

# 基于时序深度学习的数控机床运动精度预测方法

余永维<sup>1</sup> 杜柳青<sup>1</sup> 易小波<sup>2</sup> 陈 罡<sup>2</sup>

(1. 重庆理工大学机械工程学院, 重庆 400054; 2. 重庆高金实业有限公司, 重庆 401122)

**摘要:** 由于数控机床精度演化规律难以通过数学建模分析, 提出了一种基于时序深度学习网络的数控机床运动精度建模与预测方法。基于长短时记忆网络建立时序深度学习预测模型, 利用相空间重构原理构建模型时序输入向量, 采用多层网格搜索方法选择最优隐含层数、隐含层节点数等模型参数, 以 BPTT 方法训练模型; 模型自动提取运动精度时间序列的时空特征, 挖掘精度时间序列前后关联信息, 对运动精度变化趋势进行预测。实验结果表明, 基于时序深度学习网络的预测模型能够准确预测数控机床精度的衰退趋势, 预测的最大相对误差不大于 7.96%, 优于传统方法。

**关键词:** 数控机床; 运动精度; 预测; 深度学习; 神经网络

**中图分类号:** TH115 **文献标识码:** A **文章编号:** 1000-1298(2019)01-0421-06

## Prediction Method of NC Machine Tools' Motion Precision Based on Sequential Deep Learning

YU Yongwei<sup>1</sup> DU Liuqing<sup>1</sup> YI Xiaobo<sup>2</sup> CHEN Gang<sup>2</sup>

(1. College of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China

2. Chongqing Gaokin Industry Co., Ltd., Chongqing 401122, China)

**Abstract:** Because of the difficult to analyze the evolution law of CNC machine tools accuracy through mathematical modeling, a method of motion accuracy modeling and prediction based on sequential deep learning network was proposed. A deep learning network was presented based on the long short-term memory (LSTM). Using the principle of phase space reconstruction, the sequence input vector of the model was constructed. The optimal parameters of the model, such as number of hidden layer and number of hidden layer node were determined based on multi-layer grid search algorithm. The model was trained with BPTT method. The mutual information before and after the precision time series was mined with data driven. The temporal and spatial characteristics of the motion accuracy series were automatically extracted through the deep learning network. Finally, the declining trend of motion accuracy was predicted by the model. The experiments results showed that the prediction model based on the sequential deep learning network could predict properly the evolutionary trends and regularity of the precision. The maximum relative error of prediction was not more than 7.96%. The prediction accuracy of the method was better than that of the traditional methods. The method was helpful for evaluating the reliability of NC machine tools and ensuring the machining accuracy.

**Key words:** NC machine tools; motion precision; prediction; deep learning; neural network

## 0 引言

数控机床运动精度预测能发现数控装备潜在的

失效模式, 避免突发性失效, 实现数控机床可靠性增长<sup>[1]</sup>。至今, 国内外学者在误差建模与补偿<sup>[2-3]</sup>、精度检测与辨识<sup>[4-6]</sup>等方面取得了较多研

收稿日期: 2018-10-21 修回日期: 2018-11-25

**基金项目:** 国家自然科学基金面上项目(51775074)、重庆市重点产业共性关键技术创新重点研发项目(cstc2017zdcy-zdyfX0066、cstc2017zdcy-zdyfX0073)和重庆市基础研究与前沿探索项目(cstc2018jcyjAX0352)

**作者简介:** 余永维(1973—), 男, 高级工程师, 博士, 主要从事检测技术研究, E-mail: f tong@126.com

**通信作者:** 杜柳青(1975—), 女, 教授, 博士, 主要从事智能制造技术研究, E-mail: lqdu1@126.com

究成果,而对精度随时间演化规律的研究较少。栗时平等<sup>[7]</sup>基于多体系统理论对数控机床加工精度进行了预测;胡占齐等<sup>[8]</sup>基于多体运动学原理对超重型数控机床的维护周期进行了预测;王民等<sup>[9]</sup>基于斜置锥台试件对五轴数控机床的加工精度进行了预测。

