基于振动信号的电主轴回转精度预测方法

陈代伟^{1,2}, 吴军^{1,2*}, 王立平^{1,2}, 梁建红³, 宫秀梅⁴, 孔维森⁵

1. 清华大学机械工程系, 北京 100084;

2. 精密超精密制造装备及控制北京市重点实验室, 北京 100084;

3. 西南科技大学信息工程学院, 绵阳 621010;

4. 航天工程装备(苏州)有限公司, 苏州 215104;

5. 上海航天设备制造总厂有限公司, 上海 200245

* E-mail: jhwu@mail.tsinghua.edu.cn

收稿日期: 2019-10-15; 接受日期: 2019-11-19; 网络版发表日期: 2020-02-27

国家科技重大专项(编号: 2018ZX04011001)资助项目

摘要 电主轴可靠性研究中需要监测主轴回转精度, 但直接测量主轴回转精度较为复杂. 本文提出一种基于前轴承振动信号预测主轴回转精度的方法. 利用BP神经网络波形预测改进局部均值分解(local mean decomposition, LMD)的端点效应; 然后利用改进的LMD方法分解前轴承振动信号, 并提取乘积函数(product function, PF)分量的样本熵, 进一步建立从样本熵到主轴回转精度的长短期记忆(long-short term memory, LSTM)网络训练模型; 在电主轴加载实验台上利用载荷谱进行模拟加载, 进行主轴回转精度预测实验研究. 结果表明, BP神经网络波形预测对LMD端点效应有较好的抑制效果, 得到的PF分量样本熵的平均误差为2.28%, 电主轴回转精度预测精度为93.15%. 本文提出的方法可用于电主轴回转精度的预测.

关键词 电主轴, 回转精度, 局部均值分解, 端点效应, 长短期记忆网络

1 引言

电主轴作为加工中心的核心部件之一, 是集机、电、液的复杂系统. 在高速、高功率、高负荷的工况下长期运行, 主轴零部件容易产生各种疲劳磨损、裂纹等故障, 且故障的发生往往会导致连锁反应, 加剧主轴其余零部件的折损, 使主轴性能状态进一步恶化^[1]. 在切削过程中, 主轴回转精度会影响工件的加工精度, 是主轴可靠性评价中的重要指标^[2]. 在回转过程中, 主轴每一瞬时的回转轴线相对于自身理想轴线空间位置的偏离程度称为回转误差^[3], 在实际测量中, 一

般采用瞬时回转轴线的平均位置来代替理想轴线. 而回转误差可视为主轴回转精度的量化表现形式. 在主轴回转精度测试中, 需要在刀柄上安装测试仪器, 并让机床主轴在固定位上转动, 无法实现在主轴受载情况下测量回转精度. 此外, 回转精度测试仪价格昂贵, 安装精度要求高, 在实际应用中容易造成仪器损坏, 不适用于机床主轴性能的实时监测与回转误差实时补偿. 由于主轴轴承振动信号的获取相对容易得多, 利用振动信号预测主轴回转精度具有重要的工程意义.

主轴回转精度的变化受到多方面影响, 主要外界因素有转速、载荷、温度等, 而这也是影响电主轴的

引用格式: 陈代伟, 吴军, 王立平, 等. 基于振动信号的电主轴回转精度预测方法. 中国科学: 技术科学, 2020, 50: 819–828

Chen D W, Wu J, Wang L P, et al. A method for predicting spindle rotation accuracy using vibration (in Chinese). Sci Sin Tech, 2020, 50: 819–828, doi: 10.1360/SST-2019-0363

前轴承振动情况的重要因素^[4], 因此前轴承振动信号是建立主轴回转精度预测模型的最佳信号之一。但是前轴承振动信号通常含有大量复杂的干扰信号, 需要通过信号分析提取样本熵等特征信息。对于振动信号的分析, 传统方法主要有: 时域分析, 如提取信号的均幅值、峭度等指标, 但时域分析难以揭示信号的频率组成和各频率分量的大小等内部信息; 频域分析, 如傅里叶变换(FT); 时频分析, 如短时傅里叶变换(STFT)、小波变换(WT)等。但上述方法均存在一定的局限性, 如短时傅里叶变换的窗函数受到Heisenberg不确定准则的限制, 导致对非平稳信号的处理效果难以达到最优; 小波变换的时频窗口可调, 但对时频平面的矩形分割会造成分割过程中存在许多截断和分量之间的混合畸变, 且分析效果依赖于小波基的选择^[5]。信号自适应时频分析方法成为近年来研究的热点。其中经验模态分解(empirical mode decomposition, EMD)^[6]与局部均值分解(local mean decomposition, LMD)^[7]受到极大的关注, 在旋转机械故障诊断中得到广泛应用。例如Wang等人^[8]对于旋转机械健康诊断的研究表明LMD分析的效果优于EMD。程军圣等人^[9]将改进的LMD算法和支持向量机(SVM)应用于滚动轴承的故

