doi:10.3772/j.issn.1002-0470.2023.03.012

# 基于 AdaBoost 与 LCA 的滚珠丝杠副状态识别方法<sup>①</sup>

文 娟②

(浙江工业大学机械工程学院 杭州 310023) (恒丰泰精密机械股份有限公司 温州 325000)

摘 要 作为数控机床的关键部件,滚珠丝杠副的工作状态关系到整个机床的性能与产品质量。因此,对滚珠丝杠副进行状态监测,准确识别其状态能够提高机床的可靠性与安全性,并降低生产成本。为了提高状态识别精度,提出基于 AdaBoost 与局部类精度 (LCA)的滚珠丝杠副状态识别方法。首先,利用历史失效数据与 AdaBoost 算法生成一个包含多个分类器的分类器集合。然后,针对未知状态的滚珠丝杠副,根据当前监测信号的特征,利用 LCA 算法从分类器集合中选出最合适的分类器对其当前状态进行识别。实验结果表明,所提出方法能够有效地识别滚珠丝杠副状态,其状态识别准确率高于传统方法,达到 96.3%。

关键词 状态监测;滚珠丝杠副;动态分类器选择;AdaBoost;局部类精度(LCA)

# 0 引言

滚珠丝杠副是一种将旋转运动转化为直线运动的设备<sup>[1]</sup>,是数控机床的关键部件。一旦滚珠丝杠副出现异常,则会降低整个数控机床的性能,影响加工质量,甚至造成机床停机,并带来安全隐患。因此,及时准确地识别滚珠丝杠副状态,并根据识别结果制定维护维修计划,对于提高整个数控机床的可靠性、安全性与降低生产成本具有重要意义<sup>[23]</sup>。

现有的滚珠丝杠副状态监测方法主要有 2 种,即信号分析方法与智能化方法。信号分析方法利用信号分析技术分析滚珠丝杠副的状态监测信号,再结合先验知识判断滚珠丝杠副的状态。Tsai 等人[1]利用 Vold-Kalman 滤波检测滚珠经过频率的变化,从而识别滚珠丝杠副的状态变化。Feng 与 Pan<sup>[4]</sup>利用谱分析检测滚珠丝杠副的预紧力缺失。这类方法能够有效地检测滚珠丝杠副的状态变化,但需要检测人员具有一定的专业知识,且其判断过程需要一

定的时间。而智能化状态监测方法利用历史状态监测数据与智能算法构建状态识别模型,判断滚珠丝杠副的健康状态。Jin 等人<sup>[5]</sup>利用自组织映射、马氏距离以及混合高斯模型评估滚珠丝杠的状态。张磊等人<sup>[6]</sup>提出一种基于神经网络的滚珠丝杠故障诊断方法。吴希曦等人<sup>[7]</sup>利用小波包和超球面支持向量机实现丝杠的状态识别。Huang 与 Hsieh<sup>[8]</sup>利用内置信号表征滚珠丝杠副的健康状态,并采用支持向量机作为分类器实现状态识别。这类方法能够快速自动地识别滚珠丝杠副的状态,因而更适用于实际应用。

智能化状态监测方法中,分类器即智能算法的性能在很大程度上影响着状态识别的准确度。而集成多个分类器能够弥补单个分类器的缺陷,提高分类性能<sup>[9-11]</sup>。AdaBoost<sup>[12-13]</sup>是一种有效的分类器集成算法,该方法通过迭代的方式生成多个分类器,在对样本进行分类时,采用所有分类器对其进行分类,综合所有分类器的结果得到样本的类别。焦晓璇等人<sup>[14]</sup>提出了一种基于 AdaBoost 算法的机载燃油泵故障诊断方法,取得了比单个分类器更好的分类结果。姚培

① 国家自然科学基金(51475425)资助项目。

② 女,1990 年生,博士;研究方向:机械故障诊断与寿命预测;联系人,Email:juanwen@ zjut. edu. cn。(收稿日期:2021-07-19)

