

doi:10.6041/j.issn.1000-1298.2023.11.043

基于混沌表示和特征注意力机制的机床两轴动态误差预测

杜柳青 李宝钏 余永维

(重庆理工大学机械工程学院, 重庆 400054)

摘要: 针对传统方法难以揭示机床多轴插补动态误差的序列产生机制, 各时间维度上的误差时序特征存在相互关联的问题, 提出一种融合混沌表示(Chaotic representation, CR)和特征注意力机制(Feature attention mechanism, FA)的级联动态误差预测模型。首先, 在证明多元动态误差时变演化具有混沌特性的基础上, 对其进行相空间重构, 将动态误差参数时间序列背后隐藏的信息在相空间中进行表达。然后, 融合特征注意力机制在时间维度上动态分配相点特征权重的同时降低高维演化相空间信息冗余, 进一步重塑原系统的动力学状态向量空间。最后, 考虑到混沌时变演化具有长程相关性, 采用双向长短期记忆(Bi-directional long short-term memory, Bi-LSTM)网络模型逼近混沌相空间内的动力学特性, 实现动态误差混沌时间序列信息的有效预测。通过 XK-L540 型数控铣床实测数据的算例表明, 相较于 CRFA-LSTM 模型, 以及单一级联模型 CR-Bi-LSTM、FA-Bi-LSTM, 本文算法的均方根误差分别降低约 35%、16% 和 43%。

关键词: 机床; 动态误差预测; 混沌表示; 特征注意力机制; 双向长短期记忆网络

中图分类号: TH115 文献标识码: A 文章编号: 1000-1298(2023)11-0451-08

OSID:



Dynamic Error Prediction of Machine Tool Two-axis Based on Chaotic Representation and Feature Attention Mechanism

DU Liuqing LI Baochuan YU Yongwei

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

Abstract: To address the problem that traditional methods are difficult to reveal the sequence generation mechanism of dynamic error in machine tool multi-axis interpolation and the error time series features in each time dimension are interrelated, a cascaded dynamic error prediction model integrating chaotic representation (CR) and feature attention mechanism (FA) was proposed. Firstly, on the basis of proving that the time-varying evolution of multivariate dynamic error had chaotic characteristics, the phase space was reconstructed to represent the hidden information behind the time series of dynamic error parameters in the phase space. Then the fused feature attention mechanism further reshaped the dynamical state vector space of the original system by dynamically assigning phase point feature weights in the time dimension while reducing the redundancy of information in the high-dimensional evolution phase space. Finally, considering the long-range correlation of chaotic time-varying evolution, the bi-directional long short-term memory (Bi-LSTM) network model was used to approximate the dynamics in the chaotic phase space to achieve the effective prediction of dynamic error chaotic time series information. Compared with the Bi-LSTM model and the single cascade models CR-Bi-LSTM and FA-Bi-LSTM, the root mean square error of this algorithm was reduced by about 35%, 16% and 43%, respectively, as shown by the example of XK-L540 CNC milling machine with real data. The algorithm realized the phase space expression of dynamic error sequence generation mechanism in time dimension, and constantly played the main role of key phase point feature, with high prediction accuracy.

Key words: machine tool; dynamic error prediction; chaotic representation; feature attention mechanism; bi-directional long and short-term memory network

收稿日期: 2023-04-26 修回日期: 2023-05-25

基金项目: 国家自然科学基金面上项目(52375083)、重庆市自然科学基金面上项目(cstc2021jcyj-msxmX0372)、川渝联合实施重点研发项目(CSTB2022TIAD-CUX0017)、重庆市研究生科研创新项目(CYS22657)和重庆理工大学国家“两金”培育项目(2022PYZ005)

作者简介: 杜柳青(1975—),女,教授,博士,主要从事机床精度设计和智能制造研究,E-mail: lqdu@cqu.edu.cn

通信作者: 余永维(1973—),男,教授级高级工程师,博士,主要从事智能制造和机器视觉研究,E-mail: weiyi@cqu.edu.cn

0 引言

数控机床在加工过程中,指令速度及加速度等因素变化极易引起运动副产生间隙、变形及振动,具有很强的时变性、随机性、相关性和动态性^[1-3]。数控机床加工精度的稳定性会因动态误差恶化而衰退,通过捕捉机床运动轴插补动态误差演化规律,指导动态加工中的精度控制,对提高机床的定位精度和重复定位精度具有重要意义^[4]。

对于数控机床多轴插补运动产生的动态误差,国内外学者做了大量研究,WANG 等^[5]分析了速度变化过程中耦合力对刀尖点偏差的影响,提出了基于轴耦合效应的三轴龙门机床动态模型。YANG 等^[6]考虑到进给轴位置和加速度变化会引发机械结构的振动和变形,提出了一种三轴龙门机床的变参数多刚体动力学模型。CHEN 等^[7]分析了运动轴的动态误差与加工表面多尺度频域误差之间的关系,提出了一种基于傅里叶变换的动态误差建模方法。刘家汐^[8]通过层次聚类法将测得的 S 形试件表面误差划分成簇,并基于多元线性回归建立了数控机床的动刚度及位置环增益等与 S 形试件中的动态误差之间的映射关系。HE 等^[9]应用直接加工 S 形试件的检测方法,推导了伺服进给系统在频域的动态误差函数,并基于偶极子对消法简化了随输入变化的动态误差传递函数,得到了输入对动态误差影响的时域表达式。李松等^[10]以主轴转速、切深等加工条件作为模型输入,利用 AFSA-ACO-BPN 融合算法,建立了一种能综合反映各种切削条件的五轴数控机床动态误差模型。殷国为等^[11]认为运动参数是引起机床多轴联动加工误差的主要因素,并通过齐次坐标变化理论建立了机床两轴插补动态误差的数学模型。

