

## 腐蚀电场对舰船涂层的破损位置检测

胡育诚, 王向军\*, 刘武强, 汪石川, 柳 懿  
(海军工程大学 电气工程学院, 湖北 武汉 430033)

**摘要:**舰船腐蚀电场信号具有频率低、难以消除等特性,是一种线谱特征明显的船舶物理场特征。不同涂层破损区域的舰船具有区分明显的电场分布特性,可以利用腐蚀电场信号实现舰船的涂层破损位置检测。为此,提出一种结合精细复合层次反向波动色散熵(refined composite hierarchical fluctuation revise dispersion entropy, RCHFRDE)和改进哈里斯鹰优化核极限学习机(improved Harris Hawk optimization - kernel based extreme learning machine, IHHO-KELM)的检测方法。使用RCHFRDE提取腐蚀电场信号的特征信息,输入IHHO-KELM进行训练检测涂层损伤区域。通过仿真实验和缩比船模实验来验证所提方法的有效性。实验结果证明,该方法能有效预测舰船涂层的单个破损区域,仿真数据和测量数据的检测准确率分别达到94.67%和89.00%,在先验环境信息较少的情况下可以作为非接触式检测方法的有效补充。

**关键词:**腐蚀电场信号;涂层破损检测;RCHFRDE;IHHO-KELM分类器;机器学习

中图分类号:TM15 文献标志码:A 文章编号:1001-2486(2025)02-227-12



论  
文  
拓  
展

## Coating damage detection of vessels using corrosion electric field

HU Yucheng, WANG Xiangjun\*, LIU Wuqiang, WANG Shichuan, LIU Yi

(College of Electrical Engineering, Naval University of Engineering, Wuhan 430033, China)

**Abstract:** The corrosion electric field signal of ships has characteristics such as low frequency and difficulty in elimination, and it is a kind of physical field feature of ships with obvious line spectrum characteristics. Ships with different coating damage areas have distinct electric field distribution characteristics, and the corrosion electric field signal can be utilized to detect the coating damage location of ships. Therefore, a detection method combining RCHFRDE(refined composite hierarchical fluctuation revise dispersion entropy) and IHHO-KELM(improved Harris Hawk optimization - kernel based extreme learning machine) was proposed. RCHFRDE was used to extract the feature information of the corrosion electric field signal, which was then input into IHHO-KELM for training to detect the coating damage area. The effectiveness and reliability of the proposed method were verified through simulation experiments and scale model experiments of ships. The experimental results show that this method can effectively predict the single damage area of the ship's coating. The detection accuracy rates of simulation data and measurement data reach 94.67% and 89.00% respectively. It can be used as an effective supplement to non-contact detection methods in cases with less prior environmental information.

**Keywords:** corrosion electric field; coating damage detection; RCHFRDE; IHHO-KELM classifier; machine learning

随着舰船服役年限的增加以及与水面物体发生碰撞,船体上的防腐涂层会出现破损。此时,涂层破损处裸露出的合金钢会与铜合金制成的螺旋桨形成电偶腐蚀,进而产生舰船腐蚀电场,造成舰船暴露的风险<sup>[1]</sup>。在舰船暴露前,采用准确高效的非接触式方法来检测舰船涂层破损位置,及时完成修复具有十分重要的意义。腐蚀静电场信号频率集中在0.2 Hz以下,振幅几乎恒定,在近场

可以达到mV/m的量级水平<sup>[2]</sup>,在三个方向上的分量各不相同。它不仅具有明显的传播规律和良好的穿透性<sup>[3]</sup>,且不同破损区域间的分布特征区分度大,包含了大量的舰船信息,可以作为舰船破损区域识别的数据依据,为非接触式检测的实现提供理论参考。

为了保证舰船的结构和隐身安全,有必要及时检测舰船的涂层破损区域并进行修复。但舰船

收稿日期:2022-11-07

基金项目:国家自然科学基金资助项目(41476153)

第一作者:胡育诚(1995—),男,广东广州人,博士研究生,E-mail:huyuchengorg@163.com

\*通信作者:王向军(1973—),男,河北唐山人,教授,博士,博士生导师,E-mail:wxiunue@163.com

引用格式:胡育诚,王向军,刘武强,等. 腐蚀电场对舰船涂层的破损位置检测[J]. 国防科技大学学报, 2025, 47(2): 227-238.

Citation: HU Y C, WANG X J, LIU W Q, et al. Coating damage detection of vessels using corrosion electric field[J]. Journal of National University of Defense Technology, 2025, 47(2): 227-238.

长期处于水面以下,难以直接进行目视检测。传统的检测方法属于接触式检测,需要定期驶入码头检查,或由潜水员在水下使用特定设备探测舰船表面<sup>[4]</sup>。这种检测方法依赖于专家经验和先验知识,费时费力,无法及时完成修补,威胁舰船的航行安全。因此有必要利用腐蚀电场的特性实现非接触式的涂层破损检测任务,舰船只需停驶在海面上,使用载有电场测量传感器的小型无人船在舰船左右舷附近移动一段直线距离,测得此测线下的舰船腐蚀电场信号,即可利用电场信号进行涂层破损检测,无须人工检查,可提高检测效率、及时完成修补。

目前利用腐蚀电场信号对涂层破损位置进行非接触式检测的研究相对较少,当前的研究主要是基于电场信号建模公式的反演。Chung 等<sup>[5]</sup>提出了一个包含腐蚀电流一阶梯度信息的灵敏度公式,利用增广拉格朗日法和伴随变量法对其进行解析推导,为船体腐蚀状态的诊断提供了有用的信息;胡英娣等<sup>[6]</sup>提出了一种基于逐步回归的优化方法,对模拟源进行优化选择,以提高反演结果的稳定性。然而,特定矩阵的奇异值分解容易出现病态问题无法求解,而最小二乘法需要更多的已知条件,具有很大的限制和误差。受到机器学习方法在其他故障诊断领域成功应用的启发<sup>[7]</sup>,本文提出一种新型的非接触式涂层破损位置检测方法,采用基于熵的理论直接提取电场信号的信息特征,然后基于分类思想将特征集合输入分类器训练检测,提高效率。没有公式反演步骤,避免奇异值分解出现的病态问题。

结合精细复合层次反向波动色散熵(refined composite hierarchical fluctuation revise dispersion entropy, RCHFRDE)和改进哈里斯鹰优化核极限学习机(improved Harris Hawk optimization - kernel based extreme learning machine, IHHO-KELM),本文提出了一种基于机器学习的舰船涂层破损位置检测方法。RCHFRDE 融合了反向波动色散熵(fluctuation-based revise dispersion entropy, FRDE)和精细复合层次波动色散熵<sup>[8]</sup>(refined composite hierarchical fluctuation dispersion entropy, RCHFDE)的优点,用于多通道电场信号的特征提取。仿真和缩比船模实验结果验证了该方法的可行性和准确性。

## 1 破损位置检测方法

### 1.1 基于 RCHFRDE 的特征提取

对于信号处理,特征提取是关键步骤。近年

来,许多非线性动力学方法相继被应用于各种信号的特征提取。其中,信息熵无须经过复杂的频率计算和频谱分析就可以直接提取电场信号的动态特征<sup>[9]</sup>,避免基于公式反推场源的求解限制与误差。Jiao 等<sup>[10]</sup>提出的 FRDE 在计算信号的复杂度时,只考虑嵌入在低频区域的噪声信息而未考虑高频分量。RCHFDE 采用层次分解操作,可以充分得到信号的动态信息,然而随着分解层数的增加,得到的层次分量长度逐渐变短,容易产生熵值不稳定的现象。考虑到电场信号特性与噪声信号类似,受到信息熵在振动声场信号特征提取的启发,本文提出了一种新的熵 RCHFRDE,通过采用层次分解与反向计算,使信号提取出的特征具有良好的抗噪性和稳定性,而且克服了电场信号的长度限制,实现更准确的动态特征评估。RCHFRDE 的具体定义如下:

1) 对于长度为  $N$  的信号  $\mathbf{X} = (x_1, x_2, \dots, x_N)$ , 计算其低频算子和高频算子。

$$\begin{cases} Q_0^0(x) = \frac{x_{2i-1} + x_{2i}}{2} \\ Q_1^0(x) = \frac{x_{2i-1} - x_{2i}}{2} \\ Q_0^1(x) = \frac{x_{2i} + x_{2i+1}}{2} \\ Q_1^1(x) = \frac{x_{2i} - x_{2i+1}}{2} \end{cases} \quad (1)$$

其中:  $i = 1, 2, \dots, \lfloor \frac{N}{2} \rfloor$ ,  $\lfloor \frac{N}{2} \rfloor$  表示  $\frac{N}{2}$  往下取整;  $Q_j^0(x)$  与  $Q_j^1(x)$  是低频和高频算子的两种不同表达式,其矩阵形式为

$$\begin{cases} Q_j^0 = \begin{pmatrix} \frac{1}{2} & \frac{(-1)^j}{2} & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & \frac{1}{2} & \frac{(-1)^j}{2} & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & \frac{1}{2} & \frac{(-1)^j}{2} \end{pmatrix}_{\lfloor \frac{N}{2} \rfloor \times N} \\ Q_j^1 = \begin{pmatrix} 0 & \frac{1}{2} & \frac{(-1)^j}{2} & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{2} & \frac{(-1)^j}{2} & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & \dots & 0 & \frac{1}{2} \end{pmatrix}_{\lfloor \frac{N}{2} \rfloor \times N} \end{cases} \quad (2)$$

2) 层次分解与小波包分解理论类似,不断通过低频算子与高频算子将原始信号分解为一系列中心频率不同、长度相同的子信号。当分解层数

为  $k$  时,构造  $k$  维向量  $(e_1, e_2, \dots, e_k)$ ,  $e_w = 0$  或  $1$ 。层次节点为  $l = \sum_{w=1}^k 2^{k-w} e_w$ 。基于向量  $e, X$  的层次分量在滑动粗粒化处理后可通过式(3)得到。

$$X_{k,l}^a = Q_{e_k}^{k,p_k} \cdot Q_{e_{k-1}}^{k-1,p_{k-1}} \dots Q_{e_1}^{1,p_1} \cdot X \quad (3)$$

式中,  $a = 0, 2, \dots, 2^k - 1$ 。同一节点下有  $a$  个层次

分量,  $p_w = 0$  或  $1$  分别表示低频分量或高频分量,且  $a$  与  $p_w$  的对应关系为:  $a = \sum_{w=1}^k 2^{k-w} p_w$ 。当分解层数为 3 时,  $X$  的层次分解过程如图 1 所示,第 3 层节点 2 对应的  $a$  个层次分量  $X_{3,2}^a = Q_0^{3,0} \cdot Q_1^{2,1} \cdot Q_0^{1,0} \cdot X$ 。

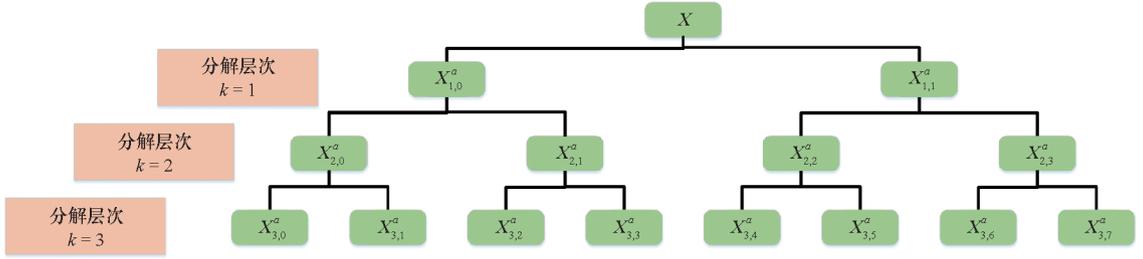


图 1 当  $k=3$  时层次分解过程

Fig. 1 Process of hierarchical decomposition when  $k=3$

3) 依据多元嵌入理论,将层次分量重构为向量  $G_m^a(\lambda) = (x_{k,l,\lambda}^a, x_{k,l,\lambda+d}^a, \dots, x_{k,l,\lambda+(m-1)d}^a)$ , 其中  $\lambda = 1, 2, \dots, N - (m-1)d$ ,  $d$  和  $m$  分别为时间延迟和嵌入维数,再通过式(4)将  $G_m^a(\lambda)$  转换为  $\bar{G}_m^a(\lambda)$ 。

$$\bar{G}_m^a(\lambda) = (x_{k,l,\lambda+d}^a - x_{k,l,\lambda}^a + c, \dots, x_{k,l,\lambda+(m-1)d}^a - x_{k,l,\lambda+(m-2)d}^a + c) \quad (4)$$

其中,  $c$  为类别数。每个  $\bar{G}_m^a(\lambda)$  均有对应的波动色散模式  $\pi_{v_0 v_1 \dots v_{m-2}}$  ( $v = 1, 2, \dots, c$ ),  $v_0 = x_{k,l,\lambda+d}^a - x_{k,l,\lambda}^a + c$ ,  $v_{m-2} = x_{k,l,\lambda+(m-1)d}^a - x_{k,l,\lambda+(m-2)d}^a + c$ 。波动色散模式表示每个  $\bar{G}_m^a(\lambda)$  向量里元素的排列组合模式,共有  $(2c-1)^{m-1}$  种。第  $k$  层节点  $l$  对应有  $2^k$  个不同层次分量,分别计算每个层次分量的波动色散模式出现的平均概率  $P(\pi_{v_0 v_1 \dots v_{m-2}})$ ,再由式(6)的反向计算求解  $P(\pi_{v_0 v_1 \dots v_{m-2}})$  与白噪声的归一化距离,得出 RCHFRDE 值。

$$P(\pi_{v_0 v_1 \dots v_{m-2}}) = \frac{1}{2^k} \sum_{a=0}^{2^k-1} \frac{Num(\pi_{v_0 v_1 \dots v_{m-2}})}{N - (m-1)d} \quad (5)$$

$$RCHFRDE(X, m, c, d, k, l) = \frac{\left[ \sum_{\pi=1}^{(2c-1)^{m-1}} P(\pi_{v_0 v_1 \dots v_{m-2}}) - \frac{1}{(2c-1)^{m-1}} \right]^2}{1 - \frac{1}{(2c-1)^{m-1}}} \quad (6)$$

RCHFRDE 的流程图如图 2 所示。

### 1.2 信号分类

作为机器学习方法的一种,分类通常用于预测输入样本的类别标签<sup>[11]</sup>。目前,卷积神经网络(convolutional neural networks, CNN)分类器<sup>[12]</sup>在样本训练过程中由于反向传播更新、复杂的网络结构以及 Dropout 操作,让网络变得难以理解,缺

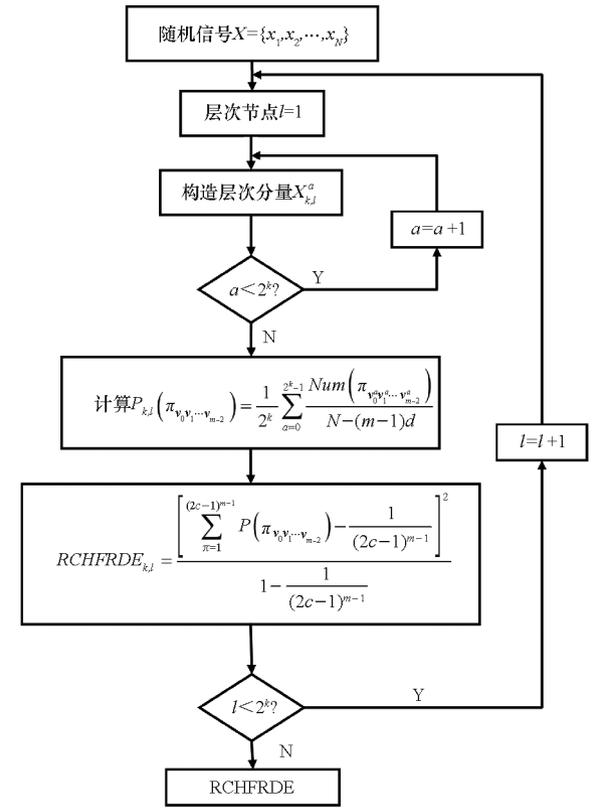


图 2 RCHFRDE 计算流程

Fig. 2 Flow chart of RCHFRDE

乏系统结构的可解释性和透明度;支持向量机<sup>[13]</sup>(support vector machine, SVM)需要不断迭代优化函数来确定最优分类超平面,使得运行机制更加复杂。核极限学习机<sup>[14]</sup>(kernel based extreme learning machine, KELM)作为分类器,在保留极限学习机高计算效率优点的同时,通过引入核函数,使其在处理线性不可分问题时的泛化性能更加优越。由于 KELM 只是一种单隐含层的前馈神经