等人<sup>[15]</sup>利用 AdaBoost 算法集成多个支持向量机,用于滚动轴承的故障诊断。卓鹏程等人<sup>[16]</sup>针对噪声干扰下的轴承健康监测问题,提出了一种输出隐含反馈(output hidden feedback,OHF)Elman-AdaBoost 算法,利用 AdaBoost 算法集成多个 OHF Elman 神经网络,组成一个强回归器,提升了故障诊断的准确率。

AdaBoost 算法的训练过程中,训练每个分类器 时各个训练样本的权值不一样,因而每个分类器的 侧重不同。然而不同测试样本所涉及的分类难点通 常有一定的差异性,因此,针对不同的测试样本,选 择最适合该样本的分类器对其进行分类更为合理, 能够取得更好的分类效果,这一过程被称为分类器 的动态选择。局部类精度(local class accuracy, LCA)是一种简单有效的分类器动态选择方法[17]。 该算法采用每个分类器在测试样本邻域上的分类准 确率衡量其对于指定测试样本的竞争力,从而选择 局部分类精度最高的分类器对测试样本进行分 类[18]。当滚珠丝杠副处于不同状态时,其即时信号 特征所涉及的分类难点不同。因此,本文提出一种 基于 AdaBoost 与 LCA 的滚珠丝杠副状态识别方法. 利用 AdaBoost 算法生成多个分类器,再利用 LCA 算 法从上述分类器中选择一个最佳分类器对滚珠丝杠 副的未知状态进行识别。

# 1 基于 AdaBoost 与 LCA 的滚珠丝杠 副状态识别方法

本文提出的滚珠丝杠副状态识别方法如图 1 所

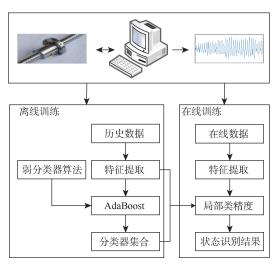


图 1 提出方法框架

示,包括离线训练和在线监测2部分。首先,利用采集到的历史数据与 AdaBoost 算法生成多分类器集合。然后,针对运行中未知状态的滚珠丝杠副,根据当前监测信号的特征,利用 LCA 算法从分类器集合中选择出最为合适的分类器识别滚珠丝杠副的当前状态。第2节与第3节将分别对分类器集合的生成与分类器的动态选择进行详细介绍。

# 2 基于 AdaBoost 的分类器集合生成

误差反向传播网络(back propagation network, BPN)是一种常用且有效的模式识别方法,被广泛应用于机械故障诊断与寿命预测中[19-21]。因此,本文选择 BPN 作为分类器算法。离线训练中,首先利用信号处理方法对历史数据进行处理,获取信号特征;然后利用 AdaBoost 算法生成多个 BPN 分类器,其过程如图 2 所示,具体实现步骤如下。

步骤 1 给定训练集  $X = \{(x_1, c_1), (x_2, c_2), \dots, (x_n, c_n)\}$ 与迭代次数 M, 其中  $x_i \in R^D$ 为训练集的特征向量,  $c_i$ 为  $x_i$ 所对应的标签, 其值取自一个有限的集合, 如 $\{1, 2, h, \dots, H\}$ 。

步骤 2 初始化训练样本权值  $w_i = 1/n, i = 1, 2, \dots, n_o$ 

- (1)利用各训练样本的当前权值 $\{w_i\}_{i=1}^n$ 对训练集 X进行重采样得到一个样本数为 n 的样本集  $X_m$ ;
- (2)利用样本集  $X_m$ 训练 BPN 分类器,其目标函数为期望输出与实际输出之间的差异,得到第 m 个分类器  $T_m$ ;
- (3)计算分类器  $T_m$ 对于训练集 X 的权值预测误差:

$$e_m = \sum_{i=1}^n w_i (c_i \neq T_m(\boldsymbol{x}_i))$$
 (1)