机床多轴插补动态误差是由伺服系统、机械变形和振动共同引起^[12],以上研究主要聚焦于动态误差影响因素建模,鲜有对动态误差时变规律的研究,且在时间维度上忽略了动态误差时序特征间的高度耦合性。动态误差的非线性动力学系统内部错综复杂,系统信息通常隐含在各参数时间序列中,如能通过相空间重构获得这部分有用的系统信息,并以算法模型逼近混沌演化相空间中的动力学特性,则能很好地提高机床动态误差的预测精度。

考虑到动态误差具有强时变性,双向长短期记忆(Bi-directional long short-term memory,Bi-LSTM)网络可以长时间存储前向时间序列信息和后向输入信息^[13],能在当前和历史状态信息共同作用下实现动态误差预测。因此,本文在机床两轴插补动态误

差时变演化具有混沌特性的基础上,提出一种融合混沌表示(Chaotic representation, CR)和特征注意力机制(Feature attention mechanism, FA)的级联动态误差预测模型。以重塑后的动力学状态向量空间为目标,通过 Bi-LSTM 网络逼近建模找到相点的演化规律,以期实现动态混沌时间序列信息有效提取。

1 CRFA-Bi-LSTM 动态误差预测模型原理

1.1 动态误差预测模型框架结构

CRFA-Bi-LSTM 的动态误差预测模型结构如图 1 所示,主要包括:①采用混沌时间序列分析揭示机床多轴插补动态误差混沌无序特征中蕴含的序列产生机制,在相空间中刻画出动态误差的基本特征。②采用“7+1”的滑动窗口法重构输入样本,用于进一步挖掘有限动态误差混沌时序样本的内在规律。③特征注意力层,用于对时间维度上的相点演化信息进行动态赋权。④Bi-LSTM 神经网络层,负责多元动态误差相空间下的时间依赖性特征提取。⑤全连接层,完成动态误差预测。

1.2 多元动态误差混沌表示

机床多轴插补动态误差的产生是数控机床各个部分共同作用的结果,看似是一个极其复杂的运动过程,其实系统内部在一定界限内存在随机性。两个非常接近的初值,在随机演化后,其轨迹也会变得复杂多样。动态误差运动轨迹的内在随机性,其本质是系统敏感地依赖于初始条件。混沌演化在初态演化时通过混沌动力学的遍历性,混沌运动轨迹会经过有界混沌吸引域中吸引子的每一个点,从而揭露隐含在各参数时间序列的系统信息。

1.2.1 多元动态误差的相空间重构

相空间中的每一轨迹点对应着物理系统对应点在某一时刻的状态,即相空间可以表示物理系统所有可能出现的状态^[14]。相空间重构是为了还原及恢复体现混沌动力学系统规律性的混沌吸引子。为避免一维时序信息重构后的相空间可能存在拓扑信息缺失,本文将多个机床两轴插补动态误差特征量(反向跃冲、横向间隙、反向间隙和伺服不匹配)的时间序列进行混沌相空间重构。TAKENS^[15]提出的嵌入定理表明,在一个混沌体系中,任一分量的演化都取决于其他分量的相互作用,因而任一分量的演化过程都蕴含着其他分量的信息。

对于机床插补运动的第 j 个动态误差特征量时间序列 $X_j(t) = (x_j(1), x_j(2), \dots, x_j(N))$, $j = 1, 2, \dots, J$, 其中 J 为动态误差特征数, N 为时间序列长度,运用坐标延迟重构法重构后的相空间状态坐标为

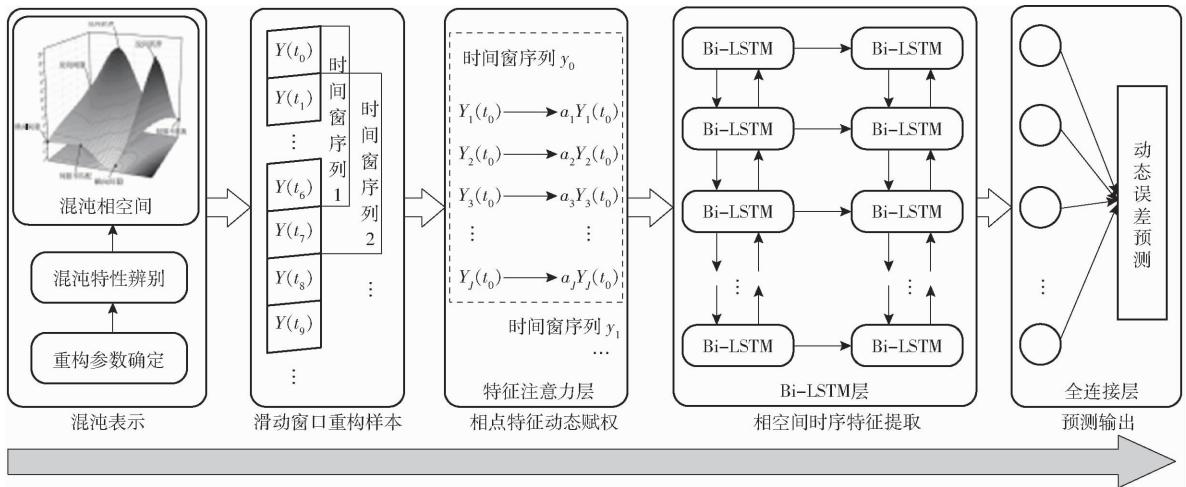


图 1 CRFA-Bi-LSTM 动态误差预测模型结构

Fig. 1 Structure of CRFA-Bi-LSTM dynamic error prediction model

$$Y_j(t_i) = (x_j(t_i), x_j(t_i - \tau_j), \dots, x_j(t_i - (m_j - 1)\tau_j)) \quad (1)$$

