

文章编号: 2095-2163(2021)01-0130-04

中图分类号: U491.1

文献标志码: A

高速铣削工件表面粗糙度蚁群-BP神经网络建模

祁翔, 张心光, 吕泽正

(上海工程技术大学机械与汽车工程学院, 上海 201620)

摘要: 由于蚁群算法具有很好的多样性、兼容性和正反馈, 故十分适合用于BP神经网络学习率的优化, 从而建立蚁群-BP神经网络。训练样本对是以实验1、实验3、实验5、实验7、实验9、实验11、实验13和实验15下的高速铣削试验数据组成的, 并用高速铣削实验中的工件表面粗糙度来建模。使用创建的高速铣削工件表面粗糙度预测模型来对实验2和实验6状态中的高速铣削工件表面粗糙度进行预测, 通过对比预测结果和试验结果, 可发现蚁群-BP神经网络能够十分有效地对高速铣削工件表面粗糙度进行建模预测。

关键词: 高速铣削; 表面粗糙度; 预测; 蚁群-BP人工神经网络

Modeling of high speed milling workpiece by surface roughness method

QI Xiang, ZHANG Xinguang, LV Zezheng

(School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] Because ant colony algorithm has good robustness, compatibility and positive feedback, it is very suitable for optimizing the learning rate of BP neural network, so as to establish ant colony-BP neural network. The training sample pair is composed of high-speed milling test data under experiment 1, experiment 3, experiment 5, experiment 7, experiment 9, experiment 11, experiment 13 and experiment 15, and the surface roughness of workpiece in high-speed milling experiments is used to model. The surface roughness prediction model of high-speed milling workpiece is established to predict the surface roughness of high-speed milling workpiece in experiment 2 and experiment 6. By comparing the prediction results with the experimental results, it is found that ant colony-BP neural network can effectively model and predict the surface roughness of high-speed milling workpiece.

[Key words] high speed milling; surface roughness; prediction; ant colony algorithm-BP artificial neural network

0 引言

高速铣削工件表面质量的重要指标之一是高速铣削工件表面粗糙度^[1]。高速铣削工件表面粗糙度预测模型可为解决高速铣削过程中存在一些无法解释且极易导致加工质量不稳定的问题提供参考^[2]。高速铣削工件表面粗糙度预测建模常采用曲线拟合^[3]、人工神经网络^[4]等方法。预测建模通常使用曲线拟合方法, 但是这种模型会存在假定数学模型和实际数学模型匹配度低致使预测误差偏大。人工神经网络克服了曲线拟合的固有缺陷, 具有结构简单、算法易实现等优点, 在分类、预测、控制中都得到了广泛的应用。张思思等人^[5]就在聚类和人工神经网络的基础上研发出了遥感信息提取的方法。阮羚等人^[6]为了让电力系统可以满足变压器风险评估与资产管理的需求, 研究提出了一种将人工神经网络和信息融合技术应用于评估方法中的变压器状态评估方法。韩庆兰等人^[7]将BP人工神经网络应用在物流配送中心的选址决策上, 最终获得了不错的效果。但是, 人工神经网络的待调参数

较多, 包括学习次数、学习率等, 且大多数待调参数的选取缺乏理论指导^[8-10]。针对人工神经网络的缺陷, 文中使用蚁群优化算法^[11]对BP神经网络学习率进行优化的预测模型, 提出了蚁群-BP神经网络。本次研究中主要运用实验1、实验3、实验5、实验7、实验9、实验11、实验13和实验15这八个实验状况下的高速铣削试验数据对训练样本对进行构建, 再使用此结果对高速铣削工件表面粗糙度进行预测建模。接下来, 将利用基于蚁群-BP神经网络的高速铣削工件表面粗糙度预测模型分别对实验2与实验6情形下的高速铣削工件表面粗糙度进行预测, 最后对预测结果和记录的试验结果通过对比验证, 可以发现蚁群-BP神经网络能够十分有效地对高速铣削工件表面粗糙度进行建模预测。

