

人工神经网络预测刀具磨损和切削力

李 鑫¹, 史振宇^{1†}, 蒋森河¹, 万 煦¹, 李 欣²

(1. 山东大学 机械工程学院, 山东 济南 250061; 2. 中国石化销售有限公司 山东石油分公司, 山东 济南 250014)

摘要: 刀具磨损和切削力预测与控制是切削加工过程中需要考虑的重要问题。本文介绍了利用人工神经网络模型预测刀具磨损和切削力的步骤并且针对产生误差的因素进行分析。首先将切削速度、切削深度、切削时间、主轴转速和不同频带的能量值通过归一化法处理, 作为输入特征值, 对改进的神经网络模型进行训练。然后利用训练完成的神经网络模型预测刀具磨损和切削力。结果表明: 神经网络模型能够综合考虑加工过程中更多的影响因素, 与经验公式结果对比, 具有更高的预测精度。研究结果表明神经网络模型预测刀具磨损和切削力具有可行性和准确性, 为刀具结构的优化及加工参数的选择提供了依据。

关键词: 机械加工; 加工工具; 切削力; 材料磨损; 神经网络; 人工智能

引用格式: 李鑫, 史振宇, 蒋森河, 等. 人工神经网络预测刀具磨损和切削力. 控制理论与应用, 2018, 35(12): 1731–1737

中图分类号: TH161 文献标识码: A

Artificial neural network predicts tool wear and cutting force

LI Xin¹, SHI Zhen-yu^{1†}, JIANG Sen-he¹, WAN Yi¹, LI Xin²

(1. School of Mechanical Engineering, Shandong University, Jinan Shandong 250061, China;
2. SINOPEC Shandong Oil Products Company, Jinan Shandong 250014, China)

Abstract: Tool wear and cutting force prediction and control are important problems to be considered in the machining process. In this paper, the process of predicting tool wear and cutting force by using artificial neural network model are introduced, and the factors that produce error are analyzed. Firstly, the cutting speed, cutting depth, cutting time, spindle speed and energy value of different frequency bands are treated by normalization method, which are used as input eigenvalues, and the improved neural network model is trained by those input eigenvalues. Then the tool wear and cutting force are predicted by using the trained neural network model. The results show that the neural network model can consider more factors in the machining process, and compared with the results of empirical formulas, it has higher prediction accuracy. The results show that the neural network model has the feasibility and accuracy in predicting tool wear and cutting force, and can be helpful for the optimization of tool structure and the selection of machining parameters.

Key words: machining; cutting tools; cutting force; wear of materials; neural networks; artificial intelligence

Citation: LI Xin, SHI Zhenyu, JIANG Senhe, et al. Artificial neural network predicts tool wear and cutting force. *Control Theory & Applications*, 2018, 35(12): 1731 – 1737

1 引言(Introduction)

刀具的磨损量和切削力是影响切削加工结果的重要指标。刀具在加工过程中, 受到切屑和工件的摩擦作用, 致使刀具的前后刀面逐渐产生磨损。当刀具磨损量达到一定程度时, 可以发现切削力明显增大, 切削温度上升, 进而产生振动, 导致工件加工精度降低, 加工表面质量变差。此时就需要磨刀或者重新换刀^[1–3]。可见, 刀具磨损量的增加和切削力的变化对于加工质量、生产效率以及加工成本有着直接影响, 是切削过程中需要考虑的极为重要的问题之一。

目前对于切削力以及刀具磨损的研究主要集中在解析法和经验公式方法, 但是这两种方法各有其局限性。解析模型的建立和所需状态量的准确获取是决定解析法预测精度的重要因素。但是由于目前对于磨损机理的研究存在一定限制性, 很难利用数学模型精准的描述磨损过程^[4]。同时, 解析模型中所需要物理状态量通常为刀具所受应力、变形系数、摩擦系数、刀-屑之间相对滑移速度等, 这些物理量很难准确获取, 严重影响解析模型的预测精度。经验公式的建立依赖于大量精准的实验测量数据, 偶然的测量误差对经验

收稿日期: 2018–10–09; 录用日期: 2018–12–20.

[†]通信作者. E-mail: shizhenyu@sdu.edu.cn; Tel.: +86 15169076215.

