

基于改进卷积神经网络的数控机床旋转轴热误差建模方法

马剑超, 项四通*

(宁波大学 机械工程与力学学院, 浙江 宁波 315211)

摘要: 为对五轴数控机床旋转轴的热误差进行更精确地预测, 解决变工况条件下预测精度不佳与热误差数据获取困难的问题, 提出了基于改进卷积神经网络的热误差建模方法. 采用激光干涉仪与热成像仪采集不同温度下的角度定位误差与热图像, 对热误差进行傅里叶函数拟合, 将预测目标由不同角度下的热误差转变为拟合函数参数. 在 VGG 网络模型架构上, 引入 SKNet 注意力机制, 以提高模型对变工况下的热图像特征提取水平, 并采用全局平均池化代替全连接层, 以改善过拟合情况. 将建立的模型用于热误差预测, 结果表明, 旋转轴热误差预测 RMSE 在升温状态下为 8.36", 降温条件下为 9.57", 预测精度达 90%以上, 优于普通卷积神经网络模型. 结果证实了所提方法在旋转轴热误差建模中的有效性.

关键词: 五轴数控机床; 旋转轴; 热误差; 角度定位误差; 改进卷积神经网络

中图分类号: TH164

文献标志码: A

文章编号: 1001-5132 (2023) 02-0108-08

五轴机床已广泛应用于航空航天等重要领域, 并且旋转轴的引入同时提高了工件的加工精度和加工效率, 在五轴加工中起到了关键的作用. 热误差是影响机床精度的重要因素, 诸多文献显示热误差约占机床总误差的 40%~70%^[1-3]. 即使机床的静态精度很高, 但由于环境温度变化和运动部件发热等原因, 也会导致机床的精度降低.

目前学者们主要以主轴与平动轴作为热误差的研究重点, 而针对旋转轴热误差建模的研究较少. 随着对五轴加工要求与工件精度要求的提高, 旋转轴热误差对加工精度的影响越来越大^[4], 因此有必要对旋转轴的热误差进行建模并补偿. 热误差建模方法可分为理论热误差建模和经验热误差建模^[5]. 由于旋转轴热误差机理复杂, 故多数采用经验热误差建模方法, 建立热误差与运动过程中的温度、损耗等信息间的函数映射关系.

Bitar-Nehme 等^[4]使用一个非接触的 R-Test 装置将热误差建模为一阶函数来测量旋转轴驱动功耗, 但整个测量周期需控制在 3 min 以内, 从而减小测量过程额外引起的热变化. Wegener 等^[6]用一个

特征工件来测试旋转轴热误差, 但是 4 个面型需要分别铣削才能辨识热误差, 且很难通过耦合得到整体热误差. Ibaraki 等^[7]提出一种基于工件切削在线测量方法来分析热误差来源, 但因为主轴长时间转动易产生轴向热漂移, 故无法精确分离旋转轴热误差的来源. Yang 等^[8]利用 Elman 神经网络建立热误差模型, 并将结果与 RBF 神经网络预测结果进行比较, 预测精度得到提高. 但 Elman 神经网络有个缺点, 对于相同输入数据, 不同时刻产生的输出也可能不同, 这也就大大影响了模型的准确性. Chang 等^[9]利用动态前馈神经网络, 其输入变量根据时间序列被修正. 夏军勇等^[10]利用分组显式算法对有限长一维杆的热问题进行数值求解, 并提出利用 NARMAX 时序模型与神经网络模型相结合方式对某丝杠进给系统热误差进行预测.

基于上述问题, 本文以热影响下的旋转轴角度定位误差作为建模对象, 建立以大量热图像驱动的改进卷积神经网络模型对热误差进行预测. 热图像可全面反映旋转轴温度场分布信息, 旋转轴产生的热量可视化多被用于定性分析旋转轴的

收稿日期: 2022-03-28.

