

基于在线学习的数控加工刀具 寿命动态预测方法*

王 强,李迎光,郝小忠,刘长青,陈海吉

(南京航空航天大学机电学院,南京 210016)

[摘要] 预测刀具寿命对保证零件质量和控制加工成本意义重大,但刀具磨损过程复杂多变,刀具剩余寿命受工况影响难以准确预测。针对以上问题,提出了一种基于在线学习的刀具寿命动态预测方法,以长短时记忆网络为基础模型,融合在线学习模块,使得模型能够在加工过程中自动更新参数,实现变工况下刀具寿命的精确预测。进行了铣削加工试验,结果表明,刀具寿命动态预测方法可以有效提升刀具寿命预测精度。

关键词: 在线学习;数控加工;刀具磨损;寿命预测;动态预测

DOI:10.16080/j.issn1671-833x.2019.07.049



王 强

硕士研究生,主要研究方向为飞机复杂结构件智能数控加工技术。

对刀具寿命进行管理,准确预测刀具剩余寿命并预估失效状态,可以避免因刀具失效导致的零件加工质量问题,这对提高加工效率、降低加工成本具有重要意义^[1]。目前刀具寿命预测方法主要分3类:(1)基于

累计加工时间预测^[2],该类方法根据刀具的使用时间预测其剩余寿命,由于刀具剩余寿命与加工工况密切相关,仅依据加工时间累积得到的剩余寿命精度很低,只能适用于粗加工或对零件加工质量要求低的情况;(2)基于模型预测^[3-5],该类方法利用刀具剩余寿命相关特征建立预测模型,其预测精度有所提升,但刀具磨损相关特征需要人工提取,固定模型难以准确表达工况的变化;(3)基于数据的回归预测^[6-7],包括利用神经网络^[8]、支持向量机^[9]、隐马尔科夫模型^[10]、贝叶斯网络^[11]、随机森林^[12]等黑盒或半黑盒方法,该类方法从数据出发,显著提升了刀具寿命预测精度,但处理变工况加工时需要大量数据训练模型。

数控加工中影响刀具寿命因素众多,相关因素变化都会影响刀具剩余使用寿命,预测刀具剩余寿命需结合实际情况。基于累计加工时间预

测和基于模型预测的方法不具备对实际复杂工况的完整表达能力,难以预测变工况下刀具剩余寿命;基于数据的回归预测方法训练出的模型由于受训练样本限制,多针对单一工况,难以适应加工过程中的工况变化。

基于在线学习的刀具寿命 动态预测方法

针对以上问题,本文提出了一种基于在线学习的刀具寿命动态预测方法,该方法以长短时记忆网络(Long-Short Term Memory, LSTM)为基础模型,融合在线学习模块建立刀具寿命动态预测模型。该刀具寿命动态预测模型充分利用了LSTM对于时间序列数据的表达能力,又发挥了在线学习模块能够依据预测值与真实值的误差自动调整权值完成自我更新的特性,实现了变工况下的刀具寿命动态预测。所提出方法的网络模型如图1所示,其中 V 、 W 、 U 为LSTM网络的权值矩阵。

* 基金项目:2015年国家重大专项(2015ZX04001002)。

1 基于LSTM的刀具寿命预测基础模型

数控加工过程中刀具剩余寿命预测是一个时间序列预测问题,刀具下一时刻剩余寿命不仅取决于当前时间点的加工状态,还与前后一段时间内的加工工况密切相关。针对这类问题,以长短时记忆网络为基础,并添加额外回归层结构,搭建刀具寿命预测基础模型,利用刀具磨损信号特征进行模型训练和参数优化,实现了时间序列上的刀具磨损量和刀具剩余寿命的预测。基础模型在第 t 时刻展开如图 2 所示。

基础模型中 LSTM 层作用是处理时间序列上信息,包括从输入数据提取信息到隐藏层并输出用于预测的多维向量、回归层作用是通过全连接的形式拟合函数完成刀具磨损量

和刀具剩余寿命预测值输出。基础模型的预测输出是刀具磨损量和剩余寿命,其中刀具磨损量是当前时刻刀具磨损的最大 VB 和均匀 VB,刀具剩余寿命是依据当前时间步的工况信息预测达到刀具磨损极限理论上的剩余寿命。