1 方法概述

1.1 蚁群算法

蚁群算法(Ant Colony Optimization, ACO)是一种受自然界中蚂蚁寻找食物行为而启发的一种模拟优化算法, 通常用来解决寻找最短路径的问题。这

作者简介: 祁翔(1995-), 男, 硕士研究生, 主要研究方向: 机器学习。

收稿日期: 2020-09-23

种算法最早是 1992 年, 由意大利学者 Marco Dorigo 在其博士论文中提出的, 由于蚁群算法具有多样性、正反馈和兼容性等良好特性, 所以现已广泛应用在旅行商问题 (TSP) 和资源二次分配等研究中。这里, 拟对蚁群算法的基本原理做阐释分述如下。

(1) 自然界中蚂蚁寻找食物时在经过的路上会留下一种名为信息素的物质, 这为其他的蚂蚁寻找食物留下了一定的参考物。

(2) 当蚂蚁寻找食物的过程中遇到了没有蚂蚁走过或者没有信息素的岔口时, 该蚂蚁就会随机选择一个方向移动, 同时留下信息素。

(3) 蚂蚁留下的信息素具有一种很好的特性——在单位时间内相对于路途比较短的路径, 路途比较长的路径上的信息素会具有的挥发性强的特点, 而且路途比较短的路径上的信息素积累得比路途比较长的路径上的快, 这样后面再有蚂蚁遇到类似的情况就会选择信息素浓度比较高的路径。

(4) 如此一来, 信息素浓度高的路径会被更多的蚂蚁选择, 反复迭代后就得到最优路径。

(5) 至此, 蚂蚁就会寻找到最优的觅食途径。

综上所述, 更容易看出蚁群算法中的所有个体都具有相互联系的交流机制, 同时全部蚁群个体都为完成一个共同的目标, 最终不断积累便产生了最优路径, 由于这一特性就使得蚁群算法尤为适用于解决 BP 神经网络中的相关数据问题。

1.2 蚁群-BP 神经网络

用蚁群算法优化 BP 神经网络的具体操作流程如下:

(1) 假设最大迭代次数为 N_m , 蚂蚁数量为 S , 在集合 $I_{pi}(1 \leq i \leq m)$ 的元素 j 所对应的信息元素设为 $\tau_j(I_{pi})(t) = C$, ($1 \leq j \leq N$), 在此基础上设置路径选择规则: 在集合 I_{pi} 前提下, 令所有的蚂蚁 k , 以概率公式(1) 选择第 j 个元素。数学计算公式如下:

$$\text{Prob}(t_j^k(I_{pi})) = (t_j(I_{pi})) / \sum_{u=1}^N t_u(I_{pi}), \quad (1)$$

(2) 让全部蚂蚁从集合 $I_{pi}(1 \leq i \leq m)$ 中出发, 并且按上述路径选择规则在全部集合中按顺序寻找食物源。

(3) 所有蚂蚁会在各个集合中选择一个元素, 此时需要记录蚂蚁所选择的权值并且把该权值当作 BP 神经网络的参数, 这样就可以求得训练样本的输出误差值, 根据这个误差值可以选择出研究所指定参数的最优解。

(4) 对于 $I_{pi}(1 \leq i \leq m)$ 集合中元素信息素的优

化, 主要按照公式(2)来处理:

$$\tau_j(I_{pi})(t+m) = \rho \tau_j(I_{pi})(t) + \Delta \tau_j(I_{pi}), \quad (2)$$

$$\Delta \tau_j(I_{pi}) = \sum_{k=1}^s \Delta t_j^k(I_{pi}), \quad (3)$$

$$\Delta t_j^k(I_{pi}) = Q/e^k, k = I_{pi}, \quad (4)$$

$$e^k = \max_{n=1}^h |O_n - O_q|. \quad (5)$$

在式(2)中, $\rho(0 \leq \rho \leq 1)$ 表示信息素的持久性; $1 - \rho$ 表示在 $t \sim t + m$ 时间段的信息下降程度; $\Delta t_j^k(I_{pi})$ 表示该次循环中蚂蚁 k 在 $I_{pi}(1 \leq i \leq m)$ 集合中第 j 个元素 P_j 中所留下的信息素; 在式(4)中, 如果 $k \neq I_{pi}$ 则 $\Delta t_j^k(I_{pi}) = 0$; Q 表示蚂蚁完成一次循环所留下的所有信息素和; e 表示全部训练样本的最大输出误差。