其中 $t_i = \max\{(m_j - 1)\tau_j + 1\}, \dots, N - 1, N$

式中 τ_j —第 j 个特征量的延迟时间

m_j —第 j 个特征量的嵌入维数

第 j 个动态误差特征量重构后的矩阵为

$$Y_j = \begin{bmatrix} x_j(t_0) & x_j(t_0 - \tau_j) & \cdots & x_j(t_0 - (m_j - 1)\tau_j) \\ x_j(t_1) & x_j(t_1 - \tau_j) & \cdots & x_j(t_1 - (m_j - 1)\tau_j) \\ \vdots & \vdots & & \vdots \\ x_j(t_i) & x_j(t_i - \tau_j) & \cdots & x_j(t_i - (m_j - 1)\tau_j) \end{bmatrix} \quad (2)$$

多元动态误差特征量时间序列可由单元时间序列的相空间重构扩展而成, 重构后的微分同胚相空间状态坐标为

$$Y(t_i) = (Y_1(t_i), Y_2(t_i), \dots, Y_j(t_i)) \quad (3)$$

1.2.2 相空间重构参数求解

式(2)中延迟时间和嵌入维数的求取性能对混沌系统吸引子的几何结构有着直接影响。C-C 算法的时间窗口长度综合考虑了两者之间的关联性, 并基于关联积分求取参数, 该算法非常适用于小数据量样本。因此, 本文采用 C-C 算法应用于多元动态误差特征量时序重构参数的计算。

将 $X_j(t)$ 分成 t 项不相交的时间子序列, 分别计算每个子项的统计量 $S(m, N, r, t)$ 为

$$S(m, N, r, t) =$$

$$\frac{1}{t} \sum_{l=1}^t (C_l(m, N/t, r, t) - C_l^m(l, N/t, r, t)) \quad (4)$$

式中 r —邻域半径

C_l —第 l 个子项的关联积分

$C(m, N, r, t)$ 定义为

$$C(m, N, r, t) = \frac{2}{M(M-1)} \sum_{1 \leq i < j \leq M} \theta(r - \|X_i - X_j\|_\infty) \quad (5)$$

其中 $M = N - (m - 1)\tau$

式中 M —相空间相点数

$\theta(\cdot)$ —Heaviside 函数

当 $N \rightarrow \infty$, 有

$$S(m, r, t) = \frac{1}{t} \sum_{l=1}^t (C_l(m, r, t) - C_l^m(1, r, t)) \quad (6)$$

m 取 $2, 3, 4, 5$; $r_e = \frac{e\sigma}{2}$; e 取 $1, 2, 3, 4$, 计算

$$\bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{j=1}^4 S(m, r_e, t)$$

$$\Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t)$$

$$S_{cor}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \quad (7)$$

式中 σ —时间序列均方差

$\Delta S(m, t)$ —度量对所有半径 r 的最大偏差

对于最大半径 r_i , 最小半径 r_j , 定义为

$$\Delta S(m, t) = \max\{S(m, r_i, t)\} - \min\{S(m, r_j, t)\} \quad (8)$$

C-C 算法认为最佳延迟时间 τ 为 $\bar{S}(t)$ 的第 1 个零点或 $\Delta \bar{S}(t)$ 的第 1 个极小点; 最佳延迟时间窗口 t_w 为 $S_{cor}(t)$ 的全局最小点, 进而通过 $t_w = (m - 1)\tau$, 即可求出最佳嵌入维数 m 。

1.3 特征注意力机制

多元动态误差经过相空间重构后, 可在高维相空间中表达原系统蕴含的序列产生机制。但根据 TAKENS 嵌入定理, 任一分量的演化过程都蕴含着其他分量的信息, 容易造成信息冗余和噪声干扰等问题^[15-16]。并且机床多轴插补动态误差的产生本身具有高度耦合性, 则需要考虑各时间维度上的动态误差参数时序的重要性差异。通过引入特征注意力机制对关键相点特征赋予不同的权重^[17], 可消除

不合理输入相点特征的贡献率,以此减少动态误差时序特征间的高度耦合性,特征注意力机制如图2所示。

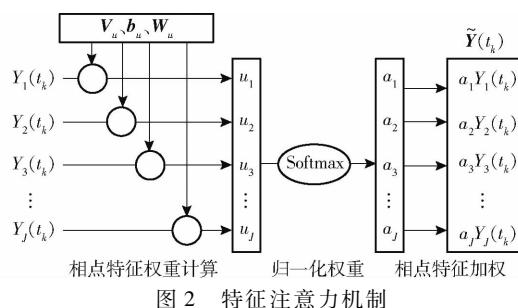


Fig. 2 Feature attention mechanism

为进一步挖掘有限动态误差混沌时序样本的内在规律,采用“7+1”的滑动窗口样本构造方式。以前7d所采数据作为输入数据,以后1d的最后1组数据作为预测输出。如图3所示,对于混沌时变演化后的时间序列 $Y = \{Y(t_0), Y(t_1), \dots, Y(t_i)\}$,其中 $\{Y(t_0), Y(t_1), \dots, Y(t_6)\}$ 构成时间窗序列 y_0 , $Y(t_7)$ 的最后一组数据作为时间窗序列 y_0 相对应的窗口标签。