障诊断。目前, 还鲜有主轴回转精度预测的研究。

本文基于电主轴前轴承振动信号, 利用LMD和长短期记忆(long-short term memory, LSTM)预测主轴回转精度。利用BP神经网络学习的方法进行信号波形预测, 用于LMD中的端点延拓以抑制端点效应; 利用改进后的LMD方法分解振动信号, 提取分解后的PF分量样本熵, 建立振动信号的特征信息向量; 利用LSTM网络建立振动信号样本熵与主轴回转精度的训练——预测模型。最后在电主轴加载试验台上对主轴进行模拟加载, 并开展回转精度预测实验研究。

2 回转精度预测及振动信号处理

2.1 基于长短期记忆的回转精度预测模型

长短期记忆是一种特殊的循环神经网络(recurrent neural network, RNN)模型, 能解决RNN模型梯度弥散的问题^[10], 对于时序信号分类与预测问题具有较好的学习效果, 在模式识别、预测模型等方面逐渐得到广泛的应用。本文基于主轴前轴承振动信号与对应的主轴回转精度, 建立LSTM网络来预测电主轴的回转精度。主轴回转精度预测的流程如图1所示。

图1 (网络版彩图) 主轴回转精度预测模型

Figure 1 (Color online) The prediction model of rotation accuracy of spindle.

(1) 利用LMD分解前轴承振动信号, 得到多个PF分量信号和一个余量信号RES;

(2) 样本熵能够度量时间序列复杂性^[11], 有效表现振动信号的内部特征, 因此利用样本熵提取PF分量及RES信号的特征信息, 构成一个一维的样本熵向量;

(3) 将样本熵向量训练集输入到LSTM网络, 输出对应的回转精度, 以此来训练LSTM网络;

(4) 输入样本熵向量测试集到训练后的LSTM网络, 得到预测的主轴回转精度, 并与实际的回转精度作比较分析.

2.2 LMD端点效应问题

在回转精度预测模型的信号处理部分, LMD分解的结果对后续的样本熵提取有重要影响, 并进一步影响模型数据的准确性. LMD可将一个复杂信号分解成一组PF之和, 每个PF分量由一个包络信号和一个纯调频信号相乘得到^[12]. LMD分解的分解误差主要为端点效应. 图2为常规的LMD主要分解步骤:

- (1) 输入信号 $x(t)$;
- (2) 搜寻极值点;
- (3) 求出局部均值、幅值, 运用插值法对局部均值、幅值进行包络;
- (4) 不断分离、解调信号, 求出并分离PF分量;
- (5) 对信号余量重复步骤(2)~(4), 直到信号余量符合停止分解要求.

然而在实际分解中, 端点处的信号不可能恰好都是极值点, 即便是极值点, 也不可能同时是极大值又是极小值, 这会影响局部均值、幅值的包络准确性, 造成分解误差, 即LMD的端点效应. 端点效应不仅会“污染”分量信号, 分解误差还会逐级累积, 导致分解效果越来越差, 甚至产生虚假的PF分量, 对于短样本长度的信号分解影响尤为明显. 因此, 对信号进行LMD分解时, 需要对LMD的端点效应进行有效的抑制.

3 LMD端点效应抑制

3.1 BP神经网络波形预测

信号的LMD分解是数据处理的首要环节, 为提高信号分解的准确率, 减小端点处的分解误差, 需对LMD分解的端点效应加以抑制. LMD端点效应抑制方法主要有波形延拓^[13,14]. 对于简单谐波信号, 改进斜率

图2 LMD分解流程

Figure 2 The decomposition process of LMD.

