

doi: 10.3969/j.issn.1001-3849.2021.07.006

遗传算法-模糊径向基神经网络模型预测自润滑镀层耐磨性

王亚利^{1*}, 于继明², 王艺³

(1. 济源职业技术学院, 河南 济源 459000; 2. 金陵科技学院, 江苏 南京 211169; 3. 中国石油化工股份有限公司西南油气分公司, 四川 成都 610041)

摘要: 针对传统神经网络模型存在的缺陷, 引入遗传算法和模糊运算建立遗传算法-模糊径向基神经网络模型(GA-FRBFNNM), 介绍了模型结构和仿真思路。以自润滑镀层耐磨性为研究主题开展正交实验, 在正交实验结果中任取10组数据作为训练样本用于模型训练, 其余6组数据作为测试样本用于模型性能测试。结果表明: GA-FRBFNNM的预测值更接近于真实值, 其预测精度明显高于相同结构的径向基神经网络模型, 验证了该模型是有效的, 能够更准确预测自润滑镀层耐磨性。主要归因于引入模糊运算使得径向基神经网络全部节点都具有特定意义, 另外引入遗传算法优化了训练算法, 避免了模型陷入局部极小点等问题, 使得模型性能得到有效提升。

关键词: 自润滑镀层; 摩擦因数; 遗传算法-模糊径向基神经网络模型; 径向基神经网络模型

中图分类号: TG174 文献标识码: A

Prediction of Wear Resistance of Self-Lubricating Coating by Genetic Algorithm-Fuzzy Radial Basis Function Neural Network Model

WANG Yali^{1*}, YU Jiming², WANG Yi³

(1. Jiyuan Vocational and Technical College, Jiyuan 459000, China;

2. Jinling Institute of Technology, Nanjing 211169, China;

3. China Petroleum & Chemical Corporation Southwest Oil & Gas Branch, Chengdu 610041, China)

Abstract: Aiming at the defects of traditional neural network model, the genetic algorithm-fuzzy radial basis function neural network model (GA-FRBFNNM) was established by introducing the genetic algorithm and fuzzy operation, and the structure and simulation thoughts of the model were introduced. Orthogonal experiment was carried out with the wear resistance of self-lubricating coating as the research theme, and any ten groups of data in the orthogonal experiment results were taken as training samples for model training, and other six groups of data were taken as test samples for model performance testing. The results showed that the predicted value of GA-FRBFNNM was closer to the real value, and its prediction accuracy was significantly higher than that of the radial basis neural network model with the same structure, which indicated that the model was effective and it can accurately predict the wear resistance of self-lubricating coating. It was mainly attributed to the introduction of fuzzy operation, which makes all nodes of RBF neural network have specific meaning. In addition, the introduction of genetic algorithm to optimize the training algorithm, which avoids the model falling into local minimum point and other problems, thus effectively improving the model performance.

收稿日期: 2021-01-13

修回日期: 2021-03-16

*通信作者: 王亚利, access082001@126.com

基金项目: 河南省科技厅科技攻关项目(202102210384)

Keywords: self-lubricating coating; coefficient of friction; genetic algorithm-fuzzy radial basis neural network model; radial basis neural network model

自润滑镀层具有自润滑和减摩功能,可以改善金属表面的摩擦性能,因此受到广泛关注,具有良好的应用前景。目前研究和应用较多的是电镀Ni基、Ni-W基自润滑镀层及化学镀Ni-P基、Ni-W-P基自润滑镀层,无论哪种自润滑镀层,摩擦因数都是关键指标^[1-6]。然而,影响自润滑镀层摩擦因数的因素较多,例如镀液温度、电镀或化学镀时间、搅拌速度、镀液pH值、电流密度、颗粒质量浓度等,且各因素之间可能存在交互作用及复杂非线性关系。

采用传统的数学方法很难表达自润滑镀层耐磨性与其影响因素之间的复杂非线性关系。近年来,神经网络以其独特的性能优势被用来建立不同类型的、可以表达某一指标与其影响因素之间复杂非线性关系的模型^[7-10]。但这些模型都或多或少存在着缺陷,例如易陷入局部极小点、收敛速度慢等。笔者以化学镀Ni-P/MoS₂自润滑镀层(以下简称自润滑镀层)耐磨性为研究主题,针对传统神经网络模型存在的缺陷,引入遗传算法和模糊运算建立遗传算法-模糊径向基神经网络模型(GA-FRBFNNM),旨在利用遗传算法和模糊运算的特性提升模型性能,使得模型能够更准确预测自润滑镀层耐磨性。

