

# 采用 BP 神经网络预测钻削灰铸铁的切削能耗

李小水, 詹友基, 贾敏忠

(福建工程学院 机械与汽车工程学院, 福建 福州 350118)

**摘要:** 采用 BP 神经网络建立灰铸铁钻削过程的切削能耗与切削参数之间的关系模型, 并建立三元线性回归预测模型, 对两种预测模型预测结果的准确性进行比对分析。考虑切削参数之间的交互作用建立三维表面图, 对比分析钻削过程的切削能耗与切削参数的变化规律。结果表明, 通过训练的 BP 神经网络在预测切削能耗方面具有更好的准确性, 对钻削过程的切削能耗预测研究具有一定应用价值和指导意义。生产实际中, 从减小切削能耗的角度分析, 在满足加工质量的前提下, 钻削灰铸铁时应优先选择较大的进给量和切削速度。

**关键词:** BP 神经网络; 钻削; 切削能耗; 三元回归

中图分类号: TG5

文献标志码: A

文章编号: 1672-4348(2017)06-0528-07

## Prediction of cutting energy consumption in drilling gray iron by BP neural network

Li Xiaoshui, Zhan Youji, Jia Minzhong

(School of Mechanical and Automotive Engineering, Fujian University of Technology, Fuzhou 350118, China)

**Abstract:** BP neural network was used to establish the relationship model of the cutting energy consumption and the cutting parameters in the drilling of gray cast iron. The ternary linear regression model was established to compare the accuracy of the prediction results of the two prediction models. The interactions among the cutting parameters were taken into consideration in establishing the three-dimensional surface graph, and the varied cutting energy consumptions and cutting parameters in the drilling process were compared and analyzed. Results show that the trained BP neural network has better accuracy in predicting the energy consumption of cutting, which has certain application value and provides guidance for the cutting energy consumption prediction of the drilling process. Under the premise of guaranteeing the processing quality, priority should be given to choosing a larger feed and cutting speed in order to reduce the cutting energy consumption when drilling gray cast iron.

**Keywords:** BP neural network; drilling; cutting energy consumption; ternary regression

机床是广泛应用于制造业的生产设备之一, He 等人<sup>[1]</sup>认为机床的效率低于 30%, 并且机床在零件加工过程中对环境的影响 99% 以上是由电能消耗所引起。切削能量消耗预测模型可以为机床加工过程的能耗定额制定、切削工艺参数节能优化、能效评估等提供一定的数据支持。机床

加工能耗预测有数值、经验和人工智能等方法。Sangwan 等人<sup>[2]</sup>利用有限单元法、有限差分法、边界元法等建立了数值模型。谢东、陈薇薇等人<sup>[3-4]</sup>利用 BP 神经网络对数控机床切削能耗进行建模预测。Zeng Y R 等人<sup>[5]</sup>利用自适应微分进化算法支持的反向传播神经网络模型来估计能

收稿日期: 2017-10-12

基金项目: 国家自然科学基金项目(5177513); 福建省自然科学基金项目(2016J01723); 福建省 2011 协同创新中心合作项目(2017XT002)

通讯作者: 詹友基(1972-), 男, 福建闽清人, 教授, 博士, 研究方向: 硬脆性材料加工技术、加工过程耗能评价。

量消耗,结果表明,此模型能够有效地预测能量消耗。邱行<sup>[6]</sup>则在工件加工过程切削能耗综合预测模型的基础上,开发出软件化的基于指数切削能耗模型。但数控机床部件繁多,机床加工能耗复杂,影响机床加工能耗的相关联因素众多,使得机床加工能耗的预测和建模变得相当困难<sup>[7]</sup>。

灰铸铁具有切削加工性能良好、耐腐蚀等特点,在生产中广泛应用。本文采用 BP 神经网络建立灰铸铁钻削过程的切削能耗与切削参数之间的关系模型,同时建立三元线性回归预测模型,对比两种预测模型的预测结果的准确性,并考虑切削参数之间的交互作用建立三维表面图,对比分析钻削过程的切削能耗与切削参数的变化规律,为实际钻削加工节能减排提供理论和实际指导。

