378	0.1473	0.2565	0.2790	0.6000
4	0.3000	0.5000	0.5000	0.0572	0.0734	0.0570	0.1410	0.0750	0.1000
5	0.3000	0.5000	0.5000	0.1758	0.1163	0.1729	0.3078	0.1468	0.3000
6	0.3000	0.5000	0.5000	0.4196	0.3621	0.2198	0.3308	0.2737	0.6000
7	0.3000	1.0000	1.0000	0.0440	0.0184	0.0429	0.0546	0.0997	0.1000
8	0.3000	1.0000	1.0000	0.1944	0.2203	0.2503	0.3474	0.1857	0.3000
9	0.3000	1.0000	1.0000	0.5404	0.4208	0.3857	0.4587	0.4718	0.6000
10	0.5000	0.3000	0.5000	0.4546	0.1995	0.2665	0.2634	0.2033	0.1000

续附录 2

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	VB(mm)
11	0.5000	0.3000	0.5000	0.6355	0.4098	0.4040	0.5884	0.2196	0.3000
12	0.5000	0.3000	0.5000	0.6423	0.6034	0.6145	0.7251	0.2256	0.6000
13	0.5000	0.5000	1.0000	0.4653	0.3950	0.2721	0.4076	0.2699	0.1000
14	0.5000	0.5000	1.0000	0.6691	0.4211	0.4727	0.5852	0.2777	0.3000
15	0.5000	0.5000	1.0000	0.6793	0.7558	0.5306	0.8057	0.3295	0.6000
16	0.5000	1.0000	0.3000	0.7716	0.5740	0.1426	0.1771	0.1136	0.1000
17	0.5000	1.0000	0.3000	0.6041	0.6069	0.4216	0.2151	0.1393	0.3000
18	0.5000	1.0000	0.3000	0.9875	0.8263	0.4536	0.3531	0.1607	0.6000
19	1.0000	0.3000	1.0000	0.4291	0.4419	0.4112	0.7219	0.4907	0.1000
20	1.0000	0.3000	1.0000	0.5912	0.4591	0.7753	0.8758	0.8358	0.3000
21	1.0000	0.3000	1.0000	0.6094	0.7488	0.9592	0.9701	0.9975	0.6000
22	1.0000	0.5000	0.3000	0.3302	0.3122	0.2084	0.2238	0.3629	0.1000
23	1.0000	0.5000	0.3000	0.8242	0.5928	0.4991	0.2448	0.4178	0.3000
24	1.0000	0.5000	0.3000	0.8372	0.9438	0.5001	0.4381	0.6737	0.6000
25	1.0000	1.0000	0.5000	0.7920	0.5712	0.2069	0.3705	0.3046	0.1000
26	1.0000	1.0000	0.5000	0.8568	0.5986	0.5241	0.4023	0.4746	0.3000
27	1.0000	1.0000	0.5000	0.8912	0.9858	0.7036	0.5333	0.4765	0.6000
28	0.3000	0.3000	0.3000	0.0281	0.0402	0.0213	0.0038	0.0188	0.1000
29	0.3000	0.3000	0.3000	0.0559	0.0596	0.0426	0.1367	0.0751	0.3000
30	0.3000	0.3000	0.3000	0.2538	0.3448	0.1596	0.2796	0.2874	0.6000
31	0.3000	0.5000	0.5000	0.0549	0.0898	0.0636	0.1481	0.0684	0.1000
32	0.3000	0.5000	0.5000	0.1397	0.1245	0.1775	0.2959	0.1435	0.3000
33	0.3000	0.5000	0.5000	0.4140	0.3591	0.2257	0.3344	0.2780	0.6000
34	0.3000	1.0000	1.0000	0.0379	0.0063	0.0419	0.0388	0.0892	0.1000
35	0.3000	1.0000	1.0000	0.1407	0.2254	0.2331	0.3525	0.2029	0.3000
36	0.3000	1.0000	1.0000	0.5717	0.4173	0.4144	0.4388	0.4737	0.6000
37	0.5000	0.3000	0.5000	0.4310	0.2103	0.2604	0.2688	0.1996	0.1000
38	0.5000	0.3000	0.5000	0.6366	0.4098	0.4119	0.5633	0.2159	0.3000
39	0.5000	0.3000	0.5000	0.6462	0.6296	0.6276	0.7378	0.2350	0.6000
40	0.5000	0.5000	1.0000	0.4819	0.4081	0.2697	0.4206	0.2610	0.1000
41	0.5000	0.5000	1.0000	0.6719	0.4514	0.4573	0.6060	0.2690	0.3000
42	0.5000	0.5000	1.0000	0.6759	0.7651	0.5390	0.7983	0.3168	0.6000
43	0.5000	1.0000	0.3000	0.5767	0.5649	0.1601	0.1718	0.1004	0.1000
44	0.5000	1.0000	0.3000	0.7880	0.6049	0.4308	0.2301	0.1343	0.3000
45	0.5000	1.0000	0.3000	0.9967	0.8335	0.4677	0.3515	0.1549	0.6000
46	1.0000	0.3000	1.0000	0.3952	0.4196	0.4181	0.7161	0.5048	0.1000
47	1.0000	0.3000	1.0000	0.6138	0.4651	0.7694	0.8754	0.8465	0.3000
48	1.0000	0.3000	1.0000	0.6467	0.7417	0.9754	0.9915	0.9926	0.6000
49	1.0000	0.5000	0.3000	0.3508	0.2999	0.1924	0.2407	0.3707	0.1000
50	1.0000	0.5000	0.3000	0.8228	0.5840	0.4734	0.2457	0.4247	0.3000
51	1.0000	0.5000	0.3000	0.8319	0.9453	0.4886	0.4399	0.6717	0.6000
52	1.0000	1.0000	0.5000	0.7769	0.5837	0.2010	0.3763	0.3005	0.1000
53	1.0000	1.0000	0.5000	0.8799	0.5843	0.5323	0.4027	0.4692	0.3000
54	1.0000	1.0000	0.5000	0.8890	0.9763	0.7142	0.5363	0.4865	0.6000
55	0.3000	0.3000	0.3000	0.0384	0.0293	0.0172	0.0006	0.0220	0.1000
56	0.3000	0.3000	0.3000	0.0502	0.0587	0.0203	0.1205	0.0680	0.3000
57	0.3000	0.3000	0.3000	0.2520	0.3524	0.1365	0.2557	0.2996	0.6000
58	0.3000	0.5000	0.5000	0.0725	0.0899	0.0707	0.1541	0.0751	0.1000