宁波大学学报(理工版)网址: <http://journalg.nbu.edu.cn/>

基金项目: 国家自然科学基金(52175470); 浙江省自然科学基金(LY20E050005).

第一作者: 马剑超(1998-), 男, 浙江温州人, 在读硕士研究生, 主要研究方向: 五轴数控机床. E-mail: w15757400310@163.com

*通信作者: 项四通(1989-), 男, 浙江绍兴人, 副教授, 主要研究方向: 五轴数控机床. E-mail: xiangsitong@nbu.edu.cn

输入热量^[11], 但很少有人将其用于热误差的直接预测. 该模型以旋转轴的多组热图像作为输入端, 在 VGG16 网络模型基础上, 去掉全连接层, 在瓶颈层后采用选择性核卷积模块及全局平均池化, 不仅不影响精度, 还可以减少参数量. 与其他卷积神经网络相比, 具有识别能力更强、准确率更高、收敛速度更快的特点.

1 热误差模型训练数据获取

1.1 热图像采集

如图 1 所示, 本文以 DMU70V 五轴数控加工中心的旋转轴 C 轴为例, 建立其热误差模型. 该机床的运动部件由 3 个平动轴 X 、 Y 、 Z 与 2 个旋转轴 B 、 C 构成, 可实现空间任意角度的加工. 五轴加工过程中, C 轴以蜗轮蜗杆驱动, 产生大量热量, 影响机床的加工精度.




图1 五轴数控机床的旋转轴

本文通过改进卷积神经网络对热图像进行特征提取, 可建立热图像中的 C 轴热量变化与热误差值之间的映射关系. 热图像记录了物体本身向外辐射的热量或温度, 可通过不同像素值反映拍摄目标的热量变化.

为可视化 C 轴热量变化, 采用热像仪 FLUKE Ti400 对 C 轴进行拍摄, 以获得 C 轴在加工时的发热情况. 如图 2 所示, 经过持续的旋转运动后, 由于

蜗轮蜗杆等部件受到负载与摩擦的作用, C 轴温度明显升高, 因此以 C 轴作为拍摄对象的热图像适用于改进卷积神经网络的特征建模.




图2 不同温度的 C 轴热图像

1.2 角度定位误差测量

旋转轴 C 在旋转加工时会产生误差, 并且角度定位误差对旋转轴精度的影响最大^[12]. 为有效提高机床的加工精度, 本文以温度影响下的角度定位误差作为建模对象. 采用双路激光旋转轴测量方法^[13], 通过激光干涉仪 MCV-5000 来测量 C 轴的角度定位误差. 如图 3 所示, 测量 1 组角度定位误差需将 C 轴旋转 1 周, 每转过 10° 用激光干涉仪采集 1 次数据, 每组误差数据包含 36 个测量点.





图3 角度定位误差测量

C 轴升温前、升温 60 min、升温 120 min、升温 180 min 后测得的角度定位误差如图 4(a)所示. 为了减少改进卷积神经网络的训练参数, 将测量得到的角度定位误差拟合为傅里叶函数曲线, 拟合后的曲线如图 4(b)~(e)所示, 图形分别是 C 轴升温前、升温 60 min、升温 120 min、升温 180 min 后的角度定位误差拟合曲线, 拟合方程如下:

$$f(x) = a_0 + a_1 \cos(wx) + b \sin(wx). \quad (1)$$



(a) 测量热误差; (b) 升温前的误差拟合; (c) 升温 60 min; (d) 升温 120 min; (e) 升温 180 min.

图 4 升温过程中的热误差变化

2 改进的 VGG16 网络模型

2.1 网络模型结构

VGG16 被广泛应用于图像处理领域, 其在 ImageNet 数据集上取得了理想分类效果. 但对于基于热图像的旋转轴热误差预测, 该网络模型存在以下缺点: 一方面, 当热图像的采集角度、距离以及旋转轴的运动状态等因素发生变化时, VGG16 网络模型无法自适应调整其感受野大小, 这限制了热误差模型的鲁棒性; 另一方面, 旋转轴热误差的测量时间较长, 训练数据集获取困难. VGG16 网络中的全连接层带有复杂的参数优化操作, 会造成模型过拟合, 严重影响了热误差的预测精度.