本文责任编辑: 刘智勇。

国家自然科学基金项目(51505255), 山东大学青年学者未来计划项目资助。

Supported by the National Natural Science Foundation of China (51505255) and the Fundamental Research Funds of Shandong University.

公式的建立产生较大的影响。除此以外，经验公式很少考虑到刀具几何参数和材料特性对切削力和刀具磨损的影响。神经网络模型具有自适应、自组织、自学习、非线性映射、容错纠错能力和高速并行计算能力等特点^[5]。由于切削用量和刀具几何形状与刀具磨损和切削力之间存在高度的非线性关系，而人工神经网络在非线性建模具有很强的能力^[6]，因此利用人工神经网络模型预测刀具磨损和切削力具有明显的优势。Wilkinson等人^[7]将加工信号和已加工表面特征作为输入信息时，利用神经网络模型能够有效的预测出铣削加工中刀具的3种磨损状态。Balazinski等人^[8]研究了不同隐藏层和训练次数对刀具磨损预测模型的影响，结果表明，当隐层的次数超过3层时，所有预测模型的误差几乎相同。文献[5]将不同磨损阶段的信号进行分解及重构做出特征向量，借助神经网络实现刀具磨损量的预估。但是传统的BP神经网格具有全局逼近网络学习速度很慢并且容易陷入局部极小的缺陷等缺点^[9-11]。与其他算法相结合，以提升神经网络结构的性能和收敛速度也是中外学者研究的重点^[11-12]。文献[13]提出了基于敏感度分析的神经网格结构优化设计，在保证神经网络收敛性能的前提下实现结构在线调整，提高神经网络的自适应能力。但是，刀具磨损是一个动态的、连续的过程，因此只考虑加工信号频域特征不能准确地描述刀具磨损过程。

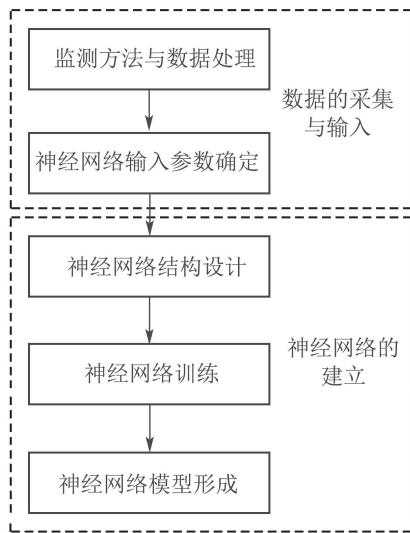


图1 神经网络的预测模型构建流程

Fig. 1 The process of building prediction model based on neural network

本文首先主要介绍了人工神经网络预测模型建立的流程及关键步骤。其次，将工艺参数和加工时间综合结果作为神经网络模型的输入项，利用改进BP神经网络模型对切削过程中刀具磨损量和切削力进行了预测并与经验公式和试验结果进行对比。最后介绍了

影响神经网络模型预测精度的因素。

2 神经网络模型建立流程 (Process of establishing neural network model)

建立神经网络预测模型的流程如下图1所示，其流程主要分为数据的采集与输入和神经网络的建立两部分。数据的采集是指通过多种传感器收集加工信息的过程。随后，收集后的信息通过数学方法处理，生成神经网络模型的输入特征量。之后，经过初始设计的人工神经网络将根据采集到的加工信息进行学习训练，通过改变神经网络拓扑结构和状态量的连接权值，缩小输出值与设定目标的差值，使预测输出值不断接近刀具真实测定的磨损值及切削力，从而建立具备预测刀具磨损和切削力的神经网络。

3 神经网络模型关键步骤 (Key steps of neural network model)

3.1 监测方法与数据收集 (Monitoring methods & data collection)

不同于解析法和经验公式法预测刀具磨损和切削力，神经网络模型根据加工过程中测定的加工信息与刀具状态信息预测出加工过程中刀具的磨损状态。数据收集过程中选取的信息数目和种类将直接影响模型的预测精度。目前，切削加工过程中的在线检测方法主要有：切削力监测、振动监测、声发射监测，电流和功率监测等。常用于的建立神经网络模型的加工信息有：切削力、振动、噪声、工件纹理、工艺参数以及能量等。

