

DOI: 10.19650/j.cnki.cjsi.J2513747

数控机床运动精度混沌自演化预测方法^{*}

杜柳青, 王煜晓, 余永维

(重庆理工大学机械工程学院 重庆 400054)

摘 要: 基于深度学习的精度预测模型会因不能自适应新的劣化数据而产生“灾难性遗忘”现象以致逐渐失效, 这是人工智能领域当前研究的热点和难点, 也是制约智能装备发展的难点之一。数控机床的运动精度演化过程具有混沌特性, 为此, 提出一种基于混沌理论与增量学习的数控机床运动精度混沌自演化预测方法。首先, 证明了数控机床运动精度的动态变化是一个复杂非线性动力学系统的混沌演化过程, 提出通过相空间重构恢复运动精度系统在混沌相空间中的演化轨迹。然后, 建立基于深度长短时记忆网络的运动精度混沌演化模型, 利用 LSTM 对时间序列长期依赖关系的出色捕捉能力, 在混沌相空间中追踪数控机床运动精度演化轨迹的内在规律。最后, 提出在混沌演化模型中引入无遗忘增量学习方法, 建立运动精度混沌自演化预测模型。该模型采用联合优化方法和知识蒸馏方法来更新参数, 使模型在适应新劣化数据的同时也传递旧任务的软目标, 在训练新数据时解决数据集更新时的“灾难性遗忘”问题, 提升长时间预测的准确性和鲁棒性。实验表明, 利用提出方法进行预测的评价指标 MSE 、 MAE 和 $MAPE$ 相较未加入无遗忘模块其波动幅度分别下降了 70.56%、33.31% 和 35.77%, 证明了模型预测的准确性, 进一步的模块消融实验也验证了该方法在预测准确度和鲁棒性上均优于传统方法。

关键词: 运动精度; 灾难性遗忘; 混沌自演化; 长短期记忆神经网络; 增量学习

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

Chaos self-evolution prediction method for motion accuracy of CNC machine tools

Du Liuqing, Wang Yuxiao, Yu Yongwei

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

Abstract: Prediction models based on deep learning often suffer from “catastrophic forgetting” caused by the inability to adapt to new degraded data. This is currently a hot and difficult topic in the field of artificial intelligence research, and also one of the constraints on the development of intelligent equipment. The accuracy evolution process of CNC machine tools has chaotic characteristics. Therefore, a chaotic self-evolution prediction method for the motion accuracy of CNC machine tools based on chaos theory and incremental learning is proposed. Firstly, it has been proven that the dynamic variation of motion errors in CNC machine tools is a chaotic evolution process of a complex nonlinear dynamic system. It is proposed to reconstruct the evolution trajectory of the precision system in the chaotic phase space through phase space reconstruction. Then, a motion accuracy chaotic evolution model based on deep long short-term memory (LSTM) network is established, utilizing the LSTM network’s excellent ability to accurately capture long-term dependencies of time series, to track the inherent laws of the evolution trajectory of CNC machine tool motion accuracy in chaotic phase space. Finally, a learning without forgetting incremental learning method is proposed in the chaotic evolution model to establish a motion accuracy chaotic self-evolution prediction model. This model uses joint optimization and knowledge distillation methods to update parameters, allowing the model to adapt to new degraded data while also conveying the soft objectives of old tasks. It solves the problem of “catastrophic forgetting” during dataset updates, improving the accuracy and robustness of long-term predictions. The experiment shows that the evaluation indicators MSE , MAE and $MAPE$ predicted by the method proposed have decreased in fluctuation amplitude by 70.56%,

收稿日期: 2025-02-14 Received Date: 2025-02-14

^{*} 基金项目: 国家自然科学基金 (52375083)、重庆英才计划 (CQYC20220207232/cstc2024ycjh-bgzxm0052)、重庆市技术创新与应用重点课题 (CSTB2022TIAD-CUX0017) 项目资助

33.31%, and 35.77%, respectively, compared to the non-LwF module. This proves the accuracy of the proposed prediction method. Further module ablation experiments also verify that the method proposed is superior to traditional methods in terms of prediction accuracy and robustness.

Keywords: motion accuracy; catastrophic forgetting; chaotic self-evolution; long short-term memory neural network; incremental learning

0 引言

高档数控机床是现代化智能制造不可或缺的重要装备^[1-2]。数控机床在服役期间,内部各组成要素之间及内部与外部系统之间不断相互作用,导致运动精度发生衰退的各类因素逐渐显现,如零部件变形、磨损、疲劳、锈蚀、老化、松动等^[3-5]。尽早对数控机床运动精度劣化进行预示对提高机床精度可靠性具有重要意义。

运动精度是数控指令与运动轴实际位移的符合程度^[6],其误差主要来源于机床几何误差、位置误差、伺服系统误差、控制时间延迟、机械振动及其相互作用。对数控机床运动精度的演化预测一直是国内外学者的研究热点,相关研究进展有:李海等^[7]提出了一种基于多维时间序列的数控机床状态预测方法,采用密度空间聚类算法进行状态序列分析,建立最佳历史状态矩阵来预测下一时刻状态。Liu等^[8]建立了基于数字孪生的数控机床运动轴时变误差模型,实现了对孔间距加工的误差预测和实时补偿。Deutsch等^[9]提出一种结合深度信念网络和反馈神经网络的设备性能预测方法,在螺旋锥齿轮测试设备剩余寿命预测实验中获得了较好的准确性。Zhao等^[10]提出一种基于局部特征的循环神经网络预测方法,并在齿轮箱和轴承早期故障预测中进行了验证。

得益于深度学习强大的特征提取能力,上述方法在预测方面取得了较大进展,然而现有深度学习模型在面临新涌现的劣化数据时会面临“灾难性遗忘”。国内外学者已针对深度学习模型的“灾难性遗忘”展开了研究,如吴美君等^[11]结合自编码器提高模型的场景学习性能,武晓栋等^[12]采用数据分离对抗样本来增强模型识别能力, Lee等^[13]采用对象检测和任务分割来解决视觉领域深度学习模型的任务遗忘问题, Zonooz等^[14]通过任务注意力模块的输出成对差异损失最大化方法来减轻遗忘,并尝试应用于自动驾驶。