# 1 试验条件与设计

## 1.1 试验材料与设备

采用灰铸铁 HT200 为试验材料,进行钻削试验研究。试样尺寸为 85 mm×64 mm×20 mm。机床设备为 MCV-810 加工中心,主轴最高转速 8 000 r·min<sup>-1</sup>,机床最大功率为 20 kVA,面板是 FANAC 数控系统。功率测量设备采用 WT330 系列功率仪。钻削刀具采用 YG6X 硬质合金麻花钻,试验加工功率测试平台如图 1 所示,加工过程中使用切削液,所加工的孔为通孔。




图 1 钻削加工功率测试平台  
Fig.1 Drilling power test platform

## 1.2 试验设计

采用全因素试验方法进行钻削试验,钻削参数如表 1 所示。试验组数为 64 组,每组钻削参数

表 1 试验参数

Tab.1 Test parameters

切削要素	数值
刀具直径 $d/\text{mm}$	8, 10, 12, 14
切削速度 $v_c/(\text{m} \cdot \text{min}^{-1})$	40, 60, 80, 100
进给量 $f/(\text{mm} \cdot \text{min}^{-1})$	0.16, 0.2, 0.24, 0.28

组合重复 3 次然后取平均值。

## 1.3 试验结果

图 2 为加工中心 MCV-810 在加工参数  $d=8\text{ mm}$ 、 $v_c=60\text{ m} \cdot \text{min}^{-1}$ 、 $f=0.16\text{ mm} \cdot \text{r}^{-1}$  时的钻削功率曲线,钻削过程的总加工功率由待机、空载及切削功率组成,本文研究的切削能耗为切削功率与钻孔时间的乘积,如公式(1)和(2)所示。

$$T_c = \frac{I_d}{n \times f} \tag{1}$$

$$E_c = P_c \times T_c \tag{2}$$

式中,  $T_c$  为钻单个孔所用时间, min;  $I_d$  为钻孔深度, mm;  $n$  为主轴转速,  $\text{r} \cdot \text{min}^{-1}$ ;  $E_c$  为切削能耗, J;  $P_c$  为切削功率, W。




图 2 加工中心 MCV-810 钻削功率曲线  
Fig.2 Drilling power curve of MCV-810

# 2 切削能耗预测模型建立

## 2.1 确定 BP 神经网络结构

随机初始化一组网络连接权重和阈值。然后,使用训练样本调整网络连接权重和阈值。经过反复学习训练,当网络输出值和训练样本的均方误差(MSE)达到误差目标时,调整过程终止。BP 算法是一个很有效的算法,许多问题都可由它来解决,其算法程序如图 3 所示<sup>[8]</sup>。

BP 神经网络通常采用三层结构,分别为输入层、隐藏层和输出层,它们互相连接,各层的每个神经元都会连接到下一层的所有神经元。如图 4 所示,本文 BP 神经网络结构的输入层为切削速度、进给量和刀具直径,输出层为切削能耗,中间层为隐藏层,隐层节点数目需合理,实际中应用公式来确定。根据前人经验,参照式(3)设计。