2 融合在线学习的刀具寿命预测模型

由于实际加工中工况信息不断变化,因而使用历史数据训练得到的固定模型预测实际变化工况时存在模型失效的问题。本文对基于 LSTM 的刀具寿命预测基础模型进行优化,在原有的网络基础上添加在线学习模块,形成融合在线学习的刀具寿命动态预测模型 (Online Learning in Long-Short Term Memory, Online-LSTM)。使用刀具

磨损量在线自动测量系统得到的刀具磨损量实测值作为在线学习模块真实数据的输入,将预测值和实测值的误差反向传播实现权值调整,构成闭环的在线学习模块,实现刀具寿命预测模型自我更新。

所提出的在线学习结构是在刀具寿命预测模型的基础上增加一个额外模块,该模块与 LSTM 网络并行相独立,在线学习模块在最终输出时微调输出结果。在线学习模块在网络中表现为一个补充向量 (Supplementary Vector, SV),补充向量中的值即为在线自动测量得到的刀具磨损实测值,补充向量通过一个权值矩阵 W_{sv} 连接到基础模型并与 LSTM 共同作用到回归层,在每次预测后将预测磨损量与实际磨损量的误差反向传播到补充向量的权值矩阵,从而实现跟随工况变化不断调整输出的寿命预测值。

3 模型自动更新

在线学习模块的补充向量通过作用于回归层的隐藏单元来影响最终预测结果,在网络进行前向传播的时候补充向量 SV 会直接作用于隐藏层 H^m ,从而间接地影响输出层的预测结果。设定补充向量的权值矩阵为 W_{sv} , LSTM 网络的输出向量为 o_{LSTM} ,输出向量到回归结构隐藏层的权值矩阵为 W_{LSTM} ,因而隐藏层的计算更新为:

$$H^m = \text{softmax}(W_{LSTM} \cdot o_{LSTM} + W_{sv} \cdot SV) \quad (1)$$

网络进行反向传播的时候调整权值矩阵 W_{sv} ,将预测出的最大磨损量 \tilde{VB}_{max} 、均匀磨损量 \tilde{VB} 与补充向量中的实际值 VB_{max} 、 VB 对比,求出磨损值的误差 E ,通过梯度下降将误差链式求导传播到补充向量的权值矩阵,计算公式为:

$$E = \frac{1}{2} \left(\tilde{VB}_{max} - VB_{max} \right)^2 + \frac{1}{2} \left(\tilde{VB} - VB \right)^2 \quad (2)$$

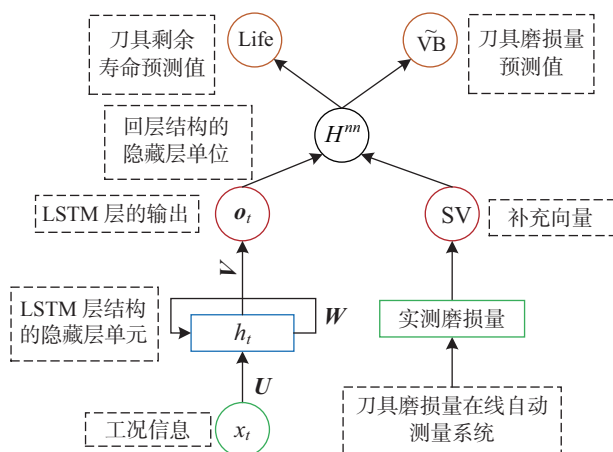


图1 刀具寿命动态预测模型
Fig.1 Dynamic prediction model of tool life




图2 基于LSTM的刀具寿命预测基础模型
Fig.2 Base model of tool life prediction based on LSTM

$$W_{SV} = W_{SV} + \eta \left(\bar{VB}_{\max} - VB_{\max} \right) \frac{\partial \bar{VB}_{\max}}{\partial W_{SV}} + \left(\bar{VB} - VB \right) \frac{\partial \bar{VB}}{\partial W_{SV}} \quad (3)$$

