

深度学习框架下融合注意机制的机床运动精度劣化预示

杜柳青 余永维

(重庆理工大学机械工程学院, 重庆 400054)

摘要: 数控机床运动精度衰退是一个动态的演化过程。为尽早发现数控机床潜在的失效风险,挖掘蕴含在各类监测数据序列中的运动精度演化特征,在深度门控循环网络(Gated recurrent unit,GRU)框架下,提出了一种融合注意机制的数控机床运动精度劣化预示方法。为了克服传统深度卷积神经网络不能学习时序特征的缺陷,采用深度编码器-解码器框架,提出基于深度GRU的运动精度深度学习建模方法,以数据驱动,自动挖掘运动精度与振动、温度、电流等状态信号时间序列的时空特征,预测运动精度,根据预测曲线对机床劣化趋势进行预示。为了增强主要状态信号和关键时间点的信息表达,提高精度劣化预测的准确性,提出一种在深度学习框架中融合注意机制的方法,建立状态参量的注意网络,计算振动、温度等状态信号与机床精度间关联程度,自动调整各信号的权值;进一步,建立时序注意网络自主选取精度劣化历史信息关键时间点,以提升较长时间段预示的准确性。实验结果表明,基于深度学习网络与注意机制的预示模型可以很好地追踪数控机床运动精度的劣化趋势和规律,有较高的预测精度,优于传统方法。

关键词: 数控机床; 劣化预示; 深度学习; 注意机制

中图分类号: TH115 文献标识码: A 文章编号: 1000-1298(2022)09-0443-08 OSID: 

Deterioration Prediction of Machine Tools' Motion Accuracy Combining Attention Mechanism under Framework of Deep Learning

DU Liuqing YU Yongwei

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

Abstract: The decline of motion accuracy of CNC machine tools is a dynamic evolution process. To detect the potential failure risk of CNC machine tools as early as possible, the motion accuracy's deterioration information contained in various monitoring data sequences was mined. Based on the difference and complementarity of multi-source monitoring big data, a prediction method for motion accuracy's deterioration of CNC machine tools was proposed by combining the deep gated recurrent unit (GRU) and attention mechanism. In order to overcome the defect that the traditional deep convolution neural network cannot learn the time series feature, the deep learning modeling method of motion accuracy based on deep GRU was proposed by using deep encoder-decoder structure. By data-driven, the temporal and spatial characteristics of motion accuracy and state signal time series were automatically mined to predict the change curve of motion accuracy and the deterioration trend of accuracy. At the same time, in order to enhance the information expression of main state signals and key time points, and improve the accuracy of accuracy deterioration prediction, a method of integrating attention mechanism in deep learning network was proposed. The method can establish the attention network of state parameter, calculate the correlation degree between vibration, temperature and other status signals and machine tools' accuracy, and automatically adjust the weight of each signal. Furthermore, through establishing time-series attention network to select the key time points of historical information of accuracy deterioration, the accuracy of long-term prediction was improved. The experimental results showed that the prediction model based on deep learning network and attention mechanism can well track the deterioration trend and law of CNC machine tools' motion accuracy, and it had high prediction accuracy than traditional methods.

Key words: CNC machine tools; deterioration prediction; deep learning; attention mechanism

收稿日期: 2021-09-05 修回日期: 2021-10-29

基金项目: 国家自然科学基金面上项目(51775074)、重庆市自然科学基金项目(cstc2021jcyj-msxmX0372)和重庆市教委科学研究重大项目(KJZD-M201801101)

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@cqut.edu.cn

0 引言

数控机床在服役期间,内部各组成要素之间及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。影响精度变化的各因素具有非线性和高度耦合的特性。因此,数控机床精度衰退具有高度的非线性和不可逆性,是一个复杂非线性系统的时空演化过程。尽早对数控机床运动精度劣化进行预示对提高机床精度保持性、可靠性具有重要意义^[1]。