如果  $e_m > 0.5$ ,则返回(1),重新训练  $T_m$ ,反之,则继续后续步骤:

(4)计算分类器  $T_m$ 的权值:

$$\alpha_m = \log \frac{1 - e_m}{e_m} \tag{2}$$

(5)更新训练集样本权值:

$$w_{i} = w_{i} \cdot \exp(\alpha_{m} \cdot (c_{i} \neq T_{m}(x_{i})))$$
(6) 对权值进行归一化处理:  $w_{i} = w_{i}/Z, Z = m_{i}$ 

$$\sum_{i=1}^{n} w_{i} \circ$$

生成多个 BPN 后,原始 AdaBoost 算法通过联合 这些 BPN,组成一个性能优于单个 BPN 的强分类 器。具体地,当对测试样本 t 进行分类时,其输出为

$$C(t) = \underset{h}{\operatorname{argmax}} \sum_{m=1}^{M} \alpha_m \cdot (T_m(t) = h) \quad (4)$$

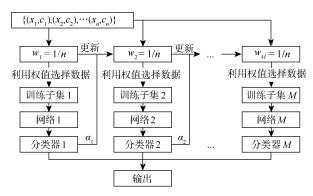


图 2 BPN 集合的生成过程

# 3 基于 LCA 的分类器动态选择

由第2节中BPN集合的生成过程可知,集合中 不同 BPN 分类器的侧重不同,即专注于不同的分类 难点。当滚珠丝杠副处于不同状态时,其即时信号 特征所涉及的分类难点不同。因此,在线监测过程 中,利用LCA 算法从BPN 集合中选择一个最合适 的分类器对滚珠丝杠副的当前状态进行判断比采用 式(4)所示的分类器联合方式进行识别更为合理。 此外,训练样本中可能存在异常样本,这些异常样本 在 AdaBoost 的迭代过程中可能会获得较高权重,进 而影响强分类器的性能。引入 LCA 后,在线监测过 程中,就能根据特定测试样本选择最合适的分类器 进行状态识别。当某一子分类器对于与测试样本相 似程度较高的训练样本具有较高的分类准确率时, 这一子分类器就很可能被选来对测试样本的状态进 行鉴别。通常,测试样本与异常样本的相似程度较 低,因而使用 LCA 时,选择对于异常样本具有较高 准确率的子分类器的概率较小,从而在一定程度上 避免了异常样本对于滚珠丝杠副状态识别结果的影

响。利用 LCA 算法判断滚珠丝杠副状态的具体实现步骤如下所述。

步骤 1 输入标签种类 $\{1,2,h,\cdots,H\}$ , BPN 集合 T, 训练集 X, 邻域尺寸 K。

**步骤 2** 对于当前待分类样本 t,进行以下操作。

使用所有分类器对t进行分类,如果所有分类器的输出标签相同,则返回该标签作为样本t的类别;反之,则针对每个分类器 $T_m$ ,采用以下步骤计算其竞争力,选出最合适的分类器。

- (1)采用分类器  $T_m$ 预测样本 t 的类别,得到其标签  $\omega_i = T_m(t)$ ;
- (2)从训练集 X 中找到样本 t 的邻域(最常用的邻域定义方法是通过计算测试样本与验证集或训练集的距离寻找该测试样本的 K 个近邻作为其邻域),采用  $T_m$ 对邻域中的样本进行分类,得到其标签。从邻域中选择标签与  $\omega_j$ 相同的样本,使用  $\psi$  代表这些样本所定义的域;
- (3)计算分类器  $T_m$ 在  $\psi$  上的分类正确率 LCA (m,t);

选择最适合样本t的分类器 $T_{i}^{*}$ :

$$T_{\iota}^{*} = \operatorname{argmax} \left\{ \operatorname{LCA}(m, t) \right\}$$
 (5)

