

DOI: 10.16410/j.issn1000-8365.2024.3257

# 基于机器学习的高强度高导 Cu 基复合材料力-电性能统一预测模型研究

刘楠<sup>1,2,3</sup>, 郭青成<sup>1,2,3</sup>, 马麟趾<sup>1,2,3</sup>, 王嘉琦<sup>1,2,3</sup>

(1. 西安理工大学材料科学与工程学院, 陕西西安 710048; 2. 陕西省电工材料与熔渗技术重点实验室, 陕西西安 710048; 3. 导电材料与复合技术教育部工程研究中心, 陕西西安 710048)

**摘要:** 颗粒增强铜基复合材料具有良好的力学、电学性能, 但增强体特征参量与材料性能之间的定量关系难以量化确定。为建立 TiB 和 TiB<sub>2</sub> 陶瓷增强相与铜基复合材料力学与电学综合性能之间的映射关系, 以求大幅提高铜基复合材料强度的同时, 将其导电率降低在可接受范围内, 提出了一种基于蚁群算法优化的 BP 神经网络铜基复合材料力-电性能统一预测模型(ACO-BP-Cu)。通过 BP 神经网络建立铜基复合材料性能与特征参数间关系, 通过蚁群算法全局寻优确定 BP 神经网络模型结构。实验表明, ACO-BP-Cu 模型能够根据 TiB 和 TiB<sub>2</sub> 陶瓷增强相特征参数有效预测铜基复合材料各项性能, 且相对决策树、线性回归、K 邻近法等 9 种回归算法准确率更高, 稳定性更强。

**关键词:** 铜基复合材料; BP 神经网络; 蚁群算法; 机器学习; 导电率

中图分类号: TB30

文献标识码: A

文章编号: 1000-8365(2024)01-0044-06

## Unified Prediction Model for the Mechanical and Electrical Properties of High Strength and High Conductivity Cu Matrix Composite Materials Based on Machine Learning Algorithms

LIU Nan<sup>1,2,3</sup>, GUO Qingcheng<sup>1,2,3</sup>, MA Linzhi<sup>1,2,3</sup>, WANG Jiaqi<sup>1,2,3</sup>

(1. School of Materials Science and Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. Shaanxi Provincial Key Laboratory of Electrical Materials and Infiltration Technology, Xi'an 710048, China; 3. Conductive Materials and Composite Technology Engineering Research Center of the Ministry of Education, Xi'an 710048, China)

**Abstract:** Particle-reinforced copper matrix composites exhibit good force-electric performance, but the quantitative relationship between the characteristic parameters of the reinforcement and the force-electric performance is difficult to quantify. To establish the relationship between the TiB and TiB<sub>2</sub> reinforcement and the force-electric performance of copper matrix composites, greatly improve the strength of the copper matrix and control the change in conductivity within an acceptable range, a back propagation (BP) neural network and ant colony optimization based copper matrix composite performance prediction model (ACO-BP-Cu) was proposed. The relationship between the performance of the copper matrix composites and characteristic parameters was determined via a back propagation neural network, and the model structure was determined via global optimization of ant colony algorithms. The results show that the ACO-BP-Cu model can effectively predict the performance of copper matrix composites according to the characteristic parameters of TiB and TiB<sub>2</sub>, and have higher accuracy and stability compared with 9 regression algorithms including decision tree, linear regression, and K-nearest neighbor algorithms.

**Key words:** Cu matrix composite; back propagation neural network; ant colony optimization; machine learning; conductivity

收稿日期: 2023-10-30

基金项目: 国家自然科学基金(51834009, 51974244, 51605382); 西安市科技计划项目(2021SFGX0004)

作者简介: 刘楠, 博士, 副教授. 研究方向为铜基复合材料跨尺度构型设计及其力学性能数值模拟研究和薄壁管/板塑性加工形性一体化全流程多尺度建模仿真理论研究. Email: liunan@xaut.edu.cn

引用格式: 刘楠, 郭青成, 马麟趾, 等. 基于机器学习的高强度高导 Cu 基复合材料力-电性能统一预测模型研究[J]. 铸造技术, 2024, 45(1): 44-49.