数控机床是集光、机、电、液于一体的复杂精密机械装备,难以建立准确的失效物理模型,目前对精度及性能演化方面的研究以基于数据驱动的智能方法为主^[2-6]。国内外学者进行了相关研究。JASON 等^[7]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。LIAO 等^[8]提出了一种基于受限玻尔兹曼机的旋转机械故障预测方法,采用正则化方法提高了输出特征的泛化性。ZHAO 等^[9]提出了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。雷亚国等^[10-11]提出基于深度自动编码器的机械装备大数据健康监测方法,并用迁移学习方法解决了训练样本不足问题,在多级齿轮传动系统的健康状态识别中效果较好。李海等^[12]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。从现有研究成果看,目前对数控机床精度演化研究的文献相对比较少,但相关研究方法对本文也具有较好的借鉴意义^[13-15]。

深度学习具有强大的特征自学习能力,在大数据处理方面显示了优越的性能,已为模式识别、图像处理、语音识别等领域提供了解决方法^[16-19]。循环神经网络(Recurrent neural

networks, RNN)是深度学习的代表算法之一,其解决了传统深度卷积神经网络不能学习时序特征的缺陷,使预测准确性大幅提升^[20-22]。门控循环单元是一种 RNN,基于长短时记忆网络(Long short-term memory, LSTM)优化而来,在挖掘时序数据的时空特征方面有独特优势,即训练参数少、收敛速度快^[23-25]。数控机床运动精度状态数据序列组合具有大数据的一些基本特点:大容量、多样性、高速率。因此,为尽早发现数控机床潜在的失效风险,预示运动精度的劣化演化,本文基于深度门控循环网络框架,提出一种融合注意机制的数控机床运动精度劣化预示方法。利用时序深度学习强大的时空特征提取能力,建立基于深度 GRU 网络的精度劣化预示模型,挖掘蕴含在振动、温度、电流等监测数据序列中的运动精度演化信息。为了提高模型预测的准确性,建立状态信号注意网络,自动分析振动、温度等状态参量对机床运动精度劣化的影响程度。为了提升较长时间段预测的准确性,建立时序注意网络自主选取精度劣化历史信息关键时间点,加强关键时间点的信息表达。

1 深度 GRU 网络

GRU 神经元之间存在反馈连接,即具有“时间参数”,能够动态记忆历史信息,在学习新信息的同时使历史信息留存持久化。GRU 单元结构如图 1 所示,每个 GRU 含有一个由更新门和重置门组成的记忆单元。更新门负责控制前一时间点的状态信息传递到当前时间点状态值的权重,重置门决定新的输入信息与记忆信息如何结合。GRU 通过以上门控单元来保存长期序列中的信息,且不会随时间而清除或因为与预测无关而移除,使得网络模型能够较长时间选择性保存并传递信息。

在当前时间点 t , GRU 单元的输入有:时间点 t 的输入信息 x_t 、时间点 $t-1$ GRU 单元的输出即历史信息 h_{t-1} ; GRU 单元的输出信号为 h_t ;更新门和重置门的输出分别为 z_t 、 r_t 。GRU 信息传递式为




图 1 GRU 单元结构

Fig. 1 Unit structure of GRU

$$h_t = (1 - z_t) \tanh(r_t \circ U h_{t-1} + W x_t) + z_t \circ h_{t-1} \quad (1)$$

式中 W, U ——权值矩阵 $\tanh$ ——激活函数
 $\circ$ ——按元素相乘运算符

将 GRU 的反馈结构在时间维度上展开,在每一时间点,GRU 在时序方向上展开为一个深度学习网络中的一层,随着时间点的不断更新,即形成时间维度上的深度 GRU 网络(图 1),自动提取动态时间序列的时空特征。

2 精度劣化预示模型

2.1 模型结构

数控机床运动精度衰退是一个动态的时间序列演化过程。当前状态与历史状态相互关联,同时与机床振动、运动件温度、驱动电流等大数据信息相关联。因此模型输入设计为数控机床运动精度时间序列 $y = (y_1, y_2, \dots, y_T)$ 和机床状态信号(振动、温度、驱动电流等)时间序列 $x^n = (x_1^n, x_2^n, \dots, x_T^n)$,其中 T 表示当前时间点,上标 n 表示机床状态信号的类型。利用运动精度当前信息与历史信息,结合数控机床其他状态信号的当前信息及历史信息,输出下一个时间点的运动精度 $\hat{y}_{T+1}$,连续预测即可获得未来时间的预测精度,劣化趋势的预示映射公式为