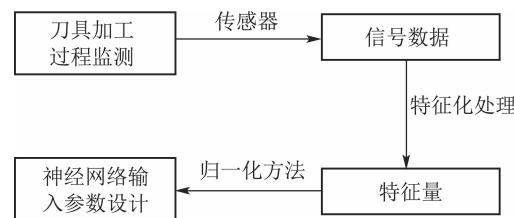


图2 数据收集过程

Fig. 2 Data collection process

对于刀具加工过程在线监测和数据处理的目的是获取影响刀具磨损及切削力等物理量的特征量。由于传感器输出的监测信号数据无法直接用于评估刀具磨损及切削力情况，必须借助一系列数学方法计算出对应的特征量。目前影响刀具磨损及切削力的特征量并没有统一规定，不同学者采用的特征量也不一样。文献[14]提取切削力信号的奇异性指数作为评估刀具磨损的特征量，文献[15-16]则考虑切削力均值、均方根、信号增量等时域参数。文献[17]对切削力进行幅域和频域分析，并且转化为无量纲的特征量，建立了基于频域特征量参数的刀具磨损神经网络模型。

3.2 神经网络种类 (Types of neural networks)

神经网络模型描述了采集的加工信息和刀具磨损状态之间的关系。因此选择合适的神经网络模型至关重要。目前，常见的工程中常用于预测加工过程的神经模型有：BP 神经网络、径向基函数 (radial basis function network, RBF) 神经网络等。

3.2.1 BP神经网络 (BP neural network)

BP神经网络是目前工程中最常用的神经网络模型。BP神经网络具有很强的非线性适应性和信息处理能力。该模型采用的是后向传播学习算法，其结构如图3所示。BP神经网络模型主要由输入层、隐层和输出层组成，输入信号在不同层的节点之间传递，每一层的节点输出信号只影响下一层节点的输出。

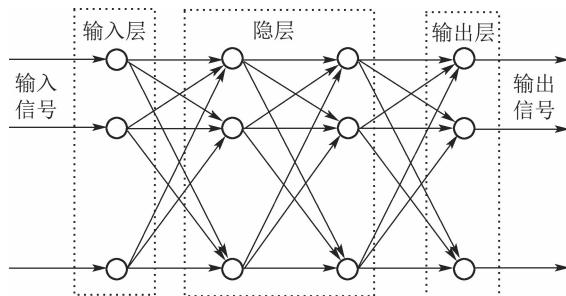


图 3 BP 神经网络结构图

Fig. 3 The structure of BP neural network

目前，3层网络能够逼近任何给定的映射，所以国内外学者多采用3层BP结构网格构建刀具磨损及切削力预测模型。BP神经网络模型属于全局逼近网络。在BP神经网络模型内，对于任何一个输入信号，整个模型内一个或多连接权系数或者可调参数都会对输出结果产生影响。

3.2.2 RBF神经网络 (RBF neural network)

RBF神经网络是一种3层前向网络。不同于BP网络模型，RBF属于局部逼近网络模型^[18]。RBF神经网络具有较强的输入和输出映射功能且无局部极小问题存在。针对RBF神经网络结构设计与优化是中外学者研究的重点^[10, 19]。

3.3 神经网络的结构 (Structure of neural network)

神经网络的结构对神经网络的训练和预测精度非常重要。神经网络的结构选择包括神经网络结构的层数和每层节点数目。

Hecht-Nielson等人^[20]研究神经网络对任意非线性映射的逼近情况，结果表明3层前向网格可以实现较高精度的逼近结果。

隐藏层神经元的节点数目对神经网络模型预测精度有一定影响。节点数目多，结构庞大，训练时间增加，

精度较高；节点数目低，结构简单，但不容易收敛。目前常用的确定节点数目的方法为试凑法或经验法。

3.4 神经网络的训练 (Training of neural network)

神经网络的训练过程就是不断调整自身拓扑结构和状态量连接权值。通过自身的调整，使得神经网络模型输出值不断接近真实测定值，为了实现这一过程，需要对建立的神经初始神经网络模型进行训练。