使用分类器  $T_i^*$  对 t 进行分类,从而识别出滚珠 丝杠副的当前状态。

### 4 实验验证

为了说明本文所提方法的有效性与优越性,本 节采用实验中采集到的滚珠丝杠副状态监测数据对 其进行验证。

#### 4.1 实验数据获取

通常,滚珠丝杠副具有较高的可靠性,因此,正常情况下其寿命较长,需要很长时间才能采集到其失效数据。为了在较短时间获得足够的状态监测数据,采用文献[22]中如图 3 所示的滚珠丝杠副加速性能退化实验系统,开展滚珠丝杠副加速寿命实验。该实验系统通过增加滚珠丝杠副负载,加速其性能退化,使其在较短时间失效。为了获得滚珠丝杠副性能退化过程中的状态监测数据,在丝杠螺母上安

装了一个加速度传感器,采集其振动信号。加速寿命实验中,从滚珠丝杠副正常状态开始采集其状态监测信号,采样频率为 5 kHz,每隔 30 min 采集一次信号,直至滚珠丝杠副失效。



图 3 实验系统

#### 4.2 特征提取

实验中采集到的振动信号,需采用信号处理方法进行处理,并提取能够代表滚珠丝杠副工作状态的特征向量,用于后续状态识别过程。为了减弱数据异常点及高频噪声的影响,本文选用了不同种类的40个特征,以从多个方面反映信号的特性。如表1 所示,选取特征包括10个时域特征、28个时频域特征以及2个三角函数特征[23]。

表 1 信号特征

类型     特征       Y1:标准差     Y6:峰值因子       Y2:峰-峰值     Y7:脉冲因子       时域特征     Y3:平均绝对值     Y8:偏度       Y4:均方根     Y9:峭度       Y5:波形因子     Y10:裕度因子					
Y2:峰-峰值 Y7:脉冲因子 时域特征 Y3:平均绝对值 Y8:偏度 Y4:均方根 Y9:峭度 Y5:波形因子 Y10:裕度因子	类型	特征			
时域特征 Y3:平均绝对值 Y8:偏度 Y4:均方根 Y9:峭度 Y5:波形因子 Y10:裕度因子		Y1:标准差	Y6:峰值因子		
Y4:均方根 Y9:峭度 Y5:波形因子 Y10:裕度因子	时域特征	Y2:峰-峰值	Y7:脉冲因子		
Y5:波形因子 Y10:裕度因子		Y3:平均绝对值	Y8:偏度		
		Y4:均方根	Y9:峭度		
4 1 1 1 4 des III 4 4 de H		Y5:波形因子	Y10:裕度因子		
Y11~Y18:8 个小波包频带的能量		Y11~Y18:8个小波包频带的能量			
时短域特征 Y19~Y26:8 个小波包频带的能量比	时频域特征	Y19~Y26:8个小波包频带的能量比			
Y27~Y32:6 个本征模态函数的瞬时能量		Y27~Y32:6个本征模态函数的瞬时能量			
Y33~Y38:6 个本征模态函数的瞬时能量比		Y33~Y38:6 个本征模	态函数的瞬时能量比		
三角函数特征 Y39. 反双曲线正弦标准差	<b>二角</b> 函粉蛙紅	Y39:反双曲线正弦标?	住差		
三用函数付值 Y40:反正切标准差	二用函数行任	Y40:反正切标准差			

其中,时频域特征包括采用小波包变换对信号进行3层分解得到的8个小波包系数的能量与能量比,即8个小波包频带的能量与能量比。同时还有利用经验模态分解对信号进行处理得到的前6个本征模态函数的瞬时能量与瞬时能量比,其计算公式