网络,网络训练变为线性系统求解问题,不像 CNN 分类器缺乏可解释性。但 KELM 的对惩罚系数、宽度参数的选择对 KELM 的分类性能影响程度较大,为了发挥 KELM 的最佳性能,本文采用改进哈里斯鹰优化(improved Harris Hawk optimization, IHHO)算法<sup>[15]</sup>迭代寻优确定 KELM 的最佳参数,以构建性能更佳的 IHHO-KELM 分类器。

IHHO 模拟了哈里斯鹰捕食行为的三个阶段,即全局探索、转换阶段、局部开发阶段。该算法具有很强的全局搜索能力,需要调整的参数较少。IHHO 的主要原理总结如下,KELM 的详细步骤参考文献[14]。

### 1.2.1 全局探索

此阶段主要分为两步:

$$X(t+1) = \begin{cases} X_{\text{rand}}(t) - v_1 |X_{\text{rand}}(t) - 2v_2 X(t)| & q \geq 0.5 \\ X_{\text{target}}(t) - X_m(t) - v_3 [lb + v_4 (ub - lb)] & q < 0.5 \end{cases} \quad (7)$$

其中: $ub$  和  $lb$  分别为维度空间的上下界, $t$  为当前迭代次数, $v_1, v_2, v_3, v_4$  和  $q$  均是  $[0, 1]$  中的随机数; $X_m(t)$  表示当前 HHO 的平均位置, $X_{\text{rand}}(t)$  和  $X_{\text{target}}(t)$  为当前 HHO 的随机位置和目标位置, $X(t+1)$  为 HHO 在第  $t+1$  次迭代时的位置。本文引入正态云模型<sup>[16]</sup>为 HHO 的位置更新机制进行改进。通过正态云模型的期望值  $Ex$  确认最优位置解,通过熵  $En$  调整其他的位置解,利用超熵  $He$  减少 IHHO 位置离散程度,优化过程如下所示:

$$X(t) = Gnc(X_{\text{best}}(t), En, He, Nd) \quad (8)$$

$$En = \lambda \left( \frac{T_{\text{max}} - t}{T_{\text{max}}} \right)^\tau \quad (9)$$

$$He = En \times 10^{-\zeta} \quad (10)$$

其中, $Nd$  为期望云滴个数, $T_{\text{max}}$  为最大迭代次数, $Gnc$  为正态云模态, $\zeta$  为一个常数。对于 HHO 的最差位置,则结合随机反向学习思想<sup>[16]</sup>进行更新。

$$X_{\text{worst},t+1} = ub_1 + \text{rand}(lb_1 + X_{\text{worst},t}) \quad (11)$$

其中, $X_{\text{worst},t}$  表示第  $t$  次迭代下 HHO 最差位置, $ub_1$  和  $lb_1$  分别为动态边界的上下界。通过对最差值进行更新,提高 HHO 种群多样性和寻得全局最优解概率。同时动态边界  $ub_1$  和  $lb_1$  降低了传统的固定边界  $ub$  和  $lb$  易丢失搜索信息的概率。

### 1.2.2 转换阶段

HHO 通过猎物能量  $E$  来控制从全局探索到局部开发的转换。

$$E = 2E_0(1 - t/T_{\text{max}}) \quad (12)$$

式中, $E_0$  为  $[-1, 1]$  中的随机数。

### 1.2.3 局部开发阶段

局部开发阶段可能出现收敛太早与陷入局部最优情况。参考文献[17],在局部开发阶段引入一种动态扰动策略,在保证算法寻优精度的同时避免陷入局部寻优。

$$\phi = -\cos[\pi t/(2T_{\text{max}}) + \pi] \quad (13)$$

$$X_{\phi, \text{target}} = \phi \cdot X_{\text{target}} \quad (14)$$

其中, $\phi$  为扰动系数, $X_{\phi, \text{target}}$  为加入扰动后的目标位置。此阶段通过猎物能量  $E$  和逃逸因子  $v$  提出四种策略对开发阶段进行更新。

软围猎:

1) 当  $1 > |E| \geq 0.5$  且  $v \geq 0.5$  时,软围猎的更新如下。

$$\begin{cases} X(t+1) = \Delta X(t) - E |JX_{\phi, \text{target}}(t) - X(t)| \\ \Delta X(t) = X_{\phi, \text{target}}(t) - X(t) \end{cases} \quad (15)$$

其中, $J = 2(1 - v_5)$  为更新步长, $v_5$  是  $[0, 1]$  中的随机数。

2) 当  $1 > |E| \geq 0.5$  且  $v < 0.5$  时,更新的策略则改为

$$X(t+1) = Y = X_{\phi, \text{target}}(t) - E |JX_{\phi, \text{target}}(t) - X(t)| \quad (16)$$

硬围猎:

1) 当  $|E| < 0.5$  且  $v \geq 0.5$  时,硬围猎的更新如下。

$$X(t+1) = X_{\phi, \text{target}}(t) - E |\Delta X(t)| \quad (17)$$

2) 当  $|E| < 0.5$  且  $v < 0.5$  时,更新的策略则改为

$$X(t+1) = Y = X_{\phi, \text{target}}(t) - E |JX_{\phi, \text{target}}(t) - X_m(t)| \quad (18)$$

本文基于 IHHO 良好的全局搜索能力提出了 IHHO-KELM,以检测错误率(error rate, Err)作为适应度函数,初始参数设为:最大迭代次数  $T_{\text{max}} = 50$ ,惩罚因子和核函数参数的优化范围为  $[0, 1, 1000]$ 。IHHO-KELM 的流程图如图 3 所示,通过 IHHO 搜索自适应确定了 KELM 的最佳参数组合,发挥出 KELM 的最佳性能。

