

DOI: 10.19650/j.cnki.cjsi.J2514529

数控机床运动误差的混沌吸引子表征与迁移学习溯因*

杜柳青, 崔楷华, 余永维, 徐 凯
(重庆理工大学机械工程学院 重庆 400054)

摘 要:数控机床运动误差信号呈现强非线性、非平稳特性,且标记数据稀缺。传统研究难以有效分离和准确识别误差源,为此提出一种基于混沌吸引子与迁移学习的数控机床运动误差溯因模型。首先,基于相空间重构将数控机床圆运动误差的一维时序信号映射至混沌相空间,恢复运动误差的混沌吸引子相图,提取表征不同误差源内在动力学机制的混沌吸引子结构特征,利用其与潜在误差源的强关联性为误差源辨识提供基础。然后,针对不同运动误差混沌吸引子相互重叠、尺度特征相差大导致溯因精度不高的问题,提出基于改进 Faster R-CNN 的误差源深度学习溯因模型,引入 ResNet50 和特征金字塔网络,提升对混沌吸引子的识别能力。最后,为了解决数控机床标记样本稀缺的难题,引入迁移学习,基于模型迁移策略,在 COCO2017 源域上充分训练模型,冻结浅层网络结构,将知识有效迁移至运动误差混沌吸引子相图分类数据目标域,显著提升模型在数据匮乏下的溯因能力。设置交并比为 0.5 时,所提模型对 4 类典型运动误差:伺服不匹配、反向越冲、反向间隙和周期误差的平均精度值分别达到 98.80%、99.64%、97.58% 和 99.97%。实验分析表明:数控机床的运动误差能被混沌吸引子有效表征;本模型在各种误差因素条件下均表现出良好的误差源辨识精度,并具有很强的鲁棒性。

关键词: 运动误差;混沌吸引子;迁移学习;深度学习;溯因

中图分类号: TH115 **文献标识码:** A **国家标准学科分类代码:** 510.40

Chaotic attractor characterization and transfer learning traceability for motion error in CNC machine tools

Du Liuqing, Cui Kaihua, Yu Yongwei, Xu Kai

(College of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: Motion error signals of CNC machine tools exhibit strong nonlinear and nonstationary characteristics, with scarce labeled data. Conventional methods struggle to effectively separate and accurately identify error sources. To address this limitation, a motion error traceability model for CNC machine tools is proposed based on chaotic attractors and transfer learning. First, one-dimensional time-series signals of circular motion errors are mapped into a reconstructed phase space to obtain chaotic attractor phase portraits. Structural features of chaotic attractors, which characterize the intrinsic dynamics of different error sources, are extracted to establish strong correlations with potential error mechanisms. These features form the basis for error source identification. Then, to address the issue of low traceability accuracy caused by overlapping chaotic attractors and significant scale variations among motion errors, a deep learning identification model based on an improved Faster R-CNN is constructed. ResNet50 and a feature pyramid network are integrated to enhance the recognition capability of chaotic attractors. Finally, to overcome the scarcity of labeled samples in CNC machine tools, transfer learning is introduced. Pre-training on the COCO2017 source domain and freezing of the shallow layers enabled effective knowledge transfer to the target domain of attractor phase portraits for motion error classification. This strategy significantly improves traceability performance under limited data conditions. At an intersection over union (IoU) threshold of 0.5, the proposed model achieves average precisions of 98.80%, 99.64%, 97.58%, and 99.97% for four typical motion error types: servo mismatch, reverse spikes, backlash, and cyclic error. Experimental analysis shows that motion errors of CNC machine tools can be effectively represented by chaotic attractors. The proposed model achieves

收稿日期:2025-09-24 Received Date: 2025-09-24

* 基金项目:国家自然科学基金(52375083)项目、重庆市教育委员会科学技术研究重大项目(KJZD-M202501102)资助

high error-source identification accuracy under various error conditions and demonstrates strong robustness.

Keywords: motion error; chaotic attractors; transfer learning; neural networks; error tracing

0 引言

数控机床的运动精度是保障产品加工精度的决定性要素,运动误差源的有效追溯是实现精度提升与智能维护的关键^[1]。

数控机床运动误差源信号在强非线性、非平稳工况下相互耦合,难以有效分离和辨识。运动误差的快速准确溯因一直是亟待解决的难点。焦安铃等^[2]利用多体系统理论及齐次坐标变换法对五轴数控机床平动轴和旋转轴进行误差辨识;潘松等^[3]在结构误差建模和分析的基础上提出了一种评估激光跟踪平台指向精度的方法,可以识别出影响平台指向精度的关键误差源;Xu等^[4]利用R-test检测仪将3个不同轨迹的准静态和动态测量数据转换到统一的参考系中,识别出双五轴加工机床的旋转轴联动运动误差。以上基于模型的方法针对单个研究对象取得了较好效果。但是,数控机床机械系统、机电系统,以及结构与控制等复杂耦合关系的存在,使各种故障模式、信号表示与故障原因之间的关系较为复杂,难以建立准确和统一的数学模型。

以深度学习为代表的驱动方法无需精确掌握数控机床内部物理机制与误差传递方程,规避了数控机床(如多轴联动、非线性摩擦、热变形耦合)难以精确建模的固有难题。Cui等^[5]提出了一种由热图像驱动的神经网络预测模型,在西门子840D平台上的预测准确性达到了99.5%;Sun等^[6]利用机床热身过程中主轴温度变化和主轴轴向误差数据建立神经网络预测模型,加工精度比常规加工提高了96.8%;孙兴伟等^[7]以温度敏感点的温升数据和机床进给系统热误差数据为数据样本,利用卷积神经网络(convolutional neural networks, CNN)的特征提取功能和门控循环单元(gate recurrent unit, GRU)的时序处理能力,提出了一种基于CNN-GRU组合神经网络的热误差预测模型,具有较高的预测精度。上述研究主要涉及深度学习用于数控机床精度(热误差)变化趋势的预测,虽然未直接涉及运动误差,但也说明了在数控机床领域深度学习方法本身的有效性。利用深度学习方法进行误差辨识需要大量标记样本,否则会因欠学习导致准确性低。由于有关数控机床误差源的标记样本稀缺,迄今深度学习应用于数控机床运动误差溯因的研究较少。

可见,数控机床运动误差溯因仍存在强非线性、非平稳工况下缺乏有效的特征表征,以及标记样本稀缺两大难点。机床运动误差的演化呈现出复杂的非线性特性,

不同误差因素的非线性动力学特性不同,其蕴含于一维时间序列中,难以直接提取^[8]。基于混沌相空间重构,可以将一维空间扩展到高维空间中恢复其混沌吸引子相图,揭示并提取蕴含其中的混沌吸引子结构特征。混沌吸引子结构特征表征了数控机床的内在动力学特性,并与潜在误差源具有强关联性,为误差源辨识提供了物理基础。

迁移学习具有以底层特征推断整体语义的能力和以可见部件理解全局的能力,成功解决了小样本数据训练的问题。通过共享模型的权重将特征提取能力进行迁移,能显著提高模型的泛化能力和训练效率,在材料缺陷识别^[9]、病灶边界确认^[10]、卫星遥感解析^[11]等工程场景展现了巨大优势。

为此,针对机床多误差源信号在强非线性、非平稳工况下相互耦合,且运动误差标记数据稀缺,导致传统方法难以有效分离和准确识别具体误差源的问题,本研究提出了一种基于混沌吸引子和迁移学习相融合的数控机床运动误差溯因方法。首先通过机床圆运动轨迹构建数控机床运动误差一维时间序列;其次,基于相空间重构对运动误差时间序列进行特征提取,深度挖掘信号的隐藏特征,恢复二维空间下数控机床混沌吸引子几何构型,并利用多延迟时间构建样本数据集;最后,以少样本数控机床运动误差混沌吸引子相图为目标域,引入基于模型迁移策略的迁移学习方法解决误差源样本不足的问题,构建改进的更快速区域卷积神经网络(faster region-based convolutional neural networks, Faster R-CNN)实现对数控机床运动误差的快速溯因。