数控机床在使用过程中不断受到各种作用力的影响,系统内部各要素之间及与外部系统的相互作用具有明显的非线性特征,数控机床运动精度演化过程可视为一种具有混沌特征的复杂非线性过程,数控机床运动精度时间序列展示了精度的动态演化过程。近年来,深度学习技术在图像识别、模式识别等领域显出巨大潜力<sup>[10-15]</sup>。深度学习方法以数据驱动、自动地从数据中提取特征,对于分析非结构化、模式不明多变、跨领域的的数据有显著优势<sup>[16-17]</sup>。此外,与时序相关联的无限深度学习网络在学习新信息的同时能保持历史信息,即能够动态记忆历史

信息,自动提取动态时间序列的时空特征<sup>[18-19]</sup>。

本文针对使用条件(使用频率、加工零件、加工工艺参数等)基本一致的数控机床,提出基于时序深度学习网络的数控机床运动精度预测模型,采用深度学习方法自动提取精度时间序列的时空特征,对数控机床的精度衰退进行准确预测,以掌握数控机床精度保持性和精度状态。

## 1 基于 LSTM 的时序深度学习网络

数控机床运动误差劣化是一个渐变的动态时间序列,当前的运动精度状态与之前历史状态相互关联。长短时记忆(Long short-term memory, LSTM)网络是一种全互连的循环式神经网络(Recurrent neural networks, RNNs),神经元之间存在反馈连接,即具有“时间参数”,能够动态记忆历史信息,在学习新信息的同时保持历史信息留存持久化。长短时记忆(LSTM)单元结构如图1所示。

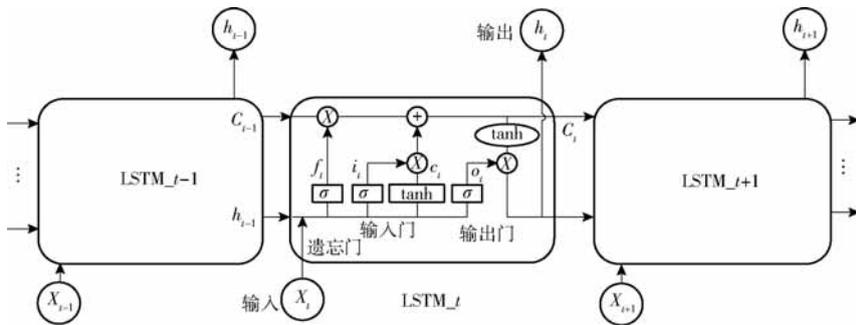


图1 基于 LSTM 的时序深度学习网络

Fig. 1 LSTM-based sequential deep learning network

每一个 LSTM 隐含层含有一个记忆单元,其由输入门、输出门、遗忘门和记忆单元组成。LSTM 通过以上门控单元来控制历史信息对当前信息的影响程度,使得网络模型能够较长时间保存并传递信息。

在当前  $t$  时刻, LSTM 单元输入有:  $t$  时刻的输入信号  $X_t$ 、 $t-1$  时刻 LSTM 单元的输出  $h_{t-1}$  (历史信号)、 $t-1$  时刻记忆单元的状态  $C_{t-1}$  (记忆信号); 输出为:  $t$  时刻 LSTM 单元的输出信号  $h_t$ 、 $t$  时刻记忆单元的状态  $C_t$ 。

$t$  时刻, LSTM 的输入门、遗忘门、输出门、记忆单元的状态分别为

$$i_t = \sigma(W_i h_{t-1} + W_i x_t + b_i) \quad (1)$$

$$f_t = \sigma(W_f h_{t-1} + W_f x_t + b_f) \quad (2)$$

$$o_t = \sigma(W_o h_{t-1} + W_o x_t + b_o) \quad (3)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c h_{t-1} + W_c x_t + b_c) \quad (4)$$

$t$  时刻, LSTM 的输出信号为

$$h_t = o_t \tanh(c_t) \quad (5)$$

式中,  $W_i$ 、 $W_f$ 、 $W_o$ 、 $W_c$  分别为输入门、遗忘门、输出门和记忆细胞的权值矩阵;  $b_i$ 、 $b_f$ 、 $b_o$ 、 $b_c$  分别为各门状