由于实际加工中没有当前时刻刀具剩余寿命的实际值,此处反向传播的误差由刀具磨损量的预测值和实测值对比得到,刀具寿命动态预测模型权值自动更新过程如图3所示。

实例分析

1 试验方案设计

为了获得足量的数据用于模型训练和模型性能验证,设计了以下切削试验,并记录刀具完整磨损周期中的工况数据和监测数据。为了得到变工况下的监测数据,试验中将切深、切宽、主轴转速、每齿进给量4个工艺参数作为变化量,设计四因素四水平正交试验如表1所示。

切削试验的毛坯选用TA15钛合金,尺寸为200mm×120mm×35mm,铣削刀具选用硬质合金整体铣刀,刀具几何参数为:切削刃直径12mm,底角半径1mm,切削刃长26mm,刀具总长83mm,刀刃个数3。参考ISO国际标准设定刀具的磨钝标准为后刀面磨损最大VB值达到0.4mm,均匀VB值达到0.25mm。

切削加工的机床为德国德玛吉公司的铣车复合中心DMG 80P DuoBlock,测力设备为德国promicron™公司的SPIKE测力刀柄,刀具实际磨损量测量采用刀具磨损

量在线自动测量系统。该系统的刀具磨损量测量方法属于基于图像的直接测量方法,它利用西尼科XT-T600无线版工业显微镜进行刀具磨损图像采集,进而通过图像处理等方法依据刀具磨损图像自动计算出刀具实际磨损量。实际加工过程中使用的整体铣刀、工业显微镜和试验过程中磨钝刀具如图4所示。

2 模型训练结果

将试验中磨钝的10把刀具的数据用于训练和验证模型,铣削刀具达到磨损极限的切削时长约60min,每隔10s调用刀具磨损自动测量系统

测量当前时刻的刀具磨损量,10把刀具总计获得数据样本约4000个。将样本的90%用于模型训练,10%用于测试模型泛化性能。刀具寿命预测模型最终训练结果为:包含两层的LSTM,其隐藏层神经元个数依次为50和30;包含一个神经元个数为25的回归层;使用了sigmoid和tanh两种激活函数;损失函数采用均方误差(Mean Square Error, MSE);权值和偏置值都采用均值为0,标准方差为1的高斯分布来进行初始化;批次大小batch size为64,时间步长度time step为50。模型训练完成之

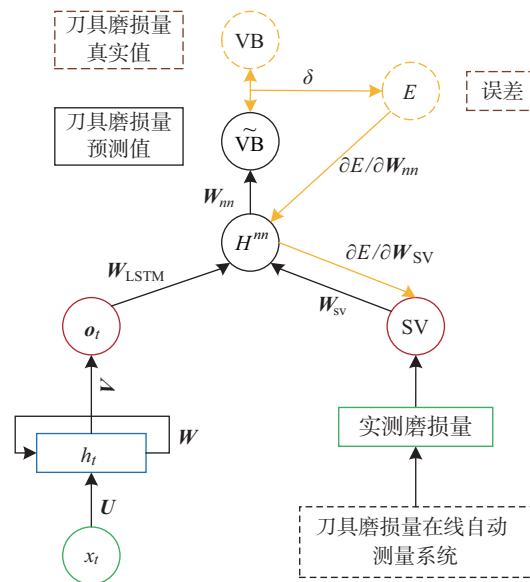


图3 模型自动更新过程

Fig.3 Automatic updating process of model

DMG80P DuoBlock 铣车复合中心 数控加工 整体铣刀




图4 实际加工过程

Fig.4 Actual machining process

表1 四因素四水平数值

Table 1 Four factors and four levels

水平	f_z /mm	S /($r \cdot \min^{-1}$)	a_c /mm	a_p /mm
水平1	0.05	400	1.0	1.0
水平2	0.07	450	1.5	2.0
水平3	0.08	500	2.0	2.5
水平4	0.10	550	3.0	3.0

后,在测试数据上计算刀具状态预测值的均方误差,包括刀具磨损均匀VB值的MSE,最大VB值的MSE和剩余寿命的MSE,结果如表2所示。

计算刀具寿命动态预测模型在10把刀切削数据上3类MSE均值,结果为均匀VB的MSE的均值为 3.40043×10^{-3} ,最大VB的MSE的均值为 2.53465×10^{-3} ,剩余寿命的MSE的均值为 2.93156×10^{-3} 。