LIU N, GUO Q C, MA L Z, et al. Unified prediction model for the mechanical and electrical properties of high strength and high conductivity Cu matrix composite materials based on machine learning algorithms[J]. Foundry Technology, 2024, 45(1): 44-49.

铜基复合材料具有良好的力学、导电、导热性能,在电子工业、机械制造、航空航天、国防电气等领域应用广泛<sup>[1-3]</sup>。随着行业领域的快速发展,人们对铜基复合材料的性能和使用提出了更高的要求,开发高强度和高导电性的铜基复合材料成为重要研究方向<sup>[4-6]</sup>。

通过添加具有高强度、高硬度的 TiB 和 TiB<sub>2</sub> 陶瓷增强相,可以大大提高铜基复合材料性能<sup>[7]</sup>。然而,复合材料的高强度和导电率存在矛盾关系,获得高强度的同时,其导电率必然降低<sup>[8]</sup>。同时,由于 TiB 和 TiB<sub>2</sub> 陶瓷增强相特征参量交互、协同影响铜基复合材料各项性能,单纯依赖实验手段难以全面揭示各特征参量对复合材料的具体影响,无法获取综合性能极佳的铜基复合材料<sup>[9-10]</sup>。如何定量评价 TiB 和 TiB<sub>2</sub> 陶瓷增强相及二者混杂占比特征等对铜基复合材料强度和导电率的具体影响,对于高性能铜基复合材料的设计开发具有重要意义。

传统铜基复合材料研究按照理论分析、仿真建模、拓扑优化等思路展开,主要进行科学实验和数值模拟,实验周期长、成本高,结果不稳定,易受异常情况的影响,分析方法也较为受限,难以全面表征增强相特征与性能间未知复杂关系<sup>[11-13]</sup>。随着机器学习、深度神经网络等技术不断发展,数据赋能传统数学、力学和实验模型的思想逐步得到应用。通过确定正确的目标函数、模型结构,基于当前实验数据,不断迭代训练,学习特征与性能间关系,可构建预测模型,应用于复合材料性能设计和结构优化。

BP(back propagation)神经网络具有良好的非线性映射、泛化和容错能力,是目前应用较为广泛的人工神经网络<sup>[14]</sup>。蚁群算法<sup>[15]</sup>是一种仿生智能优化算法,常用于求解组合优化、路径规划等问题,其灵感来源于蚂蚁觅食的过程,蚂蚁在寻找食物源的路径上会留下信息素,而群体内的蚂蚁可以感知信息素,并沿着信息素浓度高的地方移动,形成正反馈机制,经过一段时间之后,蚂蚁就可以确定一条到达食物源的最优路径。本文基于机器学习算法,针对网络隐含层节点设置问题,引入蚁群算法动态寻优确定 BP 神经网络隐含层结构,建立基于蚁群算法优化的 BP 神经网络铜基复合材料力电性能预测模型。考察 TiB 和 TiB<sub>2</sub> 陶瓷增强相对铜基复合材料力学性能和导电性能的影响规律,为高强高导铜基复合材料制备提供理论依据。

## 1 模型构建

### 1.1 问题描述

给定训练数据集  $D = \{(x_k, y_k)\} (k=1, 2, \dots, K)$ , 其

中  $x_k \in R^2$  表示输入数据,包括 TiB 晶须体积、TiB<sub>2</sub> 颗粒体积 2 个特征,  $y_k \in R^1$  表示模型输出数据,包括铜基复合材料的导电率(EC)、屈服强度(YS)、拉伸强度(TS)、伸长率(EL)4 项性能,  $K$  表示实验样本数量。旨在建立基于蚁群算法优化的 BP 神经网络铜基复合材料性能预测模型,模拟 TiB 和 TiB<sub>2</sub> 陶瓷增强相对铜基复合材料性能的影响。

### 1.2 模型构建

输入训练数据,以蚁群算法搜索到的隐含层节点数量构建 BP 神经网络并进行训练测试,计算每组 TiB 和 TiB<sub>2</sub> 陶瓷增强相参数组合所对应实际输出和期望输出的误差,找到最小误差,更新蚁群信息素,并反复迭代,直至模型收敛,得到(TiB<sub>2</sub>+TiB)/Cu 铜基复合材料性能预测模型,流程如图 1 所示。