1 自润滑镀层耐磨性的影响因素分析

自润滑镀层耐磨性的影响因素较多,如果将所有影响因素都作为模型输入,必将导致模型极其复杂,出现收敛速度慢等问题。因此,有必要筛选出与自润滑镀层耐磨性相关性较大的影响因素。采用斯皮尔曼等级相关系数^[11-12]对大部分影响因素与自润滑镀层耐磨性进行相关性分析,根据分析结果,MoS₂颗粒质量浓度与自润滑镀层耐磨性相关性最大,镀液温度、化学镀时间与自润滑镀层耐磨性相关性为显著的,因此选择镀液温度、化学镀时间和MoS₂颗粒质量浓度作为模型输入。

2 建立GA-FRBFNNM

2.1 训练样本和测试样本选取

镀液温度、化学镀时间和MoS₂颗粒质量浓度三个因素各取四个水平,分别为镀液温度80℃、

85℃、90℃、95℃,化学镀时间50 min、65 min、80 min、100 min,MoS₂颗粒质量浓度1.0 g/L、2.5 g/L、4.0 g/L、5.5 g/L。各因素水平按一定规律组合进行三因素四水平的正交实验,采用HSR-2M型摩擦磨损试验仪测试所获得自润滑镀层的摩擦因数,作为衡量自润滑镀层耐磨性优劣的指标,测试条件如下:温度25℃、载荷4.9 N、摩擦行程为8 mm。测试前清除试样表面的凸起和杂物以保证平整度,每个试样都重复测3次,摩擦因数取平均值,结果如表1所示。在表1中任取10组数据作为训练样本用于模型训练,其余6组数据作为测试样本用于模型性能测试。

表1 正交实验结果

Tab.1 Orthogonal experiment results

序号	镀液温度/℃	化学镀时间/min	MoS ₂ 颗粒质量浓度/(g·L ⁻¹)	摩擦因数
1	80	50	1.0	0.41
2	80	65	2.5	0.38
3	80	80	4.0	0.35
4	80	100	5.5	0.34
5	85	50	2.5	0.37
6	85	65	1.0	0.36
7	85	80	5.5	0.35
8	85	100	4.0	0.26
9	90	50	4.0	0.28
10	90	65	5.5	0.30
11	90	80	1.0	0.32
12	90	100	2.5	0.24
13	95	50	5.5	0.31
14	95	65	4.0	0.30
15	95	80	2.5	0.32
16	95	100	1.0	0.28

2.2 建立GA-FRBFNNM

模糊径向基神经网络是将模糊理论引入径向基神经网络,对径向基神经网络赋予模糊输入信号和模糊权值,使其全部节点都具有特定意义,对应模糊系统的隶属函数和推理过程。在径向基神经网络中,隐含层节点通过径向基函数队输入激励产生一个局部化相应,将隐含层的输出进行归一化,则形成

网络映射如公式(1)所示:

$$f(x) = \sum_{i=1}^{N_r} \lambda_i \phi_i(x) \quad (1)$$

式中: $f(x)$ 表示隐含层的输出, N_r 表示隐含层节点数量, λ_i 表示输出层和隐含层第*i*各节点之间的链接权重, $\phi_i(x)$ 表示归一化的径向基函数。

可知模糊径向基神经网络各层节点之间的最优连接参数是关键,此时的模糊径向基神经网络训练采用迭代算法,存在着易陷入局部极小点等缺陷,因此引入遗传算法,搜索模糊径向基神经网络各层节点之间的最优连接参数,从而消除该缺陷。

根据神经网络理论并结合正交实验结果建立GA-FRBFNNM,其结构如图1所示。可见该模型为五层结构,其中信号传输及各层功能如下:

第1层:输入层。将镀液温度、化学镀时间、MoS₂颗粒质量浓度作为模型输入直接连接并传至下一层。

第2层:模糊化层。输入层输入的数值由隶属度函数转化后,输出至下一层,模型选用高斯函数作为各节点隶属度函数。以镀液温度为例,假设镀液温度模糊子集数量为 R_1 ,采用K均值聚类算法计算镀液温度模糊子集的隶属度函数中心 c_{1j} ($j=1, 2, 3, \dots, R_1$),将镀液温度归一化处理至 $[0, 1]$ 区间,根据等距原则初始化各模糊子集的聚类中心 c_{1j} ,并计算初始误差 ϵ ,同时计算镀液温度样本值与聚类中心 c_{1j} 的距离。将样本值重新分配到与之距离最小的模糊子集中,重新计算镀液温度模糊子集的聚类中心 c_{1j}' ,并与原聚类中心对比,一直重复此操作直至两者差值小于误差 ϵ 。

