

基于人工神经网络的 Ni-ZrO₂ 纳米镀层 耐腐蚀性能预测

邓羽^{1,2,3}, 张杰^{1,2,3,4}, 彭中波¹, 徐玮辰^{2,3}

(1.重庆交通大学 航运与船舶工程学院, 重庆 400074; 2.中国科学院海洋研究所 中国科学院海洋环境腐蚀与生物污损重点实验室, 山东 青岛 266071; 3.青岛海洋科学与技术试点国家实验室 海洋腐蚀与防护开放工作室, 山东 青岛 266237; 4.中国科学院 海洋大科学研究中心, 山东 青岛 266071)

摘要: **目的** 对 Ni-ZrO₂ 纳米镀层的耐腐蚀性能进行预测, 优化电镀工艺参数。 **方法** 采用磁力搅拌辅助电沉积法, 在钴镍基模型合金试样表面制备 Ni-ZrO₂ 纳米镀层, 针对电镀工艺条件, 设置正交实验, 对每组实验镀层进行电化学测试, 分析不同工艺条件下镀层的耐蚀性能。将 ZrO₂ 粒子浓度、电镀液温度和电镀电流密度作为神经网络的输入层, 将自腐蚀电流密度作为输出层, 运用 GRNN 神经网络和 BP 神经网络模型, 对 Ni-ZrO₂ 纳米镀层进行耐腐蚀性能的预测研究。 **结果** 当 ZrO₂ 粒子质量浓度为 6 g/L、电镀液温度为 60 ℃、电镀电流密度为 5 A/dm² 时, Ni-ZrO₂ 纳米镀层的性能良好, 表现出较小的自腐蚀电流密度。影响 Ni-ZrO₂ 镀层自腐蚀电流密度的因素满足 ZrO₂ 粒子浓度>电镀液温度>电镀电流密度。运用 GRNN 神经网络和 BP 神经网络对 4 组非正交实验预测的平均相对误差分别为 5.30% 与 10.74%。 **结论** 运用神经模型可以有效地预测不同工艺参数下镀层的耐腐蚀性能, 从而优化工艺参数, 提高实验效率。在训练样本较少的情况下, GRNN 神经网络的预测性能更加精确。

关键词: 电沉积; Ni-ZrO₂ 纳米镀层; GRNN 神经网络; BP 神经网络; 自腐蚀电流密度; 预测

中图分类号: TG174.4

文献标识码: A

文章编号: 1672-9242(2022)02-0098-08

DOI: 10.7643/issn.1672-9242.2022.02.016

Prediction of Corrosion Resistance of Ni-ZrO₂ Nano-Plating Based on Artificial Neural Network

DENG Yu^{1,2,3}, ZHANG Jie^{1,2,3,4}, PENG Zhong-bo¹, XU Wei-chen^{2,3}

(1. School of Shipping and Naval Architecture, Chongqing Jiaotong University, Chongqing 400074, China; 2. Key Laboratory of Marine Environmental Corrosion and Bio-fouling, Institute of Oceanology, Chinese Academy of Sciences, Qingdao 266071, China; 3. Open Studio for Marine Corrosion and Protection, Pilot National Laboratory for Marine Science and Technology (Qingdao), Qingdao

收稿日期: 2021-10-14; 修订日期: 2021-11-19

Received: 2021-10-14; Revised: 2021-11-19

基金项目: 国家自然科学基金 (41376003); 中国科学院战略性先导科技专项 (A 类) (XDA13040405)

Fund: The National Natural Science Foundation of China (41376003) and the Strategic Priority Research Program of the Chinese Academy of Sciences (XDA13040405)

作者简介: 邓羽 (1997—), 男, 硕士研究生, 主要研究方向为海洋腐蚀与防护。

Biography: DENG Yu (1997—), Male, Postgraduate, Research focus: marine corrosion and protection.

通讯作者: 张杰 (1976—), 男, 博士, 研究员, 主要研究方向为海洋腐蚀与防护。

Corresponding author: ZHANG Jie (1976—), Male, Doctor, Researcher, Research focus: marine corrosion and protection.

引文格式: 邓羽, 张杰, 彭中波, 等. 基于人工神经网络的 Ni-ZrO₂ 纳米镀层耐腐蚀性能预测[J]. 装备环境工程, 2022, 19(2): 098-105.

DENG Yu, ZHANG Jie, PENG Zhong-bo, et al. Prediction of Corrosion Resistance of Ni-ZrO₂ Nano-Plating Based on Artificial Neural Network [J]. Equipment Environmental Engineering, 2022, 19(2): 098-105.