法(improved slope based method, ISBM)等传统方法简单有效, 但对于振动信号而言, 这些方法主要目的是遏制端点处拟合发散问题, 而不是解决精度问题. 深度学习的网络训练时长相对BP神经网络长得得多, 而在LMD分解中, 每个PF分量的分解都需要进行多次端点延拓, 训练后的网络仅利用一次, 因此网络训练时间是需要考虑的重要因素. 在LMD分解中找出局部极值前, 采用基于BP神经网络波形预测的方法延拓左右端点处的波形, 可以获得“额外”的波形来减小局部均值、幅值的包络误差, 从而在一定程度上抑制端点效应. 一般而言1~2对极值点即可满足要求.

BP神经网络训练测试流程如图3所示, 每隔一定

图3 (网络版彩图)神经网络训练流程

Figure 3 (Color online) The process of training the BP network.

距离截取一段长度为 n 的信号为训练的样本输入, 其后的10个点为训练的样本输出, 共同构成神经网络的训练集. 截取的距离间隔越小, 训练集越大, 训练效果越好, 但计算时间也越长.

利用一段长度为3600的振动信号, 等间距截取长度为200的信号, 其截取间隔为10, 构建容量为300的训练集; 以信号尾端200个点的信号为测试起始点, 开始分5次、步长为10的波形预测, 获得50个预测点, 利用MATLAB实现BP神经网络波形预测, 并与ISBM法得到的极值点作对比. 图4为BP神经网络预测波形与

图4 (网络版彩图)实际波形与预测波形对比

Figure 4 (Color online) Comparison of actual waveform and predicted waveform.

极值点、ISBM获得的实际波形及其极值点的对比, 以及上述方法的极值包络的对比. 可以看出BP神经网络预测的波形较为接近实际波形, 且做极值包络时, BP神经网络波形预测法的下包络线几乎与实际下包络线重合, 上包络线中也是BP神经网络波形预测法与实际的最接近; 而零延拓法在端点附近出现明显的包络失真问题, 其原因在于该方法没有进行端点延拓, 而是任由包络线在最后一对极值点到端点之间延伸, 误差呈发散趋势, 会造成LMD分解中的严重端点效应. 相比之下, ISBM法延拓得到的端点位置误差较小, 但幅值误差较大, 因而包络误差有所减小; BP神经网络预测波形法得到的延拓极值点位置准确且幅值误差小, 随着预测过程的推进, 极值点的误差没有出现明显的累积、变大现象, 包络误差进一步减小.

由于ISBM法、零延拓法等传统方法对于端点延拓的计算量极小, 因此在MATLAB的信号LMD分解中其耗时可以忽略不计. 而BP神经网络波形预测法的网络训练时间主要耗费在网络训练上, 对于长度为3600的信号, 其训练时长为0.46 s, 耗时在可接受范围内. 因此BP神经网络波形预测法适用于LMD中的端点延拓, 能有效抑制端点效应.

3.2 端点效应抑制效果检验

利用清华大学电主轴可靠性加载试验台的前轴承振动数据进行LMD分解效果检验. 由于LMD端点效应发生在分解信号的两端, 故可剪裁两端受污染信号, 保留中间未被影响部分作为LMD分解的标准参考.

使用一段长度为1000、采样频率为10 kHz的信号作为测试信号. 用信号剪裁法截取中间长度为360、未被污染的部分信号作为标准参照, 其LMD分解结果如图5所示.

可以看出, 在前3个PF分量中基于ISBM端点延拓的LMD能保持较好的分解效果, 但在PF4, RES的左端点处出现了明显的分解误差, 在右端点处甚至出现了“翘尾”的发散问题, 说明开始出现了明显的端点效应. 在PF3之后, 基于神经网络端点延拓的LMD也出现了一定的分解误差, 但波形总体与基于ISBM法的LMD分解相同, 误差较小, 不存在发散现象. 因此, 基于神经网络端点延拓的LMD分解相对于传统端点抑制方法精度较高, 不容易产生端点发散问题, 该方法有助于提高LMD分解效果.

图 5 (网络版彩图)ISBM, BP神经网络的LMD分解对比

Figure 5 (Color online) Comparison of LMD results based on ISBM and BP network.