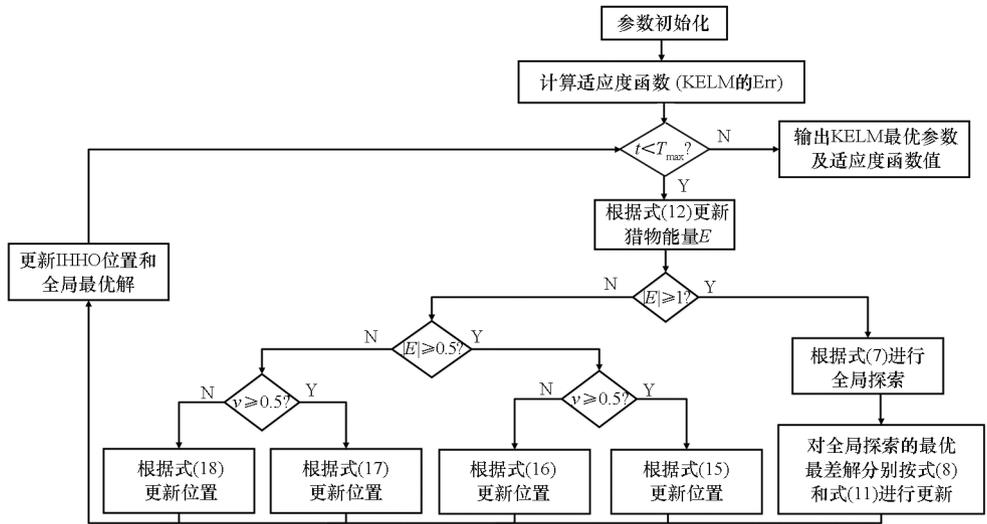


图 3 IHHO-KELM 的流程

Fig. 3 Flow chart of IHHO-KELM

## 2 仿真实验

### 2.1 仿真场景设置

舰船电场仿真信号的准确性对涂层破损位置检测精度有很大影响。本文利用有限元软件 COMSOL Multiphysics 的边界元模块进行舰船电场信号的数值仿真<sup>[17]</sup>。近年来,边界元法由于易于处理开域问题、计算精度高等优势不断应用于舰船腐蚀电场的数值仿真<sup>[18]</sup>。边界元模型基本理论可参考文献[19],舰船模型设定为:长 78 m、宽 8 m、高 6 m,电场测试路径为两条从点(-80 m, 16 m, -16 m)到点(160 m, 16 m, -16 m)以及从点(-80 m, -16 m, -6 m)到点(160 m, -16 m, -16 m)的直线,分别为舰船左下 1B 和右下 1B 位置(B 为船宽),如图 4 所示。涂层的破损尺寸设置为 800 mm × 600 mm,船体和方向舵材料为碳钢,螺旋桨材料为 B10 铜合金。通过拟合实验室前期测试得到的碳钢和 B10 铜的极化曲线<sup>[19]</sup>,可以得到仿真边界条件极化方程中的电化学参数,极化曲线测试结果如图 5 所示。将碳钢的极化曲线设置为破损处边界条件,B10 铜的极化曲线设置为螺旋桨的边界条件,其余默认为绝缘边界。

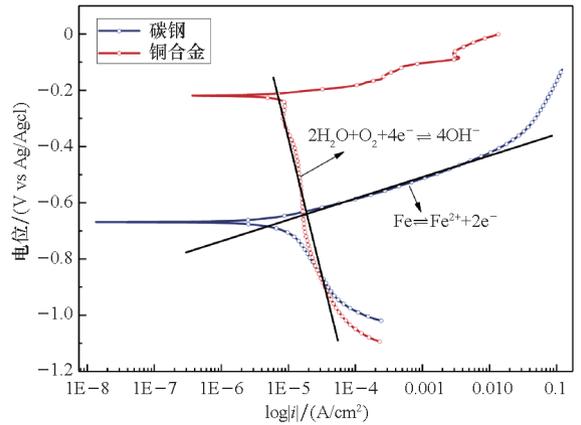


图 5 碳钢与铜合金极化曲线

Fig. 5 Polarization curves of carbon steel and copper alloy

舰船模型位于无限空域、均匀海水介质,电导率为 3.98 S/m,选择迭代求解器 BiCGStab。将舰船表面网格剖分为 45 973 个边界节点和 91 942 个边界三角形单元。图 6 展示了两测线

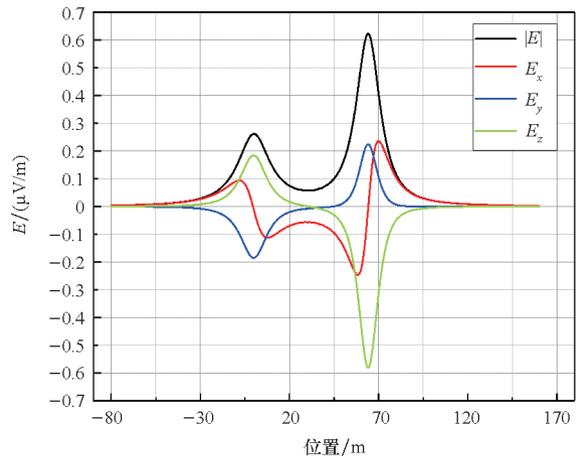
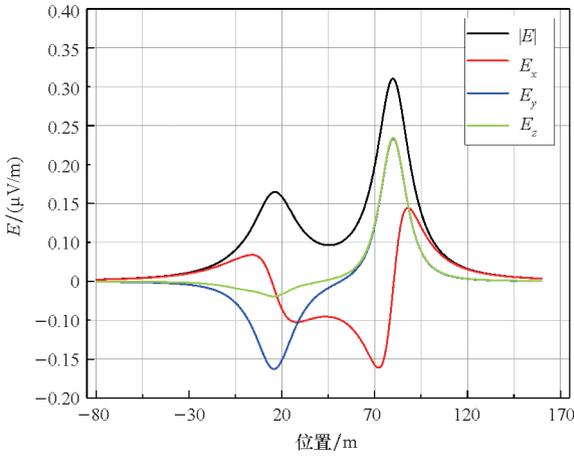


图 4 测试场景

Fig. 4 Electric field test path

(a) 右侧测线

(a) Right line



(b) 左侧测线  
(b) Left line

图 6 所有三个分量的腐蚀电场信号  
Fig. 6 Corrosion electric field signature with respect to all 3 vector components

的电场信号模值与三个方向分量的仿真结果, 信号模值中两处峰值分别表示阴阳极的腐蚀电场大小, 其仿真结果可以近似为静电场的近场测量结果。

图 7 和图 8 显示了电场分布的仿真结果。由图可知, 电场模量在螺旋桨处和破损区域处出现正峰值的双峰曲线, 且螺旋桨处峰值大于破损区域处, 与真实腐蚀电场结果一致, 可为下一节中的本文方法提供高质量的训练集。

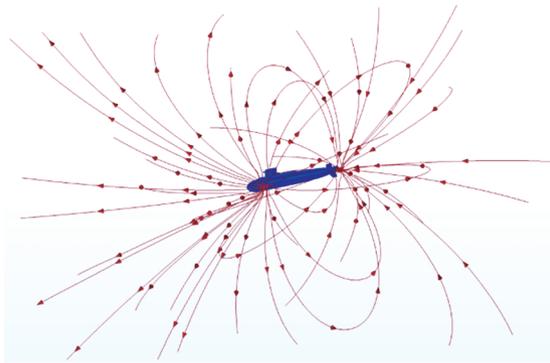


图 7 舰船电场分布  
Fig. 7 Electric field distribution of submarine

## 2.2 仿真实验框架

为了准确识别舰船涂层破损的区域, 本文提出一种利用腐蚀电场信号的基于 RCHFRDE 和 IHHO-KELM 的舰船涂层破损检测方法, 仿真实验验证的总体框架共分为 3 步, 如图 9 所示。

1) 数据仿真: 将舰船划分为 20 个区域(左右舷各 10 个)。每个区域内随机设定 80 个涂层破损

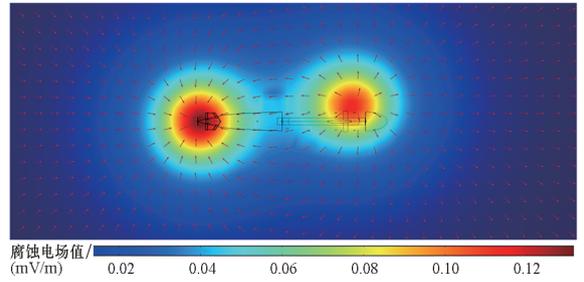


图 8 XY 平面的电场分布  
Fig. 8 Electric field distribution on the XY plane

位置, 利用 2.1 节中的仿真设置共模拟出 1 600 个数据样本, 其中每个区域对应的 80 个样本中随机分出 50 个数据作为训练集和 30 个数据作为测试集。

2) 特征提取: 如图 6、图 7 所示, 与破损区域同侧的测试路径的腐蚀电场幅值显著高于另一侧, 因为同一侧的测试路径更接近电偶极子对, 具有更密集的电场分布, 因此产生更大的电场振幅。为了确认受损涂层是在舰船的左舷还是右舷, 本文用式 (19) 计算两测线的累积差分  $D$ :

$$D = \sum_{i=1}^n (y_{li} - y_{ri}) \quad (19)$$

当  $D$  为正时, 损坏区域位于左舷, 左下 1B 测试路径保留; 当  $D$  为负时, 保留右下 1B 测试路径。从所选的信号中提取 RCHFRDE 特征。

3) 分类检测: 在分类检测阶段, 训练集的信号特征被输入 IHHO-KELM 分类器进行训练, 而测试集用于分类检测。输出层包含 1 到 10 的类别标签, 图 9 第一个图展示了对应于舰船船体右舷上的 10 个标签的特定区域。当电场信号输入分类器时, 分类器输出对应涂层破损区域的数字标签。