266237, China; 4. Center for Ocean Mega-science, Chinese Academy of Sciences, Qingdao 266071, China)

ABSTRACT: The work aims to predict the corrosion resistance of Ni-ZrO₂ nano-plating and optimize the plating process parameters. Ni-ZrO₂ nano-plating was prepared on the surface of cobalt-nickel-based model alloy samples by magnetic stirring-assisted electrodeposition. According to the electroplating process conditions, orthogonal experiments were set up, and each group of experimental plating was electrochemically tested to analyze the corrosion resistance with different process conditions. The three plating process parameters of ZrO₂ particle concentration, plating solution temperature and plating current density were used as the input layer of the neural network, and the self-corrosion current density was used as the output layer. The GRNN neural network and BP neural network models were used to predict the corrosion resistance of Ni-ZrO₂ nano-plating. When the mass concentration of ZrO₂ particles is 6 g/L, the temperature of the plating solution is 60 °C, and the plating current density is 5 A/dm², the performance of the Ni-ZrO₂ nano-plating is good, showing a small self-corrosion current density. The factors affecting the self-corrosion current density of Ni-ZrO₂ nano-plating should meet the following requirements ZrO₂ particle concentration>plating solution temperature> plating current density. The average relative errors of the four groups of non-orthogonal experiments predicted by GRNN neural network and BP neural network are 5.30% and 10.74%, respectively. The neural model can effectively predict the corrosion resistance of the plating under different process parameters, thereby optimizing the process parameters and improving the experimental efficiency. In the case of fewer training samples, the prediction performance of the GRNN neural network is more accurate.

KEY WORDS: electrodeposition; Ni-ZrO₂ nano-plating; GRNN neural network; BP neural network; self-corrosion current density; prediction

腐蚀预测一直是腐蚀领域中比较重要的研究内容^[1]。金属的腐蚀常常会受到诸如温度、氧含量、盐度、pH 值、生物活性等因素的影响^[2]。其中人工神经网络预测腐蚀速率正逐步成为一种新的技术手段,备受各界学者广泛关注和研究^[3-5]。神经网络具有大规模并行、分布式存储和处理、自组织、自适应和自学习能力等传统函数算法无法比拟的优点^[6-8]。人工神经网络的模型种类很多,目前已有近 40 种神经网络模型,而在腐蚀预测上应用最多的也最常见的神经网络是 BP 神经网络。王涛等^[9]运用 BP 神经网络对玻璃纤维增强塑料在腐蚀条件下进行寿命预测,取得了较好的预测效果。邓春龙等^[10]建立了碳钢、低合金钢在实海环境中腐蚀速率与环境因素、材料成分之间的 BP 神经网络预测模型,较准确地预测了碳钢、低合金钢在不同海域的腐蚀速率。在训练数据集数据较少的情况下,BP 神经网络的预测性能往往不太理想。Specht^[11]于 1991 年在研究径向基网络的基础上,根据它的变化形式,提出了广义回归神经网络(GRNN 神经网络)的概念,其具有很强的非线性映射能力,训练速度快,且在数据缺乏时,能够取得较好的运算效果。刘应雷等^[12]基于 GRNN 神经网络的反演方法,快速、准确地获取了粘三元乙丙橡胶薄膜接界面的力学性能参数。靳文博等^[13]基于 GRNN 神经网络对海底腐蚀管道的极限承载力进行了预测,平均相对误差为 4.67%,取得了较好的预测效果。Ni-ZrO₂ 纳米镀层作为一种复合型金属基镀层,硬度高,耐磨性能好,并具有较好的耐腐蚀性能,被广泛用于燃气轮机发动

机及重大机械的关键部件^[14-17]。因此,对不同工艺条件下制备的 Ni-ZrO₂ 纳米镀层的耐腐蚀性能研究显得尤为重要^[18-20]。

本文将采用 GRNN 神经网络和 BP 神经网络对 Ni-ZrO₂ 纳米镀层的电化学自腐蚀电流密度进行模拟和预测研究,来预测其自腐蚀电流密度的大小,达到预测其腐蚀速率的变化规律的目的,这将有助于了解不同电镀工艺条件下 Ni-ZrO₂ 纳米镀层的耐蚀性能。通过对不同神经网络模型的预测结果进行对比,也可为较少训练样本条件下的耐腐蚀性能预测提供更好的神经网络模型选择。

1 实验

1.1 材料制备

采用钴镍基模型合金(Co-35Ni-20Cr-10Mo)作为阴极,其中合金样品为直径 10 mm、厚度为 3 mm 的圆柱形试片,并用环氧树脂封装。然后使用规格为 20 mm×20 mm×2 mm 的高纯镍板(Ni-99.999%)作为阳极。在电镀之前,需用 240#—2000#的 SiC 砂纸对每个样品的工作表面进行打磨,然后用去离子水冲洗,再用无水乙醇除油,最后干燥,备用。