3 模型对比

为了对比所提出 Online-LSTM 模型的性能,利用同样的样本数据训练 LSTM 模型并计算均方误差进行对比。此处的 LSTM 网络包含两个隐藏层,第1隐藏层的神经元个数为50个,第2隐藏层的神经元个数为30个。LSTM 模型得到的3类MSE如表3所示。

其中均匀VB的MSE均值为 5.44628×10^{-3} ,最大VB的MSE均值为 4.67751×10^{-3} ,剩余寿命的MSE的均值为 4.85761×10^{-3} 。对比LSTM模型和Online-LSTM模型如图5所示。

分析图5可知 Online-LSTM 模型相较于 LSTM 模型在均匀VB,最大VB和剩余寿命预测的准确度上都有较大提升。由于 Online-LSTM 模型在实际工况变化时对预测精度提高效果明显,这说明了在线学习模块能够提升 Online-LSTM 模型对于变工况的跟随能力,本文所提出的刀具寿命动态预测方法可以有效解决变工况下刀具寿命预测的问题。

结论

针对现有刀具寿命预测方法无法适用于变工况的问题,提出了一种基于在线学习的刀具寿命动态预测方法。该方法以长短时记忆网络为基础模型,并融合在线学习模块,使得模型能够在使用中依据预测误差自动更新权值,实现了变工况下

表2 测试数据上Online-LSTM模型预测值的MSE

Table 2 Prediction MSE of Online-LTSM model on test data

刀具编号	均匀VB的MSE / 10^{-3}	最大VB的MSE / 10^{-3}	剩余寿命的MSE / 10^{-3}
1	3.2512	2.5798	3.0105
2	3.3318	2.6882	2.8067
3	3.2109	2.5304	2.9268
4	3.3172	2.4054	2.9802
5	3.1051	2.3478	3.0945
6	3.4635	2.4952	2.9814
7	3.5195	2.6974	2.7108
8	3.2562	2.2746	2.6728
9	4.1128	2.9063	3.2014
10	3.4361	2.4214	2.9305

表3 LSTM模型预测值的MSE

Table 3 Prediction MSE of LSTM model

刀具编号	均匀VB的MSE / 10^{-3}	最大VB的MSE / 10^{-3}	剩余寿命的MSE / 10^{-3}
1	5.4601	4.6138	4.3546
2	5.0336	4.4031	4.2018
3	4.8692	4.4297	4.6733
4	5.3236	4.3563	4.9334
5	4.6775	4.4145	4.6973
6	5.5273	4.3016	4.7321
7	5.4986	4.4093	4.5012
8	4.6346	4.4232	4.6675
9	8.6766	6.7311	7.3221
10	4.7617	4.6925	4.4928

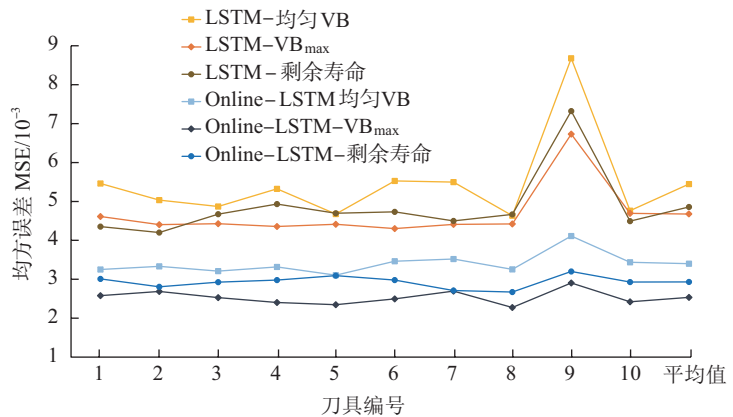


图5 两模型预测值MSE对比

Fig. 5 MSE comparison of two model prediction

刀具寿命的精确预测。并通过切削试验数据对比了原始 LSTM 模型和 Online-LSTM 模型的预测能力, Online-LSTM 模型预测的刀具寿命值与实际值平均误差约 0.05min, 远小于原始 LSTM 模型预测值与实际值约 0.1min 的平均误差, 试验结果表明能自我更新的 Online-LSTM 模型在实际测试中具有更高的预测精度。