第3层:规则层。各节点通过模糊运算与模糊化层的连接实现模糊规则的匹配,每个结点的输出为此结点所有输入信号的乘积。

第4层:归一化层。归一化层结点总数量等于规则层,用于对模型每条规则的实用度进行归一化计算。

第5层:输出层。实现自润滑镀层耐磨性的清晰化计算(去模糊化),得到最终输出值。

利用遗传算法搜索模糊径向基神经网络各层节点之间的最优连接参数,包括模糊化层中高斯函数的均值和标准差、归一化层与输出层之间的连接权重系数。

综上所述,GA-FRBFNNM预测自润滑镀层耐

磨性的流程如图2所示。使用训练样本对GA-FRBFNNM模型进行训练,当模型经多次训练后误差逐步缩小。达到设定范围时,模型可以映射镀液温度、化学镀时间、MoS₂颗粒质量浓度与自润滑镀层耐磨性,此时镀液温度、化学镀时间和MoS₂颗粒质量浓度任取某一水平输入模型,即可获得自润滑镀层的摩擦因数。

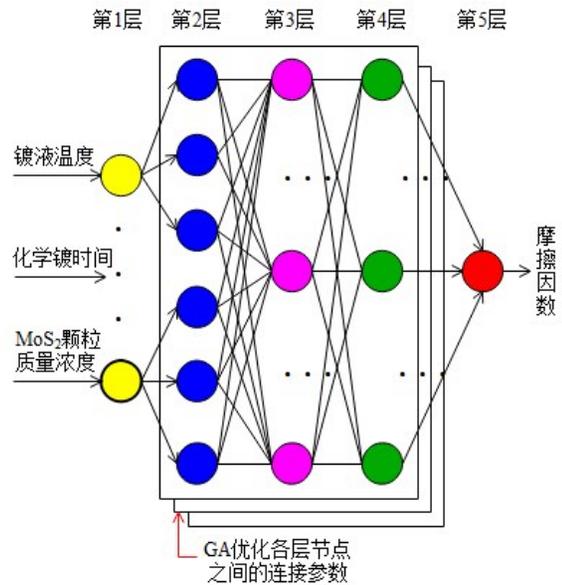


图1 GA-FRBFNNM的结构

Fig.1 Structure of FRBFNNM

3 GA-FRBFNNM 仿真与性能测试

3.1 GA-FRBFNNM 仿真

在 Matlab 软件环境下进行 GA-FRBFNNM 仿真,模型输入是镀液温度、化学镀时间、MoS₂颗粒质量浓度,输出是自润滑镀层的摩擦因数预测值。模糊径向基神经网络的第二层节点数为 5,遗传算法设置种群规模为 50,最大迭代次数为 100。图 3 所示为 GA-FRBFNNM 输入的模糊隶属度函数,结合镀液温度、化学镀时间和 MoS₂颗粒质量浓度的取值范围,划分为低、中、高三个区域。

3.2 性能测试

为了测试 GA-FRBFNNM 的有效性和准确性,将测试样本输入 GA-FRBFNNM,然后比较输出值与真实值,同时评价预测误差是否符合要求。选用相同结构的径向基神经网络模型(RBFNNM)作为对比,将测试样本也输入 RBFNNM。表 2 所示为 RBFNNM 和 GA-FRBFNNM 的预测值与真实值对