针对热误差模型的预测精度与鲁棒性问题, 本文提出了一种基于改进卷积神经网络的旋转轴

热误差模型, 模型结构如图 5 所示. 在 VGG16 网络模型的基础上, 通过迁移学习方法, 完成预训练的 VGG16 网络用于热图像的特征提取. 在瓶颈层后搭建 SK 卷积模块, 依次通过全局平均池化与 softmax 分类器, 最后输出 4 组独立的概率分布, 分别对热误差拟合函数的目标参数进行预测. 根据目标参数预测值得到采用傅里叶函数拟合的热误差曲线, 最终实现不同运动角度下的热误差预测.

提出的热误差模型利用 SK 模块可根据输入不同特征图自适应调整卷积核大小的特点, 提高其多维度特征提取水平, 令模型适用于不同状态下的旋转轴热图像. 同时, 热误差模型通过引入全局平均池化层, 以减少训练参数, 并提高收敛速度, 从而避免了模型产生过拟合, 保证了热误差的预测精度.




图 5 改进卷积神经网络模型结构

2.2 SKNet 注意力机制

不同条件下采集的旋转轴热图像对不同大小卷积核的敏感程度不同. 传统卷积神经网络多使用同一尺寸的卷积核^[14], Inception 网络使用多尺寸卷积核, 但无法根据输入目标动态地调整卷积核尺寸. 如图6所示, 本文基于SKNet注意力机制^[15], 针对不同采集角度、距离以及运动状态下的旋转轴热图像, 自适应选择卷积核大小, 主要包括分离、融合与选择三部分操作. 图中 F_{gp} 表示全局平均池化层, F_{fc} 表示全连接层.

首先对经过瓶颈层处理的输出特征图进行分离操作. 采用多个不同尺寸的卷积核, 对输入特征向量 X 进行卷积运算, 以形成多个路径, 其空间尺寸为 $H \times W$, 通道数为 C . 考虑到模型计算量与热误差补偿的实时性, 本文仅采用大小为 3×3 与 5×5 的卷积核, 分别得到 $U' \in R^{H \times W \times C}$ 与 $U'' \in R^{H \times W \times C}$ 的 2 个特征向量.

在对输出特征图进行分离操作后, 需对不同感受野信息进行融合. 通过门控机制组合多路径的特征信息, 可获得选择性权重的全局综合表示. 如式(2)所示, 由于分离得到的特征向量 U' 与 U'' 的维度相同, 因此可通过逐元素相加, 得到特征图 $U \in R^{H \times W \times C}$.

$$U = U' + U'' \quad (2)$$

如式(3)所示, 通过全局平均池化层将特征图 U 的空间特征信息转化为一维向量 $s \in R^C$, 代表特征图 U 各通道的统计特征信息.

$$s_c = F_{gp}(U) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U(i, j) \quad (3)$$

将一维数组 s 输入全连接层, 得到式(4)的特征

向量 z . 通过全连接层中的线性整流函数(Rectified Linear Unit, ReLU)与批量正则化^[16](Batch Normalization, BN), 学习各通道间的非线性特性.

$$z = F_{fc}(s) = \text{ReLU}(\text{BN}(W_s)), \quad (4)$$

式中: W_s 表示数组 s 的特征向量, $W_s \in R^{d \times C}$; d 为压缩通道的系数, 取值为 32.

