

DOI: 10.19650/j.cnki.cjsi.J2311843

基于 CNN-GRU 组合神经网络的数控机床 进给系统热误差研究*

孙兴伟^{1,2}, 杨铜铜^{1,2}, 杨赫然^{1,2}, 董祉序^{1,2}, 刘 寅^{1,2}

(1. 沈阳工业大学机械工程学院 沈阳 110870; 2. 辽宁省复杂曲面数控制造技术重点实验室 沈阳 110870)

摘要:热变形引起的误差是影响数控机床精度的主要因素之一。为了减小热误差对数控机床精度的影响,提出一种基于 CNN-GRU 组合神经网络的热误差预测方法。通过热误差实验,采集螺旋曲面专用数控机床直线进给系统的温升数据和热误差数据;利用模糊 C 均值聚类和灰色关联度分析筛选进给系统温度敏感点;以温度敏感点的温升数据和进给系统热误差为数据样本,建立 CNN-GRU 热误差预测模型。为验证模型的准确性和实用性,与基于 CNN-LSTM 和基于 LSTM 的传统热误差预测模型进行预测对比分析,结果表明 CNN-GRU 模型预测结果的平均绝对误差、均方根误差和决定系数均优于 CNN-LSTM 模型和 LSTM 模型,具有较高的预测精度和鲁棒性。提供的热误差模型可为后续误差补偿奠定基础,为数控机床的热误差预测提供思路。

关键词:模糊 C 均值聚类;灰色关联度分析;进给系统;温度敏感点;误差预测

中图分类号: TH161⁺.1 TN05 **文献标识码:** A **国家标准学科分类代码:** 460.4030

Research on thermal error of CNC machine tool feed system based on CNN-GRU combined neural network

Sun Xingwei^{1,2}, Yang Tongtong^{1,2}, Yang Heran^{1,2}, Dong Zhixu^{1,2}, Liu Yin^{1,2}

(1. School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. Key Laboratory of Numerical Control Manufacturing Technology for Complex Surfaces of Liaoning Province, Shenyang 110870, China)

Abstract: The error caused by thermal deformation is one of the main factors affecting the accuracy of CNC machine tools. Correspondingly a thermal error prediction method based on CNN-GRU combined neural network is proposed to reduce the impact of thermal error on the accuracy of CNC machine tools. By conducting thermal error experiments, the temperature rise data and thermal error data of the linear feed system of a specialized CNC machine tool are collected for spiral surfaces. Then the fuzzy c-means clustering and grey relation analysis are carried out to screen temperature sensitive points in the feed system, and a CNN-GRU thermal error prediction model is established using temperature rise data of temperature sensitive points and thermal error of feed system as data samples. To verify the accuracy and practicality of model, a comparative analysis is conducted with traditional thermal error prediction models based on CNN-LSTM and LSTM. The results showed that the CNN-GRU model possesses the high prediction accuracy and robustness, whose average absolute error, root mean square error, and determination coefficient of the prediction results are better than those of the CNN-LSTM model and LSTM model. The proposed thermal error model can lay the foundation for subsequent error compensation and provide ideas for predicting thermal errors in CNC machine tools.

Keywords: fuzzy C-means clustering; grey relation analysis; feed system; temperature sensitive points; error prediction

0 引 言

随着精密和高精密制造技术的广泛应用和快速发

展,对数控机床的加工精度要求越来越高。影响机床加工精度的因素有很多,主要有几何和运动误差、热误差、切削力引起的误差以及其他误差(如刀具磨损和机床振动引起的误差)等^[1]。通过大量的研究发现,热变形引起

收稿日期:2023-08-27 Received Date: 2023-08-27

* 基金项目:辽宁省应用基础研究计划项目(2022JH2/101300214)、2022 年度辽宁省教育厅高等学校基本科研项目面上项目(LJKMZ20220459)资助