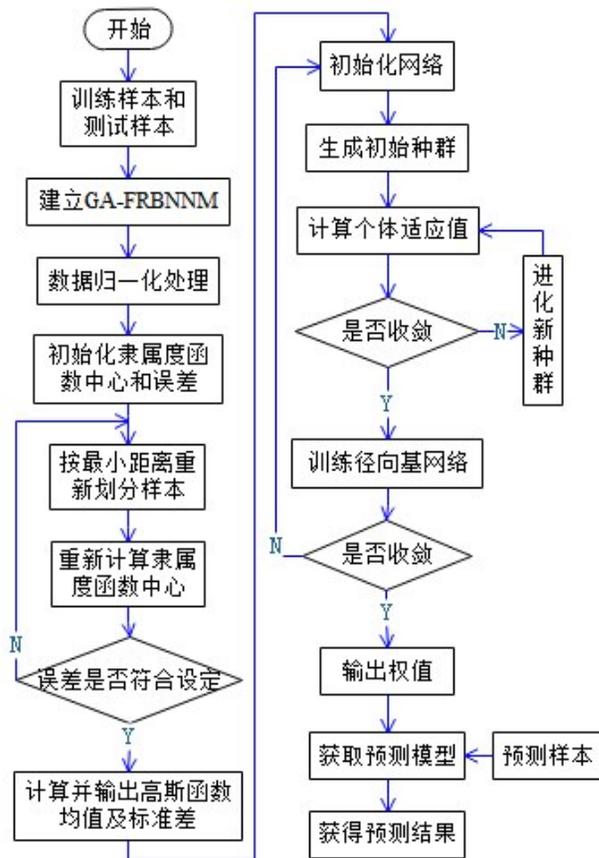


图2 GA-FRBFNN预测自润滑镀层耐磨性的流程
Fig.2 Flow for predicting the wear resistance of self-lubricating coating by GA-FRBFNN

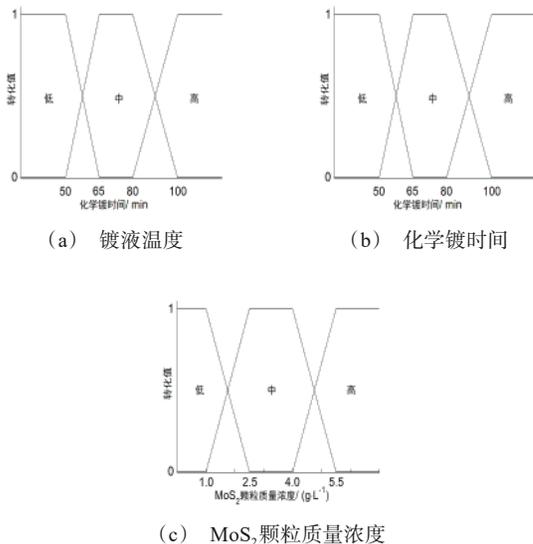


图3 GA-FRBFNN输入的隶属度函数
Fig.3 Membership function of GA-FRBFNN input

比,可见RBFNNM和GA-FRBFNNM的预测值与真实值都存在一定的误差,原因是测试样本数据量较小,并且数据的多样性不足,从而对模型的准确性造成了一定影响。相比较而言,GA-FRBFNNM的预测值更接近于真实值。

表2 RBFNNM和GA-FRBFNNM的预测值与真实值对比
Tab.2 Comparison of predicted value of RBFNNM and GA-FRBFNNM and true value

样本序号	真实值	预测值	
		RBFNNM	GA-FRBFNNM
3	0.35	0.3624	0.3531
6	0.36	0.3446	0.3604
8	0.26	0.3068	0.2522
11	0.32	0.2703	0.3192
13	0.31	0.2822	0.3039
16	0.28	0.2532	0.2817

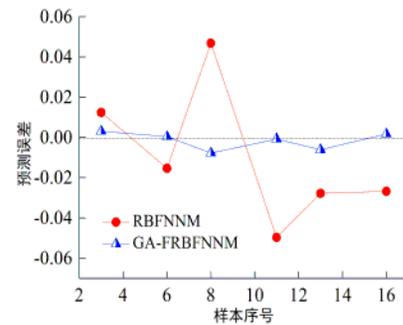


图4 RBFNNM和GA-FRBFNNM的预测误差对比

Fig.4 Comparison of prediction error of RBFNNM and GA-FRBFNNM

图4所示为RBFNNM和GA-FRBFNNM的预测误差,对于相同6组数据,RBFNNM的预测误差分别为0.0124、-0.0154、0.0468、-0.0497、-0.0278、-0.0268,GA-FRBFNNM的预测误差分别为0.0031、0.0004、-0.0078、-0.0008、-0.0061、0.0017。结合预测误差的分布规律可知GA-FRBFNNM的预测精度更高,预测误差在-0.01~+0.01范围内,表明该模型是有效的,可用于预测自润滑镀层耐磨性,获得较准确的预测值。为了进一步对比分析,取平均绝对百分比误差(简称为MAPE)和平均绝对误差(简称为MAE)作为指标,如表3所示。可知GA-FRBFNNM的MAPE和MAE相比于RBFNNM更低,进一步证实GA-FRBFNNM具有更高的预测精度,其性能优

