

上海交通大学

硕士学位论文

刀具状态在线监控策略研究

姓名：程敢峰

申请学位级别：硕士

专业：机械工程

指导教师：邵华;程熙

20041101

刀具状态在线监控策略研究

摘 要

本文对刀具状态声发射信号监控策略有关的理论和方法进行了探索, 围绕刀具磨损和破损的检测及识别问题, 进行了切削试验研究。在此基础上, 运用信号处理技术, 针对刀具磨损和破损时的声发射信号进行了特征提取和在线识别的探索。本文的主要研究工作有: (1) 刀具磨损和破损切削试验研究。设计和建立了刀具状态声发射信号的检测系统, 该系统采用高时域分辨率的数字示波器、宽带声发射传感器。在此基础上, 进行了刀具磨损和破损试验, 采集了大量的刀具正常磨损和破损时的声发射信号。(2) 信号特征的分析 and 提取。经过对切削试验数据的分析和处理, 进一步探明了切削用量和刀具后刀面磨损与声发射信号的关系。AE 信号的能量随刀具后刀面磨损量的增加而增加, 同时, 也随着切削用量的增加而增加, 另外, 刀具后刀面的磨损引起 AE 信号在 10K 赫兹处的能量密度增加。(3) 状态识别策略的研究。探索了用 BP 神经网络进行刀具状态识别的方法, 并基于声发射信号特征值和切削参数实现了变切削工况的刀具状态 ANN 识别, 识别正确率达到 81%。

关键词 刀具状态监控, 声发射, BP 神经网络

STUDY ON STRATEGY OF TOOL CONDITION MONITORING

ABSTRACT

The main purpose of this dissertation is to study the strategy of tool condition monitoring. In this paper, some methods are proposed after analyzing the relative theory thoroughly. To solve the tool condition monitoring problem, many experiments are performed using AE sensor to obtain the tool condition signals. Based on the experiment data, tool condition recognition model is carefully studied.

The main contributions of this paper are shown as follows:

1. Experimental study on tool wear and breakage.

A tool condition monitoring experiment system, using AE sensor, high resolution digital oscilloscope is developed. By using this system, a great mass of normal cutting condition signals, tools wear signals and tool breakage signals are collected under carefully designed experiments.

2. Study on feature extraction.

After analyzing a large quantity of experimental data, it is discovered that the cutting parameters and tool flank wear have some

influence on the RMS of AE signals.

3. Study on the models of tool condition recognition.

Based on investigation the present state of tool condition recognition, adaptive resonant BP neural network obtained systematic study. After studying the properties and the parameters of the BP neural network, we use this network in tool wear recognition and get ideal results.

KEY WORDS tool condition monitoring, AE sensor, BP neural network

上海交通大学
学位论文版权使用授权书

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本，允许论文被查阅和借阅。本人授权上海交通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 ， 在___年解密后适用本授权书。
本学位论文属于
不保密 。

(请在以上方框内打“√”)

学位论文作者签名：程敢峰

指导教师签名：邵华

程熙

日期： 2004 年 12 月 30 日

日期： 2004 年 12 月 30 日

上海交通大学

学位论文原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品成果。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结果由本人承担。

学位论文作者签名：程敢峰

日期： 2004 年 12 月 30 日

符号说明

a_p	切削深度
a, b, c, d, e	方程描述中的常数
$Af(\cdot)$	广义模糊函数
A^H	矩阵 A 的 Hermit 转置
$b(n)$	P 阶时序模型的后向预测误差
B_m	后向预测均方误差
$C_x(\cdot)$	时频分布
E	信号均值
E_N	规一化后的子时频域的能量
f	进给量
$f(n)$	P 阶时序模型的前向预测误差
$f_0(n)$	前向预测误差的初始值
F_z	主切削力
l, l_s	信号长度
L	自然数
LTM	长期记忆 (Long time memory)
M	输入矢量的维数
n	转速
N	F 层中的神经元个数
$P_i(k)$	信号功率谱
R^n	n 维欧式空间
$S_X(k)$	Welch 法计算得到的功率谱
T	加权后的 S
U_N	规一化算子

V	切削速度
VB	刀具后刀面平均磨损度
w_{ij}	自下而上的 LTM 权值
w_{ji}	自上而下的 LTM 权值
$W(n)$	离散窗口函数
$X(n)$	n 时刻采样数据
X_k	样本均值
X, Y	F1、F2 层中神经元状态
X_i	数据长度
$X_i(k)$	信号频谱

第一章 绪论

1.1 课题背景

随着计算机技术 (CNC)、加工中心 (MC)、柔性制造单元 (FMC)、柔性制造系统 (FMS) 及计算机集成制造系统 (CIMS) 逐渐成为现代机械制造业的主流, 为实现制造系统的高度自动化提供了先决条件。然而自动化生产的实现依赖于加工过程的自动监控, 因此研究切削过程中刀具状态的自动监控具有重要的意义。

金属切削加工过程是一个复杂的过程。其中影响加工质量的因素是多方面的, 包括毛坯材料与质量、机床、刀具和夹具等。在自动化加工中, 由于广泛采用数控技术, 机床的精度高, 可靠性好而且夹具少, 因此工件的加工质量受机床、夹具的影响较小。而刀具状态对加工质量的影响存在于整个切削过程中, 特别是刀具的磨损直接影响工件的加工精度和表面粗糙度, 刀具破损时不仅影响工件质量, 严重时甚至会影响整个加工系统的运行, 造成很大的损失, 因此刀具状态是影响加工质量的主要因素之一, 而刀具状态是有可能通过在线监控来实现实时识别和做出适当反应的。另外, 在缺乏刀具状态实时监控的系统中, 往往采用刀具寿命管理的方法来防止刀具的磨损, 因刀具寿命的随机性, 其寿命极限估计往往过于保守, 造成浪费, 同时对加工中随机发生的刀具破损现象无法及时做出反映。所以刀具监控技术已经成为现代机械制造中质量保证关键技术之一。

多年来, 对于刀具状态的自动监控技术, 国内外工业生产和研究部门均给以极大的关注并已开展了研究和开发。然而, 迄今为止, 由于切削过程的多样性、复杂性和随机性, 成熟的能够付诸于实用的刀具监控系统并不多。刀具状态自动监控仍是一项尚未完善解决且是迫切需要进一步研究和探索的科研课

题。

近年来，作者所在企业的车间里新添了多台大型的加工中心和数控机床，机床刀具的消耗量大幅度提高，与刀具状态相关的加工问题直接着困扰车间的产品质量和生产成本。在工厂（中国南车集团戚墅堰机车车辆工厂）领导的关心和支持下，作者于 2003 年度开展了数控机床刀具状态监控的攻关活动。本篇论文即是与生产实际相结合，对刀具状态监控策略展开的探索。

1.2 刀具状态监控技术的现状

1.2.1 刀具监控技术分类

刀具的失效状态包括磨损和破损，切削状态又有连续和断续之分，加上不同刀具的失效有各自独特的表现形式和切削环境，构成了研究刀具状态监控问题的复杂性。国内外在这方面做了大量的研究和开发工作，提出了各种各样的解决方法^[2~4]，按照被测量的不同，可以分为直接法和间接法。直接法是指测量与刀具有关的参数，如测量刀具径向尺寸变动量，刀具后刀面的磨损宽度，工件尺寸的变化等。直接法的优点是测量精度高，可以获得确切的被测量参数的数值，它最大的缺点是实际切削条件下信号采集困难，不能实现在线监控，同时难以检测出加工过程中出现的刀具突然失效如（破损），使其适用范围受到一定的限制。目前对直接法的研究已经不多，重点集中在间接测量技术上。

间接法是测量切削加工过程中发出的与刀具状态有内在联系的各种信号：如力、温度、功率、振动及噪声等。因此，通过监测切削过程中的各种信号，就可以间接的推断出刀具的切削状态。间接法的关键是如何从各种信号中有效的提取出反应刀具状态的特征并加以识别，这也是目前研究的重点和难点。

刀具状态监控技术分类如下：（表 1-1）

尽管提出的监测方案很多，但绝大多数检测方法还停留在实验室研究阶段。目前被认为具有潜在应用前景的几种方法是切削力/扭矩法、主轴功率/电

流法和声发射法。与切削力法和主轴功率法比较，声发射法最大优点在于计算机的发展和传感器的发展，使其识别算法相对简单，仪器使用方便。因此近十几年来，声发射法刀具状态监控技术得到较快发展，被认为是最有应用前景的方法之一。

表 1-1 刀具状态监控技术的各种方法

Table 1-1 principle classification of tool condition sensing methods

检测方法	参数	测量方法
直接法	刀具破损量	气动测量
		接触式触头测量
	刀具磨损量	工业电视摄影
		光导纤维测量
间接法	工件尺寸	微量同位素测量
		接触触发式测量
		气动测量
	表面粗糙度	涡流式非接触测量
		一般光学测量
		光导纤维测量
	切削力	激光测量
		静态切削力变化
		动态切削力方差变化
		切削力比值变化
	振动	动态力谱分析
		加速度方差分析
	声	加速度谱分析
		可听声分析
	功率	声发射分析
		主电机功率变化
	扭矩	步进电动机功率变化
		主轴扭矩变化
	刀具温度	主电机电流变化
		自然热电偶测法
刀具导电性	人工热点偶测法	
	接触式电阻测量	
		接触式电压测量

1.2.2 刀具状态间接监控技术

刀具状态的间接监控技术一般由传感器信号采集、信号处理及特征提取和状态识别器三部分组成。其最基本系统结构如图 1-1 所示：

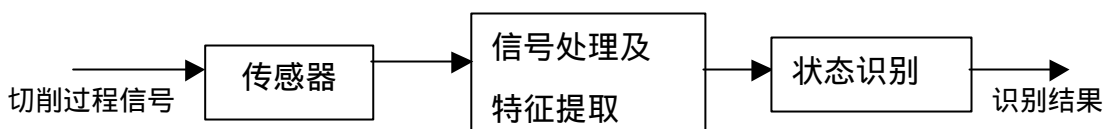


图 1-1 刀具状态监控系统的基本组成部分

Fig1-1 The basic components of tool condition monitoring system

刀具状态监控系统中的传感器主要用于拾取切削过程中发出的各种信号，如切削力、振动、功率、声发射信号等。

信号处理及特征提取是刀具状态监控系统的一个关键组成部分，它对传感器拾取的信号进行分析和处理，去除信号中夹杂的各种噪声干扰，同时提取出与刀具状态密切相关的特征量，然后把这些特征量送到后续的状态识别器中进行刀具状态的识别。信号处理和特征提取的结果对刀具状态的最终判别有极大的影响。虽然特征提取的方法有多种，但目前亟待解决的问题是如何使所提取的特征仅对刀具状态敏感而对切削参数不敏感。

状态识别器是监控系统的核心。它对已经提取出的特征量按一定的决策方法对刀具状态进行判断。它已经从最简单的固定阈值方式发展到现在的更复杂更高级的形式,如 BP 神经网络方法对 AE 信号各种信息进行融合等。

下面简要介绍一下刀具状态间接监控技术的研究状况。

1) 切削力监控法。

广泛的研究证明^[5~17]，在切削过程中，切削力、切削力矩、切削分力的比值或比值的变化率与刀具的磨损或破损有直接的内在联系，而且切削力信号可以通过普通的电阻应变仪或压电传感器方便的获得。

一般的，切削力随刀具磨损的增加而增加。S.Jetly 的实验结果表明^[18]，在车削过程中进给力对刀具磨损比主切削力敏感；但 R.Uehara 的研究结论相

反^[19]，发现主切削力最能反映刀具的磨损程度。对于刀具的破损，有两种不同的观点^{[10][20]}：(1) 当刀具破损时，挤在刀具和工件之间的断裂碎片会导致切削力的增加，而后切削力又随碎片的脱落减为零。(2) 圆周切削力和进给力对刀具破损都很敏感，而只有圆周切削力表现出下降的特性。由于刀具破损引起的圆周切削力的下降量和沿刀刃的破损长度成正比，而进给力则随刀具的磨损程度和形式不同而时增时减。众多的研究者致力于提高切削力监控的灵敏度。其一是考虑切削力的测定部位，它应尽量靠近切削区；其二是怎样选择测定三个方向的切削力；此外，还应考虑切削分力的比值或比值的变化率。

切削力监控虽然已经取得了很多成果，但并未得到广泛应用，这是因为切削力监控方法存在固有的缺点限制了其在生产实际中的应用。由于切削过程的复杂性，影响切削力的因素很多，较难建立精确而完善的切削力模型；即使建立了较完善的切削力模型，切削用量的改变引起的切削分力的变化很难与由刀具破损或磨损引起的切削分力的变化区分开；另外，在安装测力装置时需要改装机床结构，使调整和维修很不方便，不利于该方法在生产实际中推广。

切削力检测技术在国外已有商品问世。瑞典 SANDVIK 公司七十年代向用户提供了安装在主轴轴承座上的推力传感器用于监控刀具磨损，八十年代，该公司又推出的 TMS 单通道和多通道刀具监控器，可自动记忆锋利刀具的切削状态并确定警报限值，分别提供刀具的磨损、破损和未在切削等信息。

2) 刀具状态的切削噪声监控法。

在切削加工过程中测得的声音信号中含有大量有关切削状态的信息，因而可以利用声音信号监控刀具的状态^[21]。A. B. Sadat 等人发现刀具和工件间的摩擦噪声声级在 2.73~3.5KHZ 的频域内，钝刀比新刀高约 15 分贝。在磨损初期噪声声级明显上升而后趋于平稳。当切削速度提高时，噪声声级下降，而刀具的悬臂增大时，噪声声级变大。^[22]L. C. Lee 发现在大多数工件材料组合及工况下，4~6KHZ 频率附近存在一个切削噪声的特征频率，其声压级与刀具的磨损

有很好的相关性。在急剧磨损前该声压级呈下降趋势。

然而，尽管目前已有不少利用切削噪声监控刀具状态的设想，但实用的监控系统还很少见。其中一个重要原因是采用声音检测法难以在实际的加工车间实行，因为车间的环境噪声通常在 90 分贝左右，此外，信号的实时处理技术以及特征提取方法尚有待进一步研究。

3) 刀具状态的功率监控法（电流法）。

众所周知，刀具的状态变化可以引起切削力的变化，切削力的变化可以间接的反映机床所消耗的功率变化上，因此，机床功率监控可以归入切削力监控一类，即检测机床电动机的功率就可以推断出刀具状态。与切削力方法相比较，机床功率法具有测量信号简便，可以避免切削环境中切屑、油、烟、振动等干扰，监控装置易于安装的优点，是目前较为广泛应用的一种监控法。

4) 刀具状态的声发射监控法

声发射（Acoustic Emission, 简称 AE）刀具监控技术是近期内发展起来被公认是一种最具潜力的新型监控技术之一。在金属切削时，切削区的材料变形过程中，塑性应变能迅速释放并产生弹性应变波，也即发出声波，这就是声发射。而用仪器检测分析 AE 源的技术叫声发射技术。

在金属的切削过程中，存在着很多声发射源，如三个切削区材料的弹性变形，工件与刀具之间的摩擦，切屑的折断，刀具的破损等。当刀具发生磨损和破损时，所发出的声发射信号将发生变化。声发射信号是一种高频表面波，在传播过程中衰减很快，一般采用压电传感器拾取信号并尽量靠近切削区。

近年来，声学检测方法有很大的发展，它在无损检测技术中占有很重要的地位。AE 检测是声学无损检测的重要方法，它必须由外部条件作用。另一方面，由于这些因素的作用，使材料的内部结构发生变化，如滑移变形，裂纹扩展等。发声是材料内部结构变化过程中产生的，也只有内部结构变化，才能引起能量释放，才能发声，因此 AE 监测是一种动态无损监测方法。