1 基于混沌吸引子的数控机床运动误差表征

1.1 数控机床运动误差一维时间序列构建

数控机床两轴或者多轴联动运行的圆轨迹误差,可以全面地反映数控机床两轴联动过程中的几何精度、伺服控制精度、位置精度、重复定位精度等精度信息^[12]。

使数控机床主轴末端以 $O(0,0,0)$ 点为圆心,以 r 为半径作圆周运动,由于存在运动误差,机床实际运动半径为 r' 。数控机床圆运动轨迹如图1所示,则数控机床圆运动误差轨迹模型的极坐标形式为:

$$r' = r + f(e, \theta) \quad (1)$$

式中: $f(e, \theta)$ 为半径误差函数; θ 为圆运动角度; e 为误差因素; f 为与误差类型有关的函数关系。

不同的误差因素 e 对应不同形式的圆运动误差轨迹和一维时间序列。如机床存在反向间隙误差因素 β ,此

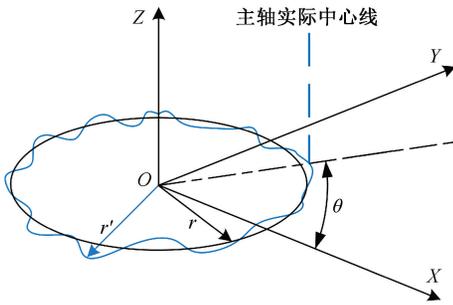


图 1 数控机床圆运动轨迹

Fig. 1 Circular motion trajectory of CNC machine tool

时对应的半径误差函数为:

$$f(\beta, \theta) = \frac{\beta}{2} \cos \theta \quad (2)$$

则反向间隙误差因素对应的误差轨迹基准圆模型为:

$$r' = r + \frac{\beta}{2} \cos \theta \quad (3)$$

同理,可以构建出其他误差因素的误差轨迹理论模型。以数控机床走完一个顺时针和一个逆时针圆周运动为一个周期,对封闭的圆运动误差轨迹按等角度间隔设置 n 个采样点,依次采集各位置上的误差数据,构建一维运动误差时间序列,即:

$$\mathbf{X}_k(i) = (x_k(1), x_k(2), \dots, x_k(n)) \quad (4)$$

式中: k 为运动误差特征数,按伺服不匹配、反向越冲、反向间隙、周期误差等典型特征,取值分别为 1、2、3、4 等。

1.2 单源运动误差混沌吸引子相图表征

根据非线性动力学规律,数控机床运动误差系统的工作状态最终将收敛至其混沌吸引子相图上。不同运动误差之间状态不同,表现为系统非线性动力学特性间的差异^[13],因此每个运动误差系统都有与之对应的混沌吸引子相图。这种混沌吸引子相图能够反映运动误差系统的演化规律,可以作为系统辨识的依据。然而由于观测手段的限制,无法直接测量运动误差系统中各个变量的实时状态,即无法直接获得运动误差的混沌吸引子。

从标量时间序列中重构与混沌吸引子相图等价的相空间,称为相空间重构技术。常用的相空间重构方法是 Takens 延迟嵌入定理^[14]。该定理将不同固定延迟点处的时间序列视为不同维数的新序列,并利用它们重构非线性系统的等效状态空间。

将式(4)进行坐标延迟重构,将序列映射到高维相空间中,重构轨迹矩阵为:

$$\mathbf{Y}_k(t) = [X_k(t) \ X_k(t + \tau_k) \ \dots \ X_k(t + (m_k - 1)\tau_k)] \quad (5)$$

式中: $t = 1, 2, \dots, n - (m_k - 1)\tau_k$; m_k 为第 k 个运动误差

的嵌入维数; τ_k 为第 k 个运动误差的延迟时间; $\mathbf{X}_k(t) = (x_k(1), x_k(2), \dots, x_k(t))$ 。

相空间重构的关键参数是延迟时间和嵌入维数。相空间重构定理指出,非线性系统信号可以在不同维数的相空间中重构。理论上,较高嵌入维数能够更加全面的展开运动误差混沌吸引子结构,从而保留更多的动态特征。然而,高维相图会导致利用深度神经网络进行运动误差溯源时计算复杂度上升,尤其面对样本数量有限的情况时会造成特征稀疏和辨识精度下降。二维混沌吸引子相图在延迟时间选取合理时,能有效反映运动误差的主要特征,提取具有区分度的吸引子形态。同时,二维相空间具备良好的可视化效果,便于开展误差轨迹的图形化分析和识别。因此,本文将嵌入维数 $m = 2$ 固定,进行二维混沌吸引子轨迹重建,以恢复运动误差的吸引子相图。

本文以伺服不匹配、反向越冲、反向间隙和周期误差这 4 种典型的运动误差因素为例进行混沌吸引子相图表征。改变延迟时间的大小,可以产生多个不同的混沌吸引子重构相图。数控机床伺服不匹配的混沌吸引子相图如图 2 所示,在延迟时间较小时,其相图表现为类直线结构,随着延迟时间的增大,相空间轨迹逐渐展开,表现为椭圆状结构(时间序列 $\mathbf{X}_k(t)$ 、时间序列 $\mathbf{X}_k(t + \tau_k)$ 、延迟时间 τ_k 无量纲)。

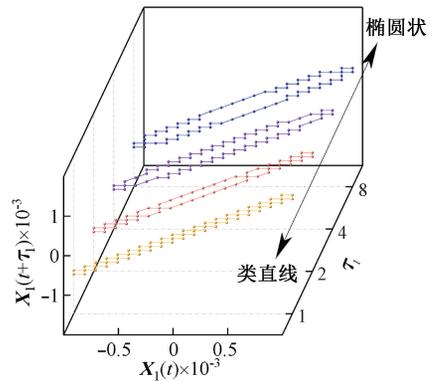


图 2 不同延迟时间下伺服不匹配的混沌吸引子相图

Fig. 2 Chaotic attractor phase diagram of servo mismatch under different delay times

反向越冲的混沌吸引子相图在延迟时间逐渐增大时相图由多边形结构向三角形再向“L”形形状转变,如图 3 所示。反向间隙对延迟时间敏感性较小,其相图形状整体呈现为三角形,如图 4 所示。

周期误差的混沌吸引子相图在延迟时间逐渐增大时,表现为斜楔状的相图结构,按主对角线方向进行鼓壳状展开趋势,如图 5 所示。

对比图 2~5,尽管在不同的延迟时间下,数控机床运动误差混沌吸引子相图会出现形状的微小差异,但是总

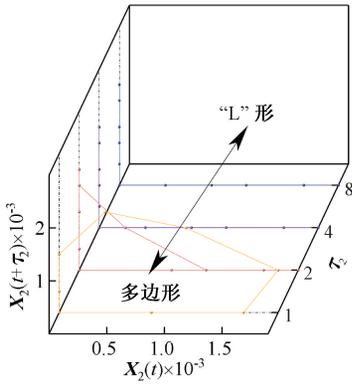


图3 不同延迟时间下反向越冲的混沌吸引子相图

Fig.3 Chaotic attractor phase diagram of reverse spikes under different delay times