## 2.3 参数选择

RCHFRDE 的主要参数为分解层数  $k$ 、嵌入维数  $m$ 、类别数  $c$  和时间延迟  $d$ 。 $k$  决定了特征向量的尺度数量, 过小的  $k$  值会导致电场信号的频带划分数量不足, 无法得到足够的低频和高频分量, 若  $k$  太大则计算效率较低, 结合文献 [20] 综合考虑, 本文选择  $k = 3$ 。 $d$  对熵值计算结果影响较小, 通常取 1。文献 [21] 建议  $m$  取 2 或 3,  $c$  取 4~8, 传统的确认方法是基于经验选择, 但此类方法缺少特定的理论基础。因此, 本文通过计算 Cohesion (Coh) 值 [10] 来确认效果最优的参数组合。

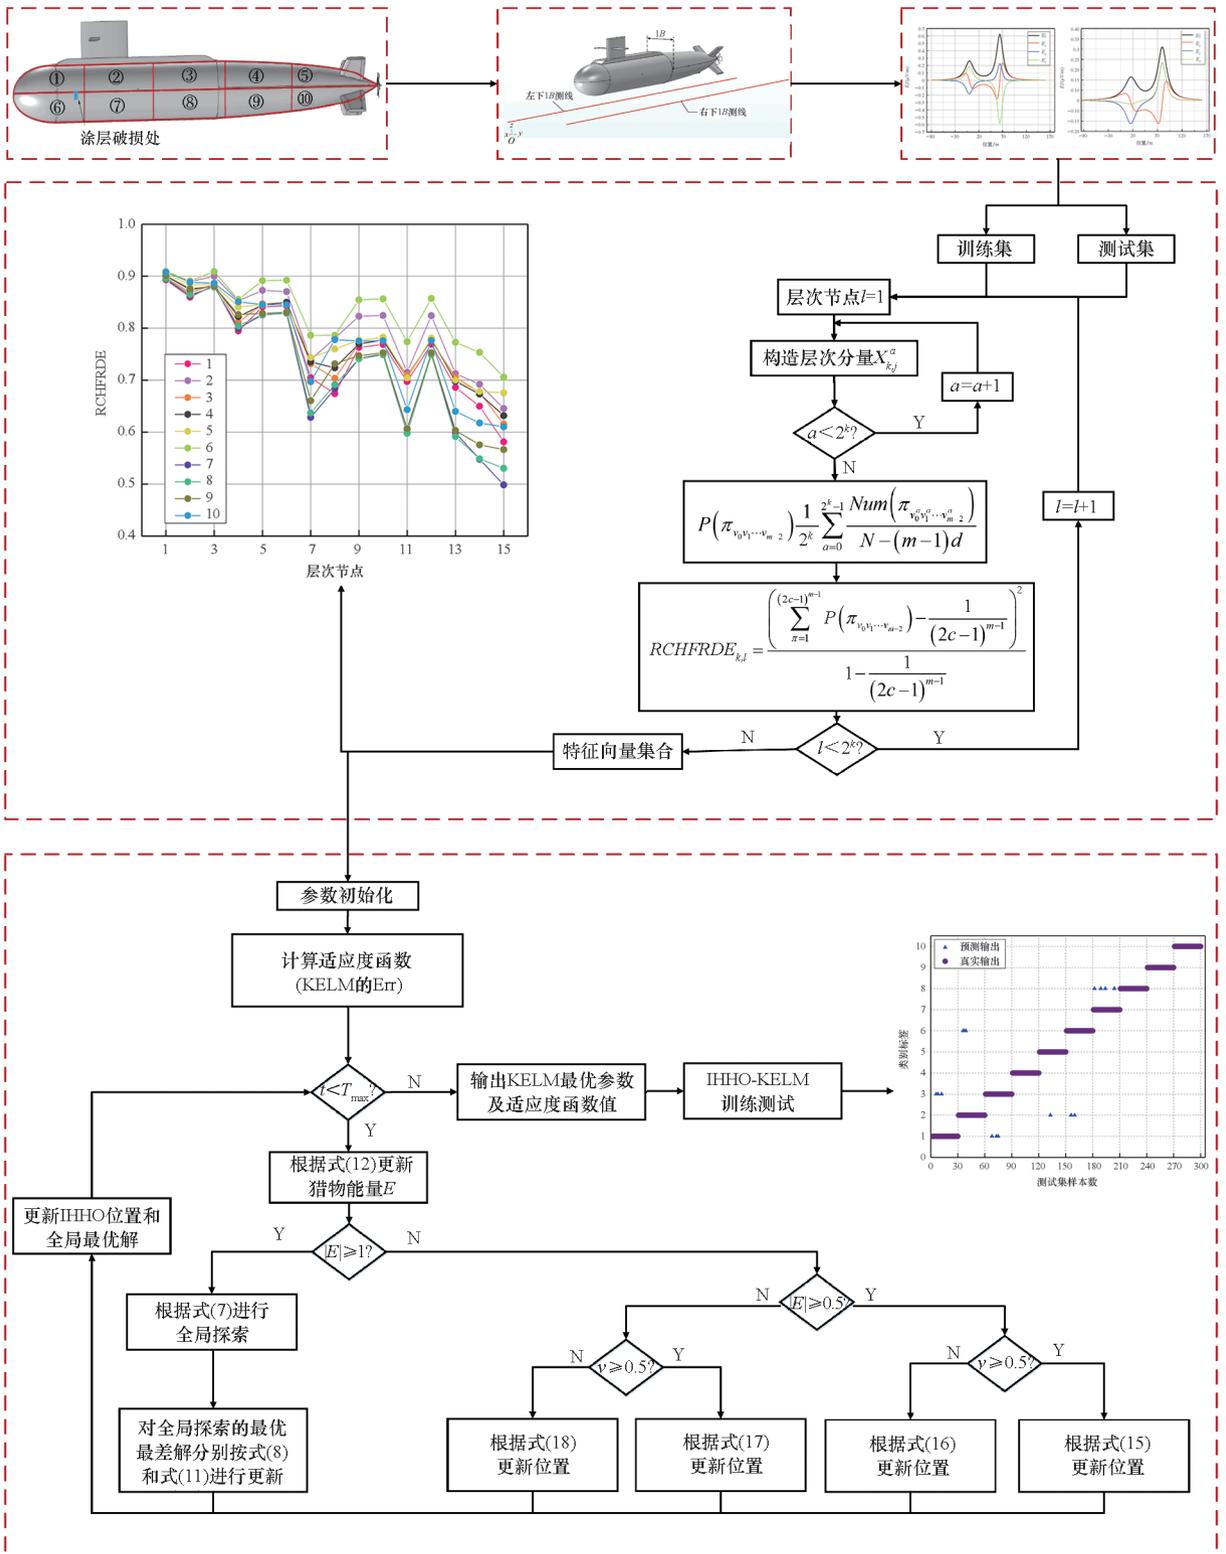


图9 仿真实验整体框架

Fig. 9 Overall framework of the experiment

$$\begin{cases} Coh = WCS/BCS \\ WCS = trace \left[ \sum_{i=1}^N \frac{1}{N} \frac{1}{M} \sum_{j=1}^M (V_i^j - \bar{V}_i) (V_i^j - \bar{V}_i)^T \right] \\ BCS = trace \left[ \sum_{i=1}^N \frac{1}{N} (V_i^j - \bar{V}) (V_i^j - \bar{V})^T \right] \end{cases} \quad (20)$$

其中:类内散射 (the within-class scatter, WCS) 表示相同破损区域内的特征差异,类间散射 (the between-class scatter, BCS) 表示不同的破损区域间的特征差异; $V_i^j$  是第  $i^{\text{th}}$  类中第  $j^{\text{th}}$  个特征的特征向量; $\bar{V}_i$  是第  $i^{\text{th}}$  类所有特征向量的平均值, $\bar{V}$  是所有特征的平均值。 $Coh$  越小,不同区域之间的特