的误差占机床总加工误差的 40%~70%^[2],并且精度等级越高的机床其热误差所占总误差的比重就越大^[3]。因此,消除热误差影响对提高机床精度具有重要意义。

热误差是指机床部件热变形导致工件与刀具之间的相对位移而产生的加工误差^[4]。目前减小热误差主要有误差避免和误差补偿两种方法^[5]。误差避免可以通过优化结构设计、全闭环控制、冷却回路设计、热和谐设计等措施提高机床精度,如 Liang 等^[6]对机床各个零部件热位移进行分解研究,实现通过相互抵消零部件的热位移来减小热误差;Sun 等^[7]通过调整两个相邻部件的接触区域间隙降低传热效率,优化磨床电机连杆、主轴和主轴箱结构降低主轴的热误差。虽然误差避免能够有效抑制机床热误差,但运用误差避免的成本会随着机床精度的提高而显著增加。误差补偿主要是通过分析、统计和归纳,掌握机床敏感温度点对热误差的影响。利用热误差与温度敏感点之间的联系,建立热误差模型,基于该模型对机床热误差进行预测和补偿^[8]。与误差避免相比,利用误差补偿来降低机床热误差是一种更方便、更经济的方法,具有更加广阔的应用前景。由于热误差存在高度复杂性和非线性特性,且受多个耦合因素的影响,所以建立更加精准的热误差模型对机床热误差进行更加准确的预测和补偿至关重要。

刘宏伟等^[9]研究机床主轴热误差在额定转速下随时间变化关系,利用最小二乘法建立数学模型,有效提高了机床精度;Zhang 等^[10]采用多元线性回归方法建立预测模型,准确预测了滚珠丝杠在任意温度和位置下的热误差,并通过补偿大大提高了系统的定位精度;李永祥等^[11]利用函数变换法和等维新陈代谢法,改善灰色系统预测模型的数据序列平滑度,使预测模型具备输入数据动态更新的能力,提高了模型预测精度;李艳等^[12]提出一种基于互信息法和改进模糊聚类法相结合的机床温度测点优化方法,并与采用变量分组优化法建立的热误差模型进行对比,证明采用该方法建立的热误差模型能够有效提高机床 X 轴和 Y 轴的热变形预测精度;石彦龙等^[13]利用蛙跳算法(shuffled frog leaping algorithm, SFLA)对支持向量机(support vector machine, SVM)的关键参数寻优,建立的 SFLA-SVM 热误差预测模型相对于遗传算法(genetic algorithm, GA)优化支持向量机(GA-SVM)和遗传算法优化(back propagation, BP)网络(GA-BP),均方根误差分别减少了 58.5%和 66.0%;谭峰等^[14]提出的基于长短期记忆神经网络(long short-term memory, LSTM)的机床热误差预测方法,利用筛选的温度敏感点的温升数据建立 LSTM 预测模型,成功将热误差预测精度相较于传统热误差预测模型提高了约 50%;李彬等^[15]利用小波神经具有良好的时频局部特性优点,采用遗传算法优化小波神经关键参数建立热误差预测模

型,通过分析实验证明该模型具有预测精度高、抗扰动和鲁棒性高等优点。

上述机床热误差预测模型大多数是以温度敏感点的温度变化数据作为输入进行建模,没有考虑热误差的时间序列特性,导致预测精度受限。虽然 LSTM 属于循环神经网络(recurrent neural network, RNN)的一种变种模型,具有对数据时序性适应能力强的优点^[16],但是 LSTM 模型同时存在着所需训练参数较多、模型收敛较为耗时的缺点^[17]。而门控循环单元(gate recurrent unit, GRU)作为 LSTM 神经网络的一个优秀变体,不仅保持了 LSTM 的预测精度,同时还有效缩短了训练时间^[18]。但 GRU 网络在提取数据特征方面存在不足,因此本文利用卷积神经网络(convolutional neural networks, CNN)深度挖掘机床热误差与温度敏感点之间的联系,建立 CNN-GRU 组合神经网络机床热误差预测模型。利用模糊 C 均值聚类 and 灰色关联度分析对机床指定进给速度下的温升数据和热误差数据进行处理,筛选出机床进给系统温度敏感点。使用温度敏感点的温升数据作为输入,进给轴热误差数据作为输出训练 CNN-GRU 热误差预测模型,并与基于 CNN-LSTM 网络和基于 LSTM 网络的传统热误差预测模型进行对比,验证本文所提出的热误差预测方法的有效性。