态的偏置;  $\tanh$  表示激活函数。

输入信号  $X_t = (x_1, x_2, \dots, x_{t-1}, x_t, x_{t+1}, \dots)$  为数控机床精度连续时间序列, 将 LSTM 的反馈结构在时间维度上展开, 在每一时刻, LSTM 展开为一个深度学习网络中的一层, 随着时间的不断运行, 网络的深度可以无限深, 即形成基于 LSTM 单元的时序深度学习网络, 如图1所示, 其计算输出序列  $H = (h_1, h_2, \dots, h_{t-1}, h_t, h_{t+1}, \dots)$ 。

## 2 基于时序深度学习网络的数控机床精度预测方法

LSTM 无限深度学习网络本质上是一个动力学系统, 网络状态随时间演化是这种网络的本质属性, 其耦合了“时间参数”, 能完全自动地从海量时序数据中学习数据中蕴含的抽象时空特征。而数控机床运动精度演化是一个动态的时间序列, 当前状态与历史状态相互关联。因此, 数控机床运动精度劣化过程与无限深度学习系统特性高度契合, 有利于实现运动精度动态行为演化及预测。

## 2.1 基于 LSTM 无限深度学习网络的运动精度预测模型

基于 LSTM 无限深度学习网络的数控机床运动精度预测模型如图 2 所示,其包括输入层、隐含层和输出层。输入层以运动精度时间序列为自变量,实现数据标准化、训练集划分等;输出层进行数据反标准化、计算预测输出等;机床运动精度预测模型在网络方向可有多个 LSTM 隐含层,每个 LSTM 隐含层在时间维度方向展开形成时序无限深度学习网络,自动挖掘运动精度序列时空特征。

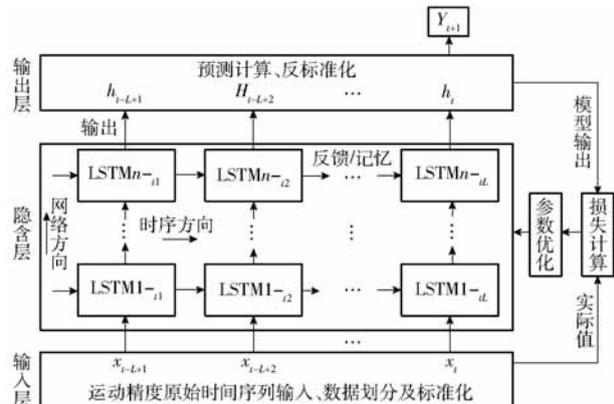


图 2 基于 LSTM 无限深度学习网络的数控机床运动精度预测模型

Fig. 2 Motion precision prediction model of NC machine tools based on LSTM infinite deep learning network

除预测模型的时间窗口长度  $L'$  外,还需确定模型的 3 个主要参数,即隐含层数、每个隐含层节点数及学习率。隐含层数即深度学习网络中 LSTM 层的个数,在训练样本充足条件下,深度学习模型的非线性拟合能力随隐含层数的增加而上升,但深度学习模型的复杂程度及训练时间及计算量也将随之增加。本文采用多层网格搜索方法确定隐含层数、每个隐含层节点数以及学习率等参数。

## 2.2 基于相空间重构的模型输入向量构建

预测模型的时间窗口长度  $L'$  为 LSTM 在时间维度上形成深度学习网络时的展开步数,也即用于运动精度预测的精度时间序列长度。过短的历史序列长度会引起预测经验知识的缺失,影响模型预测准确性;过长的历史序列长度又会加大模型训练及优化难度,也影响模型预测准确性。

根据 Takens 嵌入定理,如果重构的运动精度时间序列嵌入相空间满足  $L > 2d + 1$  ( $L$  为嵌入维数,  $d$  为吸引子分维数),则其与原精度系统的相空间轨迹具有相同的几何特性<sup>[20]</sup>。此嵌入维数即是预测模型的最优时间窗口长度  $L'$ 。基于相空间重构原理,采用虚假最近邻点法计算最小嵌入维数  $L$ ,即为最优时间窗口长度  $L'$ ,基本思想是:当重构相空间

维数从  $L$  增加到  $L + 1$ ,如相空间没有虚假的最近邻点,则认为几何结构被完全打开。

设  $X_L$  是  $X_i$  的最近邻点,两点之间的距离为

$$\|S_{Li}\|^{(L)} = \sqrt{\sum_{k=0}^{L-1} (X_{(L+k\tau)} - X_{(i+k\tau)})^2} \quad (6)$$

