

DOI: 10.19650/j.cnki.cjsi.J1905944

# 基于整周期数据和卷积神经网络的谐波 减速器健康状态评估\*

陈仁祥<sup>1</sup>, 张勇<sup>1</sup>, 杨黎霞<sup>2</sup>, 陈才<sup>3</sup>, 徐向阳<sup>1</sup>

(1. 重庆交通大学 交通工程应用机器人重庆市工程实验室 重庆 400074; 2. 重庆广播电视大学 重庆 400052;  
3. 重庆华数机器人有限公司 重庆 400714)

**摘要:**针对工业机器人谐波减速器循环往复运动、工作节拍不一和转速瞬变而导致其运行状态难以刻画和健康状态不易评估的问题,提出了基于整周期数据和卷积神经网络的谐波减速器健康状态评估方法。首先,运用相位差频谱校正-互相关法对振动信号分割构造整周期数据样本以准确刻画谐波减速器的运行状态信息;其次,应用连续小波变换对整周期数据进行分解以充分展现谐波减速器运转周期内的瞬变特征;最后,利用卷积神经网络在时间和空间上对输入信号的平移、缩放具有高度不变性的特点,充分学习谐波减速器运转周期内的瞬变特征,从而实现对谐波减速器健康状态评估。实验结果显示,所提方法识别准确率达到90%以上,证明了该方法能够有效评估谐波减速器健康状态,并具有较好的泛化能力和稳健性。

**关键词:**健康状态评估;谐波减速器;整周期数据;卷积神经网络;连续小波变换

**中图分类号:** TH165<sup>+</sup>.3 TP18 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Health condition assessment of harmonic reducer based on integer-period data and convolutional neural network

Chen Renxiang<sup>1</sup>, Zhang Yong<sup>1</sup>, Yang Lixia<sup>2</sup>, Chen Cai<sup>3</sup>, Xu Xiangyang<sup>1</sup>

(1. School of Mechatronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074, China; 2. Chongqing Radio & TV University, Chongqing 400052, China; 3. CQHS Roboter Corporation, Chongqing 400714, China)

**Abstract:** Due to the cyclic motion, different working beats and transient speed, it is difficult to effectively describe the running state and assess the health state of industrial robot harmonic reducer. In this study, a method based on integer-period data and convolutional neural network is proposed to achieve health state assessment of harmonic reducer. Firstly, the phase difference spectrum correction-cross correlation method is used to adaptively segment the original vibration signal and construct the integer-period data samples to accurately describe the running state information of the harmonic reducer. Secondly, continuous wavelet transform is applied to decompose the integer-period data sample to obtain the time-frequency map to fully show the transient characteristics of harmonic reducer in the operation cycle. Finally, convolution neural network is utilized to translate and scale the input signals in time and space with high invariability to fully learn the transient characteristics of the harmonic reducer in each operating cycle. In this way, the health state of the harmonic reducer can be evaluated. Experimental results show that the identification accuracy of the proposed method is over 90%. The effectiveness of the proposed method is verified, which has good generalization ability and robustness.

**Keywords:** health state assessment; harmonic reducer; integer-period data; convolutional neural network; continuous wavelet transform

收稿日期:2019-12-26 Received Date:2019-12-26

\* 基金项目:国家自然科学基金(51975079, 51975078)、重庆市教委科学技术研究项目(KJQN201900721)、重庆市技术创新与应用示范项目(cstc2018jscx-msybX0012)、交通工程应用机器人重庆市工程实验室开放基金(CELTEAR-KFKT-201803)、重庆交通大学硕士研究生科研创新项目(2019S0109)资助

## 0 引言

谐波减速器具有传动比大、传动效率高、传动精度高和体积小等优点,被广泛应用于工业机器人末端关节<sup>[1]</sup>。作为机器人重要零部件,谐波减速器高精度运行保证了工业机器人的精准动作,其健康状态直接决定了工业机器人的运行精度与可靠性,因此对其进行健康状态评估十分必要。