$$\hat{y}_{T+1} = f(y_1, y_2, \dots, y_T, x_1, x_2, \dots, x_T) \quad (2)$$

式中 f ——模型映射

运动精度劣化预示曲线如图 2 所示,当精度预测值超过阈值或预测精度变化速率超过阈值时,均预示机床处于运动精度快速劣化阶段,存在突发失效风险,需预先采取措施。




图 2 运动精度劣化预示曲线

Fig. 2 Prediction curve of motion accuracy's deterioration

提出的运动精度劣化预示模型采用基于 GRU 的编码器-解码器架构(图 3),包括深度 GRU 编码网络和深度 GRU 解码网络。同时,为了增强主要状态信号和关键时间点的信息表达,设计了状态信号注意网络和时序注意网络,进一步提升模型预测的准确性。劣化预示模型以数据驱动,自动挖掘运动精度与状态信号时间序列的时空特征,对运动精度劣化趋势进行预测。深度 GRU 编码网络对输入序

列进行编码,从输入原始状态序列中学习中间映射 $E = \text{Encode}(x^1, x^2, \dots, x^n)$ 。深度 GRU 解码网络根据中间映射 E 和之前已经生成的历史信息,生成每一个输出 $y_{T+1} = \text{Decoder}(E, y_1, y_2, \dots, y_T)$ 。状态信号注意网络自动挖掘状态信号与运动精度之间的关联程度,时序注意网络自动挖掘历史信息时间点的重要程度,以相应权值增强主要状态信号与关键时间点的信息表达。




图 3 精度劣化预示模型

Fig. 3 Prediction model of accuracy deterioration

2.2 深度学习框架设计

为提高模型的非线性拟合能力,采用多层 GRU 网络设计编码器/解码器。深度 GRU 编码网络除第一隐层外的其余隐层神经元数量与输入变量数量相同,均为 16(即 X, Y, Z 轴及主轴的振动幅度、温度、驱动电流、功率)。为学习更多可以馈入后续层的低阶特征,增加第一隐层神经元数量至 32。深度 GRU 解码网络的各隐层神经元数量与时间步长 L 相同。

网络的隐含层数量对深度学习网络性能至关重要,层数过少,则模型拟合能力弱;层数过多,可能会出现过拟合,并且会增加训练难度,使模型难以收敛。同时,过短的时间步长会引起预测经验知识的缺失,影响模型预测准确性;过长的时间步长又会分散对相关度高的时间点的关注。为此,采用多层网络搜索方法优化 GRU 编码网络隐层数量、解码网络隐层数量和时间步长 3 个网络参数。遍历这 3 个网络参数构成的三维搜索空间,当深度 GRU 编码/解码网络的隐层数、时间步长分别为 6/5 层和 50 时,模型的平均正确率达到最高,为 96.5%,可确定此时模型隐层数为最优网络深度。深度 GRU 编码/解码网络结构如图 4 所示。

GRU 编码网络输出为

$$h_t = f_{GRU}(h_{t-1}, x_t) \quad (3)$$

GRU 解码网络输出为




图 4 深度 GRU 编码/解码网络结构图
Fig. 4 Deep GRU coding/decoding network

$$d_t = f_{GRU}(d_{t-1}, h_t) \tag{4}$$

将 GRU 循环网络按照时间步长 L 展开为深度前馈神经网络,以反向传播算法分别对 GRU 编码/解码网络进行训练。对于深度 GRU 解码网络,基于注意机制的深度 GRU 解码网络的参数集合为 θ ,损失函数设为

$$J(\hat{y}_{T+1}, y_{T+1}, \theta) = \frac{1}{N} \sum_{i=1}^N (\hat{y}_{T+1}^i, y_{T+1}^i)^2 \tag{5}$$

以最小化损失函数为训练目标,对深度 GRU 解码网络的各参数进行更新和调整,可得到具有最优参数的解码。同理,可实现深度 GRU 编码网络的训练和优化。

2.3 注意网络设计

2.3.1 状态信号注意网络

与数控机床运动精度的关联因素较多,如机床振动、运动部件温度、传动件摩擦力、驱动电流、噪声等机床状态信号。不同的状态信号与运动精度关联程度不一样。设计一种状态信号注意网络,可以自动挖掘运动精度与状态信号间的关联关系,根据关联程度对输入信息的不同参量序列赋予不同的权重,以提高机床精度劣化预测的效率和准确性。状态信号注意网络如图 5 所示。