4 加载试验与数据处理

4.1 电主轴模拟加载试验台

图6为电主轴模拟加载试验台, 配置有NI PXI信号采集系统. 试验台还配置有气动装置, 可以实现径向、轴向力加载, 同时安装有Lion回转精度测试仪、PCB Piezotronics 356A14型振动传感器对主轴状态进行检测. 根据前期编制的主轴载荷谱^[15,16]模拟实际工况对电主轴进行加载试验, 每隔4 h使用回转精度测试仪测量一次不同转速、不同径向载荷下的主轴径向回转误差, 采用最小外接圆法计算得到主轴径向回转精度. 测试的转速范围为500~5000 r/min, 径向载荷范围为100~1000 N. 其余时间进行磨损加载.

试验过程中获得的回转精度将用来和本文预测的回转精度进行对比. 一个加载周期内回转精度测试仪

测量的回转精度变化如图7所示, 回转精度的数值总体上随着转速的提高、径向加载力的增大而变大.

4.2 PF样本熵提取与误差分析

根据样本熵计算公式提取PF分量样本熵:

$$\text{SampEn}(m, h, N) = \lim_{N \rightarrow \infty} \left[-\ln \frac{\bar{C}^{m+1}(h)}{\bar{C}^m(h)} \right], \quad (1)$$

式中, m 为构造向量 $X_m(i)$ 的维数; h 为计算阈值, 一般为输入信号标准差的0.15~0.25之间; $\bar{C}^m(h)$ 为向量间距超过阈值 h 的数目的平均值. 数据处理中, 取 $m=2$, h 取第一组输入信号的标准差的0.2.

提取基于BP神经网络端点延拓的PF分量样本熵, 并做量化分析, 在空载的10档转速下进行对比测试, 参考组为基于信号剪裁法的PF分量样本熵, 对比结果如

图 6 (网络版彩图)主轴加载试验台结构
Figure 6 (Color online) The structure of spindle loading test bench.

图 7 (网络版彩图)径向力-转速-回转精度对应图
Figure 7 (Color online) Mapping of radial force and rotation speed to rotation accuracy.

图8所示。

在PF1~PF3中, 两者的样本熵跟随较为紧密, 误差较小, 且较其他分量, PF3样本熵与转速之间具有明显的线性关系; 在PF4与RES中, 样本熵的误差相对较大, 其原因在于随着LMD分解出高频分量, 剩余的分量信号复杂度大大降低, 而端点效应在逐步累积, 因此样本熵误差随之逐级增大。

根据式(2)计算最大误差 $\varepsilon_{\max}$ 及平均误差 $\bar{\varepsilon}$:

$$\begin{cases} \varepsilon_{\max} = \max_{1 \leq i \leq N} \frac{|\varepsilon_{p,i} - \varepsilon_{st,i}|}{\varepsilon_{st,i}}, \\ \bar{\varepsilon} = \frac{1}{N} \sum_{i=1}^N \frac{|\varepsilon_{p,i} - \varepsilon_{st,i}|}{\varepsilon_{st,i}}, \end{cases} \quad (2)$$

式中, N 是样本数量, $\varepsilon_{p,i}$ 是第 i 个样本的回转精度预测值, $\varepsilon_{st,i}$ 是第 i 个样本的实际回转精度。

一般而言, 信号长度越长, LMD分解得到的分量

图 8 (网络版彩图)不同转速下的PF样本熵
Figure 8 (Color online) PF sample entropy of different rotation speed.

信号中受端点效应影响的比例也就越小, 对总体分析的影响也越小。但当信号长度较短时, 端点效应则会对分析结果产生较大影响, 在样本熵等时域分析中表现得较为明显。表1列出了100组不同长度信号LMD分解的PF4分量的平均样本熵, 当取信号长度为360时, 平均提取误差达到6.00%。

进一步与基于ISBM延拓法的样本熵作对比, 对比结果如表2所示, 可以看出样本熵误差会随着分解中PF分量级数的增加而增大, 说明LMD分解的端点效应

表 1 不同长度信号的平均样本熵误差对比表(PF4)

Table 1 Mean sample entropy error of signals in different length (PF4)

样本		样本熵	误差 (%)
360	试验	0.7945	6.00
	参照	0.7495	

表 2 样本熵误差对比表

Table 2 Error analysis of PFs based on sample entropy

项目	ISBM延拓法		BP神经网络预测法	
	最大误差	平均误差	最大误差	平均误差
PF1	1.99%	0.51%	1.67%	0.53%
PF2	2.44%	1.10%	2.87%	0.96%
PF3	4.71%	1.84%	4.57%	1.41%
PF4	8.93%	3.68%	5.55%	2.67%
RES	18.04%	6.42%	15.89%	5.83%
总体	18.04%	2.71%	15.89%	2.28%

会影响PF分量样本熵的准确度, 且误差会逐级累积. 基于BP神经网络预测法的LMD分解PF分量样本熵的总体误差为2.28%, 小于ISBM延拓法的2.71%. 分析结果表明, PF样本熵的误差会随着LMD端点效应的累积而增大, 因此抑制LMD端点效应具有重要意义.