数控机床全生命周期持续不断的流式数据为基于深度学习的运动精度预测带来了新命题。影响数控机床精度变化的各因素具有高度非线性和互耦合性,其动态变化是一个复杂非线性动力学系统的时空演化过程,现有研究鲜有从精度劣化的非线性动力学演化机理角度来探索数控机床精度的动态演化规律。混沌理论是非线性科学最重要的成就之一,其揭示了隐藏在无序和复杂表象背

后的有序和规律。基于混沌理论,通过相空间重构在高维相空间中恢复有用信息,以算法模型逼近混沌演化相空间中的动力学特性,能显著提高机床运动精度的预测效果^[15-16]。

为此,提出一种基于混沌理论与增量学习的混沌自演化预测方法,从精度劣化的混沌动力学演化角度来揭示数控机床精度的动态演化规律,利用混沌相空间重构恢复精度系统在高维相空间中的演化轨迹,建立无遗忘(learning without forgetting, LwF)的增量学习模型追踪精度轨迹演化序列,保证对新数据的自适应和对旧数据的记忆保持,避免传统模型的“灾难性遗忘”,实现混沌数据自演化建模和持续优化。

1 运动精度混沌自演化预测原理

随着机床运行过程中精度数据的不断产生,传统方法难以同时兼顾新数据的适应性与旧数据的记忆能力,提出的基于LwF增量学习的混沌自演化预测方法原理如图1所示。




图1 运动精度混沌自演化预测原理

Fig. 1 Prediction principle of chaotic self-evolution for motion accuracy

首先,利用混沌指数验证数控机床精度动态变化过程具有混沌特性,以证明运动精度的变化是一个总体呈现确定性,但包含一定随机性的混沌演化过程,其动力学演化信息蕴含在各参数时间序列中。在此基础上,基于相空间重构将运动精度时间序列嵌入到混沌相空间中,恢复精度系统在混沌相空间中的演化轨迹。然后,基于深度长短期记忆(long short-term memory, LSTM)网络的运动精度混沌演化预测模型,在重构后的高维相空间中追踪数据机床运动精度演化轨迹的内在规律。进一步,

引入 LwF 增量学习方法,赋予精度演化模型自适应学习的能力,通过持续更新模型参数,对新涌现精度数据的动态引入和自动学习,实现混沌自演化,有效解决“灾难性遗忘”问题,提升长时间预测的准确性和鲁棒性。

2 运动精度混沌自演化预测方法

2.1 机床运动精度混沌特性演化

Takens 定理^[17-18]认为混沌系统中任意分量的演化都是由与之相互作用着的其他分量所决定的,因此可用任意确定混沌系统长期演化的一维时间序列响应来重构与原动力系统拓扑同构的相空间,从而描述系统的内在演化规律。对机床运动精度数据进行混沌相空间重构,重构后的嵌入相空间与原系统的相空间在微分同胚意义下是拓扑等价的,具有相同的特性。因此可以在重构后的高维空间中追踪数据机床运动精度数据演化的内在规律,进一步对运动精度做出预测。

设 x_i 表示数控机床在第 i 个时间点测得的精度数据,则该精度的时间序列为 $\{x_1, x_2, \dots, x_i, \dots, x_n\}$, $x_i \in R$, 第 i 个运动精度特征向量重构后的高维相空间为:

$$\mathbf{X} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & \cdots & \vdots \\ x_i & x_{i+\tau} & \cdots & x_{i+(m-1)\tau} \\ \vdots & \vdots & \cdots & \vdots \\ x_n & x_{n+\tau} & \cdots & x_{n+(m-1)\tau} \end{bmatrix} \quad (1)$$

式中: m 为嵌入维数; τ 为延迟时间; n 为精度序列中数据的数量。 m 和 τ 的求取性能对混沌系统吸引子的几何结构有直接影响。因互关联 (cross-correlation, C-C) 方法的时间窗口长度综合考虑了两者的关联性,比较适合小样本数据计算,因此使用该算法求取运动精度特征量时序重构计算。

1) 定义机床运动精度时间序列的相关积分为:

$$C(m, n, r, t) = \frac{2}{M(M-1)} \sum_{i+j=M} \theta(r - d_{ij}) \quad (2)$$

式中: C 为某一精度序列的相关积分; r 为邻域半径; 一般取 $d_{ij} = x_i - x_j$ 代表上确界范数,表示相空间中某两点的距离; $M = n - (m-1)\tau$ 表示嵌入相点的数量。

2) 将精度时间序列数据独立分解为 t 项不相交的子项,计算 $S(m, n, r, t)$:

$$S(m, n, r, t) = \frac{1}{t} \sum_{s=1}^t \left[C\left(m, \frac{n}{t}, r, t\right) - C_s^m\left(1, \frac{n}{t}, r, t\right) \right] \quad (3)$$

式中: C_s 表示在 $s = 1 \sim t$ 项子序列时的每一项子序列的相关积分。

3) 取 $S(m, n, r, t)$ 的最大最小值所对应的半径 r , 定义 $\Delta S(m, t)$ 。取 $m = 2, 3, 4, 5, r_j = \frac{i\sigma}{2}, i = 1, 2, 3, 4$, 计算 $\bar{S}(t)$ 和 $\Delta \bar{S}(t)$ 。

$$\Delta S(m, t) = \max\{S(m, r_j, t)\} - \min\{S(m, r_j, t)\} \quad (4)$$

$$\begin{cases} \bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{j=1}^4 S(m, r_j, t) \\ \Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \bar{S}(m, t) \\ S_{cor}(t_i) = \Delta \bar{S}(t) + |\bar{S}(t)| \end{cases} \quad (5)$$

式中: 嵌入维数 $m = \frac{\tau_w}{\tau} + 1$, 特征时间序列的延迟时间 τ 为 $\Delta \bar{S}(t)$ 的第 1 个极小值对应的局部最大时间 t , τ_w 为 $S_{cor}(t_i)$ 最小值所对应的时间值。