状态信号注意网络由 3 层 BP 神经网络、softmax 归一化函数与加权求和函数组成。状态信号注意网络的输入除了数控机床的状态信号 x_t 外,还包含深度 GRU 编码网络上一时间点的隐层输出 h_{t-1} ,其蕴含历史信息。利用 BP 神经网络




图 5 状态信号注意网络
Fig. 5 State signal attention network

挖掘数控机床状态信号与精度的相关性,其输出为相关性系数,即

$$r_t^n = \text{BP}(x^1, x^2, \dots, x^n, h_{t-1}) \tag{6}$$

状态信号注意网络采用 softmax 函数实现注意评分操作,将 BP 神经网络输出的相关性系数转换为权值即状态信号权重矩阵 a ,得到在时间点 t 各状态信号对机床运动精度的重要程度,即

$$a_t^n = \frac{\text{expr}_t^n}{\sum_k \text{expr}_t^k} \tag{7}$$

然后对输入的状态信号对应加权,对不同状态信号采取不同的权重,作为深度 GRU 编码网络当前时间点输入的一部分,即

$$\hat{x}_t = (x_t^1 a_t^1, x_t^2 a_t^2, \dots, x_t^n a_t^n, h_{t-1})^T \tag{8}$$

2.3.2 时序注意网络

机床振动、运动部件温度、传动件摩擦力、驱动电流、噪声等状态信号在不同时间点与运动精度的关联程度不同。因此,设计时序注意网络对输入序列的不同时间点赋予不同的权重,能够在 GRU 深度解码网络中进一步增强状态信号在关键时间点的信息表达,提高预示模型较长时间的准确性及稳定性。时序注意网络如图 6 所示。

与状态信号注意网络相似,时序注意网络也由 3 层 BP 神经网络、softmax 归一化函数与加权求和函数组成。时序注意网络输入包括深度 GRU 编码网络不同时间点的输出序列 h ,以及深度 GRU 解码网络上一时间点的隐层输出 d_{t-1} 。 d_{t-1} 蕴含有时序历史信息。BP 神经网络以 h 与 d_{t-1} 作为输入进行注意评价运算。利用 softmax 将 BP 神经网络的评价结果转换为概率,获得不同时间点权重矩阵 g ,即状态信号在不同时间点机床待预测运动精度的影响程度。最后,对深度 GRU 编码网络不同时间点输出对应加权,实现对状态信号在不同时间点采取不同




图 6 时序注意网络

Fig.6 Sequential attention network

的权重,作为深度 GRU 解码网络当前时间点的部分输入。

3 实验

3.1 精度劣化预示实验方法

圆运动是通过多轴插补指令合成,圆运动精度同时反映了各联动轴精度,其不仅包含与数控机床的几何精度、位置误差、定位精度等有关信息,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。圆度误差能够较全面反映数控机床的运动精度劣化情况。

数控机床(包括 5 轴数控机床)的直线轴 X 、 Y 、 Z 轴和旋转(摆动)轴 A 、 B 、 C 之间联动形成的圆度误差均能通过球杆仪检测。以 5 轴数控机床工作台 C 轴旋转联动为例, C 轴作 $0^\circ \sim 360^\circ$ 匀速回转,主轴端球杆仪圆球球心在 XY 平面做同步圆运动,球杆仪做 C 轴轴线检测(图 7),可检测出 C 、 X 、 Y 3 个坐标轴的联动运动精度,如图 8 所示。




图 7 五轴加工中心 C 轴联动旋转沿轴线方向检测

Fig.7 Five axis machining center C -axis linkage rotation along axis direction detection

数控机床圆度误差的时间序列为 $y = (y_1, y_2, \dots, y_T)$, T 为当前时刻。圆度误差与 X 、 Y 、 Z 轴及主轴的驱动电流、功率、振动幅度、温度等状态信号相关联,数控机床状态信号矩阵为