参考文献

- [1] DOWNEY J, O'LEARY P, RAGHAVENDRA R. Comparison and analysis of audible sound energy emissions during single point machining of HSTS with PVD TiCN cutter insert across full tool life[J]. *Wear*, 2014, 313(1-2): 53-62.
- [2] 詹华西, 彭超雄. 积算加工时间实现数控机床刀具寿命管理[J]. *制造技术与机床*, 2008(8): 112-114.
- ZHAN Huaxi, PENG Chaoxiong. NC tools life management based on cutting time calculation[J]. *Manufacturing Technology & Machine Tool*, 2008(8): 112-114.
- [3] ARAMESH M, ATTIA M H, KISHAWY H A, et al. Estimating the remaining useful tool life of worn tools under different cutting parameters: a survival life analysis during turning of titanium metal matrix composites (Ti-MMCs)[J]. *Cirp Journal of Manufacturing Science & Technology*, 2016, 12: 35-43.
- [4] WANG P, GAO R X. Stochastic tool wear prediction for sustainable manufacturing[J]. *Procedia Cirp*, 2016, 48: 236-241.
- [5] GRIGORIEV S N, GURIN V D, VOLOSOVA M A, et al. Development of residual cutting tool life prediction algorithm by processing on CNC machine tool[J]. *Materialwissenschaft Und Werkstofftechnik*, 2013, 44(9): 790-796.
- [6] SI X S, WANG W, HU C H, et al. Remaining useful life estimation - A review on the statistical data driven approaches[J]. *European Journal of Operational Research*, 2011, 213(1): 1-14.
- [7] SIDDHPURA A, PAUROBALLY R. A review of flank wear prediction methods for tool condition monitoring in a turning process[J]. *The International Journal of Advanced Manufacturing Technology*, 2013, 65(1): 371-393.
- [8] KARAM S, CENTOBELLI P, D' ADDONA D M, et al. Online prediction of cutting tool life in turning via cognitive decision making[J]. *Procedia Cirp*, 2016, 41: 927-932.
- [9] BENKEDJOUH T, MEDJAHER K, ZERHOUNI N, et al. Health assessment and life prediction of cutting tools based on support vector regression[J]. *Journal of Intelligent Manufacturing*, 2015, 26(2): 213-223.
- [10] YU J, LIANG S, TANG D, et al. A weighted hidden Markov model approach for continuous-state tool wear monitoring and tool life prediction[J]. *International Journal of Advanced Manufacturing Technology*, 2016, 91(1-4): 1-11.
- [11] WIKLUND H. Bayesian and regression approaches to on-line prediction of residual tool life[J]. *Quality & Reliability Engineering International*, 2015, 14(5): 303-309.
- [12] WU D, JENNINGS C, TERPENNY J, et al. A Comparative study on machine learning algorithms for smart manufacturing: application of random forests to tool wear prediction[J]. *Journal of Manufacturing Science & Engineering*, 2017, 139(7): 71018(1-9).

通讯作者: 李迎光, 博士, 教授, 研究方向为航空航天复杂结构件数字化制造与智能制造, E-mail: liyingguang@nuaa.edu.cn.

Dynamic Prediction Method of Cutting Tool Life in NC Machining Based on Online Learning

WANG Qiang, LI Yingguang, HAO Xiaozhong, LIU Changqing, CHEN Haiji

(College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

[ABSTRACT] The prediction of tool life is of great significance to ensure the quality of parts and control the cost of machining. However, the tool wear process is complex and changeable, and it is difficult to accurately predict the residual life of the cutting tools affected by machining conditions. To solve the above problems, this paper presents a dynamic prediction method of tool life based on online learning. Using long-short term memory as base model and integrating the online learning module, the final model can automatically update the parameters during the machining process, and the accurate prediction of tool life under variable working conditions can be realized. The milling experiment was carried out, and the experimental results show that the dynamic prediction method of tool life can effectively improve the precision of tool life prediction.

Keywords: Online learning; Numerical control machining; Tool wear; Life prediction; Dynamic prediction

(责编 大漠)