征区分越明显。

表 1 给出了不同  $[m, c]$  组合的  $Coh$  值。由表可得,最小  $Coh$  对应的参数组合为  $m = 3, c = 6$ 。使用具有最佳参数组合的 RCHFRDE 来计算左舷不同破损区域的特征平均熵,结果如图 10 所示。由图可得,不同区域间的 RCHFRDE 熵值在大多数节点上的区分较为明显,有利于分类器的分类检测。

表 1 不同  $[m, c]$  的  $Coh$  值

Tab. 1 The  $Coh$  with different  $[m, c]$

参数 $[m, c]$	$Coh$	参数 $[m, c]$	$Coh$
[2, 4]	0.182 3	[3, 6]	0.170 9
[2, 5]	0.180 9	[3, 7]	0.172 0
[2, 6]	0.171 4	[3, 8]	0.171 9
[2, 7]	0.172 7	[4, 4]	0.192 3
[2, 8]	0.177 2	[4, 5]	0.196 0
[3, 4]	0.177 3	[4, 6]	0.203 6
[3, 5]	0.175 2		

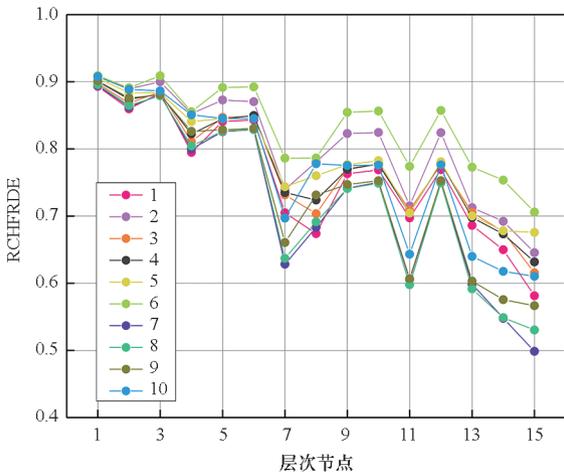


图 10 不同破损区域的熵平均值

Fig. 10 Mean entropy values between different damaged regions

### 2.4 实验结果与分析

#### 2.4.1 本文方法检测性能

为了减少过拟合或欠拟合现象对训练的影响, IHHO-KELM 分类器对不同训练集占比的数据集(即 10%、20%、30%、40%、50%、60%、70%、80%、90%)分别进行 10 次训练测试,计算测试的平均精度<sup>[22]</sup>。检测结果如图 11 所示。结果发现,随着训练样本数量的增加,检测精度也会增加。一般来说,训练样本越多,训练效果和分类器性能越好。然而,过多的训练样本也花费了大

量的训练时间,导致检测效率低下。因此,为了平衡检测精度和效率,本文将训练集的比例设置为 60%。图 12 显示了本文方法的最终检测结果,结果表明,少数的错误检测主要发生在区域 1 和 3、2 和 6。总体准确率达到 94.67%,证明本文方法可以有效地检测舰船涂层的破损区域。

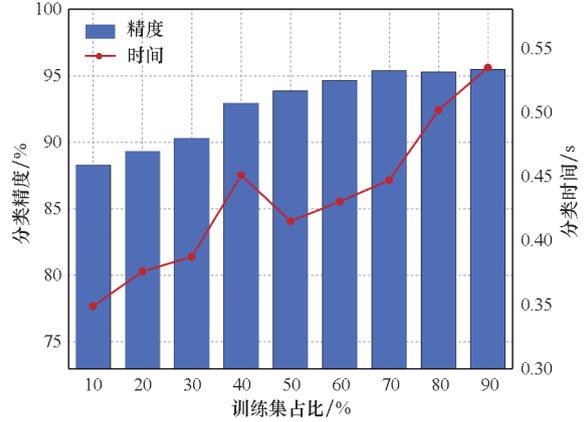
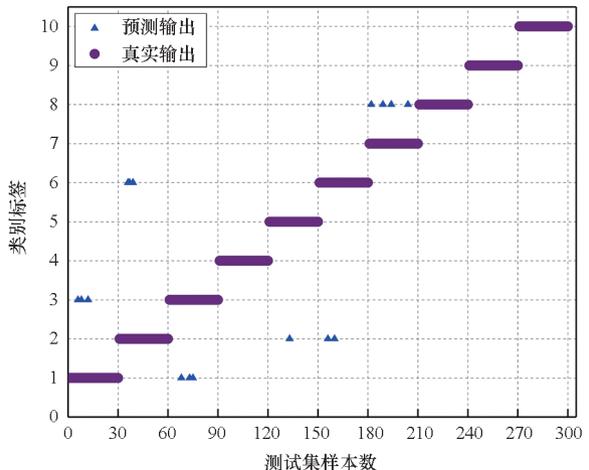


图 11 不同训练集占比的检测精度与测试时间对比

Fig. 11 Detection accuracy and time with different proportions of training set

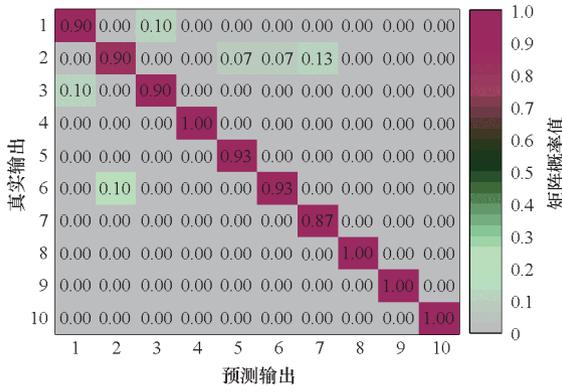
#### 2.4.2 不同特征提取方法的比较

为了验证 RCHFRDE 的优越性,采用 FRDE、RCHFDE 和 RCHFRDE 作为比较方法。RCHFDE 和 RCHFRDE 的参数设置为  $m = 3, c = 6, d = 1, k = 3$ 。相应的测试结果如图 13 和表 2 所示。结果显示:FRDE 和 RCHFDE 的标准偏差(standard deviation, SD)大于 RCHFRDE,表明 RCHFRDE 比前两者更稳定。RCHFRDE 在三者中平均精度最高,而 FRDE 和 RCHFDE 分类效果相似,但 RCHFDE 的稳定性更好。可以得出结论,检测精度  $RCHFRDE > RCHFDE > FRDE$ 。原因在于 RCHFRDE 采用层次分解操作,充分提取电场信



(a) 分类器结果输出

(a) Actual output of classifier



(b) 混淆矩阵 (%)

(b) Confusion matrix (%)

图 12 最终检测结果

Fig. 12 The final detection results of the proposed method

号高频段与低频段的动态特征,有效克服 FRDE 中存在的信息缺失的缺陷。加入反向计算,使得 RCHFRDE 面对波动幅度大的信号稳定性更高。但是这两项操作提高了熵值的计算复杂度,令 RCHFRDE 的检测时间变长,考虑到本文优先考虑破损位置的检测精度,增加检测时长在可接受范围内。

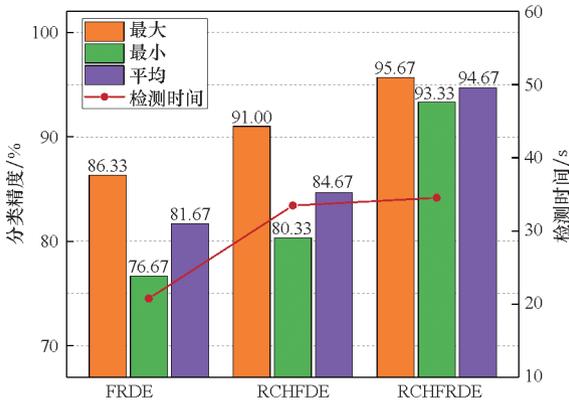


图 13 不同熵的检测精度

Fig. 13 Detection accuracy corresponding to different entropy

表 2 不同熵间的检测结果

Tab. 2 Detection results with different entropy

特征提取方法	检测精度/%				检测时间/s
	最大	最小	平均	SD	
FRDE	86.33	76.67	81.67	2.4	20.76
RCHFRDE	91.00	80.33	84.67	1.76	33.47
RCHFRDE	95.67	93.33	94.67	1.25	34.53