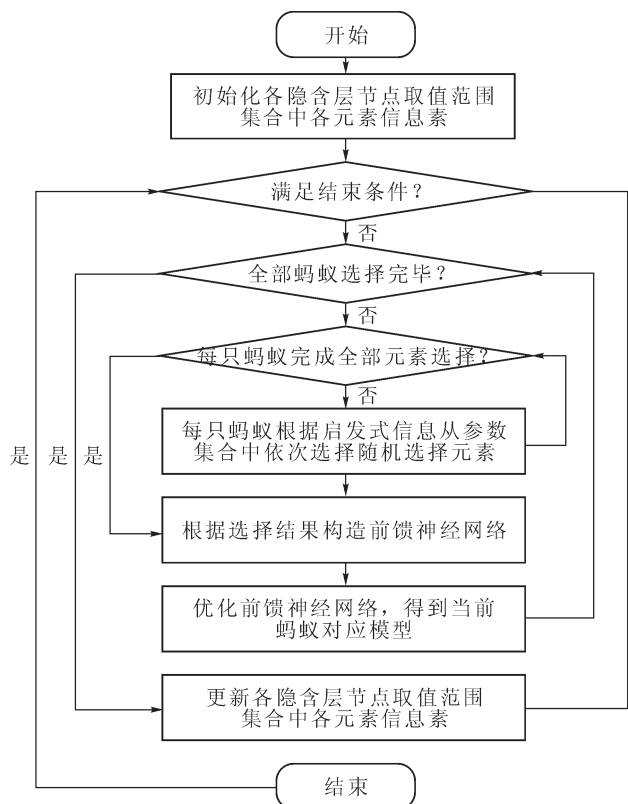


图 1 模型流程图

Fig.1 Model flowchart

步骤 1:初始化。设置 BP 神经网络的隐含层数  $L$ ,被优化的各隐含层节点取值范围集合  $S_i (i=1, 2, \dots, L)$ ,集合  $S_i$  中的元素个数  $Q_i$ ,最大迭代次数  $N_{bp-max}$ 。设置蚁群算法最大迭代次数为  $N_{aco-max}$ ,蚂蚁数量  $M$ ,局部搜索步长  $step$ 。

步骤 2:随机产生蚂蚁初始位置,计算适应度数值,设为蚁群算法初始信息素,并计算状态转移概率  $P_n$ 。

$$P_n = \frac{\tau_{max} - \tau_m}{\tau_{max}} \quad (1)$$

式中,  $\tau_{\max}$  为信息素的最大值;  $\tau_m$  为蚂蚁的信息素;  $P_n$  为第  $n$  次迭代蚂蚁  $m$  的转移概率。然后, 进行蚁群方案更新。

当状态转移概率小于转移概率常数时, 进行局部搜索。

$$\text{solution}_{\text{new}} = \text{solution}_{\text{old}} + r_1 * \text{step} * \frac{1}{n} \quad (2)$$

式中,  $\text{solution}_{\text{new}}$  为蚂蚁生成的新的解空间;  $\text{solution}_{\text{old}}$  为蚂蚁原先的解空间;  $r_1$  为介于  $[-1, 1]$  的随机数;  $\text{step}$  为局部搜索步长;  $\frac{1}{n}$  为当前迭代次数的倒数。

当状态转移概率大于转移概率时, 进行全局搜索。

$$\text{solution}_{\text{new}} = \text{solution}_{\text{old}} + r_2 * \text{range} \quad (3)$$