经过特征融合, 采用 softmax 分类器以得到 a 与 b 的 2 个权重向量, 表示卷积核的权重. 如式(5)和(6)所示, 通过将特征图 U' 、 U'' 与对应权重向量进行加权求和, 得到各通道的输出向量, 并由各通道的输出向量组成最终的特征图 $V \in R^{H \times W \times C}$.

$$V_c = a_c U' + b_c U'', \quad (5)$$

$$V = [V_1, V_2, \dots, V_c], \quad (6)$$

式中: a_c 、 b_c 表示通道 c 的权重, $a_c + b_c = 1$; V_c 表示对应通道的输出向量, $V_c \in R^{H \times W}$.

2.3 全局平均池化

热误差测量时间较长, 增加了热误差训练数据的成本. 然而在特征提取过程中, 全连接层会产生大量参数, 这些参数的优化会增加模型的复杂度, 这不仅会延长模型收敛时间, 也容易产生过拟合. 因此本文在SK模块后引入全局平均池化层^[17]. 通过特征图像素的平均值得到一维特征向量, 由于没有涉及参数的优化, 不仅解决了全连接层中参数优化过多导致模型收敛速度较慢的问题, 也避免了热误差模型产生过拟合, 有效地提高了热误差的预测精度.

3 实验验证

3.1 旋转轴热图像预处理

以下对提出的旋转轴热误差建模方法进行实




图6 SKNet 中的 SK 卷积示意图

验验证, 实验包括升温 and 降温两个过程. 升温时, C 轴以 $3600^{\circ} \cdot \text{min}^{-1}$ 转速运动 4 h. 令 C 轴顺时针与逆时针交替旋转 360° , 每隔 6 min 采集 1 组数据, 采集 1 组数据需要 4 min, 因此升温过程中得到 24 张热图像. 升温数据采集结束后停转静置, 降温 3 h, 重复上述升温的数据采集步骤, 得到 18 张热图像. 每组实验时长 7 h, 共采集 42 张热图像, 得到的热图像数据集如图 7(a)所示.

共进行 10 组实验, 分 10 d 完成. 最终得到的实验数据包括升温图像 240 张、降温图像 180 张, 以及对应的热误差值作为标签. 将得到的 10 组实验数据按 8:1:1 划分为训练集、验证集与测试集, 其中, 8 组实验数据作为训练集, 1 组实验数据作为验证集, 1 组实验数据作为测试集.

为了满足模型训练要求, 需对原始热图像进行预处理. 为消除初始温度对模型预测结果的影响, 让热误差模型在各个初始温度下都能适用, 需剔除热图像的初始温度. 图 7(b)则是预处理后的热图像.

为提高模型的泛化能力, 需对热图像数据集进行扩充. 如图 7(c)所示, 将其中一张预处理后的热图形进行上下和左右翻转, 且顺时针旋转 90° 、

180° 、 270° , 完成数据集扩充. 最终共得到热图像 2520 张, 目的是为增加热图像的数量, 以防止过拟合.

热图像扩充完成后制作数据集, 按 8:1:1 将数据集分为训练集、验证集与测试集. 搭建 Pytorch 深度学习平台, 将数据集输入模型, 进行模型训练和验证. 完成训练、验证和测试后, 将任意 C 轴热图像输入模型即可完成预测, 得到该状态下的 C 轴转角热误差值.

3.2 热误差预测精度分析

完成训练后输入测试集, 利用模型对旋转轴 C 轴的转角热误差拟合曲线参数 (a_0, a_1, b, w) 进行预测, 将参数 (a_0, a_1, b, w) 的预测值与实际值对比. 热误差拟合参数 a_1 与 w 在一定范围内随机跳动, 跳动范围较小, 对转角热误差预测影响较小, 因此只给出 a_0 与 b 的对比结果. 升温状态如图 8(a)~(b)所示, 降温状态如图 8(c)~(d)所示.