式中  $\tau$ ——延迟时间

当维数增加到  $L + 1$  时,距离为  $\|S_{(L+1)i}\|^{(L+1)}$ 。

如有  $\frac{\|S_{Li}\|^{(L+1)} - \|S_{(L+1)i}\|^{(L+1)}}{\|S_{Li}\|^{(L)}} > R_T, 10 \leq R_T \leq$

50,则  $X_L$  是  $X_i$  的虚假最近邻点。对于运动精度实测时间序列,令  $L$  从 2 开始,取  $R_T = 30$ ,计算虚假最近邻点的比例,以此求得的  $L$  即为最小嵌入维数,也即预测模型时间窗口分割长度。

数控机床运动精度原始时间序列经 Zscore 方法标准化后为  $X = (x_1, x_2, \dots, x_n)$ ,前  $m$  个时间样本点为训练集  $X_x = (x_1, x_2, \dots, x_m)$ , $m$  以后样本点为测试集  $X_c = (x_{m+1}, x_{m+2}, \dots, x_n)$ ,其中  $m < n, m, n \in \mathbf{N}$ ,参数  $m$  表示组成训练集的时间样本点数量, $n$  表示总的时间样本点数量。

如时间窗口分割长度为  $L'$ ,模型输入样本集为  $X = (X_1, X_2, \dots, X_k, \dots, X_L)$ ,其中输入向量  $X_k = (x_k, x_{k+1}, \dots, x_{m-L+k+1})$ ,则在  $t$  时刻,模型输入向量  $X_t = (x_{t-L+1}, x_{t-L}, \dots, x_t)$ ,对应的 LSMT 隐藏层输出为  $H = (h_{t-L+1}, h_{t-L}, \dots, h_t)$ ,预测输出为  $y_{t+1} = W_y h_t + b_y, W_y, b_y$  分别为输出层权值和偏置。

## 2.3 深度学习预测模型训练方法

LSTM 网络采用 BPPT (Back propagation through time) 算法进行训练,步骤如下:

(1) 前向计算。根据式 (1) ~ (5) 计算每个 LSTM 单元的输入门、遗忘门、输出门和记忆单元的状态及模型输出  $h_t$ 。

(2) 误差沿时序方向反向传播。在  $t$  时刻误差项  $\delta_t$  为损失函数  $E$  对输出值  $h_t$  的导数:  $\delta_t = \frac{\partial E}{\partial h_t}$ ;  $t - 1$  时刻,误差反向传播为:  $\delta_{t-1} = \delta_t \frac{\partial h_t}{\partial h_{t-1}}$ 。

误差沿网络方向反向传播。当前为第  $l$  层,  $l - 1$  层的误差项为损失函数对  $l - 1$  层加权输入  $net_{l-1}$  的导数,即:  $\delta_{l-1} = \frac{\partial E}{\partial net_{l-1}}$ 。

(3) 根据相应的误差项,计算每个权重的梯度,然后更新每个权值。

权值更新算法为

$$w_{\text{new}} = w_{\text{old}} + \eta \nabla_w$$

式中  $\nabla_w$ ——网络性能函数在权值空间内的梯度

(4) 重复步骤 (1) ~ (3),直到模型预测的均方

根误差收敛为止。

均方根误差 RMSE 收敛判别式为

$$\frac{RMSE(v-1) - RMSE(v)}{RMSE(v-1)} \leq \lambda$$

式中  $v$ ——训练次数

$\lambda$ ——极小阈值,一般设为小于 0.01

### 3 实验

两轴插补的圆运动精度能全面地反映数控机床运动精度演化状态,采用描述数控机床圆运动精度的圆度误差来验证与优化基于无限深度学习网络的运动精度预测方法。

以某企业大型数控龙门加工中心为对象,该机床主要加工大型船舶发动机缸体,为评估机床精度状态,需定期对机床作运动精度检测分析以评估机床精度状态,测试时机床作半径为 200 mm、进给速度为 1 000 mm/min 的两轴插补圆运动,用 Renishaw QC20 型球杆仪在线测量机床的圆度误差。以其近 5 年定期测试获得的 245 个圆运动误差为实验样本,将各时间点的圆度误差前后相减,标准化后得到该龙门加工中心 245 个圆度误差增量时间序列  $X = (x_1, x_2, \dots, x_{245})$ 。以前 230 个数据  $X_x = (x_1, x_2, \dots, x_{230})$  为训练样本,后 15 个数据为测试样本。