图 8 C 轴联动旋转沿轴线方向检测结果

Fig.8 Detection results of C -axis linkage rotation along axis direction

$$\mathbf{x} = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^N \\ x_2^1 & x_2^2 & \cdots & x_2^N \\ \vdots & \vdots & \ddots & \vdots \\ x_T^1 & x_T^2 & \cdots & x_T^N \end{bmatrix} \quad (9)$$

其中, $1, 2, \dots, N$ 表示不同的机床状态信号类型,实验采集 X 、 Y 、 Z 轴和主轴的驱动电流、功率、振动幅度、温度共 16 类状态信号。在时刻点 t 数控机床状态信号表示为 $x_t = (x_t^1, x_t^2, \dots, x_t^N)$ 。圆度误差劣化预示实验步骤为:

- (1)采集圆度误差的历史信息 y 及状态信号的历史信息 x ,标准化后作为模型样本数据。
- (2)建立基于深度学习网络与注意机制的数控机床精度劣化预示模型,确定网络结构。
- (3)采用机床加速劣化实验数据进行 GRU 深度网络和注意网络的第一阶段训练,粗调网络参数。
- (4)用机床实际精度劣化样本数据进行第 2 阶段训练,优化网络参数,建立模型输入/输出映射 f_{GRU} 。
- (5)实时检测圆度误差当前信息 y_T 及当前状态信号信息 x_T 作为模型输入。

- (6)预测未来时间点圆度误差数值,预测值为

$$\hat{y}_{T+1} = f(y_1, y_2, \dots, y_T, x_1, x_2, \dots, x_T)$$

- (7)连续预测获得精度变化曲线,对机床精度劣化趋势进行预示。

模型预示流程如图 9 所示。

3.2 数据采集

数控机床在服役过程中的精度劣化是一个缓慢过程,为解决深度学习网络训练所需大量数据的问题,提出两阶段网络训练的策略:第 1 阶段,用机床加速劣化实验获得的样本数据训练 GRU 深度网络,初步学习网络参数;第 2 阶段,用机床实际精度劣化样本数据进行训练,进一步优化网络参数。

深度学习网络结构复杂,训练需要较大的样本数量。图 10 为深度 GRU 预示模型误差与样本数量关系曲线,在样本数量大于 3 500 后,测试误差与训练误差均收敛且相差很小,测试模型泛化性能好。因此,采集 3 500 个机床加速劣化实验样本,450 个




图 9 深度学习模型预示流程图

Fig. 9 Prediction process of deep learning model




图 10 模型误差与样本量关系曲线

Fig. 10 Relationship between model error and sample size

机床精度实际劣化样本,共 3 950 个样本来训练及测试本文深度 GRU 预示模型。

以 XHA2120 * 60 型龙门加工中心为对象,检测时机床作半径为 200 mm、进给速度为 1 000 mm/min 的 X - Z 两轴插补圆运动,利用 Renishaw QC20 型球杆仪在线测量机床的圆度误差。同时,通过内置及外置传感器采集 X、Y、Z 轴和主轴的振动幅度、温度、驱动电流、功率等 16 个状态信号序列。以该机床服役期间定期监测获得的 560 个圆运动误差为实际样本,其中前 450 个作为第 2 阶段训练样本,后 110 个作为测试样本,通过预测曲线分析数控机床运动精度劣化变动规律。

将各时间点的圆度误差标准化后得到该龙门加工中心圆度误差时间序列 $y = (y_1, y_2, \dots, y_{3950})$,状态信号样本集为 $x = (x^1, x^2, \dots, x^k, \dots, x^{16})$, $x^k = (x_1^k, x_2^k, \dots, x_{3950}^k)$,则在时间点 t ,模型输入为 $x_t = (x_t^1, x_t^2, \dots, x_t^{10})$ 。

3.3 结果分析

在基于深度学习和注意机制的运动精度劣化预示模型中,使用多层网格搜索方法优化后的时间步长确定为 50,采用前 50 个时间点的状态信号历史数据预测后续时间点的圆度误差;采用多层网格搜索并交叉验证,依据各隐层数对应模型的平均正确率,确定深度 GRU 编码网络和解码网络隐藏层数分

别为 6 和 5。对预示模型中权重矩阵按均值为 0、方差为 1 的高斯分布随机初始化,偏置项均初始化为 0,设置学习率为 0.001。训练迭代次数为 970 时,训练集拟合精度达到最高,获得具有最优参数的运动精度劣化预示模型。

