

doi: 10.3969/j.issn.1001-3849.2026.01.016

## 基于贝叶斯优化神经网络的 Cu-SiC 镀层镀速预测

魏波, 刘翠芳, 吕焦盛

(郑州工业应用技术学院 信息工程学院, 河南 郑州 451150)

**摘要:** Cu-SiC 镀层镀速受多种因素影响, 包括电流密度、镀液成分、温度、搅拌速度等, 这些因素与镀速之间存在着复杂的非线性关系。传统的神经网络模型只能处理线性关系, 对于复杂的电镀数据特征之间的非线性关系以及时空特性难以有效捕捉, 影响了模型超参数的优化速度及预测精度。为此, 提出基于贝叶斯优化神经网络的 Cu-SiC 镀层镀速预测方法。该方法系统地采集电镀过程中的电流值、镀液温度、镀液 pH 值、SiC 粒子浓度、镀液搅拌速率数据, 并采用 Z-score 标准化方法对每种电镀数据进行归一化处理, 以促进模型在不同特征间的有效比较。设计贝叶斯优化神经网络的 BO-CNN-LSTM 模型, 将各种电镀数据的归一化处理结果作为模型输入, 同时捕捉电镀数据的空间特征和时间依赖性, 利用贝叶斯算法优化层自动搜索模型最优超参数组合。利用最优超参数组合实施模型训练, 最终实现 Cu-SiC 镀层镀速的高效精准预测。实验结果表明, 经过贝叶斯算法优化超参数后, 该预测方法的决定系数  $R^2$  显著提升, 更接近 1。预测结果与实际镀速之间的偏差较小, 曲线走势与实际镀速高度一致。此外, 该方法的 CPU 使用率也相对较低。

**关键词:** 电镀数据; Z-score 标准化; 贝叶斯优化算法; BO-CNN-LSTM 模型; Cu-SiC 镀层; 镀速预测

中图分类号: O213; TQ153 文献标志码: A

## Research on Cu-SiC coating plating rate prediction based on Bayesian optimization neural network

WEI Bo, LIU Cuifang, LYU Jiaosheng

(School of Information Engineering, Zhengzhou University of Industrial Technology, Zhengzhou 451150, China)

**Abstract:** The plating rate of Cu-SiC coating is influenced by various factors, including current density, plating solution composition, temperature, stirring speed, etc. There is a complex nonlinear relationship between these factors and the plating rate. Traditional neural network models can only handle linear relationships, making it difficult to effectively capture the nonlinear relationships and spatiotemporal characteristics between complex electroplating data features, which affect the optimization speed and prediction accuracy of model hyperparameters. Therefore, a prediction method for Cu-SiC coating plating rate based on Bayesian optimization neural network was proposed. This method systematically collects data on current value, plating solution temperature, plating solution pH value, SiC particle concentration, and plating solution stirring rate during the electroplating process, and uses Z-score normalization method to normalize each electroplating data to promote effective comparison of the model between different features. Design a BO-CNN-LSTM model for Bayesian optimization neural network, taking the normalized results of various electroplating data as model inputs, while capturing the spatial features and temporal

收稿日期: 2025-01-14 修回日期: 2025-02-24

通信作者: 魏波(1982—), 男, 硕士, 高级实验师, 研究方向为计算机网络, e-mail: yxds14780@163.com

基金项目: 河南省科技厅项目(182102210549); 教育部产学合作协同育人项目(230703175305222)

引用信息: 魏波, 刘翠芳, 吕焦盛. 基于贝叶斯优化神经网络的 Cu-SiC 镀层镀速预测[J]. 电镀与精饰, 2026, 48(1): 123-130.

WEI Bo, LIU Cuifang, LYU Jiaosheng. Research on Cu-SiC coating plating rate prediction based on Bayesian optimization neural network[J]. Plating and Finishing, 2026, 48(1): 123-130.

dependencies of electroplating data. Then, use Bayesian algorithm optimization layer to automatically search for the optimal hyperparameter combination of the model. Train the model using the optimal combination of hyperparameters and ultimately achieve efficient and accurate prediction of Cu SiC coating rate. The experimental results show that after optimizing the hyperparameters using Bayesian algorithm, the coefficient of determination  $R^2$  of this prediction method is significantly improved, approaching 1. The deviation between the predicted results and the actual plating rate is small, and the curve trend is highly consistent with the actual plating rate. In addition, the CPU usage of this method is relatively low.