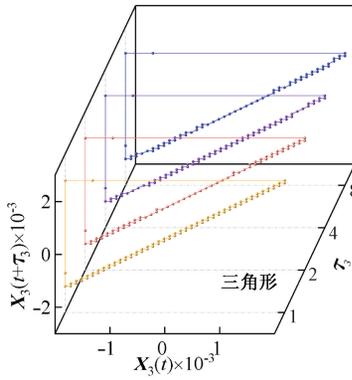


图4 不同延迟时间下反向间隙的混沌吸引子相图

Fig.4 Chaotic attractor phase diagram of backlash under different delay times

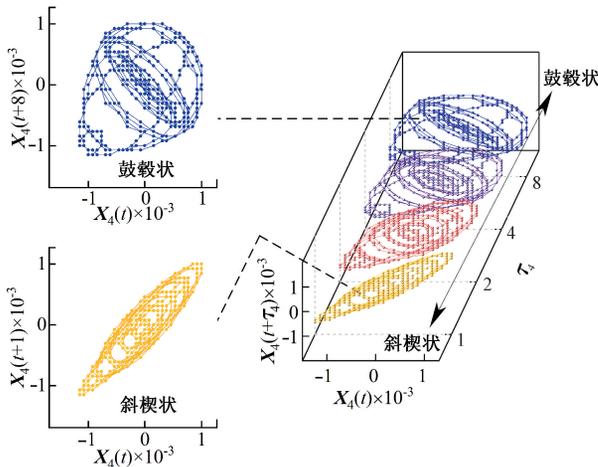


图5 不同延迟时间下周期误差的混沌吸引子相图

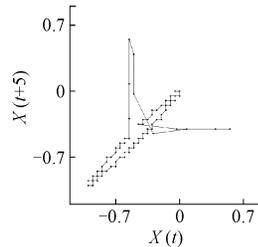
Fig.5 Chaotic attractor phase diagram of cyclic error under different delay times

1.3 运动误差混沌吸引子相图复合表征

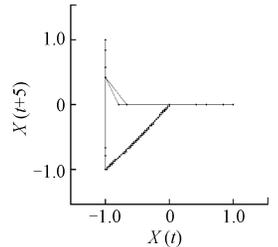
实际生产工况下,机床的运动误差往往受到机械、电气、装配等多因素耦合作用。为了增强模型的实用性,需要进行多源运动误差的复合表征。首先,将不同单一运动误差时间序列归一化后进行叠加,得到多源运动误差一维时间序列。然后,进行相空间重构得到多源运动误差混沌吸引子相图。

伺服不匹配在和反向越冲、反向间隙复合时能各自表征出其单源混沌吸引子相图,而在和周期误差进行复合时产生新结构,表现为相互缠绕的纺锤状;反向间隙在和反向越冲复合时中部直角缺口被打开,表现为类似箭头的形状;反向越冲在和周期误差复合时出现部分图像被周期误差遮挡情况。图6(a)~(f)所示为两种误差复合混沌吸引子相图,以 $\tau=5$ 为例。

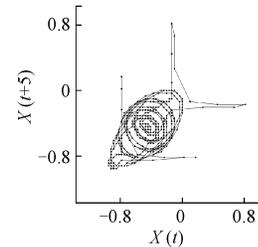
如图6(g)~(k)所示为多源运动误差复合混沌吸引子相图,虽然无单源运动误差未被表征情况出现,但是表现为不同运动误差因素的重叠、遮挡,导致运动误差识别难度加大。



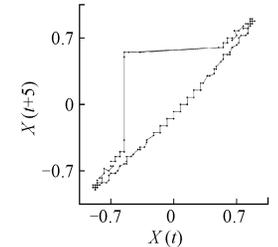
(a) 伺服不匹配+反向越冲
(a) Servo mismatch + reverse spikes



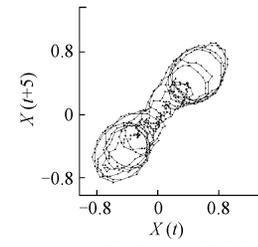
(b) 反向越冲+反向间隙
(b) Reverse spikes + backlash



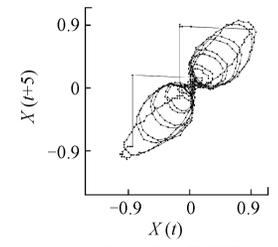
(c) 反向越冲+周期误差
(c) Reverse spikes + cyclic error



(d) 伺服不匹配+反向间隙
(d) Servo mismatch + backlash



(e) 伺服不匹配+周期误差
(e) Servo mismatch + cyclic error



(f) 反向间隙+周期误差
(f) Backlash + cyclic error

体而言,不同运动误差混沌吸引子相图表现出显著的差异性。

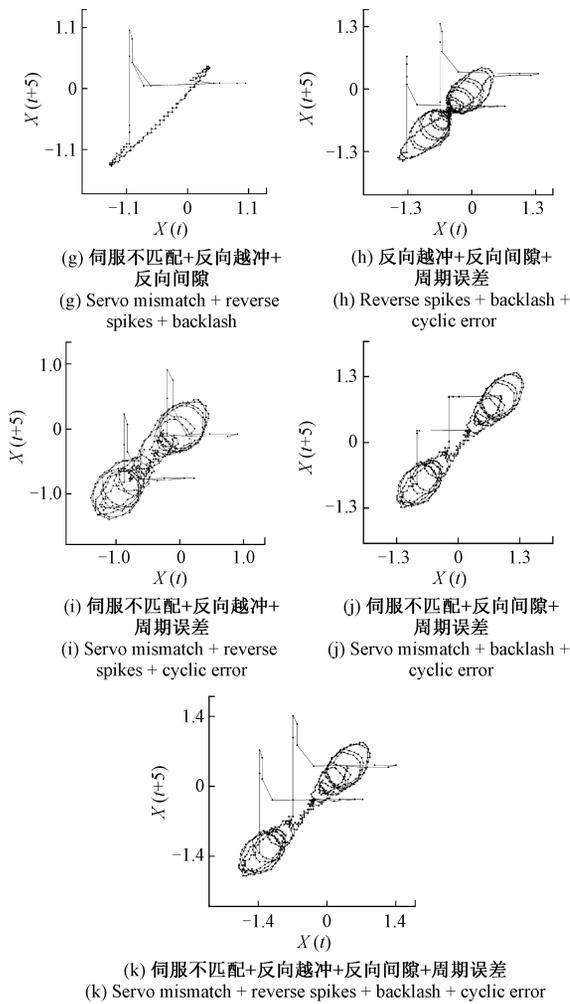


图 6 多源运动误差混沌吸引子相图

Fig. 6 Chaotic attractor phase diagrams of multi-source motion errors

在实际应用中,数控机床运动误差常常伴随着噪声干扰。以伺服不匹配和反向越冲复合混沌吸引子相图为例,在信噪比 (signal-to-noise ratio, SNR) 为 20 dB 时,混沌吸引子相图被噪声遮挡,如图 7 (a) 所示;随着噪声比例的下降,相图逐渐清晰,如图 7 (b) ~ (f) 所示。