2.2 运动精度混沌自演化预测模型构建

现有的混沌演化预测方法仅能对一段时间内产生的部分数据进行预测,缺乏对新劣化数据的适应能力。为提升运动精度预测模型对新劣化数据的适应性,使其在保持原有数据预测性能的同时能够接受和处理新数据,提出了一种基于增量学习与 LSTM 深度神经网络的混沌自演化预测模型,简称 CSE-IL-LSTM (chaotic self-evolution-incremental learning-long short-term memory neural network) 预测模型。

该模型由运动精度重构演化模块、LSTM 时空特征提取模块和 LwF^[19] 处理模块组成。首先通过运动精度重构演化模块计算运动精度变化序列数据的嵌入维度和延迟时间,而后求取最大 Lyapunov 指数并进行混沌特性分析。当数据表现出混沌特性时,执行相空间演化重构,并对重构后的运动精度变化数据进行归一化处理; LSTM 网络模块隐藏层含有 128 个神经单元,将重构后的运动精度时间序列分批输入到 LSTM 模型中,以挖掘数据中的时空特征,预测运动精度未来的时间序列轨迹; LwF 预测输出模块由 LwF 学习网络 and 全连接预测输出网络组成,其用于适应性地预测新劣化数据,同时实现增量学习,保持对原始数据的预测精度。通过这 3 个模块的协同作用,实现了对运动精度的混沌自演化预测和对新劣化数据的有效适应。CSE-IL-LSTM 模型结构如图 2 所示。

提出的 CSE-IL-LSTM 预测模型需要确定模型的演化时间步长、神经元个数、LSTM 层数、学习率等超参数,模型结构信息如表 1 所示。

传统的混沌时间序列预测方法中, LSTM 模型作为一种重要工具,凭借其强大的特征自学习能力和对时间序列长期依赖关系的捕捉能力^[20-25],被广泛应用于混沌系统的动态建模与预测。




图 2 CSE-IL-LSTM 预测模型
Fig. 2 CSE-IL-LSTM prediction model

表 1 CSE-IL-LSTM 模型结构参数

Table 1 CSE-IL-LSTM model structural parameters	
CSE-IL-LSTM	模块信息
运动精度重构演化模块	混沌特征辨别
	求取 m 和 τ
	混沌相空间重构维度:6
LSTM 模块	LSTM 神经元数:128
	学习率:0.000 1
	序列长度:2
	批次大小:10
LwF 预测输出模块	神经元个数:128
	层数:1
	学习率:0.000 1
	序列长度:2
	批次大小:10

然而,在面对动态变化的机床精度数据或多阶段任务时,LSTM 在学习新数据的过程中容易遗忘旧任务中的重要知识,从而导致模型性能退化。这种遗忘效应限制了 LSTM 模型在复杂混沌系统中持续学习的能力,降低了预测的稳定性和泛化能力。因此,在传统混沌演化与 LSTM 预测模型的基础上,引入一种新的机制来实现知识的持续保留和动态适应尤为必要。

2.3 混沌自演化模型的 LwF 方法实现

为了应对动态变化的非线性特性,提升精度预测模型对新数据的适应能力,提出在模型中引入 LwF 增量学习方法,赋予模型自适应学习的能力,实现运动精度混沌序列的自演化。在 LwF 方法中,模型通过知识蒸馏,在学习新数据时保留旧任务的特征分布,避免知识遗忘的同时,实现对动态混沌系统的有效建模。

基于混沌自演化模型的运动精度无遗忘学习方法如图 3 所示。




图 3 基于混沌自演化模型的运动精度无遗忘学习方法
Fig. 3 A learning without forgetting method for motion accuracy based on chaotic self-evolution model

1) 混沌自演化模型参数初始化

将混沌自演化模型的参数分为 3 类,共享参数 θ_s 、旧任务参数 θ_o 和新任务参数 θ_n ,均随机初始化。 θ_s 用于提取输入特征,在新旧任务间共享; θ_o 用于表示旧任务特定的输出层,固定其权重以保留历史知识; θ_n 针对新任务的输出层参数,通过新任务数据训练更新。

2) 生成新精度数据在旧任务模型中的预测分布

随着机床精度劣化,采集获得新的精度数据时,为保持原有精度数据集即旧任务知识,冻结旧任务相关参数 θ_s 和 θ_o ,计算新精度数据 X_{new} 在旧任务模型中的预测输出 Z_{old} 。

$$Z_{old} = f_{old}(X_{new}, \theta_s, \theta_o) \tag{6}$$

式中: $f_{old}()$ 为旧任务的预测函数。

将 Z_{old} 通过带平滑参数的 SoftMax 转换为旧任务模型的预测分布 y_{old} :

$$y_{old} = \text{softmax}\left(\frac{Z_{old}}{T}\right) \tag{7}$$

式中: y_{old} 是 Z_{old} 通过 SoftMax 函数归一化后的结果; T 为平滑参数,用于平滑分布,降低大概率类别权重。

3) 计算新精度数据在新任务模型中的监督损失

在增加新精度数据即新任务训练阶段,利用新精度数据的真实标签 y_{new} ,和当前新任务模型的预测输出 $\hat{y}_{new}$,计算新任务模型的监督损失 L_{new} ,即:

$$L_{new} = - \sum_i y_{new,i} \log \hat{y}_{new,i} \quad (8)$$

式中: $y_{new,i}$ 为新任务真实标签第 i 类的概率值; $\hat{y}_{new,i}$ 为当前模型预测分布第 i 类的概率值; i 表示当前计算的类别索引, $i \in [1, C]$, 其中 C 是任务的类别总数。

4) 基于蒸馏损失的联合优化

引入知识蒸馏来保持旧任务的输出, 定义蒸馏损失 L_{old} 使网络的输出概率值一定程度上逼近旧任务, 以直接保留旧任务的知识。

$$L_{old} = KL(y_{old}, \hat{y}_{old}) \quad (9)$$

式中: $\hat{y}_{old}$ 为当前模型旧任务的预测分布; $KL(\cdot)$ 为 Kullback-Leibler 散度, 用于衡量两个分布之间的差异。