### 2.4.3 不同分类器的对比

为了比较不同分类器的性能,特征提取采用

RCHFRDE,参数设置为  $m = 3, c = 6, d = 1, k = 3$ 。IHHO-KELM 与 SVM、KELM 和一维 CNN (1D-CNN) 进行比较,其中 1D-CNN 具有两个卷积层、两个平均池层、一个全连接层和一个 softmax 输出层。激活函数为 ReLU 函数。其他分类器的参数设置如下: KELM 的迭代次数与随机种子数为 [500,10],SVM 的惩罚因子和核函数参数也设置为 [500,10]。实验结果如表 3 所示。由表可得, IHHO-KELM 比其他分类器的精度更高,表明 IHHO-KELM 分类器在涂层损伤检测方面具有更优越的性能。1D-CNN 由于结构的复杂性,检测时间最长,IHHO 的寻优确定使得 IHHO-KELM 的计算成本比 KELM 与 SVM 更大,但增加的检测时间也在可接受范围内。

表 3 不同分类器的精度对比

Tab. 3 Accuracy comparison of different classifier

特征提取	分类器	检测精度/%			检测时间/s
		最大	最小	平均	
	SVM	88.57	83.81	86.24	30.81
	KELM	88.57	86.19	87.56	31.29
	RCHFRDE 1D-CNN	90.81	88.43	89.32	41.26
	IHHO-KELM	95.67	93.33	94.67	34.53

## 3 船模实验

为了进一步验证本文方法的可行性,进行了不同涂层破损区域的尺度缩比模型 (physical scale modeling, PSM) 实验。

### 3.1 实验设置

使用的舰船模型长 1.2 m,宽 0.15 m。船尾轴采用电绝缘处理,船体涂覆绝缘油漆。船体和螺旋桨材料与实际舰船相同,以减少船体材料本身造成的误差。水池底部与侧面为绝缘,实验参数设置如表 4 所示。实验采用三分量 Ag/AgCl 电场测量传感器,同对电极间的距离为 3 cm,固定在三轴方向的塑料支架上。通过测量同一对电极之间的电势差,可以得到三个方向上的电场强度。实验的总体布局如图 14 所示。

利用裸钢片接通铜导线与螺旋桨连接。通过改变裸钢片的位置来模拟不同的破损区域。改变钢片位置并移动模型测量数据,在每个破损区域测量 40 个数据样本,其中随机划分 30 个样本为训练集和 10 个样本为测试集。实际应用时训练

表 4 实验参数设置

Tab.4 Parameter setting of the experiment condition

参数名称	参数设置
水池长	8 m
水池宽	5 m
水深	0.8 m
模型移动速度	(0.05 m/s, 0 m/s, 0 m/s)
采样频率	2.5 kHz
电极电流	150 mA
水电导率	1.6 S/m
传感器 I 坐标	(5 m, -0.15 m, 0.4 m)
传感器 II 坐标	(5 m, 0.15 m, 0.4 m)
裸露钢板输出电流	225 mA

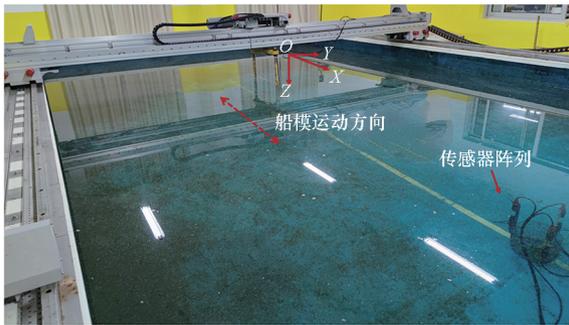


图 14 实验总体布局

Fig. 14 Overall layout of the experiment

集主要有两种获取方式:①根据缩比模型实验理论,舰船模型的电场信号特征与真实舰船成正比,因此将船模电场信号乘以比例系数可得到相同型号的真实舰船电场信号。②在实船船壳上与螺旋桨上分别附加一块裸钢片,用铜导线连接电源与钢片,输出电流模拟电偶极子,形成水下电场。通过改变船壳上裸钢片的位置来模拟不同的破损区域,测量获取训练集数据。

其中一个测量结果如图 15 所示。测量结果中有明显的噪声,其最大值与峰峰值反映出船只通过传感器的场景。电场模量与三分量的关系为  $|E| = [(E_x)^2 + (E_y)^2 + (E_z)^2]^{1/2}$  (21)

### 3.2 实验结果与分析

图 16 显示了最终检测结果,检测错误的区域与仿真实验情况相似。总体准确率达到 89.00%,证明本文方法可以有效地检测涂层破损区域。对比两种实验结果,发现缩比船模实验的检测精度低于仿真实验结果,这主要由以下原因导致:①在测量过程中,传感器测得的腐蚀电场信

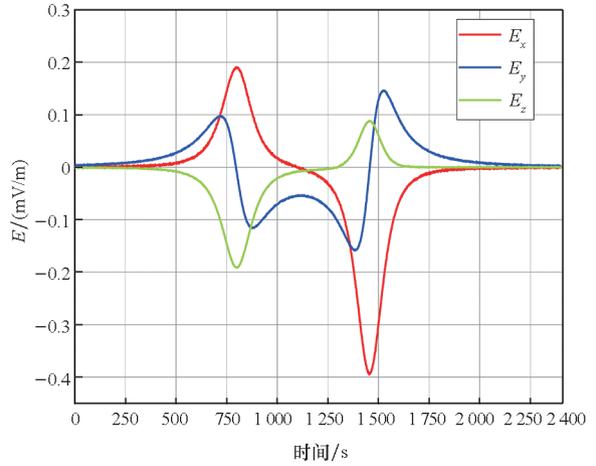
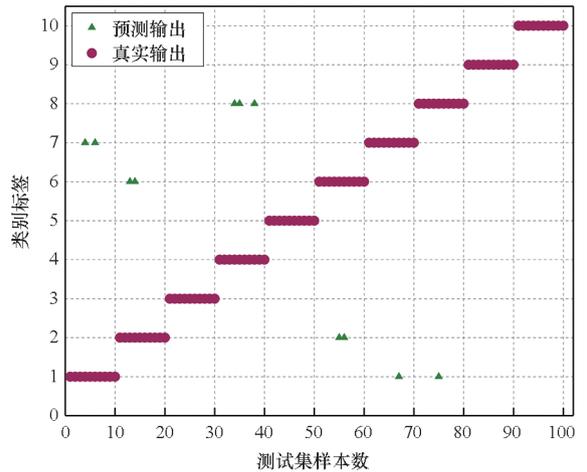


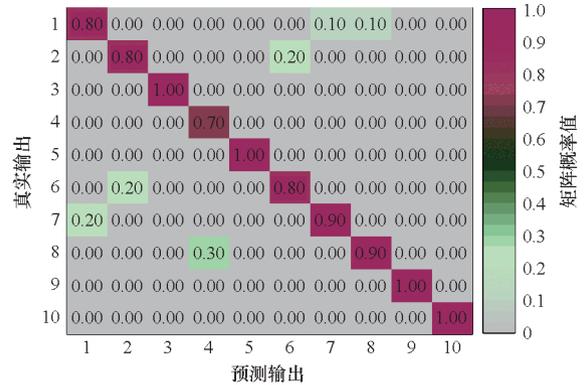
图 15 舰船模型腐蚀电场信号

Fig. 15 Corrosion electric field signature of the vessel model



(a) 分类器结果输出

(a) Classifier output



(b) 混淆矩阵 (%)

(b) Confusion matrix (%)

图 16 基于本文方法的船模实验检测结果

Fig. 16 Ship model detection results of the proposed method

号包含各种背景噪声和干扰噪声。这些干扰使 RCHFRDE 提取冗余的特征信息,导致分类精度

降低。②船模实验中的水电导率成比例下降为 1.6 S/m。电导率太低限制了传感器的测量精度,导致船模与仿真实船的电场密度相等的假设不成立,使得船模与仿真实船的电场比值远小于理论值,从而影响分类器的学习精度。