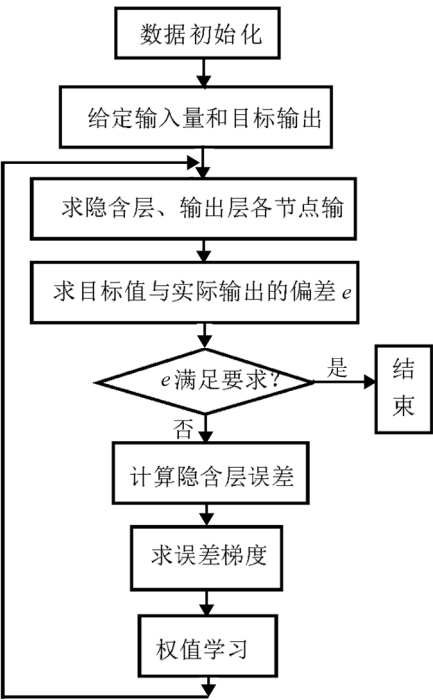


图 3 BP 神经网络算法程序框图

Fig.3 Flow chart of BP neural network algorithm




图 4 BP 神经网络结构

Fig.4 BP neural network structure

其中, $L$ 为隐层节点数; $m$ 为输入层节点数; $n$ 为输出节点数; $a$ 为 $[0, 10]$ 之间的常数,一般取 $3\sim 6$ 。

2.2 确定 BP 神经网络样本

预测样本可以有规律地选择。因为刀具直径的大小对切削能耗的影响较大,而且切削速度和进给量对切削能耗的影响规律不一样,因此考虑每种刀具直径选择 4 组,切削速度以 40、60、80、100  $\text{m} \cdot \text{min}^{-1}$  分 4 组,进给量以 0.16、0.2、0.24、

0.28  $\text{mm} \cdot \text{r}^{-1}$  每一大组循环,由此得到 16 组预测样本。每种切削速度和进给量的数据一样多,其余 48 组作为训练样本。

2.3 建立和训练 BP 神经网络

在训练和测试之前,为了数据处理的方便,保证程序运行收敛加快,采用 `premnmx` 函数将输入数据归一化到  $-1\sim 1$ 。隐层中的 `tansig` 传递函数和输出层中的 `purelin` 传递函数用于映射切削能耗值。选择 `trainscg` 量化共轭梯度算法训练函数作为实现 BP 神经网络训练功能。根据式(3)隐层节点在 5~8,通过 BP 神经网络误差的比较,当隐层节点为 8 时误差最小,由此将 BP 神经网络隐层节点数取为 8。进行 BP 神经网络基本训练参数设定,网络最大迭代次数为 10 000 次,学习速率为 0.05,次数显示间隔为 50,目标误差为  $10^{-3}$ ,二次求导对权值调整的影响参数为  $5.0\times 10^{-5}$ ,Hessian 矩阵不确定性调节参数  $5.0\times 10^{-7}$ ,均方误差为  $1.0\times 10^{-4}$ 。

如图 5 所示,均方误差随着迭代次数的增加而减小,直到 243 次迭代停止。测试数据的预测值与实验值之间的相关系数  $R$  为 0.999 83,如图 6 所示,显示其拟合效果很好,刀具直径、切削速度、进给量和切削能耗之间存在很强的相关性。由图 7 可以看出测试样本切削能耗实验值和预测值较为一致。保存使用所选参数训练好的 BP 神经网络模型,调用网络模型将整体 64 组试验样本代入进行预测,图 8 其  $R$  值为 0.999 54。




图 5 均方误差 (MSE) 随时间的变化

Fig.5 Variation of mean square error (MSE) over time




图 6 预测值与测试数据之间的相关性  
Fig.6 Correlation between the predicted value and the test data




图 8 预测值与全部数据之间的相关性  
Fig.8 Correlation between the predicted value and the total data




图 7 切削能耗实验值和预测值的比较  
Fig.7 Comparison of experimental values and predicted values of cutting energy consumption




图 9 切削能耗三元回归  
Fig.9 Ternary regression of cutting energy consumption

2.4 切削能耗三元线性回归预测模型的建立

对钻削过程的切削能耗进行三元回归拟合,分析刀具直径、切削速度、进给量对钻削过程切削能耗的影响。经过拟合分析,得到如图 9 所示切削能耗三元线性回归图,并建立钻削过程的切削能耗三元线性回归预测模型,如式(4)所示。其相关系数  $R^2$  是检测三元线性回归预测模型的重要指标,其值越接近于 1,表明所建立的预测模型拟合效果越好。式(4)的  $R^2$  值为 0.970 86,说明所建立的三元线性回归预测模型拟合效果很好,可以用于钻削过程切削能耗的预测。由式(4)可看出,切削能耗随刀具直径的增加和进给量、切削

速度的降低而变大,其影响主次为  $d > f > v_c$ ,  $f$  和  $v_c$  对切削比能耗的影响都为正效应,且程度相当,而  $d$  则呈负效应。

$$E_c = 0.643\ 01d^{1.251\ 58}v_c^{-0.551\ 46}f^{-0.660\ 12} \quad (4)$$

3 试验结果与分析

3.1 切削能耗预测模型误差分析

根据 BP 神经网络和三元线性回归预测模型,可预测出 64 组试验的切削能耗。在此列出神经网络测试样本的 16 组试验数据、预测结果及相对误差对比,如表 2 所示。经过比对分析,神经网络预测值相对误差比较小,都在 1.5%之内,其平均相对误差为 0.635%,三元回归预测值相对误差

