

# 基于磨削声与电流的砂带磨损状态识别<sup>\*</sup>

程 灿<sup>1</sup>, 李建勇<sup>1,2</sup>, 刘月明<sup>1,2</sup>, 聂 蒙<sup>1,2</sup>

(1. 北京交通大学机械与电子控制工程学院 北京, 100044)

(2. 载运工具先进制造与测控技术教育部重点实验室 北京, 100044)

**摘要** 为实时监测砂带磨损状态, 采用基于磨削声信号与电流信号的监测方案。首先, 利用时域分析方法与小波包分析方法提取砂带磨损信号特征, 通过朴素贝叶斯方法融合两种信号, 从而识别砂带磨损状态; 其次, 为提高砂带磨损状态识别准确率, 针对朴素贝叶斯方法的分类特性, 改进了一种基于 Fisher 判别率与互信息的信号特征选择方法。实验结果表明, 利用基于 Fisher 判别率与互信息方法能够挑选出可分性好同时特征间相关性弱的信号特征, 基于朴素贝叶斯的砂带磨损状态识别方法能够准确地识别砂带磨损状态。

**关键词** 砂带磨损; 朴素贝叶斯; 状态识别; 声信号; 电流信号

**中图分类号** TG74; TH117

## 引 言

近年来, 随着高强度重载砂带、高质量精密砂带的发展和各种型号砂带磨床的不断涌现, 砂带磨削技术发展迅速, 受到了制造业各领域的关注, 加之砂带柔性加工的特点, 使其在复杂曲面加工、大面积板材加工、大长径比工件内外圆加工等场合具有明显优势, 应用日益广泛<sup>[1]</sup>。单层磨粒是砂带的一个显著特点, 使得砂带磨削性能受磨粒磨损的影响程度大。一般来说, 随着砂带的磨损, 材料去除率下降、磨削温度升高, 而磨削通常作为工件加工的最后一道工序, 对保证加工表面质量与尺寸精度起决定性作用, 而人工监测的方式难以满足实时、准确、高效的监测需求, 因此利用传感技术、信号处理与人工智能技术进行砂带磨损程度的自动监测十分必要<sup>[2]</sup>。

Lemaster 等<sup>[3]</sup>进行了砂带磨损状态监测的研究, 验证了当工件表面光滑时, 声发射信号能够监测砂带磨削过程, 砂带磨损程度、磨粒尺寸、加工参数都会影响声发射信号。Carrano 等<sup>[4]</sup>为了在木材加工中实时预测砂带剩余寿命, 开发了一套图像监测装置, 建立了以砂带图像 RGB 像素值为输入的人工神经网络模型识别砂带磨损状态。Saloni 等<sup>[5]</sup>设计了一套砂带磨削自动监测方案, 通过声发射传感器监测砂带磨损状态, 从而决定是否更换砂带。叶浩

浩等<sup>[6]</sup>利用图像传感器监测砂带磨损状态, 以图像数据的能量、熵、惯性矩、相关性及逆差矩 5 个特征为输入, 以砂带磨损状态为输出, 分别建立了识别氧化铝与锆刚玉砂带磨损状态的支持向量机分类模型。Pandiyani 等<sup>[2]</sup>采集了砂带磨削过程中的力信号、振动信号与声发射信号, 从中提取了 162 个时域与频域特征, 利用遗传算法与 K 近邻算法相结合进行特征选择, 最后将筛选后的特征训练支持向量机模型, 利用训练后的模型进行砂带磨损状态识别。上述研究所采用的力信号、图像与声发射信号采集装置对安装位置有较高要求, 并且成本较高, 制约了其在实际加工中的应用。

加工过程产生的声信号蕴含丰富的加工状态信息, 其采集装置——传声器与加工设备无直接关联、安装方便、成本低, 被认为是一种工业实用性强、应用潜力大的监测方式<sup>[7-8]</sup>, 已被应用于车刀、铣刀、钻头、冲压刀具及砂轮等加工工具的磨损状态监测中<sup>[9-13]</sup>。声信号能够获取到磨削区域的高频振动信息, 但是易受环境噪声干扰, 而电流信号中低频信息丰富, 两种信号所蕴含的信息具有很强的互补性, 通过信息融合可有效提高系统识别准确性, 同时两种信号的干扰来源差别较大, 通过信息融合可增强系统的鲁棒性<sup>[14]</sup>, 因此, 为准确识别砂带磨损状态, 本研究采用基于磨削声信号与电流信号的监测方案。