工业机器人机械臂通常作循环往复运动,一个往复运动过程为:启动—加速—平稳—减速—停止—反向启动—加速—平稳—减速—停止。同时,生产节拍不同使得工业机器人工作节拍不一,即往复运动的周期、加速度与最高转速均不同,导致不同工作节拍下运行状态信息难以比较。另外,往复运动中频繁的启动与加、减速导致谐波减速器转速瞬变,所获取信号的特征呈现出典型的瞬变特性,在进行谐波减速器健康状态评估时面临变工况的问题。目前,对于变工况问题,宋涛等<sup>[2]</sup>提出了一种基于奇异值分解插值的变工况旋转机械故障诊断方法;Liu等<sup>[3]</sup>运用 Hilbert-Huang 变换和奇异值分解对滚动轴承进行故障诊断;Borghesani等<sup>[4]</sup>利用阶比跟踪对旋转机械进行故障诊断;沈飞等<sup>[5]</sup>提出了谱质心迁移模型以诊断变工况轴承故障。以上方法对于工况变化范围小或工况变化慢的情况效果较好,而谐波减速器循环往复、工作节拍不一及转速瞬变,其工况变化范围大且变化快速,导致上述方法力不从心。同时,这些方法还需要人工提取特征,依赖于人的经验。

近年来,因具有不依赖于人而能自动学习输入信号内部特征的优势,及在时间和空间上对输入信号的平移、缩放具有高度不变性的特点<sup>[6]</sup>,卷积神经网络(convolution neural network, CNN)已在诸如图像分类、目标检测、图像语义分割等领域取得了一系列突破性的研究成果<sup>[7-8]</sup>。同时, CNN 也被广泛运用于故障预测与健康领域。Xia等<sup>[9]</sup>提出了基于深度神经网络和分级器级传感器融合的齿轮传动故障分类方法;胡葛庆等<sup>[10]</sup>将信号经过经验模态分解后的内禀模式函数作为 CNN 输入以对行星齿轮箱进行故障识别;刘涵等<sup>[11]</sup>提出了基于 X 射线图像和 CNN 的石油钢管焊缝缺陷检测方法;陈仁祥等<sup>[12]</sup>信号经过离散小波变换后的时频图输入到 CNN 中以对滚动轴承进行故障识别;Zeng等<sup>[13]</sup>将信号 S 变换时频图作为 CNN 输入用以提取相应故障特征以识别齿轮箱故障。CNN 自动学习数据样本特征为谐波减速器的健康状态评估提供了有益借鉴。但针对谐波减速器循环往复、工作节拍不一及转速瞬变的特点,现有方法难以有效刻画谐波减速器的运行状态信息以利于 CNN 有效学习特征。

若要有效解决循环往复运动、工作节拍不一及转速瞬变条件下谐波减速器健康状态评估问题,关键在于准确刻画其运行状态信息以有效获取其运行特征。为此,本文针对循环往复的工作特点,运用相位差频谱校正—互相关法对原始信号自适应分割构造出整周期数据样本以匹配谐波减速器周期性的往复运转模式,实现运行状态信息的准确刻画。其次,应用连续小波变换(continuous wavelet transform, CWT)对整周期数据样本分解获得时频图以充分展现谐波减速器运转周期内的瞬变特征;然后,利用 CNN 在时间和空间上对输入信号的平移、缩放具有高度不变性的特点充分学习谐波减速器在不同工作节拍下运转周期内的瞬变特征;最后,利用 Softmax 分类器输出谐波减速器健康状态评估结果。最终形成基于整周期数据和 CNN 的谐波减速器健康状态评估方法。通过对不同健康状态及不同工作节拍下的谐波减速器进行健康状态评估实验,证明了本文方法的可行性与有效性。

## 1 基于相位差频谱校正—互相关的谐波减速器整周期数据提取方法

由于工业机器人机械臂做周期性循环往复运动,故获取的谐波减速器振动信号也呈现出了周期性的特点。在实际生产当中,生产节拍不同则会导致工作节拍也不同。图 1 所示为不同工作节拍下谐波减速器原始振动信号。3 种工作节拍分别对应谐波减速器处于 30%、60% 以及 100% 满转速。观察图 1 可知,随着工作节拍的增大,振幅也随之增大,而往复运动的周期越短。




图 1 不同工作节拍下谐波减速器原始振动信号  
Fig.1 Original vibration signal of harmonic reducer under different working beats

因此准确地提取出整周期数据以充分展现谐波减速器在各个运转周期内的瞬变特征是解决循环往复运动、工作节拍不一及转速瞬变条件下谐波减速器健康状态评估问题的关键。谐波减速器整周期数据的提取包括周期时间长度的提取以及周期起始位置的提取。本文采用相位差频谱校正提取整周期数据时间长度、互相关法提取整周期数据起始位置。

### 1.1 基于相位差频谱校正的周期时间长度提取方法

利用相位差频谱校正法来校正原始振动信号的频率值进而得到周期长度,具体步骤如下:

1) 作出振动信号的有效包络线,如图 2 所示,然后利用公式  $X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt$  对包络线进行傅里叶变换得到包络谱,进而得到包络谱的峰值频率  $f_m$ 。




图 2 信号包络线

Fig.2 The effective envelope of signal

2) 将包络线向左平移  $t_0$  (平移时间为  $f_m$  所对应周期的  $1/2$ ), 得到平移后的信号包络线。

3) 分别求取平移前后的包络线相位谱,并在它们的相位谱中求出频率  $f_m$  处对应的相位值,然后做出相位差  $\Delta\varphi$ 。

4) 利用公式  $f = \frac{\Delta\varphi}{2\pi t_0}$  得到整周期数据的频率值,进而得到周期长度  $T = 2 \cdot \frac{1}{f}$  (由于工业机器人机械臂是往复运动)。

### 1.2 基于互相关的周期起始位置提取方法

利用互相关法计算得到原始信号的实际相位从而得到整周期数据的起始位置,具体步骤如下:

1) 将包络信号与频率为  $f_m$  的正、余弦信号进行互相关计算,得到时延为 0 的两个数值  $R_{xy}(0)$ 、 $R_{xz}(0)$ 。

2) 根据互相关中初始相位计算公式  $\varphi = \arctan\left(\frac{R_{xz}(0)}{R_{xy}(0)}\right)$  得到信号的初始相位值,当  $R_{xy}(0) < 0$  时,信号实际相位  $\theta = \varphi + \pi$ ; 当  $R_{xy}(0) > 0$  且  $R_{xz}(0) < 0$  时,信号实际相位  $\theta = \varphi + 2\pi$ 。

3) 利用公式  $t = \frac{\theta}{2\pi} \cdot \frac{1}{f_m}$  将初始相位转化到时间上,从而得到整周期数据的周期起始位置,如图 3 所示。




图 3 原始信号的周期起始位置

Fig.3 Period start points of the original vibration signal

最终提取到的整周期信号如图 4 所示。30%工作节拍下一个完整的往复运动周期为 3.26 s。




图 4 整周期信号

Fig.4 Integer-period signal

## 2 连续小波变换 (CWT) 和卷积神经网络 (CNN)

### 2.1 连续小波变换 (CWT)

设  $h(t)$  为一平方可积函数,即  $h(t) \in L^2(R)$ , 如果其傅里叶变换  $H(\omega)$  满足以下条件<sup>[14]</sup>:

$$C_h = \int_{-\infty}^{\infty} \frac{|H(\omega)|^2}{|\omega|} d\omega < \infty \quad (1)$$

则称  $h(t)$  为一个母小波函数,并称上式为小波函数的可允许条件。母小波函数  $h(t)$  经过尺度伸缩和平移后得到一个小波基函数  $h_{\mu,v}(t)$ :

$$h_{\mu,v}(t) = \frac{1}{\sqrt{|\mu|}} h\left(\frac{t-v}{\mu}\right) \quad (2)$$

式中:  $\mu$  为尺度因子;  $v$  为平移因子; 为保证能量恒定,引入规范因子  $\frac{1}{\sqrt{|\mu|}}$ , 使得  $\|h_{\mu,v}\|_2 = \|h\|_2$ 。

且小波基函数  $h_{\mu,v}(t)$  应满足以下约束条件:

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

对于任意时域信号  $f(t) \in L^2(R)$ , 其 CWT 表达式为:

$$W_f(\mu, v) = \frac{1}{\sqrt{|\mu|}} \int_{-\infty}^{\infty} f(t) \overline{h\left(\frac{t-v}{\mu}\right)} dt \quad (4)$$

连续小波逆变换表达式为:

$$f(t) = \frac{1}{C_h} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{\mu^2} W_f(\mu, v) h\left(\frac{t-v}{\mu}\right) d\mu dv \quad (5)$$

由于 Morlet 小波波形与齿轮啮合时产生的冲击特征相似,且 ComplexMorlet 小波 (cmor 小波) 是 Morlet 小波的复数形式,自适应性能更好,故在此采用的是 cmor 小波。

### 2.2 卷积神经网络 (CNN)

CNN 是一种深度神经网络,具有局部感知、权重共享和多卷积核的特点。由输入层、输出层以及隐藏层组成,隐藏层分为卷积层、池化层以及全连接层<sup>[15]</sup>。