目前在声发射监测中所采用的特征量有均方根值 (RMS) 能量分析, 振铃计数, 幅值分布和频谱分析等。T.Blum^[23-27] 等研究了切削条件的变化对声发射信号的 RMS、计数率等的影响, 发现声发射信号的 RMS 值随刀具后刀面磨损程度的加剧而增加, 并且随切削用量的加大而增加; 计数率与切削速度和进给量成线性增加关系, 而总的声发射事件发生率随进给量的增加而减少。^[28] 上海交通大学的赵曙伟等发现刀具破损时声发射信号能量主要集中在 340KHZ 左右, 持续时间短 (0.4-0.6ms), 能量大, 并且能量幅值依破损面积的大小而相应变化。研究表明, 表征刀具磨损的声发射信号特征量受切削参数的影响很大, 因此如何区分由刀具磨削和切削参数变化而引起的特征量的变化十分重要。

声发射检测技术在国外已有很多专利面世, 国内清华大学也已研制成功声发射车削监控器。

声发射刀具状态监控法有很多优点, 首先, 声发射信号直接来源于切削区, 与刀具状态相关程度高。而且声发射信号一般是高频信号, 不易受环境噪声的干扰, 具有灵敏度高, 响应快的特点, 这是其它信号无法比拟的。因此声发射信号在刀具状态监控中得到越来越广泛的应用。^[30-43] 但是由于切削过程中的声发射源很多, 声发射信号的产生机理十分复杂, 使其在时域和频域上也十分复杂, 要将不同来源的声发射信号分离出来是极为困难的。所以如何对声发射信号进行处理, 提取刀具状态敏感的特征量是十分重要的。

1.2.3 常用的特征提取技术

各种刀具状态的监控方法, 除了采用合理的信号获取方法之外, 第二个关键部分是对传感器获得的原始信号进行有效处理, 提取对刀具状态敏感的特征量。在过去的几十年里, 刀具状态特征量的提取方法也随信号处理技术的发展而不断完善和发展。根据不同的传感方法, 特征提取可以采用能量分析, 相关分析, 频谱分析, 谱估计和小波变换等方法。

刀具状态的变化常常引起信号的能量分布发生变化。例如，在其它切削条件不变的条件下，随着刀具后刀面的磨损，声发射信号、噪声、振动、电机功率信号的 RMS 值都随着增大，因此计算信号的 RMS 值是广泛采用的一种方法。^{[32][44-46]}但是信号的 RMS 值受切削参数变化的影响很大，并且不能反映系统的动态信息。所以反映信号幅值分布情况的方差和峰值的方差和峰值系数也常被作为监测特征量^[44-46]。

尽管信号处理和特征提取的方法不同，其基本要求是能反映刀具状态的变化，又要尽量减少对切削参数的敏感性。而就目前所发表文献来看，特征提取技术远未成熟，尚须进一步探索。

1.3 刀具状态监控技术的发展趋势

现阶段，虽然刀具状态监控技术的研究已经取得了不少进展，但它还远未成熟。由于刀具监控技术是一项综合性的多学科交叉的高技术，它包括了金属加工学、信号处理、传感器技术、计算机和自动控制等各种不同领域的知识。它既是一项应用技术，又需要进行大量的基础理论研究。因此刀具状态监控技术的发展趋势表现在两个方面：

1. 要加强基础理论的研究，主要是对切削过程的进一步认识，进一步了解切削过程中各个变形区的应力应变的动态过程以及发出的各种信号和他们所表现出来的特征。

2. 其次要加强应用技术的研究，具体表现在三个方面：

- (1) 信号采集，一方面是采用各种高性能集成化、智能化的传感器，这种新型的传感器将传统的传感器、初级的信号处理功能集中在一起，具有较高的抗干扰性和可靠性；另一方面是信号采集的多传感器化。

- (2) 信号处理与特征提取方面，采用各种先进的数字信号处理及特征提取的多模型化。

- (3) 在刀具状态识别模型方面使信息决策智能化。如采用新型的神经网络

和模糊神经网络技术等。

总之，对刀具状态监控的研究，一方面要加强基础理论的研究，获得对刀具时效敏感的特征，发展使用可靠的新型决策模型；另一方面要加强理论和实践相结合，才能使刀具状态监控技术得到进一步的完善。

1.4 本文主要研究内容

在上述诸多刀具状态监控的理论研究和实施方案中，提出了许多有价值的刀具状态特征信号和监控策略。然而迄今为止，刀具状态的监控系统还不能说非常成功，因此它们无法给出可靠的、可以适用于多种加工工况的刀具状态监控指标。本文采用声发射法，利用 BP 神经网络模式识别技术针对车削过程中的粗加工和半精加工刀具状态的监测问题进行研究探索，具体工作内容如下：

1) 拟建立刀具磨损的声发射试验系统，并在此基础上拟定试验方案，采集刀具磨损的声发射信号。

2) 在试验数据的基础上，分析切削用量和刀具后刀面磨损量对声发射信号的影响，对刀具磨损和破损声发射信号进行分析处理，在分析对比的基础上进一步明确在多种工况下刀具磨损的声发射特征量，采用 BP 神经网络进行刀具磨损和破损的 AE 信号进行信息融合，并基于切削参数（切削速度，切削深度，进给率）实现变切削工况下刀具状态 AE 识别。

第二章 刀具切削试验设计与试验系统

为了考察切削用量和刀具后刀面的磨损对 AE 信号的影响，作者建立了刀具状态的切削实验系统，制定了实验方案。采集刀具磨损和破损时的 AE 信号，考察切削用量对 AE 信号的影响，我们进行了刀具磨损和破损的试验，采集了大量的试验数据以供考察 AE 信号与刀具状态之间的关系。

2.1 试验装置及系统

本实验主要在一台型号为 Index G200 的数控车床上进行，刀具采用可转位的 PF4015 硬质合金刀片，试件为调质后的 45 号钢，AE 信号由传感器采集，通过放大以及滤波，输出到 TekScope 高速数字示波器中进行波形显示与数据采集。在实验过程中，通过改变切削速度 v ，进给率 f ，切削深度 a_p 等切削参数，采集到一系列对应的 AE 信号，从中探求 AE 信号与刀具状态之间的关系。试验系统组成如图 2-1 所示：

试验所用仪器及设备简要说明如下：

1、机床

一台型号为 Index G200 的数控车床与一台型号为 CA6150 卧式车床（沈阳第一机床厂生产）。前者主要用于切削实验，后者用于加速磨损。其参数分别为：Index G200：床身上最大工件回转直径 400mm，最大工件长度 1000mm，主轴电动机为三相异步电动机，三角形接法，额定功率为 18KW，额定电流为 15A。；CA6150：床身上最大工件回转直径 500mm，最大工件长度 1000mm，主轴电动机为三相异步电动机，三角形接法，额定功率为 7.5KW，额定电流为 15A。

2、刀具

采用 55° 菱形可转位硬质合金刀片。刀片型号是 PF4015，刀片采用机械夹固方式进行固定，每个刀片有两个刀刃。刀具的材料组成为：0.4% C，

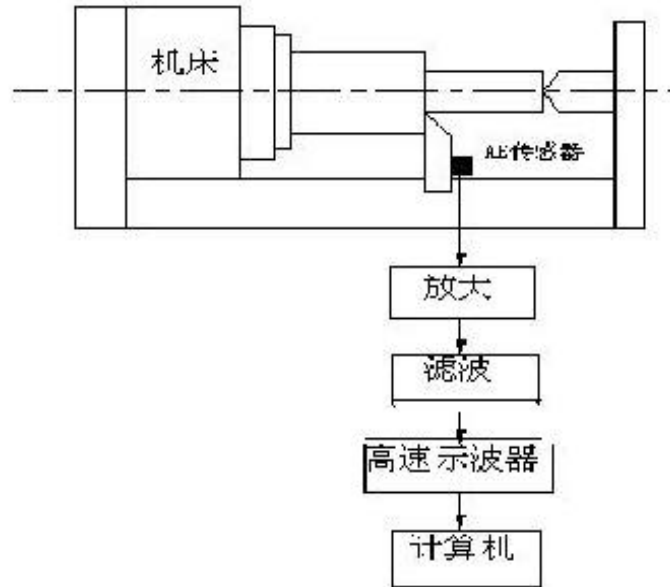


图 2-1 试验系统的组成

Fig2-1 Constitutes of experiment system .

0.28% Si, 0.27% Mo, 1.18% Cr, 0.5% Mn, 1.4%; 刀具的几何参数如图 2-2 所示, 其中: $l = 11\text{mm}$, $r_e = 0.4\text{mm}$, $s = 3.97\text{mm}$ 。(在每一刀片上用笔作好标记, 注明刀刃, 以防止试验时发生混淆。)

3、试件

试件一材料是不锈钢, 型号为 1Cr18Ni9Ti。具体尺寸: 外径 330~340mm, 内径 120mm。具体材料成分如表 2-1 所示:

表 2-1 试件一材料成分

Table2-1 Material component of workpiece NO.1

C	Si	Mn	P	S	Ni	Cr	Mo	Cu	N
0.12	1.00	2.00	0.035	0.030	8.00-11.00	17.00-19.00	—	—	—




图2-2 刀具几何参数

Fig2-2 Geometry parameter of tool insert

试件二材料是 45 号钢，具体尺寸：外径 155mm，内径 90mm。具体材料成分如表 2-2 所示：

表 2-2 试件二材料成分

Table2-2 Material component of workpiece NO.2

C	Si	Mn	P	S	Ni	Cr	Cu
不大于							
0.42-0.50	0.17-0.37	0.50-0.80	0.035	0.035	0.25	0.25	0.25

试件一用于加速磨损，试件二用于切削试验。

3、KEYENCE 放大镜，型号 VH-800，用于实验中对刀片的后刀面磨损值的测量。

4、AE 传感器

试验中使用50KHZ到1MHZ的宽带压电陶瓷传感器，利用压电陶瓷的受激共

振将AE信号的弹性应力波转化为电压波动信号，以便采集和分析。传感器放置在刀杆接近刀头处，且被固定。为了消除AE波在越过界面的能量损失，刀杆和AE传感器接触表面均用金相砂纸研磨过，中间采用黄油作耦合剂。

5、放大及滤波

实验中AE信号的放大倍数为20dB。在放大以后，为了去除噪声的影响需要进行滤波处理，本系统采用了通带范围为20KHZ~1MHZ的宽带滤波，目的是为了滤掉低频的机械噪声和高频的电磁干扰。

6、TekScope THS720 型高速数字示波器

该仪器用于AE信号的采集及暂时存储数据。它具有两个瞬时采样通道，采样频率最大可达500MHZ，可通过RS232串口和专用软件Wavestar完成向微机的数据传输。数据记录可通过设定被采样信号阈值，利用多种触发方式，多时基触发完成。本试验采用了边沿触发，采样频率为2.5MHZ，并根据各种切削工况下AE信号的大小调整阈值。

7、微机

PII微机一台，用于数据的传输和处理。

8、分析软件

Matlab 软件用于编写数据处理与图形绘制的程序。

2.2 试验方案

在生产实际中，影响AE信号的因素很多，除刀具的状态因素之外，最重要的影响因素是切削用量。因此本试验除了进行刀具后刀面磨损和刀具破损试验之外，还进行了切削用量对AE信号影响试验，具体试验如下，在试验中未使用切削液。

2.2.1 切削用量对 AE 信号的相关性试验

1. 切削速度对AE信号影响的试验：

试验中采用同一新刀片的同一个切削刃进行切削。为了避免工件直径变化而引起切削速度变化,试验中工件直径保持不变,均为 $\Phi 150\text{mm}$,二组试验的切削用量如下:

1) $f=0.1\text{mm/r}$ $a_p=0.1\text{mm}$ $VB=0.302\text{mm}$

2) $f=0.15\text{mm/r}$ $a_p=0.1\text{mm}$ $VB=0.302\text{mm}$

转速依次为200, 250, 300, 400, 500, 600r/min。

2. 切削深度对AE信号影响的试验

与上述试验类似,用同一个新刀片的同一切削刃切削做二组试验,工件直径为 $\Phi 150\text{mm}$,所用切削用量如下:

1) $n=400\text{r/m}$ $f=0.1\text{mm/r}$ $VB=0.225\text{mm}$

2) $n=600\text{r/m}$ $f=0.2\text{mm/r}$ $VB=0.225\text{mm}$

切削深度取三个等级,分别为0.1, 0.2, 0.3mm

3. 进给量对AE信号影响的试验

同上,用同一把新刀的同一切削刃做二组试验,所用的切削用量如下:

1) $n=500\text{r/m}$ $a_p=0.1\text{mm}$ $VB=0.225\text{mm}$

2) $n=600\text{r/m}$ $a_p=0.1\text{mm}$ $VB=0.225\text{mm}$

进给量依次从0~0.4mm/r依次变大。

上述各试验是在材料是45#钢的情况下进行的,在试验进行的同时,采集AE信号。

2.2.2 刀具状态对 AE 信号的影响

对于刀具后刀面的磨损试验,选用的切削用量为 $n=400\text{r/m}$ $a_p=0.15\text{mm}$ $f=0.15\text{mm/r}$

每走刀若干次采集记录AE信号,拆下刀片用工具显微镜量后刀面平均磨损量VB值,并记录下来。

2.2.3 刀具破损试验

在正常条件下，刀具自然破损很难发生，为了加速刀具的破损，在加工工件过程人为冲击工件，采集AE信号，并重复进行。

2.3 小结

本章主要是针对刀具磨损和破损的AE检测建立了实验装置和系统。该系统包括先进的检测仪器，宽带AE传感器和高速示波器，其中AE信号采集装置具有极高的时域分辨率。在此基础上，刀具磨损试验为有效的研究刀具监控理论打下了基础。

第三章 基于声发射的刀具状态检测

采集到切削过程中大量的 AE 信号之后, 为了实现刀具状态的识别, 需要进行各种信号处理, 从原始 AE 信号中提取能反映刀具状态的特征信号, 以达到刀具状态的最高识别。

3.1 声发射检测的原理

3.1.1 声发射信号的产生机理

材料受外力或内力作用产生变形或断裂, 以弹性波形式释放出应力应变能的现象称为声发射(Acoustic Emission, 简称AE)。各种材料声发射的频率范围很宽, 从次声频、声频到超声频。声发射是一种常见的物理现象, 如果释放的应变能足够大, 就可产生人耳听得见的声音。大多数金属材料塑性变形和断裂时有声发射发生, 但许多金属材料的声发射信号强度很弱, 人耳不能直接听见, 需要借助灵敏的电子仪器才能检测出来。用仪器检测、记录、分析声发射信号和利用声发射信号推断声发射源的技术称为声发射技术。声发射技术的研究工作最早是德国人Kaiser于1950-1953年开始进行的。他观察到金属锌、铜、铝及铅都有声发射现象, 并且发现了声发射的不可逆性。但在制造过程中作为过程监控方法的研究只是从七十年代后期开始的。这里介绍金属切削加工中与过程监测密切相关的两种声发射产生机理。

1、位错运动和塑性变形

以位错运动为基础的滑移变形是金属及其合金形状不可逆转变化的基本形式之一。滑移的过程就是位错运动, 当位错以足够高的速度运动时, 位错周围的局部应力场就成为声发射的条件。一方面, 在位错运动中, 滑移面内的原子在前拥后挤的过程中使原子发生碰撞, 从而发生弹性波; 另一方面, 一个稳定

的位错是处于低能状态的，在外部应力作用下，位错从一个稳定状态运动到另一个稳定状态前要克服高能位垒，当位错移动到高能位时，原子点阵的位能增加，从高能位向低能位运动时，释放出多余的弹性应变能，其中一部分成为弹性振动波，即 AE 波。实验表明，当许多金属材料在拉伸变形时，在屈服点附近出现声发射计数率高峰，在进入加工硬化阶段，声发射计数率急剧减少。这是由于在屈服点附近可动位错数量的增加，而在加工硬化阶段，由于位错的交割和钉扎使可动位错数量减少所致。另外，金属的孪生变形过程也会成为强烈的声发射源。

2.、裂纹的形成和扩展

裂纹的形成和扩展也是一种重要的声发射源，一旦裂纹形成，材料局部区域的应力集中得到卸载，就会产生声发射源。材料的断裂过程大体可分为三个阶段：（1）裂纹形成；（2）裂纹扩展；（3）最终断裂。三个阶段都可以成为强烈的声发射源。研究表明，^[47]裂纹形成和扩展产生的声发射比位错滑移产生的声发射信号能量至少大两个数量级。