<sup>\*</sup> 国家自然科学基金资助项目(51605024)

收稿日期: 2018-05-19; 修回日期: 2018-08-05

# 1 砂带磨损状态识别方法

## 1.1 砂带磨损信号特征选择

笔者针对朴素贝叶斯分类器的特点,改进了一种基于 Fisher 判别率与互信息的特征选择方法。本节将分别介绍所使用的特征选择方法与基于朴素贝叶斯分类的砂带磨损状态识别方法。

类可分性是特征分类能力的一种度量。在多种类可分性度量准则中, Fisher 判别率 (Fisher's discrimination ratio, 简称 FDR) 计算简便, 应用较为广泛, 其计算方法为

$$F = \sum_i^M \sum_{j \neq i}^M \frac{(\mu_i - \mu_j)^2}{\sigma_i^2 + \sigma_j^2} \times \frac{N_i + N_j}{N} \quad (1)$$

其中:  $M$  为砂带磨损类别个数;  $\mu_i$  与  $\mu_j$  分别为  $i, j$  两类砂带磨损状态信号特征的均值;  $\sigma_i$  与  $\sigma_j$  分别为  $i, j$  两类状态的信号特征的方差;  $N_i$  与  $N_j$  分别为  $i, j$  两类砂带不同状态的样本个数;  $(\mu_i - \mu_j)^2$  为类间距离的测度, 反映了不同磨损状态的砂带在此特征维度上的距离;  $\sigma_i^2 + \sigma_j^2$  为类内距离的测度, 反映了同一磨损状态的砂带在此特征维度上的离散程度。

当不同磨损程度的砂带信号特征差别大、相同磨损程度的砂带信号特征差别小时, 此特征区分砂带磨损程度的能力就强, 此时类间距离大, 类内距离小, FDR 大, 此特征的类可分性好。

利用 FDR 能够挑选出可分性好的特征组合, 但是特征之间往往存在较强的相关性, 使得增加特征个数不仅不能明显提高模型精度, 而且增加了计算负担, 影响监测的实时性。另一方面假设要求各输入特征之间是统计无关的, 特征之间的相关性违背了此假设, 降低了模型精度。鉴于此, 针对朴素贝叶斯分类器的特点, 笔者改进了一种特征选择方法, 采用 FDR 与互信息相结合的方法筛选出可分性好同时特征间相关性较弱的信号特征集合。互信息是两个变量之间相互关联程度的度量, 可以看作一个特征包含另一个特征的信息量, 计算方法为

$$I(X; Y) = H(X) + H(Y) - H(X, Y) \quad (2)$$

其中:  $H(X)$  为特征  $X$  的信息熵, 是特征  $X$  的不确定性的度量;  $H(X, Y)$  为特征  $X$  与  $Y$  的联合熵。

$H(X)$  与  $H(X, Y)$  的计算方法分别为

$$H(X) = - \sum_{i=1}^L p_i \log_a p_i \quad (3)$$

$$H(X, Y) = - \sum_{i=1}^L \sum_{j=1}^M p_{ij} \log_a p_{ij} \quad (4)$$

由于信号特征是连续型的数值变量, 因此计算各特征之间的互信息时需要首先将特征进行离散化, 具体计算方法如下:

1) 将特征  $X = \{X_i\}_{1 \leq i \leq N}$  与特征  $Y = \{y_i\}_{1 \leq i \leq N}$  进行离散化, 具体是将其分别按照增序排列, 然后等分为  $b$  级, 则每级有  $N/b$  个样本;

2) 将两个信号特征组成的样本集  $\{(X_i, y_i)\}_{1 \leq i \leq N}$  根据  $X_i$  与  $y_i$  在上面所划分的级别分配到一个  $b \times b$  的网格中;