训练步骤如下：

1) 从样本集内取出一组试验数据 $X(x_1x_2x_3 \dots x_n)$ ，经过数据处理，作为输入信息，输入到神经网络模型；

2) 根据输入信息，由初始神经网络模型计算出刀具磨损的预测值：

$$Y = f\left(\sum_{i=1}^{N+1} w_i x_i\right), \quad (1)$$

其中初始权值 w_i 为 $0 \sim 1$ 范围内随机分布的非零值。

3) 依次代入样本集内全部试验数据并且计算出预测值。计算预测值与真实测量值之间的差值，以均方误差来评价预测模型的精度：

$$E(t) = \frac{1}{2}[d_k - y_k(t)]^2, \quad (2)$$

式中： d_k 为第 k 组样本真实测量值， $y_k(t)$ 为计算预测值， $E(t)$ 为当前误差。

4) 根据样本集数据计算出的均方误差，反向调整上一层网络的连接权值，以减少均方误差值：

$$w_i(t+1) = w_i(t) + \eta[d - Y(t)]x_i, \quad (3)$$

其中 η 用于控制修正速度，并且 $0 \leq \eta \leq 1$ 。

5) 重复步骤1)~4)，经过反复尝试，确立了最优的函数组合，直至整个样本训练集内误差最小或者达到设定值以内，训练终止，输出训练完成的神经模型。

4 基于神经网络的刀具磨损预测模型 (Tool wear prediction model based on neural network)

本文以文献[21]中数据为例，进一步验证基于神经网络的刀具磨损预测模型可行性和准确性。

4.1 选择输入参数 (Selection of input parameters)

试验采用硬质合金车刀车削高温合金材料。在不同的切削条件下分别采集刀具状态下的声发射信号，将刀具不同状态的声发射信号用Db10小波分解，获取每组信号的6个频带的能量值^[21]。具体工艺参数如表1所示。

表1 刀具各频带的能量值, 切削条件及实际VB值

Table 1 The energy value of the tool in different frequency bands, cutting condition and VB value

样本序号	各频带能量						切削速度/ (r·min⁻¹)	切削深度/ mm	进给量/ (mm·r⁻¹)	切削时间/ s	实际VB/mm
	E ₁ /kJ	E ₂ /kJ	E ₃ /kJ	E ₄ /kJ	E ₅ /kJ	E ₆ /kJ					
1	206.08	17.28	3.829	0.7762	0.164	0.0348	280	0.2	0.3	10	0.18
2	40.84	2.696	0.511	0.0938	0.0236	0.0082	220	0.2	0.51	15	0.16
3	157.06	27.77	11.264	3.1583	0.0582	0.0845	140	0.4	0.15	30	0.19
4	109.41	23.98	6.265	1.1856	0.1999	0.0434	220	0.6	0.3	20	0.19
5	70.59	8.607	3.558	1.8295	1.0692	0.2724	280	0.4	0.51	10	0.19
6	14.08	2.049	0.461	0.1167	0.0705	0.0101	140	0.6	0.51	25	0.16
7	309.2	19.28	4.006	1.5268	0.2783	0.0672	280	0.2	0.3	90	0.26
8	110.98	12.10	1.482	0.5506	0.1282	0.0234	220	0.2	0.51	135	0.25
9	93.62	13.91	2.710	0.7811	0.1775	0.0336	140	0.4	0.15	140	0.28
10	157.62	16.21	3.69	1.0795	0.1972	0.0380	220	0.6	0.3	50	0.26
11	126.53	9.937	3.297	0.7273	0.5628	0.2128	280	0.6	0.51	30	0.27
12	67.61	8.905	1.768	0.3529	0.0881	0.0321	140	0.6	0.51	100	0.25
13	94.52	7.407	1.348	0.3692	0.0623	0.0157	280	0.2	0.3	229	0.40
14	83.07	10.25	1.481	0.3796	0.0659	0.0235	220	0.2	0.51	315	0.36
15	140.84	12.59	3.899	1.2010	0.2761	0.0363	140	0.4	0.15	280	0.45
16	81.06	10.06	2.494	0.5371	0.4964	0.1352	220	0.6	0.3	85	0.32
17	106.5	3.767	2.581	0.6368	1.8324	0.3562	280	0.6	0.51	50	0.33
18	18.57	1.344	0.230	0.0434	0.0134	0.0051	280	0.2	0.3	10	0.35

4.2 数据归一化方法(Data normalization method)