**Keywords:** electroplating data; Z-score standardization; Bayesian optimization algorithm; BO-CNN-LSTM model; Cu-SiC coating; prediction of plating rate

Cu-SiC镀层镀速作为电镀过程中的一个关键指标,直接影响着镀层的质量、生产效率以及成本。准确预测Cu-SiC镀层镀速,对于实现高质量镀层的高效生产具有重要意义<sup>[1]</sup>。然而,Cu-SiC镀层镀速的预测面临诸多挑战。研究表明,Cu-SiC镀层镀速受多种因素影响,涵盖电流密度、镀液成分、温度、搅拌速度等。这些因素并非独立作用,它们相互交织,与镀速之间存在着复杂的非线性关系<sup>[2]</sup>。这种复杂性使得准确捕捉镀速与各影响因素之间的内在联系难度较大,预测精度无法满足实际需求<sup>[3]</sup>。鉴于此,深入开展Cu-SiC镀层镀速预测研究具有重要的理论和实际应用价值。

当前,速度预测的研究现状呈现出多元化与精确化的发展趋势。例如,文献[4]提出一种创新的支持向量回归(SVR)掘进速度预测模型,该模型融合了改良的麻雀搜索算法。通过引入蒸发系数 $T$ ,对麻雀搜索算法的基础搜索环境施加全局性的随机扰动,旨在逐步淡化粒子对历史最优位置的记忆,避免搜索过程受限于初始条件,从而有效防止算法收敛至局部最优。此外,该文献还运用了改良的麻雀搜索算法(TSSA)来优化SVR的参数配置。在实际电镀过程中,镀液温度随时间的变化以及在镀槽内不同位置的差异对镀速有重要影响,但该模型未能充分考虑这些因素,从而导致预测结果不准确。文献[5]以掘进速度为预测核心,采用皮尔逊相关系数分析技术筛选出关键特征参数,并应用均值滤波手段对这些特征参数的时间序列数据进行降噪处理。降噪后的数据被用于计算均值与方差,两者共同构成了特征向量,进而基于XGBoost机器学习框架建立了预测模型。然而,因皮尔逊相关系数仅考虑线性相关性,会遗漏与镀速有复杂非线性关系的重要镀液成分因素,致使镀速预测误差大,无法满足生产对镀速精确控制的需求。文献[6]采用遗传算法优化的BP神经网络预测振动速度。在处理镀速相关数据

时,对于镀液成分、温度等因素随时间的动态变化以及在镀槽内不同位置(空间)的分布差异等时空特性,BP神经网络难以自动捕捉和分析。这会导致模型的预测性能显著下降。文献[7]提出了一种基于多模态融合的端到端转向角和车速预测网络(MFE SSNet)。该网络创新性地将单流和双流结构扩展为三流结构,并使用HRNet和LSTM层巧妙地提取图像、转向角和车辆速度的特征。但对于电镀数据,HRNet无法有效提取电流密度、镀液成分等非图像类特征信息,导致LSTM层难以捕捉电镀数据复杂的时间依赖性和空间特性,无法在不同电镀场景稳定准确预测镀速。鉴于上述问题,本研究设计了基于贝叶斯优化神经网络的Cu-SiC镀层镀速预测方法。

## 1 Cu-SiC 镀层镀速预测方法设计

现有的镀速预测方法在处理具有复杂空间特征和时间依赖性的电镀数据时存在一定的局限性。因此,为了更有效地控制和优化Cu-SiC镀层的制备过程,提高其性能,需要设计一种能够准确预测镀速的方法。该方法结合电镀过程的特性,设计专门的神经网络模型,并利用贝叶斯优化算法对模型超参数进行优化,以达到更高的预测精度。

### 1.1 电镀数据采集与 Z-score 标准化处理

电镀过程涉及复杂的物理化学变化,其产生的数据具有高度时空依赖性,这意味着数据不仅随时间变化,还受到电镀液中不同位置条件的影响。此外,原始电镀数据可能存在量纲和数值范围不一致的问题,这对后续分析和模型训练构成挑战。因此,需要对原始电镀数据进行全面的系统性采集和标准化处理,以保障神经网络模型能够精准捕捉数据间的复杂关联性,为后续模型训练和预测奠定坚实的数据基础。

为了深入理解电镀过程并优化Cu-SiC镀层的

制备,使用电流表测量Cu-SiC镀层电镀过程中的电流值。将温度传感器插入镀液中,应用其测量镀液的温度。利用pH计测量镀液的pH值。应用离子选择性电极传感器测量Cu-SiC镀层电镀过程中的SiC粒子浓度<sup>[8]</sup>。使用激光多普勒测速仪测量Cu-SiC镀层电镀过程中的镀液搅拌速率。