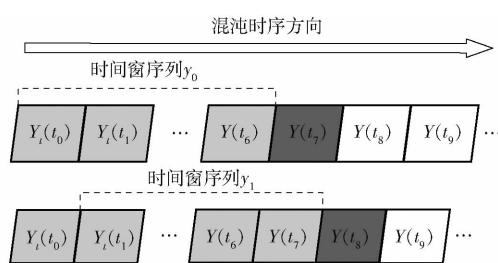


图3 滑动窗口样本构造

Fig. 3 Sliding window sample construction

滑动时间窗口的步长设置为1,经过不断地滑动分割生成训练样本,时间序列 Y 被划分为 $y = \{y_0, y_1, \dots, y_k, \dots, y_n\}$,其中 n 表示被划分的子样本个数, $y_k = \{Y(t_k), Y(t_{k+1}), \dots, Y(t_{k+6})\}$ 为第 k 个输入序列。该方法不仅避免了因样本数量不足造成模型鲁棒性低的问题,还保留了动态误差混沌演化过程中相邻误差间的关联性。

对于输入序列 y_k , t 时刻的输入相点特征为 $Y(t_k) = (Y_1(t_k), Y_2(t_k), \dots, Y_J(t_k))$,计算相点特征对动态误差的贡献率

$$u_j = V_u \tanh(W_u Y_j(t_k) + b_u) \quad (9)$$

式中 V_u, W_u ——权重矩阵

b_u ——偏置项

再通过Softmax函数对贡献率进行加权平均,突出关键相点特征权重

$$a_j = \frac{\exp(u_j)}{\sum_j \exp(u_j)} \quad (10)$$

将加权系数 a_j 与 $Y(t_k)$ 相乘得到加权后的相点特征向量 $\tilde{Y}(t_k)$ 为

$$\tilde{Y}(t_k) = (a_1 Y_1(t_k), a_2 Y_2(t_k), \dots, a_J Y_J(t_k)) \quad (11)$$

1.4 基于Bi-LSTM网络的相空间时序特征提取

传统神经网络难以共享从序列数据不同位置学习到的特征,无法挖掘序列数据前后之间存在的相互关联。LSTM网络利用“门”结构控制记忆细胞的状态,有选择性地增加或删除信息,从而能长时间存储历史信息的同时学习动态误差相空间时序特征信息。但LSTM只能前向训练时序数据,造成后向序列的有用信息被忽略。Bi-LSTM网络在LSTM结构上增添了一个后向层,能抓取前后向相点特征的完整序列信息^[18],其网络结构如图4所示。

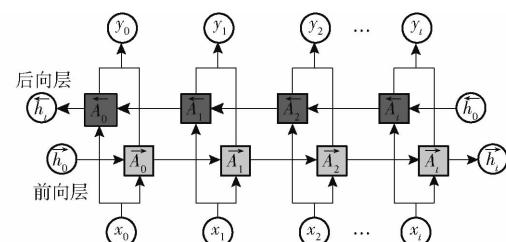


图4 Bi-LSTM网络结构

Bi-LSTM网络 t 时刻隐藏状态 h_t 的数学表达式为

$$h_t = \begin{bmatrix} \overrightarrow{h}_t \\ \overleftarrow{h}_t \end{bmatrix} \quad (12)$$

其中

$$\overrightarrow{h}_t = \overrightarrow{\text{LSTM}}(h_{t-1}, x_t, c_{t-1}) \quad (13)$$

$$\overleftarrow{h}_t = \overleftarrow{\text{LSTM}}(h_{t+1}, x_t, c_{t+1}) \quad (14)$$

式中 $\overrightarrow{\text{LSTM}}, \overleftarrow{\text{LSTM}}$ ——前向、后向LSTM网络

$\overrightarrow{h}_t, \overleftarrow{h}_t$ ——前向、后向隐藏状态

x_t ——输入特征

c_t ——状态记忆单元

1.5 模型训练及优化

采用随时间反向传播(Back propagation through time,BPTT)算法来训练动态误差预测模型。不断对模型网络层数、超参数进行优化调参,最终选取如表1所示的模型架构和超参数。通过在Bi-LSTM层和全连接层后使用Dropout正则化方法,可人为设置丢弃率使部分神经元在训练过程随机地失效。部分神经元不再参与BPTT算法的权重矩阵更新,防止神经元互相适应的同时减少模型的过拟合,增强模型的鲁棒性。

表 1 网络结构参数

Tab. 1 Network structure parameters

网络层	参数	数值
CR 层	混沌相空间总嵌入维数	8
Bi - LSTM_1	神经元数	16
Dropout_1	丢弃率	0.4
Bi - LSTM_2	神经元数	8
Dropout_2	丢弃率	0.3
Dense_1	激活函数 ReLU 神经元数	64
Dropout_3	丢弃率	0.3
Dense_2	激活函数 Tanh 神经元数	1