分别如式(6)和(7)所示[24]。

$$E_i = \sum_{n=1}^{N} (n \triangle t) (f_i(n \triangle t))^2$$
 (6)

$$E = (E_1, E_2, \dots, E_6) / \sum_{i} E_i \tag{7}$$

式中,N 为信号样本点数, $\Delta t$  是采样点之间的间隔时间, $f_i$ ( $i=1,2,\cdots,6$ )为第i个本征模态函数。

此外,分别利用反双曲线正弦函数与反正切函数对原始信号进行变换,并求取 2 个变换后序列的标准差作为特征,分别称为反双曲线正弦标准差(standard deviation of inverse hyperbolic sine, SD of IHS)以及反双曲正切标准差(standard deviation of inverse tangent, SD of IT),其计算公式如式(8)所示。

$$\begin{cases} SD \text{ of } IHS = \sigma \left( \log \left( x_n + \sqrt{x_n^2 + 1} \right) \right) \\ SD \text{ of } IT = \sigma \left( \frac{1}{2} \log \left( \frac{1 + x_n}{1 - x_n} \right) \right) \end{cases}$$
(8)

式中, $x_n(n=1,2,\dots,N)$ 为信号序列。

#### 4.3 状态识别

#### 4.3.1 滚珠丝杠副状态识别

滚珠丝杠副的全寿命周期经历了正常、退化以及失效3个阶段。因此,本文将滚珠丝杠副的状态分为这3个状态,并采用图1所示方法进行状态识别。实现过程中,共选取了100组正常状态样本,77组退化状态样本,40组失效状态样本。其中,每种状态使用50%的数据作为训练数据,其余50%的数据作为测试数据。

数据准备好后,利用 AdaBoost 方法与训练数据 生成一个数量为 10 的 BPN 集合。训练过程中,分 类器数量不同时,采用原始 AdaBoost 算法,即利用 式(4)得到训练误差与测试误差,如图 4 所示。由 图 4 可知,随着迭代次数的增加、分类器数量的增 多,训练误差和测试误差都随之减小。因此,相对于 单个 BPN 分类器,采用 AdaBoost 集成多个 BPN 的 方法具有更好的泛化能力,能够提高滚珠丝杠副的 状态识别精度。

生成 BPN 集合后,便可以结合 LCA 算法通过第 3 节描述的步骤对测试数据进行分类,实现过程中采用邻域尺寸 K = 1 进行分类器选择。表 2 为不同方法的测试结果,表中 BPN 为 10 个 BPN 分类器中分类效果最好的分类器的测试结果,AdaBoost 为

原始 AdaBoost 算法的结果。由表 2 可知,10 个 BPN 中,分类效果最好的 BPN 分类准确率为 81.84%,采用 AdaBoost 联合多个分类器分类能够提高分类精度,达到 88.88%,本文提出的方法测试结果最好,识别精度达到 93.52%。

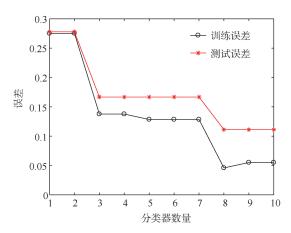


图 4 不同分类器数量时的识别误差

表 2 不同方法的测试结果

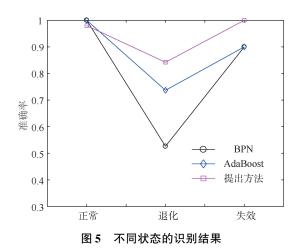
方法	BPN	AdaBoost	本文方法
准确率/%	81.84	88.88	93.52

#### 4.3.2 状态识别结果分析

图 5 为不同方法对于滚珠丝杠副不同状态的识 别准确率。由图 5 可知,单个 BPN 分类器与 Ada-Boost 算法能够准确地识别出正常状态,精度能够达 到 100%,好于提出方法对于正常状态的识别准确 率 98%。同时,这 2 种方法对于失效状态的识别率 也能达到90%。但单个BPN分类器对于退化状态 的识别效果不理想,识别率仅为52.63%,采用 Ada-Boost 算法能够提高退化状态的识别精度,达到 73.68%,而本文提出方法能够进一步提高其识别准 确率,达到84.21%。这可能是因为当滚珠丝杠副 系统处于正常状态时,其工作较为稳定,因此振动信 号也较为稳定,没有大的波动。同理,当滚珠丝杠副 系统失效时,其振动信号也较为稳定。但是在退化 过程中,随着退化程度的加深,滚珠丝杠副系统的状 态存在较大波动,因而导致其振动信号存在一定程 度上的变动,因此,对于退化状态的识别难度较大。