上述仪器采集到的电镀数据,由于各自变量的单位不同且存在如电流分布不均匀性、镀液温度波动等复杂因素,若直接用于模型训练,量纲的差异可能会导致梯度下降速度变慢,严重时甚至会使模型陷入局部最优解,从而影响训练效果。对此,本研究对这些电镀数据进行了标准化处理,将其数值范围统一限定在0至1之间<sup>[9]</sup>。标准化处理采用的是Z-score方法,以促进模型在不同特征间的有效比较。具体步骤如下:

(1) 对采集的每种电镀数据,计算其所有样本的均值:

$$\xi_j = \frac{1}{M} \sum_{j=1}^M \alpha_j \quad (1)$$

式中: $M$ 为各种电镀数据的总样本数量; $\alpha_j$ 为第 $j$ 个特征的值; $j$ 为不同的电镀特征,包括电流值、温度、pH值、SiC粒子浓度、镀液搅拌速率<sup>[10]</sup>。

(2) 对采集的每种电镀数据,计算其所有样本的标准差:

$$\tau_j = \sqrt{\frac{1}{M} \sum_{j=1}^M (\alpha_j - \xi_j)^2} \quad (2)$$

对每个电镀样本特征数据实施标准化处理:

$$z_j = \frac{\alpha_j - \xi_j}{\tau_j} \quad (3)$$

(3) 经过上述标准化处理后,得到的电镀数据 $z_j$ 将作为BO-CNN-LSTM模型的输入数据<sup>[11]</sup>,以确保模型能够精准捕捉数据间的复杂关联性,为后续的电镀过程优化和Cu-SiC镀层性能提升提供有力的数据支持。

## 1.2 基于贝叶斯优化神经网络的镀层镀速预测

在Cu-SiC镀层的研究中,镀速是一个关键的性能指标,受到多种因素的影响,如电流密度、镀液成分、温度、搅拌速度等。这些因素与镀速之间存在着复杂的非线性关系,使得传统的线性模型难以准确捕捉电镀数据与镀速之间的复杂非线性关系,

预测精度受限。因此,需要一种能够捕捉这种复杂非线性关系的预测模型。为此,本研究设计了贝叶斯优化神经网络的BO-CNN-LSTM模型。该模型在处理Cu-SiC镀层镀速预测问题时,能够充分挖掘多种电镀因素与镀速之间的复杂非线性关系,有效处理电镀数据的时空特性,并且在贝叶斯优化算法的帮助下找到最优超参数组合,实现Cu-SiC镀层镀速的高效精准预测,满足实际生产对镀速精确控制的要求。

BO-CNN-LSTM模型的结构由输入层、CNN层、LSTM层、输出层以及贝叶斯算法优化层组成。该模型各层的具体设计如下:

(1) 输入层负责接收并处理原始电镀数据,包括电流值、镀液温度、镀液pH值、电镀中的SiC粒子浓度以及镀液搅拌速率等。这些数据经过标准化处理后,被输入到模型中用于Cu-SiC镀层镀速的预测<sup>[12]</sup>。输入层的表达式具体如下:

$$\psi = z_j = \{z_1, z_2, z_3, z_4, z_5\} \quad (4)$$

式中: $z_1$ 、 $z_2$ 、 $z_3$ 、 $z_4$ 、 $z_5$ 为标准化处理后的电流值、镀液温度、镀液pH值、电镀中的SiC粒子浓度以及镀液搅拌速率数据。

(2) CNN层作为模型的第二层,主要用于提取输入数据的时序特征。考虑到输入数据随时间变化的特性,该层采用了Conv1D一维卷积结构来捕捉这些时序特征<sup>[13-15]</sup>。Conv1D一维卷积结构的设计如图1所示。

利用Max Pooling层对卷积后的电镀数据特征实施下采样,以去除冗余信息并压缩特征维度。以上的卷积和池化处理能够显著减少Cu-SiC镀层电镀数据特征的维度,提取出更有效的Cu-SiC镀层电镀数据特征值,从而缓解过拟合问题。最后,通过Flatten层将降维后的Cu-SiC镀层电镀特征数据扁平化为一维数据,为后续LSTM层的处理提供输入。

(3) LSTM层为模型的第三层,利用其强大的时序特征提取能力,深入提取CNN层输出的特征数据中的深层信息。考虑到LSTM结构的复杂性和参数优化的难度,本模型将LSTM层数设定为1层,以达到较好的预测效果。该层的操作基于LSTM网络的内部机制,能够捕捉和利用时序数据中的长期依赖关系,可以用式(5)来表示:

$$h_j(t) = LSTM(x_j(t), h_j(t-1)) \quad (5)$$

式中: $x_j(t)$ 为在时刻 $t$ ,CNN层输出的一维Cu-SiC镀

层电镀特征数据;  $h_j(t-1)$ 为时刻 $t-1$ 的LSTM层输出, 它作为Cu-SiC镀层电镀特征的时序信息被传递到当前时刻;  $LSTM(\bullet)$ 为LSTM层;  $h_j(t)$ 为LSTM层输出的Cu-SiC镀层电镀特征数据的深层数据特征。