1.2 电镀实验

主要借助 DF-101S 集热式恒温加热磁力搅拌器和 IT6863 可编程直流电源辅助电镀实验的顺利开展,电镀过程所需试剂及工艺参数见表 1。

表 1 Ni-ZrO₂ 镀层镀液成分及制备工艺
Tab.1 Compositions and preparation process of Ni-ZrO₂ plating solution

Chemical reagent	Parameter	Process condition	Parameter
$\rho(\text{NiSO}_4 \cdot 6\text{H}_2\text{O})/(\text{g} \cdot \text{L}^{-1})$	250	Plating bath temperature/ $^{\circ}\text{C}$	30~60
$\rho(\text{NiCl}_2 \cdot 6\text{H}_2\text{O})/(\text{g} \cdot \text{L}^{-1})$	45	Plating current density/ $(\text{A} \cdot \text{dm}^{-2})$	3~6
$\rho(\text{H}_3\text{BO}_3)/(\text{g} \cdot \text{L}^{-1})$	40	Magnetic rotor speed/ $(\text{r} \cdot \text{s}^{-1})$	10
$\rho(\text{Activator HCl})/(\text{g} \cdot \text{L}^{-1})$	3	Activation time/min	10
$\rho(\text{ZrO}_2 \text{ particles})/(\text{g} \cdot \text{L}^{-1})$	3~12	Plating time/min	10

1.3 电化学腐蚀实验

电化学测试溶液采用常温下质量分数为 3.5%的 NaCl 溶液, 借助电化学工作站 Zahner Zennium Pro 对试样进行动电位极化实验。其中动电位极化扫描速率为 1 mV/s, 扫描范围为-250~250 mV (vs.SCE)。自腐蚀电流密度可以通过 Cview 软件从极化曲线的 Tafel 区域拟合获得。

1.4 正交实验设计

影响镀层耐腐蚀性能的电镀工艺条件主要为 ZrO₂ 粒子浓度、电镀液温度和电镀电流密度。每个工艺条件都有 4 组数值设置方式, 为了使实验简单高效, 采用正交实验设计法, 一共设计 16 组正交实验。采用 L₁₆(4³)正交实验表进行电镀实验, 并且对每组实验镀层进行极化测试, 计算出自腐蚀电流密度。其所选用因素及实验结果见表 2。从表 2 中计算的极差结果可以看出, 影响 Ni-ZrO₂ 镀层自腐蚀电流密度

表 2 正交实验结果
Tab.2 Results of orthogonal experiment


Number	$\rho(\text{ZrO}_2 \text{ particles})/(\text{g} \cdot \text{L}^{-1})$	Plating bath temperature/ $^{\circ}\text{C}$	Plating current density/ $(\text{A} \cdot \text{dm}^{-2})$	Free corrosion current density/ $(\mu\text{A} \cdot \text{cm}^{-2})$
1	3	30	3	1.5734
2	3	40	4	1.5227
3	3	50	5	1.1025
4	3	60	6	1.0208
5	6	30	4	0.9189
6	6	40	3	0.8828
7	6	50	6	0.9068
8	6	60	5	0.8686
9	9	30	5	1.4107
10	9	40	6	1.0873
11	9	50	3	1.1885
12	9	60	4	0.9886
13	12	30	6	1.3151
14	12	40	5	0.9550
15	12	50	4	1.1062
16	12	60	3	1.4875
Extremum	0.4106	0.2285	0.2005	—

大小的条件权重满足: ZrO₂ 粒子浓度>电镀液温度>电镀电流密度。将表 2 的数据作为神经网络的训练集, ZrO₂ 粒子浓度、电镀液温度和电镀电流密度为神经网络的输入层神经节点, 自腐蚀电流密度为输出层神经节点, 对目标神经网络进行训练。

2 神经网络的设计

2.1 GRNN 神经网络

如图 1 所示, 输入层接收样本的输入, 神经元个数等于输入向量的维数。模式层是径向基层, 神经元个数等于训练样本数。求和层的神经元分为两种: 第一种神经元计算模式层各神经元的代数和; 第二种神经元计算模式层神经元的加权和。输出层将求和层的加权和与代数和相除, 即得 y 的估算值^[21]。



Input layer Pattern layer Summation layer Output layer

图 1 GRNN 神经网络的结构

Fig.1 GRNN neural network structure diagram

假设 x, y 是两个随机变量, 其联合概率密度为 $f(x, y)$ 。若已知 x 的观测值为 x_0 , 则 y 相当于 x 的回归, 见式 (1)。

$$E(y | x_0) = (x_0) = \frac{\int_{-\infty}^0 y f(x_0, y) dy}{\int_{-\infty}^0 f(x_0, y) dy} \quad (1)$$