对于 CRFA - Bi - LSTM 动态误差预测模型, 经过 BPTT 算法求出每个权重参数的梯度后, 再通过 Adam 优化算法对权重矩阵更新, 从而使损失函数的值最小。Adam 算法利用梯度的一阶矩阵和二阶矩阵自适应地调节每个参数的学习率, 在经过偏置校正之后, 每一次迭代的学习率都有一个确定范围, 具有善于处理稀疏梯度和非平稳目标的优点。同时, Adam 算法适用于大多非凸优化和高维空间的求解。

2 实验数据采集

数控机床圆运动实际上是各个运动轴进行插补运动而成, 是机械传动部件和伺服控制系统综合作用的结果, 能全面反映动态误差的演化情况^[12]。基于球杆仪的误差检测法已被 ISO/CD 10791-6 标准所采纳, 因此本文选用雷尼绍球杆仪系统采集数控机床圆运动数据^[19]。实验测试平台为 XK-L540 型数控铣床, 如图 5 所示。

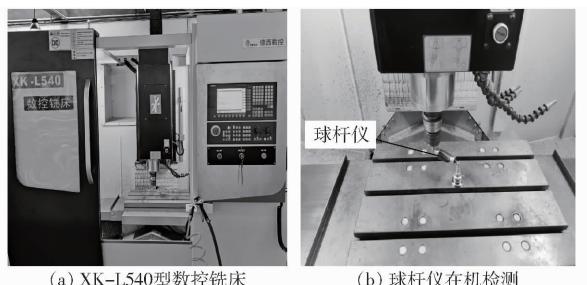


图 5 动态误差实验平台

Fig. 5 Dynamic error experiment platform

数控机床工作台在 XY 平面作进给速度为 1 500 mm/min, 半径为 100 mm 的顺/逆时针 360° 圆周运动, 实验结果如图 6 所示。数据采样间隔约为 1 h, 共采集 1 021 组, 并将同一时刻的两轴插补动态误差特征量和圆度误差串联成向量表示, 经过滑动均值滤波后保存。

3 实测数据算例分析

3.1 多元动态误差混沌表示

混沌动力学系统对初值具有极端敏感性, 两个

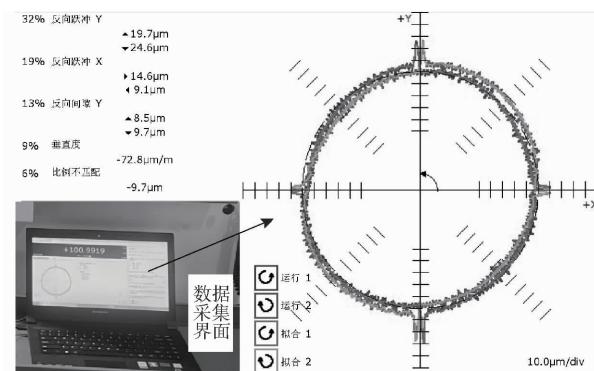


图 6 圆运动检测结果

Fig. 6 Circular motion test results

相邻初始值间更迭形成的轨道, 经过混沌运动之后, 2 条混沌轨迹会呈指数规律分离, 可用 Lyapunov 混沌指数对吸引子轨迹的改变进行定量描述。实际上, 只要最大 Lyapunov 指数大于 0, 则可证明动态误差系统呈混沌状态。本文采用 WOLF 法^[20]来确定机床两轴插补动态误差各参数的最大 Lyapunov 指数

$$\lambda = \frac{1}{t_Q - t_0} \sum_{i=0}^Q \ln \frac{L'_i}{L_i} \quad (15)$$

式中 Q ——演化过程总迭代次数

L_i —— t_i 时刻相点与其最近邻点的距离

L'_i —— t_{i+1} 时刻两相点的距离

通过前文所述 C - C 算法求取多元动态误差特征量的最佳延迟时间和最佳嵌入维数。计算结果如图 7 所示。

通过求取的最大 Lyapunov 指数来识别多元动态误差各参数是否具有混沌特性, 其结果如表 2 所示。从表 2 可知, 机床两轴插补多元动态误差特征量时序数据的最大 Lyapunov 指数各不相同, 但均大于 0, 说明多元动态误差特征量均具备混沌特性。

根据混沌初值存在极端敏感性、运动轨迹存在遍历性等混沌动力学特性, 利用 C - C 算法求得的延迟时间和嵌入维数对 4 个机床两轴插补动态误差特征量时间序列进行混沌演化, 在高维相空间中恢复动态误差的混沌吸引子, 图 8 为同一时刻样本数据的混沌演化示意图。图 8b 为混沌演化后的多元动态误差图像, 相比于混沌演化前的图 8a, 混沌演化可以将参数时间序列演化到更高维的相空间, 增加了多个之前没有出现的动态误差特征量特征。因此, 混沌相空间重构可以很好地挖掘蕴含在动态误差时间序列中的一些微小但重要的信息, 为后续建立的预测模型开辟混沌输入通道。