解冻混沌自演化模型的共享参数 θ_s , 结合 L_{new} 形成联合优化目标函数:

$$L = \lambda_{old} \cdot L_{old} + L_{new} + R(\theta_s, \theta_o, \theta_n) \quad (10)$$

式中: L 为整体损失; λ_{old} 为蒸馏损失的权重, 用以控制新旧任务学习的平衡; $R(\cdot)$ 为正则化项, 用以防止模型过拟合。

同时, 动态调整蒸馏损失权重, 如式(11)所示。

$$\lambda_{old} = \max\left(0.7, 1.0 - \frac{epoch}{total_epochs}\right) \quad (11)$$

式中: $epoch$ 为当前训练轮次; $total_epochs$ 为总训练轮次。

5) 运动误差预测值生成

通过多轮训练, 混沌自演化模型的将逐步优化 θ_s 和 θ_n :

$$\theta_n^* \leftarrow \theta_n - \eta \cdot \frac{\partial L}{\partial \theta_n} \quad (12)$$

$$\theta_s^* \leftarrow \theta_s - \eta \cdot \frac{\partial L}{\partial \theta_s} \quad (13)$$

式中: η 为学习率; $\frac{\partial L}{\partial \theta_s}$ 为总损失对共享参数的梯度; $\frac{\partial L}{\partial \theta_n}$

为总损失对新任务参数的梯度; θ_s^* 和 θ_n^* 为优化后的共享参数和新任务参数。

则混沌自演化模型的最终预测值:

$$\hat{y}_{new} = f_{new}(X_{new}, \theta_s^*, \theta_n^*) \quad (14)$$

$$\hat{y}_{old} = f_{old}(X_{old}, \theta_s^*, \theta_n^*) \quad (15)$$

式中: $\hat{y}_{new}$ 为模型对于新任务的预测值; f_{new} 为新任务的预测函数; $\hat{y}_{old}$ 为模型对于旧任务的预测值。

LwF 方法在混沌自演化模型的网络方向和任务方向上分别形成深度。网络方向的深度通过 LSTM 隐藏单元的层次结构挖掘混沌时间序列的时空特征, 而任务方向的深度通过蒸馏损失动态调节, 保证新旧机床精度数据之间的无缝衔接。

3 实验与分析

3.1 数据采集

数控机床圆运动是各坐标轴的多轴联动。通过双轴插补指令合成的圆运动精度不仅包含与数控机床的几何精度、位置误差、重复精度有关的信息, 而且还包含与进给速度和伺服控制系统有关的动态误差分量信息, 能全面反映运动误差的演化情况。基于球杆仪的误差检测方法已被 ISO 230-4:2005 标准所采纳^[26], 选用雷尼绍球杆仪系统采集数控机床圆运动数据。实验测试平台为 XK-L540 型数控铣床, 如图 4 所示。




图4 XK-L540 型数控铣床实验

Fig. 4 Experiment on XK-L540 CNC milling machine

以圆度误差作为圆运动精度的评价指标, 圆运动误差轨迹夹在其间且半径差最小的两圆半径之差即为圆度误差, 如图 5 所示。




图5 圆度误差示意

Fig. 5 Diagram of roundness error

使 XK-L540 机床主轴以 100 mm 圆半径、1 000 mm/min 进给速度作两轴联动的圆运动, 采集到圆运动误差数据共 3 059 组, 经四分位距方法去噪后, 分为 3 个在时序上连续的数据集, 按时间顺序分别命名为数据集 1、2、3。

3.2 运动精度混沌特性及相空间重构

混沌动力学系统对初始条件具有极高的敏感性。当两个相邻的初始值经过混沌演化后, 其对应的轨迹会呈指数规律分离。这种轨迹分离的特性可以通过 Lyapunov 指数进行定量描述, 其中最大 Lyapunov 指数是关键判

据^[27]。若系统的最大 Lyapunov 指数 >0 ,则可以证明该动态误差系统处于混沌状态。使用 WOLF 法来确定数据的最大 Lyapunov 指数,同时采用 C-C 法求取圆运动误差的最佳延迟时间和最佳嵌入维数,结果如表 2 所示。

表 2 圆度时间序列的时间延迟 (τ)、嵌入维数 (m) 和最大 Lyapunov 指数

Table 2 Time delay (τ), embedding dimension (m) and maximum Lyapunov exponent of roundness time series

数据集	τ	m	Lyapunov 指数
数据集 1	4	2	1.657 1
数据集 2	3	2	1.423 2
数据集 3	2	2	1.627 8

各数据集的最大 Lyapunov 指数均 >0 ,表明圆运动误差系统处于混沌状态,即数控机床运动误差的动态变化是一个具有混沌特性的非线性演化过程。

根据各数据集的延迟时间和嵌入维数,即可将各数据集时间序列重构到混沌相空间。

3.3 混沌自演化预测实验

建立的 CSE-IL-LSTM 神经网络模型在 Python3.11 语言环境下开发,基于 PyTorch24.1 框架,配置的硬件为 Intel Core i7-14700KF CPU、32 GB 内存、NVIDIA GeForce RTX 4060Ti GPU。

运动误差时序样本数据变化较大,重构后的相空间矩阵维度不同,因数据维度不同可能导致模型在训练过程中无法收敛,因此在模型训练前对数据进行归一化处理,即:

$$X = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

(16)

式中: $x_{\max}$ 、 $x_{\min}$ 分别表示高维相空间中某一维数据的最大值和最小值。

归一化后,将各数据集的前 80% 数据用于模型训练,后 20% 用于验证预测效果。激活函数为 Tanh 函数,同时采用 Adam 优化。3 个数据集在训练时的学习率均设置为 0.000 1,并采取早停机制以防止过拟合。

为对模型预测性能进行量化评价,采用均方误差 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 作为预测模型的评价指标。计算式分别为:

$$MSE = \frac{1}{N} \sum_{n=1}^N (y - \hat{y})^2$$

(17)

$$MAE = \frac{1}{N} \sum_{n=1}^N |y - \hat{y}|$$

(18)

$$MAPE = \frac{100\%}{N} \sum_{n=1}^N \left| \frac{y - \hat{y}}{y} \right|$$

(19)