(4) 输出层为模型的第四层, 包含两个全连接层(Dense层)。第一个Dense层用于汇聚LSTM层提取的预测信息, 并转换信息的维度; 第二个Dense层则负责输出Cu-SiC镀层镀速的预测结果<sup>[16]</sup>。

$$s_1 = L_1 h_j(t) + C_1 \quad (6)$$

$$\hat{y} = \theta(L_2 s_1 + C_2) \quad (7)$$

式中:  $s_1$ 为第一个Dense层的输出;  $C_1$ 为第一个Dense层的偏置;  $L_1$ 为第一个Dense层的权重;  $\hat{y}$ 为Cu-SiC镀层镀速的预测结果;  $L_2$ 为第二个Dense层的权重;  $C_2$ 为第二个Dense层的偏置;  $\theta$ 为线性激活函数<sup>[17]</sup>。

(5) 贝叶斯算法优化层作为模型的第五层, 利用BO算法对模型中的学习率(learning\_rate)、卷积核尺寸(kernel\_size)、卷积核个数(filters)、Dense层神经元个数(dense\_units)以及LSTM层神经元个数(lstm\_units)这5个超参数实施优化, 以进一步提升Cu-SiC镀层镀速预测的准确性和效率。




图1 Conv1D 一维卷积结构的设计

Fig.1 Design of Conv1D convolution structure

具体的超参数优化步骤如下:

(1) 定义目标函数

将模型的损失函数(如均方误差MSE函数)作为目标函数, 以超参数为输入, 输出模型在验证集上的损失值。目标函数的表达式如下:

$$MSE(\mathcal{G}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i(\mathcal{G}))^2 \quad (8)$$

式中:  $N$ 为验证集中Cu-SiC镀层电镀数据的样本数量<sup>[18-19]</sup>;  $\mathcal{G}$ 为超参数集合;  $y_i$ 为Cu-SiC镀层电镀数据样本 $i$ 的真实标签;  $MSE()$ 为均方误差函数;  $\hat{y}_i$ 为模型在超参数集合 $\mathcal{G}$ 下对Cu-SiC镀层电镀数据样本 $i$ 的预测值。

(2) 设置超参数空间

将Cu-SiC镀层镀速预测的超参数空间设置为下式:

$$\mathcal{G} = \left\{ \begin{array}{l} \text{learning\_rate} \in [0.0001, 0.1], \text{kernel\_size, filters,} \\ \text{dense\_units, lstm\_units} \in \{32, 64, 128\} \end{array} \right\} \quad (9)$$

(3) 初始化概率代理模型

使用超参数空间中的超参数取值来评估目标函数  $MSE(\mathcal{G})$ , 也就是将超参数空间中的超参数取值代入式(8)中, 利用式(8)的计算结果集合  $MSE(\mathcal{G})'$  构建初始的代理模型, 以指导后续的搜索过程, 从而提高Cu-SiC镀层镀速预测的准确性和效率:

$$G(\mathcal{G}) = \begin{cases} \mu(\mathcal{G}) = H(K + \sigma^2)^{-1} MSE(\mathcal{G})' \\ \rho^2(\mathcal{G}) = H^2 - H^2(K + \sigma^2)^{-1} MSE(\mathcal{G})' \end{cases} \quad (10)$$

式中:  $K$ 为单位函数;  $\mu(\mathcal{G})$ 为高斯预测的目标函数正态分布的均值。在Cu-SiC镀层镀速预测的上下文中, 这个均值越小, 意味着模型在验证集上的表现越好, 即预测的镀速与实际镀速之间的差异越小;  $\sigma^2$ 为  $MSE(\mathcal{G})'$  观测噪声的方差;  $\rho^2(\mathcal{G})$ 为高斯预测的目标函数正态分布的方差。在Cu-SiC镀层镀速预测的上下文中, 这个方差越小, 意味着模型在验证集上的表现越好, 即预测的镀速与实际镀速之间的差异越小;  $H$ 为集合  $MSE(\mathcal{G})'$  中最大值与最小值之间的协方差<sup>[20-21]</sup>。

(4) 迭代优化

在每次迭代中, 使用期望增量来选择下一个最有潜力的超参数组合  $\mathcal{G}^*$ :

$$\mathcal{G}^* = \arg \max_{\mathcal{G} \in \mathcal{G}} EI(G(\mathcal{G})) \quad (11)$$