于RBFNNM。主要归因于引入模糊运算使得径向基神经网络全部节点都具备特定意义,另外引入遗传算法优化了训练算法,避免了模型陷入局部极小点等问题。

表3 RBFNNM和GA-FRBFNNM的MAPE和MAE

Tab.3 MAPE and MAE of RBFNNM and GA-FRBFNNM

模型	MAPE	MAE
RBFNNM	9.98%	0.0298
GA-FRBFNNM	1.14%	0.003

4 结论

(1)采用斯皮尔曼等级相关系数对大部分影响因素与自润滑镀层耐磨性进行相关性分析,确定镀液温度、化学镀时间和MoS₂颗粒质量浓度作为模型输入。

(2)RBFNNM和GA-FRBFNNM的预测值与真实值都存在一定误差,相比较而言,GA-FRBFNNM的预测值更接近于真实值,具有更高的预测精度,其性能优于RBFNNM。主要归因于引入模糊运算使得径向基神经网络全部节点都具备特定意义,另外引入遗传算法优化了训练算法,避免了模型陷入局部极小点等问题。

参考文献

[1] 杨志昆. 纳米溶胶对Ni基自润滑复合镀层微观组织及性能影响的研究[D]. 哈尔滨:哈尔滨工程大学, 2014.
Yang Z K. The effect of nano-sol on the microstructure and properties of Ni-based self-lubrication composite coating[D]. Harbin: Harbin Engineering University, 2014 (in Chinese).

[2] Cheng Q, Yao Z J, Zhang F, et al. Microstructure and tribological property of Ni-MoS₂ composite coatings prepared by ultrasonic and mechanical stirring electrodeposition [J]. Materials Research Express, 2019, 6(12):126434.

[3] Sangeetha S, Kalaignan G P, Anthuvan J T. Pulse electrodeposition of self-lubricating Ni-W/PTFE nanocomposite coatings on mild steel surface[J]. Applied Surface Science, 2015, 359:412-419.

[4] He Y, Wang S C, Walsh F C. Self-lubricating Ni-P-MoS₂ composite coatings[J]. Surface and Coatings Technology, 2016, 307:926-934.

[5] Ni M, Wang S L, Li W D, et al. A novel self-lubricating Ni-

P-AlN-WS₂ nanocomposite coating[J]. Materials Research Express, 2019, 6(11):116413.

[6] Chen M, Cheng W, Zhao Z, et al. Synergistic effect between nano-ceramic lubricating additives and electroless deposited Ni-W-P coating[J]. Chinese Journal of Mechanical Engineering, 2013, 26:114-120.

[7] 宋昌熙, 郑春花, 车硕源, 等. 基于人工神经网络的固体氧化物燃料电池性能预测模型开发[J]. 集成技术, 2020, 9(5):27-33.
Song C H, Zheng C H, Cha S W, et al. Development of a simulation model for polarization characteristics of solid oxide fuel cells based on an artificial neural network[J]. Journal of Integration Technology, 2020, 9(5): 27-33 (in Chinese).

[8] 韩建军, 南少伟, 王俊伟. 基于支持向量机的有机成膜涂层混凝土碳化深度预测模型[J]. 施工技术, 2020, 49(2): 94-98.
Han J J, Nan S W, Wang J W. Carbonization depth prediction model of organic film-forming coating concrete based on support vector machine[J]. Construction Technology, 2020, 49(2):94-98 (in Chinese).

[9] 杨武, 张春燕, 马超. 基于GA-BP神经网络的镁合金微弧氧化膜层厚度预测[J]. 兵器材料科学与工程, 2017, 40(1):88-92.
Yang W, Zhang C Y, Ma C. Thickness prediction of micro-arc oxidation coating on magnesium alloy based on GA-BP neural network[J]. Ordnance Material Science and Engineering, 2017, 40(1):88-92 (in Chinese).

[10] 柯超, 甘屹, 王俊, 等. 基于BP神经网络辨识模型的PEMFC系统建模[J]. 软件工程, 2020, 23(3):14-16.
Ke C, Gan Y, Wang J, et al. PEMFC system modeling based on BPNN identification model[J]. Software Engineer, 2020, 23(3):14-16 (in Chinese).

[11] 杨军华, 李勇, 程伟. 基于最邻近相关系数的指纹室内定位新算法[J]. 西北工业大学学报, 2017, 35(4):676-682.
Yang J H, Li Y, Cheng W. A novel algorithm for fingerprinting indoor localization based on correlation coefficient[J]. Journal of Northwestern Polytechnical University, 2017, 35(4):676-682 (in Chinese).

[12] 贾晓芬, 郭永存, 黄友锐, 等. 基于斯皮尔曼等级相关性的彩色图像椒盐噪点检测算法[J]. 中国科学技术大学学报, 2019, 49(1):63-70.
Jia X F, Guo Y C, Huang Y R, et al. Salt&pepper noise detection algorithm for color images based on spearman rank correlation[J]. Journal of University of Science and Technology of China, 2019, 49(1):63-70 (in Chinese).