1 热误差预测模型建立

1.1 CNN-GRU 热误差预测模型结构

本文提出的 CNN-GRU 热误差模型主要由温度敏感点筛选、CNN 网络和 GRU 网络组成,其结构如图 1 所示。通过利用 CNN 网络对输入的温度敏感点温升数据和进给轴热误差数据进行特征提取;然后利用序列展开层和扁平化层将数据传入 GRU 网络中进行模型预测训练,最后通过全连接层将预测结果输出。




图 1 CNN-GRU 热误差预测模型结构

Fig. 1 Structure diagram of CNN-GRU thermal error prediction model

模型主要结构如下:

1) 温度敏感点筛选。利用模糊 C 均值聚类 and 灰色关联度分析对采集到的机床进给系统温升数据和热误差数据进行处理,筛选出进给系统温度敏感点,再使用输入层将归一化后的温度敏感点的温升数据和进给轴热误差数据输入到神经网络模型中。

2) 序列折叠层、序列展开层和扁平化层。序列折叠层、序列展开层和扁平化层将输入的时间序列数据转化为适合后续神经网络的输入格式,以便数据特征的提取和神经网络模型的训练。

3) CNN 网络。CNN 网络主要由 2 个卷积层和 2 个池化层组成,实现对输入时间序列数据的特征提取。

4) GRU 网络。GRU 网络主要由 2 个门控循环单元、1 个随机失活层和 1 个全连接层组成,利用 CNN 网络提取的特征数据进行学习,实现对数据内部变化规律的掌握。

5) 数据输出。通过全连接层计算出输入数据的热误差值 $\mathbf{Y} = [y_1, y_2, y_3, \dots, y_m]^T$, 并进行数据输出。

1.2 温度敏感点筛选

为了提高模型预测精度,减少计算量,采用模糊 C 均值聚类和灰色关联度分析筛选出机床进给系统的温度敏感点。利用模糊 C 均值聚类进行反复迭代运算,得到最优隶属度矩阵 $\mathbf{U}$ 和聚类中心矩阵 $\mathbf{V}$,进而将机床进给系统温度测点的温升数据聚类为 3 类。聚类目标函数、隶属度和聚类中心分别如式(1)~(3)所示^[19-20]。

$$J(\mathbf{U}, \mathbf{V}) = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m d_{ij}^2 \quad (1)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{ik}} \right)^{\frac{2}{m-1}}} \quad (2)$$

$$v_j = \frac{\sum_{i=1}^n u_{ij}^m x_i}{\sum_{i=1}^n u_{ij}^m} \quad (3)$$

式中: $\mathbf{U}$ 为隶属度矩阵; $\mathbf{V}$ 为聚类中心矩阵; u_{ij} 为第 i 个样本属于第 j 类隶属度; m 为隶属度因子; $d_{ij} = \|x_i - v_j\|$ 为样本到聚类中心的距离。

然后使用灰色关联度分析对经模糊 C 均值聚类处理得到的 3 类温升数据与热误差之间的关联度进行计算,每类中关联度为最大值的温度测点即为该类中的温度敏感点,进而筛选出进给系统中的温度敏感点。关联系数和关联度如式(4)和(5)所示^[21-22]。

$$\zeta(k) = \frac{\min_i \min_k |x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|} \quad (4)$$

$$r_i = \frac{1}{n} \sum_{k=1}^n \zeta(k) \quad (5)$$

式中: $x_0(k)$ 为目标序列; $x_i(k)$ 为比较序列; ρ 为灰色分辨系数,取值为 0~1,一般取值为 0.5。

1.3 CNN-GRU 热误差预测模型

CNN 神经网络主要由输入层、卷积层、池化层、全连接层和输出层组成^[23],并通过引入卷积结构减少深层网络的内存占用量。CNN 神经网络具有局部连接、权值共享和池化操作 3 个关键特性,在减少网络参数个数和解决过拟合问题的同时,能够有效提取数据特征^[24]。为保证建立的预测模型可准确掌握机床温度敏感点和热误差之间的内在联系,提高模型整体性能,本文使用 CNN 神经网络对温度敏感点的温升数据和进给轴热误差数据进行特征提取,然后将处理后的数据导入后续神经网络,建立热误差预测模型。