续附录 2

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	VB(mm)
59	0.3000	0.5000	0.5000	0.1734	0.1417	0.1844	0.3165	0.1461	0.3000
60	0.3000	0.5000	0.5000	0.4250	0.3697	0.2380	0.3534	0.2740	0.6000
61	0.3000	1.0000	1.0000	0.0510	0.0350	0.0565	0.0370	0.0991	0.1000
62	0.3000	1.0000	1.0000	0.1654	0.2177	0.2406	0.3503	0.2115	0.3000
63	0.3000	1.0000	1.0000	0.5589	0.4312	0.4132	0.4430	0.4710	0.6000
64	0.5000	0.3000	0.5000	0.4197	0.1967	0.2590	0.2601	0.2173	0.1000
65	0.5000	0.3000	0.5000	0.6033	0.4043	0.3985	0.5613	0.2259	0.3000
66	0.5000	0.3000	0.5000	0.6285	0.6121	0.6100	0.7467	0.2435	0.6000
67	0.5000	0.5000	1.0000	0.4948	0.3965	0.2761	0.4117	0.2379	0.1000
68	0.5000	0.5000	1.0000	0.6662	0.4300	0.4773	0.5626	0.2603	0.3000
69	0.5000	0.5000	1.0000	0.6793	0.7859	0.5068	0.7953	0.3146	0.6000
70	0.5000	1.0000	0.3000	0.5744	0.5384	0.1667	0.2057	0.1149	0.1000
71	0.5000	1.0000	0.3000	0.8115	0.5994	0.4405	0.2094	0.1260	0.3000
72	0.5000	1.0000	0.3000	0.9937	0.8486	0.4948	0.3620	0.1479	0.6000
73	1.0000	0.3000	1.0000	0.4216	0.4289	0.4176	0.7322	0.5145	0.1000
74	1.0000	0.3000	1.0000	0.5825	0.4761	0.7799	0.8918	0.8432	0.3000
75	1.0000	0.3000	1.0000	0.6146	0.7337	0.9673	0.9868	0.9906	0.6000
76	1.0000	0.5000	0.3000	0.3505	0.3075	0.1951	0.2180	0.4108	0.1000
77	1.0000	0.5000	0.3000	0.7864	0.5736	0.4575	0.2402	0.3712	0.3000
78	1.0000	0.5000	0.3000	0.8290	0.9684	0.5135	0.4415	0.6722	0.6000
79	1.0000	1.0000	0.5000	0.7840	0.5788	0.2156	0.3820	0.3028	0.1000
80	1.0000	1.0000	0.5000	0.8726	0.6018	0.5399	0.4273	0.4524	0.3000
81	1.0000	1.0000	0.5000	0.8774	0.9832	0.7051	0.5316	0.4635	0.6000