3) 按照式 (5, 6) 计算  $H_c(X), H_c(Y)$  与  $H_c(X, Y)$ , 式中的底数  $a$  一般取 2, 但是为了使互信息计算结果在  $[0, 1]$  范围内, 便于后续与可分性的结合, 将底数取为等分级别个数  $b$ , 计算结果如下

$$H_c(X) = - \sum_{i=1}^b \frac{n_i}{N} \log_b \frac{n_i}{N} \quad (5)$$

$$H_c(X, Y) = - \sum_{i=1}^b \sum_{j=1}^b \frac{n_{ij}}{N} \log_b \frac{n_{ij}}{N} \quad (6)$$

其中:  $n_i$  为特征每个级别包括的样本个数;  $n_{ij}$  为  $b \times b$  的网格中第  $i$  行、第  $j$  列的样本个数。

4) 按照式 (2) 计算互信息  $I(X; Y)$ , 由于  $n_i = N/b$ , 因此  $H_c(X)$  与  $H_c(Y)$  均恒为 1, 式 (2) 等价于

$$I(X, Y) = 2 - H_c(X, Y) \quad (7)$$

基于 FDR 与互信息的特征选择方法完整流程如下: 首先, 计算每 1 个特征  $X_k (k=1, 2, \dots, m)$  的 FDR, 归一化之后按照降序排列, 选取 FDR 最大的特征  $X_{i_1}$  作为第 1 个输入特征; 其次, 计算  $X_{i_1}$  与剩余  $m-1$  个特征间的互信息, 设为  $I(X_{i_1}; X_j), j \neq i_1$ , 将满足式 (8) 的特征作为  $X_{i_2}$ , 其中,  $\alpha \in [0, 1]$  为调节可分性与相关性比重的系数, 调节系数越大, 特征之间的相关性所占比重越大, 会倾向于选择与已选中特征不相关的特征; 最后, 选择  $X_{i_k}, k=3, 4, \dots, m$ , 将满足式 (9) 的特征作为  $X_{i_k}$ 。

$$i_2 = \arg \max_j \{ (1 - \alpha) F(j) + \alpha (1 - I(X_{i_1}; X_j)) \} \quad (8)$$

$$i_k = \arg \max_j \{ (1 - \alpha) F(j) + \frac{\alpha}{k-1} \sum_{r=1}^{k-1} (1 - I(X_{i_r}; X_j)) \} \quad (9)$$

## 1.2 基于贝叶斯分类的砂带磨损状态识别

贝叶斯分类方法的核心是贝叶斯定理<sup>[15]</sup>, 定理内容如下

$$P(A | B) = \frac{P(A)P(B | A)}{P(B)} \quad (10)$$

其中:  $P(A)$  为事件  $A$  发生的概率;  $P(B)$  为事件  $B$  发生的概率;  $P(A|B)$  为事件  $B$  发生的条件下事件

$A$  发生的概率;  $P(B|A)$  为事件  $A$  发生的条件下事件  $B$  发生的概率;  $P(A)$  也被称为事件  $A$  发生的先验概率;  $P(A|B)$  也被称为已知与事件  $A$  相关的事件  $B$  发生时, 事件  $A$  发生的后验概率。

利用贝叶斯定理, 可以融合事件本身发生的概率以及获取的与之相关的新信息, 从而对事件是否发生做出更为准确的判断。在砂带磨损状态识别中, 事件  $A$  代表砂带是否属于某磨损类别  $S$ , 事件  $B$  代表砂带磨削监测信号特征, 即与砂带磨损状态相关的监测信号特征, 利用贝叶斯定理分别得到砂带磨损状态属于各类别的概率, 其中最大的概率值所对应的磨损状态即为预测的砂带磨损状态。

在实际的分类中, 往往尽可能地获取更多的信息, 此时砂带监测信号的特征值有多个, 这样不仅能够提高分类正确率, 而且能够增强系统鲁棒性, 此时事件  $A$  发生的后验概率通过式(11)得到

$$P(A | B_1, B_2, \dots, B_l) = \frac{P(A)P(B_1, B_2, \dots, B_l | A)}{P(B_1, B_2, \dots, B_l)} \quad (11)$$