式中: N 为数据个数; y 为真实值; $\hat{y}$ 为预测值。MSE、MAE、MAPE 的值越小,表示预测效果越好。

依据采集机床圆运动获得的 3 个运动误差实际劣化过程数据集,将 CSE-IL-LSTM 模型混沌自演化分为 3 个阶段,即:第 1 次混沌自演化、第 2 次混沌自演化、第 3 次混沌自演化。对运动精度数据集的混沌自演化预测流程如图 6 所示。




图 6 混沌自演化预测流程

Fig. 6 Process of chaotic self-evolution prediction

1) 第 1 次混沌自演化

利用 CSE-IL-LSTM 模型训练数据集 1 的损失曲线如图 7 所示,模型能够有效学习数据集 1 的特征,在迭代 12 次后达到收敛,训练及验证的收敛损失值分别为 $6.233\ 0 \times 10^{-3}$ 和 $3.495\ 3 \times 10^{-3}$ 。




图 7 数据集 1 第 1 次混沌自演化预测训练损失

Fig. 7 Training loss of the first chaotic self-evolution prediction in dataset 1

CSE-IL-LSTM 模型对于数据集 1 的混沌自演化单纯预测结果如图 8 所示。




图8 数据集1第1次混沌自演化预测结果

Fig. 8 Prediction result of the first chaotic self-evolution in dataset 1

CSE-IL-LSTM 模型对于数据集1第1次混沌自演化的 MSE 、 MAE 和 $MAPE$ 值分别为 1.338 2、0.896 1 和 2.066 6%,对于数据集1的预测准确性较高。

2) 第2次混沌自演化

随着数控机床精度劣化,获得了劣化后的精度数据集即数据集2。采用 LwF 增量学习方法,模型首先冻结运动精度数据集1对应的参数,将数据集1和2在 CSE-IL-LSTM 模型中训练。利用数据集2生成数据集1的软目标分布,即“回忆”数据集1的训练目标,然后通过联合优化数据集1的监督损失和数据集2的蒸馏损失来更新参数。CSE-IL-LSTM 模型在适应新数据的同时传递旧任务的知识,避免了“灾难性遗忘”问题的出现。CSE-IL-LSTM 模型对数据集2第1次混沌自演化预测的训练损失如图9所示,模型在迭代15次后达到收敛,训练及验证的收敛损失值分别为 $9.024\ 8 \times 10^{-3}$ 和 $2.952\ 7 \times 10^{-3}$,有效学习了数据集2特征。




图9 数据集2第1次混沌自演化预测训练损失

Fig. 9 Training loss of the first chaotic self-evolution in dataset 2

CSE-IL-LSTM 模型对于数据集2的第1次混沌自演化预测结果如图10所示。




图10 数据集2第1次混沌自演化预测结果

Fig. 10 Prediction result of the first chaotic self-evolution in dataset 2

CSE-IL-LSTM 模型对于数据集2的 MSE 、 MAE 和 $MAPE$ 值分别为 1.181 2、0.686 1 和 1.483 6%,预测效果较好,能够自适应数据集2新的数据分布。

当 CSE-IL-LSTM 模型结束对于数据集2的训练之后,加入2次数据集1和2的“回忆”,即加入2轮自演化单纯预测的软目标分布参数,重新评价模型其对数据集1的预测,其 MSE 、 MAE 和 $MAPE$ 值分别为 1.449 5、0.883 3 和 2.043 8%。预测效果如图11所示。




图11 数据集1第2次混沌自演化预测结果

Fig. 11 Prediction result of the second chaotic self-evolution in dataset 1

从量化指标来看,在加入了数据集2后 CSE-IL-LSTM 模型对于数据集1的自演化预测结果比单纯预测数据集1时的 MAE 和平均预测误差分别提升了 1.428 4% 和 1.103 3%,这是由于数据集1和2在数据分布以及发展趋势上具有相似性。

CSE-IL-LSTM 模型通过 LwF 增量学习方法,在训练数据集2时不仅学习了新数据的特征,还通过知识蒸馏保留了从数据集1中学到的知识。这种机制使得模型能够将数据集2中的新信息与数据集1的已有知识相结合,进一步优化对数据集1的理解和预测能力。因此,模型在训练数据集2后,对数据集1的预测误差降低,提升了预测效果。

3) 第 3 次混沌自演化

在 CSE-IL-LSTM 模型结束对于数据集 1 和 2 的训练之后,新增精度劣化数据即数据集 3。

采用 LwF 增量学习方法“回忆”数据集 1 和 2 的软目标分布,避免“灾难性遗忘”,CSE-IL-LSTM 模型对数据集 3 进行第 1 次混沌自演化的预测训练在迭代 10 次后达到收敛,训练及验证的收敛损失值分别为 $9.619\ 0\times 10^{-3}$ 和 $3.063\ 3\times 10^{-2}$ (如图 12 所示),模型有效学习了数据集 3 的特征。




图 12 数据集 3 第 1 次混沌自演化预测训练损失
Fig. 12 Training loss of the first chaotic self-evolution in dataset 3

CSE-IL-LSTM 模型对于数据集 3 的第 1 次混沌自演化预测结果如图 13 所示。




图 13 数据集 3 第 1 次混沌自演化预测结果
Fig. 13 Prediction result of the first chaotic self-evolution in dataset 3

CSE-IL-LSTM 模型对于数据集 3 进行第 1 次混沌自演化的 MSE 、 MAE 和 $MAPE$ 值分别为 15.529 0、2.903 7 和 5.807 6%,预测结果较为理想,能够自适应数据集 3 新的数据分布。

当 CSE-IL-LSTM 模型结束对于数据集 3 的训练之后,对数据集 1 进行第 3 次混沌自演化,对数据集 2 进行第 2 次混沌自演化,预测效果分别如图 14(a)、(b)所示。数据集 1 第 3 次混沌自演化的量化指标为: MSE 值 1.380 0、 MAE 值 0.881 8、 $MAPE$ 值 2.054 6%;数据集 2