#### 1) 卷积层

在卷积层,前一层的特征图与卷积核进行卷积运算,然后经过激活函数得到本层的特征图,每一个卷积核对应一个特征图。使用的激活函数为 sigmoid 函数,其函数表达式为:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{6}$$

卷积过程数学表达式为:

$$X_j^l = f(\sum_{i \in M_j} X_i^{l-1} \cdot \omega_{ij}^l + b_j^l) \tag{7}$$

式中:  $X_j^l$  为第  $l$  层第  $j$  个元素;  $M_j$  为  $l-1$  层特征图的第  $j$  个卷积区域;  $X_i^{l-1}$  为其中的元素;  $\omega_{ij}^l$  为对应卷积核的权重矩阵;  $b_j^l$  为偏置项;  $f(\cdot)$  为激活函数。

#### 2) 池化层

池化层的作用是对上一个卷积层得到的特征进行抽样,以降低维度,减小计算复杂度,同时在一定程度上保证了特征尺度的不变性。池化层一般只进行降维操作,没有参数,不需要进行权值更新。经过池化区域大小为  $n \times n$  的池化运算后,输出的特征图边长变为原来的  $1/n$ ,特征图的个数不变。

#### 3) 全连接层

将池化后得到的所有特征图的每个像素依次展开,排成一列,构成特征向量。特征向量与输出层全连接,构成全连接层。将 CNN 用来做分类任务时,会在全连接层训练一个分类器。选用的分类器是 softmax。

#### 4) CNN 结构

标准的 CNN 结构模型如图 5 所示,输入信号为二维信号,  $C_1$  为卷积层、 $S_1$  为降采样层,  $C_1$  和  $S_1$  交替出现并持续提取信号特征,并在全连接层形成分布式特征表达。




图 5 CNN 结构

Fig.5 The structure of CNN

### 3 基于整周期数据和 CNN 的谐波减速器健康状态评估方法

本文提出的基于整周期数据和 CNN 的谐波减速器健康状态评估方法过程如下:首先运用相位差频谱校正—互相关法将谐波减速器振动信号分割构造整周期数据样本集,以准确刻画其运行状态信息;其次利用 CWT 对整周期数据样本进行分解获得时频图以充分展现谐波减速器运转周期内的瞬变特征;然后利用 CNN 充分学习谐波减速器在不同工作节拍下运转周期内的瞬变特征;最后,利用 Softmax 分类器输出谐波减速器健康状态评估结果。方法具体流程如图 6 所示,具体步骤如下:

- 1) 计算谐波减速器原始振动信号有效包络线;
- 2) 对包络信号进行傅里叶变换得到包络谱,进而得到包络谱峰值频率  $f_m$ ;
- 3) 平移包络线,作平移前后包络线相位谱,计算出平移前后包络线相位谱频率  $f_m$  对应的相位差值,从而计算得到整周期数据长度;
- 4) 将包络信号与频率为  $f_m$  的正弦、余弦信号进行互相关计算,得到信号的初始相位,进而得到整周期数据起始位置;
- 5) 提取出整周期数据,并对其进行 CWT 分解得到小波时频图;
- 6) 设置网络参数,构建 CNN 模型;
- 7) 以批量的方式将训练样本输入到 CNN 模型中;
- 8) 将测试样本输入到已训练完毕的 CNN 模型中,从而得到谐波减速器健康状态评估结果。

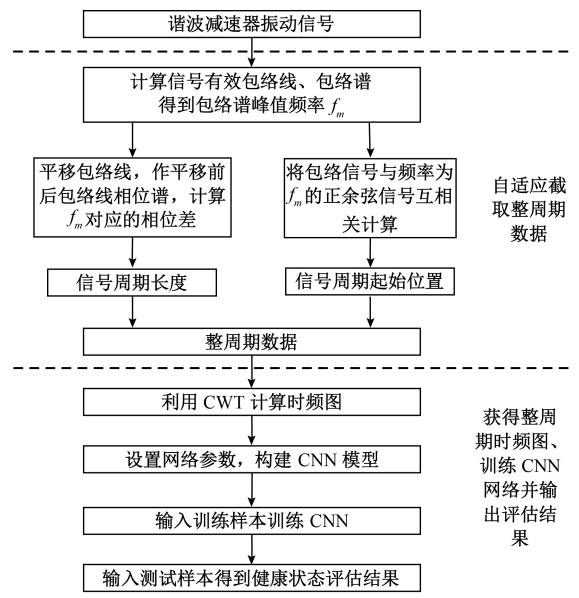


图 6 方法流程

Fig.6 Flow chart of method



## 4 谐波减速器实验

### 4.1 实验数据

本文实验数据采集自工业机器人末端关节上型号为 LHSG-17 的谐波减速器,如图 7 所示。共有 3 种状态:间隙过大、卡顿(谐波减速器转动时卡塞)和正常,传动比为 80,传感器布置如图 7 所示。间隙过大和卡顿状态的谐波减速器为工业机器人使用单位对工业机器人维修、保养时更换下来的减速器。