式(11)中的  $P(B_1, B_2, \dots, B_l | A)$  可利用条件概率公式改写为式(12)

$$\begin{aligned} P(B_1, B_2, \dots, B_l | A) &= P(B_1 | A)P(B_2, \dots, B_l | A, \\ &B_1) = P(B_1 | A)P(B_2 | A, B_1)P(B_3 | A, B_1, B_2) \\ &\dots P(B_l | A, B_1, B_2, \dots, B_{l-1}) \end{aligned} \quad (12)$$

为了通过实际数据准确估计式(12)中各条件概率的分布, 训练样本的数量应足够大, 如果在一维空间中,  $N$  个样本能够准确估计概率密度函数, 则在  $l$  维空间中需要  $Nl$  个样本。然而在实际中很难获取这么多的数据, 因此, 朴素贝叶斯分类作出了一个条件独立性假设, 即

$$P(B_i | A, B_j) = P(B_i | A) \quad (1 \leq i, j \leq l, i \neq j) \quad (13)$$

由式(13)可将式(12)改写为式(14)

$$P(B_1, B_2, \dots, B_l | A) = P(B_1 | A)P(B_2 | A)P(B_3 | A) \dots P(B_l | A) \quad (14)$$

由于  $P(B_1, B_2, \dots, B_l)$  为定值, 由式(14)可将式(11)改写为式(15)

$$\begin{aligned} P(A | B_1, B_2, \dots, B_l) &\propto P(A)P(B_1 | A) \\ &P(B_2 | A) \dots P(B_l | A) = \\ &P(A) \prod_{i=1}^l P(B_i | A) \end{aligned} \quad (15)$$

这样  $l$  维概率密度函数估计就转化为  $l$  个一维概率密度函数估计问题, 极大地减少了数据量。

将属性  $B$  替换为根据上节筛选出的信号特征  $X_{i_k}$  ( $k = 1, 2, \dots, l$ ) 确定砂带磨损状态  $S$ , 根据

式(15), 可确定砂带处于各磨损状态的概率为

$$P(S | X_{i_1}, X_{i_2}, \dots, X_{i_k}) \propto P(S) \prod_{k=1}^l P(X_{i_k} | S) \quad (16)$$

其中:  $P(S | X_{i_1}, X_{i_2}, \dots, X_{i_k})$  为已知信号特征时的砂带磨损状态后验分布;  $P(S)$  为砂带磨损状态本身的先验分布;  $P(X_{i_k} | S)$  为在不同砂带磨损状态下, 信号特征的条件分布; 砂带磨损状态  $S$  为离散变量, 可通过历史数据样本统计得到其频率分布作为砂带磨损状态的概率分布  $P(S)$ ;  $X_{i_k}$  为数值型连续变量;  $P(X_{i_k} | S)$  为其条件概念密度函数, 文中采用核密度估计方法确定。

文中核函数采用高斯核函数, 模型如下

$$\hat{p}(x) = \frac{1}{N} \sum_{i=1}^N \frac{1}{(\pi h^2)^{\frac{1}{2}}} \exp\left(-\frac{(x - X_i)(x - X_i)}{2h^2}\right) \quad (17)$$

其中:  $X_i$  为历史数据样本点;  $h$  为高斯核函数的方差, 影响数据点  $X_i$  对空间的作用范围。

$P(S)$  与  $P(X_{i_k} | S)$  通过历史数据得到后, 可利用在线测量、提取得到的信号特征  $X_{i_k}$  更新砂带磨削状态先验分布  $P(S)$ , 得到砂带磨损状态后验分布  $P(S | X_{i_1}, X_{i_2}, \dots, X_{i_k})$ , 将符合式(18)的磨损状态作为砂带磨损状态识别结果

$$s = \underset{s_j}{\operatorname{argmax}} \{P(s_j | X_{i_1}, X_{i_2}, \dots, X_{i_k})\} \quad (18)$$

## 2 砂带磨损状态监测实验

实验采用砂带磨削加工中较为常用的恒压磨削方式, 连续测量砂带磨损全生命周期过程的声信号、电流信号、砂带磨损质量以及砂带表面图像。实验装置如图1所示, 砂带的速度可以在  $0 \sim 35$  m/s 内调节, 压强可在  $0 \sim 8 \times 10^5$  Pa 范围内调节。声信号与电流信号通过传感器测量, 经过采集卡采样后送入工作站存储, 传声器采用声科测自由场传声器 MP21, 布置在磨削区域侧面 35 mm 处, 电流传感器采用霍尔效应传感器, 采集卡采用丹麦 BK 公司的 12 通道采集模块, 型号为 3053-B-120。实验中通过显微镜观察砂带磨损过程中的形貌, 砂带质量通过精度为 0.1 g 的称重天平测量。