3.1.2 声发射信号的传播与检测

为了有效的检测 AE 信号，首先要了解 AE 信号的传播途径。声发射波的传播规律与固体介质的弹性性质密切相关。声发射波在传播过程中，引起周围材料应力与应变的变化，使材料不仅产生体积变形，而且产生剪切变形，因此将激起两种波：即纵波（压缩波）和横波（剪切波）。它们以不同的传播速度在介质中传播，当遇到不通介质的界面时会发射和折射，当传播至金属表面时，引起沿表面的表面波。

声发射波从声源到换能器传播过程中会发生许多变化。首先是能量衰减问题，AE 波在金属材料中传播时，会产生能量的衰减。主要有散射衰减、粘性衰减、位错运动引起的衰减、铁磁性材料磁畴壁运动引起的衰减、由于存在残余应力使声场混乱引起的衰减，以及其它各种内摩擦引起的衰减。散射衰减主

要来自多晶体金属中多晶粒对波的散射它是 AE 波衰减的主要，而且这种散射与频率的关系很密切，试验证明，^[48]在低频时，即波长比晶粒尺寸大的情况下，散射较小，引起的衰减就较小；而在高频时散射较大，引起的衰减就较大。而其它情况如晶格缺陷、位错阻尼、内部摩擦、变形滞后和微量蠕变等许多机械作用亦会使波动系统受到衰减，而且由于粘弹性阻尼与频率的平方成正比，即频率越高，受到的衰减也越大，^[29]这一情况得到了大量实验的证实。所以，在检测 AE 波时，换能器相对于声源的位置对记录信号的频率分布会造成很大的影响。其次是波形畸变问题，晶粒边界的存在会给 AE 波传输带来复杂性，因为边界两侧声阻抗的差别会形成反射波；而且如果边界相对于声波方向是倾斜的，就会在纵波和横波之间发生某些模式转换。当靠近声发射源的发射脉冲在一部分发射波到达前还没有消失，就会造成声波的重叠而出现畸变。由于各个晶粒的非均匀及去向的随机性，当声波越过晶粒边界时，其速度往往会发生变化。而不同频率的波传播速度不同会引起频率分量在相位上的分离，发生频散现象，从而波形发生畸变。所以，换能器接受到的 AE 信号是源 AE 波经过多次发射和发生畸变的复杂波形。因此为了尽量减少声发射信号在传播过程中的衰减和畸变，在刀具磨损检测中，声发射传感器的安装尽可能靠近切削区。

3.2 声发射信号的处理方法

声发射技术作为一种动态检测技术已广泛应用于各种材料或结构的稳定性评价。声发射检测的目的就是发现声发射源和尽可能多地得到有关声发射源的信息。因此，声发射信号处理实质上是要根据不完整、受到畸变和干扰并混合有大量噪声源的声发射信号信息中获得声发射源的信息特征和描述。目前，常用声发射信号处理基本上可以分为时域和频域两大类，在时域主要是一些统计分析如方差、均值、均方值等，而在频域主要是对频率成分进行分析和估计，如时频分析、小波分析等，但从实用、有效、成熟的角度来讲，最基本的方法

是频谱分析，其理论基础为傅立叶变换，为了适应计算机的计算，必须把连续的傅立叶变换变成离散的傅立叶变换。快速傅立叶变换 FFT(Fast Fourier Transform)的出现大大缩短了计算时间。一旦监视发现被监测的对象异常(即有故障)，要判断到底是什么类型的故障，故障发生的部位、产生原因以及严重程度等比较准确的信息，就要对所测量的数据进行比较精确的分析处理，以便根据此分析处理结果对被测对象进行控制等动作。信号经 FFT 变换后得到频谱图，根据频谱图中的频率成分以及各有关频率成分处频谱值的大小等信息可以更准确地判断出对象所处的状态。

声发射信号处理方法是声发射检测技术中的重要环节。声发射信号是声发射检测技术对检测对象作出评定的主要依据，它是一种复杂的波形，包含着丰富的声发射源信息，同时在波的传播过程中波形会发生畸变并会引入干扰噪声。如何选用合适的信号处理方法来分析声发射信号，从而获取正确描述声发射源的特征，一直是声发射检测技术发展中的难点和研究热点。声发射信号处理技术面临的两大困难是 AE 信号的微弱性(但又完全可以是宽动态范围)和干扰噪声的多样性。由于声发射信号具有不可预知性、突发瞬态性、声发射源信号的多样性和干扰噪声的多样性等特点，使得在声发射技术发展史上，各种可能的信号处理方法都曾被尝试过。根据分析对象不同，可以把声发射信号处理方法分为两大类：基于参数的分析方法和基于波形的分析方法。参数分析方法是以前多个简化波形特征参数来表示声发射信号的特征，然后对这些波形特征参数进行分析和处理，其应用比较成熟。波形分析方法是存储和记录声发射信号的波形，然后对波形进行分析，它能够提供更比参数分析更多的信息量。目前这两大类处理方法都在声发射检测技术中得到应用和发展，下面介绍声发射信号处理方法具体的应用和发展情况。

3.2.1 参数分析

声发射信号简化波形特征参数分析方法自二十世纪五十年代已经广泛使

用，目前仍广泛应用于声发射检测技术。对连续型声发射信号，能量测量是定量研究声发射信号的主要方法之一。声发射信号的能量通常用均方电压 V_{MS} 或均方根电压 V_{RMS} 来表征。一个信号 $V(t)$ 的均方电压 V_{MS} 和均方根电压 V_{RMS} 定义如下：

$$V_{MS} = \frac{1}{\Delta T} \int_0^{\Delta T} V^2(t) dt \quad (3-1)$$

$$V_{RMS} = \left(\frac{1}{\Delta T} \int_0^{\Delta T} V^2(t) dt \right)^{\frac{1}{2}} = \sqrt{V_{MS}} \quad (3-2)$$

其中： $V(t)$ 为随时间变化的信号电压， T 为平均时间长度

当刀具磨损、破损时，可见信号的能量变化率正比于 RMS 值，AE 信号的均方电压值或均方根电压会随之增大，而刀具破损时则会产生较大的突发性信息。因此，监测 AE 信号的表征参数可获得刀具切削状态的信息。

3.2.2 波形分析

波形分析是指根据所纪录的声发射信号时域波形，采用信号处理方法对之进行分析来获取声发射源信息。声发射信号波形中包含有丰富的声发射源信息，随着信号处理方法的发展，更多的先进处理方法用于声发射波形信号的特征分析，使得波形分析逐渐发展成声发射源特征获取的主要方法。从理论上讲，波形分析应当能给出任何所需的信息，因而也是最精确的分析方法，可实现对声发射信号的定量分析。目前人们常用现代信号处理的一些方法对声发射信号的波形进行分析，如：小波分析方法、相关分析、频谱分析方法、AR 谱分析方法等。频域方法可从另一角度揭示由于刀具状态突变而应起的 AE 信号能量在频域上的分布情况。由于 AE 信号是随机信号，所以在进行频谱的分析应采用功率谱密度。

1、直接法^[49]

直接周期图法又称周期图法，它是把随机信号 $x(n)$ 的 N 点观察数据 $x_N(n)$ 视为一能量有限信号，直接取 $x_N(n)$ 的傅立叶变化结果 $X_N(e^{j\omega})$ ，再取其

幅值平方，并除以 N ，作为对 $x(n)$ 真实功率谱 $P(e^{j\omega})$ 的估计。以 $\mathbf{P}_{PER}(e^{j\omega})$ 表示用直接法估计处的功率谱，则：

$$\mathbf{P}_{PER}(\omega) = \frac{1}{N} |X_N(\omega)|^2 \quad (3-3)$$

自从 FFT 出现后，此方法就变成了谱估计中的一个常用的方法。将 ω 在单位圆上等间隔取值，可得：

$$\mathbf{P}_{PER}(k) = \frac{1}{N} |X_N(k)|^2 \quad (3-4)$$

由于 $x_N(k)$ 可以用 FFT 快速计算，所以 $\mathbf{P}_{PER}(k)$ 也可以方便地求出。由其原理可知此方法包含了下述假设及步骤：

(1) 把平稳随机信号 $X(n)$ 视为各态历遍地，用其一个样本 $x(n)$ 来代替 $X(n)$ ，并且仅利用 $x(n)$ 的 N 个观察值 $x_N(n)$ 来估计 $x(n)$ 的功率谱 $P(\omega)$ 。

(2) 从一记录到的一个连续信号 $x(t)$ 到估计出 $\mathbf{P}_{PER}(k)$ ，还包括了对 $x(t)$ 的离散化，必要的预处理(如除去均值、除去信号的趋势项、滤波)等。

直接法与真实谱存在偏差，不是真实谱的一致估计。同时，数据加窗对谱分辨率具有不利影响：

(1) 造成“频谱泄漏”。序列与加窗函数相乘意味着总的变换是所期望的变换与窗函数变换的卷积，如果信号的真正功率集中在一个窄的频带内，此卷积将把这个窄带功率扩展到邻近的范围，从而导致“频谱泄漏”的产生。“频谱泄漏”对功率谱估计及正弦分量的监测带来有害的影响，因为弱信号的主瓣很容易被强信号泄漏到邻近的副瓣所淹没或畸变，引起谱的模糊与失真。

(2) 降低频率分辨率。谱估计总的谱峰分辨率是指其能分辨真实功率谱中的两个相邻谱峰的能力。窗的变换使实际信号的卷积式信号的主瓣变宽，其增加的宽度是由窗函数的主瓣宽度决定的。对于矩形窗，其傅立叶变换的 3dB 间的主瓣宽度近似等于观测时间的倒数，对于其它窗的使用，分辨率也常是正

比于观测时间的倒数。因此对于短观测数据序列，其功率谱估计的分辨率是不高的。非均匀窗的使用，可以减低旁瓣泄漏，但付出的代价是窗函数变换主瓣的加宽，因而造成谱分辨率的降低。

2、Welch 法^[50]

周期图法估计出的谱 $P_{PER}(k)$ 性能不好，当数据长度 N 太大时，谱曲线起伏加剧， N 太小时，谱的分辨率又不太好，因此需加以改进。对其改进的方法一是使其平滑，二是平均法。Welch 平均法又称为加权交叠平均法，它正是基于此原理对周期图法的改进。Welch 平均法的原理简要介绍如下：

设有时域采样信号 $x(n)$ ，长度为 l ，将 l 点数据分段，设每段数据长度为 l_s ，为了增大 l_s 以利于进一步平方后的方差，各段数据有交迭，然后对每段数据进行加窗处理，补零使 $M \geq L$ 且为 2 的整次幂，并作 FFT 运算，得到该段数据的信号频率，进而求出该段的功率谱，

$$X_i(k) = \sum_{n=0}^{M-1} x_i(n)w(n)e^{-jwn} \quad (3-5)$$

$$P_i(k) = \frac{1}{M} |X_i(k)|^2 \quad (3-6)$$

然后再算出 k 段的平均值，作为功率谱的最后估计值，

$$\hat{S}(k) = \frac{1}{KU} \sum_{i=1}^k P_i(k) \quad (3-7)$$

式中， $U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n)$ 是归一化算子，以保证谱估计的渐进无偏。具体计算过程

如图 3-1 所示。




图 3-1 Welch 法计算过程

Fig3-1 Spectrum calculation procedure using Welch method

3、 频谱泄漏及加窗处理^[50]

一般将时间函数 $x(t)$ 称为截断函数，又称数据窗，其傅立叶变换称为谱窗或窗函数。由于离散(采样)波形需要截断，波形被离散与截断后的傅立叶逆变换等于窗函数与波形截断前的傅立叶逆变换的卷积。截断后的谱图对于真实谱来说，只是一个近似，称为估计谱。这是由于截断原始数据使频率域函数产生了畸变而造成的。同时还造成了能量的漏失。这种效应叫做频谱泄漏。为了减少泄漏，就要考虑选用一种时域截断函数(数据窗)，即它对应的频域函数与 $\sin f/f$ 型函数比较，具有较小的旁瓣值，后者值越小，泄漏对于傅立叶变换的影响也越小。在谱分析中，如不强调或明确指出加某种窗函数时，就是加矩形窗。在时域内截断时，除矩形窗外，其它窗函数都会引起波形畸变。所以对谱值加以修正。

加不同的窗函数可以改变泄漏的效果，同时也产生了不良的影响，即谱线变宽而模糊了，因此必须根据需要选用合适的窗函数，从减小泄漏和避免谱线过分加宽综合考虑，汉宁窗还是比较好的。

3.2.3 AE 信号时频分析^[21]

由于金属切削过程的复杂性，金属切削过程中所发出的声发射信号十分复杂，既有连续型 AE 信号，又有突发型 AE 信号。突发型 AE 信号又常常和刀具的异常破损相联系。由于产生突发型信号的声发射源比较多，如刀具破损、刀具内部微裂纹的扩展、切屑折断、切屑和工件之间的撞击等，而突发型 AE 信

号的幅值常常又较连续型大出数倍甚至几十倍，因此仅仅用时域方法无法将由刀具破损发出的 AE 信号与其他 AE 源发出的信号区别开来，应用在实际中会出现虚假报警的现象。从以 FFT 为基础的频域角度上看，各种声发射源发出的 AE 信号会有所不同，但这种分析方法的根本假设是 AE 信号是平稳的或时不变的信号。但突发型 AE 信号常与材料内部裂纹扩展，材料断裂等密切相关，因此是一种非平稳信号。对非平稳信号，更科学更合理的方法是从时域的频域两方面同时分析信号的变化情况，后续的实验数据处理也证明了这种方法具有其他方法无法比拟的优越性。而在已发表的文献中，作者没有发现采用时频分析方法对 AE 信号进行处理的先例，作者将用这种方法进行有益的尝试。

短时傅立叶变换是一种常用的时频分析方法，其基本思想是在傅立叶变换的基础上为了实现时频的局部化，对待分析的时变信号 $x(t)$ 加窗函数 $g(t)$ 。在窗口宽度足够窄的情况下认为信号是平稳的，这种方法最主要的缺点是窗的宽度直接和频率分辨率相关，为了获得高的频率分辨率，就必须增加信号观测长度，既增加窗的宽度，然而窗的加长就抹杀了这段时间内信号的时变特性。而具有一系列优良性质的 Wigner-viller 分布近年来受到科技界的广泛重视。1966 年，Cohen 给出了时频分布的统一表达形式。本文将采用在 1988 年由 Clio-Williams 提出的 ED(Exponential Distribution)分布。

Cohen 关于信号时频分布的统一表达形式如下：

$$C_c(t, \omega, f) = \frac{1}{2p} \int \int \int \lambda^{j(xm-tw-x)} f(x, t) c\left(m + \frac{t}{2}\right) c^*\left(m - \frac{t}{2}\right) dm dt dx \quad (3-8)$$

其中 $x(\mu)$ 是时域信号， $x^*(\mu)$ 是其复共轭， $f(x, t)$ 为核函数 (Kernel function)，给定不同的 $f(x, t)$ 可以得到不同的分布。当 $f(x, t)=1$ 时，即为 Wigner 分布。当 $f(x, t)=e^{-\xi^2 + 2/\mu}$ 时，即为 ED 分布。Cohen 类分布是双线性分布，在利用 Cohen 类分布进行时频变换时，将不可避免的发生交叉项干涉问

题。设多份量信号 $x(t)$ 可以表示为若干个单分量信号之和：

$$c(t) = \sum_{k=1}^n c_k(t) \quad (3-9)$$

其中 $x_k(t)$, $k=1, 2, \dots$ 都是单分量信号。因此

$$c\left(m + \frac{t}{2}\right) \cdot c^*\left(m - \frac{t}{2}\right) = \sum_{i=1}^n c_i\left(m + \frac{t}{2}\right) c_i\left(m - \frac{t}{2}\right) + \sum_{i \neq j} \sum_{j=1}^n c_i\left(m + \frac{t}{2}\right) c_j\left(m - \frac{t}{2}\right) \quad (3-10)$$

对应的时频分布为：

$$C_c(t, \mathbf{w}, \mathbf{f}) = \sum_{i=1}^n C_{c_i c_i}(t, \mathbf{w}, \mathbf{f}) + \sum_{i \neq j} \sum_{j=1}^n C_{c_i c_j}(t, \mathbf{w}, \mathbf{f}) \quad (3-11)$$