通过图中的数据可以计算出模型对拟合函数参数的预测准确率, 计算公式如下:

$$\eta = \frac{n_{y_i = \hat{y}_i}}{n}, \quad (7)$$

式中: η 为拟合函数参数预测准确度; $n_{y_i = \hat{y}_i}$ 为预




图 7 旋转轴热图像预处理




图8 拟合函数参数预测

测准确的样本量; n 为样本总量。

利用预测得到的曲线参数 (a_0, a_1, b, w) 得到误差预测曲线, 并将热误差预测曲线与实际测量值进行比较。如图9所示, 对预测曲线每隔 10° 取点, 得到36个转角热误差预测值, 并和实际测量值作差值运算, 得到36个测量点的残差值。




图9 转角热误差预测结果

为测试模型的泛化能力, 分别在升温与降温

状态时, 计算出模型对实际转角热误差的预测精度。实际转角热误差的预测精度指标为预测均方根误差(Root Mean Squared Error, RMSE), RMSE 越小, 则表示模型预测精度越高。

在计算转角热误差的预测精度时, 需要将转角热误差的36个预测值和实际测量值进行比较, 鉴于计算太过于繁琐, 因此本文选取具有最大残差值的预测值与实际测量值计算RMSE, 具体计算方式如下:

$$Q_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (8)$$

式中: y_i 为具有最大残差的实际测量热误差值; $\hat{y}_i$ 为对应的预测热误差值。

由表1可见, 经过计算, 函数参数 a_0 、 b 的预测准确度在升温状态下为96.0%和92.0%, 降温状态下为88.9%和94.4%; C轴转角热误差预测RMSE在升温状态下为8.36", 降温状态下为9.57"。C轴不同状态下的热误差预测结果不同。与降温状态相

比,升温状态下的 C 轴温度变化范围更大,热图像的像素值可反映更丰富的温度特征,因此热误差的预测精度更高.将同样数据集输入VGG16网络模型中,计算得出 C 轴转角热误差预测RMSE在升温状态下为12.76",降温状态下为13.48".最终结果表明,与普通的卷积神经网络相比,本文搭建的网络模型识别能力更强、预测精度越高,充分证实了基于改进卷积神经网络的旋转轴热误差建模方法的有效性.

表1 转角热误差预测精度评价

C轴状态	函数参数 $a_0/\%$	函数参数 $b/\%$	RMSE/(")	
			改进卷积神经网络模型	VGG16网络模型
升温	96.0	92.0	8.36	12.76
降温	88.9	94.4	9.57	13.48

4 结论

以DMU70V五轴数控加工中心为实验对象,以 C 轴作为热误差主要研究对象,用热成像仪拍摄旋转轴热图像,并通过激光干涉仪测量机床旋转轴的角度定位误差形成数据集.在VGG16网络模型基础上,运用迁移学习方法搭建出改进卷积神经网络模型.通过计算旋转轴热误差精度,总结出以下结论:

(1)在旋转加工过程中, C 轴产生大量热量,对机床加工精度的影响较大.热图像不同的像素值反映了被拍摄物体的热量变化,剔除热图像的初始温度可提高模型鲁棒性,对热图像进行扩充可提高模型的泛化能力.

(2)对 C 轴的角度定位误差进行拟合,将原本36个输出减少到4个输出,减少了改进卷积神经网络的训练参数,提高了建模效率.

(3)文中构建的基于改进卷积神经网络的旋转轴热误差模型在任意 C 轴热图像中输入模型即可完成预测,能得到该状态下的 C 轴转角热误差值,且该模型与普通卷积神经网络相比,具有更强的识别能力和更高的预测精度,适用于旋转轴的热误差建模.

参考文献:

[1] Wu C Y, Xiang S T, Xiang W S. Spindle thermal error

prediction approach based on thermal infrared images: A deep learning method[J]. Journal of Manufacturing Systems, 2021, 59:67-80.