第 2 次混沌自演化的量化指标为: MSE 值 1.303 1、 MAE 值 0.715 4、 $MAPE$ 值 1.558 2%。




图 14 第 3 次混沌自演化预测结果
Fig. 14 Prediction results of the third chaotic self-evolution

从量化指标来看数据集 1 在加入了数据 3 后 CSE-IL-LSTM 模型对于数据集 1 的预测结果比单独预测数据集 1 时的 MAE 和平均预测误差均有所提升,这主要得益于 CSE-IL-LSTM 模型的知识蒸馏,使模型能够将数据集 3 中的新信息与数据集 1 的已有知识相结合,进一步优化对数据集 1 的理解和预测能力。对于数据集 2,虽然数据集 3 内精度劣化数据的发展趋势和分布情况与其有较大不同,但对数据集 2 的预测结果仍然有较好的准确性。

以上 3 组精度数据集的混沌自演化预测实验表明,CSE-IL-LSTM 模型引入 LwF 增量学习方法,通过知识蒸馏技术,使模型在学习新数据时能够保留旧任务的特征分布,避免了“灾难性遗忘”问题,同时通过联合优化新任务的监督损失和旧任务的蒸馏损失,实现了对新数据的自适应学习。这一机制显著提升了模型的预测精度和泛化能力,在多任务连续学习中保持了稳定的预测性能。实验结果表明,CSE-IL-LSTM 模型在多个数据集上的混沌自演化预测误差显著降低,特别是在长期精度劣化预测中表现出较高的稳定性和鲁棒性,达到了较好的运动精度混沌自演化预测效果。

3.4 对比实验及分析

为验证提出的 CSE-IL-LSTM 预测模型在应对新数据输入时对于新旧任务的预测效果,并验证 CSE-IL-LSTM 模型各模块的有效性,建立了消融无增量学习模块后基于 LSTM 深度学习的 CSE-LSTM 模型、消融混沌相空间重构模块后基于增量学习的 IL-LSTM 模型进行对比实验。同时,为了验证 CSE-IL-LSTM 模型相对于同类型 RNN(recurrent neural network)网络模型的预测优势,建立了基于门控循环单元(gated recurrent unit, GRU)的 CSE-IL-GRU 模型和基于双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)的 CSE-IL-BiLSTM 模型进行对比。各模型采用与 CSE-IL-LSTM 神经网络运动精度预测模型相同的训练参数设置。

首先采集获得数据集 1 并进行训练,随机床精度劣化,依次获得并训练数据集 2、3 的机床实际劣化过程,各模型与 CSE-IL-LSTM 模型在连续多个数据集即多个任务阶段预测误差如表 3 所示。

由表 3 可知,CSE-LSTM 模型在依次增加数据集 2 和 3 后,预测精度逐渐较大幅下降,对原数据集 1 的精度预测曲线与真实值曲线明显偏离,如图 15 所示, MSE 增加了 73.68%、 MAE 增加了 34.91%、 $MAPE$ 增加了 36.35%,如表 4 所示。由表 3 和 4 可知,CSE-LSTM 模型由于缺乏增量学习机制,模型在学习新数据集时,原有数据集的知识被部分覆盖,导致基于 LSTM 的深度学习预测模型在多任务连续学习中存在“灾难性遗忘”问题,无法有效保留旧任务的知识,导致预测误差增大,预测性能逐渐退化,不能有效应对多任务连续学习的需求。此外,CSE-IL-LSTM 模型相比 IL-LSTM 模型、CSE-IL-GRU 模型及 CSE-IL-BiLSTM 均展现了不同程度的优越性。




图 15 CSE-LSTM 模型对原数据集 1 预测结果
Fig. 15 Prediction result of CSE-LSTM model in the original dataset 1

表 3 和 4 表明,CSE-IL-LSTM 模型因 LwF 增量学习方法在依次增加数据集 2 和 3 后,预测精度仍然保持稳

表 3 不同模型多任务预测效果对比
Table 3 Comparison of multi-task prediction performance among different models

精度劣化阶段	预测数据集	模型	MSE / μm	MAE / μm	$MAPE$ / %
第 1 次演化	数据集 1	IL-LSTM	1.549 9	0.939 2	2.176 7
		CSE-IL-GRU	1.348 8	0.8769	2.033 9
		CSE-IL-BiLSTM	1.344 7	0.877 1	2.030 3
		CSE-LSTM	1.542 0	0.939 2	2.176 7
		CSE-IL-LSTM	1.338 2	0.896 1	2.066 6
第 2 次演化	数据集 1	IL-LSTM	1.638 6	0.945 4	2.190 3
		CSE-IL-GRU	1.360 6	0.881 7	2.043 2
		CSE-IL-BiLSTM	1.488 1	0.954 0	2.189 0
		CSE-LSTM	1.705 0	0.961 6	2.233 2
		CSE-IL-LSTM	1.449 5	0.883 3	2.043 8
	数据集 2	IL-LSTM	1.201 5	0.939 2	2.176 7
		CSE-IL-GRU	1.381 2	0.721 3	2.033 9
		CSE-IL-BiLSTM	1.550 7	0.861 3	1.828 5
		CSE-LSTM	1.203 8	0.704 3	1.526 7
		CSE-IL-LSTM	1.182 1	0.686 1	1.483 6
第 3 次演化	数据集 1	IL-LSTM	1.821 1	1.003 4	2.343 2
		CSE-IL-GRU	1.677 2	0.959 4	2.249 5
		CSE-IL-BiLSTM	1.488 8	0.906 0	2.092 5
		CSE-LSTM	2.678 2	1.267 1	2.967 9
		CSE-IL-LSTM	1.380 0	0.881 8	2.054 6
	数据集 2	IL-LSTM	1.432 0	0.777 4	1.691 4
		CSE-IL-GRU	2.135 3	0.933 9	2.060 5
		CSE-IL-BiLSTM	1.271 6	0.725 2	1.569 3
		CSE-LSTM	2.298 6	1.088 6	2.359 9
		CSE-IL-LSTM	1.303 1	0.715 4	1.558 2
	数据集 3	IL-LSTM	17.330 3	2.861 8	5.758 1
		CSE-IL-GRU	16.423 2	3.092 1	6.201 3
		CSE-IL-BiLSTM	16.267 9	2.881 1	5.766 2
		CSE-LSTM	16.755 3	2.895 9	5.862 6
		CSE-IL-LSTM	15.529 0	2.903 7	5.807 6