实验的砂带选用 Cubiron II 陶瓷磨料砂带, 粒度号为 P36, 磨削工件材料为锰钢, 采用的实验参数如表1所示, 实验流程如下: 磨削前测量砂带质量与表面形貌, 磨削时记录磨削过程的声信号, 每隔 60 s 测量砂带剩余质量, 利用显微镜观察砂带形貌, 不断重复共进行 33 次磨削, 即砂带磨削了 33 min。

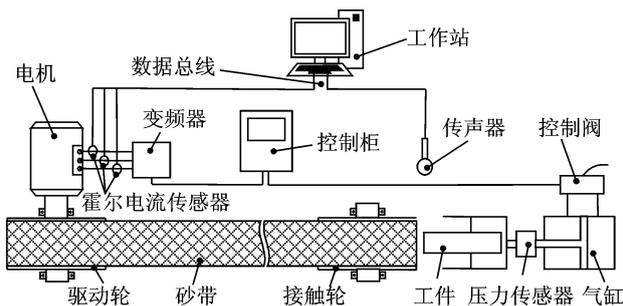


图1 实验装置示意图

Fig. 1 Schematic diagram of experimental devices

表1 实验参数表

Tab. 1 Experimental parameters table

名称	数值
砂带线速度/( $m \cdot s^{-1}$ )	21
气缸压强/MPa	0.3
工件尺寸/( $mm \cdot mm$ )	14×20
采样频率/Hz	65 536

### 3 实验结果分析

#### 3.1 砂带磨损过程分析及信号特征提取

砂带全生命周期的磨损质量与表面图像如图2所示,砂带表面图像能够直观观察砂带磨粒磨损,通过砂带质量能够定量反映砂带表面磨粒磨损程度。由图2可知,在初期快速磨损阶段,由于参与磨削的磨粒个数较少,单颗磨粒承受的磨削力大,磨粒易发生破碎与脱落,使得砂带质量急剧减小;在稳定磨损阶段,由于参与磨削的磨粒数较多,单颗磨粒承受载荷小,磨粒破碎较少,主要发生磨耗磨损,质量变化较慢。

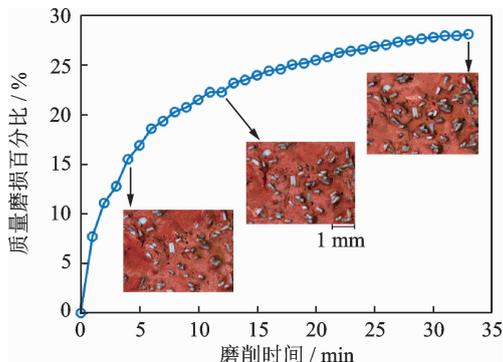


图2 砂带磨损过程图

Fig. 2 Abrasive belt wear process

磨削声信号与电流信号的绝对值均值随砂带磨损的变化趋势如图3所示。随着砂带不断磨损,砂带表面逐渐变平,在恒定压力作用下,磨削力减小,电流信号也随之减小。砂带磨损过程中,磨粒会发