此外,本文提出的方法也能提高失效状态下的识别精度,提升至100%。虽然提出方法对于正常状态

的识别精度略低于其他 2 种方法,但其对于退化状态和失效状态的识别率明显高于其他 2 种方法。状态监测过程中,可以接受对正常状态存在较小概率的误判,但对于退化状态与失效状态的准确判断及其重要,关系到设备的可靠性、安全性以及维修成本。因此,所提方法的性能优于单个 BPN 分类器与 Ada-Boost 算法,更适用于滚珠丝杠副的状态识别。



为了进一步说明本文提出方法的优点,并更进一步探索滚珠丝杠副退化过程的本质特性,表3、4和5分别列出了上述3种方法对于滚珠丝杠副不同退化状态的识别结果。通过这3个表格可知,当分类器的性能不佳时,退化状态很容易被认定为正常状态。如使用BPN进行状态识别时,有44.74%的退化状态样本被确定为正常状态;使用AdaBoost集成多个BPN时,有26.32%的退化样本被识别为正常状态;而使用提出方法进行状态识别时,虽然能够进一步降低退化状态的误判水平,但仍有13.16%的退化样本被识别成正常状态。这是因为在滚珠丝杠副系统退化初期,由于退化程度较小,退化状态在振动信号上表现得并不明显,与正常状态的相似性大,因此,容易将此时的退化状态识别为正常。

表 3 BPN 的识别结果

	正常	退化	失效	准确率
正常	100.00%	0.00%	0.00%	100.00%
退化	44.74%	52.63%	2.63%	52.63%
失效	5.00%	5.00%	90.00%	90.00%
准确率	100.00%	52.63%	90.00%	81.84%

表 4	AdaBoost	的识别结果

	正常	退化	失效	准确率
正常	100.00%	0.00%	0.00%	100.00%
退化	26.32%	73.68%	0.00%	73.68%
失效	5.00%	5.00%	90.00%	90.00%
准确率	100.00%	73.68%	90.00%	88.88%

表 5 本文方法的识别结果

	正常	退化	失效	准确率
正常	98.00%	2.00%	0.00%	98.00%
退化	13.16%	84.21%	2.63%	84.21%
失效	0.00%	0.00%	100.00%	100.00%
准确率	98.00%	84.21%	100.00%	93.52%

#### 4.3.3 邻域尺寸大小的影响

使用 LCA 算法进行分类器选择时,邻域尺寸,也就是测试样本近邻的数量 K 会影响分类结果。为了研究邻域尺寸对滚珠丝杠副状态识别精度的影响,取  $K=1\sim30$ ,分别对测试样本进行状态判定,不同邻域尺寸时的识别精度如图 6 所示。由图 6 可知,最初滚珠丝杠副的识别精度随着邻域尺寸的增大而升高,在 K=3 时达到最大值,为 96.3%,并且在 K=4 及 K=5 时,保持不变;当 K=6 时,识别精度降低到 94.44%,并在 K=7 及 K=8 时保持不变;当 K=9 时,精度再次升高到 95.37%,并在 K=10 时保持不变;当 K=11 时,精度再次下降至 94.44%;此后直至 K=30,识别精度一直保持不变。由上述分析可知,邻域尺寸的大小会在一定程度上影响滚珠丝杠副的退化状态识别精度,但其准确率不是单纯地随着测试样本近邻数量的增多而增大.