训练完成后,用运动精度劣化预示模型对 450 个时间点之后的运动精度实际劣化情况进行预测,预测相对误差定义为

$$E_r = (\hat{y}_t - y_t) / \hat{y}_t \times 100\%$$

采用单步预测,即依次迭代预测后一个时间点的输出,以此类推,该龙门加工中心圆度误差劣化预测值与实际值变化趋势基本一致,实际样本的后 110 个点的预测最大绝对误差为 0.13 μm,相对误差最大为 4.52%,表明预测结果能够较好反映该运动精度劣化量的趋势和规律,预测精度较高,表明了本文方法的有效性和准确性,预测趋势如图 11 所示。




图 11 本文方法结果

Fig. 11 Result of proposed method

在样本采集及二阶段训练策略有效性对比实验中,只用机床加速劣化样本训练本文深度预示模型,在实际测试样本集上的最大相对误差为 15.06%;只用 450 个实际机床精度劣化样本训练本文深度预示模型,因训练样本不足,预测误差偏大,实际测试的最大相对误差为 8.11%;采用本文两阶段训练策略训练本文深度预示模型,实际测试时的最大相对误差为 4.52%,说明了本文样本采集及二阶段训练策略的有效性,机床加速劣化样本的训练误差能够通过第 2 阶段实际样本的训练来消除。此外,文献[6]证明了采用深度迁移训练方法在大数据下机械装备故障诊断中的有效性和深度学习方法具有很好的适应性和泛化性,也间接说明了本文训练方法的有效性。

为验证本文提出注意机制的效果,进一步分析注意机制的实验数据,发现在时间点 $t = 356$,Z 轴伺服增益不匹配加大,此时状态信号的相关性权值之和为 1,相关状态信号的权值在 0 ~ 1 之间,以此量化关联关系。相关状态信号的权值越大表明其与运动精度的关联程度越强。分析状态信号注意网络提

取的圆度误差与机床其他状态信号的相关性权值,其中Z轴的振动权值最大,为0.49,其对X/Z轴联动运动精度影响最大。Y轴温度权值为0.06,其对X/Z轴联动运动精度的影响最小,这与理论分析及实际情况相符,说明状态信号注意机制的有效性。分析时序注意网络提取的圆度误差与前50时间点的时序信息相关性权值,可知其在时间点 $t=431$ 的权值为0.35,此时间点的状态信息与运动精度关联程度最大,这与时间点 $t=431$ 反向间隙劣化较大对运动精度影响较大相符。

将本文方法与不含注意机制深度GRU预示模型比较,对于预测的110个时间点,与本文相同结构的传统GRU预示模型预测最大绝对误差为 $0.38\text{ }\mu\text{m}$,相对误差最大为9.72%,本文方法明显高于传统GRU预示模型,传统预测趋势如图12所示。为比较本文方法和传统GRU方法的报警预示性能,分别以处于报警预示区的测试集后35个时间点圆度误差为阈值,定义报警预示正确率 $W=T'/A$ 为评价指标,其中A为测试集样本数,即为35, T' 为被模型正确预测的数据量,设定相对误差在 $\pm 4\%$ 以内的预测为正确预测,反之为错误预测。本文方法误报




图12 传统GRU预示模型结果

Fig. 12 Prediction model results of traditional GRU

1个、漏报1个、报警预示正确率为94%,传统GRU方法误报5个、漏报3个、报警预示正确率为77%。可见,在报警预示性能方面传统GRU方法显著低于本文方法。

与非平稳ARIMA时间序列预测法和BP神经网络预测法作对比实验,ARIMA方法的最大相对误差为13.62%,BP神经网络预测方法为17.09%。可见,本文方法预测精度明显优于传统方法,证明了本文方法的有效性。

为进一步验证本文方法的适应性,以XHA2120*60型龙门加工中心预测模型相同网络结构参数:深度GRU编码/解码网络的隐层数、时间步长分别为6/5和50时,对加工中心、数控车床、数控磨床、数控铣床等4种数控机床作同样的训练及预测实验,预测精度均较高,其预测最大相对误差为5.67%、6.07%、5.15%、5.89%,表明本文方法有较好的泛化性能和适应性。