还要指出, 公式(5)主要表示当 e 作为第 k 只蚂蚁所选择的元素、且用作 BP 神经网络的权值时, 全部训练样本的最大输出误差。其中, h 表示样本数目, O_n 表示神经网络的实际输出值, O_q 表示神经网络的期望输出值。

由公式(2)~(5)可得, 当输出误差不大时, 信息素会越来越大, 形成正反馈机制。重复执行以上各步骤, 将发现所有蚂蚁的路径会不断地趋于相同, 当所有蚂蚁的路径都趋于相同时, 迭代过程就完成了, 此时会得到最优解, 算法结束。

2 方法验证

本篇文章中所使用的高速铣削试验数据都来源于文献[2], 见表 1。高速铣削数据来自于 16 组实验。在每个实验中, 表面粗糙度的值主要受主轴转速、进给速度、切削深度、切削行距和刀具倾角这五个参数影响。

用实验 1、实验 3、实验 5、实验 7、实验 9、实验 11、实验 13 和实验 15 中的切削深度和切削行距的数据来构建训练样本输入向量, 使用这 8 个实验的表面粗糙度数据来构建学习样本输出向量, 最后基于蚁群-BP 神经网络来对高速铣削工件表面粗糙度进行预测建模。

当蚁群-BP 神经网络进行高速铣削工件表面粗糙度建模, 蚁群算法优化参数为学习速率, 训练误差目标为 $1e^{-5}$, 最大迭代次数为 1 000。不同蚂蚁规模下的学习速率的优化过程如图 1 所示, 最优学习率见表 2。

表1 实验参数及结果

Tab. 1 Experimental parameters and results

试验次数	主轴转速/ ($r \cdot \min^{-1}$)	进给速度/ ($\text{mm} \cdot \min^{-1}$)	切削深度/ /mm	切削行距/ /mm	表面粗糙度/ / μm	刀具倾角/ / $^\circ$
1	5 000	5 000	0.02	0.01	0.725 8	10
2	5 000	6 000	0.04	0.03	1.115 6	20
3	5 000	7 000	0.06	0.05	1.008 6	30
4	5 000	8 000	0.08	0.07	1.177 2	40
5	10 000	5 000	0.04	0.05	0.901 2	40
6	10 000	6 000	0.02	0.07	1.086 8	30
7	10 000	7 000	0.08	0.01	1.866 0	20
8	10 000	8 000	0.06	0.03	1.984 8	10
9	15 000	5 000	0.06	0.07	2.041 8	20
10	15 000	6 000	0.08	0.05	1.726 4	10
11	15 000	7 000	0.02	0.03	1.138 6	40
...
16	20 000	8 000	0.02	0.05	1.254 6	20

表2 不同蚂蚁规模下的学习速率优化结果

Tab. 2 Results of learning rate optimization under different ant sizes

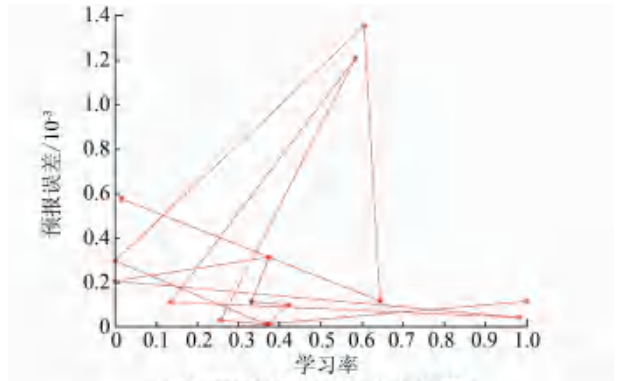
蚂蚁规模	最优学习率	高速铣削工件表面粗糙度建模预报误差
15	0.367 0	$1.254 0 e^{-4}$
25	1.000	$7.194 2 e^{-4}$
35	0.884 9	$1.944 7 e^{-4}$
45	0.836 8	$1.482 2 e^{-6}$