3.2 模型预测

前文采集的机床两轴插补动态误差时序样本数

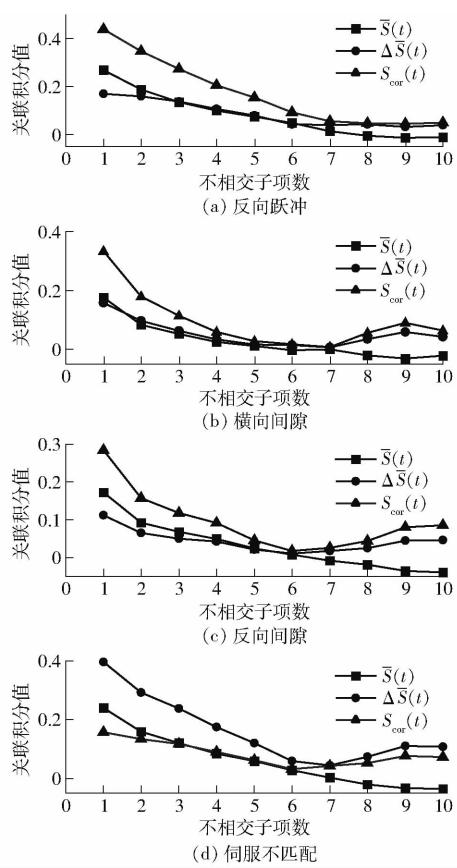


图 7 C-C 算法重构结果

Fig. 7 C-C algorithm reconstruction results

表 2 最佳延迟时间 τ 、嵌入维数 m 和最大 Lyapunov 指数Tab. 2 Optimal delay time τ , embedding dimension m and maximum Lyapunov exponent

误差特征量	延迟时间	嵌入维数	最大 Lyapunov 指数
反向跃冲	7	2	0.2749
横向间隙	7	2	0.4537
反向间隙	6	2	0.3614
伺服不匹配	6	2	0.5781

据有不同的量纲和量纲单位,为避免不同量纲数据存在可比性以及奇异样本使模型收敛速度慢、稳定性低和出现饱和态等问题,需在模型训练前对数据进行归一化处理。

为验证本文所提 CRFA-Bi-LSTM 预测模型的优越性,建立以下预测模型作为对比:①CR-Bi-LSTM:未引入特征注意力机制的单一级联 Bi-LSTM 预测模型。②FA-Bi-LSTM:未引入混沌表示的单一级联 Bi-LSTM 预测模型。③CRFA-LSTM:融合混沌表示和特征注意力机制的单向 LSTM 预测模型。

上述模型均在 Python 3.6 语言环境下,基于 TensorFlow 2.3.0 深度学习框架编写。实验环境配置为 Intel Core i3-7100 CPU, NVIDIA GTX 1050 Ti GPU, 16 GB 内存。模型初始学习率设为 0.001, 选

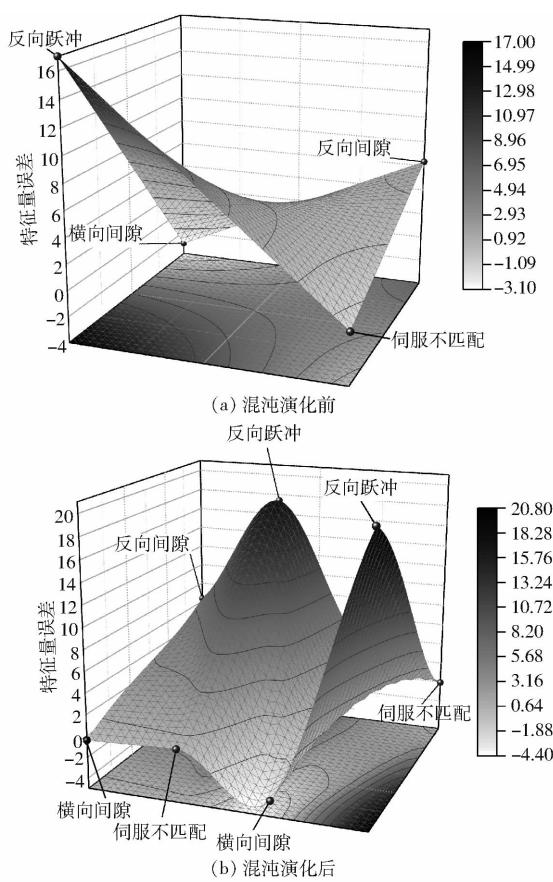


图 8 多元动态误差混沌表示

Fig. 8 Chaotic representation of multivariate dynamic error

用 Adam 和 BPTT 算法优化模型参数,每批为 39 个样本,共迭代 100 次。选取均方误差 (Mean squared error, MSE) 作为损失函数,4 种模型训练结果如图 9 所示。从图 9 可知,随着训练次数的增加,各模型 MSE 总体上呈振荡下降趋势,最后都趋于稳定,并且 CRFA-Bi-LSTM 模型的损失函数值在收敛后最小。

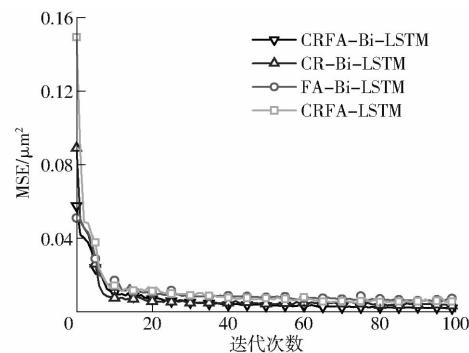


图 9 模型损失函数曲线

Fig. 9 Model loss function curves

4 种模型的动态误差预测结果如图 10 所示。从图 10 可以看出,4 种算法模型都对机床两轴插补动态误差达到较为准确的预测效果,但与其余 3 种模型相比,CRFA-Bi-LSTM 模型不仅能成功预测出动态误差时间序列的变化趋势,且与实测值曲线