式中:  $EI$ 为期望增量。

将下一个最有潜力的超参数组合  $\mathcal{G}^*$  代入式(8)中, 利用计算结果集合  $MSE(\mathcal{G})''$  更新代理模型, 重复此过程, 直到达到预定的迭代次数, 输出使代理模型达到最小值的超参数组合  $\hat{\mathcal{G}}$ , 即为优化后的最优超参数组合。利用最优超参数组合实施BO-CNN-LSTM模型的训练, 利用训练后的BO-CNN-LSTM

模型实现Cu-SiC镀层镀速的高效精准预测。

## 2 实验过程

以某汽车零部件制造厂的Cu-SiC电镀生产线为实验对象,利用设计的基于贝叶斯优化神经网络的Cu-SiC镀层镀速预测方法实施预测。实验过程中,参照1.1中的数据采集过程,采集目标生产线上的相关数据。其中,温度测量的现场如图2所示。对采集的电镀数据实施标准化处理,处理结果示例如表1所示。利用设计的贝叶斯优化神经网络的BO-CNN-LSTM模型实施Cu-SiC电镀生产线的Cu-SiC镀层镀速预测,其中前4层的实验参数设置情况如表2所示。



图2 温度测量现场

Fig.2 Temperature measurement site

表1 标准化处理结果示例

Tab.1 Examples of standardized processing results

样本编号	电流值/A	镀液温度/°C	镀液pH值	SiC 粒子浓度/(g·L <sup>-1</sup> )	镀液搅拌速率/(r·min <sup>-1</sup> )
1	0.23	0.45	0.12	0.67	0.34
2	0.56	0.12	0.23	0.12	0.45
3	0.12	0.78	0.45	0.33	0.12
4	0.89	0.67	0.46	0.98	0.78

表2 前4层的实验参数设置情况

Tab.2 Experimental parameter Settings of the first four layers

序号	参数项目	参数设置
1	CNN 层 Max Pooling 尺寸	2
2	LSTM 层激活函数	Tanh
3	LSTM 层 Dropout 率	0.2
4	Dense 层 1 激活函数	ReLU
5	Dense 层 2 神经元数量	1
6	Dense 层 2 激活函数	Linear

贝叶斯算法优化层的实验参数中,设置迭代次数为200次。完成BO-CNN-LSTM模型训练后,利用该模型实现Cu-SiC镀层镀速的预测。采用测试设计方法,对利用贝叶斯算法优化超参数前后模型的 $R^2$ 进行分析。通过 $R^2$ 能够评判模型的拟合效果,该值越接近1,说明模型的预测效果越好。随后,运用测试设计方法对Cu-SiC镀层镀速的预测效果进行测试,最后测试该方法的计算资源消耗。在这后两项测试中,将基于TSSA-SVR算法、基于均值滤波去噪和XGBoost算法的预测方法作为对比方法。

## 3 实验结果分析

### 3.1 贝叶斯算法优化超参数前后的决定系数测试

本研究利用贝叶斯算法优化超参数前后的 $R^2$ 测试结果如图3所示。从图3中可以明显看出,经过贝叶斯算法优化超参数后,本文所提方法的 $R^2$ 显著提升,更接近1,表示其预测性能得到大幅提升。原因分析如下:不同的超参数组合会导致模型在训练集和验证集上的表现差异显著。而贝叶斯优化是一种高效的超参数优化方法,能够在有限的迭代次数内找到较优的超参数组合。经过贝叶斯算法优化后的BO-CNN-LSTM模型,其超参数组合更加合理,能够更好地适应Cu-SiC镀层电镀数据的特性。在时序特征提取、数据相关性捕捉等方面,该模型展现出更强的解析力,使得 $R^2$ 值更加接近理想值1。




图3 决定系数测试结果

Fig.3 Test results of determination coefficient

### 3.2 Cu-SiC 镀层镀速预测表现效果测试

针对某生产线Cu-SiC镀层的镀速,本研究所设计的方法与两种对比方法的预测效果的结果如图4所示。从图4中可以看出,本研究所设计方法的预测

结果与实际镀速之间的偏差最小，其曲线走势与实际镀速高度一致，表现出较高的预测精度。这是由于以下原因：本研究所设计方法融入了CNN层以提取输入数据的时序特征。其中，Conv1D一维卷积结构能够敏锐捕捉电镀数据中随时间变化的关键信息，而Max Pooling层则进一步精简了信息，提取出更为精炼的特征值。这种特征提取机制使模型能够更深刻地理解电镀过程中的复杂动态关系，进一步提升了预测精度。