4 结束语

利用时序深度学习网络强大的时空特征自动提取能力,提出了一种基于深度GRU网络框架的数控机床运动精度建模与预测方法,并融合状态信号与时序注意机制,自动分析振动、温度等状态信号与机床精度间的关联关系,同时自主选取精度劣化历史信息关键时间点,提升了精度劣化预测的准确性。实验证明可以很好地追踪数控机床精度变化趋势,对劣化趋势进行预示,有较高的准确性和鲁棒性,优于单纯的GRU深度网络,也优于传统的ARIMA时序方法和BP网络预测方法。

参 考 文 献

[1] 马军旭,赵万华,张根保. 国产数控机床精度保持性分析及研究现状[J]. 中国机械工程, 2015, 26(22):3108-3115. MA Junxu,ZHAO Wanhua, ZHANG Genbao. Research status and analyses on accuracy retentivity of domestic CNC machine tools[J]. China Mechanical Engineering, 2015, 26(22):3108-3115. (in Chinese)

[2] XIA M, LI T, SHU T X, et al. A two-stage approach for the remaining useful life prediction of bearings using deep neural networks[J]. IEEE Transactions on Industrial Informatics,2018,15(6):3703-3711.

[3] CHEN Z H, WU M, ZHAO R, et al. Machine remaining useful life prediction via an attention based deep-learning approach [J]. IEEE Transactions on Industrial Electronics,2021,68(3):2521-2531.

[4] REN L, SUN Y Q, CUI J, et al. Bearing remaining useful life prediction based on deep auto encoder and deep neural networks [J]. Journal of Manufacturing Systems,2018,48:71-77.

[5] HUANG Z W, ZHU J M, LEI J T, et al. Tool wear predicting based on multi-domain feature fusion by deep convolutional neural network in milling operations[J]. Journal of Intelligent Manufacturing, 2019, 31(9-12):1-14.

[6] CHEN Y H, PENG G L, ZHU ZH Y, et al. A novel deep learning method based on attention mechanism for bearing remaining useful life prediction[J]. Applied Soft Computing,2020,86:105919.

[7] JASON D, DAVID H. 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.

[8] LIAO L X, JIN W J. Enhanced restricted Boltzmann machine with prognosability regularization for prognostics and health assessment[J]. IEEE Transactions on Industrial Electronics, 2016, 63(11):7076-7083.

[9] ZHAO R, WANG D Z, YAN R Q, et al. Machine health monitoring using local feature-based gated recurrent unit[J]. IEEE

Transactions on Industrial Electronics, 2018, 65(2): 1539 – 1548.