对圆度误差增量时间序列,用虚假最近邻点法求得最小嵌入维数  $L = 8$ ,此即预测模型的时间窗口分割长度。因此,模型输入样本集为  $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_k, \dots, \mathbf{X}_8), \mathbf{X}_k = (x_k, x_{k+1}, \dots, x_{k+223})$ ,则在  $t$  时刻,模型输入  $\mathbf{X}_t = (x_{t-7}, x_{t-6}, \dots, x_t)$ 。

采用多层网络搜索并交叉验证,优化隐含层数、学习率等超参数。当 LSTM 隐含层数为 2、每个隐含层节点数为 16、学习率 0.05 时,预测模型的训练集拟合精度达到最高。对预测模型中权重矩阵按均值为 0、方差为 1 的高斯分布随机初始化,偏置项均初始化为 0。采用 BPTT 方法,正向测试新得到的各层权值参数;反向修正预训练获得的初始权值;迭代 526 次时,模型预测的均方根误差收敛,获得最优预测模型。

用训练好的 LSTM 深度学习模型对 230 时刻点以后的运动精度数据进行预测,采用 5 步预测,即模型输入为  $X_{230} = (x_{t-7}, x_{t-6}, \dots, x_t) = (x_{223}, x_{224}, \dots, x_{230})$  时,依次迭代预测后 5 个时刻点的输出  $y_{231}$  至  $y_{235}$ ,以此类推,预测结果如图 3a 所示。该龙门加工中心圆度误差增量预测值与实际值变化趋势较一致,预测最大绝对误差为 0.065  $\mu\text{m}$ (图 3b),说明本

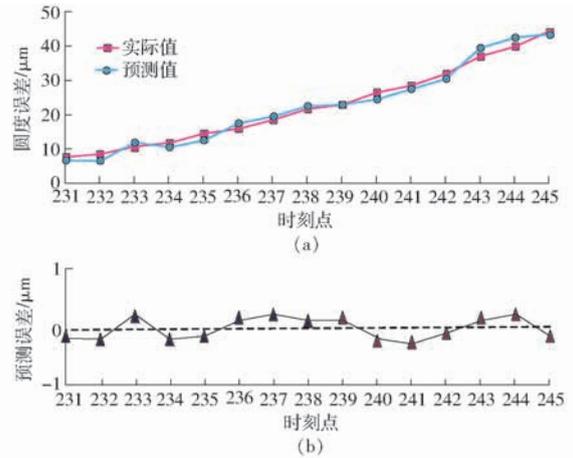


图3 圆度误差预测结果

Fig. 3 Prediction results of roundness error

文方法有较好的预测效果。

为评价预测模型的准确性,定义预测相对误差

$$E_r = (\hat{y}_t - y_t) / \hat{y}_t \times 100\%$$

相对误差最大为 5.05%,结果表明预测结果能够很好地反映该检测运动精度变化量的趋势和规律,预测精度较高。

用非平稳 ARIMA 时间序列预测法和 3 层 BP 神经网络预测法作对比实验,部分实验结果如表 1 所示。ARIMA 方法的最大相对误差为 14.85%,BP 神经网络预测方法为 18.17%。可见,本文方法预测精度明显优于其他两种方法,说明了本文方法的有效性。

表 1 预测相对误差比较

Tab. 1 Method comparison

| 时刻点 | 本文方法 | BP 方法 | ARIMA 方法 | % |
|-----|------|-------|----------|---|
| 231 | 3.75 | 15.52 | 11.26    |   |
| 232 | 3.26 | 16.58 | 12.11    |   |
| 233 | 4.01 | 16.89 | 12.76    |   |
| 234 | 4.17 | 17.25 | 14.80    |   |
| 235 | 3.89 | 16.99 | 12.61    |   |
| 236 | 3.12 | 17.88 | 13.18    |   |
| 237 | 4.67 | 17.05 | 13.55    |   |
| 238 | 4.38 | 17.97 | 14.28    |   |
| 239 | 4.05 | 18.05 | 14.85    |   |
| 240 | 5.05 | 18.17 | 14.77    |   |