1997 年提出的 LSTM 神经网络^[25]不仅能够有效解决传统 RNN 网络在处理长期依赖关系时存在的梯度消失或梯度爆炸问题,还能够处理时间序列数据时,捕获序列中的长期依赖关系,但 LSTM 神经网络同时也存在着内部结构复杂、训练时间长和有过拟合风险等问题。而 GRU 神经网络通过将 LSTM 神经网络中的输入门和遗忘门合并为更新门,使 GRU 神经网络只由重置门和更新门构成,简化了使用的门结构,减少了模型参数,从而有效提高模型训练效率。GRU 模型运算过程如式(6)~(9)所示^[26]。

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t]) \quad (6)$$

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t]) \quad (7)$$

$$\tilde{h}_t = \tanh(\mathbf{W}_h \cdot [r_t \times h_{t-1}, x_t]) \quad (8)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (9)$$

式中: $\mathbf{W}_z$ 、 $\mathbf{W}_r$ 和 $\mathbf{W}_h$ 为权重矩阵; σ 为激活函数 Sigmoid; r_t 为重置门; z_t 为更新门; x_t 为输入数据; h_{t-1} 为上一时间步隐藏状态; $\tilde{h}_t$ 为输入数据 x_t 上一时间步隐藏状态 h_{t-1} 的汇总; h_t 为隐藏层的输出。

2 热误差实验

2.1 实验过程

为了验证本文提出的热误差预测方法的有效性和准确性,选用螺旋曲面专用数控机床的直线进给轴进行热误差预测实验。使用雷尼绍 XL-80 激光干涉仪测量进给轴的定位精度,以获得进给轴准确的热误差数据;使用两个型号为 TXY606 的 8 通道液晶测控仪和 9 个分辨率为 0.1℃ 的 PT100 磁吸式温度传感器采集机床进给系统各部件温度数据,温度传感器主要分布在主轴箱、丝杠螺母、轴承座、床身等位置,具体安装位置如表 1 和图 2 所示。

表 1 温度传感器安装位置

Table 1 Installation position of temperature sensor

传感器安装位置	传感器编号
丝杠后轴承座后端面	T1
丝杠后轴承座前端面	T2
丝杠螺母外壳端面	T3
丝杠前轴承端面	T4
主轴箱后端面	T5
主轴箱上端面	T6
主轴箱前端面	T7
床身内壁	T8
环境温度	T9




图 2 温度传感器安装位置

Fig. 2 Installation position of temperature sensor

为了获取各温度测点准确的温度数据,关闭机床冷却系统以消除切削液的影响,并在 $28^{\circ}\text{C}\pm 1^{\circ}\text{C}$ 恒定环境温度下进行实验,现场实验装置如图 3 所示。




图 3 实验装置

Fig. 3 Test device

测量机床进给轴以 1.0 m/min 进给速度空载运行时,进给系统各个温度测点的温升状况以及机床进给轴各位置测点的热误差数据。

进给轴测量范围为 $-1\ 600\sim -200\text{ mm}$,相邻位置测点间距为 200 mm ,共设置 8 个位置测点,分别为 P1~P8,位置测点分布如图 4 所示。每次实验总时长为 300 min ,每 10 min 采集一次温度数据和热误差数据,每次实验间隔至少 24 h 。为避免丝杠的反向间隙影响进给系统定位误差测量,在丝杠两端位置测点分别设置 20 mm 超程。




图 4 进给轴测点位置分布

Fig. 4 Distribution of measurement points on the feed axis

2.2 实验结果分析

通过热误差实验获得的指定进给速度下机床各温度测点的温升曲线如图 5 所示。从实验数据可以看出各个温度测点的温度随着时间逐步上升,在 $0\sim 200\text{ min}$ 时温升最为显著,其中主轴箱上温度测点 T4~T7 的上升幅度最大。当连续运行 250 min 之后,各温度测点温度变化较小,机床整体趋于热稳态。各温度测点中丝杠前轴承端面 T4 的温升最高,最高为 7.9°C ,其次是主轴箱前端面 T7 最高为 7.6°C 。由于本文选用的螺旋曲面专用数控机床的床身体积较大,因此床身的散热面积较大,热量扩散速度较快,但同时由于实验过程中机床进给系统处于运行状态,持续产生热量,因此床身 T8 温升呈现波动上升趋势。而主轴箱、丝杠螺母、轴承座等部件散热面积较小,因此温度测点 T1~T7 呈现稳步上升趋势。由图 6 的进给轴热误差曲线可得,各位置测点的热误差值都随着时间产生相应变化,产生热误差最大的位置测点分别为进给轴 $-1\ 600$ 和 -600 mm 处,最大热误差值分别为 80.5 和 $-48.6\text{ }\mu\text{m}$,其次为 -400 mm 位置测点处,最大热误差值为 $33.9\text{ }\mu\text{m}$ 。相较于上述 3 个位置测点,剩余位置测点的误差值变化较为集中,主要在 $\pm 20\text{ }\mu\text{m}$ 内变化。