附录 3 多工况刀具监测系统检验样本数据表 2

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	VB(mm)
1	0.3000	1.0000	0.3000	0.5813	0.3583	0.0886	0.0256	0.1305	0.1000
2	1.0000	0.5000	0.5000	0.7229	0.5399	0.3357	0.4107	0.3182	0.3000
3	0.5000	1.0000	0.5000	0.5311	0.8618	0.6678	0.5328	0.2351	0.6000
4	1.0000	0.5000	1.0000	0.8213	0.9591	0.4832	0.5641	0.2813	0.6000
5	0.3000	1.0000	0.3000	0.6340	0.4208	0.0798	0.0324	0.1378	0.1000
6	1.0000	0.5000	0.5000	0.6888	0.6216	0.3404	0.4182	0.3630	0.3000
7	0.5000	1.0000	0.5000	0.5815	0.8521	0.6086	0.5916	0.2317	0.6000
8	1.0000	0.5000	1.0000	0.7678	1.0081	0.4959	0.5056	0.2464	0.6000
9	0.3000	1.0000	0.3000	0.5719	0.3939	0.0885	0.0326	0.1308	0.1000
10	1.0000	0.5000	0.5000	0.7625	0.5561	0.3711	0.4047	0.3232	0.3000
11	0.5000	1.0000	0.5000	0.5560	0.8418	0.6972	0.5576	0.2239	0.6000
12	1.0000	0.5000	1.0000	0.7637	0.9523	0.4670	0.5498	0.2550	0.6000
13	0.3000	1.0000	0.3000	0.6558	0.4204	0.0946	0.0428	0.1209	0.1000
14	1.0000	0.5000	0.5000	0.7730	0.5346	0.2902	0.4082	0.3231	0.3000
15	0.5000	1.0000	0.5000	0.5265	0.8513	0.6874	0.5741	0.2160	0.6000
16	1.0000	0.5000	1.0000	0.7716	1.0687	0.4863	0.5403	0.2449	0.6000
17	0.3000	1.0000	0.3000	0.6105	0.3888	0.0922	0.0449	0.1360	0.1000
18	1.0000	0.5000	0.5000	0.7558	0.6043	0.3467	0.4285	0.3185	0.3000
19	0.5000	1.0000	0.5000	0.5562	0.8393	0.6300	0.5369	0.2330	0.6000