$y(x_0)$ 即在输入为 x_0 的条件下, y 的预测输出。应用 Parzen 非参数估计, 可由样本数据集 $\{x_i, y_i\}_{i=1}^n$ 按照式 (2) 估算密度函数 $f(x_0, y)$ 。

$$f(x_0,y)=\frac{1}{n(2\pi)^{\frac{p+1}{2}}\sigma^{p+1}}\sum_{i=1}^n e^{-d(x_0,x_i)}e^{-d(y_0,y_i)} \tag{2}$$

其中：

$$d(x_0,x_i)=\frac{(x_0-x_i)^T(x_0-x_i)}{2\sigma^2} \tag{3}$$

$$d(y_0,y_i)=\frac{(y_0-y_i)^2}{2\sigma^2} \tag{4}$$

式中： n 为样本容量； p 为随机变量 x 的维数； σ 为光滑因子。将式（2）—（4）代入（1），并交换积分与求和的顺序，有：

$$y(x_0)=\frac{\sum_{i=1}^n\left(e^{-d(x_0,x_i)}\int_{-\infty}^{+\infty} ye^{-d(y_0,y_i)}dy\right)}{\sum_{i=1}^n\left(e^{-d(x_0,x_i)}\int_{-\infty}^{+\infty} e^{-d(y_0,y_i)}dy\right)} \tag{5}$$

由于 $\int_{-\infty}^{+\infty} xe^{-x^2}dx=0$ ，式（5）可简化为：

$$y(x_0)=\frac{\sum_{i=1}^n ye^{-d(y_0,y_i)}}{\sum_{i=1}^n e^{-d(x_0,x_i)}} \tag{6}$$

GRNN 神经网络不需要训练，但光滑因子的值对网络性能的影响很大，需要优化取值^[22]。以 ZrO₂ 粒子质量浓度、电镀液温度以及电镀的电流密度作为 GRNN 神经网络的输入层，以在电化学实验中测试所得到的自腐蚀电流密度表征 Ni-ZrO₂ 纳米镀层的腐蚀速率，并以此作为输出层。在确定输入和输出变量后，对所有数据进行归一化处理，使数据都在[0, 1]，最后与实际数值进行对比时，再进行反归一化处理。为了确定 GRNN 神经网络的光滑因子 σ ，对 16 组正交实验样品数据进行训练，将光滑因子进行一维寻优，对每组光滑因子下的网络模型都进行计算，最终与实验值进行比对，选出误差最小的组别，此时的神经网络模型才具备良好的预测条件。不同光滑因子下网络模型的模拟值和实验值见表 3。不同光滑因子下模拟值和实验者的误差如图 2 所示。可以看出，当 σ 的值为 0.1 时，误差趋近于 0，此时的神经网络模型具有较好的预测性能。

采用 GRNN 神经网络对非正交组 4 组样本进行预测，以验证其预测的效果。GRNN 神经网络对非正交组的预测值与实验值的对比如图 3 所示，具体参数见表 4。由表 4 中数据可知，GRNN 神经网络结构预测值与实验值的差异并不大。其中用来预测的 4 组非正交实验结果也显示，误差率并没有超过 10%，可见对于在训练样本不是足够多的情况下，GRNN 神经网络依然能够较好地预测 Ni-ZrO₂ 镀层自腐蚀电流密度的变化规律。

表 3 不同光滑因子下模型训练模拟值
Tab.3 Simulation values of model training under different smoothing factors

Number	Experimental value	Simulation value				
		$\sigma=1$	$\sigma=0.5$	$\sigma=0.3$	$\sigma=0.2$	$\sigma=0.1$
1	1.5734	1.1762	1.273	1.4095	1.5455	1.5734
2	1.5227	1.1495	1.2068	1.3493	1.4911	1.5227
3	1.1025	1.1213	1.0886	1.0919	1.1007	1.1025
4	1.0208	1.0928	1.0059	0.9996	1.0171	1.0208
5	0.9189	1.1576	1.1801	1.0985	0.9526	0.9189
6	0.8828	1.1549	1.1583	1.0595	0.9156	0.8828
7	0.9068	1.1086	1.0322	0.9581	0.9157	0.9068
8	0.8686	1.1067	1.0183	0.9301	0.8793	0.8686
9	1.4107	1.1459	1.168	1.2651	1.3838	1.4107
10	1.0873	1.1248	1.1121	1.1108	1.0919	1.0873
11	1.1885	1.1428	1.1388	1.1573	1.1828	1.1885
12	0.9886	1.1224	1.0952	1.0606	1.0023	0.9886
13	1.3151	1.141	1.1905	1.2568	1.3052	1.3151
14	0.9550	1.1342	1.1222	1.0694	0.9766	0.955
15	1.1062	1.1339	1.127	1.1256	1.11	1.1062
16	1.4875	1.1405	1.2128	1.3484	1.4639	1.4875