- [10] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49 – 56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49 – 56. (in Chinese)
- [11] 雷亚国, 杨彬, 杜兆钧, 等. 大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1 – 8.
LEI Yaguo, YANG Bin, DU Zhaojun, et al. Deep transfer diagnosis method for machinery in big data era[J]. Journal of Mechanical Engineering, 2019, 55(7): 1 – 8. (in Chinese)
- [12] 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 Hai, WANG Wei, HUANG Pu, et al. State prediction method research in NC machine tool based on multidimensional time series[J]. Advanced Engineering Sciences, 2018, 50(1): 187 – 195. (in Chinese)
- [13] 申中杰, 陈雪峰, 何正嘉, 等. 基于相对特征和多变量支持矢量机的滚动轴承剩余寿命预测[J]. 机械工程学报, 2013, 49(2): 183 – 189.
SHEN Zhongjie, CHEN Xuefeng, HE Zhengjia, et al. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine[J]. Journal of Mechanical Engineering, 2013, 49(2): 183 – 189. (in Chinese)
- [14] 冯吉路, 孙志礼, 赵坚, 等. 基于 AK – MCS 法的主轴系统振动可靠性分析[J]. 振动与冲击, 2019, 38(18): 135 – 140.
FENG Jilu, SUN Zhili, ZHAO Jian, et al. Vibration reliability analysis on a spindle system based on AK – MCS method[J]. Journal of Vibration and Shock, 2019, 38(18): 135 – 140. (in Chinese)
- [15] 刘显波, 何恩元, 龙新华, 等. 时滞作用下切削系统的时频响应特性研究[J]. 振动与冲击, 2020, 39(6): 8 – 14, 58.
LIU Xianbo, HE Enyuan, LONG Xinhua, et al. Time and frequency domain characteristics of a cutting system with time-delay effects[J]. Journal of Vibration and Shock, 2020, 39(6): 8 – 14, 58. (in Chinese)
- [16] 杜柳青, 殷国富, 余永维. 基于图形识别的数控机床运动误差溯源方法[J]. 仪器仪表学报, 2014, 35(7): 1662 – 1668.
DU Liuqing, YIN Guofu, YU Yongwei. Abduction of CNC machine tool's motion error based on graphic recognition[J]. Chinese Journal of Scientific Instrument, 2014, 35(7): 1662 – 1668. (in Chinese)
- [17] 李庆旭, 王巧华, 肖仕杰, 等. 基于深度学习的群体种鸭蛋受精信息检测方法[J]. 农业机械学报, 2021, 52(1): 193 – 200.
LI Qingxu, WANG Qiaohua, XIAO Shijie, et al. Detection method for fertilizing information of group duck eggs based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 193 – 200. (in Chinese)
- [18] 段恩泽, 方鹏, 王红英, 等. 基于深层卷积神经网络的肉兔图像分割与体质量估测[J]. 农业机械学报, 2021, 52(6): 259 – 267.
DUAN Enze, FANG Peng, WANG Hongyiny, et al. Meat rabbit image segmentation and weight estimation model based on deep convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 259 – 267. (in Chinese)
- [19] 冯权洸, 陈泊安, 牛博文, 等. 基于多尺度扩张卷积神经网络的城中村遥感识别[J]. 农业机械学报, 2021, 52(11): 181 – 189.
FENG Quanlong, CHEN Boan, NIU Bowen, et al. Identification of urban villages from remote sensing image based on multi-scale dilated convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(11): 181 – 189. (in Chinese)
- [20] 赵明, 社会芳, 董翠翠, 等. 基于 word2vec 和 LSTM 的饮食健康文本分类研究[J]. 农业机械学报, 2017, 48(10): 202 – 208.
ZHAO Ming, DU Huifang, DONG Cuicui, et al. Diet health text classification based on word2vec and LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(10): 202 – 208. (in Chinese)
- [21] 陈英义, 方晓敏, 梅思远, 等. 基于 WT – CNN – LSTM 的溶解氧含量预测模型[J]. 农业机械学报, 2020, 51(10): 284 – 291.
CHEN Yingyi, FANG Xiaomin, MEI Siyuan, et al. Dissolved oxygen prediction model based on WT – CNN – LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 284 – 291. (in Chinese)
- [22] 谢家兴, 高鹏, 孙道宗, 等. 基于长短期记忆的柑橘园蒸散量预测模型[J]. 农业机械学报, 2020, 51(增刊 2): 351 – 356.
XIE Jiaying, GAO Peng, SUN Daozong, et al. Modeling on prediction of evapotranspiration of citrus orchard based on LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2): 351 – 356. (in Chinese)
- [23] GAVES A, MOHAMED A, HINTON G E, et al. Speech recognition with deep recurrent neural networks[C]// International Conference on Acoustics, Speech, and Signal Processing. IEEE, 2013: 6645 – 6649.
- [24] 赵全明, 宋子涛, 李奇峰, 等. 基于 CNN – GRU 的菇房多点温湿度预测方法研究[J]. 农业机械学报, 2020, 51(9): 294 – 303.
ZHAO Quanming, SONG Zitao, LI Qifeng, et al. Multi-point prediction of temperature and humidity of mushroom based on CNN – GRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 294 – 303. (in Chinese)
- [25] 闵海根, 方煜坤, 吴霞, 等. 基于自动编码器和长短时记忆网络的智能汽车故障诊断方法研究[J]. 四川大学学报(自然科学版), 2021, 58(5): 73 – 81.
MIN Haigen, FANG Yukun, WU Xia, et al. Fault diagnosis research for intelligent vehicles based on autoencoder and LSTM[J]. Journal of Sichuan University(Natural Science Edition), 2021, 58(5): 73 – 81. (in Chinese)