- [2] Yang J, Shi H, Feng B, et al. Thermal error modeling and compensation for a high-speed motorized spindle[J]. The International Journal of Advanced Manufacturing Technology, 2015, 77:1005-1017.
- [3] Wu C, Xiang S, Xiang W. Thermal error modeling of rotary axis based on convolutional neural network[J]. Journal of Manufacturing Science and Engineering, 2021, 143(5):1-13.
- [4] Bitar-Nehme E, Mayer J R R. Thermal volumetric effects under axes cycling using an invar R-test device and reference length[J]. International Journal of Machine Tools and Manufacture, 2016, 105:14-22.
- [5] 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.
- [6] Wegener K, Gebhardt M, Mayr J, et al. Thermal issues in 5-axis machine tools[C]. The Proceedings of MTTRF 2013 Annual Meeting. Eidgenössische Technische Hochschule Zürich, 2014.
- [7] Ibaraki S, Inui H, Hong C F, et al. On-machine identification of rotary axis location errors under thermal influence by spindle rotation[J]. Precision Engineering, 2019, 55:42-47.
- [8] Yang Z Y, Sun M L, Li W Q, et al. Modified Elman network for thermal deformation compensation modeling in machine tools[J]. The International Journal of Advanced Manufacturing Technology, 2011, 54:669-676.
- [9] Chang C W, Kang Y, Chen Y W, et al. Thermal deformation prediction in machine tools by using neural network[M]//Neural Information Processing. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006, 4233:850-859.
- [10] 夏军勇, 胡友民, 吴波, 等. 热弹性效应分析与机床进给系统热动态特性建模[J]. 机械工程学报, 2010, 46(15): 191-198.
- [11] Gebhardt M, Ess M, Weikert S, et al. Phenomenological compensation of thermally caused position and orientation errors of rotary axes[J]. Journal of Manufacturing Processes, 2013, 15(4):452-459.
- [12] Ibaraki S, Oyama C, Otsubo H. Construction of an error map of rotary axes on a five-axis machining center by static R-test[J]. International Journal of Machine Tools and Manufacture, 2011, 51(3):190-200.
- [13] He Z Y, Fu J Z, Zhang L C, et al. A new error measurement method to identify all six error parameters

- of a rotational axis of a machine tool[J]. International Journal of Machine Tools and Manufacture, 2015, 88:1-8.
- [14] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA. IEEE, 2015:1-9.
- [15] Newell A, Yang K, Deng J. Stacked hourglass networks for human pose estimation[C]//Computer Vision – ECCV 2016, 2016:483-499.
- [16] Baranwal S, Khandelwal S, Arora A. Deep learning convolutional neural network for apple leaves disease detection[C]//International Conference on Sustainable Computing in Science, Technology & Management, 2019: 1-8.
- [17] Li X, Wang W H, Hu X L, et al. Selective kernel network[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA. IEEE, 2019:510-519.

Thermal error modeling method for rotary axis of CNC machine tool based on improved convolutional neural network

MA Jianchao, XIANG Sitong*

(Faculty of Mechanical Engineering & Mechanics, Ningbo University, Ningbo 315211, China)

Abstract: To solve the problems of poor prediction accuracy and the difficulty in thermal error data collection under various working conditions, a thermal error modeling method based on improved convolutional neural network is proposed for more accurately predicting the thermal error of five-axis CNC machine tool rotary axis. A laser interferometer and a thermal imager are used to collect the angular positioning errors and the thermal images of the rotary axis at different temperatures. Through Fourier function fitting, the thermal error prediction under different motion angles is transformed into the prediction of the parameters of the fitting function. Based on the VGG network architecture, the SKNet attention mechanism is introduced to improve the feature extraction ability of the model for different motion situations of the rotary axis, and the global average pooling is adopted to avoid over fitting. The established model is used for thermal error prediction, and the results show that the RMSE of the thermal error prediction is 8.36" under the heating condition and 9.57" under the cooling condition, and the prediction accuracy is over 90%, which is better than the traditional convolutional neural network model. The results confirm the effectiveness of the proposed method in the thermal error modeling of the rotary axis.

Key words: five-axis CNC machine tool; rotary axis; thermal error; angular positioning error; improved convolutional neural network

(责任编辑 章践立)