图 5 测点温升曲线

Fig. 5 Temperature rise curve of measuring point




图 6 进给轴热误差曲线
Fig. 6 Thermal error curve of feed axis

3 关键温度敏感点确定及热误差模型建立

3.1 关键温度敏感点确定

温度敏感点在准确表示机床温升特性的同时,还能够降低温升数据冗余,提高建模效率和模型预测精度。利用模糊 C 均值聚类和灰色关联度分析对采集到的各温度测点温升数据和进给轴热误差数据进行处理,进而确定机床进给系统的温度敏感点。确定的温度敏感点及其温升曲线如表 2 和图 7 所示。

表 2 进给系统温度敏感点

分组	测点 FCM 聚类	温度敏感点
1	T1、T2、T9	T1
2	T3、T8	T3
3	T4、T5、T6、T7	T4




图 7 敏感点温升曲线
Fig. 7 Temperature rise curve of sensitive points

3.2 CNN-GRU 热误差预测模型验证

CNN-GRU 热误差预测模型主要由 CNN 网络和 GRU 网络构成,CNN 网络负责数据特征提取,GRU 网络负责热误差预测。将 CNN-GRU 热误差预测模型中的输入层和输出层单元个数分别设置为 4 和 1,梯度下降算法设置为 Adam,最小训练批次设置为 31,最大训练周期设置为 1 500,学习率设置为 0.01。从机床进给系统温度敏感点的温升数据和进给轴热误差数据中,每 8 个取出 1 个组成测试集,剩余数据作为训练集,然后对训练集和测试集进行归一化处理,再在设置的训练参数下利用训练集进行 CNN-GRU 热误差预测模型训练,训练结束后使用测试集对热误差模型进行预测性能验证,模型热误差预测结果如图 8 所示。




图 8 测试集预测对比
Fig. 8 Prediction comparison chart with test set

4 热误差预测模型对比分析

为验证 CNN-GRU 热误差预测模型的优越性,设置相同的模型训练参数,使用相同的训练集分别训练基于 CNN-LSTM 神经网络和 LSTM 神经网络的热误差预测模型,然后利用测试集样本数据对上述两种热误差预测模型进行测试,并与本文提出的 CNN-GRU 热误差预测模型进行对比,得到的各模型预测结果如表 3 所示,模型预测评价指标如表 4 所示,各模型的热误差预测值与实际值的对比如图 9 所示。

从表 4 可得,CNN-GRU 模型预测结果的最大绝对误差、最小绝对误差以及平均绝对误差均小于 CNN-LSTM 模型和 LSTM 模型;CNN-GRU 模型预测结果的均方根误差 RMSE 为 2.20 相较于 CNN-LSTM 模型和 LSTM 模型的 2.85 和 8.76,分别降低了 22.8% 和 74.9%;CNN-GRU 模型预测结果的决定系数 R^2 为 0.995,均优于 CNN-LSTM 模型和 LSTM 模型的 0.952 和 0.923。因此,本文所提出的 CNN-GRU 热误差预测模型相较于基于