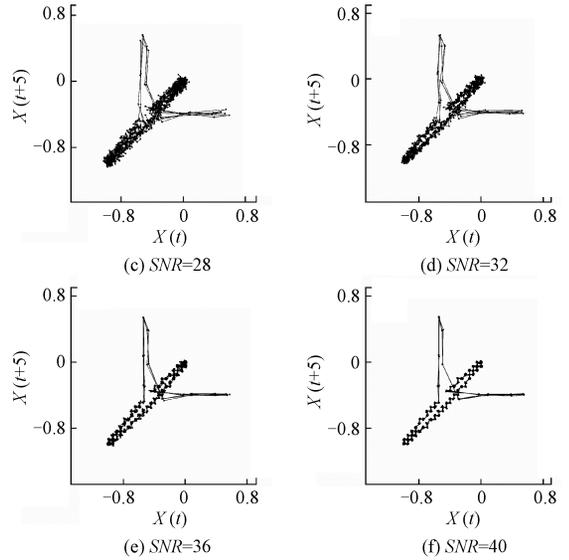
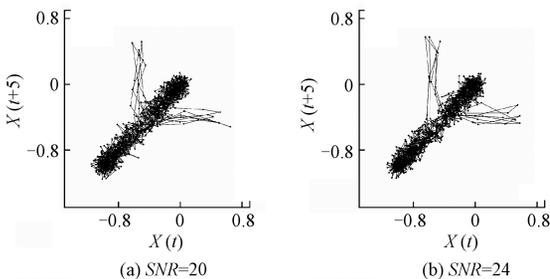


图 7 伺服不匹配和反向越冲的复合误差因素不同信噪比环境下混沌吸引子相图

Fig. 7 Chaotic attractor phase diagrams of composite error factors of servo mismatch and reverse spikes under different SNR conditions

2 基于迁移学习的数控机床运动误差溯源

对数控机床运动误差进行溯源时,由于真实样本误差源稀缺,直接利用混沌吸引子相图训练深度神经网络容易出现过拟合、模型泛化性差等问题。本文将迁移学习思想引入机床运动误差溯源模型,通过数据训练将混沌吸引子相图特征进行迁移,以缓解训练数据不足的问题。该模型由时间序列构建模块、混沌吸引子表征模块、迁移学习模块和误差溯源模块组成,如图 8 所示。

首先通过数控机床的圆运动轨迹构建单源一维运动误差时间序列,将不同单源误差时间序列归一化后相加得到多源一维运动误差时间序列。然后,利用相空间重构将一维时间序列转化为混沌吸引子相图以提取表征数控机床不同非线性误差系统的动力学特征,从而建立数控机床运动误差与混沌吸引子映射关系模型。基于多延迟时间生成数控机床运动误差数据集,并添加不同程度噪声以增强数据集的实用性。引入残差神经网络 50 层 (residual network 50, ResNet50) 和特征金字塔结构 (feature pyramid network, FPN) 作为主干网构建改进 Faster R-CNN 模型,提高对运动误差混沌吸引子的识别能力;以运动误差混沌吸引子相图数据集为目标域、以微软的通用数据集 2017 版 (common objects in context 2017, COCO2017) 为源域,进行迁移学习得到数控机床运动误差溯源模型,解决数控机床运动误差数据标记样本稀缺

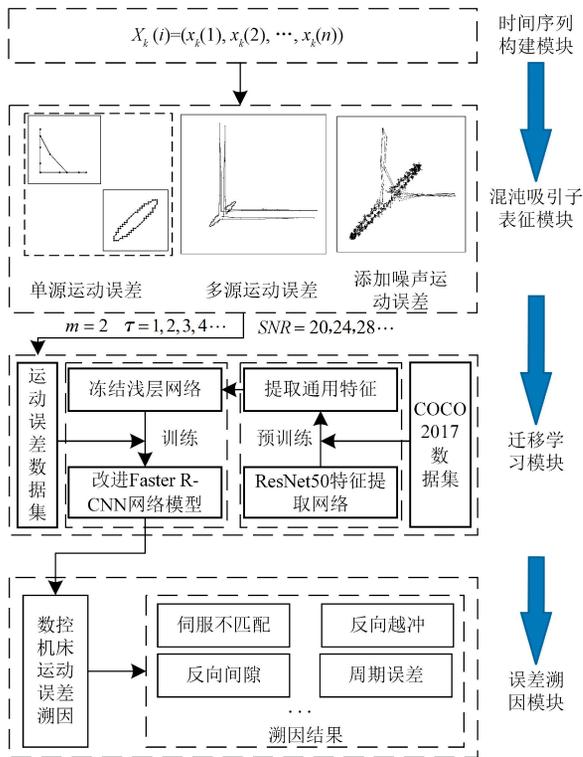


图8 数控机床运动误差溯因模型

Fig. 8 CNC machine tool motion error traceability model

问题。最后,将训练好的模型用于机床运动误差诊断,实现运动误差类型的精确识别。

2.1 运动误差溯因网络构建

数控机床各部件间的复杂耦合作用使运动误差往往呈现为多因素运动误差的复合,加大了溯因难度。运动误差的混沌吸引子相图具有鲜明的表征特性,为机床运动误差溯因提供了新思路。然而,不同运动误差源在相空间中呈现出相互重叠的动力学特征,尤其当吸引子相图被噪声干扰时,重构后的混沌吸引子结构边界异常模糊,从而影响运动误差溯因的准确性。同时,不同误差源混沌吸引子相图尺度特征相差较大,容易出现漏检等情况。

Faster R-CNN^[15] 的区域候选网络 (region proposal network, RPN) 具备良好的局部特征提取与目标定位能力,能够精准捕捉混沌吸引子相图中代表不同误差源的关键模式区域,且 Faster R-CNN 支持在同一图像中并行检测多个目标区域,为运动误差复合诊断提供了有效的模型基础。因此,本文选择 Faster R-CNN 网络作为基本框架。

为实现 Faster R-CNN 模型对混沌吸引子边界的准确识别,本文在特征提取阶段加深卷积层深度以增强特征表达能力。考虑到深层卷积网络容易出现梯度消失导致模型难以收敛等问题,引入 ResNet50 替换原有的视觉几

何组 16 层网络 (visual geometry group 16 layer network, VGG16) 作为特征提取网络。ResNet50 模型结构包括 1 个初始卷积层 (Conv1, C1), 以及 4 个阶段 (Conv2 ~ Conv5, C2 ~ C5) 的主干网络,每个主干网络由多个残差模块组成^[16]。残差块通过快捷连接在网络层之间引入直接路径,使得混沌吸引子相图信息可以跨层传递,从而有效缓解梯度消失并提升深层特征学习能力。

在此基础上,为了增强模型对不同尺度运动误差特征的感知能力,在主干网络中引入 FPN,使其适用于混沌吸引子相图中不同运动误差的检测。FPN 通过自上而下与横向连接的方式构建多尺度特征层级,可以将高层级的语义信息和低层级的空间信息融合,以适应吸引子相图中多样化结构特征,从而提高运动误差的检测精度。图 9 为改进后 Faster R-CNN 网络框架图。

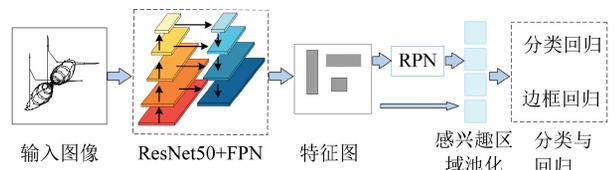


图9 改进 Faster R-CNN 网络框架

Fig. 9 Improved Faster R-CNN network framework

2.2 基于迁移学习的运动误差溯因模型

数控机床运动误差混沌吸引子相图以轨迹曲线为主要特征,边缘和几何形状是实现运动误差溯因的关键。

COCO2017^[17] 是一个计算机视觉领域开源数据集,主要用于物体检测、关键点检测和全景分割等任务 (<https://cocodataset.org>)。COCO2017 数据集与本文混沌吸引子相图识别实质均为视觉领域对图像/图形的检测任务,二者在特征层面上存在一些不变的共性特征,如边缘、纹理等抽象特征具有相似性。