图 2 正交组 Ni-ZrO₂ 镀层在 GRNN 神经网络不同光滑因子下的模拟误差结果

Fig.2 Simulation error results of different smoothing factors of GRNN neural network of Ni-ZrO₂ plating in orthogonal group




图 3 非正交组 Ni-ZrO₂ 镀层 GRNN 神经网络的模拟结果
Fig.3 Simulation results of GRNN neural network of Ni-ZrO₂ plating in non-orthogonal group

表4 非正交组 GRNN 神经网络模型预测值与实验值的比较

Tab.4 Comparison of experimental values and predicted values by GRNN neural network model in non-orthogonal group

Number	$\rho(\text{ZrO}_2 \text{ particles})/(\text{g} \cdot \text{L}^{-1})$	Plating bath temperature/ $^{\circ}\text{C}$	Plating current density/ $(\text{A} \cdot \text{dm}^{-2})$	Free corrosion current density/ $(\mu\text{A} \cdot \text{cm}^{-2})$		Relative error/%
				Predictive value	Experimental value	
1	6	30	5	1.1648	1.1084	5.10
2	6	40	6	0.9970	1.0377	3.91
3	9	30	6	1.2711	1.2119	4.88
4	9	40	5	1.1510	1.2421	7.33

2.2 BP 神经网络

BP 神经网络的结构如图 4 所示。BP 神经网络的运算过程主要分为两个阶段，第一阶段是信号的前向传播，第二阶段是误差的反向传播。反复对前向传播和反向传播的中间参数进行调整，得到 BP 神经网络基础模型^[23-25]。




图4 BP神经网络的结构

Fig.4 BP neural network structure diagram

设节点 i 和节点 j 之间的权值为 w_{ij} ，节点 j 的阈值为 b_j ，每个节点的输出值为 x_j ，而每个节点的输出值是根据上层所有节点的输出值、当前节点与上一层所有节点的权值和当前节点的阈值还有激活函数来实现的^[26]。计算方法见式 (7)。

$$S_j = \sum_{i=0}^{m-1} w_{ij} + b_j \quad (7)$$

$$x_j = f(S_j)$$

其中 f 为激活函数，一般选取 S 型函数或者线性函数。误差函数见式 (8)。

$$E(w, b) = \frac{1}{2} \sum_{j=0}^{n-1} (d_j - y_j)^2 \quad (8)$$

根据梯度下降法，权值矢量的修正正比于当前位置上 $E(w, b)$ 的梯度，对于第 j 个输出节点有：

$$\Delta w(i, j) = -\eta \frac{\partial E(w, b)}{\partial w(i, j)} \quad (9)$$

假设选择激活函数为 $f(x) = \frac{A}{1 + e^{-\frac{x}{B}}}$ ，对激活函数

求导，得到：

$$f'(x) = \frac{f(x)[A - f(x)]}{AB} \quad (10)$$

针对 w_{ij} ，有：

$$\frac{\partial E(w, b)}{\partial w_{ij}} = \frac{1}{\partial w_{ij}} \cdot \frac{1}{2} \sum_{j=0}^{n-1} (d_j - y_j)^2 = \quad (11)$$

$$(d_j - y_j) \cdot \frac{f[A - f(S_j)]}{AB} \cdot x_i = \delta_{ij} \cdot x_i$$

其中， $\delta_{ij} = (d_j - y_j) \cdot \frac{f(S_j)[A - f(S_j)]}{AB}$ ，对于 b_j ，

有 $\frac{\partial E(w, b)}{\partial b_j} = \delta_{ij}$ 。

采用 3 层 BP 神经网络模型对 Ni-ZrO₂ 纳米镀层的腐蚀速率进行预测。与 GRNN 神经网络一样，以 ZrO₂ 粒子质量浓度、电镀液温度以及电镀的电流密度作为输入层，以在电化学实验中测试所得到的自腐蚀电流密度表征 Ni-ZrO₂ 纳米镀层的腐蚀速率，并以此作为输出层。以 16 组正交实验数据作为训练数据，在非正交组中的实验数据中随机选取 4 组作为预测数据。设置隐含层节点数为 10，最大训练次数为 1500，训练目标最小误差为 0.001，学习速率设置为 0.01。采用 logsig 函数为传递函数，trainlm 函数为训练函数，所有数据均进行归一化处理。

该网络的训练集拟合曲线如图 5 所示。拟合系数 R 表征神经网络的训练情况，越接近 1，训练程度越好。该网络训练拟合系数为 0.997 78，已可以用于预测。图 6 和表 5 为 BP 神经的预测数值以及预测数值和实验数值对比，可以看出，这 4 组值的相对误差均在 15% 以内。