图 7 卡顿(左)、间隙过大(中)、传感器布置图(右)

Fig.7 Stuck (left), excessive clearance (middle), sensor layout (right)

在进行实验时,采样频率为 10 240 Hz,采样长度为

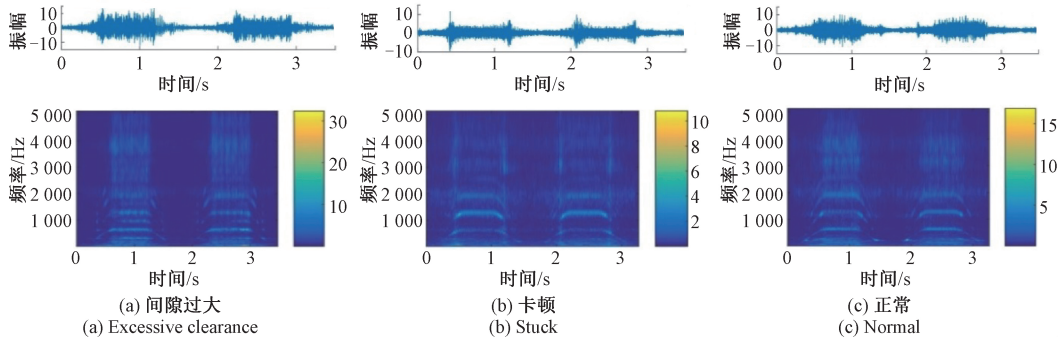


图 8 不同状态下的全周期数据时域信号及其时频

Fig.8 Time domain signals and time-frequency of integer-period data in different states

观察图 8 可知,3 种不同健康状态下谐波减速器振动信号的能量几乎连续分布于所有频段内,且低频段内相对于高频段内能量明显较高,整个时间段呈现明显的能量波动,瞬变特征明显,且间隙过大减速器的整体能量范围明显大于另外两类减速器。由此可知,不同健康状态下信号在连续小波时频域表现出的差别明显比在时域所表现的差别更加突出,准确刻画了谐波减速器在一个循环往复周期内信号变化特点,表明了 CWT 可充分展现不同健康状态下的瞬变特征。

### 4.2 实验结果及分析

本文的 CNN 网络共有 2 个卷积层:分别有 10、20 个卷积核,卷积核的大小皆为 5×5;降采样层的池化区域为 2×2。采用最值池化的方式,学习率 0.001,批量大小

1 000 k,工业末端关节(实验用谐波减速器)上下往复运动,在工作节拍分别为 30%、60%、100% 满转速的工况下重复采集多组数据,将采集到的振动信号利用所提方法自适应分割构造整周期数据样本。分别从 3 种不同健康状态下的谐波减速器整周期数据样本中分别随机选取 480 个数据样本构成训练样本集;同理从余下样本中随机选取 120 个数据样本构成测试样本集,如表 1 所示。

表 1 谐波减速器整周期数据样本集

Table 1 Integer-period data sample set of Harmonic reducer

状态类型	训练样本	测试样本	标签类别
间隙过大	480	120	I
卡顿	480	120	II
正常	480	120	III
合计	1 440	360	

图 8 所示为谐波减速器不同健康状态下的整周期数据样本振动信号波形以及时频。由于时域信号无法刻画谐波减速器不同工作节拍下的瞬变特征,对整周期数据样本信号进行 CWT 生成小波时频。

256,学习轮数  $k=80$ 。

将本文方法(整周期数据+CWT)与非整周期数据下 CWT+CNN(非整周期数据+CWT)、整周期数据下频谱+CNN(整周期数据+FT)以及文献[12]所提的 S 变换+CNN 方法(整周期数据+ST)进行对比,以验证本文方法的有效性和优势。图 9 和 10 所示分别表示谐波减速器在 30% 工作节拍下不同健康状态的分类准确率和分类损失的对比结果,表 2 所示为 3 种不同工作节拍下准确率的对比结果。