5 基于LSTM网络的回转精度预测试验

5.1 LSTM网络训练集

取采样频率 f 为10 kHz, 主轴转速 n 为500~5000 r/min, 3个转动周期的信号为样本, 则截取的信号长度 N 的计算公式为

$$L = \frac{3f}{n/60}. \quad (3)$$

可知信号样本长度 L 在360~3600之间. 采集多个加载周期的振动信号与回转精度, 经过初步处理得到网络训练样本.

图9为PF分量样本熵, 可以看出PF3~RES的样本熵分层清晰, 且随着回转精度呈正相关变化; PF1与PF2点图区域大部分重叠, 说明这两个分量信号复杂度较高, PF1到PF2的LMD分解度不高. 振动信号PF分量样本熵与回转精度之间存在显著的正相关性, 说明可以利用PF样本熵预测主轴回转精度.

5.2 LSTM预测结果分析

LSTM网络训练样本为经LMD分解后的PF分量样

图9 (网络版彩图)PF分量样本熵散点图

Figure 9 (Color online) Plot of sample entropy of PF mapping to rotation accuracy.

本熵与相应的回转精度, 取600份训练样本, 50份测试样本作为输入, 输入的信号样本为一维的PF样本熵向量, 相应的回转精度在3.5~18 μm之间. 应用LSTM进行PF样本熵信号分类. 另设对照试验3组: (1) 应用时序信号直接进行深度学习网络训练; (2) 使用PF分量样本熵进行BP神经网络训练; (3) 使用原信号进行BP神经网络训练. 训练参数以达到稳定收敛效果为准.

4种方法预测的结果如图10所示, 可以看出预测结果具有较大的差异. 在回转精度谷值处, 基于原信号的LSTM预测效果最差; 而基于原信号的BP神经网络预测误差较大, 整体预测结果偏大; 基于样本熵的LSTM预测结果与实际最为接近. 在回转精度峰值处, 基于原信号的BP神经网络预测结果整体偏大, 基于样本熵的LSTM预测整体上与实际偏差最小. 整体上基于PF样本熵的LSTM预测效果比基于原信号的LSTM预测效果更好.

进一步计算这50个预测点的平均准确度, 结果如表3所示. 基于PF分量样本熵的LSTM预测准确度相对最高, 达到93.15%, 采用LMD分解得到PF分量并提取样本熵, 再进行LSTM深度学习网络训练的方法能有效预测回转精度. 其中基于原信号的LSTM网络训练时间最长, 且在增加迭代次数与调整标签划分等条件下收敛效果提高有限, 因此该方法不适用于回转精度的预测.

通过实验发现, 在相同输入和相似参数下, LSTM网络训练时间往往比基于BP神经网络长得多. 对于LSTM网络训练而言, 隐藏层数目、迭代次数以及标

图10 (网络版彩图)预测效果对比

Figure 10 (Color online) Prediction results of different prediction methods.

表 3 预测精度与训练时长对比

Table 3 Comparison of prediction accuracy and training time

训练方法	预测准确度	训练时长 (s)
基于PF样本熵的LSTM预测	93.15%	192
基于原信号的LSTM预测	89.06%	21663
基于PF样本熵的BP网络预测	87.63%	2
基于原信号的BP网络预测	87.40%	114

签划分是影响训练效果的重要因素。图11为在不同隐藏层数目下的PF样本熵的LSTM预测结果。在回转精度谷值处均有较好的预测效果,当隐藏数目较小为10时,预测的结果较为“机械”。在回转精度峰值处,预测结果几乎没有变化;当隐藏层数目为100时,峰值处对实际值的跟随性明显改善;但隐藏层增加至300时,预测值对实际值的误差并没有减小,跟随性反而变差。因此隐藏层的数目不是越多越好,100左右的隐藏层数目有较好的LSTM网络预测效果。

表4给出了不同训练时间、隐藏层数目、标签间隔下的LSTM网络训练准确度与训练时间,可以看出训练时间随迭代周期数、标签数目和隐藏层数目的增加而增加。随着迭代周期数的增加,预测精度并没有线

图 11 (网络版彩图)不同隐藏层的训练效果对比

Figure 11 (Color online) Prediction result of different hidden layer.