最大为 14.133%,其平均相对误差为 5.793%。根据图 10 也可看出,切削能耗的实测值与 BP 神经网络预测值的曲线非常贴近,而三元回归的预测值则有点偏离,由此说明 BP 神经网络预测模型

预测值的精度和稳定性明显比三元线性回归预测模型高,通过训练的 BP 神经网络在预测切削能耗方面具有良好的准确性,对钻削过程的切削能耗预测研究具有一定应用价值和指导意义。


表 2 试验数据、预测结果及相对误差对比  
Tab.2 Test data, predicted results and comparison of relative errors

实验组别	d/ mm	$v_c/$ ( $m \cdot min^{-1}$ )	$f/$ ( $mm \cdot r^{-1}$ )	实测值 $E_c/kJ$	神经网络预测值 $E_c/kJ$	三元回归预测值 $E_c/kJ$	神经网络预测 相对误差/%	三元回归预测 相对误差/%
1	8	40	0.16	4.279	4.302	3.805	0.520	11.080
2	8	60	0.20	2.554	2.522	2.626	1.265	2.816
3	8	80	0.24	1.902	1.897	1.986	0.260	4.420
4	8	100	0.28	1.437	1.437	1.586	0.003	10.380
5	10	40	0.16	5.804	5.763	5.031	0.703	13.320
6	10	60	0.20	3.317	3.337	3.472	0.618	4.676
7	10	80	0.24	2.429	2.400	2.627	1.183	8.149
8	10	100	0.28	1.975	1.996	2.098	1.063	6.194
9	12	40	0.16	6.018	6.076	6.321	0.963	5.027
10	12	60	0.20	4.313	4.257	4.362	1.283	1.140
11	12	80	0.24	3.295	3.316	3.300	0.641	0.151
12	12	100	0.28	2.652	2.649	2.635	0.119	0.630
13	14	40	0.16	7.554	7.529	7.666	0.337	1.477
14	14	60	0.20	5.099	5.121	5.290	0.434	3.745
15	14	80	0.24	4.229	4.214	4.002	0.351	5.356
16	14	100	0.28	3.722	3.707	3.196	0.417	14.133


3.2 切削参数对切削能耗的影响分析

由图 10 可看出,刀具直径、切削速度、进给量对切削能耗的影响趋势与三元回归预测模型的指数完全一致。图 11 为 64 组整体样本范围内 BP 神经网络切削能耗预测值与切削参数之间的三维表面图,其只固定一个而同时考虑两个切削参数对切削能耗的交互作用。从图 11(a)可看出,同时提高进给量和切削速度,切削能耗反而降低。在刀具直径固定的情况下,切削参数值越高,机床会输出更高的负载,切削能耗理应越大,但此种情况下,随着切削参数值的增加,能耗反而急剧下降。这表明加工时间主导着能源消耗,切削参数值越高,材料去除率就会越大,加工时间反而缩短,最终导致切削能耗降低。图 11(b)  $v_c = 60 m \cdot min^{-1}$ 和图 11(c)  $f = 0.2 mm \cdot r^{-1}$ 都与刀具直径有交互作用,增大刀具直径,切削能耗急剧增


高,可见刀具直径对切削能耗有很大的影响,但实际加工中考虑刀具直径对切削能耗的影响意义不大。因此从减小切削能耗的角度分析,在满足加工质量前提下,钻削灰铸铁时优先选择较大的进给量和切削速度更有利于节能降耗。








(b)  $d=8\text{ mm}$ ,  $f=0.24\text{ mm}\cdot\text{r}^{-1}$




(c)  $d=8\text{ mm}$ ,  $v_c=60\text{ m}\cdot\text{min}^{-1}$


图 10 切削参数对切削能耗实测值和预测值的影响  
Fig. 10 Effect of cutting parameters on the measured and the predicted values of cutting energy consumption