数据的归一化是神经网络预测模型常用的数据处理方法。其处理的主要目的是把相同类型的测量数据转化为分布在[-1, 1]之间的对应数值, 这样可以消除同一纬度各个数据数量级之间差别, 减小数据收集和处理过程中产生的误差。转化公式如下:

$$x_k = 2 \times (x_k - x_{\min}) / (x_{\max} - x_{\min}) - 1. \quad (4)$$

4.3 建立神经网络(Establishment of neural network model)

在 MATLAB 中, 根据参考文献[22], 选择BP神经网络结构作为本次构建刀具磨损模型的基础。为了提高网络学习能力和增加算法可靠性^[23], 在训练过程中结合 Levenberg-Marquardt 算法(简称 LM 算法)。选择输入层到隐层的传递函数为 logsig, 隐层到输出层传递函数为 purelin。设置训练函数为 trainglm。选择表1中不同频带的能量值、切削速度、切削深度、进给量及切削时间一起作为BP神经网络的输入向量。

4.4 神经网络模型的训练与结果(Training of neural network & results)

根据表1数据, 选择试验序号1~5, 选择序号13~18作为训练样本, 选择序号6~12, 作为测试样本。用 MATLAB 神经网络工具箱函数 sim 对训练好的神经网络作进一步验证与计算, 测试结果如图4所示。

结果显示, 神经模型的预测精度依赖于训练的样本数据。如测试点6和7的预测数据, 因为与其他样本数据的值比较接近, 所以测试精度较高。反之在测试

点8和9测试精度较差。这是因为测试点6, 7的测试数据值与样本数据比较接近, 预测精度较高。因此, 在利用神经网络预测刀具磨损量时, 尽量选择样本数据范围内的预测数据, 这样可以获得比较好的预测结果。

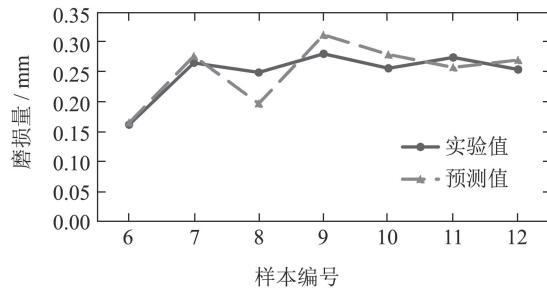


图4 神经网络预测结果

Fig. 4 The results of neural network model

5 基于神经网络的切削力预测模型介绍(Cutting force prediction model based on neural network)

以铣削加工平均铣削力计算为例, 比较神经网络的预测模型与经验公式计算结果。

5.1 试验方案(Experimental procedure)

端铣切削试验使用机床为DEKELMAHO DMU-70V立式加工中心。工件材料为铝合金7075-T651, 尺寸为70×40×20 mm; 刀具为硬质合金端铣刀(主偏角为90°), 直径为20 mm, 齿数为3。切削力的测量采用 Kistler9257A 测力仪。测试系统如图5所示。

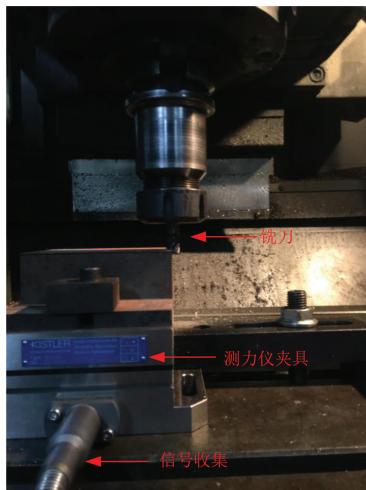


图5 铣削数据收集

Fig. 5 Collection of milling data

选取主轴转速、径向切深、每齿进给量3个铣削参数为变量, 每个铣削参数选取3个水平值, 进行全因子实验。表2内容为27组实验的结果。

5.2 正交经验公式(Orthogonal empirical formula)

对实验结果进行拟合, 得到用铣削参数表示的铣削力或铣削温度的经验公式, 以拟合铣削力经验公式为例, 拟合为指数形式的经验公式, 采用的公式形式为

$$F = a \times n^b \times a_p^c \times f^d, \quad (5)$$

式中: n, a_p, f 为3个铣削参数, 分别为主轴转速、径向深度和每齿进给量; F 为铣削力, a, b, c, d 四个参数为要拟合得到的经验公式系数。通过拟合确定了 a, b, c, d 四个参数值后, 也就得到了指数形式的经验公式。