表 3 热误差预测模型预测结果

Table 3 Prediction results of thermal error prediction model

实验组数	原数据	CNN-GRU	绝对误差	CNN-LSTM	绝对误差	LSTM	绝对误差
1	-27.90	-27.10	0.800 0	-27.300	0.600 0	-24.900	3.000
2	-37.60	-38.80	1.200 0	-37.100	0.500 0	-32.500	5.100
3	-45.70	-46.20	0.500 0	-45.100	0.600 0	-36.700	9.000
4	0	-2.68	2.680 0	-0.703	0.703 0	5.160	5.160
5	-1.20	-1.36	0.160 0	-4.220	3.020 0	1.880	3.080
6	11.00	8.93	2.070 0	9.390	1.610 0	3.020	7.980
7	16.20	15.00	1.200 0	14.900	1.300 0	3.480	12.700
8	-9.30	-5.59	3.710 0	-3.300	6.000 0	15.700	2.290
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
25	8.70	3.57	5.130 0	3.850	4.850 0	-0.598	9.300
26	26.00	27.50	1.500 0	30.100	4.100 0	35.700	9.700
27	33.50	34.20	0.700 0	32.300	1.200 0	37.500	4.000
28	-3.60	-3.61	0.010 0	-2.040	1.560 0	-3.130	0.470
29	-4.60	-5.07	0.470 0	-4.520	0.080 0	-3.550	1.050
30	-4.20	-4.94	0.740 0	-1.330	2.870 0	-4.010	0.190
31	-4.20	-5.55	1.350 0	-1.570	2.630 0	-4.560	0.360

表 4 热误差预测模型评价指标

Table 4 Evaluation indicators of thermal error prediction model

模型	$e_{imin}/\mu\text{m}$	$e_{imax}/\mu\text{m}$	MAE	RMSE	R^2
CNN-GRU	5.90×10^{-3}	5.13	1.71	2.20	0.995
CNN-LSTM	7.40×10^{-3}	6.00	2.30	2.85	0.952
LSTM	1.85×10^{-1}	20.40	7.32	8.76	0.923




图 9 模型预测结果对比

Fig. 9 Comparison of model prediction results

CNN-LSTM 和基于 LSTM 的传统热误差预测模型具有更高的预测精度。

5 结 论

本文以螺旋曲面专用数控机床为实验对象,利用 CNN 神经网络能够有效提取数据特征和 GRU 神经网络训练效率高的优点,建立 CNN-GRU 神经网络热误差预测模型。以经过模糊 C 均值聚类 and 灰色关联度分析筛选得到的机床进给系统温度敏感点的温升数据和机床直线进给轴热误差数据为训练数据,训练得到具有高精度预测能力的热误差预测模型。

为验证本文提出的热误差预测模型的有效性和优越性,与使用相同训练集和测试集的 CNN-LSTM 模型和 LSTM 模型进行预测结果对比分析,结果表明本文所提出的 CNN-GRU 热误差预测模型的预测精度均优于对比模型。因此基于 CNN-GRU 组合神经网络的热误差预测模型具有更好的热误差预测性能,为数控机床的热误差建模及补偿提供了一种新的思路。

参考文献

[1] LI Y, ZHAO W H, LAN S H, et al. A review on spindle thermal error compensation in machine tools [J]. International Journal of Machine Tools and Manufacture, 2015, 95: 20-38.

[2] LI Y, YU M L, BAI Y M, et al. A review of thermal error modeling methods for machine tools [J]. Applied