图5 训练样本的线性拟合

Fig.5 Linear fitting of training samples

表 5 非正交组 BP 神经网络模型预测值与实验值的比较

Tab.5 Comparison between the predicted value and the experimental value by BP neural network model in the non-orthogonal group

Number	$\rho(\text{ZrO}_2 \text{ particles})/(\text{g}\cdot\text{L}^{-1})$	Plating bath temperature/ $^{\circ}\text{C}$	Plating current density/ $(\text{A}\cdot\text{dm}^{-2})$	Free corrosion current density/ $(\mu\text{A}\cdot\text{cm}^{-2})$		Relative error/%
				Predictive value	Experimental value	
1	6	30	5	0.9416	1.1084	15.00
2	6	40	6	0.9607	1.0377	7.42
3	9	30	6	1.3272	1.2119	9.51
4	9	40	5	1.1049	1.2421	11.04




图 6 非正交组 Ni-ZrO₂ 镀层 BP 神经网络的预测结果
Fig.6 Prediction result of BP neural network Ni-ZrO₂ plating in non-orthogonal group

2.3 GRNN 和 BP 神经网络预测效果对比

由于 Ni-ZrO₂ 纳米镀层的制备工艺复杂，且成功率低，所以训练样本数量较少。在训练样本集少的情况下，使用了两种神经网络对 Ni-ZrO₂ 纳米镀层的自腐蚀电流密度即耐蚀性能进行了预测。实验值、GRNN 和 BP 神经网络预测值的对比如图 7 所示。可以看出，对 4 组样本的预测，GRNN 神经网络的结果都更接近于实验值，最终预测的平均相对误差为 5.30%，具有良好的预测性能，而 BP 神经网络预测值的平均相对误差为 10.74%。可知在训练样本少的情况下，在预测效果和计算速度上，GRNN 神经网络都更具有优势。




图 7 神经网络预测值与实验值对比
Fig.7 Comparison of the predicted value and experimental value of neural networks

3 结论

1) 从 ZrO₂ 粒子质量浓度、电镀液温度以及电镀的电流密度等设置参数变化的角度，研究了 3 个工艺条件对 Ni-ZrO₂ 纳米镀层耐腐蚀性能的影响。结果表明，电镀过程中，ZrO₂ 粒子浓度对镀层耐蚀性能的影响最大，其次是电镀液温度，电镀电流密度影响最小。当 ZrO₂ 粒子质量浓度为 6 g/L、电镀液温度为 60 $^{\circ}\text{C}$ 、电镀电流密度为 5 A/dm² 时，表现出较小的自腐蚀电流密度，此时 Ni-ZrO₂ 纳米镀层的耐蚀性能较好。

2) 建立 GRNN 和 BP 神经网络模型对 Ni-ZrO₂ 纳米镀层的自腐蚀电流密度进行预测。GRNN 神经网络的平均预测误差为 5.30%，BP 神经网络的平均预测误差为 10.74%，都具有较好的预测效果。

3) 由于电镀工艺的特殊性，短期内不能大量获取样本实验数据，而 GRNN 神经网络在训练集较少的情况下也能表现出良好的预测效果。由此可知，当实验数据足够多时，便可以建立更加精准的神经网络模型。只需给出 ZrO₂ 粒子浓度、电镀液温度和电镀电流密度这 3 个变量或者更多变量的不同组合值，便能获取在该种电镀工艺条件下镀层腐蚀电流密度的近似值，这将对探究镀层的耐蚀性能具有极其深远的意义。这种紧密结合神经网络与电化学的研究方法，为相关研究领域引进了新思路和新方法。

参考文献：

[1] COTTISR A, TUREGA M. Neural Network Applications in Corrosion Engineering[M]. Chicago: Engineering Books Inc, 1993, 201-204.

[2] 兰志刚, 侯保荣, 白刚, 等. 海洋环境中平台钢腐蚀速率的三层 BP 神经网络预测[J]. 海洋科学, 2010, 34(12): 75-77.

LAN Zhi-gang, HOU Bao-rong, BAI Gang, et al. Prediction of Effects of Marine Environmental Factors on Steel Corrosion Rates with Three-Layer BP Neural Network[J]. Marine Sciences, 2010, 34(12): 75-77.

[3] 周琼宇, 谢蔚, 王小芬, 等. 基于人工神经网络预测 Ni-W 合金镀层的硬度和耐腐蚀性能[J]. 表面技术, 2016, 45(12): 140-146.