定:对原数据集 1 的预测 MSE 、 MAE 和 $MAPE$ 仅仅分别波动了 3.12%、1.6% 和 0.58%,表明 CSE-IL-LSTM 模型在多任务机床精度连续预测中的表现均优于各对比模型,展现了更高的稳定性和鲁棒性,能够有效应对长期精度劣化预测的需求。

表 4 模型对数据集 1 预测稳定性误差对比

Table 4 Comparison of models' prediction stability error in dataset 1

指标	模型	第 1 次 演化	第 2 次 演化	第 3 次 演化	预测精度 波动比/%
MSE / μm	IL-LSTM	1.549 9	1.638 6	1.821 1	17.50
	CSE-IL-GRU	1.348 8	1.360 6	1.677 2	24.35
	CSE-IL-BiLSTM	1.344 7	1.488 1	1.488 8	7.97
	CSE-LSTM	1.542 0	1.705	2.678 2	73.68
	CSE-IL-LSTM	1.338 2	1.449 5	1.380 0	3.12
MAE / μm	IL-LSTM	0.939 2	0.945 4	1.003 4	6.84
	CSE-IL-GRU	0.876 9	0.881 7	0.959 4	9.43
	CSE-IL-BiLSTM	0.877 1	0.954 0	0.90 60	3.98
	CSE-LSTM	0.939 2	0.961 6	1.267 1	34.91
	CSE-IL-LSTM	0.896 1	0.883 3	0.881 8	1.60
MAPE (%)	IL-LSTM	2.176 7	2.190 3	2.343 2	7.65
	CSE-IL-GRU	2.033 9	2.043 2	2.249 5	10.60
	CSE-IL-BiLSTM	2.030 3	2.189 0	2.092 5	3.06
	CSE-LSTM	2.176 7	2.233 2	2.967 9	36.35
	CSE-IL-LSTM	2.066 6	2.043 8	2.054 6	0.58

4 结 论

本研究提出了一种 CSE-IL-LSTM 混沌自演化预测模型,实现了数控机床运动精度长时间劣化过程中动态建模与准确预测。

1)提出了基于混沌理论与增量学习的运动精度混沌自演化方法,从精度劣化的混沌动力学角度揭示了数控机床精度演化的混沌特性,通过混沌相空间重构恢复运动精度数据在混沌空间的演化轨迹,并结合深度 LSTM 网络与 LwF 增量学习模块,实现对新旧劣化数据的自适应学习与动态演化建模。

2)建立了 CSE-IL-LSTM 模型,在混沌演化模型中引入无遗忘(LwF)增量学习方法,能够长时间追踪精度轨迹演化序列,通过知识蒸馏保证了对新数据的自适应和对旧数据的记忆保持,解决了模型的“灾难性遗忘”问题,大幅提高了在长时间多数据集下机床精度连续预测的准确性。

3)实验证明了 CSE-IL-LSTM 方法在提升预测精度和模型适应性方面的有效性和优势,在对多个连续数据集的演化预测中,对加入新数据的预测准确性明显优于传统方法,对原有数据预测的评价指标 MSE、MAE 和 MAPE 波动幅度分别下降了 70.56%、33.31% 和

35.77%,证明了 CSE-IL-LSTM 方法长时间预测的准确性和鲁棒性。

参考文献

[1] 陶飞,张辰源,刘蔚然,等. 数字工程及十个领域应用展望[J]. 机械工程学报,2023,59(13):193-215.
TAO F, ZHANG CH Y, LIU W R, et al. Digital engineering and its ten application outlooks[J]. Journal of Mechanical Engineering, 2023, 59(13): 193-215.

[2] 贺帅宇,周涛,金玲兴,等. 基于光谱共焦原理的五轴数控机床工件在位测量系统[J]. 仪器仪表学报, 2025,46(1):75-82.
HE SH Y, ZHOU T, JIN L X, et al. A workpiece in-place measurement system for 5-axis CNC machine tools based on spetral confocal principle[J]. Chinese Journal of Scientific Instrument, 2025,46(1):75-82.

[3] LI H, DENG ZH M, GOLILARZ N A, et al. Reliability analysis of the main drive system of a CNC machine tool including early failures[J]. Reliability Engineering & System Safety, 2021, 215: 107846.

[4] 杜柳青,吕发良,余永维. 数字孪生下基于 DACS-MFAC 的数控机床热误差自适应预测方法[J]. 仪器仪表学报,2024,45(4):248-257.
DU L Q, LYU F L, YU Y W, DACS-MFAC-based adaptive prediction method for thermal errors of CNC machine tools under digital twin[J]. Chinese Journal of Scientific Instrument, 2024,45(4):248-257.

[5] 李帅,杨赫然,孙兴伟,等. 基于改进神经网络算法的数控钻攻中心进给轴热误差预测[J]. 电子测量与仪器学报,2023,37(9):234-242.
LI SH, YANG H R, SUN X W, et al. Prediction of thermal error of CNC drilling center feed axis based on improved neural network algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(9):234-242.

[6] 吕盾,张佳辉,王大伟,等. 国产数控机床动态精度技术现状与对策[J]. 航空制造技术, 2022, 65(6): 22-33.
LYU D, ZHANG J H, WANG D W, et al. Technical status and countermeasures of dynamic accuracy of domestic CNC machine tools[J]. Aeronautical Manufacturing Technology, 2022, 65(6): 22-33.

[7] 李海,王伟,黄璞,等. 基于多维时间序列的数控机床状态预测方法研究[J]. 工程科学与技术, 2018, 50(1): 187-195.
LI H, WANG W, HUANG P, et al. State prediction method research in NC machine tool based on multidimensional time series[J]. Advanced Engineering Sciences, 2018, 50(1): 187-195.