Resnet50 网络在 COCO2017 源域数据集训练后,已具备丰富的低层视觉特征提取能力,包括边缘检测、形状轮廓与局部结构等,这些特征同样适用于混沌吸引子轨迹形态的几何特征捕捉。模型迁移能将这种共性特征迁移到混沌吸引子相图识别上,从而实现从通用视觉特征到特定误差形态特征的跨域映射。因此,本文采用模型迁移策略构建数控机床运动误差溯因模型,COCO2017 源域数据集内容丰富,经模型迁移后可提高目标模型的泛化性。

本文运动误差溯因网络的目标域 A_v 为数控机床运动误差混沌吸引子相图,源域 A_s 为 COCO2017 数据集。运动误差溯因网络的迁移学习定义为:

$$\begin{cases} A_s = \{q_s, D_{(q_s)}\} \\ A_v = \{q_v, D_{(q_v)}\} \end{cases} \quad (6)$$

式中: q_s 代表 COCO2017 数据集的特征空间; q_v 代表数控机床运动误差混沌吸引子相图数据集的特征空间; $D_{(q_s)}$ 、 $D_{(q_v)}$ 表示各特征空间对应的边缘概率分布。

运动误差溯源网络的迁移学习流程如图 10 所示。

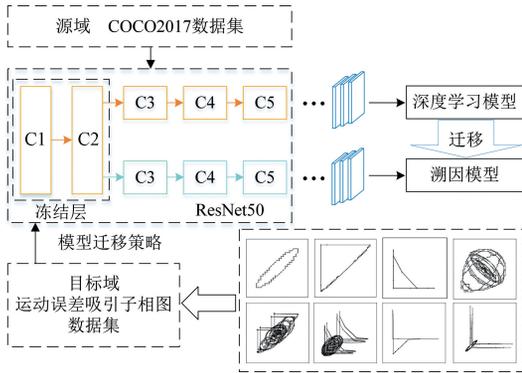


图 10 迁移学习流程图

Fig. 10 Transfer learning flowchart

1) 将 COCO2017 数据集作为源域, 训练 ResNet50 网络模型, 让模型充分学习通用特征, 增强模型对于边缘和几何形状特征的识别能力;

2) 冻结 C1 和 C2 层网络, 将训练好的模型迁移到改进 Faster R-CNN 网络中;

3) 利用数控机床运动误差混沌吸引子相图数据集作为目标域进行训练, 得到数控机床运动误差溯源模型。

3 实验及结果分析

为了证明本文方法的有效性, 选取实际情况中最典型的 4 种单源运动误差作验证实验。

3.1 数据集构建

根据数控机床运动误差因素实际误差值的可能范围, 在两轴联动圆半径为 100 mm 的条件下, 改变误差轨迹理论模型中运动误差因素 e 类型, 即可生成数控机床单源运动误差一维时间序列。将不同单源运动误差时间序列归一化后融合, 得到多源运动误差一维时间序列。然后, 利用混沌相空间重构技术获得各时间序列即各种误差源情况下的混沌吸引子相图。

改变不同延迟时间, 即可得到不同数量的混沌吸引子相图理论样本。当延迟时间在合理范围内时, 混沌吸引子相图变化较小, 能够对数控机床运动误差进行表征, 如图 11(a)~(c) 所示; 当延迟时间过大时, 相空间结构被完全打开, 不再适合对运动误差进行表征, 如图 11(d) 所示。

设置单源运动误差延迟时间为 1~40, 设置多源运动误差延迟时间为 1~20, 共设计样本 380 张, 记为数据集 K1, 具体分类如表 1 所示。

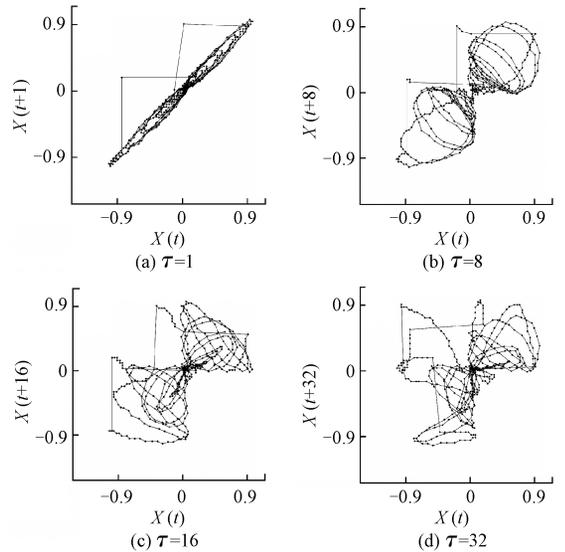


图 11 反向间隙和周期误差的复合运动误差不同延迟时间混沌吸引子相图

Fig. 11 Chaotic attractor phase diagrams of composite motion errors of backlash and cyclic error under different delay times

表 1 数控机床运动误差数据集 K1

Table 1 CNC machine tool motion error dataset K1

误差因素	标签名称	样本数量/张
伺服不匹配	SM	40
反向越冲	RS	40
反向间隙	BL	40
周期误差	CE	40
伺服不匹配+反向越冲	SM&RS	20
伺服不匹配+反向间隙	SM&BL	20
伺服不匹配+周期误差	SMCE	20
反向越冲+反向间隙	RSBL	20
反向越冲+周期误差	RS&CE	20
反向间隙+周期误差	BL&CE	20
伺服不匹配+反向越冲+反向间隙	SM&RSBL	20
伺服不匹配+反向越冲+周期误差	SMCE&RS	20
伺服不匹配+反向间隙+周期误差	SMCE&BL	20
反向越冲+反向间隙+周期误差	RSBL&CE	20
伺服不匹配+反向越冲+反向间隙+周期误差	SMCE&RSBL	20

表 1 中列出了 4 种单源运动误差及其所有 11 种组合多源运动误差的全部误差源情况。根据误差源情况即可确定标签个数。为从表 1 所列误差源情况中识别出

4种单源误差,标签个数最少为4个,但由于伺服不匹配和周期误差复合时,以及反向间隙在和反向越冲复合时出现不可分的新混沌吸引子结构,因此,将这两种误差源情况也分别作为标签类型,在构造数据集时,将标签类型设置为6。其中,伺服不匹配,标记为SM;反向越冲,标记为RS;反向间隙,标记为BL;周期误差,标记为CE;反向间隙+反向越冲,标记为RSBL;伺服不匹配+周期误差,标记为SMCE。

为了提高模型的实用性,对纯净数据集添加SNR为20、24、28、32、36、40 dB的噪声以扩充数据集,共2 280张。将数据集K1添加不同程度噪声后记为数据集K2,共2 660张,具体分类如表2所示,其中,“/”为纯净数据,即:无噪声。

表2 数控机床运动误差数据集K2

Table 2 CNC machine tool motion error dataset K2

SNR/dB	样本数量/张
/	380
20	380
24	380
28	380
32	380
36	380
40	380

3.2 模型训练

实验环境为Microsoft Windows10专业版(64位)操作系统;英特尔Intel(R)Core(TM)i7-12700F CPU,主频2.10 GHz;NVIDIA GeForce RTX 3060GPU,32 G显存;Pytorch版本为1.7.1,torchvision版本为0.8.2。

将数控机床运动误差图像按照7:3的比例划分训练集和测试集进行迁移学习训练。训练周期设置为100,学习率为0.001;批处理大小为4;采用带有动量机制的随机梯度下降优化器(stochastic gradient descent,SGD)进行训练,动量参数设置为0.9。训练过程中的损失函数是一个多任务损失函数,该函数同时进行分类与坐标回归的训练任务^[18]。