- ZHOU Qiong-yu, XIE Wei, WANG Xiao-fen, et al. Artificial Neural Network-Based Prediction of Hardness and Corrosion Resistance of Ni-W Alloy Coating[J]. Surface Technology, 2016, 45(12): 140-146.
- [4] 吴剑胜, 王天林, 周玄昊, 等. 基于神经网络的热镀锌镀层厚度建模与预测方法[J]. 中国仪器仪表, 2017(4): 65-68.
- WU Jian-sheng, WANG Tian-lin, ZHOU Xuan-hao, et al. Study on the Modeling and Prediction of Coating Weight in Hot Dip Galvanizing Line Based on Neural Network[J]. China Instrumentation, 2017(4): 65-68.
- [5] 颜菲, 张军. 粒子群算法优化的人工神经网络预测 Ni-Fe 合金镀层的性能[J]. 电镀与环保, 2019, 39(1): 24-27.
- YAN Fei, ZHANG Jun. Prediction of Properties of Ni-Fe Alloy Coatings Based on Particle Swarm Optimization Optimized Artificial Neural Network[J]. Electroplating & Pollution Control, 2019, 39(1): 24-27.
- [6] 姚尚锋. 基于正交试验的神经网络设计[J]. 数学的实践与认识, 2008, 38(13): 116-122.
- YAO Shang-feng. Design of Neural Network Based on Experiment of Orthogonality[J]. Mathematics in Practice and Theory, 2008, 38(13): 116-122.
- [7] 武晓威, 冯玉杰, 陈宇, 等. 均匀共沉淀法制备 NiO 包覆 Al 粉体及性能研究[J]. 人工晶体学报, 2012, 41(2): 479-484.
- WU Xiao-wei, FENG Yu-jie, CHEN Yu, et al. Preparation and Properties of NiO Coated Al Powders by Homogeneous Coprecipitation Method[J]. Journal of Synthetic Crystals, 2012, 41(2): 479-484.
- [8] 魏汉军, 孙万昌, 侯冠群, 等. 基于 BP 神经网络的 Ni-Si₃N₄ 复合镀层工艺-性能模型预测[J]. 人工晶体学报, 2014, 43(9): 2377-2383.
- WEI Han-jun, SUN Wan-chang, HOU Guan-qun, et al. Model Prediction of Processing-Property of Ni-Si₃N₄ Composite Coatings Based on Artificial Neural Network[J]. Journal of Synthetic Crystals, 2014, 43(9): 2377-2383.
- [9] 王涛, 王俊, 赵迪宇, 等. 基于 BP 神经网络的玻璃纤维增强塑料腐蚀条件下的寿命预测[J]. 化工学报, 2019, 70(12): 4872-4880.
- WANG Tao, WANG Jun, ZHAO Di-yu, et al. Life Prediction of Glass Fiber Reinforced Plastics Based on BP Neural Network under Corrosion Condition[J]. CIESC Journal, 2019, 70(12): 4872-4880.
- [10] 邓春龙, 李文军, 孙明先. BP 神经网络在碳钢、低合金钢海水腐蚀中的应用[J]. 腐蚀科学与防护技术, 2006, 18(1): 54-57.
- DENG Chun-long, LI Wen-jun, SUN Ming-xian. BP Neural Network Approach to Prediction of Corrosion in Seawater of Carbon Steel and Low Alloy Steel[J]. Corrosion Science and Protection Technology, 2006, 18(1): 54-57.
- [11] SPECHT D F. A General Regression Neural Network[J]. IEEE Transactions on Neural Networks, 1991, 2(6): 568-576.
- [12] 刘应雷, 高波, 姚东. 基于 GRNN 的三元乙丙橡胶薄膜粘接界面力学性能参数反演[J]. 固体火箭技术, 2019, 42(6): 699-705.
- LIU Ying-lei, GAO Bo, YAO Dong. Inverse Analysis of Adhesive Interfacial Mechanical Properties for EPDM Film Based on GRNN[J]. Journal of Solid Rocket Technology, 2019, 42(6): 699-705.
- [13] 靳文博, 肖荣鸽, 田震, 等. 基于广义回归神经网络的海底腐蚀管道极限承载力预测[J]. 热加工工艺, 2020, 49(8): 58-61.
- JIN Wen-bo, XIAO Rong-ge, TIAN Zhen, et al. Prediction of Ultimate Bearing Capacity of Submarine Corrosion Pipeline Based on Generalized Regression Neural Network[J]. Hot Working Technology, 2020, 49(8): 58-61.
- [14] TANAKA T, ISONO Y. Influences of Phase Transformation and Ground Surface Roughness to Strength of Zirconia/Nickel Compounds[J]. Journal of the Japan Society for Precision Engineering, 2003, 69(8): 1087-1092.
- [15] YOSHIKAWA I, MATSUMURA S, OKADA M. On Co-Deposition Mechanism of Zirconia Fine Particles in Nickel/Zirconia Composite Plating[J]. Journal of the Japan Society of Powder and Powder Metallurgy, 1994, 41(6): 644-648.
- [16] 李志明, 钱士强, 王伟. Ni-ZrO₂ 纳米复合镀层研究进展[J]. 上海工程技术大学学报, 2009, 23(4): 358-363.
- LI Zhi-ming, QIAN Shi-qiang, WANG Wei. Research Progress of Ni-Based ZrO₂ Nano-Composite Coatings[J]. Journal of Shanghai University of Engineering Science, 2009, 23(4): 358-363.
- [17] 韩见存. 电沉积 Ni/Al₂O₃ 复合镀层的研究[J]. 电镀与环保, 2019, 39(5): 20-22.
- HAN Jian-cun. Study on Electrodeposition of Ni/Al₂O₃ Composite Coating[J]. Electroplating & Pollution Control, 2019, 39(5): 20-22.
- [18] 田水昌, 崔洪芝, 张国松, 等. Ni-W-GO-Al₂O₃ 复合镀层的制备及其耐磨耐蚀性能[J]. 材料热处理学报, 2019, 40(2): 140-147.
- TIAN Shui-chang, CUI Hong-zhi, ZHANG Guo-song, et al. Preparation of Ni-W-GO-Al₂O₃ Composite Coatings and Its Wear and Corrosion Resistance[J]. Transactions of Materials and Heat Treatment, 2019, 40(2): 140-147.
- [19] 周宏明, 胡雪仪, 李荐. 纳米 Al₂O₃ 对电刷镀 Ni-P 复合镀层耐蚀性能的影响[J]. 表面技术, 2017, 46(7): 32-38.