与仿真实验类似,将不同提取方法对应的特征向量输入 IHHO-KELM 分类器中进行训练和测试。相应的检测结果如表 5 所示,可以得出,检测精度 RCHFRDE > RCHFDE > FRDE,与仿真实验结果一致。

表 5 不同熵的船模检测结果

Tab.5 Ship model detection results with different method

特征提取方法	检测精度/%			检测时间/s
	最大	最小	平均	
FRDE	86.00	76.00	81.00	63.20
RCHFDE	90.00	80.00	84.00	89.32
RCHFRDE	92.00	88.00	89.00	93.67

为了比较不同分类器的性能,特征提取同样采取 RCHFRDE。RCHFRDE 和分类器的参数设置与仿真实验一致。实验结果证明了所提出的分类方法在涂层破损检测中的优越性,如表 6 所示。

表 6 不同分类器的船模检测结果

Tab.6 Ship model detection results with different classifier

特征提取	分类器	检测精度/%			检测时间/s
		最大	最小	平均	
	SVM	86.00	81.00	83.00	87.59
	KELM	88.00	84.00	85.00	88.92
RCHFRDE	1D-CNN	90.00	86.00	88.00	106.46
	IHHO-KELM	92.00	88.00	89.00	93.76

由于船模实验传感器的采样频率高,采集时间长,测得的腐蚀电场信号数据量较大,因此船模实验的检测时间普遍比仿真实验的时间要长。但与舰船进入船坞检查的时间相比,明显减少,因此本文方法远比接触式检测方法省时高效。

## 4 结论

为了准确检测舰船涂层的破损位置,本文提出了一种结合 RCHFRDE 和 IHHO-KELM 的方法。采用腐蚀电场信号作为特征提取的输入参数,然后将特征集合输入分类器中进行训练检测,

最终输出破损位置的类别标签,并进行了一系列实验验证了该方法的可靠性。实验证明该方法可以有效地预测涂层的单个破损区域,并在仿真数据和测量数据中达到 94.67% 和 89.00% 的检测精度,为非接触检测方法的有效补充提供技术借鉴。下一步的工作将研究舰船涂层存在多处破损时的位置检测。

## 参考文献 (References)

- [1] 徐庆林,王向军,张建新,等. 补偿阳极位置对舰船腐蚀电场防护效果的影响[J]. 哈尔滨工业大学学报, 2020, 52(9): 123-128.  
XU Q L, WANG X J, ZHANG J C, et al. Influence of compensation anode position on corrosion electric field damping effect of ship [J]. Journal of Harbin Institute of Technology, 2020, 52(9): 123-128. (in Chinese)
- [2] KIM Y S, LEE S K, CHUNG H J, et al. Influence of a simulated deep sea condition on the cathodic protection and electric field of an underwater vehicle [J]. Ocean Engineering, 2018, 148: 223-233.
- [3] KALOVELONIS D T, RODOPOULOS D C, GORTSAS T V, et al. Cathodic protection of a container ship using a detailed BEM model[J]. Journal of Marine Science and Engineering, 2020, 8(5): 359.
- [4] ZHANG J W, YU P, JIANG R X, et al. Real-time localization for underwater equipment using an extremely low frequency electric field[J]. Defence Technology, 2023, 26: 203-212.
- [5] CHUNG H J, YANG C S, JEUNG G W, et al. Accurate prediction of unknown corrosion currents distributed on the hull of a naval ship utilizing material sensitivity analysis[J]. IEEE Transactions on Magnetics, 2011, 47(5): 1282-1285.
- [6] 胡英娣,龚沈光,闫永贵. 船舶静态电场混合模型的逐步回归法优化求解[J]. 探测与控制学报, 2013, 35(4): 32-35.  
HU Y D, GONG S G, YAN Y G. Stepwise regression method of optimization and solving for static electric field mixed model of ship[J]. Journal of Detection & Control, 2013, 35(4): 32-35. (in Chinese)
- [7] 张士刚,罗旭,骆彦廷,等. 基于统一理论框架的故障诊断模型及学习进化方法[J]. 国防科技大学学报, 2020, 42(2): 142-149.  
ZHANG S G, LUO X, LUO Y T, et al. Fault diagnosis models and evolution method based on a unified theory framework [J]. Journal of National University of Defense Technology, 2020, 42(2): 142-149. (in Chinese)
- [8] ZHOU F M, GONG J C, YANG X Q, et al. A new gear intelligent fault diagnosis method based on refined composite hierarchical fluctuation dispersion entropy and manifold learning[J]. Measurement, 2021, 186: 110136.
- [9] LI Y B, WANG X Z, LIU Z B, et al. The entropy algorithm and its variants in the fault diagnosis of rotating machinery: a review[J]. IEEE Access, 2018, 6: 66723-66741.
- [10] JIAO S B, GENG B, LI Y X, et al. Fluctuation-based reverse dispersion entropy and its applications to signal classification[J]. Applied Acoustics, 2021, 175: 107857.

- [11] JAYARAM V, AVSETH P A, AZBEL K, et al. Introduction to special section: pattern recognition and machine learning[J]. *Interpretation*, 2015, 3(4): 1N-Y1.
- [12] GU X W, ANGELOV P P. Self-organising fuzzy logic classifier[J]. *Information Sciences*, 2018, 447: 36 – 51.
- [13] CRISTIANINI N, SHAWE-TAYLOR J. An introduction to support vector machines and other kernel-based learning methods[J]. Preface, 2000(6): 93 – 124.
- [14] HUANG G B. An insight into extreme learning machines: random neurons, random features and kernels[J]. *Cognitive Computation*, 2014, 6(3): 376 – 390.
- [15] 张帅, 王俊杰, 李爱莲, 等. 集成正态云和动态扰动的哈里斯鹰优化算法[J]. *小型微型计算机系统*, 2023, 44(6): 1153 – 1161.  
ZHANG S, WANG J J, LI A L, et al. Harris Hawk optimization algorithm integrating normal clouds and dynamic perturbations[J]. *Journal of Chinese Computer Systems*, 2023, 44(6): 1153 – 1161. (in Chinese)
- [16] 李德毅, 刘常昱. 论正态云模型的普适性[J]. *中国工程科学*, 2004, 6(8): 28 – 34.  
LI D Y, LIU C Y. Study on the universality of the normal cloud model[J]. *Engineering Science*, 2004, 6(8): 28 – 34. (in Chinese)
- [17] 赵志刚, 林玉娇, 尹兆远. 基于自适应惯性权重的均值粒子群优化算法[J]. *计算机工程与科学*, 2016, 38(3): 501 – 506.  
ZHAO Z G, LIN Y J, YIN Z Y. A mean particle swarm optimization algorithm based on adaptive inertia weight[J]. *Computer Engineering & Science*, 2016, 38(3): 501 – 506. (in Chinese)
- [18] THIEL C, NEUMANN K, LUDWAR F, et al. Coating damage localization of naval vessels using artificial neural networks[J]. *Ocean Engineering*, 2019, 192: 106560.
- [19] 谭浩, 陈聪, 沈滨. PCP 系统的优化对船舶水下电场的抑制作用[J]. *国防科技大学学报*, 2021, 43(1): 139 – 144.  
TAN H, CHEN C, SHEN B. Restraining effect of PCP system optimization on electric field signal in the sea[J]. *Journal of National University of Defense Technology*, 2021, 43(1): 139 – 144. (in Chinese)
- [20] 徐庆林, 王向军, 张建春, 等. 温度对舰船阴极保护和腐蚀静电场的影响[J]. *国防科技大学学报*, 2019, 41(4): 182 – 189.  
XU Q L, WANG X J, ZHANG J C, et al. Influence of temperature on the cathodic protection and corrosion electrostatic field of ships[J]. *Journal of National University of Defense Technology*, 2019, 41(4): 182 – 189. (in Chinese)
- [21] ROSTAGHI M, AZAMI H. Dispersion entropy: a measure for time-series analysis [J]. *IEEE Signal Processing Letters*, 2016, 23(5): 610 – 614.
- [22] GAN X, LU H, YANG G Y. Fault diagnosis method for rolling bearings based on composite multiscale fluctuation dispersion entropy[J]. *Entropy*, 2019, 21(3): 290.