式中

$$C_c(t, \mathbf{w}, \mathbf{f}) = \frac{1}{2p} \iiint \lambda^{j(xm-tw-xt)} f(\mathbf{x}, t) c_i\left(m + \frac{t}{2}\right) c_j^*\left(m - \frac{t}{2}\right) dm dt dx \quad (3-12)$$

$C_{c_i c_i}(t, \mathbf{w}, \mathbf{f})$ 为 T-F 分布中的自项， $C_{c_i c_j}(t, \mathbf{w}, \mathbf{f})$ 为互项，即交叉项。交叉项的形状和幅值是由核函数的特性决定的，交叉项在 T-F 分布中模糊了真正的能量分布，是多余的信息，并且对利用 T-F 分布进行模式识别及分类的后续工作将造成很大的影响。因此。在过去的十几年中，人们都在努力探索压制交叉项的方法，其中由 Clio-Williams^[158] 提出的指数核 $f(\mathbf{x}, t) = e^{-\xi_2 t^2 / a}$ 很好的解决了这一问题。和指数核相对应的分布称为指数分布，记为 ED。

ED 对交叉项的抑制是通过调整常数 σ 来实现的。这可以通过广义模糊函数的结构得到说明。 $x(t)$ 的广义模糊函数可以表示为：

$$A_f(\hat{t}, \hat{\sigma}, \emptyset) = f(\mathbf{x}, t) \int_m \lambda^{jxm} c\left(m + \frac{t}{2}\right) c^*\left(m - \frac{t}{2}\right) dm \quad (3-13)$$

从式 (3-13) 可以看出，广义模糊函数亦是一种双线性结构。对于多分量信号，广义模糊函数可以被分解为自项和交叉项如下：

$$A_f(\hat{1}, \hat{\delta}, \phi) = \sum_{i=1}^p A_{c_i c_i}(\mathbf{x}, \mathbf{t}, \mathbf{f}) + \sum_{i \neq j} \sum A_{c_i c_j}(\mathbf{x}, \mathbf{t}, \mathbf{f}) \quad (3-14)$$

这里：

$$A_{c_i c_i}(\mathbf{x}, \mathbf{t}, \mathbf{f}) = \mathbf{f}(\mathbf{x}, \mathbf{t}) \int_m \lambda^{jxm} c_i \left(m + \frac{\mathbf{t}}{2} \right) c_i^* \left(m - \frac{\mathbf{t}}{2} \right) dm \quad (3-15)$$

$$A_{c_i c_j}(\mathbf{x}, \mathbf{t}, \mathbf{f}) = \mathbf{f}(\mathbf{x}, \mathbf{t}) \int_m \lambda^{jxm} c_i \left(m + \frac{\mathbf{t}}{2} \right) c_j^* \left(m - \frac{\mathbf{t}}{2} \right) dm \quad (3-16)$$

比较 (3-12) 式和 (3-14) 是可以看出, $A_{c_i c_i}(\mathbf{x}, \mathbf{t}, \mathbf{f})$ 和 $A_{c_i c_j}(\mathbf{x}, \mathbf{t}, \mathbf{f})$ 分别是 $C_{c_i c_i}(t, \mathbf{w}, \mathbf{f})$ 和 $C_{c_i c_j}(t, \mathbf{w}, \mathbf{f})$ 在 (\mathbf{x}, \mathbf{t}) 域的表示形式, (3-15) 是对应于自项, (3-16) 式对应于互项。文献中指出, 自项 $A_{c_i c_i}(\mathbf{x}, \mathbf{t}, \mathbf{f})$ 的曲线通过 (\mathbf{x}, \mathbf{t}) 平面的原点, 而互项 $A_{c_i c_j}(\mathbf{x}, \mathbf{t}, \mathbf{f})$ 不通过 (\mathbf{x}, \mathbf{t}) 面的原点, 并且保持一定的距离。因此为了抑制交叉项, 在 (\mathbf{x}, \mathbf{t}) 平面上对接近原点的模糊函数应给以较大的加权, 而远离原点的模糊函数施以较小的权。而处于 (\mathbf{x}, \mathbf{t}) 平面上的核函数 处正是广义模糊函数的权函数。Clio-Williams 提出的指数核

$$\mathbf{f}(\mathbf{x}, \mathbf{t}) = \lambda^{-x^2 t^2 / \sigma} \quad (3-17)$$

可以达到有效的抑制交叉项的目的。式中 σ 为常数, σ 越大, 自项的分辨率越高, σ 越小, 对交叉项的抑制作用越大。在实际应用中, 根据信号的特点, σ 的取值应在自项分辨率和交叉项的抑制之间取折中, 若信号的幅度和频率变化快, 应取较大的 σ ($\sigma > 1$), 反之取较小的 σ ($\sigma \leq 1.0$, 一般 σ 在 0.1~10 之间, 当 $\sigma \rightarrow \infty$ 时, $\phi(\hat{1}, \hat{\delta}) \rightarrow 1$, ED 变成 WVD, 这时 ED 有最好的分辨率, 但交叉项变得很大, 实际使用时采用 ED 的离散形式:

$$C_c(n, \mathbf{q}, \mathbf{f}) = \frac{2}{2p} \sum_t \sum_m \int_{x=-p}^p \lambda^{j(xm-2tq-x^2)} \mathbf{f}(\mathbf{x}, \mathbf{t}) \cdot c(m+t) c^*(m-t) dx \quad (3-18)$$

并且为了避免过采样和减小交叉项, 需将 $x(n)$ 作 Hilbert 变换, 求取 $x(n)$ 的解析信号 $z(n)$: $z(n) = x(n) + jx(n)$, 并且对信号 $x(n)$ 进行加窗处理。具体实现步骤如图 3-2 所示。

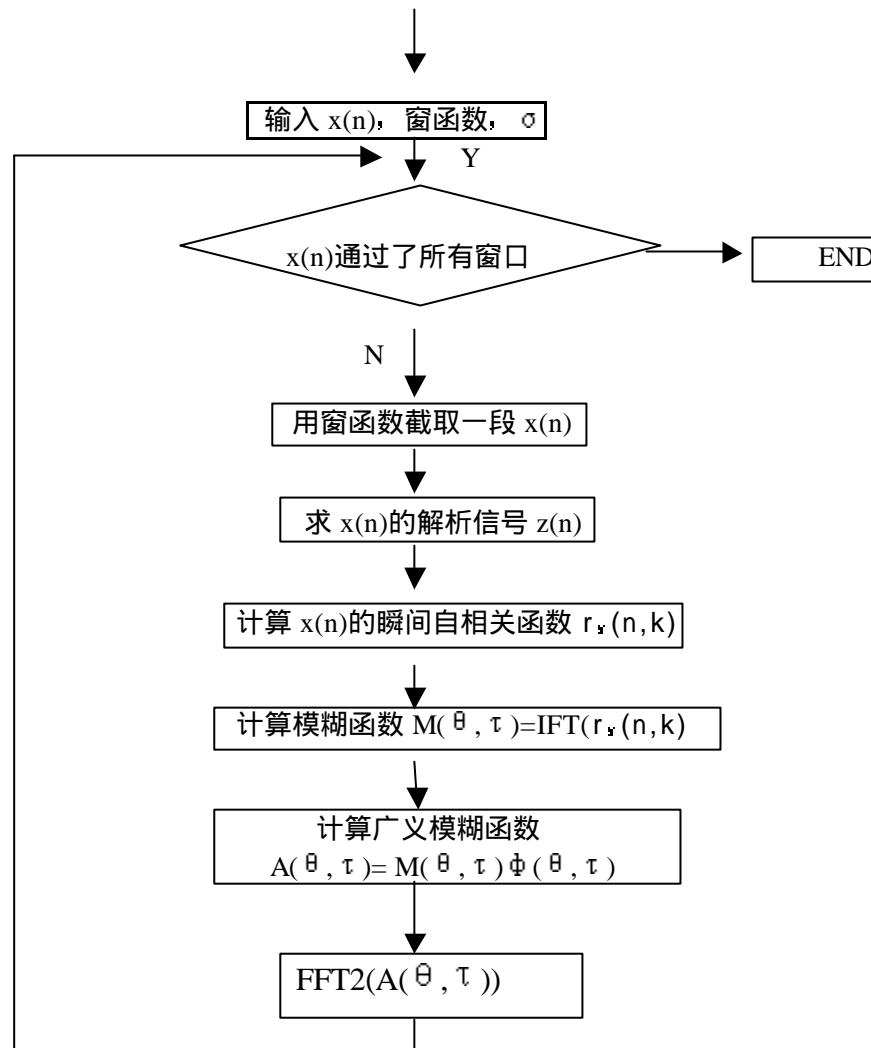


图 3-2 ED 的实现步骤

Fig3-2 Diagram of ED procedure

本节简要介绍了对 AE 信号处理采用的一些方法，在下节中将详细介绍利用这些方法对实验数据处理的结果，并对各种方法的优缺点作分析比较，根据其中对刀具状态分类效果最好的方法，提取反映刀具状态的特征量。

3.3 声发射信号的能量及其频谱分析

前面简要介绍了对 AE 信号处理所采用的一些方法，作者根据第二章介绍的刀具切削试验获得的实验数据，对 AE 信号的能量和频谱进行分析，提取反映刀具状态的特征量。

3.3.1 切削参数与 AE 信号能量的关系

1、切削速度与 AE 信号能量(RMS)的关系

为了考察切削速度与AE信号能量(RMS)的关系,进行了两组实验,用以考察不同进给率下AE 信号的RMS值随切削速度的变化情况。在每组实验中,保持切削深度和进给率不变,只改变切削速度。

各组实验的切削参数为:

第一组: $f=0.1\text{mm/r}$ $a_p=0.1\text{mm}$ $V_B=0.302\text{mm}$

第二组: $f=0.15\text{mm/r}$ $a_p=0.1\text{mm}$ $V_B=0.302\text{mm}$

(1) 线速度 $v = [100\ 125\ 150\ 200\ 250\ 300]$

RMS = [2.94 3.163 2.63 2.866 3.236 2.956]

(2) 线速度 $v = [100\ 125\ 150\ 200\ 250\ 300]$

RMS = [3.181 3.264 3.413 3.486 3.748 4.268]

AE 信号的 RMS 值随切削速度 v 变化的情况如图 3-3 所示。

图3-3显示了45#钢AE信号的RMS 值随切削速度的变化关系。从图中可以看出,两组实验的同一趋势是在切削速度较低,大致在 $50\text{m/min} < v < 150\text{m/min}$ 时,随着 v 的增加AE信号的RMS值曲线较为平坦,增加缓慢,甚至有减小的趋势;而当 $v > 150\text{m/min}$ 时,随切削速度的增加,AE信号的RMS的值呈上升趋势;在进给率较低时,曲线变化相对平缓,而随着进给率的加大,AE信号的RMS值随切削速度的增加而快速增大。对于45#钢,对于较大的进给率,当 $v > 150\text{m/min}$ 时,随着 v 的增加AE信号的RMS的值迅速增加。

上述现象产生的原因是:(1) 由于切削速度增大时,引起切削区的应变率增大,从而引起 AE 信号幅值和能量的增加。对于 45# 钢在 $50\text{m/min} < v < 150\text{m/min}$ AE 能量增幅不明显,在此范围内切削速度较大时甚至出现微小下降趋势的现象,则是由于在此速度范围内易产生积屑瘤,由于积屑瘤的存在增大了刀具前角和后角,使金属应变率降低的缘故。

(2) 较大的进给率对应的 AE 信号有较大的 RMS 值, 这是由于随着进给率的增加, 单位切削用量随之增大, 导致后刀面的摩擦力增加, 从而产生了更大的能量信号。




图 3-3 切削速度----RMS 关系图(45#)

Fig3-3 Relationship between RMS and cutting speed(45#).

2、切削深度与 AE 信号能量(RMS)的关系

为了考察切削深度与AE信号能量(RMS)的关系, 进行了两组实验, 用以考察不同切削速度下AE 信号的RMS值随切削速度的变化情况。在每组实验中, 保持切削速度和进给率不变, 只改变切削深度。

各组实验的切削参数为:

第一组: $f=0.1\text{mm/r}$ $v=200\text{m/min}$ $VB=0.225\text{mm}$

第二组: $f=0.2\text{mm/r}$ $v=300\text{m/min}$ $VB=0.225\text{mm}$

(1) 切削深度 $a_p = [0.1 \ 0.2 \ 0.3]$

$$\text{RMS} = [2.487 \ 3.224 \ 3.391]$$

(2) 线速度 $a_p = [0.1 \ 0.2 \ 0.3]$

$$\text{RMS} = [3.937 \ 5.565 \ 6.785]$$

AE 信号的 RMS 值随切削深度 a_p 变化的情况如图 3-4 所示




图 3-4 切削深度---RMS 关系图(45#)

Fig3-4 Relationship between RMS and cutting depth(45#).

图3-4显示了45#钢AE信号的RMS值随切削速度的变化关系。从图中可以看出，两组实验的同一趋势是随着 a_p 的增加AE信号的RMS值上升趋势；AE信号的RMS值与切削深度基本呈线性变化趋势。当切削速度较大时，RMS幅值随切深增大的速率较大，而在切削速度较小时，增长速率较小。

上述现象产生的原因是：由于切削速度的增加，切削变形区扩大，在变形区中的滑移晶面和裂纹分布情况更加复杂，滑移和裂纹更容易发生堆积后再突然释放，引起声发射能量增加，同时使声发射信号的波峰一波谷值变大。

3、进给率与 AE 信号能量(RMS)的关系

为了考察进给率与AE信号能量(RMS)的关系,进行了两组实验,用以考察不同切削速度下AE信号的RMS值随进给率的变化情况。在每组实验中,保持切削速度和切削深度不变,只改变进给率。

AE信号的RMS值随进给率 f 变化的情况如图3-5 所示

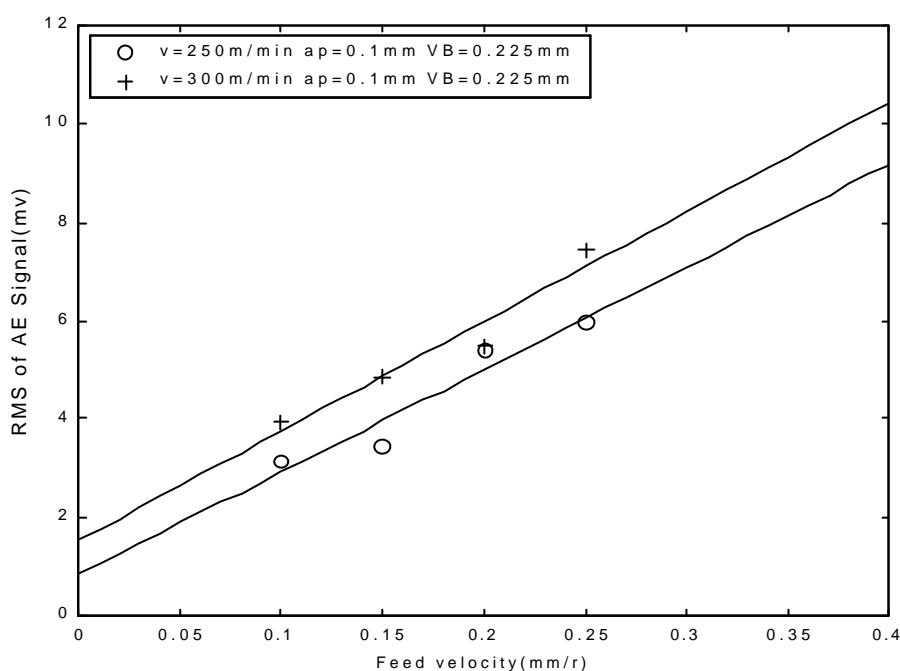


图3-5 进给量-RMS关系图(45#)

Fig3-5 Relationship between RMS and feed velocity(45#).