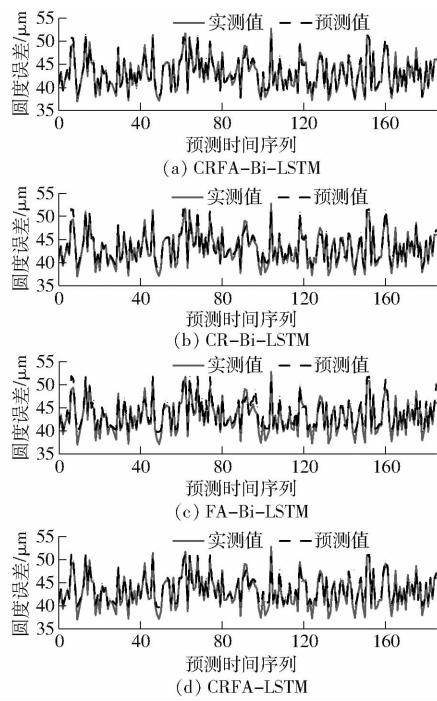


图 10 4 种模型预测结果对比

Fig. 10 Comparison of prediction results of four models

贴合更加紧密。

为对模型预测性能进行量化评价,选取均方根误差(Root mean square error, RMSE)、平均绝对误差(Mean absolute error, MAE)和决定系数 R^2 作为机床两轴插补动态误差预测模型的评价指标。当 MAE、RMSE 越小, R^2 越大时, 模型性能越好。

表 3 为 4 种模型的预测指标。从表 3 可知, CRFA - Bi - LSTM 模型的各项指标均优于其他模型, 其中 RMSE 降低 16% ~ 43%, MAE 降低 17% ~ 44%, R^2 增加 2% ~ 7%, 有效证明了该模型对机床两轴插补动态误差具有更为优秀的回归预测能力。

在未考虑多元动态误差混沌特征的情况下, FA - Bi - LSTM 模型预测精度相对较低。而 CR - Bi - LSTM 模型和 CRFA - LSTM 模型虽考虑了混沌特征, 但未考虑各时间维度上相点特征的重要性差异或仅依赖单向时变演化信息, 难以获得较高的动态误差预测精度。综上所述, 本文所提 CR - Bi - LSTM 模型

表 3 4 种模型性能评价结果

Tab. 3 Performance evaluation results of four models

模型	RMSE/ μm	MAE/ μm	R^2
CRFA - Bi - LSTM	0.755 5	0.583 3	0.956 5
CR - Bi - LSTM	0.903 4	0.703 6	0.937 7
FA - Bi - LSTM	1.329 4	1.032 7	0.865 2
CRFA - LSTM	1.170 2	0.893 4	0.895 5

在机床多轴插补动态误差预测性能上更佳。

为验证特征注意力机制在时间维度上的相点特征权重自适应分配, 提取测试集中特征注意力层的 16 个时间点的特征权重, 如图 11 所示。由图 11 可知, 特征注意力机制可以很好地抓住演化时序特征的重要性差异, 弱化不合理输入特征的权重。

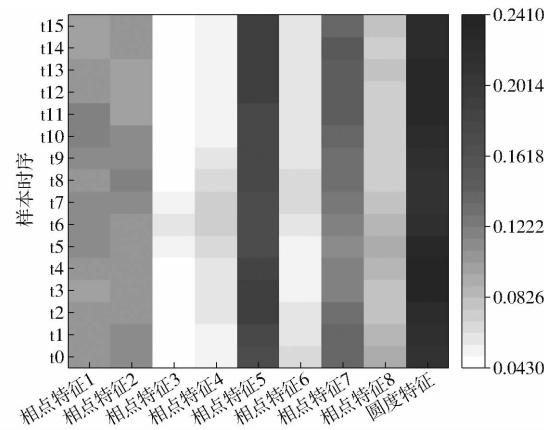


图 11 输入相点特征动态赋权

Fig. 11 Dynamic weighting of input phase point features

4 结束语

融合混沌表示和特征注意力机制, 提出了一种级联机床两轴插补动态误差预测模型。该模型以相点特征表示隐含在各参数时间序列的系统信息, 通过引入特征注意力机制动态赋予相点特征权重, 在消除重构信息冗余的同时, 减少了动态误差本身具有的高度耦合性。与其他模型的对比实验, 结果表明, 本文所提 CRFA - Bi - LSTM 模型, 其 RMSE 降低 16% ~ 43%, MAE 降低 17% ~ 44%, 证明了本文所提动态误差预测方法的有效性和优越性。

参 考 文 献

- [1] 许桢英, 费业泰, 陈晓怀. 动态精度理论研究与发展[J]. 仪器仪表学报, 2001, 22(增刊 2): 70 ~ 71, 74.
XU Zhenying, FEI Yetai, CHEN Xiaohuai. Study and development of the theory of the accuracy of dynamic measurement[J]. Chinese Journal of Scientific Instrument, 2001, 22(Supp. 2): 70 ~ 71, 74. (in Chinese)
- [2] 李杰, 谢福贵, 刘辛军, 等. 五轴数控机床空间定位精度改善方法研究现状[J]. 机械工程学报, 2017, 53(7): 113 ~ 128.
LI Jie, XIE Fugui, LIU Xinjun, et al. Analysis on the research status of volumetric positioning accuracy improvement methods for five-axis NC machine tools[J]. Journal of Mechanical Engineering, 2017, 53(7): 113 ~ 128. (in Chinese)
- [3] 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.
LÜ Dun, ZHANG Jiahui, WANG Dawei, et al. Technical status and countermeasures of dynamic accuracy of domestic CNC