根据图 9 和 10 可知,本文方法随着学习轮数的增加,分类损失迅速降低直至 0,分类准确率不断提高。当  $k=20$  时,分类准确率已接近 100%,证明了本文方法是所采用的整周期数据准确地刻画了谐波减速器循环往复的运行状态信息,CWT 时频图充分展现了谐波减速器各运




图9 不同方法分类准确率对比

Fig.9 Comparison of classification accuracy of different methods




图10 不同方法分类损失

Fig.10 Classification loss of different methods

表2 不同方法准确率

Table 2 The accuracy of different methods

方法	分类准确率/%			均值
	节拍 30%	节拍 60%	节拍 100%	
整周期数据+CWT	100	100	100	100
整周期数据+ST	100	99.17	98.06	99.08
整周期数据+FT	88.89	80.56	82.78	84.08
非整周期数据+CWT	68.06	58.61	65.56	64.08

转周期内的瞬变特征。说明所提方法是可行的、有效的。

观察图 10 可知,整周期数据+ST 方法的分类损失随着学习轮数的增加也呈现了不断降低的趋势,在学习轮数  $k=60$  时,分类损失接近 0。根据图 9、10 及表 2 可知,在学习轮数较少的情况下,本文方法明显具有更快的收敛性,在学习轮数  $k=12$  时本文方法分类准确率已达到 91.94%,而整周期数据+ST 方法仅为 67.78%。当  $k=20$  时,本文方法分类准确率已接近 100%,而整周期数据+ST 方法在  $k=40$  才接近 100%。说明本文方法不仅诊断效率更高,而且收敛性更好。同时,整周期数据+FT 方法平均分类准确率仅为 84.08%,这是由于频谱只反映了频域特性,不能全面刻画谐波减速器的瞬变特征,从而导致

健康状态评估效果不佳。而非整周期数据+CWT 方法平均分类准确率仅为 64.08%,准确率最低,说明非整周期数据不能全面刻画谐波减速器的运行状态,从而影响了健康状态评估结果。

为进一步验证本文方法的泛化能力和稳健性,在不同工作节拍下对谐波减速器进行健康状态评估交叉实验,即训练样本和测试样本的工作节拍不同。3 种健康状态的谐波减速器分别在 30%、60%、100% 满转速的工作节拍下随机选取 480 个样本作为训练样本、剩下样本中随机选取 120 个样本作为测试样本,交叉实验时训练样本与测试样本如表 3 所示。

表3 不同工作节拍样本

Table 3 The samples under different working beats

编号	状态类型	训练样本		测试样本	
		节拍	样本数	节拍	样本数
A	间隙过大	30%/60%	480	100%	120
	卡顿	30%/60%	480	100%	120
	正常	30%/60%	480	100%	120
B	间隙过大	100%	480	30%/60%	120
	卡顿	100%	480	30%/60%	120
	正常	100%	480	30%/60%	120

图 11 所示为样本集 A 在不同工作节拍下各方法准确率对比结果,表 4 所示为样本 A、B 在不同工作节拍下各方法分类准确率。根据图 11 和表 4 可知,本文方法随着学习轮数的增加,分类准确率不断提高,当  $k=80$  时,分类准确率已经达到了 90% 以上,说明了在不同工作节拍下,本文方法仍然具有很好的效果。与此同时, $k=80$  时,整周期数据+ST 方法平均分类准确率仅为 79.46%,整周期数据+FT 方法也仅为 72.49%,非整周期数据+CWT 方法仅为 55.99%。由此可知,对于不同工作节拍下的谐波减速器健康状态评估,本文方法依然具有较好的分类效果,证明了其具有较好的泛化能力和稳健性。




图11 不同工作节拍下各方法分类准确率对比

Fig.11 The accuracy of each method under different working beats

表4 不同工作节拍下各方法准确率

Table 4 The accuracy of each method under different working beats

方法	分类准确率/%		均值
	A	B	
整周期数据+CWT	91.67	91.11	91.39
整周期数据+ST	80.56	78.38	79.46
整周期数据+FT	73.33	71.64	72.49
非整周期数据+CWT	55.28	56.7	55.99