表2 铣削实验表

Table 2 Milling test table

编号	主轴转速 $n/(r \cdot min^{-1})$	径向切深 a_p/mm	每齿进给 f/mm	轴向切深 a_e/mm	平均铣削力 F/N	最高温度 $T/^\circ C$
1	16000	2	0.05	5	234	282.1
2	16000	2	0.08	5	350	304.5
3	16000	2	0.1	5	434	310.4
4	16000	5	0.05	5	238	282.7
5	16000	5	0.08	5	356	266.4
6	16000	5	0.1	5	431	265.7
7	16000	10	0.05	5	239	282.1
8	16000	10	0.08	5	348	304.1
9	16000	10	0.1	5	428	307.6
10	17000	2	0.05	5	238	265.4
11	17000	2	0.08	5	355	266.4
12	17000	2	0.1	5	420	313.1
13	17000	5	0.05	5	242	285.4
14	17000	5	0.08	5	351	267.0
15	17000	5	0.1	5	432	314.4
16	17000	10	0.05	5	243	285.0
17	17000	10	0.08	5	360	267.9
18	17000	10	0.1	5	433	313.6
19	18000	2	0.05	5	246	282.6
20	18000	2	0.08	5	360	267.5
21	18000	2	0.1	5	438	267.5
22	18000	5	0.05	5	242	286.1
23	18000	5	0.08	5	353	268.4
24	18000	5	0.1	5	437	315.2
25	18000	10	0.05	5	243	285.5
26	18000	10	0.08	5	360	293.0
27	18000	10	0.1	5	437	315.2

利用表2中编号1, 5, 9, 10, 15, 16, 21, 22, 26数据进行经验公式拟合, 借助MATLAB和EXCEL软件, 拟

合结果如下:

$$F = 943 \times n^{0.121} \times a_p^{0.007} \times f^{0.854}. \quad (6)$$

由拟合结果可知, 铣削力 F 与 n, a_p, f 之间的关系可用指数模型描述。指数系数值得大小反应了该因素对铣削力的影响程度。其中, 每齿进给量 f 对铣削力 F 影响最大, 主轴转速 n 次之, 径向切深 a_p 最小。

5.3 神经网络模型建立与结果(Establishment of neural network model & results)

在MATLAB中设计BP神经网络模型结构。其中, 输入层到隐层的传递函数为logsig, 隐层到输出层传递函数为purelin。设置训练函数为trainlm。把表2中的主轴转速 n 、径向切深 a_p 及每齿进给量 f 一起作为BP神经网络的输入向量。选择表2中21组数据为训练模型的样本数据, 其余6组作为测试组对模型进行测试。其结果如表3所示, 分别是铣削力的实验值、利用神经网络预测值和通过经验公式预测值及各自的相对误差。

由表3数据可知, 在一定样本训练的情况下, 经验公式和神经模型的预测结果具有相同的变化趋势, 但是神经网络具有的自学习和自适应能力使得预测精度高于经验公式。相比于经验公式方法, 神经网络模型具有更好的拓展性。如将上述实验中温度和切削力的频谱信息也作为训练信息, 则可以进一步增加神经网络模型的预测精度。经验公式需要预先假设铣削力与加工参数之间的指数关系式, 而神经网络对非线性模型具有更强的建模和处理能力, 因此神经网络预测模型不需要假设铣削力与加工参数之间的关系式, 就能准确地反映出切削力随着切削力影响因素的变化。

表3 铣削力结果
Table 3 Milling force results

测试组	实验	神经网络	经验公式	神经网络	经验公式
	值/N	预测值/N	值/N	误差/%	误差/%
1	238	240.68	229.40	1.12	-3.61
2	348	367.59	373.45	5.63	7.31
3	355	347.34	372.02	-2.16	4.80
4	351	341.07	374.35	-2.83	6.65
5	438	435.85	428.92	-0.49	-2.07
6	243	248.27	255.41	2.17	5.11

6 影响神经网络模型精度的因素(Factors affecting the accuracy of neural network model)

由于神经网络预测模型的建立基于信号数据的采集和处理, 因此信号采集的准确性、信号种类的选择, 以及信号数据的处理方式都会对预测模型的建立和预测精度产生重要作用。目前影响刀具磨损及切削力的特征量并没有统一规定, 不同学者采用的特征量也不一样。这是影响神经网络预测精度的重要原因。