- Sciences, 2021, 11(11): 5216.
- [3] 魏新园, 钱牧云, 冯旭刚, 等. 基于偏最小二乘的数控机床热误差稳健建模算法[J]. 仪器仪表学报, 2021, 42(5): 34-41.
- WEI X Y, QIAN M Y, FENG X G, et al. Robust modeling method for thermal error of CNC machine tools based on partial least squares algorithm[J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 34-41.
- [4] 刘阔, 韩伟, 王永青, 等. 数控机床进给轴热误差补偿技术研究综述[J]. 机械工程学报, 2021, 57(3): 156-173.
- LIU K, HAN W, WANG Y Q, et al. Review on thermal error compensation for feed axes of CNC machine tools[J]. Journal of Mechanical Engineering, 2021, 57(3): 156-173.
- [5] 吕学祜, 郭前建, 王昊天, 等. 数控机床误差补偿关键技术综述[J]. 航空制造技术, 2022, 65(11): 104-111, 119.
- LYU X H, GUO Q J, WANG H T, et al. Summary of key technologies for error compensation of CNC machine tools[J]. Aeronautical Manufacturing Technology, 2022, 65(11): 104-111, 119.
- [6] LIANG Y C, SU H, LU L H, et al. Thermal optimization of an ultra-precision machine tool by the thermal displacement decomposition and counteraction method[J]. The International Journal of Advanced Manufacturing Technology, 2015, 76(1-4): 635-645.
- [7] SUN L J, REN M J, HONG H B, et al. Thermal error reduction based on thermodynamics structure optimization method for an ultra-precision machine tool[J]. The International Journal of Advanced Manufacturing Technology, 2017, 88(5-8): 1267-1277.
- [8] CHEN T C, CHANG C J, HUNG J P, et al. Real-time compensation for thermal errors of the milling machine[J]. Applied Sciences, 2016, 6(4): 101.
- [9] 刘宏伟, 杨锐, 向华, 等. 基于最小二乘法的机床主轴热误差补偿技术研究[J]. 机械设计与研究, 2020, 36(6): 130-133.
- LIU H W, YANG R, XIANG H, et al. Research on thermal error compensation technology of machine tool spindle on least square method[J]. Machine Design and Research, 2020, 36(6): 130-133.
- [10] ZHANG J, LI B, ZHOU C X, et al. Positioning error prediction and compensation of ball screw feed drive system with different mounting conditions[J]. Proc IMechE Part B: J Engineering Manufacture, 2016, 230(12): 2307-2311.
- [11] 李永祥, 杨建国, 李昱瑶, 等. 基于灰色系统的机床热误差建模研究[J]. 武汉理工大学学报, 2007(1): 58-61.
- LI Y X, YANG J G, LI Y Y, et al. Application of grey system model to thermal error modeling on machine tools[J]. Journal of Wuhan University of Technology, 2007(1): 58-61.
- [12] 李艳, 李英浩, 高峰, 等. 基于互信息法和改进模糊聚类的温度测点优化[J]. 仪器仪表学报, 2015, 36(11): 2466-2472.
- LI Y, LI Y H, GAO F, et al. Investigation on optimization of temperature measurement key points based on mutual information and improved fuzzy clustering analysis[J]. Chinese Journal of Scientific Instrument, 2015, 36(11): 2466-2472.
- [13] 石彦龙, 田春苗, 阿勇嘎, 等. 混合蛙跳算法优化 SVM 的进给轴热误差预测研究[J]. 航空制造技术, 2021, 64(22): 48-55.
- SHI Y L, TIAN C H M, A Y G, et al. Research on SFLA-SVM prediction method for feed axis thermal error of CNC machine tool[J]. Aeronautical Manufacturing Technology, 2021, 64(22): 48-55.
- [14] 谭峰, 李成南, 萧红, 等. 基于 LSTM 循环神经网络的数控机床热误差预测方法[J]. 仪器仪表学报, 2020, 41(9): 79-87.
- TAN F, LI C H N, XIAO H, et al. A thermal error prediction method for CNC machine tool based on LSTM recurrent neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 79-87.
- [15] 李彬, 张云, 王立平, 等. 基于遗传算法优化小波神经网络数控机床热误差建模[J]. 机械工程学报, 2019, 55(21): 215-220.
- LI B, ZHANG Y, WANG L P, et al. Modeling for CNC machine tool thermal error based on genetic algorithm optimization wavelet neural networks[J]. Journal of Mechanical Engineering, 2019, 55(21): 215-220.
- [16] 惠文珊, 李会军, 陈萌, 等. 基于 CNN-LSTM 的机器人触觉识别与自适应抓取控制[J]. 仪器仪表学报, 2019, 40(1): 211-218.
- HUI W S H, LI H J, CHEN M, et al. Robotic tactile recognition and adaptive grasping control based on CNN-LSTM[J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 211-218.
- [17] 姚程文, 杨苹, 刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
- YAO C H W, YANG P, LIU Z J. Load forecasting method based on CNN-GRU hybrid neural network[J]. Power System Technology, 2020, 44(9): 3416-3424.