## 5 结 论

为解决循环往复运动、工作节拍不一和转速瞬变下的工业机器人谐波减速器健康状态评估,提出了基于整周期数据和CNN的谐波减速器健康状态评估方法。本文方法通过整周期数据准确刻画了谐波减速器的运行状态信息,为其健康状态评估奠定了基础。同时,应用CWT对整周期数据样本分解获得时频图充分展现了谐波减速器运转周期内的瞬变特征。最后,利用CNN充分学习不同工作节拍下运转周期内的运行状态信息获得瞬变特征,实现了谐波减速器的健康状态评估。通过对不同健康状态以及不同工作节拍的对比实验证明了本文方法能够有效评估谐波减速器健康状态。本文研究对工业机器人减速器健康监测与科学维护提供了新思路和新方法,也发展了往复周期瞬变工况下的健康状态评估理论。

## 参考文献

- [1] 王田苗,陶永. 我国工业机器人技术现状与产业化发展战略[J]. 机械工程学报, 2014, 50(9): 1-13.  
WANG T M, TAO Y. Current situation and industrialization development strategy of industrial robotics in China[J]. Journal of Mechanical Engineering, 2014, 50(9): 1-13.
- [2] 宋涛,王瑜琳,赵明富,等. 基于SVDI的变工况旋转机械故障诊断方法[J]. 振动与冲击, 2018, 37(19): 211-216.  
SONG T, WANG Y L, ZHAO M F, et al. Fault diagnosis of rotating machinery under variable working conditions based on SVDI[J]. Journal of Vibration and Shock, 2018, 37(19): 211-216.
- [3] LIU H, WANG X, LU C. Rolling bearing fault diagnosis under variable conditions using Hilbert-Huang transform and singular value decomposition[J]. Mathematical Problems in Engineering, 2014(1): 1-10.
- [4] BORGHESANI P, PENNACCHI P, RANDALL R B, et al. Order tracking for discrete-random separation in

variable speed conditions[J]. Mechanical Systems and Signal Processing, 2012, 30: 1-22.

- [5] 沈飞,陈超,徐佳文,等. 谱质心迁移在变工况轴承故障诊断的应用[J]. 仪器仪表学报, 2019, 40(5): 99-108.  
SHEN F, CHEN CH, XU J W, et al. Application of spectral centroid migration in fault diagnosis of bearing under variable working conditions[J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 99-108.
- [6] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.  
ZHOU F Y, JIN L P, DONG J. Overview of convolutional neural networks[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]. International Conference on Neural Information Processing Systems, 2012, 60(2): 1097-1105.
- [8] 王永利,曹江涛,姬晓飞. 基于卷积神经网络的PCB缺陷检测与识别算法[J]. 电子测量与仪器学报, 2019, 33(8): 78-84.  
WANG Y L, CAO J T, JI X F. PCB defect detection and recognition algorithm based on convolutional neural network[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 78-84.
- [9] XIA M, SILVA C W. Gear Transmission fault classification using deep neural networks and classifier level sensor fusion[J]. Instrumentation, 2019, 6(2): 101-109.
- [10] 胡芑庆,陈徽鹏,程哲,等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7): 9-18.  
HU N Q, CHEN H P, CHENG ZH, et al. Fault diagnosis method of planetary gear box based on empirical mode decomposition and deep convolutional neural network[J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18.
- [11] 刘涵,郭润元. 基于X射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别[J]. 仪器仪表学报, 2018, 39(4): 247-256.  
LIU H, GUO R Y. Detection and identification of weld defects in petroleum steel pipe based on X-ray image and convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 247-256.
- [12] 陈仁祥,黄鑫,杨黎霞,等. 基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J]. 振动工程学报, 2018, 31(5): 883-891.

CHEN R X, HUANG X, YANG L X, et al. Fault diagnosis of rolling bearing based on convolutional neural network and discrete wavelet transform [J]. *Journal of Vibration Engineering*, 2008,31(5):883-891.

- [13] ZENG X, LIAO Y, LI W. Gearbox fault classification using S-transform and convolutional neural network [C]. *International Conference on Sensing Technology*. IEEE, 2016; 16575291. DOI: 10.1109/ICST.2016.7796330.
- [14] 李宏坤,练晓婷,周帅. 小波尺度谱同步平均在弱信息识别中的应用[J]. *机械工程学报*, 2013,49(5):32-38.
- LI H K, LIAN X T, ZHOU SH. Application of wavelet scale spectrum synchronization average in weak information recognition [J]. *Journal of Mechanical Engineering*, 2013,49(5):32-38.
- [15] 李恒,张氢,秦仙蓉,等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. *振动与冲击*, 2018,37(19):124-131.
- LI H, ZHANG Q, QIN X R, et al. Fault diagnosis method of bearing based on short-time Fourier transform and convolutional neural network [J]. *Journal of Vibration and Shock*, 2018,37(19):124-131.