- ZHOU Hong-ming, HU Xue-yi, LI Jian. Effect of Nano-Al₂O₃ on Corrosion Resistance of Ni-P Composite Coating by Electro-Brush Plating[J]. Surface Technology, 2017, 46(7): 32-38.
- [20] 贾卫平, 吴蒙华, 贾振元, 等. 磁场方向对脉冲电沉积制备 Ni-ZrO₂ 纳米复合镀层性能的影响[J]. 表面技术, 2019, 48(9): 252-259.
- JIA Wei-ping, WU Meng-hua, JIA Zhen-yuan, et al. Effects of Magnetic Field Direction on Properties of Ni-ZrO₂ Nanocomposite Coatings Prepared by Pulse Electrodeposition[J]. Surface Technology, 2019, 48(9): 252-259.
- [21] JIA Shi-yuan, WANG Yi-lin, DING Yue-chen, et al. Research on Short Term Load Forecasting Model Based on Adaptive Neuro Fuzzy Inference System[C]//2018 Chinese Automation Congress (CAC). Xi'an: IEEE, 2018: 665-669.
- [22] YANG Zheng-xiang, XU Gui-min, WANG Jin-wen. Transport Volume Forecast Based on GRNN Network[C]//2010 2nd International Conference on Future Computer and Communication. Wuhan: IEEE, 2010: V3-629.
- [23] 彭中波, 高阳. BP 神经网络在水下地形高程拟合的应用[J]. 重庆交通大学学报(自然科学版), 2018, 37(11): 64-68, 82.
- PENG Zhong-bo, GAO Yang. Application of BP Neural Network in Elevation Fitting of Underwater Terrain[J]. Journal of Chongqing Jiaotong University (Natural Science), 2018, 37(11): 64-68, 82.
- [24] 马良涛, 董海防, 朱刚, 等. 神经网络预测海洋环境下金属腐蚀速率的应用及研究[J]. 材料保护, 2018, 51(9): 35-39.
- MA Liang-tao, DONG Hai-fang, ZHU Gang, et al. Application and Research of Neural Network in Predicting Metal Corrosion Rate in Marine Environment[J]. Materials Protection, 2018, 51(9): 35-39.
- [25] 骆正山, 袁宏伟. 基于误差补偿的 GM-RBF 海底管道腐蚀预测模型[J]. 中国安全科学学报, 2018, 28(3): 96-101.
- LUO Zheng-shan, YUAN Hong-wei. GM-RBF Model Based Error Compensation for Prediction of Submarine Pipeline Corrosion[J]. China Safety Science Journal, 2018, 28(3): 96-101.
- [26] 王金东, 赵岩, 高媛媛, 等. 基于 BP 神经网络的 Ni-Al₂O₃ 镀层粒子复合量预测研究[J]. 功能材料, 2016, 47(1): 1226-1228.
- WANG Jin-dong, ZHAO Yan, GAO Yuan-yuan, et al. Prediction on the Al₂O₃ Contents in Ni-Al₂O₃ Coatings by Using BP Neural Network[J]. Journal of Functional Materials, 2016, 47(1): 1226-1228.