式中,  $r_2$  为  $[-0.5, 0.5]$  的随机数;  $\text{range}$  为隐含层节点个数的区间大小。

步骤 3: 以每只蚂蚁选择的解空间为隐含层节点个数构造多层 BP 神经网络, 利用前馈算法对 BP 神经网络进行训练, 使用实际输出和期望输出的均方误差  $\text{MSE}_{ij}$  作为损失函数。

$$\text{MSE}_{ij} = \frac{1}{K} \sum_{k=1}^k (\hat{Y}_k - Y_k) \quad (4)$$

式中,  $\hat{Y}_k$  为网络实际输出;  $Y_k$  为网络期望输出。对训练结束后的均方误差进行排序, 找到最小误差, 对应的蚂蚁即为本次迭代最优解。通过判断待移动位置损失与当前位置损失的大小来确定是否更新蚂蚁当前位置, 并利用边界吸收方式进行边界条件处理, 将蚂蚁位置界定在取值范围内。

步骤 4: 根据本次迭代解损失对蚁群算法信息素进行更新。

$$\tau_{ij}(t+1) = (1-\rho)\tau_{ij}(t) + \Delta\tau_{ij}(t)$$

$$\Delta\tau_{ij}(t) = \sum_{m=1}^M \Delta\tau_{ij}^m(t) \quad (5)$$

$$\Delta\tau_{ij}^m(t) = \begin{cases} \frac{Q}{\text{MSE}_{ij}}, & m \text{ 选择第 } j \text{ 个元素} \\ 0, & m \text{ 不选择第 } j \text{ 个元素} \end{cases}$$

式中,  $\tau_{ij}(t)$  为  $t$  时刻元素  $s_{ij}$  的信息素浓度;  $\tau_{ij}(t+1)$  为更新后  $t+1$  时刻元素  $s_{ij}$  的信息素浓度;  $\Delta\tau_{ij}^m(t)$  为蚂蚁  $m$  本次循环中在元素  $s_{ij}$  上留下的信息量;  $\Delta\tau_{ij}(t)$  为在本次循环结束后, 所有蚂蚁在元素  $s_{ij}$  上留下的总信息素量;  $Q$  为常数, 用于控制蚁群算法收敛速度,  $Q$  值越小, 蚁群算法收敛速度越慢, 反之, 蚁群算法收敛速度越快。当蚁群算法的迭代次数  $N_{\text{aco-max}}$  满足最大迭代次数, 结束循环, 输出最优解对应网络结构作为  $(\text{TiB}_2 + \text{TiB})/\text{Cu}$  铜基复合材料性能预测模型 ACO-BP-Cu, 同时根据测试数据输出预测结果。模型对应伪代码如表 1 所示。

## 2 实验方法

### 2.1 实验环境与数据集

在真实数据集上进行对比实验验证所提模型的有效性及其优越性。程序语言为 python-3.6.13, 使用 keras-2.3.0、scikit-learn-0.24.2 实现相关算法, CPU 为 11th Gen Intel(R) Core(TM) i7-11800H @ 2.30 GHz 2.30 GHz, 内存为 16G, 显卡为 NVIDIA GeForce RTX3070, 操作系统为 Windows 11。实验数据来源于  $(\text{TiB}_2 + \text{TiB})/\text{Cu}$  有限元模型<sup>[6]</sup>。数据集自变量为电子显微镜获得的  $\text{TiB}_2$  颗粒和  $\text{TiB}$  晶须几何特征, 因变量为加入相应配比的  $\text{TiB}_2$  颗粒和  $\text{TiB}$  晶须后, 得到的铜基复合材料导电率  $\text{EC}(\text{MS}/\text{mm})$ 、屈服强度  $\text{YS}(\text{MPa})$ 、拉伸强度  $\text{TS}(\text{MPa})$  和伸长率  $\text{EL}(\%)$  4 项性

表1 模型伪代码

Tab.1 Pseudo-code of the proposed model

输入: 训练数据集;

BP 神经网络的隐含层数及取值范围;

蚁群算法参数集合;

输出: ACO-BP-Cu 模型预测结果

Begin

1. While(迭代次数 < 蚁群算法最大迭代次数){

2. For(蚁群中每只蚂蚁){

3. 根据公式(1)至(3)从参数集合中随机选择元素构造解空间;

4. 根据选择结果构造 BP 神经网络;

5. 以公式(4)作为损失函数对当前 BP 神经网络进行优化, 并得到当前蚂蚁最小误差;

6. }

7. 根据公式(5)计算本次迭代解的适应度, 并对蚁群算法信息素进行更新;