## 作者简介



陈仁祥(通信作者),分别在2007年和2012年于重庆大学获得学士学位和博士学位,现为重庆交通大学教授、硕士生导师,主要研究方向为智能测试技术与信号处理。

E-mail: manlou.yue@126.com

**Chen Renxiang** (Corresponding author) received his B.Sc. degree and Ph.D. degree both from Chongqing University in 2007 and 2012, respectively. He is currently a professor and a master advisor at Chongqing Jiaotong University. His main research interests include intelligent testing technology and signal processing.



张勇,2018年于太原科技大学获得学士学位,现为重庆交通大学硕士研究生,主要研究方向为机电装备故障诊断及安全服役。

E-mail: 248692294@qq.com

**Zhang Yong** received his B.Sc. degree from Taiyuan University of Science and Technology in 2018. He is currently a M.Sc. candidate at Chongqing Jiaotong University. His main research interests include fault diagnosis and safety service of electromechanical equipment.

DOI: 10.19650/j.cnki.cjsi.J1905818

# 一种快速的数学形态学滤波方法及其在脉搏信号处理中的应用\*

丑永新<sup>1</sup>, 张爱华<sup>2</sup>, 顾亚<sup>1</sup>, 刘继承<sup>1</sup>, 冯玉峰<sup>3</sup>

(1. 常熟理工学院电气与自动化工程学院 苏州 215500; 2. 兰州理工大学电气工程与信息工程学院 兰州 730050; 3. 常熟市第一人民医院 苏州 215500)

**摘要:**针对数学形态学滤波法处理一维信号运算量大的问题,提出一种快速的数学形态学滤波方法。首先,对腐蚀操作进行改进,使其能够用于信号实时处理;然后,将微处理器系统缓存区的数据更新过程与形态学滤波原理相结合,采用滑窗迭代的方式进行运算,减少运算量;进一步,改进平滑滤波,提高滤波结果优化速度。采用实测脉搏信号作为实验数据,结果表明,相比于现有方法,改进后方法保持精度不变,并有效地降低了运算时间(提速70倍以上),基于扁平型和线型结构元素的形态学滤波法具有更快的滤波速度(提速110倍以上),随着结构元素和缓存区长度的增加,所提出方法仍能快速地进行信号处理(对于240 s的数据,耗时小于4.5 s),并能用于脉搏信号实时滤波、分割和特征提取(耗时小于45 s)。因此,所提出方法有望用于手环、手表等实时性要求较高的智能可穿戴设备。

**关键词:**快速的形态学滤波;滑窗迭代;改进平滑滤波;脉搏信号实时处理

**中图分类号:** R318.6 TH77 **文献标识码:** A **国家标准学科分类代码:** 310.6110

## Fast mathematical morphological filtering method and its application on pulse signal processing

Chou Yongxin<sup>1</sup>, Zhang Aihua<sup>2</sup>, Gu Ya<sup>1</sup>, Liu Jicheng<sup>1</sup>, Feng Yufeng<sup>3</sup>

(1. School of Electrical and Automatic Engineering, Changshu Institute of Technology, Suzhou 215500, China; 2. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; 3. Changshu No.1 People's Hospital, Suzhou 215500, China)

**Abstract:** In the actual one-dimensional signal processing, the mathematical morphological filtering method (MMFM) has a large amount of operation. To address this issue, a fast mathematical morphological filtering method (FMMFM) is proposed in this study. First, the erosion operation is modified to realize the real-time signal processing. Then, the data updating process of buffer in the microprocessor system is combined with the theory of MMFM. The iteration of sliding window is used to improve the time consumption of MMFM. In further, the smooth filtering method is also improved to speed up the optimization of the FMMFAM results. The measured pulse signals are used as experimental data. Compared with the MMFM, results show that the FMMFM can effectively reduce the calculation time (speed up over 70 times) and keep the filtering accuracy unchanged. The FMMFM with flat and linear structuring elements have faster filtering speed than those of other elements (speed up over 110 times). The proposed method can still process the signal in real-time (less than 4.5 s for the signals of 240 s) as the increase of the lengths of structuring element and buffer. It can be employed in pulse signal filtering, segmenting and feature extracting in real-time (less than 45 s). Therefore, the proposed method may be applied in some smart wearable devices with high real-time requirements, such as wristbands and watches.

**Keywords:** fast mathematical morphology filtering method; sliding window; the improved smooth filtering method; PPG signal processing in real-time