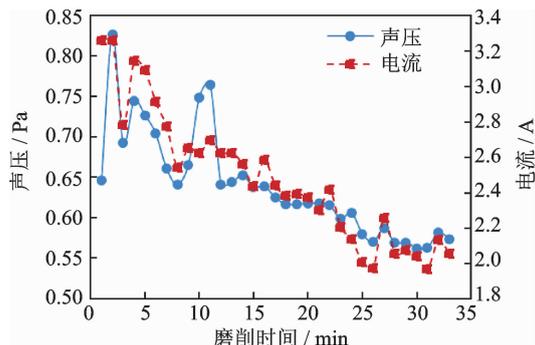


图3 声压与电流随砂带磨损变化趋势图

Fig. 3 Change trend of sound pressure and current with abrasive belt wear

生破碎与磨耗,使得磨粒顶部形成不断增大的磨钝小平面,砂带与工件的接触面积增大,在砂带与工件高速相对运动时产生的磨削力的动态分量减小,再加上磨削力的减小,磨削机构振动减弱,声信号随之逐渐减小。两者变化趋势接近,但是局部的波动并不相同,比如9~12 min 声信号受到较大的噪声干扰,但是电流信号比较稳定,22~27 min 时电流信号受到了比较大的干扰,但是声信号能够保持稳定,说明两者的干扰来源不同,在信息融合中具有较强的互补性。根据砂带磨削时间,将砂带磨损状态分为锋利期(0~10 min)、稳定磨损期(11~25 min)、严重磨损期(26~33 min)。

为尽可能多地从砂带磨削原始声信号与电流信号中提取出砂带磨损信息,分别计算磨削声信号的绝对值均值、方差、均方根值、峭度系数、偏度系数、峰值及7层小波包分解后各频带能量占比,磨削电流信号的绝对值均值、方差、均方根值、峭度系数及偏度系数、峰值等共140个特征作为备选特征。信号特征随砂带磨损的变化趋势如图4所示,图中纵坐标为特征序号,无量纲。随着砂带磨损,大多数信号特征呈现规律性的变化,小波包分解后中高频频带能量逐渐减小,说明随着砂带磨粒钝化,切削作用逐渐减弱,切削材料时造成的振动逐渐减弱。

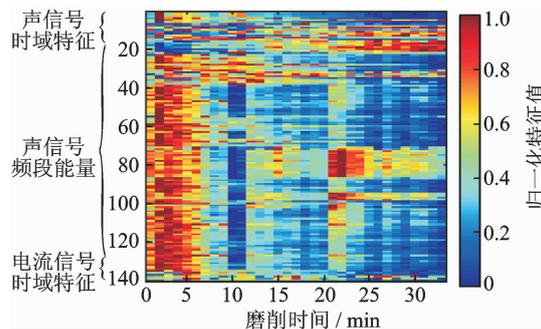


图4 声信号与电流信号特征随砂带磨损的变化趋势

Fig. 4 Change trend of acoustic signal and current signal features with abrasive belt wear

### 3.2 砂带磨损信号特征选择与磨损状态识别

在进行砂带磨损信号特征选择时,需要确定输入特征数量  $l$  与调节系数  $\alpha$ ,这两个参数的取值与实际的信号特征有关,很难直接选定,因此通过网格搜索的方法计算了不同输入特征数量与调节系数的磨损状态识别错误率,识别错误率随特征数量  $l$  与调节系数  $\alpha$  的变化结果如图 5 所示。当输入特征数量为 1 时,此时砂带磨损状态识别错误率较大,最大为 34.4%;当输入特征数量为 13,调节系数为 0.8 时,此时识别错误率最小为 16.2%。特征数量  $l$  与调节系数  $\alpha$  之间存在较强的交互作用,当采用较少的输入特征时,需采用较小的调节系数,挑选出可分性较强的特征,当采用较多的特征时,需采用较大的调节系数,使得特征之间的相关性较弱,冗余的信息量较少。由于设备结构固定,砂带磨损程度与信号特征间的关系也不会发生变化,因此只需做一次特征选择确定贝叶斯方法的输入特征,在磨削过程的实时监测阶段,直接使用选择后的特征识别砂带磨损状态。

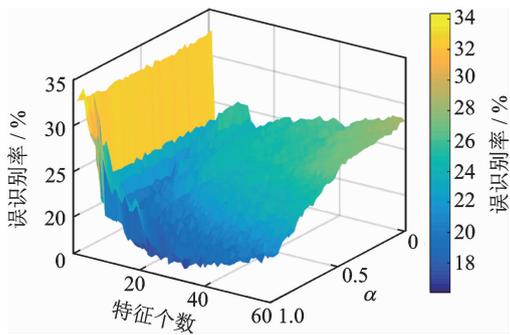


图 5 误识别率变化图

Fig. 5 The change of false recognition rate

采用不同调节系数,砂带磨损状态识别错误率随输入特征个数的变化如图 6 所示。实线代表不同输入特征数量下的砂带磨损状态识别错误率最小值,采用可分性与相关性相结合的特征选择方法,当调节系数为 0 时,此时相当于只根据可分性选择输入特征,错误识别率均高于根据可分性与相关性相结合进行特征选择的结果,总体上高 8% 左右。当调节系数为 1 时,此时需要较多的输入特征才能使识别效果较好,并且当输入特征个数较多时,识别错误率非常接近最低识别错误率,因此当受限于计算能力,不能采用网格搜索确定输入特征个数及调节系数时,可以采用较大的输入特征个数与较大调节系数,此时的识别效果较好。