8. }

9. 输出 ACO-BP-Cu 模型, 并根据测试数据预测复合材料性能

End

能,共 30 个样本,信息如表 2 所示。

表2 实验数据集  
Tab.2 Datasets

TiB <sub>2</sub>	TiB	EC/(MS·mm <sup>-1</sup> )	YS/MPa	TS/MPa	EL/%
1	5	93.01	130.892 6	226.003 7	0.079 483
1.25	6.25	92.97	131.572 3	223.958 8	0.081 161
1.5	7.5	93.05	131.708 3	233.030 9	0.082
1.75	8.75	92.95	132.049 6	236.152 3	0.075 276
2	4	93.12	131.861 2	239.998 5	0.073 589
2	10	91.45	134.647 8	248.886 4	0.093 656
2.25	11.25	91.33	135.777 2	241.303 4	0.074 433
2.5	5	91.32	134.32	245.203 4	0.070 204
3	3	91.35	136.865 8	236.974 1	0.053 972
3	6	91.41	135.505 4	255.230 3	0.079 483
3.5	7	89.64	138.940 1	231.656	0.074 433
3.75	3.75	89.46	138.587 7	248.297 7	0.067 659
4	2	89.69	137.781 8	245.885 9	0.063 402
4	8	89.62	137.579 5	259.006 5	0.071 052
4.5	4.5	89.75	138.211 9	249.855 9	0.063 402
4.5	9	88.09	142.619 9	239.915	0.085 343
5	1	88.01	143.244 3	244.868 1	0.065 107
5	2.5	87.89	139.967	249.292 8	0.066 809
5.25	5.25	88.01	139.972 4	255.176 8	0.063 402
6	3	88	137.390 4	271.051 3	0.068508
6	6	86.44	145.665 3	229.520 1	0.057 411
6.25	1.25	86.48	143.999 1	253.427	0.066 809
6.75	6.75	86.36	143.108 9	251.901	0.059 983
7	3.5	86.34	140.418 2	264.728 7	0.053 11
7.5	1.5	86.37	136.566 1	281.935 3	0.060 839
8	4	84.91	147.395 8	240.184 9	0.065 107
8.75	1.75	84.84	144.673 4	251.404 9	0.063 402
9	4.5	84.74	143.561 2	260.035 2	0.054 833
10	2	84.8	140.8585	271.747 1	0.050 52
11.25	2.25	84.69	136.054 2	281.163 7	0.052 248

## 2.2 评价指标

由于所提模型总体为回归预测模型<sup>[17]</sup>,而  $R^2$  指标由于能够很好表征观测值和预测值之间的差异,反映模型的可靠性和效果,在回归预测领域被作为评价指标广泛使用, $R^2$  通过下式表示:

$$R^2 = 1 - \frac{\sum_{i=1}^{60} (\hat{Y}_i - Y_i)^2}{\sum_{i=1}^{60} (\bar{Y}_i - Y_i)^2} \quad (6)$$

式中,  $(\hat{Y}_i - Y_i)^2$  为真实值与预测值的平方差;  $(\bar{Y}_i - Y_i)^2$  为真实值与均值的平方差。系数  $R^2$  常规取值范围为 0~1, 值越大, 模型拟合效果越好; 若  $R^2$  取值为负数, 则模型无效。

## 2.3 数据分析

为了初步掌握 TiB<sub>2</sub> 颗粒和 TiB 晶须的几何特

征与铜基复合材料导电率、屈服强度、拉伸强度和伸长率 4 项性能的相关性及数据分布特征规律, 进行特征间 Pearson 相关性<sup>[18]</sup>分析, 并绘制样本相关性散点图, 结果如图 2 所示。图 2 中红色为正相关, 蓝色为负相关, 圆形大小与 Pearson 相关系数保持一致, 在圆心处标识。