- [8] LIU K, SONG L, HAN W, et al. Time-varying error prediction and compensation for movement axis of CNC machine tool based on digital twin[J]. IEEE Transactions on Industrial Informatics, 2021, 18(1): 109-118.
- [9] DEUTSCH J, HE D. Using deep learning-based approach to predict remaining useful life of rotating components[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 48(1): 11-20.
- [10] ZHAO R, WANG D ZH, YAN R Q, et al. Machine health monitoring using local feature-based gated recurrent unit networks [J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1539-1548.
- [11] 吴美君,杨新,潘超凡,等. 自编码器结合持续学习: 现状、挑战与展望[J]. 计算机学报, 2025, 48(2): 317-357.
- WU M J, YANG X, PAN CH F, et al. Autoencoders combined with continual learning: Development, challenges, and prospects [J]. Chinese Journal of Computers, 2025, 48(2): 317-357.
- [12] 武晓栋,金志刚,陈旭阳,等. 对抗学习辅助增强的增量式入侵检测系统[J]. 哈尔滨工业大学学报, 2024, 56(9): 31-37, 84.
- WU X D, JIN ZH G, CHEN X Y, et al. Adversarial learning-augmented incremental intrusion detection system[J]. Journal of Harbin Institute of Technology, 2024, 56(9): 31-37, 84.
- [13] LEE J J, LEE S I, KIM H. Continual learning for instance segmentation to mitigate catastrophic forgetting[C]. 2021 18th International SoC Design Conference, 2021: 85-86.
- [14] ZONOOZ B, ARANI E, BHAT P S. Method for partially preventing catastrophic forgetting in continual learning of multiple tasks sequentially using artificial neural network for perception and understanding, involves using classifier representing classes belonging to tasks for action and learning: EP4343622-A1[P]. 2024-03-07.
- [15] 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(9): 1362-1373.
- [16] 肖域坤,曾治霖,唐越,等. 基于激光球杆干涉仪的数控机床空间误差高效测量、辨识与补偿[J]. 仪器仪表学报, 2024, 45(10): 222-233.
- XIAO Y K, ZENG ZH L, TANG Y, et al. Efficient measurement, identification and compensation of volumetric errors on machine tools using laserbar [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 222-233.
- [17] 师鹏飞,赵西键,徐辉荣,等. 融合相空间重构和深度学习的径流模拟预测[J]. 水科学进展, 2023, 34(3): 388-397.
- SHI P F, ZHAO Y J, XU H R, et al. Simulation and prediction of streamflow based on phase space reconstruction and deep learning algorithm[J]. Advances in Water Science, 2023, 34(3): 388-397.
- [18] ROUSSEL R, EDELEN A, MAYES C, et al. Phase space reconstruction from accelerator beam measurements using neural networks and differentiable simulations[J]. Physical Review Letters, 2023, 130(14): 145001.
- [19] ZHANG P ZH, BAN Y F, NASCETTI A. Learning U-Net without forgetting for near real-time wildfire monitoring by the fusion of SAR and optical time series[J]. Remote Sensing of Environment, 2021, 261: 112467.
- [20] FENG T, YANG SH Y, HAN F. Chaotic time series prediction using wavelet transform and multi-model hybrid method[J]. Journal of Vibroengineering, 2019, 21(7): 1983-1999.
- [21] 黄伟建,李永涛,黄远. 基于混合神经网络和注意力机制的混沌时间序列预测[J]. 物理学报, 2021, 70(1): 235-243.
- HUANG W J, LI Y T, HUANG Y. Prediction of chaotic time series using hybrid neural network and attention mechanism[J]. Acta Physica Sinica, 2021, 70(1): 235-243.
- [22] JIA B W, WU H Y, GUO K Y. Chaos theory meets deep learning: A new approach to time series forecasting[J]. Expert Systems with Applications, 2024, 255: 124533.
- [23] SUN Y, ZHANG L Y, YAO M H. Chaotic time series prediction of nonlinear systems based on various neural network models[J]. Chaos, Solitons & Fractals, 2023, 175: 113971.
- [24] 孙巍伟,梁毅玮,毛亦鹏,等. 基于多传感信息融合的跌倒监测系统开发[J]. 电子测量技术, 2024, 47(22): 94-103.
- SUN W W, LIANG Y W, MAO Y P, et al. Development of a fall detection system based on multi-sensor information fusion[J]. Electronic Measurement Technology, 2024, 47(22): 94-103.
- [25] 彭铎,查海音,曹坚,等. 基于CNN-LSTM声速预测的水下移动节点定位算法[J]. 电子测量与仪器学报, 2024, 38(11): 146-157.
- PENG D, ZHA H Y, CAO J, et al. Underwater mobile node location algorithm based on CNN-LSTM sound velocity prediction[J]. Journal of Electronic

Measurement and Instrumentation, 2024, 38(11): 146-157.

[26] GAO W, IBARAKI S, DONMEZ M A, et al. Machine tool calibration: Measurement, modeling, and compensation of machine tool errors[J]. International Journal of Machine Tools and Manufacture, 2023, 187: 104017.

[27] ZHOU P, HU X K, ZHU ZH G, et al. What is the most suitable Lyapunov function? [J]. Chaos, Solitons & Fractals, 2021, 150: 111154.

作者简介



杜柳青(通信作者),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,研究方向为微弱信号检测、机床精度设计。

E-mail: lqdu@cqut.edu.cn

Du Liqing (Corresponding author) 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. Now she is a professor and master supervisor at Chongqing University of Technology. Her main research interests include weak signal detection and machine tool's precision design.



王煜晓,2021 年于烟台大学获学士学位,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:1154826297@qq.com

Wang Yuxiao received his B. Sc. degree from Yantai University in 2021. Now he is a M. Sc. candidate at Chongqing University of Technology. His main research interests include advanced manufacturing technology and machine tool's precision design.



余永维,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:weiyy@cqut.edu.cn

Yu Yongwei received his B. Sc. degree from Wuhan University of Technology in 1997, received his M. Sc. degree from Chongqing University in 2005, received his Ph. D. degree from Sichuan University in 2014. Now he is a professor and master supervisor at Chongqing University of Technology. His main research interests include machine vision and intelligent control.