通过对表2进行筛选,可确定当蚁群规模为45时,学习效率最优,故蚁群-BP神经网络选用最优学习率为0.8368,迭代次数为1000,训练误差目标为 $1e^{-5}$,进行高速铣削工件表面粗糙度建模。为验证蚁群-BP神经网络所建立的高速铣削工件表面粗糙度预测数学模型,选用实验2和实验6中的高速铣削工件表面粗糙度的数据进行预测估计,通过对比预测模型所产生的这两组预测数据和试验中产生的数据见表3。

表3 表面粗糙度蚁群-BP神经网络预测模型预测结果和实验结果的对比


Tab. 3 Comparison of prediction results and experimental results for surface roughness ant colony - BP neural network model

工况	预测结果	实验结果	绝对误差	相对误差
	/ μm	/ μm	/ μm	/%
2	1.126 7	1.115 6	0.011 1	0.99
6	1.098 1	1.086 8	0.011 3	1.04



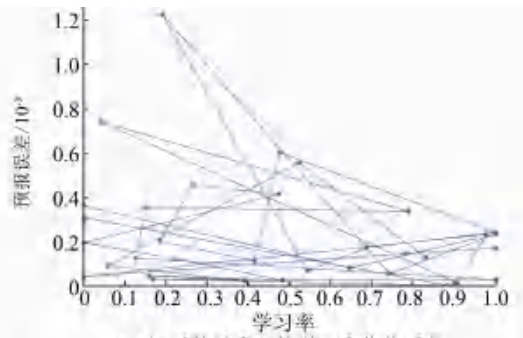
(a) 蚁群数量为15的学习率优化过程

(a) The learning rate optimization process with 15 ant colonies




(b) 蚁群数量为25的学习率优化过程

(b) The learning rate optimization process with 25 ant colonies



(c) 蚁群数量为35的学习率优化过程

(c) The learning rate optimization process with 35 ant colonies



(d) 蚁群数量为45的学习率优化过程

(d) The learning rate optimization process with 45 ant colonies

图1 不同蚁群规模下的学习速率的优化过程

Fig. 1 The optimization process of learning rate under different ant colony scales

当对高速铣削工件表面粗糙度建模采用基于 BP 神经网络时,学习速率参数选取为 0.500,迭代次数选取为 1 000,训练误差目标选取为 $1e^{-5}$ 。为验证 BP 神经网络所建立的高速铣削工件表面粗糙度预测数学模型,选用实验 2 和实验 6 中的高速铣削工件表面粗糙度的数据进行预测估计,预测结果和试验结果的比较见表 4。

表 4 表面粗糙度 BP 神经网络预测模型
预测结果和实验结果的对比

Tab. 4 Comparison of prediction results and experimental results of surface roughness neural network prediction model

工况	预测结果 / μm	实验结果 / μm	绝对误差 / μm	相对误差 /%
2	1.162 8	1.115 6	0.047 2	4.23
6	1.123 6	1.086 8	0.036 8	3.39

由表 3 和表 4 分析可知,基于蚁群-BP 神经网络所构建的高速铣削工件表面粗糙度预测模型在精确度方面是明显胜过基于 BP 神经网络所构建的高速铣削工件表面粗糙度预测模型,由此可以证明蚁群-BP 神经网络是一种对高速铣削工件表面粗糙度建模的更加有效的方法。

3 结束语

本文主要采用基于蚁群优化算法和 BP 神经网络结合的方法构建蚁群-BP 神经网络。再分别使用 BP 神经网络和蚁群-BP 神经网络来对高速铣削工件表面粗糙度进行建模和预测,通过对比记录运行模型产生的预测数据和试验数据可发现基于蚁群-