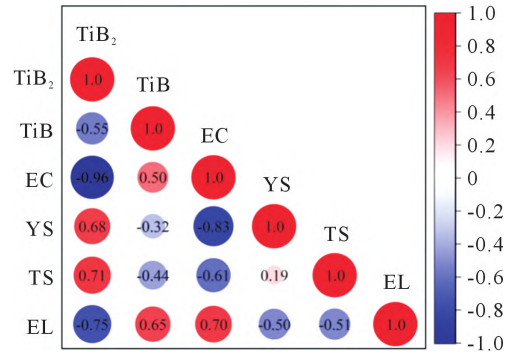


图 2 相关性分析结果

Fig.2 Correlation analysis results

由图 2 可知, TiB<sub>2</sub> 颗粒和 TiB 晶须的几何特征与 4 项性能及性能本身存在不同程度的线性相关, 其中 TiB<sub>2</sub> 颗粒体积与导电率与伸长率、导电率与屈服强度相关性大于 0.7, 为高度线性相关。当同时调整 TiB<sub>2</sub> 颗粒、TiB 晶须配比, 相应性能分布是否仍然服从此规律, 无法通过简单函数直接表示, 有必要分别建立回归模型, 表征铜基复合材料各项性能与特征参数之间的复杂关系。

## 2.4 对比实验

为了验证所提算法的优越性, 将所提算法分别与决策树(decision tree, DT)、随机森林(random forest, RF)、引导聚集算法(bootstrap aggregating, BA)、梯度提升决策树(gradient boosting decision tree, GB-DT)、自适应增强决策树(adaptive boosting decision tree, ADBT)、线性回归(linear regression, LR)、支持向量回归(support vector regression, SVR)、K 邻近法(K-nearest neighbor, KNN)、极端随机树(extremely randomized trees, ERT)9 种回归算法进行对比。

ACO-BP-Cu 模型训练数据与测试数据按照 4:1 划分, 根据 Dorigo 等<sup>[19]</sup>给出的蚁群算法参数进行多组实验, 确定本模型使用的蚁群算法常数  $Q$  为 1, 迭代次数为 10、蚂蚁数量为 5。综合考虑数据规模和模型表现, 经过多次优化, 确定模型使用的 BP 神经网络迭代次数为 1 000, 学习率为 0.01, 隐含层层数为 2, 采用 ReLU<sup>[20]</sup>作为激活函数。针对铜基复合材料导电率、屈服强度、拉伸强度和伸长率 4 项性能进行训练并预测, 蚁群算法最终构造的 BP 神经网络隐藏层节点个数如表 3 所示。

对比实验结果如图 3 所示, 横轴分别为不同对

表3 ACO-BP-Cu最终隐层含节点个数  
Tab.3 The number of hidden layer nodes in the final ACO-BP-Cu

Predict performance	The number hidden layer nodes
EC	36, 29
YS	23, 85
TS	75, 65
EL	83, 58




图3 对比实验结果  
Fig.3 Results of comparative experiments

比算法,纵轴为评价指标,不同颜色折线分别表示各回归算法对铜基复合材料不同性能的预测情况。

从图3可以看出,部分对比算法R2指标为负数,代表方法无效。即决策树DT和极端随机树ERT模型对拉伸强度和屈服强度的预测无效,其余所有回归算法对各项性能预测均有效。ACO-BP-Cu模型模型在各个性能上预测结果更接近1。同时,各算法对不同性能的预测结果存在波动,效果由好到坏依次为对导电率、屈服强度、拉伸强度、伸长率的预测。不同算法针对不同性能的预测结果也存在差距,这与各性能和增强相关系有关,当相关关系适用于当前回归模型时,效果相对较好,而ACO-BP-Cu模型由于具备较好的泛化能力和较强的表达能力,其在各项性能预测上的表现也相对鲁棒。对于YS, ACO-BP-Cu模型预测结果相对其他性能,效果一般。分析原因为:①训练样本数据有限;②模型还存在进一步优化的空间。但是,通过不同方法间的对比,该模型仍然较其它方法更具优势,且R2值大于0接近0.6,也能够说明算法是有效的。我们会在后续的研究中通过增加样本空间数量来进一步提升相关性能的预测水平,使模型更具指导意义。