性增加,在迭代周期数为300时,更是出现预测精度下降的现象;标签划分的数目越小,网络训练的时间越短,标签预测的准确度也越好,但标签间隔过大也会造成系统精度变差,出现如图10中的基于原信号的LSTM预测结果“跳跃”问题;当隐藏层达到100时,预测精度不再提高,出现起伏变化现象。因此选择合理的网络参数对回转精度预测精度至关重要。根据预测精度与实际预测点在回转精度峰值处的预测效果,选择隐藏层数150,迭代周期数200,标签间隔0.1 μm进行LSTM网络训练,最终得到93.15%的预测结果。

表 4 预测精度与训练时间结果

Table 4 Result of prediction accuracy and training time

迭代周期数	标签间隔 (μm)	隐藏层数目			
		10	50	100	200
100	0.5	91.47%	91.67%	92.69%	92.26%
		107 s	133 s	179 s	320 s
	0.1	91.89%	91.70%	92.56%	92.13%
		120 s	154 s	214 s	367 s
200	0.5	91.96%	91.44%	92.88%	92.63%
		219 s	271 s	362 s	648 s
	0.1	91.41%	90.67%	91.57%	91.95%
		262 s	319 s	418 s	697 s
300	0.5	89.66%	92.61%	93.08%	92.75%
		268 s	377 s	518 s	917 s
	0.1	89.51%	90.50%	89.94%	89.81%
		321 s	429 s	553 s	1000 s

6 讨论与结论

本文应用BP神经网络波形预测改进LMD的端点效应,并用改进后的LMD获得主轴前轴承振动信号的PF分量并提取样本熵,采用LSTM深度学习建立前轴承振动信号PF分量样本熵到主轴回转精度的训练-预测模型。

基于BP神经网络的端点波形延拓方法能有效抑

制端点效应,与传统方法相比,具有相对较高的预测精度;运用改进后的LMD分解方法能够提高样本熵提取的准确度,得到的PF样本熵平均误差为2.28%。

基于PF分量样本熵的LSTM深度学习综合效果较好,且适当的隐藏层数目能提高网络训练效果,在LSTM隐藏层数目为150时,预测精度达到93.15%。本研究为电主轴可靠性分析中信号深度融合分析及回转精度预测奠定了基础。