基于神经网络建立的刀具磨损和切削力预测模型都缺乏对于切削加工中物理本质的描述, 在神经网络

建模时, 存在节点内部单元意义不明确, 节点数目选择具有一定随意性等缺点。缺乏从本质上解释输入信息对刀具磨损的影响作用和过程。

神经模型的预测精度依赖于训练的样本数据。当测试数值在样本范围以内时, 神经网络能够参考周围样本数据信息值, 其预测值与试验结果误差较小。当测试数据偏离训练样本数据的上下限范围时, 预测值与实验值误差较大。

7 结论(Conclusions)

神经网络模型建立的刀具磨损和切削力预测模型能较好地满足工程需要, 为预测加工过程中刀具的磨损状态和切削力提供有力工具, 对于生产实践具有很好的实际意义。

多种传感器信号来源和改进神经网络结构联合使用, 可以提高神经网络模型的拓展性, 减少训练次数, 提高预测精度。

参考文献(References):

- [1] GRUM J. Book review: Fundamentals of machining and machine tools [J]. *International Journal of Microstructure & Materials Properties*, 2008, 3(2/3): 469 – 470.
- [2] ZHAO G Y, LIU Z Y, HE Y, et al. Energy consumption in machining: Classification, prediction, and reduction strategy [J]. *Energy*, 2017, 133: 142 – 157.
- [3] FERNANDEZ-VALDIVIELSO A, LACALLE L L D, URBIAKIN G, et al. Detecting the key geometrical features and grades of carbide inserts for the turning of nickel-based alloys concerning surface integrity [J]. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. 2015, 230(20): 3725 – 3742.
- [4] YADAV R K, ABHISHEK K, MAHAPATRA S S. A simulation approach for estimating flank wear and material removal rate in turning of Inconel 718 [J]. *Simulation Modelling Practice & Theory*, 2015, 52: 1 – 14.
- [5] GUAN Shan, NIE Peng. Application of improved L-M optimization algorithm BP neural network in tool wear prediction [J]. *Machine Tool & Hydraulics*, 2012, 40(15): 22 – 26.
(关山, 聂鹏. L-M优化算法BP网络在刀具磨损量预测中的应用 [J]. 机床与液压, 2012, 40(15): 22 – 26.)
- [6] XU Zhihao, LI Sheng, CHEN Qingwei. Velocity observer based distributed consensus tracking control for multiple Euler-Lagrange systems [J]. *Control Theory & Applications*, 2015, 32(1): 50 – 57.
(徐智浩, 李胜, 陈庆伟. 采用速度观测器的多Euler-Lagrange系统一致性跟踪控制 [J]. 控制理论与应用, 2015, 32(1): 50 – 57.)
- [7] WILKINSON P, REUBEN R L, JONES J D C, et al. Tool wear prediction from acoustic emission and surface characteristics via an artificial neural network [J]. *Mechanical Systems and Signal Processing*, 1999, 13(6): 955 – 966.
- [8] BALAZINSKI M, CZOGALA E, JEMIELNIAK K, et al. Tool condition monitoring using artificial intelligence methods [J]. *Engineering Applications of Artificial Intelligence*, 2002, 15(1): 73 – 80.
- [9] SICK B. On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research [J]. *Mechanical Systems & Signal Processing*, 2002, 16(4): 487 – 546.
- [10] LEUNG F H F, LAM H K, LING S H, et al. Tuning of the structure and parameters of a neural network using an improved genetic algo-