为进一步验证本文方法的有效性及其适应性,对超高速数控磨床、数控车床、数控铣床等 10 台数控机床作同样的分析实验,提取运动精度周期检测数据,均得到了比较准确的结果,步长为 5 时,预测最大相对误差不大于 7.96%,各机床预测最大相对误差数据如表 2 所示。ARIMA 方法的最大相对误差为 15.29%,BP 神经网络预测方法为 19.90%。

表 2 各机床预测最大相对误差

Tab.2 Maximum error of machine tool prediction

|          |          |          |            | %        |          |          |            |
|----------|----------|----------|------------|----------|----------|----------|------------|
| 机床<br>编号 | 本文<br>方法 | BP<br>方法 | ARIMA<br>法 | 机床<br>编号 | 本文<br>方法 | BP<br>方法 | ARIMA<br>法 |
| 1        | 5.81     | 18.22    | 13.98      | 6        | 5.22     | 17.96    | 13.60      |
| 2        | 6.37     | 18.66    | 14.25      | 7        | 6.68     | 18.61    | 15.12      |
| 3        | 7.12     | 19.90    | 14.78      | 8        | 7.27     | 19.20    | 15.29      |
| 4        | 7.96     | 19.28    | 14.19      | 9        | 7.47     | 18.83    | 14.91      |
| 5        | 6.51     | 18.86    | 15.01      | 10       | 7.32     | 18.14    | 14.88      |

## 4 结束语

利用时序无限深度学习网络强大的时空特征自动提取能力,提出了一种基于 LSTM 无限深度学习网络的数控机床运动精度建模与预测方法,实验证明可以很好地预测数控机床精度的衰退趋势,有较高的预测精度和鲁棒性,圆度误差增量预测差相对误差不大于 7.96%,优于传统的 ARIMA 时序方法和 BP 网络预测方法。