为了验证基于贝叶斯优化神经网络的Cu-SiC镀层镀速预测方法的可行性和准确性，根据第2部分的方法采集了电镀过程中的关键变量数据，包括电流值、镀液温度、镀液pH值、SiC粒子浓度、镀液搅拌速率等，并采用Z-score标准化方法对每种电镀数据进行归一化处理。随后，利用处理后的数据训练BO-CNN-LSTM模型，通过贝叶斯优化算法自动

搜索模型的最优超参数组合，以实现Cu-SiC镀层镀速的高效精准预测。电镀数据及其对应的镀速预测结果及实际镀速结果如表3所示。

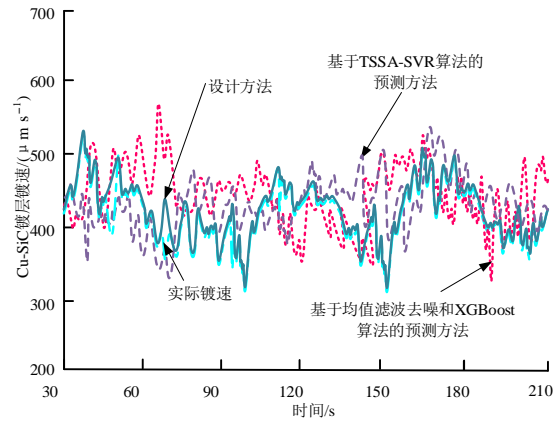


图4 Cu-SiC 镀层镀速预测表现效果测试结果

Fig.4 Test results of Cu-SiC plating speed prediction performance

表3 电镀数据及对应的镀速预测结果

Tab.3 Electroplating data and corresponding plating rate prediction results

实验编号	电流/A	镀液温度/°C	镀液pH值	SiC 粒子浓度/(g·L <sup>-1</sup> )	搅拌速率/(r·min <sup>-1</sup> )	镀速预测值/(μm·h <sup>-1</sup> )	实际镀速值/(μm·h <sup>-1</sup> )
1	5	40	5.5	20	200	2.15	2.13
2	10	50	6.0	30	300	3.87	3.85
3	15	60	6.5	40	400	5.42	5.40
4	20	70	7.0	50	500	6.78	6.80
5	25	80	7.5	60	600	8.05	8.02

由表3可知，本研究所设计方法展现出了较高的预测精度，预测值与实际镀速值极为接近。如实验编号1中的预测镀速为2.15 μm/h，与实际镀速2.13 μm/h之间仅存在0.02 μm/h的微小误差。进一步分析可知，电流值、镀液温度、镀液pH值、SiC粒子浓度及搅拌速率等电镀过程中的关键变量均对镀速有显著影响，且这些影响趋势与实验数据相吻合，如电流值的增加伴随着镀速的上升。以上结果不仅验证了本研究所设计方法的可行性和准确性，还通过系统地采集和归一化处理电镀数据，有效训练了BO-CNN-LSTM模型，实现了镀速的高效精准预测。

### 3.3 计算资源消耗测试

本研究所设计方法与两种对比方法的计算资源消耗测试结果如图5所示。由图5可以看出，本研究所设计方法在计算资源消耗方面展现出显著优势。其计算资源消耗相对较低，这主要归功于贝叶

斯优化算法的应用。贝叶斯优化算法通过高效地搜索模型的最优超参数组合，避免了传统方法中需要大量时间和计算资源来手动调整参数的弊端。这种优化不仅提升了模型的预测性能，还显著降低了模型训练过程中的计算资源消耗，使得本研究所设计