3.3 本文方法识别效果

采用精确率(precision,P)、召回率(recall,R)、平均精度值(average precision,AP)和平均精度均值(mean average precision,MAP)评价模型检测的性能^[19-20]。交并比(intersection of union,IoU)分别设置为0.5和0.75,则精确率、召回率、平均精度值和平均精度均值记为

P50/P75、R50/R75、AP50/AP75和MAP50/MAP75。P、R、AP、MAP计算过程如式(7)~(10)所示。

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

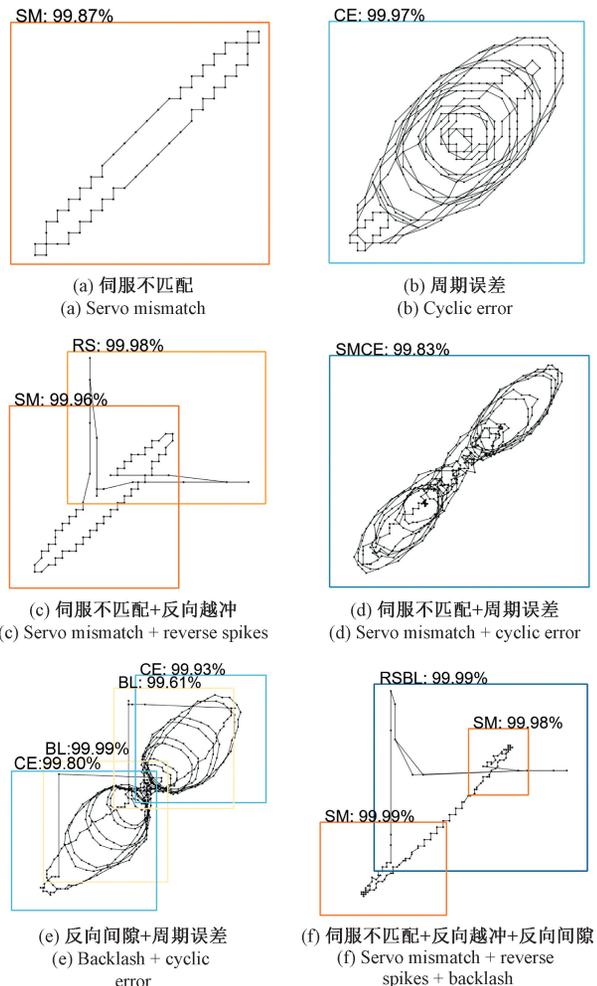
$$AP = \int_0^1 P(R) \cdot dR \quad (9)$$

$$MAP = \frac{1}{z} \sum_{i=1}^z AP_i \quad (10)$$

式中:TP表示模型正确分类数控机床误差的数量;FP表示模型将负样本识别为正样本数量;FN表示模型将正样本识别为负样本的数量;z表示类别数。

本文方法对数控机床多因素复合运动误差、噪声环境下的检测都能正确分类,识别结果(IoU为0.5)如图12~13所示。

设置IoU为0.5时,本文方法对伺服不匹配、反向越冲、反向间隙、周期误差的识别准确率分别达到93.35%、89.91%、90.60%、86.83%,召回率达到98.99%、100.0%、99.31%、100.0%,平均精度值AP50分别达到



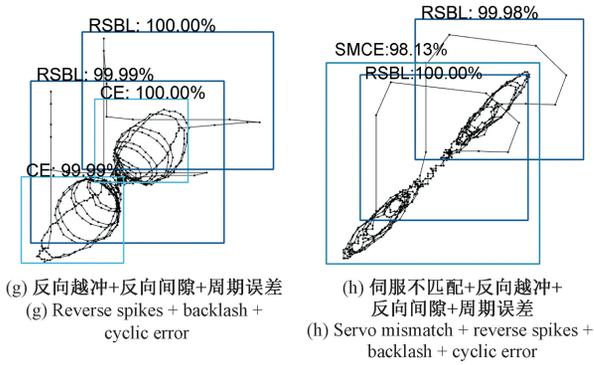


图 12 运动误差识别结果

Fig. 12 Recognition results of motion errors

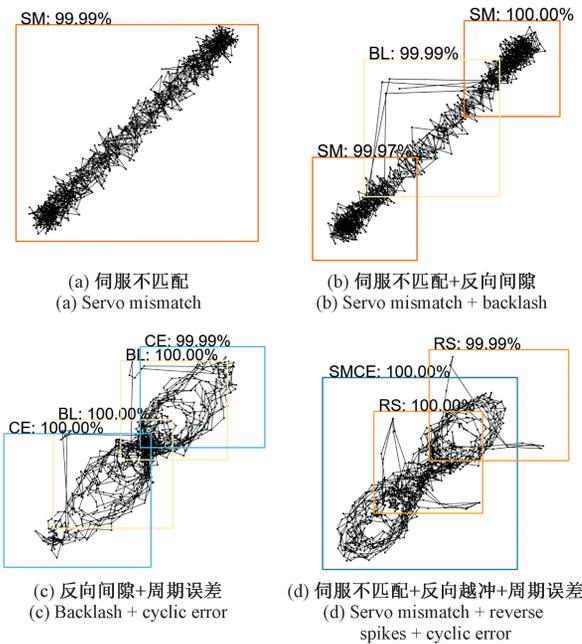


图 13 噪声环境下运动误差识别结果

Fig. 13 Recognition results of motion errors under noisy conditions

98.80%、99.64%、97.58%、99.97%，平均精度均值 MAP50 达到 99.00%。即使设置 IoU 为 0.75 时，MAP75 也达到 83.23%。本文方法识别效果如表 3 所示。

以存在误差源的数控铣床 XK-L540 和数控车床 CKY400B 为例，用训练好的溯源模型对其进行检测，溯源结果如图 14 所示。在现实环境中由于噪声的干扰，机床混沌吸引子相图表现能力较差。本文溯源模型中添加了相关噪声训练样本，能够正确识别出数控机床存在的误差源 (IoU 为 0.5)，表明本文方法具有较高的实用性。

3.4 对比实验

为了验证迁移学习的可行性，基于数据集 K2 将其与

表 3 本文方法识别效果

Table 3 Recognition performance of the proposed method (%)

指标	SM	RS	BL	CE
P75	66.46	89.32	86.83	83.23
R75	70.47	99.34	95.19	95.86
AP75	47.63	98.09	91.60	95.58
MAP75	83.23			
P50	93.35	89.91	90.60	86.83
R50	98.99	100.00	99.31	100.00
AP50	98.80	99.64	97.58	99.97
MAP50	99.00			

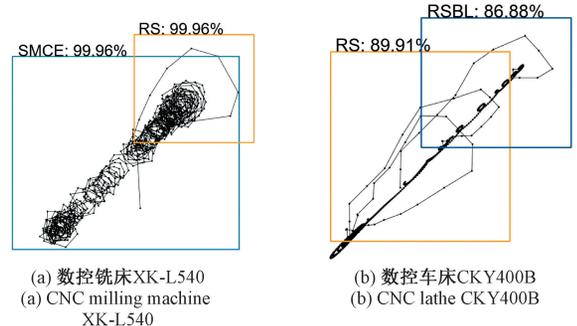


图 14 实际数控机床溯源

Fig. 14 Traceability of actual CNC machine tools

传统方式训练(直接在 Faster R-CNN 网络上训练)、迁移学习样本数减少为 50% 进行对比实验。

不同训练方式对比结果如表 4 所示。通过迁移学习训练出来的模型取得了最高的 MAP50 和 MAP75，对比传统方式训练出来的模型分别提高了 0.77 个百分点和 4.02 个百分点，即使只迁移了 50% 训练样本，其 MAP50 和 MAP75 也高于传统方式训练出来的模型。当 IoU 为 0.5 时，3 种模型的 AP50 精度都较高，不同误差源的 AP50 都达到了 95% 以上；当 IoU 为 0.75 时，伺服不匹配由于在不同延迟时间参数下及复合误差中混沌吸引子相图结构变化较大，检测精度急剧下降，基于传统方式训练出来的模型 AP75 只有 43.52%。通过迁移学习的训练，各种运动误差因素的 AP75 都得到不同程度的提高；CE 的 AP75 为 95.58%，比基于传统方式训练的模型提高了 8.49 个百分点。