- machine tools [J]. Aeronautical Manufacturing Technology, 2022, 65(6): 22–33. (in Chinese)
- [4] 曾翠兰. 基于多元相空间重构的数控机床运动精度预测 [D]. 重庆:重庆理工大学, 2017.
- ZENG Cuilan. Prediction of NC machine tool's motion precision based on phase reconstruction of multivariate time series [D]. Chongqing: Chongqing University of Technology, 2017. (in Chinese)
- [5] WANG L, LIU H, YANG L, et al. The effect of axis coupling on machine tool dynamics determined by tool deviation [J]. International Journal of Machine Tools and Manufacture, 2015, 88: 71–81.
- [6] YANG L, ZHANG X, WANG L, et al. Dynamic error of multiaxis machine tools considering position dependent structural dynamics and axis coupling inertial forces [J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2022, 236(3): 281–295.
- [7] CHEN G, LIANG Y, EHMANN K F, et al. Fourier transform based dynamic error modeling method for ultra-precision machine tool [C] // 7th International Symposium on Advanced Optical Manufacturing and Testing Technologies: Advanced Optical Manufacturing Technologies. SPIE, 2014: 928102.
- [8] 刘家汐. 基于层次聚类分析的五轴联动数控机床动态误差溯源方法研究 [D]. 成都:电子科技大学, 2019.
- LIU Jiaxi. Research on dynamic error traceability of five-axis CNC machine tool based on hierarchical clustering analysis [D]. Chengdu: University of Electronic Science and Technology of China, 2019. (in Chinese)
- [9] HE W, WANG L, GUAN L. A novel method for evaluating the validity of dynamic accuracy test pieces for five-axis machine tools [J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2020, 234(11): 2189–2210.
- [10] 李松, 梅盛开, 袁伟, 等. 基于AFSA-ACO-BPN算法的五轴机床动态误差模型 [J]. 机床与液压, 2020, 48(4): 141–145.
- LI Song, MEI Shengkai, YUAN Wei, et al. Dynamic error model of five-axis machine tool based on AFSA-ACO-BPN algorithm [J]. Machine Tool & Hydraulics, 2020, 48(4): 141–145. (in Chinese)
- [11] 殷国为, 李翔龙, 陈兵. 总线式数控机床动态误差测量及辨识 [J]. 电子科技大学学报, 2023, 52(2): 313–320.
- YIN Guowei, LI Xianglong, CHEN Bing. Measurement and identification of dynamic errors for bus CNC machine tools [J]. Journal of University of Electronic Science and Technology of China, 2023, 52(2): 313–320. (in Chinese)
- [12] 杜柳青, 余永维. 深度学习框架下融合注意机制的机床运动精度劣化预示 [J]. 农业机械学报, 2022, 53(9): 443–450.
- DU Liuqing, YU Yongwei. Deterioration prediction of machine tools' motion accuracy combining attention mechanism under framework of deep learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 443–450. (in Chinese)
- [13] 郭旭超, 唐詹, 刁磊, 等. 基于部首嵌入和注意力机制的病虫害命名实体识别 [J]. 农业机械学报, 2020, 51(增刊2): 335–343.
- GUO Xuchao, TANG Zhan, DIAO Lei, et al. Recognition of Chinese agricultural diseases and pests named entity with joint radical-embedding and self-attention mechanism [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51 (Supp. 2): 335–343. (in Chinese)
- [14] 高俊杰. 混沌时间序列预测研究及应用 [D]. 上海:上海交通大学, 2013.
- GAO Junjie. Study and application of chaotic time series prediction [D]. Shanghai: Shanghai Jiao Tong University, 2013. (in Chinese)
- [15] TAKENS F. Detecting strange attractors in turbulence [C] // Dynamical Systems and Turbulence, Warwick 1980: Proceedings of a Symposium Held at the University of Warwick 1979/80. Berlin, 2006: 366–381.
- [16] 王岩韬, 李景良, 谷润平. 基于多变量混沌时间序列的航班运行风险预测模型 [J]. 工程科学学报, 2020, 42(12): 1664–1673.
- WANG Yantao, LI Jingliang, GU Runping. Flight operation risk prediction model based on the multivariate chaotic time series [J]. Chinese Journal of Engineering, 2020, 42(12): 1664–1673. (in Chinese)
- [17] DAI Y, ZHOU Q, LENG M, et al. Improving the Bi-LSTM model with XGBoost and attention mechanism: a combined approach for short-term power load prediction [J]. Applied Soft Computing, 2022, 130: 109632.
- [18] SUN W, LI W, ZHANG D, et al. Lost circulation monitoring using bi-directional LSTM and data augmentation [J]. Geoenergy Science and Engineering, 2023, 225: 211660.
- [19] ISO/CD 10791-6:2014. Test conditions for machining centers-part 6: accuracy of feeds, speeds and interpolations [S]. Geneva: International Organization for Standardization, 2014.
- [20] WOLF A, SWIFT J B, SWINNEY H L, et al. Determining Lyapunov exponents from a time series [J]. Physica D: Nonlinear Phenomena, 1985, 16(3): 285–317.