- rithm [J]. *IEEE Transactions on Neural Networks*, 2003, 14(1): 79 – 88.
- [11] FENG H M. Self-generation RBFNs using evolutional PSO learning [J]. *Neurocomputing*, 2006, 70(1): 241 – 251.
- [12] SHENG C, XIA H, BING L L, et al. Construction of tunable radial basis function networks using orthogonal forward selection [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics—A Publication of the IEEE Systems Man & Cybernetics Society*, 2009, 39(2): 457 – 466.
- [13] QIAO Junfei, HAN Honggui. Optimal structure design for RBFNN structure [J]. *Acta Automatica Sinica*, 2010, 36(6): 865 – 872.
(乔俊飞, 韩红桂. RBF神经网络的结构动态优化设计 [J]. 自动化学报, 2010, 36(6): 865 – 872.)
- [14] XIANG Wenjiang, ZHAO Xuezhi. Wear detecting method based on wavelet transformation [J]. *Tool Engineering*, 2000, 34(5): 34 – 36.
(向文江, 赵学智. 基于小波变换的刀具磨损检测方法 [J]. 工具技术, 2000, 34(5): 34 – 36.)
- [15] LIANG Jiancheng, LI Shengyi, WEN Xisen, et al. Tool wear monitoring on the basis of multisensory fusion by neural network [J]. *Mechanical Science and Technology*, 1995, (6): 125 – 130.
(梁建成, 李圣怡, 温熙森, 等. 基于神经网络多传感器融合的刀具磨损定量监测的研究 [J]. 机械科学与技术, 1995, (6): 125 – 130.)
- [16] ZHENG Jianming, LI Yan, LI Pengyang, et al. Tool wear monitoring based on the multiple features of the cutting force fusing in time and frequency domain [J]. *Machinery & Electronics*, 2001, (3): 46 – 48.
(郑建明, 李言, 李鹏阳, 等. 基于切削力信号时域频域特征融合的刀具磨损监测 [J]. 机械与电子, 2001, (3): 46 – 48.)
- [17] LI Pengyang, YANG Mingshun, YUAN Qilong, et al. Drill wear online monitoring by using cutting force signal [J]. *Tool Engineering*, 2005, 39(8): 79 – 82.
(李鹏阳, 杨明顺, 袁启龙, 等. 基于切削力信号的钻头磨损状态实时监测 [J]. 工具技术, 2005, 39(8): 79 – 82.)
- [18] WU Yuxiang, ZHANG Jing, WANG Cong. Fault diagnosis of cracked rotor systems based on radial basis function neural networks [J]. *Control Theory & Applications*, 2014, 31(8): 1061 – 1068.
- (吴玉香, 张景, 王聪. 基于径向基函数神经网络的转子系统裂纹故障诊断 [J]. 控制理论与应用, 2014, 31(8): 1061 – 1068.)
- [19] PANCHAPAKESAN C, PALANISWAMI M, RALPH D, et al. Effects of moving the center's in an RBF network [J]. *IEEE Transactions on Neural Networks*, 2002, 13(6): 1299 – 1307.
- [20] NIELSEN H R. Theory of the backpropagation neural network [C] //International Joint Conference on Neural Networks. Washington: IEEE, 2002: 445.
- [21] NIE Peng, CHEN Xin. Prediction of tool VB value based on PCA and BP neural network [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2011, 37(3): 364 – 367.
(聂鹏, 谌鑫. 基于主元分析和BP神经网络对刀具VB值预测 [J]. 北京航空航天大学学报, 2011, 37(3): 364 – 367.)
- [22] GHOSH N, RAVI Y B, PATRA A, et al. Estimation of tool wear during CNC milling using neural network-based sensor fusion [J]. *Mechanical Systems & Signal Processing*, 2007, 21(1): 466 – 479.
- [23] FAN Zhaofeng, MA Xiaoping, SHAO Xiaogen. Method to determine initial value of local optimization for neural network predictive control [J]. *Control Theory & Applications*, 2014, 31(6): 741 – 747.
(樊兆峰, 马小平, 邵晓根. 神经网络预测控制局部优化初值确定方法 [J]. 控制理论与应用, 2014, 31(6): 741 – 747.)

作者简介:

- 李 鑫 (1990–), 男, 硕士研究生, 目前研究方向为机械加工控制理论等, E-mail: 316590272@qq.com;
- 史振宇 (1984–), 女, 博士, 讲师, 硕士生导师, 目前研究方向为机械加工控制理论等, E-mail: shizhenyu@sdu.edu.cn;
- 蒋森河 (1994–), 男, 硕士研究生, 目前研究方向为机械加工控制理论等, E-mail: 1210107099@qq.com;
- 万 熠 (1977–), 男, 博士, 教授, 博士生导师, 目前研究方向为机械加工控制理论等, E-mail: wanyi@sdu.edu.cn;
- 李 欣 (1982–), 男, 目前研究方向为信息化集成.