以导电率预测为例,图4展示了蚁群算法迭代过程中评价指标的变化,图5展示了真实值与预测值间的关系。

由图4可知,随着迭代次数不断增加,评价指标不断上升,大约在迭代10次之后稳定在0.984,并最终确定了模型的隐含层个数。

由图5可知,图中每点代表1个测试数据,对




图4 蚁群算法评价指标变化(以导电率为例)  
Fig.4 Ant colony algorithm R2 curve (taking EC as an example)

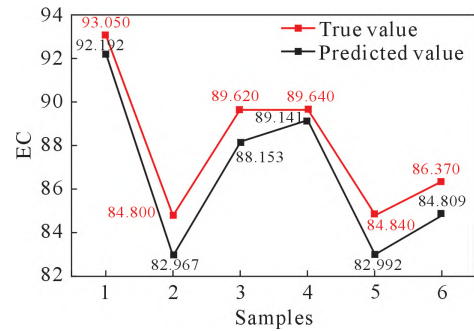


图5 模型预测值导电率与真实导电率  
Fig.5 True EC and predicted EC

于不同测试数据,预测值与真实值相差不多,总体趋势保持一致,在一定误差范围内,模型能够根据TiB<sub>2</sub>颗粒和TiB晶须两项特征预测铜基复合材料性能。

### 2.5 学习率敏感性实验

为验证学习率对BP神经网络结果的影响,以导电率预测为例,将神经网络学习率分别设置为0.0001, 0.001, 0.01, 0.1进行实验,图6展示了评价指标R2随学习率变化情况。由图6可知,模型受学习率影响不大,当学习率设置为0.001或0.01时效果最优。




图6 学习率对模型导电率预测影响  
Fig.6 The influence of the learning rate on EC prediction

## 3 结论

(1)在预测力学、电学性能时,基于蚁群算法进

行动态寻优,确立了BP神经网络的隐含层节点数量,获得了[36、29]、[23、85]、[75、65]和[83、58]个节点的最优设置。

(2)ACO-BP-Cu预测模型的结果与其他9种回归算法(决策树、随机森林、引导聚集算法、梯度提升决策树、自适应增强决策树、线性回归、支持向量回归、K邻近法和极端随机树)的结果进行对比分析。表明ACO-BP-Cu预测模型的预测精度显著高于其他算法,在预测不同复合材料力电性能方面,ACO-BP-Cu预测模型表现出明显的优势。

(3)该模型受学习率影响小,表现出较强的有效性和相对鲁棒性,可进一步拓展到复杂空间构型化铜基复合材料力电性能与特征参数之间映射关系的建立。为具有智能空间构型设计的铜基复合材料制备提供理论依据。