图3-5显示了45号钢AE信号的RMS值随进给率的变化关系。从图中可以看出,两组实验的曲线图几乎平行,AE信号的RMS值都是随着 f 的增加而增加;AE信号的RMS值与切削深度基本呈线性变化趋势。

4、后刀面磨损量与 AE 信号能量(RMS)的关系

为了考察后刀面磨损量与AE信号能量(RMS)的关系,进行了一组实验,用以考察不同切削速度下AE信号的RMS值随进给率的变化情况。实验中,保持切削速度、切削深度和进给率不变,使用不同VB值的刀具进行切削实验。

AE信号RMS值后刀面磨损量VB变化的情况如图3-6所示




图3-6 VB-RMS关系图(45#)

Fig3-6 Relationship between RMS and flank wear(45#).

图3-6显示了45号钢AE信号的RMS值随刀具后刀面磨损量的变化关系。可以看出，在 $VB < 0.1\text{mm}$ 时，随着后刀面的不断磨损，AE信号的RMS的值也逐渐减小；而在 $VB > 0.1\text{mm}$ 时，随着VB的增加，RMS的值也逐渐增加；当 $VB > 0.3\text{mm}$ 时，RMS值增加速度明显加快。

上述现象产生的原因是：使用新刀进行切削时，刀具处于磨损的第一阶段：初期磨损阶段，这一阶段刀具磨损较快，切削刃由于刃磨及前刀面的凹凸不平原因，使切屑流经前刀面时阻力较大，引起声发射信号能量较大。当VB逐渐增大，超过 0.1mm 时，刀具进入磨损的第二阶段：正常磨损阶段，此时刀具后刀面磨损宽度逐渐增加，使切削区金属受挤压的程度增大，切削区变形程

度增大，同时后刀面与第三变形区的摩擦增大，使AE信号能量增大。而随着刀具后刀面磨损量的进一步增大，刀具进入了磨损的第三阶段：急剧磨损阶段，此时切削区变形程度加剧，切削状况恶化，导致AE信号迅速增大。

3.3.2 切削参数与 AE 功率谱密度的关系

1、切削速度与 AE 信号功率谱的关系

为了考察不同切削速度与 AE 信号功率谱的关系，选取实验的切削参数为： $f=0.1\text{mm/r}$ $a_p=0.1\text{mm}$ $VB=0.302\text{mm}$

线速度 $v = [100\ 125\ 150\ 200\ 250\ 300]$

AE信号的功率谱值随切削速度 v 变化的情况如图3-7所示




图3-7 切削速度对功率谱密度的影响

Fig3-7 The influence of cutting speed on spectrum

从图3-7中可以看出，正常切削时45#钢发出的AE信号频率主要分布在10KHz处。在线速度处于125m/min~200m/min的范围内，功率谱变化不明显，随着线速度的继续增加，功率谱密度有了较大的增长。

2、切削深度与 AE 信号功率谱的关系

为了考察切削深度与AE信号能量(RMS)的关系,在切削实验中,保持切削速度和进给率不变,只改变切削深度。

实验的切削参数为: $f=0.1\text{mm/r}$ $v=200\text{m/min}$ $VB=0.225\text{mm}$

切削深度 $a_p = [0.1\ 0.15\ 0.2\ 0.25\ 0.3\ 0.35]$ (mm)

AE 信号的功率谱密度随切削深度变化情况如图 3-8 所示。




图3-8切削深度对功率谱密度的影响

Fig3-8 The influence of cutting depth on spectrum.

从图3-8中可以看出,当切削深度增大时,AE信号在10Khz的功率谱密度随之增大,但在其它处的能量基本保持不变。这说明切深与AE能量有较好的相关性,在以后的研究中值得注意。

3、进给率与 AE 信号功率谱的关系

为了考察进给率与AE信号功率谱的关系,在切削实验中,保持切削速度和切削深度不变,只改变进给率。

实验的切削参数为： $a_p=0.1\text{mm}$ $v=250\text{m/min}$ $VB=0.225\text{mm}$

进给率 $f = [0.1 \ 0.15 \ 0.2 \ 0.25 \ 0.3 \ 0.35]$ (mm/r)

AE信号的功率谱随进给率 f 变化的情况如图3-9所示




图3-9进给率对功率谱密度的影响

Fig3-9 The influence of feed velocity on spectrum.

从图3-9中可以看出，当切削进给率增大时，AE信号在10Khz的功率谱密度随之增大，其增长幅度近似线性，而在其它频率处的能量基本保持不变。这说明研究的范围内的切削进给率与AE能量在有良好的线性相关性。

4、后刀面磨损量与 AE 信号功率谱的关系

为了考察后刀面磨损量与AE信号功率谱的关系，在相应的切削实验中，保持切削速度、切削深度和进给率不变，使用不同VB值的刀具进行切削实验。

切削实验参数如下： $a_p=0.15\text{mm}$ $v=250\text{m/min}$ $f=0.15\text{mm/r}$

进给率 $VB = [0 \ 0.07 \ 0.145 \ 0.16 \ 0.225 \ 0.302 \ 0.425]$ (mm)

AE信号RMS值后刀面磨损量VB变化的情况如图3-10所示。




图3-10后刀面磨损对功率谱密度的影响

Fig3-10 The influence of flank wear on spectrum .

从图 3-10 中可以看出后刀面磨损量变化对功率谱的影响，在 VB 值从零（即新刀）增大到 0.145mm 阶段，AE 信号的功率谱在 10KHz 的能量随 VB 的增大而增大。但是在 VB 值从 0.145mm 到 0.302mm 这一阶段，AE 信号的功率谱在 10KHz 的能量变化不明显，趋于平缓，其原因是刀具进入了磨损的第二阶段：正常磨损阶段，产生的 AE 信号趋于稳定，变化不再剧烈。从以上的分析可以看出，刀具后刀面磨损引起 AE 信号能量在 10KHz 处的能量增加趋势与刀具磨损的过程有一定的相似性。因此理论上将可以用 10KHz 频率处的能量作为特征

值对刀具后刀面的磨损进行监测，但是由于它们受到切削用量的影响。再加上刀具破损、断屑和偶然因素引起的随机信号，使得各种信号相互叠加，难于对这些信号进行完全的分析，无法准确的分析出各因素对 AE 信号的影响。因此，采用功率谱密度分析 AE 信号的特征也不是完美的。这样采用其它的分析方法是必要的。

3.4 小结

本章首先具体介绍了声发射信号的产生机理及检测原理。然后介绍了 AE 信号的各种处理方法，最后应用 AE 信号能量和功率谱分析法对实验数据进行了处理并提取出了刀具磨损和破损的特征量，具体体现在以下几点：

- 1.通过对各种切削条件下 AE 信号能量分析发现，AE 信号的能量随着刀具后刀面磨损量的增加而增加，同时也随着切削用量的增加而增加，当刀具发生破损时，AE 信号的能量也会大幅度增加。但是切削过程中随时产生的断屑信号和随机因素引起的 AE 信号也会引起 AE 信号的能量大幅度增加。因此，用 AE 信号能量可以监测刀具的状态。

- 2.通过对 AE 信号的功率谱分析，发现刀具后刀面磨损会引起 AE 信号在 10kHz 处的能量密度增加，但是由于切削过程十分复杂，各种信号相叠加在一起，因此，用 10kHz 频段处能量来检测刀具的磨损不十分可靠。

第四章 基于 BP 人工神经网络的在线识别

在声发射检测中，现场获取的声发射信号几乎都不是单一机制产生的，往往是由许多类型的声发射信号组成的，因此一直以来，声发射信号模式识别的研究是声发射检测技术中的重点之一。目前主要用于声发射信号模式识别的方法有幅值鉴别、频率鉴别、统计模式识别和人工神经网络。由于人工神经网络具有良好的自学习能力，具有良好的学习外推性，是声发射信号模式识别的有效方法。以下作者将运用 BP 人工神经网络在线识别刀具状态的声发射信号。

4.1 神经网络

对声发射信号分析处理的最终目的是实现对声发射源的识别，即实现声发射信号的模式识别。人工神经网络是目前实现模式识别的主要方法，因此也成为声发射信号处理方法研究的主要内容之一。

人工神经网络是在现代神经科学研究成果的基础上提出的，并反过来用于工程或其它领域。其着眼点是采用生物体神经细胞网络中可利用的部分来克服目前计算机或其它系统不能解决的问题，如学习、识别专家系统等。它是由大量而简单的处理单元(神经元)广泛地相连接而形成的非线性复杂网络系统，具有非线性函数逼近的能力，有很强的容错能力和学习能力。神经网络的主要特点是：①高度并行性；其并行性不仅体现在网络的结构上，它的处理运行过程也是并行的和同时的。②高度的非线性全局作用；神经网络通过各个神经元互相制约互相影响，从而实现从输入状态空间到输出状态空间，其中前馈型网络由输入层、中间层(隐层)、输出层组成。隐层可有若干层，每一层的神经元只接受前一层神经元的输出，这样就实现了从输入层结点的状态空间到输出层状态空间的非线性映射。网络中的连接权和连接结构都可以通过学习而得到。神经网络所记忆的信息存储在神经元之间的连接权中，从单个权中看不出其存储

信息的内容，因而是分布式存储方式。③良好的容错性与联想记忆功能，人工神经网络通过自身的网络结构能够实现对住处的记忆，所记忆的信息是存储在神经之间的权值中，从单个权值中看不出所储存的住处内容，因而是分布式的存储方式，这使得网络具有良好的容错性，并能进行聚类分析，特征提取，缺损模式复原等模式信息处理工作；又宜于做模式分类，模式模拟等模式识别了解。④十分强的自适应，自学习功能。人工神经网络可以通过训练和学习来获得网络的权值和结构，呈现出很强的自学习能力和对环境的自适应能力。

BP 网络的模式识别原理是通过网络自身的学习来实现输入 维学习样本向量 X 和输出 N 综合分类向量 Y 的高度非线性映射，映射关系表示为：

$$y = f_2(\mathbf{w}_{nm} \mathbf{c} f_1(\mathbf{w}_{ml} \mathbf{c} \mathbf{c})) \quad (4-1)$$

上式中， \mathbf{w}_{ml} 为输入和隐层之间的连接权值矩阵， \mathbf{w}_{nm} 为隐层和输出层之间的连接权值矩阵， f_1 为神经网络的转换函数一般采用非线性激活函数不清即 sigmoid 函数：

$$f(c) = \frac{1}{1 + \lambda^{-c}} \quad (4-2)$$

4.2 BP 神经网络结构

众多神经网络模型中，误差反向传播网络(Back Propagation)是目前应用最为广泛的网络模型，通常由输入层、输出层和隐含层构成，层与层之间的神经采用全互连的连接方式，通过相应的网络权系数 W 相互联系，每层内的神经元之间没有连接。如图 4-1 所示。

BP 网络在应用于预测预报之前，需要一个网络学习过程。网络根据输入的训练（学习）样本进行自适应、自组织，确定各神经元的连接权 W 和阈值。经过多次训练后，网络具有了对学习样本的记忆和联想的能力。网络学习过程包括信息正向传播和误差反向传播两个反复交替的过程。




图 4-1 典型 BP 网络结构示意图

Fig4-1 The structure of BP neural network

图 4-1 中有 N 个输入节点和 L 个输出节点，它们的非线性激活函数即 Sigmoid 函数。

多层计算单元的输出按式(4-4)、(4-5)计算：

$$Y_j = f\left(\sum_{i=0}^{N-1} W_{ij} X_i - \theta_j\right) \quad j = 0, 1, \dots, M-1. \quad (4-3)$$

$$Z_k = f\left(\sum_{j=0}^{M-1} W_{jk} Y_j - \theta_k\right) \quad k = 0, 1, \dots, L-1 \quad (4-4)$$

式中 X_i ——输入层第 i 个节点的输出值

Y_j ——中间层（隐层）第 j 个节点的输出值

W_{ij} ——输入层第 i 个节点到中间层第 j 个节点的权系数

W_{jk} ——隐蔽层第 j 个节点到输出层第 k 个节点的权系数

θ_j ——中间层第 j 个节点的内部阈值

θ_k ——输出层第 k 个节点的内部阈值

Z_k ——输出层中第 k 个节点的实际输出值

BP 神经网络的自学习过程是一个反复迭代的过程，首先给网络一组初始权值，然后输入一个样本并计算其输出，通过实际的输出与期望值之间的差值用一定的方法来修改网络的权值，以达到减小这个差值的目的。反复执行这个过程直到这个差值小于预先确定的值为止。对足够的样本进行这样的训练后，网络所得的那组权值便是网络经过自适应学习得到的正确的内部关系。

自学习过程的具体算法如下：

(1) 给网络赋一组小的随机初始权值，其值在 0 到 1 之间，并使其互不相等。

(2) 将输入数据规一化，使其在 0 到 1 之间，并确定期望输出信号 (d_0, d_1, \dots, d_{L-1})。

(3) 逐层计算神经网络的实际输出

$$f\left(\sum_{i=0}^N W_{ij} X_i\right) \rightarrow Y_j \quad j=0, \dots, M-1$$

$$f\left(\sum_{i=0}^N W_{jk} Y_j\right) \rightarrow Z_k \quad j=0, \dots, L-1 \quad (4-5)$$

(4) 从输出层开始，反向调整权值，其调整公式如下：

$$\mathbf{d}_j = Y_j(1 - Y_j) \cdot \sum_{k=0}^{L-1} \mathbf{d}_k \cdot W_{jk} \quad (4-6)$$

$$W_{jk} + \eta \delta_k Y_j \rightarrow W_{jk}$$

$$W_{ij} + \eta \delta_j X_i \rightarrow W_{ij}$$

式中 $\delta_k = (d_k - Z_k) Z_k (1 - Z_k)$

(5) 计算总的误差 E，若 $E \leq \varepsilon$ ，学习停止，否则转到(3)重新计算。

在实际编程序时，如果步长 η 较小则学习速度较慢，而若 η 过大则会引起网络出现摆动。为解这一问题，可在式(4)中加入一个动量 α ($0 < \alpha < 1$)，

即 $W_{jk} + \eta \delta_k Y_j + \alpha \cdot \Delta W_{jk} \rightarrow W_{jk}$

$W_{ij} + \eta \delta_j X_i + \alpha \cdot \Delta W_{ij} \rightarrow W_{ij}$

式中 ΔW_{jk} ——连续两次 W_{jk} 之差

ΔW_{ij} ——连续两次 W_{ij} 之差

4.3 实验数据归一化

神经网络本质上是一个连续分布式数值计算过程。对于信息融合目标识别系统来说，它较适合于特征层融合处理。因为多源特征所构成的特征空间一般说来是高维的，常规的特征分类识别技术往往难以进行有效的整和处理，而神经网络对于解决这类问题具有巨大的潜力。因而，可以利用神经网络尝试创建一个合适的回归模型。

在各种神经网络系统中，由于BP网络实质上实现了一个从输入到输出的映射功能，而数学理论已证明它具有实现任何复杂非线性映射的功能，特别适合于求解内部机制复杂的问题。同时BP网络能通过学习带正确答案的实例集自动提取“合理的”求解规则，即具有自学习能力，具有一定的推广、概括能力。本文因而选择BP网络作为研究声发射与刀具后刀面磨损关系的一个算法平台。

根据Kolmogorov定理，3层结构的前向网络可以逼近任意连续函数，因此可以用它来估计刀具的磨损，网络的结构如图所示，神经元的激励函数为Sigmoid函数。由于各个特征量的物理量不尽相同，量纲不同，又因特征量与刀具的磨损量之间的关系有正相关与负相关之分，所有的特征参数都应该归一化。

归一化的方法如下：

$$x' = x1 + (x2 - x1) \times \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \quad (4-8)$$

式中 x 为正规化前的特征参数, x_1, x_2 分别为归一化的下限与上限, $x_{\max} = \max(x), x_{\min} = \min(x)$, x' 为正规化后的特征参数。此处的 x_1 与 x_2 分别取 0 和 1, 经过这样的标准化处理以后, 特征参数都被压缩到 $[0, 1]$ 之间。