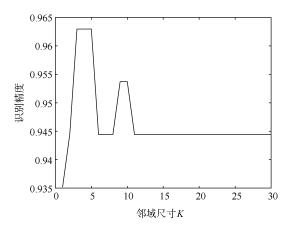


图 6 不同近邻数量 $(1 \le K \le 30)$ 时的识别精度

存在一定的波动性。因此,在实际应用中,需要通过 实验来确定最优的邻域尺寸,以保证滚珠丝杠副的 高精度状态识别效果。

## 5 结论

为了准确地监测滚珠丝杠副的状态,提出一种基于 AdaBoost 与 LCA 的滚珠丝杠副状态识别方法。实验结果表明,本文所提方法能够准确有效地识别滚珠丝杠副的状态。通过实验分析,得出以下结论。

- (1)相对于单个分类器而言,采用 AdaBoost 算 法生成多个分类器,并结合多个分类器输出的方法 能够更好地识别滚珠丝杠副的状态,提高识别精度。
- (2)未知状态滚珠丝杠副的状态识别中,采用LCA算法进行分类器的动态选择比采用AdaBoost算法联合所有分类器进行类别预测更为合理,其识别准确率高于AdaBoost算法。且其邻域尺寸的大小会对识别结果有一定的影响,选择合适的近邻数量能够确保获得最佳的状态识别精度。
- (3)滚珠丝杠副的状态识别中,正常和失效 2 种状态比较容易识别,退化状态的识别难度较大,当 分类器的性能不佳时,退化状态容易被识别模型确 定为正常状态。

虽然提出方法能够取得较为理想的整体识别精度,但其对于滚珠丝杠副退化状态的识别准确率仍有待于进一步提高。因此,本文的下一步工作将研究如何更好地识别滚珠丝杠副的退化状态。

#### 参考文献

- [1] TSAI P C, CHENG C C, HWANG Y C. Ball screw preload loss detection using ball pass frequency [J]. Mechanical Systems and Signal Processing, 2014, 48 (1-2): 77-91.
- [2] AZAMFAR M, LI X, LEE J. Intelligent ball screw fault diagnosis using a deep domain adaptation methodology [J]. Mechanism and Machine Theory, 2020, 151: 103932.
- [3] SHAN P, LV H, YU L, et al. A multisensor data fusion method for ball screw fault diagnosis based on convolutional neural network with selected channels [J]. IEEE Sensors Journal, 2020, 20(14); 7896-7905.
- [4] FENG G H, PAN Y L. Investigation of ball screw preload variation based on dynamic modeling of a preload adjustable feed-drive system and spectrum analysis of ball-nuts

- sensed vibration signals[J]. International Journal of Machine Tools and Manufacture, 2012, 52(1): 85-96.
- [5] JIN W. A comparative study of fault detection and health assessment techniques for motion control mechanism[D]. Cincinnati: University of Cincinnati, 2014: 14-76.
- [6] 张磊, 赵晓光, 张爱瑜, 等. 小波包与神经网络在滚珠丝杠故障诊断中的应用[J]. 华中科技大学学报(自然科学版), 2011,39(S2): 430-432.
- [7] 吴希曦, 高宏力, 燕继明, 等. 基于超球面支持向量机的丝杠故障诊断技术[J]. 计算机集成制造系统, 2010,16(12): 2661-2667.
- [8] HUANG Y C, HSIEH Y K. Applying a support vector machine for hollow ball screw condition-based classification using feature extraction[J]. Proceedings of the Institution of Mechanical Engineers Part B Journal of Engineering Manufacture, 2020(3): 095440542095884.
- [9] Lei Y, He Z, Zi Y, et al. Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs [J]. Mechanical Systems and Signal Processing, 2007, 21(5): 2280-2294.
- [10] 陈永毅, 张丹, 薛焕新. 基于集合经验模态分解的滚动轴承智能故障诊断方法[J]. 高技术通讯, 2021, 31 (5): 559-568.
- [11] 艾鑫, 刘永阔, 蒋利平, 等. 基于 iForest-Adaboost 的 核电厂一回路故障诊断技术研究[J]. 核动力工程, 2020, 41(3): 208-213.
- [12] FREUND Y, SCHAPIRE R E. Experiments with a new boosting algorithm [C] // Proceedings of the 13th International Conference on Machine Learning (ICML'96). Bari: ECCAI, 1996: 148-156.
- [13] 吕雁飞, 侯子骄,张凯. 多分类 BP-AdaBoost 算法研究与应用[J]. 高技术通讯, 2015, 25(5): 437-444.
- [14] 焦晓璇,景博,黄以锋,等. 基于小波包 BP\_AdaBoost 算法的机载燃油泵故障诊断研究[J]. 仪器仪表学报, 2016, 37(9): 1978-1988.