- [18] SAJJAD M, KHAN Z A, ULLAH A, et al. A novel CNN-GRU-Based hybrid approach for short-term residential load forecasting[J]. IEEE Access, 2020, 8: 143759-143768.
- [19] 谭峰, 殷鸣, 彭骥, 等. 基于集成 BP 神经网络的数控机床主轴热误差建模[J]. 计算机集成制造系统, 2018, 24(6): 1383-1390.
- TAN F, YIN M, PENG J, et al. CNC machine tool spindle thermal error modeling based on ensemble BP neural network[J]. Computer Integrated Manufacturing Systems, 2018, 24(6): 1383-1390.
- [20] 李国龙, 陈孝勇, 李喆裕, 等. 采用天鹰优化卷积神经网络的精密数控机床主轴热误差建模[J]. 西安交通大学学报, 2022, 56(8): 51-61.
- LI G L, CHEN X Y, LI ZH Y, et al. Thermal error modeling of spindle for precision CNC machine tool based on AO-CNN[J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 51-61.
- [21] 徐凯, 李国龙, 李喆裕, 等. 直线轴热定位误差解耦与分步建模研究[J]. 仪器仪表学报, 2022, 43(7): 72-81.
- XU K, LI G L, LI ZH Y, et al. Research on decoupling and step-by-step modelling of thermal positioning error of the linear axis [J]. Chinese Journal of Scientific Instrument, 2022, 43(7): 72-81.
- [22] 张林, 陈国华, 赵殿章, 等. 基于模糊聚类与灰色理论的机床主轴温度测点优化方法[J]. 机床与液压, 2020, 48(22): 85-90.
- ZHANG L, CHEN G H, ZHAO D ZH, et al. Optimization method of machine tool spindle temperature measuring point based on fuzzy clustering and grey theory[J]. Machine Tool & Hydraulics, 2020, 48(22): 85-90.
- [23] 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. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [24] 贾睿, 杨国华, 郑豪丰, 等. 基于自适应权重的 CNN-LSTM&GRU 组合风电功率预测方法[J]. 中国电力, 2022, 55(5): 47-56, 110.
- JIA R, YANG G H, ZHENG H F, et al. Combined wind power prediction method based on CNN-LSTM&GRU with adaptive weights [J]. Electric Power, 2022, 55(5): 47-56, 110.
- [25] 刘国海, 孙文卿, 吴振飞, 等. 基于 Attention-GRU 的短期光伏发电功率预测[J]. 太阳能学报, 2022, 43(2): 226-232.
- LIU G H, SUN W Q, WU ZH F, et al. Short-time photovoltaic power forecasting based on Attention-GRU model[J]. Acta Energiae Solaris Sinica, 2022, 43(2): 226-232.
- [26] 阳雨妍, 宋爱国, 沈书馨, 等. 基于 CNN-GRU 的遥操作机器人操作者识别与自适应速度控制方法[J]. 仪器仪表学报, 2021, 42(3): 123-131.
- YANG Y Y, SONG AI G, SHEN SH X, et al. Operator recognition and adaptive speed control method of teleoperation robot based on CNN-GRU [J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 123-131.

作者简介



孙兴伟, 分别于 1992 年和 1995 年在沈阳工业大学获得学士和硕士学位, 于 2006 年在天津大学获得工学博士学位。现为沈阳工业大学机械工程学院教授, 博士生导师, 主要研究方向为复杂曲面测量与数控加工轨迹优化、数控技术与专用集成数控系统、CAD/CAM/CAE 技术等。

E-mail: sunxingw@126.com

Sun Xingwei received her B.Sc. degree and M.Sc. degree both from Shenyang University of Technology in 1992 and 1995, and received her Ph.D. degree from Tianjin University in 2006. She is currently a professor and a doctoral supervisor in the School of Mechanical Engineering at Shenyang University of Technology. Her main research interests include complex surface measurement and NC machining trajectory optimization, CNC technology and dedicated integrated CNC system, and CAD/CAM/CAE technology.



杨赫然 (通信作者), 分别于 2006 年、2008 年和 2012 年在吉林大学获得学士、硕士和博士学位, 现为沈阳工业大学机械工程学院副教授, 主要研究方向为复杂曲面数字化制造技术与装备。

E-mail: yangheran@sut.edu.cn

Yang Heran (Corresponding author) received his B.Sc. degree, M.Sc. degree and Ph.D. degree all from Jilin University in 2006, 2008 and 2012, respectively. He is currently an associate professor at Shenyang University of Technology. His main research interests include digital manufacturing technology and equipment of complex surface.