表4-1 特征参数归一化表

样 本 号	ap	f	v	RMS	VB	apl	fl	vl	RMS1	VB1
1	0.1	0.1	250	3.0586	0.125	0	0	0.5	0.134305	0
2	0.1	0.15	250	3.0762	0.125	0	0.333333	0.5	0.13844	0
3	0.1	0.2	250	3.0627	0.125	0	0.666667	0.5	0.135268	0
4	0.1	0.25	250	2.9184	0.125	0	1	0.5	0.101363	0
5	0.2	0.1	250	2.6807	0.128	0.5	0	0.5	0.045512	0.009231
6	0.2	0.15	250	3.064	0.128	0.5	0.333333	0.5	0.135573	0.009231
7	0.2	0.2	250	3.0927	0.129	0.5	0.666667	0.5	0.142317	0.012308
8	0.2	0.25	250	4.0464	0.13	0.5	1	0.5	0.3664	0.015385
9	0.3	0.1	250	2.7887	0.13	1	0	0.5	0.070888	0.015385
10	0.3	0.15	250	3.0204	0.131	1	0.333333	0.5	0.125329	0.018462
11	0.3	0.2	250	2.8332	0.132	1	0.666667	0.5	0.081344	0.021538
12	0.3	0.25	250	2.8517	0.132	1	1	0.5	0.085691	0.021538
13	0.1	0.1	300	3.1364	0.145	0	0	1	0.152585	0.061538
14	0.1	0.15	300	3.0323	0.145	0	0.333333	1	0.128125	0.061538
15	0.1	0.2	300	3.185	0.146	0	0.666667	1	0.164004	0.064615
16	0.1	0.25	300	3.4903	0.146	0	1	1	0.235738	0.064615
17	0.2	0.1	300	2.8314	0.149	0.5	0	1	0.080921	0.073846
18	0.2	0.15	300	2.6363	0.15	0.5	0.333333	1	0.03508	0.076923
19	0.2	0.2	300	2.8048	0.152	0.5	0.666667	1	0.074671	0.083077
20	0.2	0.25	300	3.6682	0.152	0.5	1	1	0.277538	0.083077
21	0.3	0.15	300	3.0292	0.152	1	0.333333	1	0.127397	0.083077
22	0.3	0.25	300	3.3823	0.152	1	1	1	0.210362	0.083077
23	0.3	0.1	300	2.8489	0.155	1	0	1	0.085033	0.092308
24	0.1	0.1	200	2.487	0.225	0	0	0	0	0.307692
25	0.1	0.1	250	3.134	0.225	0	0	0.5	0.152021	0.307692
26	0.1	0.1	300	3.937	0.226	0	0	1	0.340695	0.310769
27	0.1	0.15	200	3.049	0.226	0	0.333333	0	0.132049	0.310769
28	0.1	0.15	250	3.465	0.226	0	0.333333	0.5	0.229793	0.310769
29	0.1	0.15	300	4.863	0.228	0	0.333333	1	0.558271	0.316923
30	0.1	0.2	200	2.646	0.228	0	0.666667	0	0.037359	0.316923
31	0.1	0.2	250	5.398	0.229	0	0.666667	0.5	0.683976	0.32
32	0.1	0.2	300	5.483	0.23	0	0.666667	1	0.703947	0.323077
33	0.1	0.25	200	4.437	0.232	0	1	0	0.458177	0.329231
34	0.1	0.25	250	5.954	0.232	0	1	0.5	0.814615	0.329231
35	0.1	0.25	300	6.577	0.233	0	1	1	0.960996	0.332308
36	0.2	0.1	200	3.224	0.235	0.5	0	0	0.173167	0.338462
37	0.2	0.1	250	3.361	0.237	0.5	0	0.5	0.205357	0.344615
38	0.2	0.1	300	5.565	0.237	0.5	0	1	0.723214	0.344615

续表4-1

样 本 号	ap	f	v	RMS	VB	apl	fl	v1	RMS1	VB1
39	0.2	0.15	200	4.167	0.237	0.5	0.333333	0	0.394737	0.344615
40	0.2	0.15	250	4.352	0.237	0.5	0.333333	0.5	0.438205	0.344615
41	0.2	0.15	300	5.257	0.237	0.5	0.333333	1	0.650846	0.344615
42	0.2	0.2	200	5.452	0.237	0.5	0.666667	0	0.696664	0.344615
43	0.2	0.2	250	6.061	0.238	0.5	0.666667	0.5	0.839756	0.347692
44	0.2	0.2	300	6.743	0.238	0.5	0.666667	1	1	0.347692
45	0.2	0.25	200	4.243	0.238	0.5	1	0	0.412594	0.347692
46	0.2	0.25	250	5.285	0.238	0.5	1	0.5	0.657425	0.347692
47	0.2	0.25	300	6.204	0.24	0.5	1	1	0.873355	0.353846
48	0.3	0.1	200	3.391	0.24	1	0	0	0.212406	0.353846
49	0.3	0.1	300	3.785	0.24	1	0	1	0.304981	0.353846
50	0.3	0.15	250	3.615	0.241	1	0.333333	0.5	0.265038	0.356923
51	0.3	0.2	200	4.218	0.241	1	0.666667	0	0.40672	0.356923
52	0.3	0.2	300	4.102	0.241	1	0.666667	1	0.379464	0.356923
53	0.3	0.25	250	6.106	0.241	1	1	0.5	0.850329	0.356923
54	0.1	0.1	200	2.861	0.302	0	0	0	0.087876	0.544615
55	0.1	0.1	250	3.236	0.302	0	0	0.5	0.175987	0.544615
56	0.1	0.1	300	3.956	0.302	0	0	1	0.34516	0.544615
57	0.1	0.15	200	3.486	0.302	0	0.333333	0	0.234727	0.544615
58	0.1	0.15	250	3.748	0.304	0	0.333333	0.5	0.296288	0.550769
59	0.1	0.15	300	4.298	0.304	0	0.333333	1	0.425517	0.550769
60	0.1	0.2	200	2.688	0.304	0	0.666667	0	0.047227	0.550769
61	0.1	0.2	250	3.698	0.305	0	0.666667	0.5	0.284539	0.553846
62	0.1	0.2	300	4.485	0.305	0	0.666667	1	0.469455	0.553846
63	0.2	0.1	200	3.327	0.306	0.5	0	0	0.197368	0.556923
64	0.2	0.1	250	2.73	0.306	0.5	0	0.5	0.057096	0.556923
65	0.2	0.1	300	3.839	0.307	0.5	0	1	0.317669	0.56
66	0.2	0.15	200	3.84	0.307	0.5	0.333333	0	0.317904	0.56
67	0.2	0.15	250	3.793	0.307	0.5	0.333333	0.5	0.306861	0.56
68	0.2	0.15	300	4.185	0.307	0.5	0.333333	1	0.398966	0.56
69	0.2	0.2	200	3.374	0.307	0.5	0.666667	0	0.208412	0.56
70	0.2	0.2	250	3.177	0.31	0.5	0.666667	0.5	0.162124	0.569231
71	0.2	0.2	300	4.312	0.311	0.5	0.666667	1	0.428806	0.572308
72	0.3	0.1	300	4.238	0.312	1	0	1	0.411419	0.575385
73	0.3	0.15	250	6.589	0.318	1	0.333333	0.5	0.963816	0.593846
74	0.3	0.2	200	4.644	0.32	1	0.666667	0	0.506814	0.6
75	0.1	0.1	200	5.196	0.425	0	0	0	0.636513	0.923077

续表4-1

样 本 号	a_p	f	v	RMS	VB	a_{p1}	$f1$	$v1$	RMS1	VB1
76	0.1	0.1	250	4.901	0.429	0	0	0.5	0.567199	0.935385
77	0.1	0.1	300	5.342	0.431	0	0	1	0.670818	0.941538
78	0.1	0.15	200	4.525	0.438	0	0.333333	0	0.478853	0.963077
79	0.1	0.1	250	4.914	0.441	0	0	0.5	0.570254	0.972308
80	0.1	0.1	300	4.972	0.445	0	0	1	0.583882	0.984615
81	0.1	0.2	300	5.861	0.445	0	0.666667	1	0.792763	0.984615
82	0.1	0.2	250	5.237	0.446	0	0.666667	0.5	0.646147	0.987692
83	0.1	0.2	200	4.699	0.45	0	0.666667	0	0.519737	1

表4-1中, a_p , f , v 分别对应切削参数中切削深度 (单位: mm), 进给率 (单位: mm/r), 切削速度 (单位: m/min), RMS为AE信号均方根电压值 (单位: mv), VB为刀具后刀面平均磨损量 (单位: mm)。 a_{p1} , $f1$, $v1$, RMS1, VB1 分别为 a_p , f , v , RMS, VB归一化的结果。

4.4 BP神经网络的训练和验证

神经网络的结构对神经网络的训练非常重要, 结构复杂, 训练时间增加; 结构简单不易收敛。输入节点数的选择与特征参数选取有关, 本实验从采集的声发射信号和实验所采用的切削参数中选取了4个特征量作为输入层参数。网络的输出层参数为刀具的后刀面磨损, 因此网络的输入节点取4, 用1个输出节点的值来表示刀具的磨损状态。这样网络的输入节点数和输出节点数就确定了。隐层节点数确定的原则是使网络的结构尽可能简单, 同时保证一定的精度, 通过测试选择为15。故BP网络如图4-2所示

在表4-1中共列出了83个实验样本, 选择其中的奇数部分作为神经网络的训练样本, 偶数部分用于对BP神经网络的验证。

对神经网络进行训练, 选择适当的初始权值和偏差, 学习率为0.1, 网络的误差平方和小于0.000001。




图4-2 BP网络图

Fig4-2 The diagram of BP network

图4-3表明经过169个单位时间的学习，达到了0.000001的误差范围，结果收敛。

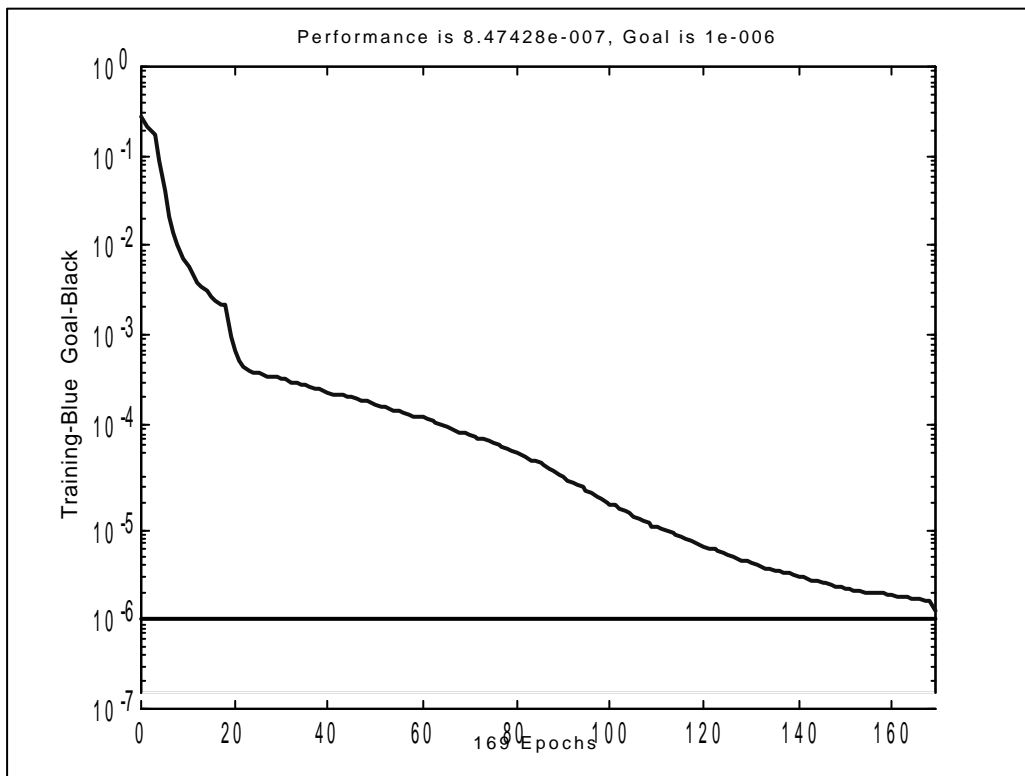


图4-3 BP神经网络训练误差逼近曲线图

Fig 4-3 Curve of error in training BP network

接着做出训练集合、测试集合和确证集合的误差分布图4-4。




图4-4 误差分布图

Fig 4-4 curve of error

由图4-4中可以看出，测试集合和确证集合的误差有着的相似性质，说明此BP网络有着较好的预测性。

下面对此BP网络的响应进行一些分析，将所有的数据（包括训练集合、测试集合和确证集合）通过网络，然后对网络输出和相应的目标进行线性回归。结果如图4-5所示。

可以看出，此BP网络对目标的跟踪的还可以（ $R = 0.811$ ），因为毕竟刀具的切削影响因素非常的复杂，但是仍然有相当大的误差存在。这主要有以下几个原因：

1、从数学角度看，BP算法为一种局部搜索的优化方法，但它要解决的问题为

求解复杂非线性函数的全局极值，因此，算法很有可能陷入局部极值，使训练失败。




图4-5 网络线性回归图

Fig4-5 The diagram of linear regression

- 2、以解决应用问题的实例规模和网络规模间的矛盾。这涉及到网络容量的可能性与可行性的关系问题，即学习复杂性问题。
- 3、络结构的选择尚无一种统一而完整的理论指导，一般只能由经验选定。为此，有人称神经网络的结构选择为一种艺术。而网络的结构直接影响网络的逼近能力及推广性质。因此，应用中如何选择合适的网络结构是一个重要的问题；
- 4、BP网络的预测能力（也称泛化能力、推广能力）与训练能力（也称逼近能

力、学习能力)的矛盾。一般情况下,训练能力差时,预测能力也差,并且一定程度上,随训练能力地提高,预测能力也提高。但这种趋势有一个极限,当达到此极限时,随训练能力的提高,预测能力反而下降,即出现所谓“过拟合”现象。此时,网络学习了过多的样本细节,而不能反映样本内含的规律。

- 5、实验中样本数量稍有不足,对于BP网络等人工神经网络而言,一般都需要大量的训练样本,而本次实验由于条件限制,错过了部分切削条件下的实验。因而一定程度上影响了BP网络的预测精度。

但从总体上看,使用BP人工神经网络建立的刀具磨损与AE信号之间的模型在一定程度上还是有效可行的,值得对其做进一步的研究。

4.5 本章小结

本章在第三章提取的刀具磨损和破损特征量的基础上,利用BP人工神经网络实现了刀具磨损和破损状态的识别。其中BP网络对目标的跟踪达到了81.1%,说明BP人工神经网络有较好的预测性。

第五章 总结和展望

本文讨论了刀具状态监控技术的现状和发展方向。在此基础上对刀具状态的声发射信号监控系统进行了深入的研究。在信号获取方面,针对声发射法具有灵敏度高、时效性好、易于实现刀具状态监控的特点,获取刀具状态的 AE 信号。为了提取反映刀具磨损、破损的特征量,作者建立了刀具磨破损实验系统,在此基础上进行了大量的切削试验,获取了大量的实验数据,并采用了各种 AE 信号处理方法,从声发射信号中提取出对刀具状态敏感的特征量。作者尝试采用 BP 神经网络实现刀具磨损状态的监控,并取得了很好的效果。本文的主要工作和创新如下:

1. 仔细研究了 BP 神经网络的基本原理和学习算法。深入的分析了 BP 神经网络在声发射模式识别应用中收敛慢的现象,对初始值进行了合理选择,对 BP 神经网络进行了训练学习,使网络跟踪的目标值达到 0.811。

2. 设计和建立了刀具状态声发射试验系统,该系统采用先进的声发射信号采集仪器、声发射传感器,在此基础上,进行了刀具磨损和破损试验,采集了大量的刀具正常磨损和破损时的声发射信号。

3. 通过对各种切削条件下声发射信号能量的分析发现,声发射信号的能量随着刀具后刀面磨损量的增加而增加,也随着切削用量的增加而增加。当刀具发生破损时,声发射信号的能量也会大幅度增加。但是切削过程中随机因素(如断屑信号)引起的 AE 信号能量值变化,直接影响 AE 信号的能量作为特征量来监测刀具状态的精度,这在以后的工作中进一步研究。

4. 在调整网络参数和网络训练的基础上,利用 BP 神经网络模型实现了刀具磨损破损状态的识别。

由于切削工况极为复杂,使得刀具在线监控技术离实际运用阶段还有很大

距离，包括声发射监控技术在内，运用于社会工况实际的仪器仍很小。尽管如此，由于刀具在线监控技术的运用前景十分广阔，其实际利用价值很大，具有很高的经济价值，使得我们研究这一技术十分必要。