(a)  $d=8\text{ mm}$



(b)  $v_c=60\text{ m}\cdot\text{min}^{-1}$



(c)  $f=0.2\text{ mm}\cdot\text{r}^{-1}$

图 11 BP 神经网络预测值与切削参数之间的三维表面图  
Fig. 11 Three-dimensional surface graph between BP neural network predictions and cutting parameters

4 结论

1)采用 BP 神经网络模型对钻削过程的切削能耗进行预测。将 BP 神经网络预测模型与三元线性回归预测模型进行比较发现,BP 神经网络预测模型的预测值相对误差较小,都在 1.5%之内,其平均相对误差为 0.635%,其预测精度和稳定性均比三元线性回归预测模型高,说明通过训练的 BP 神经网络模型能较准确地预测切削能耗,对钻削过程的切削能耗预测研究具有一定应用价值和指导意义。

2)通过切削参数对灰铸铁钻削过程中切削能耗实测值和预测值的影响分析,切削能耗随刀具直径的增加和进给量、切削速度的降低而变大。在刀具直径不变情况下,随着切削参数值的增加,

能耗急剧下降,加工时间主导了能量消耗,即使在较高负荷的情况下,总能耗也会降低。因此从减小切削能耗的角度分析,在满足加工质量的前提下,钻削灰铸铁时应优先选择较大的进给量和切削速度更有利于节能降耗。

参考文献:

[1] He Y, Liu B, Zhang X, et al. A modeling method of task-oriented energy consumption for machining manufacturing system [J]. Journal of Cleaner Production, 2012, 23(1): 167-174.

[2] Sangwan K S, Kant G, Deshpande A, et al. Modeling of Stresses and Temperature in Turning Using Finite Element Method [J]. Applied Mechanics & Materials, 2013, 307: 174-177.

[3] 谢东,陈国荣,施金良,等.基于 BP 神经网络数控机床切削能耗的研究[J].机床与液压,2012,40(1):54-57.

[4] 陈薇薇,张华,向琴,等.基于支持向量机数控机床切削能耗预测方法研究[J].机械设计与制造,2014(11):54-56.

[5] Zeng Y R, Zeng Y, Choi B, et al. Multifactor-Influenced Energy Consumption Forecasting Using Enhanced Back-propagation Neural Network [J]. Energy, 2017, 127: 381-396.

[6] 邱行.工件加工过程切削能耗的预测方法研究及应用系统开发[D].重庆:重庆大学,2016.

[7] Kant G, Sangwan K S. Predictive Modeling for Energy Consumption in Machining Using Artificial Neural Network [J]. Procedia Cirp, 2015, 37: 205-210.

[8] 胡伍生.神经网络理论及其工程应用[M].北京:测绘出版社,2006:63-76.

(责任编辑:陈雯)

(上接第 522 页)

[5] Sun Y, Ma Z, Tang G, et al. Estimation method of state-of-charge for lithium-ion battery used in hybrid electric vehicles based on variable structure extended kalman filter [J]. Chinese Journal of Mechanical Engineering, 2016, 29(4): 717-726.

[6] Gregory L P. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs; Part 3. State and parameter estimation [J]. Journal of Power Sources, 2004, 134(2): 277-292.

[7] Jayasinghe J, Nadishan K. Neural network based state of charge (SOC) estimation of electric vehicle batteries [J]. University of Moratuwa, 2014, 4(12): 1-4.

[8] 鲍慧,于洋.基于安时积分法的电池 SOC 估算误差校正[J].计算机仿真,2013,30(11):148-151.

[9] Liu X, Wu J, Zhang C. et al. A method for state of energy estimation of lithium-ion batteries at dynamic currents and temperatures [J]. Journal of Power Sources, 2014, 270: 151-157.

[10] 李哲,卢兰光,欧阳明高.提高安时积分法估算电池 SOC 精度的方法比较[J].清华大学学报,2010,50(8): 1293-1296.

[11] 赵昂,成勇,杨晓军,等.一种电池 SOC 的检测方法及装置:106154176A [P]. 2016-11-23.

(特约编辑:黄家瑜)