BP 神经网络所创建的高速铣削工件表面粗糙度预测模型具有相对误差率较低和精度较高的预测结果。然而,不同蚂蚁规模下的学习速率优化结果不同,下一步研究工作将集中在蚂蚁规模选取方面,以期获得 BP 神经网络最佳学习率。

参考文献

- [1] 张宝磊,李聪,覃金昌,等. 基于 BP 和 GRNN 神经网络的高速铣削 TC4 粗糙度预测[J]. 桂林航天工业学院学报,2015(4):502-505.
- [2] 王义强,闰国琛,王晓军,等. 高速铣削工件表面粗糙度的预测[J]. 机械设计与制造,2014(11):131-133,137.
- [3] 关祥宏. 基于安全性分析的深基坑变形实测与曲线拟合方法研究[J]. 施工技术,2020,49(11):109-112.
- [4] 杨帆,周敏,金继民,等. 智能优化算法及人工神经网络在催化裂化模型分析中的应用进展[J]. 石油学报(石油加工),2020,36(4):878-888.
- [5] 张思思,高旭光,滑文强. 基于聚类与人工神经网络的遥感图像信息提取方法[J]. 电子设计工程,2020,28(15):106-109.
- [6] 阮羚,谢齐家,高胜友,等. 人工神经网络和信息融合技术在变压器状态评估中的应用[J]. 高电压技术,2014,40(3):822-828.
- [7] 韩庆兰,梅运先. 基于 BP 人工神经网络的物流配送中心选址决策[J]. 中国软科学,2004(6):140-143.
- [8] 董海龙,汤旻安,程海鹏. 非均衡交通流五岔路口交通信号智能控制研究[J]. 郑州大学学报(工学版),2017,38(1):68-73.
- [9] 王山海,景新幸,杨海燕. 基于深度学习神经网络的孤立词语音识别的研究[J]. 计算机应用研究,2015,32(8):2289-2291,2298.
- [10] 许新征,丁世飞,史忠植,等. 一种基于 QPSO 的脉冲耦合神经网络参数的自适应确定方法[J]. 模式识别与人工智能,2012,25(6):909-915.
- [11] 刘永健,曾国辉,黄勃. 改进蚁群优化算法的机器人路径规划研究[J]. 传感器与微系统,2020,39(4):56-58,62.

(上接第 129 页)

- [14] 孔锐,蔡佳纯,黄钢. 基于生成对抗网络的对抗攻击防御模型[J/OL]. 自动化学报: 1-21 [2020-07-23]. <https://doi.org/10.16383/j.aas.c200033>.
- [15] DWORC C, MCSHERRY F, NISSIM K, et al. Calibrating noise to sensitivity in private data analysis[M]//HALEVI S, RABIN T. Theory of Cryptography. TCC 2006. Lecture Notes in Computer Science. Berlin:Springer, 2006,3876:265-284.
- [16] 鲍海燕,芦彩林. 基于改进 RSA 算法的隐私数据集同态加密方法[J]. 太赫兹科学与电子信息学报,2020,18(5):929-933.
- [17] 赵秀凤,付雨,宋巍涛. 循环安全的同态加密方案[J]. 计算机研究与发展,2020,57(10):2117-2124.
- [18] 全秦玮,李洁,王洁,等. 一种基于智能合约的全同态加密方

- 法[J]. 网络空间安全,2020,11(9):32-38.
- [19] YAO C C. Protocols for secure computations (Extended Abstract) [C]// 23rd Annual Symposium on Foundations of Computer Science. Chicago, Illinois, USA:IEEE,1982:160-164.
- [20] 李强,颜浩,陈克非. 安全多方计算协议的研究与应用[J]. 计算机科学,2003(8):52-55.
- [21] CHANDIRAMANI K, GARG D, MAHESWARI N. Performance analysis of distributed and federated learning models on private data[J]. Procedia Computer Science, 2019,165:349-355.
- [22] 罗长银,陈学斌,马春地,等. 面向区块链的在线联邦增量学习算法[J/OL]. 计算机应用: 1-11 [2020-08-17]. <http://kns.cnki.net/kcms/detail/51.1307.TP.20200814.1034.002.html>.