通过网格搜索,确定当输入特征数量为 13,调

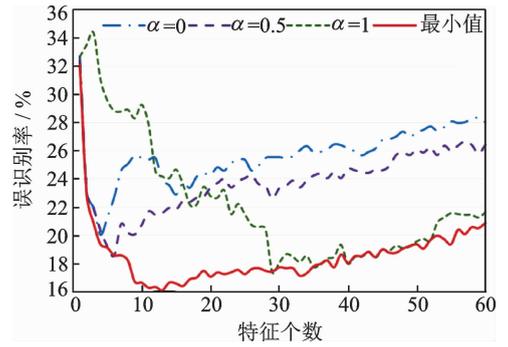


图 6 误识别率随特征数量变化图

Fig. 6 The change of false recognition rate with feature amount

节系数为 0.8 时,砂带磨损状态识别错误率最低为 16.2%,具体的识别结果如表 2 所示。第 1 行代表砂带真实磨损状态为锋利时的砂带有 88.6% 被识别为锋利,11.2% 被识别为稳定磨损,0.2% 被识别为严重磨损;第 2,3 行分别代表稳定磨损与严重磨损的识别结果,当砂带处于严重磨损状态时的识别准确率达到 91%,识别效果较好。

表 2 砂带磨损状态识别结果表

Tab. 2 Recognition result of wear state of abrasive belt table

实际状态	预 测 / %		
	锋利	稳定磨损	严重磨损
锋利	88.6	11.2	0.2
稳定磨损	10.8	76.7	12.5
严重磨损	0	9.0	91.0

根据砂带磨损时间将砂带划分为 3 个磨损状态,由于划分的状态数量有限,实际上相同磨损状态的砂带的磨损程度并不完全相同,不同磨损时间砂带磨损状态的识别结果如图 7 所示。一方面新砂带表面磨粒被胶层覆盖,另一方面少数出刃高度较大的磨粒与工件接触易发生脱落与破碎,使得新砂带

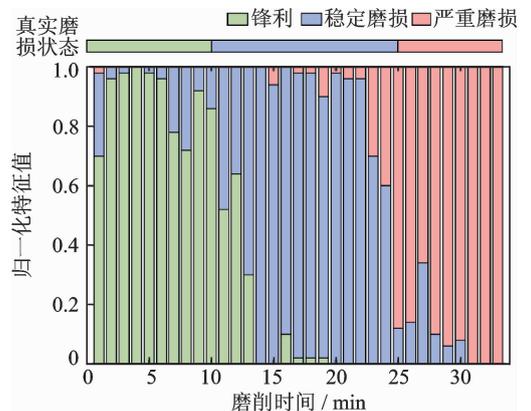


图 7 砂带磨损状态识别结果

Fig. 7 Recognition result of wear state of abrasive belt at different wear time

在最初使用时并不是最锋利的,因此磨削时间为1 min时的砂带只有70%被识别为锋利期。识别错误率较高的部分主要分布在锋利与稳定磨损的过渡期(9~12 min)以及稳定磨损与严重磨损的过渡期(23~27 min),这部分砂带的磨损状态实际上介于相邻的两个磨损状态之间,难以精确识别。在砂带各磨损状态的典型磨损时间段,如2~6,14~23,29~33 min,其磨损状态的识别准确率均在90%以上。