续附录 3

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	VB(mm)
20	1.0000	0.5000	1.0000	0.7528	1.0638	0.5334	0.5449	0.2795	0.6000
21	0.3000	1.0000	0.3000	0.6569	0.4128	0.0870	0.0372	0.1122	0.1000
22	0.3000	1.0000	0.3000	0.6569	0.4128	0.0870	0.0372	0.1122	0.1000
23	0.5000	1.0000	0.5000	0.5387	0.9254	0.6305	0.5848	0.2166	0.6000
24	1.0000	0.5000	1.0000	0.7387	0.9739	0.4944	0.5222	0.2831	0.6000
25	0.3000	1.0000	0.3000	0.6109	0.3552	0.0989	0.0512	0.1246	0.1000
26	1.0000	0.5000	0.5000	0.7069	0.5785	0.3190	0.4184	0.3241	0.3000
27	0.5000	1.0000	0.5000	0.5900	0.9177	0.7055	0.5342	0.1999	0.6000
28	1.0000	0.5000	1.0000	0.7788	0.9389	0.4686	0.5218	0.2541	0.6000
29	0.3000	1.0000	0.3000	0.6235	0.3563	0.1011	0.0369	0.1141	0.1000
30	1.0000	0.5000	0.5000	0.7797	0.6275	0.3269	0.4173	0.3279	0.3000
31	0.5000	1.0000	0.5000	0.5420	0.8879	0.6753	0.5782	0.2205	0.6000
32	1.0000	0.5000	1.0000	0.8041	0.9285	0.4815	0.4893	0.2394	0.6000
33	0.3000	1.0000	0.3000	0.6212	0.3870	0.0891	0.0539	0.1289	0.1000
34	1.0000	0.5000	0.5000	0.7444	0.5647	0.3353	0.4141	0.3637	0.3000
35	0.5000	1.0000	0.5000	0.5660	0.8734	0.6194	0.5638	0.2010	0.6000
36	1.0000	0.5000	1.0000	0.7682	0.9191	0.4490	0.5493	0.2583	0.6000
37	0.3000	1.0000	0.3000	0.5789	0.3766	0.0843	0.0564	0.1124	0.1000
38	1.0000	0.5000	0.5000	0.7736	0.6366	0.3136	0.4082	0.3122	0.3000
39	0.5000	1.0000	0.5000	0.4958	0.8617	0.6994	0.5995	0.2223	0.6000
40	1.0000	0.5000	1.0000	0.7359	0.9763	0.4818	0.5000	0.2298	0.6000
41	0.3000	1.0000	0.3000	0.5894	0.3893	0.0884	0.0571	0.0951	0.1000
42	1.0000	0.5000	0.5000	0.7315	0.5734	0.2917	0.4652	0.3499	0.3000
43	0.5000	1.0000	0.5000	0.5461	0.8489	0.6570	0.5481	0.2217	0.6000
44	1.0000	0.5000	1.0000	0.7361	0.9387	0.5229	0.5361	0.2478	0.6000
45	0.3000	1.0000	0.3000	0.6007	0.4206	0.0976	0.0286	0.1163	0.1000
46	1.0000	0.5000	0.5000	0.6999	0.5851	0.3173	0.4001	0.3455	0.3000
47	0.5000	1.0000	0.5000	0.5168	0.8871	0.7093	0.5937	0.2185	0.6000
48	1.0000	0.5000	1.0000	0.7748	1.0608	0.4858	0.5854	0.2360	0.6000
49	0.3000	1.0000	0.3000	0.6179	0.3727	0.0925	0.0606	0.1173	0.1000
50	1.0000	0.5000	0.5000	0.7290	0.5813	0.3665	0.4489	0.3202	0.3000
51	0.5000	1.0000	0.5000	0.5865	0.8899	0.6814	0.5947	0.2139	0.6000
52	1.0000	0.5000	1.0000	0.7074	0.9830	0.4612	0.5128	0.2450	0.6000
53	0.3000	1.0000	0.3000	0.6122	0.4056	0.0943	0.0387	0.1102	0.1000
54	1.0000	0.5000	0.5000	0.7242	0.5628	0.3436	0.4327	0.3527	0.3000
55	0.5000	1.0000	0.5000	0.5705	0.7952	0.6887	0.5450	0.2225	0.6000
56	1.0000	0.5000	1.0000	0.7682	1.0442	0.4561	0.5058	0.2626	0.6000
57	0.3000	1.0000	0.3000	0.5942	0.4041	0.0822	0.0384	0.1267	0.1000
58	1.0000	0.5000	0.5000	0.7954	0.6107	0.3481	0.3997	0.3506	0.3000
59	0.5000	1.0000	0.5000	0.5050	0.9295	0.6154	0.5769	0.2127	0.6000
60	1.0000	0.5000	1.0000	0.8348	0.9825	0.4612	0.4949	0.2668	0.6000
61	0.3000	1.0000	0.3000	0.6245	0.4039	0.0954	0.0558	0.1208	0.1000
62	1.0000	0.5000	0.5000	0.7306	0.6198	0.3412	0.4112	0.3103	0.3000
63	0.5000	1.0000	0.5000	0.5897	0.8037	0.6257	0.5429	0.1995	0.6000
64	1.0000	0.5000	1.0000	0.8204	0.9407	0.4565	0.5280	0.2642	0.6000