## 参 考 文 献

- [1] 马军旭,赵万华,张根保. 国产数控机床精度保持性分析及研究现状[J]. 中国机械工程,2015,26(22):3108-3115. MA Junxu, ZHAO Wanhua, ZHANG Genbao. Research status and analyses on accuracy retentivity of domestic CNC machine tools[J]. China Mechanical Engineering,2015,26(22):3108-3115. (in Chinese)
- [2] 韩飞飞,赵继,张雷,等. 数控机床几何精度综合解析与试验研究[J]. 机械工程学报,2012,48(21):141-148. HAN Feifei, ZHAO Ji, ZHANG Lei, et al. Synthetical analysis and experimental study of the geometric accuracy of CNC machine tools[J]. Journal of Mechanical Engineering,2012,48(21):141-148. (in Chinese)
- [3] FUJIMORI T, TANIGUCHI K, ELLIS C, et al. A study on error compensation on high precision machine tool system using a 2D laser holographic scale system[J]. Journal of Advanced Mechanical Design, Systems and Manufacturing,2012,6(6):999-1114.
- [4] IBARAKI S, OYAMA C, OTSUBO H. Construction of an error map of rotary axes on a 5-axis machining center by static R-test [J]. International Journal of Machine Tools and Manufacture,2011,51(3):190-200.
- [5] MANN S, BEDI S, ISRAELI G, et al. Machine models and tool motions for simulating five-axis machining[J]. Computer-Aided Design,2010,42(3):231-237.
- [6] 萨日娜,张树有,刘晓健. 面向零件切削性评价的数控机床精度特性重要度耦合识别技术[J]. 机械工程学报,2013,49(9):113-120. SARINA, ZHANG Shuyou, LIU Xiaojian. Identification of accuracy characteristics importance of machine tool for parts machinability evaluation[J]. Journal of Mechanical Engineering,2013,49(9):113-120. (in Chinese)
- [7] 粟时平,李圣怡. 多体系统理论在数控加工精度软件预测中的应用[J]. 组合机床与自动化加工技术,2004(4):26-30. SU Shiping, LI Shengyi. Study about the application of multi-body system theory in machining precision of CNC machine tools [J]. Modular Machine Tool & Automatic Manufacturing Technique,2004(4):26-30. (in Chinese)
- [8] 胡占齐,刘金超,解亚非,等. 基于多体运动学的超重型数控机床维护周期预测[J]. 燕山大学学报,2012,36(3):201-214. HU Zhanqi, LIU Jinchao, XIE Yafei, et al. Prediction of super-heavy CNC machine maintenance cycle based on multibody kinematics[J]. Journal of Yanshan University,2012,36(3):201-214. (in Chinese)
- [9] 王民,胡建忠,咎涛,等. 基于斜置锥台的五轴数控机床加工精度预测技术[J]. 高技术通讯,2011,21(12):1299-1304. WANG Min, HU Jianzhong, ZAN Tao, et al. Prediction of the machining precision of five-axis NC machine tools based on cone frustum[J]. High Technology Letters,2011,21(12):1299-1304. (in Chinese)
- [10] 余永维,殷国富,殷鹰,等. 基于深度学习网络的射线图像缺陷识别方法[J]. 仪器仪表学报,2014,35(9):2012-2019. YU Yongwei, YIN Guofu, YIN Ying, et al. Defect recognition for radiographic image based on deep learning network [J]. Chinese Journal of Scientific Instrument, 2014,35(9):2012-2019. (in Chinese)
- [11] 余永维,杜柳青. 基于深度学习特征匹配的铸件微小缺陷自动定位方法[J]. 仪器仪表学报,2016,37(6):1364-1370. YU Yongwei, DU Liqing. Automatic location of casting small defect based on deep learning feature [J]. Chinese Journal of Scientific Instrument, 2016,37(6):1364-1370. (in Chinese)
- [12] 谭文学,赵春江,吴华瑞,等. 基于弹性动量深度学习神经网络的果体病理图像识别[J/OL]. 农业机械学报,2015,46(1):20-25. http://www.j-csam.org/jcsam/ch/reader/view\_abstract.aspx?flag=1&file\_no=20150104&journal\_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.01.004. TAN Wenxue, ZHAO Chunjiang, WU Huarui, et al. A deep learning network for recognizing fruit pathologic images based on flexible momentum [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015,46(1):20-25. (in Chinese)
- [13] 高震宇,王安,刘勇,等. 基于卷积神经网络的鲜茶叶智能分选系统研究[J/OL]. 农业机械学报,2017,48(7):53-58. http://www.j-csam.org/jcsam/ch/reader/view\_abstract.aspx?flag=1&file\_no=20170707&journal\_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.07.007. GAO Zhenyu, WANG An, LIU Yong, et al. Intelligent fresh-tea-leaves sorting system research based on convolution neural

- network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2017,48(7): 53 – 58. (in Chinese)
- [14] 孙钰, 韩京冶, 陈志泊, 等. 基于深度学习的大棚及地膜农田无人机航拍监测方法[J/OL]. 农业机械学报,2018,49(2): 133 – 140. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20180218&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180218&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2018.02.018.  
SUN Yu, HAN Jingye, CHEN Zhibo, et al. Monitoring method for UAV image of greenhouse and plastic-mulched landcover based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2018,49(2): 133 – 140. (in Chinese)
- [15] 余永维, 杜柳青, 闫哲, 等. 基于深度学习特征的铸件缺陷射线图像动态检测方法[J/OL]. 农业机械学报,2016,47(7): 407 – 412. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=201160755&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=201160755&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2016.07.055.  
YU Yongwei, DU Liqing, YAN Zhe, et al. Dynamic detection of casting defects radiographic image based on deep learning feature[J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2016,47(7): 407 – 412. (in Chinese)
- [16] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning,2009,2(1):1 – 127.
- [17] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science,2006,313(5786):504 – 507.
- [18] GERS F A, SCHMIDHUBER J. Learning to forget: continual prediction with LSTM[J]. Neural Computation,2000,12(10):2451 – 2471.
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8):1735 – 1780.
- [20] TAKENS F. Detecting strange attractor in turbulence [C]//Lecture Notes in Mathematics,1981,898:366 – 381.