参考文献

- 1 Tan C. The research of fault check technology of motorized-spindle system based on wavelet transform (in Chinese). Dissertation for Master's Degree. Changsha: Hunan University, 2011. 1–11 [谭琛. 基于小波变换的电主轴振动故障检测技术研究. 硕士学位论文. 长沙: 湖南大学, 2011. 1–11]
- 2 Wang L P, Zhang B B, Wu J. Rotation accuracy evaluation of electric spindle based on least square method (in Chinese). *Manuf Tech Mach Tool*, 2018, 2: 63–69 [王立平, 张彬彬, 吴军. 基于最小二乘法的电主轴回转精度评价. *制造技术与机床*, 2018, 2: 63–69]
- 3 Guo Z. Precision design and measurement method of large precision rotary body rotary (in Chinese). *Manuf Tech Mach Tool*, 2019, 6: 145–148 [郭召. 大型精密回转体回转精度设计及测量评估方法. *制造技术与机床*, 2019, 6: 145–148]
- 4 Shen Y, Zhang X P, He F T. Early failure analysis of spindle bearing of precision machine tool (in Chinese). *Bearing*, 2012, 5: 38–40 [申阳, 张晓鹏, 何峰涛. 精密机床主轴轴承早期失效分析. *轴承*, 2012, 5: 38–40]
- 5 Cheng J S, Zhang K, Yang Y. Local mean decomposition method and its application to roller bearing fault diagnosis (in Chinese). *China Mech Eng*, 2009, 22: 2711–2717 [程军圣, 张亢, 杨宇. 局部均值分解方法及其在滚动轴承故障诊断中的应用. *中国机械工程*, 2009, 22: 2711–2717]
- 6 Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc R Soc Lond A*, 1998, 454: 903–995
- 7 Smith J S. The local mean decomposition and its application to EEG perception data. *J R Soc Interface*, 2005, 2: 443–454
- 8 Wang Y, He Z, Zi Y. A comparative study on the local mean decomposition and empirical mode decomposition and their applications to rotating machinery health diagnosis. *J Vib Acoust*, 2010, 132: 021010
- 9 Cheng J S, Shi M L, Yang Y, et al. A roller bearing fault diagnosis method based on improved LMD and SVM. *J Measur Sci Instrum*, 2011, 1: 1–5
- 10 Chen W, Chen J X, Jiang Y Q, et al. Fault identification of rolling bearing based on RS-LSTM (in Chinese). *China Sciencepaper*, 2018, 10: 51–58 [陈伟, 陈锦雄, 江永全, 等. 基于RS-LSTM的滚动轴承故障识别. *中国科技论文*, 2018, 10: 51–58]
- 11 Han M, Pan J. A fault diagnosis method combined with LMD, sample entropy and energy ratio for roller bearings. *Measurement*, 2015, 76: 7–19
- 12 Guo W, Huang L, Chen C, et al. Elimination of end effects in local mean decomposition using spectral coherence and applications for rotating machinery. *Digital Signal Process*, 2016, 55: 52–63
- 13 Wang F W, Zhou Y Q, Zhou S J. Study on methods for improving LMD end effect. *Appl Mech Mater*, 2016, 851: 559–566
- 14 Zhang M J, Tang J, He X H. EEDM and Its Application in Mechanical Fault Diagnosis (in Chinese). Beijing: National Defense Industry Press, 2015 [张梅军, 唐建, 何晓辉. EEDM方法及其在机械故障诊断中的应用. 北京: 国防工业出版社, 2015]
- 15 Chen C H, Yang Z J, Chen F, et al. Reliability modeling of machining center spindle based on Bootstrap-Bayes (in Chinese). *J Jilin Univ (Eng Tech Ed)*, 2014, 1: 95–100 [陈传海, 杨兆军, 陈菲, 等. 基于Bootstrap-Bayes的加工中心主轴可靠性建模. *吉林大学学报(工学版)*, 2014, 1: 95–100]
- 16 Chen D W, Wu J, Zhang B B, et al. Method of load spectrum compilation of machining center spindle based on S-shaped specimen (in Chinese). *J Tsinghua Univ (Sci Tech)*, 2018, 12: 1107–1114 [陈代伟, 吴军, 张彬彬, 等. 基于S试件的加工中心电主轴载荷谱编制. *清华大学学报(自然科学版)*, 2018, 12: 1107–1114]

A method for predicting spindle rotation accuracy using vibration

CHEN DaiWei^{1,2}, WU Jun^{1,2}, WANG LiPing^{1,2}, LIANG JianHong³,
GONG XiuMei⁴ & KONG WeiSen⁵

¹ Department of Mechanical Engineering, Tsinghua University, Beijing 100084, China;

² Beijing Key Lab of Precision/Ultra-Precision Manufacturing Equipment and Control, Beijing 100084, China;

³ School of Information Engineering, Southwest University of Science and Technology, Mianyang 621010, China;

⁴ Aerospace Engineering Equipment (Suzhou) Co., Ltd., Suzhou 215104, China;

⁵ Shanghai Aerospace Equipments Manufacturer Co., Ltd., Shanghai 200245, China

When investigating motorized spindle reliability, it is very difficult to monitor spindle rotation accuracy in real-time. To address this, a method for predicting spindle rotation accuracy using the vibration signal from the front bearing is proposed. Waveform prediction based on a back propagation (BP) neural network is used for boundary extension to suppress local mean decomposition (LMD) end effects; the vibration signal from the front bearing is decomposed using the modified LMD, and sample entropy extracted from the PFs is used to build the training-prediction model, with spindle rotation accuracy based on long short-term memory (LSTM). An experiment based on the spindle's load spectrum was performed to acquire data and validate the prediction model. The results show that waveform prediction based on a BP neural network can effectively suppress end effects. The mean error of the extracted sample entropy was just 2.28%, and the accuracy of the spindle rotation prediction was 93.15%. Results from training the LSTM show that the rotation accuracy of the spindle can be accurately predicted based on the vibration signal from the spindle front bearing.

motorized spindle, rotation accuracy, local mean decomposition, endpoint effect, long-short term memory network

doi: [10.1360/SST-2019-0363](https://doi.org/10.1360/SST-2019-0363)