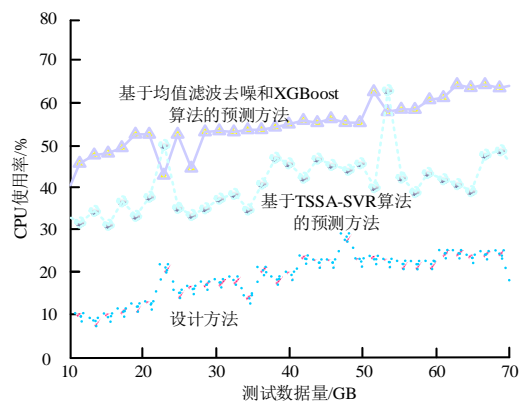


图5 计算资源消耗测试结果

Fig.5 Test results of computing resource consumption

的方法在计算资源消耗方面展现出优势。

### 3.4 镀层中SiC颗粒复合量的预测潜力测试

镀层中SiC颗粒复合量直接决定了镀层的硬度、耐磨性、耐腐蚀性等关键性能。通过准确预测镀层中SiC颗粒的复合量,可以更有效地控制电镀过程,优化电镀参数,从而制备出具有优异性能的复合镀层。这对于提高产品质量、降低生产成本以及推动复合电镀技术的发展都具有重要意义。虽然本研究设计的方法主要聚焦于镀速预测,但也对该方法用于镀层中SiC颗粒复合量的预测潜力进行了测试。实验采用了固定的电镀参数组合(电流密度 $30\text{ A/dm}^2$ 、镀液温度 $40\text{ }^\circ\text{C}$ 、镀液pH值4.5、搅拌速率 $300\text{ r}\cdot\text{min}^{-1}$ ),以评估本研究设计的方法在Cu-SiC复合电镀过程中对镀速及镀层中固体颗粒复合量的预测性能。实验过程中, SiC粒子浓度选取了不同水平进行测试,以观察其对预测精度的影响。测试结果如表4所示。

表4 镀层中SiC颗粒复合量的预测潜力

Tab.4 Prediction potential of SiC particle composite content in coatings

SiC 粒子浓度/ ( $\text{g}\cdot\text{L}^{-1}$ )	镀速预测精度/ %	镀层中 SiC 颗粒复 合量预测精度/%
10	96.5	84.2
15	97.2	86.5
20	96.8	87.3
25	97.0	88.1
30	96.7	87.8

由表4可以看出,在不同SiC粒子浓度下,本研究设计的方法在镀速和镀层中SiC颗粒复合量的预测上均展现出了较高的精度。值得注意的是,随着SiC粒子浓度的增加,镀层中SiC颗粒复合量的预测精度呈现出上升趋势,这可能与SiC粒子在镀液中的分散状态更加均匀、碰撞频率增加以及沉积效率提高有关。具体来说,当SiC粒子浓度较低时,粒子间的距离较大,碰撞和沉积的机会相对较少,导致预测精度稍低;而随着浓度的增加,粒子间的相互作用增强,分散更加均匀,碰撞和沉积到镀层中的机会也随之增加,从而提高了预测精度。同时,镀速预测精度在不同SiC粒子浓度下也保持了相对稳定,这表明该方法在电镀参数变化时具有较好的适应性和鲁棒性,能够准确反映电镀过程中的动态变化。

## 4 结论

本研究针对Cu-SiC镀层镀速预测问题,提出了一种创新的解决方案,即基于贝叶斯优化的神经网络预测方法。该方法通过系统地采集电镀过程中的关键参数,并应用Z-score标准化处理,有效增强了数据的一致性和可比性。随后,设计了BO-CNN-LSTM模型,该模型不仅能够捕捉电镀数据的空间特征,还能准确反映其时间依赖性。通过贝叶斯优化算法自动搜索最优超参数组合实现了模型训练的高效性。实验验证表明,该方法在预测Cu-SiC镀层镀速方面展现出高精度,预测结果与实际镀速高度吻合,且计算效率显著提升,CPU使用率相对较低。这一研究成果为电镀过程控制和优化提供了新的视角和工具。

## 参考文献

- [1] 丁浩,张慧,孙锡科,等.电刷镀-电接触强化复合工艺制备厚镀层研究[J].热加工工艺,2022,51(24):92-96.
- [2] 周柏玉.聚醚醚酮化学镀Ni-P及Ni-Cu-P镀层微观结构及性能对比研究[J].材料保护,2023,56(5):127-132.
- [3] 赵健伟,于晓辉,袁桂云,等.无氰镀银液的浓度对成核机理,镀液和镀层性能的影响[J].电镀与精饰,2022,44(12):1-10.
- [4] 彭继慎,郝茗,宋立业,等.基于TSSA-SVR算法的TBM掘进速度预测[J].辽宁工程技术大学学报(自然科学版),2023,42(5):634-640.
- [5] 杜庆峰,张双俐,张晨曦,等.基于均值滤波去噪和XGBoost算法的泥水平衡盾构掘进速度预测方法[J].现代隧道技术,2022,59(6):14-23.
- [6] 胡业红,何梦,周参军,等.基于GA-BP神经网络的毫秒延时爆破振动速度预测研究[J].中国矿业,2022,31(2):72-77.
- [7] HUANG Y, LIU W, LI Y, et al. MFE-SSNet: Multi-modal fusion-based end-to-end steering angle and vehicle speed prediction network[J]. Automotive Innovation, 2024, 7(4): 545-558.
- [8] 崔凯,任伟和. Cr12MoV 模具钢化学镀 Ni-W-P/PTFE 复合镀层及耐磨性能研究[J]. 电镀与精饰, 2023, 45(10): 32-39.
- [9] 任鑫,王港,孙涛,等.纳米TiC浓度对双脉冲电沉积Ni-TiC复合镀层结构及性能的影响[J].材料热处理学报,2024,45(4):167-173.