尽管文中通过对实验数据的处理得到了 VB 和 AE 信号，切削用量与 AE 信号的关系，找到了 AE 信号的特征量，并利用 BP 人工神经网络进行了刀具磨损和破损的在线识别，但是实验过程由于受时间、空间和设备状态的影响，实验数据总量略显不足，同时由于自身对信号处理方面理论知识的欠缺，论文中仍有许多不如人意之处。总之，结合生产实际，此次论文中研究的内容对于自身的知识结构，工作方式都有长远的意义。通过加强在线信号采集，信号处理及特征提取，刀具状态识别模型智能化这三个方面的研究学习，刀具状态的在线监控技术一定会越来越成熟。

参考文献

- [1] 周泽华, 金属切削理论, 机械工业出版社, 1992年5月
- [2] H. K. Tonshoff and J. P. Wulfsberg, Developments and trends in monitoring and control of machining process, *Ann.CIRP*, Vol.37, No.2, 1998, pp611-622
- [3] Li Dan and J. Mathew, Tool condition monitoring techniques for turning ----A review, *Int. J. Mathew, Tool Manufact.* Vol.30, No.4, 1990, pp579-598
- [4] G. Byrne and D. Dornfeld, Tool condition monitoring(TCM)----the status of research and industrial application, *Ann.CIRP*, Vol.30, No.2, 1995, pp541-567
- [5] 胥光申, 卢秉恒, 刀具磨破损时监测系统的开发与研究, *西安交通大学学报*, Vol.26, No.5, 1992, pp59-74
- [6] S. C. Lin and R. J. Yang, Force-based model for tool wear monitoring in face milling, *Int. J. Mach. Tool Manufact*, Vol.35, No.9, 1995, pp1201-1211
- [7] W. L. jin and P. K. Venuvinod, An optical fiber sensor based cutting force measuring device, *Int. J. Mach. Tool Manufact*, Vol.35, No.6, 1995, pp877-883
- [8] Zhang Deyuan and Han Yuntai, On-line detection of tool breakage using telemetering of cutting forces in milling, *Int. J. Mach. Tool Manufact*, Vol.35, No.1, 1995, pp19-27
- [9] S. H. Yeo and S. W. Lye, A tool condition monitoring system in a CIM work cell. *Computers in Industry*, Vol.25, 1994, pp77-82
- [10] K. Jemielniak, Detection of cutting edge breakage in turning, *Ann. CIRP*, Vol. 41, No.1, 1992, pp97-100
- [11] A. Novak and H. Wiklund, On-line prediction of the tool life, *Ann. CIRP*, Vol.45, No.1, 1996, pp93-96
- [12] M. Rahman and Q. Zhou, On-line cutting state recognition in turning using a neural network, *Int. J. Adv. Manu fact. Tech*, Vol.10, 1995, pp87-92
- [13] T. J. Ko and D. W. Cho, On-line monitoring of tool breakage in face milling

- using a self organized neural networks , *Int. J. Mach. Tool Manu fact*, Vol. 35, No.8, 1995, pp1137-1147
- [14] I.N.Tansel and C. Mekdeci, Detection of tool failure in end milling with wavelet transformations and neural networks, *Int. J. Mach. Tool Manu fact*, Vol.35, No.8, 1995, pp1137-1147
- [15] T. J. Ko and D. W. Cho, Tool wear monitoring drill condition with wavelet based encoding and neural networks, *Int. J. Mach. Tool Manu fact*, Vol.33, No.4, 1993, pp559-575
- [16] T. J. Ko and D. W. Cho, Fuzzy pattern recognition for tool wear monitoring on diamond turning, *Ann. CIRP*, Vol.41, No.1, 1992, pp125-128
- [17] T. J. Ko and D. W. Cho, Tool wear monitoring in diamond turning by fuzzy pattern recognition *J. Eng. for Ind.*, Vol. 116, May, 1994, pp225-232
- [18] M. P. Groover, R. J. Karpovich, A study of the relationship between remote thermocouple temperatures and tool wear in machining . *Int. J. Prod.Res.*, Vol.25, 1977, pp129-141
- [19] D. Spurgeon and R. A. C. Slater ,In-process indication of surface roughness using a fibre-optics transducer , *Proc. 15 th Int. Machine Tool Design and Research Conf.*, 1974, pp339-347
- [20] A. B. Sadat and S. Raman, Detection of tool flank wear using acoustic signature analysis , *Wear*, Vol.26, 1987, pp265-272
- [21] 邵华 铣削功率监控研究与刀具监控系统的研制 上海交通大学博士论文 1994
- [22] 王海丽 刀具状态多传感器监控策略的研究 上海交通大学博士论文 1999
- [23] T. Moriwaki and I. Inasaki and M. Yobito, A new approach to automatic detection of life of coated tool based on acoustic emission measurement, *Trans. ASME, J. Eng. Ind.*, Vol.112, Aug., 1990, pp212-218
- [24] E. K. Asibu, and D. A. Dornfeld, Qualitative relationship for acoustic

- emission from orthogonal metal cutting , Trans. ASME, J. Eng. Ind. , Vol. 103,1981,pp330-340
- [25] R.Teti and D. Dornfeld , Modeling and experimental analysis of acoustic emission from metal cutting ,J.Eng.Ind.,Vol.111,Aug.,1989,pp229-237
- [26] R.Trti, Tool wear monitoring through acoustic emission, Ann.CIRP,Vol.38,No.1,1989,pp198-205
- [27] E. Emel and E. K. Asibu,Jr,Tool failure monitoring in turning by pattern recognition analysis of AE signals, Trans. ASME, J.Eng . Ind., Vol.110,May,1988,pp137-145
- [28] 杨青, 袁哲俊, 铣刀破损的声发射检测技术, 组合机床及自动化加工技术, 1992, 第3期
- [29] 赵曙伟, 刀具失效监控的声发射信号检测技术的研究, 上海交通大学硕士学位论文, 1994
- [30] J. A.Carolan and D. P. Hand, Acoustic emission source and transmission path characterization through homographic processing ,Trans. ASME, J. Eng. Ind. , Vol. 118 ,Aug, 1996.pp428-433
- [31] S. Y. Lanf and D. A. Dornfeld, Tool wear detection using time series analysis of acoustic emission , Trans. ASME, J. Eng. Ind. , Vol. 111 ,Aug, 1989.pp199-205
- [32] E.Waschkies and C. Sklarczy, Tool wear monitoring at turning, Trans. ASME, J. Eng. Ind. , Vol. 116 ,Aug, 1994.pp521-524
- [33] I. Grabec and E. Kujanic, characterization of manufacturing processed based upon acoustic emission analysis by neural networks, Ann. CIRP, Vol.43,No.1,1994,pp77-80
- [34] J. M. Lee and D. K. Choi, Real-time tool breakage for NC turning and drilling, Ann.CIRP,Vol.43, No.1,1994,pp81-84
- [35] E. N. Diei and D. A. Dornfeld, Acoustic emission sensing of tool wear in face milling, Trans. ASME, J. Eng. Ind. , Vol. 109 ,Aug, 1987.pp234-240

- [36] 雷继荣, 陈弘, 用声发射 (AE) 实时监控刀具异常的研究, 工具技术, V01.25No.2,1991
- [37] 罗振壁, 徐家球, 切削过程刀具监视与声发射监视仪的研制, 组合机床与自动化加工技术, 1990, 第 1 期
- [38] C. R. Heiple and S. H. Carpenter ,Acoustic emission from single point machining: source mechanisms and signal changes with tool wear ,Materials Evaluation, May, 1994,pp590-596
- [39] J. T. Barnett and R. B. Clough, Power considerations in acoustic emission, J. Account. Soc. Am., Vol. 98 ,No.4,1995,pp2070-2081
- [40] A. E. Diniz and J. J. Liu, Correlating tool life , tool wear and surface roughness by monitoring acoustic emission in finish turning , Wear, Vol.152,1992,pp395-407
- [41] M. Liu and S. Y. Liang , Analytic modeling of acoustic emission for monitoring of peripheral milling process , Int.J. Mach. Tools Manu fact., Vol.31, No. 4, 1991, pp89-606
- [42] S. S. Cho and K. Komvmpoulos, Correlation between acoustic emission and wear of multilayer ceramic coated carbide tools, Trans. ASME, Vol.119, May, 1997,pp238-246
- [43] J. A. Rice and S. M. Wu, On the feasibility of catastrophic cutting tool fracture prediction via acoustic emission analysis, Trans. ASME, Vol.119, Nov., 1993,pp390-397
- [44] 崔松涛, 朱名拴, 刀具磨损识别的人工神经网络方法, 机械科学与技术, 1995, 第 6 期
- [45] 徐春广, 王义信,数据融合法在监测刀具状态中的应用, 北京理工大学学报, Vol.15, No.1, 1995, pp75-81
- [46] A. N. Khajavi and R. Komanduri ,On multisensor approach to drill wear monitoring, Ann. CIRP, Vol.42,No. 1, 1993, pp71-74

-
- [47] 袁振明, 马羽宽, 声发射技术及其应用, 机械工业出版社, 1984
- [48] [英]J.西拉德, 超声检测新技术, 科学出版社, 1984
- [49] 张贤达, 现代信号处理, 清华大学出版社, 1995
- [50] 史维祥, 尤昌德, 系统辨识基础, 上海科学技术出版社, 1988
- [51] 方崇智, 萧德云, 过程辨识, 清华大学出版社, 1988
- [52] 万光岷, 李小铨, 用模糊模式识别方法识别金属切削刀具的磨损, 工具技术, Vol.26, No.7, 1994

附 录

1、切削速度与 AE 信号能量(RMS)的关系	rms1.m
2、切削深度与 AE 信号能量(RMS)的关系	rms2.m
3、进给率与 AE 信号能量(RMS)的关系	rms3.m
4、后刀面磨损量与 AE 信号能量(RMS)的关系	rms4.m
5、AE 信号功率谱相关程序	experiment_powmuti.m
所有相关程序都用此程序，根据选取文件的不同，得到不同的图形。	
6、神经网络	aeshenjing.m

```
function x=rms1
clear;
v1=[100 125 150 200 250 300];
v2=v1; %[100 200 250 300]; %切削速度
RMS1=[2.94 3.163 2.63 2.866 3.236 2.956];
RMS2=[3.181 3.264 3.413 3.486 3.748 4.268];
p1=polyfit(v1,RMS1,2);
p2=polyfit(v2,RMS2,2);
v=50:5:400;

RMS11=polyval(p1,v);
RMS22=polyval(p2,v);
plot(v1,RMS1,'ok',v2,RMS2,'+k');
hold on;
plot(v,RMS11,'k',v,RMS22,'k');
xlabel('Cutting Speed(m/min)');
ylabel('RMS of AE Signal(mv)');
legend('f=0.1mm/r    ap=0.1mm    VB=0.302mm', 'f=0.15mm/r    ap=0.1mm
VB=0.302mm',2)
hold off;
```

```
function x=rms2
clear;
ap1=[0.1 0.2 0.3];
RMS1=[2.956 3.839 4.238];
RMS2=[2.188 2.374 2.644];
RMS3=[2.487 3.224 3.391];
RMS4=[3.937 5.565 6.785];
p1=polyfit(ap1,RMS1,1);
p2=polyfit(ap1,RMS2,1);
p3=polyfit(ap1,RMS3,1);
p4=polyfit(ap1,RMS4,1);
ap=0:0.01:0.4;

RMS11=polyval(p1,ap);
RMS22=polyval(p2,ap);
RMS33=polyval(p3,ap);
RMS44=polyval(p4,ap);
%subplot(211);
plot(ap,RMS1,'ok',ap,RMS2,'+k');
hold on;
plot(ap,RMS11,'k',ap,RMS22,'k');
xlabel('Cutting depth(mm)');
ylabel('RMS of AE Signal(mv)');
legend('f=0.1mm/r v=300m/min VB=0.302mm', 'f=0.2mm/r v=200m/min
VB=0.302mm',2);
%subplot(212);
hold off;
plot(ap,RMS3,'ok',ap,RMS4,'+k');
hold on;
plot(ap,RMS33,'k',ap,RMS44,'k');
xlabel('Cutting depth(mm)');
ylabel('RMS of AE Signal(mv)');
legend('f=0.1mm/r v=200m/min VB=0.225mm', 'f=0.2mm/r v=300m/min
VB=0.225mm',2)

hold off;
```

```

function x=rms3
clear;
v1=[0.1 0.15 0.2 0.25];
v2=v1;%[100 200 250 300];%切削速度
RMS1=[3.134 3.465 5.398 5.954];
RMS2=[3.937 4.863 5.483 7.437];
p1=polyfit(v1,RMS1,1);
p2=polyfit(v2,RMS2,1);
v=0:0.01:0.4;

RMS11=polyval(p1,v);
RMS22=polyval(p2,v);
plot(v1,RMS1,'ok',v2,RMS2,'+k');
hold on;
plot(v,RMS11,'k',v,RMS22,'k');
xlabel('Feed velocity(mm/r)');
ylabel('RMS of AE Signal(mv)');
legend('v=250m/min ap=0.1mm VB=0.225mm','v=300m/min ap=0.1mm
VB=0.225mm',2)
hold off;

function x=rms4
clear;
v1=[0 0.07 0.145 0.16 0.225 0.302 0.425];
v2=v1;%[100 200 250 300];%切削速度
RMS1=[3.9406 4.0032 4.0623 4.1513 4.3765 4.4007
6.1311];
RMS2=[3.937 4.863 5.483 7.437];
p1=polyfit(v1,RMS1,2);
p2=polyfit(v2,RMS2,1);
v=0:0.01:0.5;

RMS11=polyval(p1,v);
RMS22=polyval(p2,v);
plot(v1,RMS1,'+k');
hold on;
plot(v,RMS11,'k');
xlabel('Flank wear(mm)');

```

```
ylabel('RMS of AE Signal(mv)');
legend('v=200m/min ap=0.15mm f=0.15mm/r',2)
hold off;

function x=experiment_pow
clear;
str1='f:\work\AE\lunwen\';
for i=1:6
str2=num2str(i);
str3=[str1,str2,'.txt'];
fid=fopen(str3,'r');

x1=fscanf(fid,'%f');
fclose(fid);
Fs=2500000;
lie=2;
n=length(x1);
n1=n/lie;
time=x1(1:2:n-1);
singal=x1(2:2:n);
singal1=singal(1:1:1500);
time=time';
singal=singal';
singal1=singal1';

nfft=256;
x=singal1;
w=hanning(nfft);
noverlap=0;
[pxxf(:,i),f]=pwelch(x-mean(x),nfft,Fs,w,noverlap,0.95);
end
waterfall(f,1:6,pxxf');
xlabel('Frequency(Hz)');
ylabel('Feed Velocity Index');
zlabel('G(f)')

function x=aeshenjing
```

```
clear;
a=load ('ae.txt');
depth=a(:,1);
f=a(:,2);
v=a(:,3);
vb=a(:,4);
rms=a(:,8);
maxd=max(depth);
mind=min(depth);
dn=(depth-mind)./(maxd-mind);
maxf=max(f);
minf=min(f);
fn=(f-minf)./(maxf-minf);
maxv=max(v);
minv=min(v);
vn=(v-minv)./(maxv-minv);

maxvb=max(vb);
minvb=min(vb);
vbn=(vb-minvb)./(maxvb-minvb);
maxrms=max(rms);
minrms=min(rms);
rmsn=(rms-minrms)./(maxrms-minrms);%正规化结束

b=[dn,fn,vn,rmsn];
b=b';vbn=vbn';
[R,Q]=size(b);

iitst=2:4:Q;
iival=4:4:Q;
iitr=[1:4:Q 3:4:Q] ;
vv.P=b(:,iival);
vv.T=vbn(:,iival);
vt.P=b(:,iitst);
vt.T=vbn(:,iitst);
ptr=b(:,iitr);
ttr=vbn(:,iitr);
%建立网络
```

```
net=newff(minmax(ptr),[15 1],{'logsig' 'logsig'},'trainlm');
%训练网络
%net.trainParam.show=111;
net.trainParam.epochs = 200;
net.trainParam.goal = 0.000001;
net=train(net,b,vbn);
figure(1);
[net,tr]=train(net,ptr,ttr,[],[],vw,vt);
%绘出训练过程中各误差的变化曲线
figure(2);
plot(tr.epoch,tr.perf,'r',tr.epoch,tr.vperf,':g',tr.epoch,tr.tperf,'-b');
legend('Training','Validation','Test',-1);
ylabel('Square Error');
xlabel('Epochs');
t2 = sim(net,b);
figure(3);
[m,bb,r]=postreg(t2,vbn);
```