#### 参考文献:

- 王怡然,高义民. Ti元素对 $Ti_3SiC_2$ 在铜基复合材料中的分解抑制研究[J]. 铸造技术, 2022, 43(6): 410-416.  
WANG Y R, GAO Y M. Effect of Ti in inhibiting the decomposition of  $Ti_3SiC_2$  in copper matrix composites[J]. Foundry Technology, 2022, 43(6): 410-416.
- LIU N, ZHANG Q Q, FENG P F, et al. Effects of configuration parameters on the deformation and fracture behaviors of  $TiB_2/Cu$  composites with network structure: A numerical approach using an enhanced finite element model[J]. Computational Materials Science, 2022, 205: 111212.
- LIU N, ZHANG Q Q, ZHANG H Y, et al. Experimental verification and numerical analysis on plastic deformation and mechanical properties of the in-situ  $TiB_2$  homogeneous composites and  $TiB_2/Cu$  network composites prepared by powder metallurgy[J]. Journal of Alloys and Compounds, 2022, 920: 165897.
- LIU N, ZHANG X, ZHANG Q Q, et al. Numerical evaluation and experimental verification of mechanical properties and fracture behavior for  $TiB_2/Cu$  composites prepared by in-situ mixing casting[J]. Journal of Alloys and Compounds, 2022, 895: 162475.
- 李海生,周叶晨,李焯飞,等. 烧结温度对MAX/Cu复合材料的组织及性能影响[J]. 铸造技术, 2022, 43(6): 439-444.  
LI H S, ZHOU Y C, LI Y F, et al. Effect of sintering temperature on microstructure and properties of MAX/Cu composites[J]. Foundry Technology, 2022, 43(6): 439-444.
- 帅歌旺,张萌. 高强度、高导电铜合金及铜基复合材料研究进展[J]. 特种铸造及有色合金, 2005, 25(9): 534-537.  
SHUAI G W, ZHANG M. Progress in high-strength and high-conductivity copper alloys and copper base composites[J]. Special Casting & Nonferrous Alloys, 2005, 25(9): 534-537.
- WANG J, GUO L N, LIN W M, et al. The effects of graphene content on the corrosion resistance, and electrical, thermal and mechanical properties of graphene/copper composites[J]. New Carbon Materials, 2019, 34(2): 161-169.
- WANG F C, ZHANG Z H, LUO J, et al. A novel rapid route for in situ synthesizing  $TiB-TiB_2$  composites[J]. Composites Science and Technology, 2009, 69(15-16): 2682-2687.
- GUO X H, YANG Y B, SONG K X, et al. Arc erosion resistance of hybrid copper matrix composites reinforced with CNTs and micro- $TiB_2$  particles[J]. Journal of Materials Research and Technology, 2021, 11: 1469-1479.
- 任建强,梁淑华,姜伊辉,等. 原位( $TiB_2-TiB$ )/Cu复合材料组织与性能研究[J]. 金属学报, 2019, 55(1): 126-132.  
REN J Q, LIANG S H, JIANG Y H, et al. Research on the microstructure and properties of in situ ( $TiB_2-TiB$ )/Cu composites[J]. Acta Metallurgica Sinica, 2019, 55(1): 126-132.
- LIU N, ZHANG X, ZHANG X D, et al. Numerical investigations on the hybrid effect and deformation mechanism of  $TiB_{2p}$  and  $TiB_w$  reinforced Cu composites prepared by in-situ mixing casting[J]. Computational Materials Science, 2022, 213: 111657.
- 曹飞,许英琴,张兴德,等. 球形Cu粉粒径对谐波结构 $TiB_2/Cu$ 复合材料组织及性能的影响[J]. 铜业工程, 2023(5): 10-16.  
CAO F, XU Y Q, ZHANG X D, et al. Microstructure and properties of heterogeneous  $TiB_2/Cu$  composites based on different spherical Cu particle sizes with a harmonic structure[J]. Copper Engineering, 2023(5):10-16.
- 丁昱寰,张修庆,徐金鹏,等. ( $Ti_2SnC+TiB_2$ )颗粒增强铜基复合材料的研究[J]. 热加工工艺, 2015, 44(12): 143-145, 149.  
DING Y H, ZHANG X Q, XU J P, et al. Study on particle reinforced Cu matrix Cu- $Ti_2SnC-TiB_2$  composite[J]. Hot Working Technology, 2015, 44(12): 143-145, 149.
- RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323: 533-536.
- COLORNI A, DORIGO M, MANIEZZO V. Distributed optimization by ant colonies[A]. Proceedings of ECAL91-European conference on artificial life[C]. Paris: Elsevier Publishing, 1991. 134-142.
- 刘楠,刘圆聪,姜伊辉,等.  $TiB_2$ 颗粒和TiB晶须混杂增强铜基复合材料导电率有限元模拟[J]. 稀有金属材料与工程, 2022, 51(2): 559-565.  
LIU N, LIU Y C, JIANG Y H, et al. Simulation of electrical conductivity of ( $TiB_{2p}+TiB_w$ )/Cu composites[J]. Rare Metal Materials and Engineering, 2022, 51(2): 559-565.
- JORDAN M I, MITCHELL T M. Machine learning: Trends, perspectives, and prospects[J]. Science, 2015, 349(6245): 255-260.
- COHEN I, HUANG Y, CHEN J, et al. Pearson correlation coefficient[A]. Noise Reduction in Speech Processing[C]. Berlin: Springer, 2009. 1-4.
- DORIGO M, BIRATTARI M, STUTZLE T. Ant colony optimization[J]. IEEE Computational Intelligence Magazine, 2006, 1(4): 28-39.
- AGARAP A F. Deep learning using rectified linear units(ReLU)[J]. arXiv: 1803.08375, 2018.