不同训练方式训练损失函数变化曲线如图 15 所示。随着迭代次数的增加，通过采用迁移学习的方式，本文所提方法能够根据目标任务的数据来微调模型参数，让模型适应目标任务的特征分布，在训练收敛时损失函数值下降至 0.03 左右，当迁移学习样本减少为 50% 时，训练

表4 不同训练方式对比结果

Table 4 Comparison results of different training methods

		AP75 (%)			
训练方式	运动误差因素	AP50	AP75	MAP50	MAP75
传统训练	SM	95.36	43.52		
	RS	99.73	95.62	98.23	79.21
	BL	98.07	90.60		
	CE	99.76	87.09		
迁移50% 样本	SM	97.42	50.44		
	RS	99.64	96.99	98.84	83.00
	BL	98.97	91.03		
	CE	99.32	93.54		
迁移学习	SM	98.80	47.63		
	RS	99.64	98.09	99.00	83.23
	BL	97.58	91.60		
	CE	99.97	95.58		

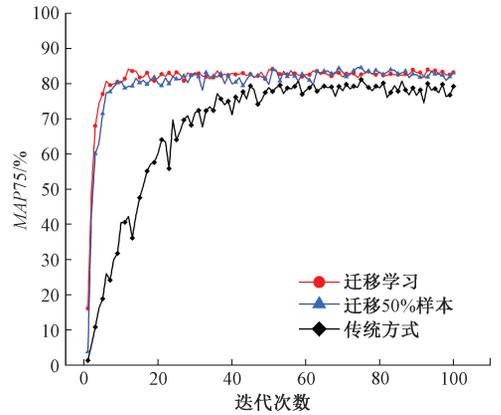


图16 不同训练方式模型 MAP75

Fig. 16 MAP75 of models under different training methods

两种数据集检测精度。使用 K1 数据集的模型算法检测精度虽然和 K2 数据集检测精度相差较小,但其波动程度较大且收敛速度较慢,说明在扩充数据集后,本文算法的鲁棒性得到提升。

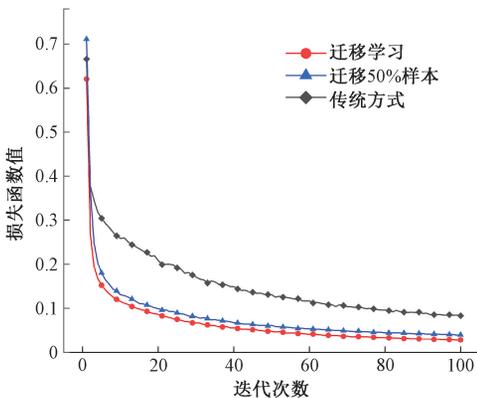


图15 不同训练方式训练损失函数变化曲线

Fig. 15 Training loss curves under different training methods

损失函数值下降至 0.04 左右,而采用传统方式训练损失函数值最终下降至 0.08 左右。

不同训练方式下模型 MAP75 如图 16 所示。在增加了迁移学习模块后,MAP75 在迭代到第 10 轮之后稳定在较高水平;当迁移学习样本为 50%时,模型在迭代到 15 轮之后趋于稳定;传统方式训练方法在迭代到 40 轮之后趋于稳定。由图 15 和 16 可知,迁移学习方法能够在提高模型精度的同时显著加速模型收敛速度。

为了验证本文添加噪声样本数据集的有效性,基于纯净信号数据集 K1、扩充数据集 K2 和高噪声环境 (dB=20,记为 K3)数据集采用本文方法进行对比实验。不同数据集下模型 MAP75 如图 17 所示,由于噪声的影响,在高噪声环境数据集中的检测精度低于采用其它

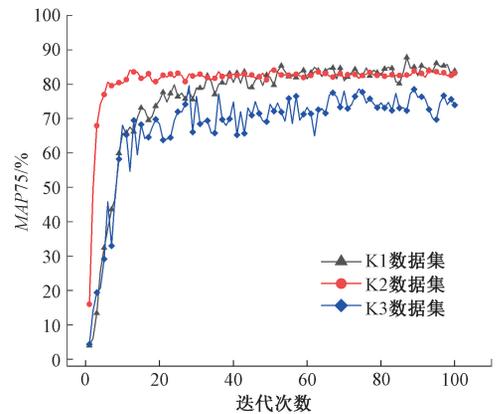


图17 不同数据集下模型 MAP75

Fig. 17 MAP75 of models under different datasets

为了进一步验证本文算法的性能,基于 K2 数据集与掩码区域神经网络 (mask region-based convolutional neural network, Mask R-CNN) 和单次多框检测器 (single shot multibox detector, SSD) 目标检测算法进行对比实验。如表 5 所示,Mask R-CNN 算法 MAP75 最低,SSD 算法由于将前置网络改进为 ResNet50 结构,其 MAP75 高于 Mask R-CNN 算法,Faster R-CNN 算法 MAP75 最高,达到了 83.23%。在 AP 方面,3 种模型在 SM 的检测精度上表现最差,其中 SSD 的 AP75 为 54.81%,Mask R-CNN 的 AP75 为 52.76%,Faster R-CNN 的 AP75 为 47.63%;3 种模型在 RS 的检测精度上表现最好,Faster R-CNN 的 AP75 为 98.09%,Mask R-CNN 的 AP75 为 80.17%,SSD 的 AP75 为 76.88%。

表5 不同模型迁移学习对比结果

Table 5 Transfer learning comparison of different models

(%)

算法	运动误差因素	AP50	AP75	MAP50	MAP75
SSD	SM	95.16	54.81		
	RS	99.83	76.88	98.27	73.47
	BL	98.53	78.35		
	CE	99.60	78.12		
Mask R-CNN	SM	85.42	52.76		
	RS	94.70	80.17	90.50	69.93
	BL	88.03	68.55		
	CE	85.49	65.17		
Faster R-CNN	SM	98.80	47.63		
	RS	99.64	98.09	99.00	83.23
	BL	97.58	91.60		
	CE	99.97	95.58		

4 结 论

基于运动误差因素与圆运动轨迹的映射关系,利用混沌理论对非线性时间序列强大的特征提取能力,提出了一种基于混沌吸引子与迁移学习的数控机床运动误差溯源方法。相较于传统方法,本文方法对各种运动误差因素以及各种复合运动误差因素条件下均表现出更高的误差源辨识精度和更强的鲁棒性,其优势为:

1) 利用混沌吸引子刻画了运动误差的非线性动力学本质,其与潜在误差源具有强关联性,为误差源辨识提供了理论基础。

2) 通过采用多延迟时间和添加噪声的方法,解决了数控机床运动误差样本难以获取且数据样本质量不高的问题。

3) 通过迁移学习方法有效破解了运动误差小样本学习瓶颈,使用模型迁移策略大幅降低了模型对标记数据的需求,验证了模型在小样本运动误差因素诊断中的优越泛化性。

在对数控机床运动误差准确溯源的基础上,下一步工作将研究混沌吸引子相图与运动误差变化关系模型,在溯源实现基础上进行运动误差量化分析。

参考文献

[1] 冉琰,田轲,窦一凡,等. 数控机床元动作链运动误差传递及综合精度建模[J]. 机械工程学报, 2023, 59(23): 211-220.