[10] 邱有春, 赵立平. 基于改进神经网络的机身镀层抗冲击性能预测[J]. 兵器材料科学与工程, 2022, 45(5): 148-153.

[11] 刘征达, 于静, 张帅. 基于响应曲面法的镍-钴合金镀层多性能优化[J]. 电镀与涂饰, 2023, 42(17): 8-15.

[12] 睦志强, 李树华, 林璟, 等. 机器学习在超临界二氧化碳制膜技术教学中的应用实践[J]. 电镀与涂饰, 2024, 43(6): 93-101.

[13] 秦海森, 刘丽, 张凤, 等. 泡沫基材-Ni-石墨烯复合镀层制备及电催化析氢性能研究[J]. 表面技术, 2024, 53(2): 221-229.

[14] ZHOU M, ZHOU J, XU G J. Clarification question generation diversity and specificity enhancement based on question keyword prediction[J]. Applied Intelligence: The International Journal of Artificial Intelligence, Neural Networks, and Complex Problem-Solving Technologies, 2024, 54(3): 2379-2396.

[15] YADAV S, GANESAN S. ConvStabNet: a CNN-based approach for the prediction of local stabilization parameter for SUPG scheme[J]. Calcolo, 2024, 61(3): 1-23.

[16] 王琳, 黄昊天, 周宏桥, 等. 基于响应面法的锌-铁-锰合金脉冲电沉积工艺优化[J]. 电镀与涂饰, 2024, 43(10): 31-40.

[17] 黄燕, 杨裴裴, 董富江. 基于贝叶斯算法优化的多阈值图像分割仿真[J]. 计算机仿真, 2024, 41(6): 223-226, 312.

[18] 毛望军, 高志廷. 齿轮钢电沉积Ni-W/MoS<sub>2</sub>自润滑复合镀层及性能研究[J]. 电镀与精饰, 2023, 45(4): 31-37.

[19] RAMAZAN K, IREM D K. The optimization of nickel electroplating process parameters with artificial intelligence methods[J]. Journal of Applied Electrochemistry, 2023, 53(10): 2077-2089.

[20] GAO M, PEI Z, SONG H G J. Wear resistance of Ni/nano-Al<sub>2</sub>O<sub>3</sub> composite coatings by brush electroplating[J]. Journal of Materials Science, 2024, 59(16): 7009-7027.

[21] NGUYEN D T, CHU D T, NGUYEN T H N, et al. Highly selective welding of ultralong silver nanowire transparent conductive electrodes by electroplating[J]. Journal of Electronic Materials, 2023, 52(11): 7676-7682.

\*\*\*\*\*

\*上接 122 页\*

适应控制[J]. 电镀与精饰, 2025, 47(2): 118-125.

[8] 肖洋轶, 罗静, 石万凯, 等. 表面微织构涂层-基体系统重载弹流润滑性能分析[J]. 表面技术, 2020, 49(7): 159-167.

[9] 高磊, 王明伟, 张文超, 等. 基于灰色关联分析法的电火花沉积 WC-12Co 涂层工艺参数优化[J]. 热加工工艺, 2024, 53(12): 57-61.

[10] 李远哲, 孙亚东, 付昭旺, 等. 基于改进灰色关联分析法的装备作战能力量化评估[J]. 火力与指挥控制, 2024, 49(3): 178-184.

[11] 杨光义, 薛若尧, 张若茜, 等. 基于 BP 神经网络的特征融合遥感图像阴影检测[J]. 武汉大学学报(工学版), 2023, 56(6): 757-763.

[12] 纪泳丞, 季文昊, 贾艳敏, 等. 基于 BP 神经网络的寒区再生微粉工程水泥基复合材料力学性能研究[J]. 冰川冻土, 2024, 46(1): 126-136.

[13] 陈勇, 姜一炜, 易文超, 等. 基于 GA-BP 神经网络的智能制造系统评价模型[J]. 浙江工业大学学报, 2023, 51(4): 377-386.

[14] 李凯, 魏鹤琳, 尹志凡, 等. 基于 GA-BP 神经网络模型预测水基炭黑-胶原蛋白纳米流体热导率和黏度[J]. 化工进展, 2024, 43(7): 4138-4147.

[15] 新巴雅尔, 辛英臣, 孙思意, 等. 基于 ANSYS 的耐热钢高温磨损性能研究[J]. 计算机仿真, 2023, 40(9): 318-323, 501.