## 4 结束语

从声信号与电流信号中提取出的时域与频域特征蕴含丰富的砂带磨损状态信息,两种信号的干扰源不同,具有较强的互补性,通过信息融合能够增强系统鲁棒性,并且两种信号的监测装置均安装方便、成本低,应用于实际生产的可行性较强。FDR与互信息相结合的方法能够筛选出可分性好且特征间相关性较弱的信号特征集合,提高了砂带磨损状态识别准确率8%左右。基于贝叶斯的砂带磨损状态识别方法的准确率达到83.8%,其中大部分识别错误的情况发生在相邻两种砂带磨损状态的过渡阶段,在砂带各磨损状态的典型磨损时间段如2~6,14~23,29~33 min,其磨损状态的识别准确率均在90%以上,说明笔者提出的方法能够很好地融合声信号与电流信号信息,较为准确地识别砂带磨损状态。

### 参 考 文 献

- [1] 黄云,黄智.现代砂带磨削技术及工程应用[M].重庆:重庆大学出版社,2009:7-8.
- [2] PANDIYAN V, CAESARENDRA W, TJAHO-WIDODO T, et al. In-process tool condition monitoring in compliant abrasive belt grinding process using support vector machine and genetic algorithm [J]. Journal of Manufacturing Processes, 2018, 31: 199-213.
- [3] LEMASTER R L, DORNFELD D A. The use of acoustic emission to monitor an abrasive machining process[C] // Proceedings of the 11th International Wood Machining Seminar. Honne; Norway Wood Processing Association, 1993: 231-245.
- [4] CARRANO A L, VORA B S, SAHIN F, et al. Monitoring of abrasive loading for optimal belt cleaning or replacement. [J]. Forest Products Journal, 2007, 57(5): 78.
- [5] SALONI D E, LEMASTER R, JACKSON S. Control

system evaluation and implementation for the abrasive machining process on wood[J]. Bioresources, 2011, 6(3): 2763-2775.

- [6] 叶浩浩.基于图像处理的砂带磨削性能监测实验研究[D].厦门:华侨大学,2017.
- [7] SALGADO D R, ALONSO F J. An approach based on current and sound signals for in-process tool wear monitoring[J]. International Journal of Machine Tools & Manufacture, 2007, 47(14): 2140-2152.
- [8] GHOSH N, RAVI Y B, PATRA A, et al. Estimation of tool wear during CNC milling using neural network-based sensor fusion[J]. Mechanical Systems & Signal Processing, 2007, 21(1): 466-479.
- [9] KOPAC J, ŠALI S. Tool wear monitoring during the turning process[J]. Journal of Materials Processing Technology, 2001, 113(1/3): 312-316.
- [10] AIC S, SUN Y J, HE G W, et al. The milling tool wear monitoring using the acoustic spectrum[J]. International Journal of Advanced Manufacturing Technology, 2012, 61(5/8): 457-463.
- [11] RAFEZI H, BEHZAD M, AKBARI J. Time domain and frequency spectrum analysis of soundsignal for drill wear detection[J]. International Journal of Computer & Electrical Engineering, 2012, 4(5): 722-725.
- [12] HOSOKAWA A, MASHIMO K, YAMADA K, et al. Evaluation of grinding wheel surface by means of grinding sound discrimination[J]. Jsme International Journal, 2004, 47(1): 52-58.
- [13] UBHAYARATNE I, PEREIRA M P, XIANG Y, et al. Audio signal analysis for tool wear monitoring in sheet metal stamping[J]. Mechanical Systems & Signal Processing, 2017, 85: 809-826.
- [14] 李娟莉,王健,杨兆建.基于三层信息融合的提升机制动系统故障诊断[J].振动、测试与诊断,2018,38(2): 407-412.
- LI Juanli, WANG Jian, YANG Zhaojian. Fault diagnosis of mine hoist braking system based on three layers information fusion [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(2): 407-412. (in Chinese)
- [15] KARANDIKAR J, MCLEAY T, TURNER S, et al. Tool wear monitoring using naïve Bayes classifiers[J]. International Journal of Advanced Manufacturing Technology, 2015, 77(9/12): 1613-1626.



**第一作者简介:**程灿,男,1992年7月生,博士生。主要研究方向为砂带磨损状态识别。曾发表《Deep convolutional neural network-based in-process tool condition monitoring in abrasive belt grinding》(《Computers in Industry》2019, Vol. 106)等论文。  
E-mail: 15116328@bjtu.edu.cn