- [15] 姚培, 王仲生, 姜洪开, 等. 局部保形映射和 Ada-Boost 方法在滚动轴承故障诊断中的应用[J]. 振动与冲击, 2013, 32(5): 144-148.
- [16] 卓鹏程, 夏唐斌, 郑美妹, 等. 基于 OHF Elman-Ada-Boost 算法的滚动轴承故障多时期诊断方法[J]. 振动与冲击, 2021, 40(6): 71-78.
- [17] BRITTO A S, SABOURIN R, OLIVEIRA L E. Dynamic selection of classifiers—a comprehensive review [J]. Pattern Recognition, 2014, 47(11): 3665-3680.
- [18] WOODS K, KEGELMEYER W P, BOWYER K. Combination of multiple classifiers using local accuracy estimates [J]. IEEE Transactions on Pattern Analysis and Machine intelligence, 1997, 19(4): 405-410.
- [19] TIAN Z. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring [J]. Journal of Intelligent Manufacturing, 2012, 23(2):227-237.
- [20] 刘家秀. 滚珠丝杠副故障诊断方法及试验研究[D]. 哈尔滨:哈尔滨工业大学机电工程学院, 2020: 47-67.
- [21] 高利民, 许庆阳, 李锋, 等. 基于 SOM-BP 混合神经网络的道岔设备退化状态研究 [J]. 中国铁道科学, 2020, 41(3): 50-58.
- [22] WEN J, GAO H. Degradation assessment for the ball screw with variational autoencoder and kernel density estimation[J]. Advances in Mechanical Engineering, 2018, 10(9): 168781401879726.
- [23] JAVED K, GOURIVEAU R, ZERHOUNI N, et al. Enabling health monitoring approach based on vibration data for accurate prognostics[J]. IEEE Transactions on Industrial Electronics, 2015, 62(1); 647-656.
- [24] BIN G F, GAO J J, LI X J, et al. Early fault diagnosis of rotating machinery based on wavelet packets—empirical mode decomposition feature extraction and neural network [J]. Mechanical Systems and Signal Processing, 2012, 27; 696-711.

# A novel approach for ball screw condition identification with AdaBoost and local class accuracy

#### WEN Juan

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023) (Hengfengtai Precision Machinery Co. Ltd., Wenzhou 325000)

#### **Abstract**

The ball screw is one of the important components of a numerical control tool, and its working condition is critical for the performance of the machine tool and the product quality. Therefore, identifying the health state of the ball screw accurately can enhance the reliability and safety of the entire machine tool and reduce the maintenance cost. To improve the condition recognition accuracy, a novel approach is proposed to identify the ball screw performance based on AdaBoost and local class accuracy(LCA). First, a classifier ensemble is created with AdaBoost according to the failure history data. Second, once the new condition monitoring data is obtained for ball screw in unknow state, the LCA is utilized to select the most suited classifier to recognize the current state of the ball screw. Experimental results show that the proposed method can identify the ball screw condition effectively with an accuracy of 96.3%, which is higher than the traditional techniques.

**Key words:** condition monitoring, ball screw, dynamic classifier selection, AdaBoost, local class accuracy (LCA)