致 谢

本文是在邵华老师、程曦高工、时殷平高工的悉心指导下完成的，各位导师渊博的学识，严谨的治学之道，积极进取的人生态度和诲人不倦的风范，给我以深刻的印象，对我的启发很大，值得我永远的学习。

在过去的一年多时间里，我从对刀具在线监控、声发射、BP 人工神经网络的一无所知到慢慢了解，从硕士论文设计的茫然到思绪清晰，然后到完成，这期间，有成功的喜悦，有不知的无助，有面对困难的迷茫，更有工作和学习冲突的苦恼。硕士论文，设计工作量大，要求高而且具体，自己首先对课题进行认真分析，仔细查阅各种资料，虚心请教导师和上海交大的教授，然后自己定下设计提纲，设计实验系统，设计实验数据处理程序，最后试验完成以后，对数据进行分析处理。

有得必有失，牺牲了大量的休息和家庭义务的同时，我学到了许多东西。我感到它对我以后的工作、学习均有较大的影响，那就是认真、严谨的态度。为了顺利完成设计，我查阅了大量的资料，包括别人的博士、硕士论文，工程信号处理、MATLAB 方面的书籍，另外，为了完成各种试验，花费了大量的财力和精力赴上海交大。

当然，由于本人知识有限，加上时间所限，在论文中难免有欠考虑的地方，甚至有一些错误地方，在这里恳请各位批评指正。

最后，再一次感谢邵华导师、时殷平和程曦三位企业导师的指导，感谢妻子宋倩和儿子程正宇的理解支持，感谢车间周忠主任及许多同事给我的关心和帮助，当然，对于和我一起进行试验工作的李希及几位交大的师弟表示真诚的感谢。

程敢峰
2004.11.12

攻硕期间发表的论文

1. 程敢峰 浅谈振动时效处理技术在 16V280ZJA 型柴油机机体生产中的应用
戚厂科技 2002.1
2. 程敢峰 浅谈振动时效处理技术在 16V280ZJA 型柴油机机体生产中的应用
机车车辆工艺 2002.3
3. 程敢峰 切削力、刀具状态及工件表面完整性之间的相关性研究
戚厂科技 2004.3
4. 程敢峰 刀具磨损与切削力及工件表面残余应力的研究
机车车辆工艺 2004.6

上海交通大学学位论文答辩决议书

申 请 者	程敢峰	所在学科 (专业)	机械与制造
论 文 题 目	刀具状态在线监控策略研究		
答 辩 日 期	2005 年 1 月 14 日	地 点	教学三楼 100 室
答辩委员会成员			
姓 名	单 位	职 称	签 名
杨建国	上海交通大学机械与动力工程学院	教授	杨建国
胡德金	上海交通大学机械与动力工程学院	教授	胡德金
邵华	上海交通大学机械与动力工程学院	副教授	邵华
王海丽	上海交通大学机械与动力工程学院	副教授	王海丽
程熙	戚墅堰机车车辆厂	高工	程熙
<p>评语和决议：</p> <p>程敢峰同学的论文“刀具状态在线监控策略研究”主要研究基于声发射信号的刀具状态在线监控问题，论文工作对于确保自动化切削加工系统的可靠运行和产品质量具有使用价值。论文研究了声发射信号与刀具状态的相关性，进一步探明了刀具磨损的 AE 信号特征，并利用 BP 网络进行了刀具状态识别的探索，初步实现了变切削工况下的刀具状态识别。</p> <p>论文表达清楚，试验数据可信，答辩过程中回答问题正确。经答辩委员会评议，并进行无记名投票决议，一致通过其论文答辩，建议授予工程硕士学位。</p>			
<p>表决结果：</p> <p style="text-align: center;">全票通过</p> <p style="text-align: right;">答辩委员会主席：杨建国（签名）</p>			

2005 年 1 月 14 日

作者：[程敢峰](#)
 学位授予单位：[上海交通大学](#)

相似文献(10条)

1. 期刊论文 [韩亚利, 陈勇, HAN Ya-li, CHEN Yong 基于小波分析的数控刀具状态在线监控系统 - 装备制造技术 2009, \(7\)](#)

提出了一种利用检测进给机电流实现切削加工过程中刀具破损的在线监控系统。在该系统中,离散小波分析技术被用来实现对电机电流信号的处理,并有效地提取了刀具破损时的特征;探讨了中断型宏指令功能在刀具破损在线监控系统中的应用;经实践证明,利用该监测系统和中断型宏指令,能够实时的识别加工过程刀具的破损,并能及时报警、自动换刀等,机床的故障停机时间大大减少,利用率得到了提高。

2. 学位论文 [刘冬芳 基于计算机视觉的刀具状态在线监控研究 2007](#)

基于计算机视觉的刀具状态在线监控是综合了机器视觉和图像处理分析技术对刀具磨损状态进行监测的一种技术。本文通过对刀具的不同磨损状态下加工的工件表面纹理图像的纹理特征进行研究,应用数据挖掘技术对纹理特征进行特征数据的提取,通过对特征数据进行模式识别,以达到对刀具磨损状态监测的目的。

分析了切削加工表面纹理的形成过程,以及加工表面纹理的形态及图像特征,并对影响工件表面纹理的因素进行了对比,阐明了基于加工表面纹理的刀具磨损监测方法的合理性和可行性。

论文结合实验所得到的工件表面图像,对常用的图像预处理方法进行了研究、分析和比较,找出了适合工件表面图像的预处理算法,为实现刀具磨损状态监测的图像特征提取奠定了基础。研究和探索了适合于工件表面纹理图像的数据挖掘算法,对辅助工人进行刀具状态的在线监控具有重要实用价值。

本文通过基于灰度共生矩阵法、基于空间像素投影面积法、基于连通区域法和基于马尔可夫随机场模型四种方法对工件表面图像的纹理特征数据进行提取,通过实验数据分别得到的估计参数都能正确的表达纹理图像和刀具磨损状态的对应关系,从而为刀具状态的识别提供了数据来源。

本文在进行刀具状态识别时,针对不同刀具状态类别特征样本存在重叠区域造成的分类困难,本文提出了基于模糊判决的刀具状态识别模型和方法;针对特征判决边界存在一定的非线性特性,本文提出了基于BP神经网络的刀具状态识别模型和方法;再对上述两种识别模型进行决策层融合研究,提出了基于分类器融合的刀具状态识别模型和方法。通过对上述两种基于不同特征的识别模型的融合,刀具状态识别的效率和准确率显著提高。

3. 学位论文 [金建江 转子轮槽铣削加工刀具状态在线监控研究 2008](#)

汽轮机转子是火力发电机组的关键部件之一,其转子纵树型轮槽型线复杂,成型铣削工作量大,切削加工时极易发生刀具磨损或破损,需要操作人员注意力高度集中以防止刀具失效造成工件超差及烧伤等质量事故。研制轮槽加工刀具状态及切削过程在线监控系统,对保证加工质量,降低操作人员劳动强度具有重要的经济 and 实用价值。

本文采用温度、声音及功率三种非接触式传感器用于在线监测切削加工过程及刀具状态。基于虚拟仪器软件开发工具LabVIEW (Laboratory Virtual Instrument Engineering Workbench) 作为数据采集系统软件设计平台。软件由数据采集与存储、数据分析、数据标定与超限报警三个主要模块组成,以实现切削温度、声音及功率参数的实时采集、信号调理和实时显示等功能。在数据分析模块采用了信号数字滤波技术和FFT以及小波分析。本文通过等螺旋角波型刀轮槽铣刀磨损试验研究了不同主轴转速、进给功率和径向切削深度对刀具磨损状态的影响,在试验室及汽轮机车间转子轮槽铣机床上,利用刀具状态监控系统测量铣削过程中各监控参数,并对监控参数与切削参数及铣刀磨损状态的相关性进行了研究,获取了刀具在不同磨损状态下的切削温度、切削声音和切削功率信号,通过对信号的处理分析,初步实现了刀具磨损的识别。

4. 期刊论文 [翁德玮, 邵华, 王海丽 多传感器刀具状态监控系统 - 机械制造 2004, 42 \(6\)](#)

介绍一个多传感器、多特征量的刀具状态监控系统。以声发射、功率监控和改进的神经网络技术,借助刀具监控软件,识别刀具切削工作的正常和失效状态。软件有信号采集、特征提取、网络训练回忆以及监控等功能,可实现离线和在线监控。并以离线控制试验为实例,考核该系统识别刀具状态的可靠性。

5. 学位论文 [胡家英 刀具寿命在线监控与管理 2003](#)

刀具失效是切削加工过程不可避免的事件。因此,在数控机床、加工中心、柔性制造系统(FMS)以及计算机集成制造系统(CIMS)等自动化加工过程中,刀具失效将导致工件报废甚至加工机床故障。因此,刀具状态监控问题是自动化乃至无人化加工系统得以可靠运行的一个关键。该文在总结国内外有关刀具状态监控研究成果的基础上,针对目前刀具磨损监控存在的问题,提出了利用刀具相对寿命消耗量的磨损监测算法。该文首先总结了并剖析了刀具状态监测技术的现状提出了用于铣削加工中刀具状态监测的混合智能模型,并详细介绍了该模型的体系结构和工作原理,并提出利用刀具相对寿命消耗量作为监测刀具磨损的标准的关键是获取切削深度和切削宽度。由于现代加工系统加工零件的复杂性和多样性,提出利用铣削中的平均功率和功率波动量来推算切削深度和切削宽度,并通过切削仿真和切削试验证明了该方法的正确性。论文通过利用泰勒公式对各种加工条件下的刀具寿命进行了仿真,并利用数据库对刀具寿命进行优化管理,为在监测刀具磨损中计算刀具相对寿命消耗量奠定了基础。论文还开发了刀具状态监测的软件系统。软件是基于Windows环境开发,采用Visual C++以及SQL Server等软件开发了刀具磨损监控模块和刀具状态查询模块。还深入研究了Visual C++的ADO(ActiveX Data Object)技术,并应用该技术完成了对数据库的存取。同时,为了实际需要,利用多线程技术对刀具磨损监控模块进行操作。论文根据上述算法建立了刀具磨损在线监测与寿命管理试验系统,验证了该文提出的刀具寿命在线监控方法在实际应用中的正确性和可靠性。

6. 期刊论文 [王建平, 童建平, WANG Jianping, TONG Jianping 加工中心刀具破损在线监控研究 - 机床与液压 2006, \(7\)](#)

随着机械加工自动化程度的提高,刀具状态的在线监控已成为迫切需要解决的问题,并越来越受到重视。本文根据主轴机电流与刀具破损的关系,提出了一种刀具在线检测的方法。实验表明,电机电流信号可用来监控刀具的破损状态,并以此作为刀具更换的依据。

7. 学位论文 [宋书善 刀具状态\(磨损\)在线切削力监控研究 2006](#)

刀具状态监控直接关系到自动化加工的效率、安全及产品质量,是一个迫切需解决的课题。本文以实际切削过程监测试验研究为背景,总结国内外有关刀具监测研究;针对外圆车削加工,通过切削试验和理论分析,研究了基于切削力模型的刀具状态监测问题,探索了切削力监测模型,建立了刀具状态监测的识别系统。

首先建立了外圆车削的切削试验系统,设计试验方法,并进行了试验。接着处理和分析了利用测力仪及数据采集卡采集的力信号,在此基础上建立了基于切削参数与刀具状态的切削力模型,并进行了试验验证。最后,设计了刀具状态监控策略,并初步实现了刀具状态监控。

试验表明:1)主切削力 F_z 的预测值基本能反映其实际切削力的变化;2)切削力模型能正确描述切削力与刀具后刀面磨损量之间的关系;3)还能揭示刀具状态监控参数与后刀面磨损量及切削三要素之间的关系。

这些结论对开发可适应不同工况的刀具状态监测系统具有实用价值。

8. 学位论文 [范伟 基于红外温度测量的刀具状态识别研究 2008](#)

在金属切削加工中,刀具会不可避免地发生磨损或破损。刀具磨损或破损会使零件的加工精度下降,零件表面粗糙度及表层质量恶化,严重时将使刀具失去切削能力,甚至危及机床设备。因此,研究刀具状态在线监控不仅具有重要的理论意义而且还有实际应用价值。刀具状态监控系统的成功应用的基础是找出与刀具状态有较好对应关系的特征量,从这些特征量中提取的特征信息能够识别刀具状态。尽管近十年来,国内外对刀具状态监控做了大量的探索研究,但在实际切削加工过程中,由于现场工况的变化与工件材料的不均匀性,很难找到与刀具状态对应较好的特征量。刀具磨损与切削温度有着密切的关系,随着刀具磨损的增加,切削温度会相应升高。本文拟采用红外远程测温方法,对不同刀具状态下测得的表面切削温度进行分析,探索切削温度随刀具状态变换的规律,为实现基于切削温度的刀具状态监控作理论准备。

本文研究针对端铣加工。首先基于红外测温原理,建立了刀具监控系统,并对刀具监控系统的红外测温误差进行了研究。然后,通过建立铣刀的三维模型并确定铣刀温度场的边界条件,分析了铣刀前刀面在稳定铣削状态下的温度分布情况,试验研究表明刀具表面温度变化能够反映切削区温度的变化,因此可以通过测量刀具表面温度监控刀具磨损状态。本文还通过刀具寿命试验,探索了刀具磨损过程。通过试验研究了切削参数、刀具磨损等因素对刀具的表面切削温度的影响规律。试验表明表面切削速度 v 、进给量 f_z 、径向切宽 a_w 的增大都会使刀具的表面切削温度增高。其中,切削速度 v 对表面切削温度的影响最大,进给量 f_z 其次,径向切宽 a_w 则为最小。

最后,采用BP神经网络建立了刀具磨损状态与表面切削温度特征值及切削工况参数间的映射关系,使监控系统能识别变切削工况下的刀具状态,提高了刀具磨损在线监控的柔性。

9. 期刊论文 [王永新 球头铣刀寿命在线监测和管理 - 组合机床与自动化加工技术 2005, \(1\)](#)

随着机械加工自动化程度的提高,刀具状态在线监控已成为迫切需要解决的问题,越来越受到重视。文章根据主轴功率、功率波动量与刀具寿命的关系,提出了一种刀具在线监测和刀具寿命管理相结合的新方法,详细分析了刀具寿命预测模型,并用实验验证其可行性。

10. 学位论文 [王震霞 变切削参数铣削加工中刀具破损辨识 2005](#)

刀具监测的方法很多,在对众多反映刀具状态信息的信号选取过程中,考虑到实际的加工条件及传感器安装的难易程度,选择了振动信号作为研究对象。在本次课题的研究中,模拟变切削参数的加工过程设计了一套实验方案,该试验系统中硬件包括振动加速度计、自行设计的放大电路、数据采集卡等,软件采用C语言程序实现信号的采集与存储。该试验装置用于采集研究刀具破损监控系统中所需振动信号、主轴转速信号。在实际的振动信号采集过程中,由于试验系统、现场等客观因素的影响,采集到的振动信号中含有大量的“无用信号”,因此对振动信号进行了去除直流量、低通滤波、剔除奇异点等处理。经过时域与频域分析提取出了振动信号的均方根、方差和齿啮合频率处的功率谱值作为反映刀具破损的特征量,获得了后续网络试验过程中所需的样本集。最后,利用现代模式识别手段——人工神经网络进行了网络试验。

1. [马旭, 陈捷](#) [数控机床刀具磨损监测方法研究](#)[期刊论文]-[机械](#) 2009(6)

本文链接: http://d.g.wanfangdata.com.cn/Thesis_D006615.aspx

下载时间: 2010年6月21日