RAN Y, TIAN K, DOU Y F, et al. Kinematic error transfer and integrated precision modeling of the meta-action chain for CNC machine tools [J]. Journal of Mechanical Engineering, 2023, 59(23): 211-220.

[2] 焦安铃,陈光胜. 基于球杆仪的五轴数控机床误差快速检测方法[J]. 仪器仪表学报, 2024, 45(1): 138-148.

JIAO AN L, CHEN G SH. Fast error identification method for five-axis machine tools based on double ball-bar[J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 138-148.

[3] 潘松,梁永锦,陈雷,等. 超声电机驱动的激光跟踪平台误差建模与分析[J]. 仪器仪表学报, 2025, 46(1): 93-104.

PAN S, LIANG Y J, CHEN L, et al. Error modeling and analysis of a laser tracking platform driven by ultrasonic motor [J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 93-104.

[4] XU K, ZHUANG Z X, JI Y L, et al. An efficient method for measuring and identifying geometric and dynamic errors in dual five-axis machine tools [J]. Precision Engineering, 2024, 86: 359-375.

[5] CUI CH, ZAN T, MA SH K, et al. Thermal image-driven thermal error modeling and compensation in CNC machine tools based on deep attentional residual network [J]. The International Journal of Advanced Manufacturing Technology, 2024, 134(7): 3153-3169.

[6] SUN J CH, LIU ZH Y, QIU CH, et al. Machining accuracy prediction and adaptive compensation method of CNC machine tool under absence of machining process sensing [J]. Journal of Intelligent Manufacturing, 2025, 36(6): 3923-3940.

[7] 孙兴伟,杨铜铜,杨赫然,等. 基于CNN-GRU组合神经网络的数控机床进给系统热误差研究[J]. 仪器仪表学报, 2023, 44(10): 219-226.

SUN X W, YANG T T, YANG H R, et al. Research on thermal error of CNC machine tool feed system based on CNN-GRU combined neural network [J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 219-226.

[8] DU L Q, LI F Q, YU Y W. Analysis of the configuration characteristics of the chaotic attractor for machine tool dynamic error under the singular spectrum [J]. Journal of Manufacturing Processes, 2023, 101: 1362-1373.

[9] 程军,朱煜龙,汪步云,等. 基于改进迁移学习的CFRP缺陷涡流检测与识别[J]. 机械工程学报, 2025, 61(6): 53-65.

CHENG J, ZHU Y L, WANG B Y, et al. Improved transfer learning method for eddy current testing and identification of CFRP defects [J]. Journal of Mechanical Engineering, 2025, 61(6): 53-65.

- [10] SALEH A W, GUPTA G, KHAN S B, et al. An Alzheimer's disease classification model using transfer learning Densenet with embedded healthcare decision support system [J]. *Decision Analytics Journal*, 2023, 9: 100348.
- [11] LIU CH, YUAN X H, NI G Q, et al. Utilizing deep transfer learning to discover changes in landscape patterns in urban wetland parks based on multispectral remote sensing [J]. *Ecological Informatics*, 2024, 83: 102808.
- [12] 杜柳青, 王煜晓, 余永维. 数控机床运动精度混沌自演化预测方法 [J]. *仪器仪表学报*, 2025, 46(4): 283-294.
- DU L Q, WANG Y X, YU Y W. Chaos self-evolution prediction method for motion accuracy of CNC machine tools [J]. *Chinese Journal of Scientific Instrument*, 2025, 46(4): 283-294.
- [13] 赵雨睿, 黄知涛, 王翔. 基于相空间重构的辐射源个体识别技术综述 [J]. *雷达学报*, 2023, 12(4): 713-737.
- ZHAO Y R, HUANG ZH T, WANG X. A review of specific emitter identification based on phase space reconstruction [J]. *Journal of Radars*, 2023, 12(4): 713-737.
- [14] TANG Z H, JI T Y, KANG J X, et al. Learning global and local features of power load series through transformer and 2D-CNN: An image-based multi-step forecasting approach incorporating phase space reconstruction [J]. *Applied Energy*, 2025, 378: 124786.
- [15] HOU J L, CHE Y H, FANG Y R, et al. Early bruise detection in apple based on an improved Faster RCNN model [J]. *Horticulturae*, 2024, 10(1): 100.
- [16] 翁海勇, 李效彬, 肖康松, 等. 基于 Mask R-CNN 的柑橘主叶脉显微图像实例分割模型 [J]. *农业机械学报*, 2023, 54(7): 252-258, 271.
- WENG H Y, LI X B, XIAO K S, et al. Instance segmentation model for microscopic image of citrus main leaf vein based on Mask R-CNN [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(7): 252-258, 271.
- [17] WANG CH L, XIAO ZH F. Potato surface defect detection based on deep transfer learning [J]. *Agriculture*, 2021, 11(9): 863.
- [18] LI R X, YU J Y, LI F, et al. Automatic bridge crack detection using unmanned aerial vehicle and Faster R-CNN [J]. *Construction and Building Materials*, 2023, 362: 129659.
- [19] CRESPO A, MONCADA C, CRESPO F, et al. An efficient strawberry segmentation model based on Mask R-CNN and TensorRT [J]. *Artificial Intelligence in Agriculture*, 2025, 15(2): 327-337.

- [20] TANG H P, HE L F, FENG Q CH, et al. Fine-grained mineral recognition and segmentation in metal mineral optical images based on improved YOLOv8n model [J]. *Minerals Engineering*, 2025, 227: 109290.

作者简介



杜柳青, 1996 年于四川工业学院获学士学位, 2003 年于重庆大学获硕士学位, 2016 年于四川大学获博士学位, 现为重庆理工大学教授, 硕士生导师, 主要研究方向为微弱信号检测、机床精度设计。

E-mail: lqdu@cqut.edu.cn

Du Liuqing received her B. Sc. degree from Sichuan Institute of Technology in 1996, received her M. Sc. degree from Chongqing University in 2003, received her Ph. D. degree from Sichuan University in 2016. She is currently a professor and master supervisor at Chongqing University of Technology. Her main research interests include weak signal detection and machine tool's precision design.



崔楷华, 2016 年于燕山大学获学士学位, 现为重庆理工大学硕士研究生, 主要研究方向为先进制造技术、机床精度设计。

E-mail: 1146917449@qq.com

Cui Kaihua received his B. Sc. degree from Yanshan University in 2016. He is currently a master's candidate at Chongqing University of Technology. His main research interests include advanced manufacturing technology and machine tool's precision design.



余永维 (通信作者), 1997 年于武汉理工大学获学士学位, 2005 年于重庆大学获硕士学位, 2014 年于四川大学获博士学位, 现为重庆理工大学教授, 硕士生导师, 主要研究方向为机器视觉、智能控制。

E-mail: weiyi@cqut.edu.cn

Yu Yongwei (Corresponding author) received his B. Sc. degree from Wuhan University of Technology in 1997, received his M. Sc. degree from Chongqing University in 2005, and his Ph. D. degree from Sichuan University in 2014. He is currently a professor and master's supervisor at Chongqing University of Technology. His main research interests include machine vision and intelligent control.



徐凯, 2016 年于重庆大学获学士学位, 2022 年于重庆大学获博士学位, 现为重庆理工大学讲师, 主要研究方向为机床误差测量、辨识。

E-mail: xukai@cqut.edu.cn

Xu Kai received his B. Sc. and Ph. D. degrees both from Chongqing University in 2016 and 2022. He is currently a lecturer at Chongqing University of Technology. His main research interests include error measurement and identification of machine tools.